

## **2**

### **Revisão Bibliográfica**

#### **2.1.**

##### **Degradação do Desempenho da Turbina a Gás**

O desempenho de uma turbina a gás se deteriora ao longo da vida de operação devido à degradação dos seus componentes por onde passa o fluido de trabalho. As causas mais comuns desta degradação são falhas físicas que resultam em mudanças no desempenho termodinâmico das turbinas a gás, medido em termos de eficiências e vazões volumétricas dos componentes, as quais produzem mudanças nos parâmetros observados da máquina, tais como temperatura, pressão, velocidade de rotação e consumo específico de combustível [5].

Para se garantir a disponibilidade e confiabilidade das turbinas a gás é necessária uma manutenção efetiva. Com o desenvolvimento das tecnologias de diagnóstico, o processo de manutenção preventivo das turbinas a gás vem sendo complementado, e, em alguns casos, substituído, por um processo de manutenção centrado na confiabilidade baseado na monitoração do comportamento da máquina e no diagnóstico das falhas [5].

#### **2.2.**

##### **Falhas no Caminho do Gás**

A deterioração do desempenho da turbina a gás é resultado de vários tipos de falhas dos componentes que estão no caminho do gás, sendo os principais o compressor, o combustor e a turbina propriamente dita (expansor). Nesta seção serão apresentadas as falhas mais comuns que podem ocorrer no caminho do gás, seus efeitos e suas implicações.

- Acúmulo de Sujeira:

O acúmulo de sujeira no compressor, ou *compressor fouling*, pode ser definido como o acúmulo de depósitos nas superfícies das pás, que dá origem a um aumento da rugosidade, mudanças nos perfis aerodinâmicos e redução da área da garganta na entrada da turbina a gás [6]. Isto pode resultar na redução da razão de pressão do compressor, da eficiência e da margem de *stall*, além de levar à erosão, corrosão e desbalanceamento do aerofólio.

Estes depósitos não só causam a degradação do desempenho do compressor como também afetam indiretamente o desempenho da turbina a gás, alterando o consumo de combustível, a temperatura de exaustão e as emissões.

Estima-se que acima de 70% da degradação do desempenho global da máquina pode ser atribuída ao *compressor fouling*. Na turbina, também pode ocorrer acúmulo de depósitos nas palhetas causado pelas cinzas resultantes da queima do combustível [7].

- Aumento da Folga de Topo (*Increaded Tip Clearence*):

O *tip clearance* é a folga entre as palhetas e a carcaça, tanto do compressor quanto da turbina, e seu aumento é causado pelo desgaste decorrente do contato entre a ponta da palheta e a carcaça do equipamento, principalmente durante os períodos de partida. Este fenômeno leva a uma diminuição da eficiência e da capacidade de bombeamento no compressor e do aproveitamento energético no expensor.

- Erosão:

A erosão é causada por partículas duras que colidem com os componentes no caminho do gás e removem material de suas superfícies. O resultado pode ser um aumento da rugosidade, *tip clearance* e mudança do perfil aerodinâmico [5].

- Corrosão:

A corrosão é o fenômeno de degradação causado pela exposição do equipamento ao ambiente. Em turbinas a gás a corrosão pode causar uma perda progressiva de material nos componentes do caminho do gás devido à reação química com o ar de entrada ou com o enxofre no combustível.

A corrosão no compressor leva à degradação das propriedades do material, ao aumento da rugosidade e, finalmente, à queda de vazão e de eficiência isentrópica. Em se tratando da turbina, a corrosão pode levar a um aumento da vazão e à redução da eficiência isentrópica [5].

- Danos por Objetos Estranhos ou Domésticos:

O *Foreign Object Damage* (FOD) e o *Domestic Object Damage* (DOD) são danos produzidos pelo impacto de objetos estranhos (admitidos na seção de entrada do compressor) e domésticos (provenientes de desprendimentos das partes do próprio equipamento em contato com o fluido de trabalho), respectivamente.

FOD e DOD podem resultar na concentração de tensões, em quebras, em tensões residuais e em danos micro estruturais no caminho do gás. Estes efeitos podem resultar em uma grande redução da eficiência do componente [6].

### **2.2.1. Índices de Falhas no Caminho do Gás**

A condição dos componentes da turbina a gás é caracterizada pelos parâmetros da máquina. Geralmente dois parâmetros característicos podem ser observados para o compressor e a turbina: a vazão e a eficiência isentrópica. Com o objetivo de se determinar a severidade da falha no caminho do gás, um índice com cada tipo de falha pode ser representado pelo desvio da porcentagem das características dos componentes da turbina a gás [6].

As falhas da turbina podem ser quantificadas como segue:

- Acúmulo de Sujeira: redução de vazão e de eficiência no compressor e na turbina.
- Erosão/Corrosão: redução da eficiência isentrópica dos componentes afetados; redução da vazão no compressor; aumento da vazão na turbina.
- FOD/DOD: grande redução de eficiência nos componentes afetados.
- *Tip Clearance*: redução de vazão e de eficiência. A eficiência é mais sensível ao tip clearance do que ao acúmulo de sujeira.

Normalmente falhas no caminho do gás têm características ou assinaturas distintas, mas algumas podem ter assinaturas idênticas e podem requerer outra técnica de monitoração, como a análise de vibração, para distinguí-las.

### **2.3. Métodos de Diagnóstico Baseados na Análise do Caminho do Gás**

A identificação exata do componente responsável pela degradação de desempenho facilita a escolha da ação de recuperação a ser empreendida. A análise do caminho do gás ou GPA (do inglês, *Gas Path Analysis*) trata principalmente de diagnósticos de falhas dos componentes por onde o fluido de trabalho escoar.

Os métodos de análise do caminho do gás são baseados na idéia de que qualquer mudança no desempenho dos componentes que estão em contato com o caminho do gás resultará na mudança dos parâmetros termodinâmicos. Se esta segunda mudança for rastreada, a causa original pode, em princípio, ser detectada [8].

Alguns dos métodos mais utilizados no diagnóstico de falhas do caminho do gás são: Árvore de Falhas; Análise do Caminho do Gás

Linear; Análise do Caminho do Gás Não-Linear, Algoritmos Genéticos, Sistemas Especialistas e Redes Neurais Artificiais.

### **2.3.1.**

#### **Árvore de Falhas**

A abordagem mais antiga de técnicas de diagnóstico é a análise da árvore de falha ou *Fault Tree Analysis* (FTA), que é uma análise dedutiva de falhas que são focadas em um evento particular (indesejável) e que prevê um método para determinar as causas do mesmo [9]. Este evento indesejável é o evento principal do diagrama de árvore de falhas construído para um determinado sistema. Para o sucesso da análise da árvore de falhas, é necessária uma escolha cuidadosa do evento principal. Uma escolha muito geral pode ocasionar uma análise incompleta e uma escolha muito específica pode também não gerar uma visão completa do sistema [10].

Este método, de quase cinquenta anos, que pode ser usado para analisar a maioria dos problemas de confiabilidade das indústrias. É baseado em duas idéias: a primeira de que uma falha em um sistema pode gerar falhas subseqüentes e a segunda de que um problema pode ser rastreado de volta para a sua origem [11].

Através das árvores de falha, é possível realizar uma análise qualitativa, verificando quais eventos e suas combinações levam à ocorrência do evento principal. Além disso, pode-se também realizar uma análise quantitativa a partir da probabilidade do evento principal ocorrer em função das probabilidades dos eventos básicos. Nas seqüências de falhas que deverão ocorrer para que ocorra o evento principal, podem ser inseridas as probabilidades de cada defeito e assim calcular a probabilidade que o evento principal ocorra [12].

### **2.3.2.**

#### **Análise do Caminho do Gás: Modelo Linear**

A relação entre os parâmetros dependentes da turbina a gás (temperatura, pressão, vazão mássica, etc.) e os parâmetros

independentes (razão de pressão, vazão volumétrica e eficiência dos componentes) é altamente não linear [5]. Esta relação pode ser expressa como segue [13]:

$$z = h(x, y) + v + b \quad (1)$$

Onde  $z$  é o vetor de parâmetros dependentes, obtidos através de medições nos componentes,  $x$  é o vetor de parâmetros independentes, isto é, parâmetros de desempenho dos componentes,  $y$  é o vetor que inclui as condições ambientais,  $v$  é o vetor que considera o ruído nas medições,  $b$  é o vetor que considera as características particulares (ruídos) do sensor (sensor *bias*) e  $h( )$  é uma função não linear, fornecida pelo programa de simulação [13].

Os métodos do GPA linear são baseados na hipótese de que as variações nos parâmetros independentes são relativamente pequenas e que o conjunto de equações pode ser linearizado ao redor de um determinado ponto de operação em regime permanente [13]. Assim, as equações linearizadas podem ser expressas como:

$$z = Hx \quad (2)$$

Onde  $H$  é a matriz de coeficientes de influência, ICM (*Influence Coefficient Matrix*). Desta maneira, o desvio dos parâmetros dos componentes pode ser calculado em função da matriz de coeficientes de falha, FCM (*Fault Coefficient Matrix*), ou matriz de diagnóstico, a qual é a inversa da matriz de coeficientes de influência [5]:

$$\Delta x = H^{-1} \Delta z \quad (3)$$

A geração da matriz de coeficientes de falha baseia-se na implantação de degradações conhecidas dos componentes. Este método é relativamente simples e fornece soluções rápidas nos processos de diagnóstico de turbinas a gás [5]. Em [13] é salientado que devido ao fato deste método ser baseado na suposição de que a matriz de coeficientes

de influência possui inversa, o número de parâmetros de desempenho tem que ser menor ou igual ao número de parâmetros medidos no componente. Caso contrário, outras técnicas de diagnóstico devem ser usadas. Esta condição é, às vezes, difícil de ser satisfeita devido ao número limitado de medições disponíveis [5]. As principais limitações deste método são [13]: (i) a necessidade de uma quantidade pertinente de medições, (ii) a incapacidade de lidar com ruído e falha de sensores, e (iii) a suposição de linearidade, a qual é somente aceitável para pequenas faixas dos valores dos parâmetros de influência numa determinada condição de operação.

### **2.3.3.**

#### **Análise do Caminho do Gás: Modelo Não-Linear**

Uma maneira de melhorar a precisão das estimações é tratar de resolver a relação não linear entre os parâmetros considerados saudáveis e os valores obtidos das medições usando um processo iterativo, tal como descrito resumidamente em [6]. Neste processo iterativo, uma aproximação linear é empregada recursivamente e uma solução exata é obtida através do uso da técnica de Newton-Raphson. Essencialmente, via esta abordagem, uma ICM é gerada levando em consideração uma pequena deterioração do desempenho dos componentes; logo a ICM é invertida para calcular o vetor de variações nos parâmetros de desempenho dos componentes. A partir dos resultados calculados, uma nova ICM é gerada e o processo é recursivamente repetido até que um definido critério de convergência que minimiza o erro (diferença entre valor medido e estimado) é atingido, ou o processo pára depois de um determinado número de iterações [13].

### **2.3.4.**

#### **Algoritmos Genéticos**

O método de diagnóstico baseado em algoritmos genéticos é uma abordagem teoricamente similar àqueles métodos baseados em modelos não lineares. Em outras palavras, algoritmos genéticos são aplicados como uma ferramenta efetiva de otimização para obter um conjunto de

parâmetros (independentes) dos componentes que são usados para produzir um conjunto de parâmetros dependentes estimados através de um modelo não linear de turbina a gás que correlaciona melhor os valores obtidos das medições. A solução é obtida quando a função objetivo, a qual é a diferença entre os valores dos parâmetros dependentes medidos e estimados, atinge seu mínimo valor [13].

Os algoritmos genéticos são uma técnica de busca e otimização e, comparado com outras técnicas de otimização, apresentam algumas características únicas. Entre estas características podem ser mencionadas a não necessidade de funções que possuam derivadas, isto é, qualquer função pode ser otimizada, o uso de rotinas de busca global, as quais evitam a obtenção de resultados errados originados pela presença de mínimos/máximos locais, são apropriados para problemas de diagnóstico com um limitado número de instrumentos de medição, entre outras.

Mas apesar das vantagens oferecidas pelos métodos de diagnóstico baseados em algoritmos genéticos, eles trabalham com tempos de convergência prolongados para a detecção das falhas. Melhorias para que a convergência da solução seja mais rápida e mais precisa são necessárias [6].

### **2.3.5. Sistemas Especialistas**

Um sistema especialista (ES, *Expert System*) é um programa de computador que imita o pensamento humano para resolver problemas complexos. Normalmente sistemas especialistas consistem em conhecimento base, sistema de inferência ou dedução, e interface com o usuário [5]. A parte principal de um sistema especialista é o conhecimento base, o qual contém as relações entre as causas e as possíveis falhas. Tais relações podem ser derivadas de manuais de manutenção fornecidos pelo fabricante da máquina, da experiência acumulada de diferentes máquinas do mesmo tipo durante a sua vida útil e de códigos



computacionais usados para a simulação que reproduzem o comportamento da máquina quando uma ou mais falhas ativas afetam um ou mais componentes.

Diferentes sistemas especialistas têm sido desenvolvidos ao longo dos anos. Alguns deles realizam diretamente o diagnóstico usando os parâmetros da máquina (razão de pressão, consumo específico de combustível, potência, velocidade de rotação, etc.), outros utilizam somente as tendências dos principais parâmetros da máquina. Por fim, têm-se sistemas especialistas que guiam o usuário até a detecção da falha requerendo, em cada etapa, informação particular dos parâmetros da máquina [6].

Uma detalhada revisão dos diferentes tipos de sistemas especialistas utilizados para o diagnóstico de turbinas a gás é mostrado por [5]. O autor ressalta que os primeiros diagnósticos de falhas das turbinas a gás foram realizados pelos usuários comparando os padrões de desvio dos parâmetros medidos com as características de falha fornecidas pelos fabricantes dos equipamentos, o que constitui um padrão de reconhecimento/correlação, uma das metodologias usadas em ESs.

### **2.3.6. Redes Neurais Artificiais**

As redes neurais artificiais (RNA) são paradigmas de processamento da informação inspirados no sistema nervoso biológico. Diferentes tipos de redes neurais têm sido utilizados na detecção de falha em turbinas a gás desde 1990, incluindo redes de treinamento supervisionado e redes de treinamento não-supervisionado [14]. A aplicação de redes neurais em diagnóstico de falhas em turbinas a gás tem sido explorada usando os seguintes tipos de redes: rede neural de alimentação progressiva com retropropagação (*multilayer perceptron - MLP*), redes neurais probabilísticas (*probabilistic neural network - PNN*), redes auto-organizáveis (*self-organizing map - SOM*), redes RBF (*radial basis function*), entre outras [9].

A RNA tem um amplo leque de aplicações devido à sua excelente capacidade de generalização. Vem sendo provado que a RNA é capaz de reconhecer as condições de falhas em máquinas mesmo quando as medições do equipamento são ruidosas ou incompletas [14]. As redes neurais artificiais e suas vantagens serão discutidas com maior detalhe no capítulo 3.

#### **2.4. Estado da Arte**

No trabalho de Li [5] é feita uma análise comparativa dos diversos métodos de diagnóstico. O autor enfatiza que aqueles baseados em modelos lineares e não lineares têm um claro significado físico, enquanto que os métodos como redes neurais, baseados em regras, são gerados usando conhecimento experimental. Os métodos baseados em inteligência artificial são mais complexos quando comparados aos métodos baseados em modelagem.

Os métodos lineares e não lineares (baseados no GPA), as redes neurais e os ESs baseados em regras (uma vez criadas as bibliotecas com as regras) realizam o processo de diagnóstico mais rápido que os métodos não lineares baseados na otimização convencional ou em algoritmos genéticos [5].

De acordo com o autor, todos os métodos, exceto os métodos de GPA baseados em modelagem linear e não linear, podem lidar com ruídos de medições e dos sensores. A Figura 1 mostra, em forma comparativa, o tempo computacional requerido no processo em função da complexidade das diversas metodologias de diagnóstico de falhas em turbinas a gás [5].

No trabalho de Marinai et al. [13], é também feita uma análise comparativa entre as diferentes metodologias de diagnóstico. São considerados os conceitos de múltiplas falhas, descritas como sendo mais adequadas para os componentes da máquina que se deterioram lentamente, e de falhas simples, adequadas para uma mudança rápida da

tendência do comportamento de um componente. Assim, os autores indicam que todos os métodos baseados em inteligência artificial são mais adequados para problemas de falhas simples, já que os mesmos conseguem aproximar todas as possíveis soluções para treinar o sistema usando um limitado número de dados. As técnicas baseadas em inteligência artificial não apresentam a tendência de distribuir as falhas sobre um grande número de componentes e sensores, e, pelo contrário, apresentam uma boa capacidade de “concentração” para identificar o componente com falha.

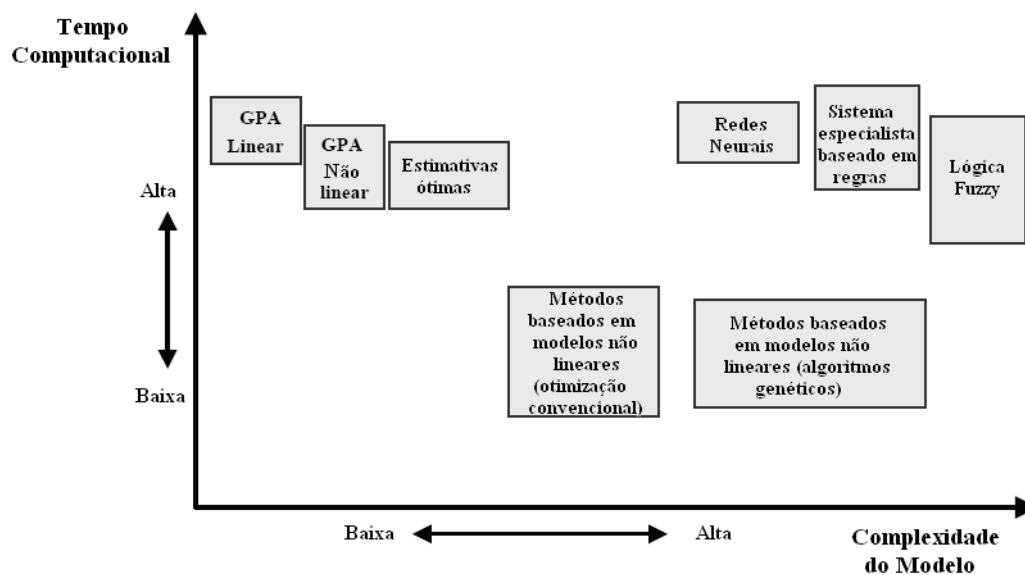


Figura 1 – Comparação dos métodos de diagnóstico em termos de velocidade de processamento e complexidade do modelo [5].

Ghoreyshi et al. [4] utilizou redes neurais para superar limitações da técnica de GPA que decorrem da existência de sensores defeituosos. Neste trabalho é ressaltada a capacidade das RNAs de aprender relacionamentos não lineares que surgem entre a degradação dos componentes das turbinas a gás e o desvio do comportamento esperado, apresentado pelos parâmetros de funcionamento destas, segundo o que foi definido pelos fabricantes.

A rede neural empregada foi do tipo MLP – *Multilayer Perceptron* (rede de múltiplas camadas com alimentação progressiva) com seis nós na entrada, vinte nós em uma camada escondida e um (às vezes dois) nós na saída. Para o treinamento, do tipo supervisionado, foi empregado o algoritmo de Newton com a modificação de Levenberg-Marquadt [4]. Para detecção de defeitos, a rede neural classificou cada amostra de dados como sendo “turbina defeituosa” ou “turbina saudável”. O percentual de acerto obtido foi de 100% para o caso de falhas na eficiência da turbina e do compressor e também para a vazão do compressor. No caso da vazão da turbina o percentual de acerto foi de 95,43% [4].

Para a detecção da origem do defeito (quando este se trata de degradação da turbina a gás), o objetivo foi identificar o que ocasionou o mesmo: se foi o entupimento do compressor, ou se foi a erosão da turbina. O resultado encontrado no caso do entupimento do compressor foi um percentual de acerto de 100% e o percentual encontrado no caso de erosão da turbina foi de 96,62%.

No trabalho de Dambrosio et al. [15] foi desenvolvida uma ferramenta de diagnóstico baseada em redes neurais de alimentação progressiva com retropropagação (MLP). Esta ferramenta é composta de dois tipos diferentes de MLP: o primeiro opera com o objetivo de avaliar a influência de uma única variável para cada condição de falha. Já com o objetivo de detectar falhas causadas por condições combinadas, um segundo tipo de MLP foi incluído na ferramenta. Após detectar a condição dominante, o segundo tipo MLP remove a contribuição desta condição do parâmetro de falha e reinicia o processo de detecção das condições de falhas.

Neste trabalho foram considerados cinco variáveis cujos desvios, de acordo com os autores, caracterizam as condições da falha da turbina a gás, sendo elas: a vazão mássica de ar na entrada, a temperatura e a pressão de descarga no compressor, a temperatura de saída do combustor e a temperatura de saída da turbina. Além disso, também

foram considerados cinco tipos de falha: falhas no rotor da turbina, deterioração do bocal da turbina, acúmulo de sujeira no bocal, falhas no compressor e acúmulo de sujeira no compressor [15].

A ferramenta desenvolvida foi organizada em várias MLPs para que uma única rede não seja responsável por todo diagnóstico. Como pode ser visto na Figura 2, a ferramenta é composta por duas camadas de MLP: a primeira, formada por 25 MLPs, e a segunda, formada por 5 MLPs. Cada MLP da primeira camada foi treinada para avaliar a influência que cada uma das variáveis sofre em cada condição de falha [15].

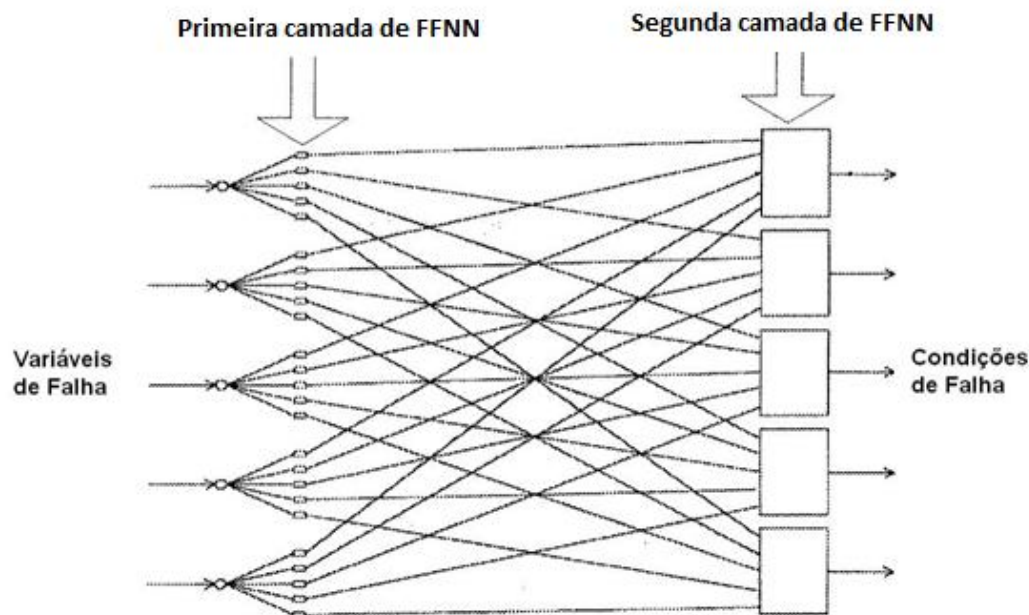


Figura 2 – Ferramenta de diagnóstico baseado em MLP [15].

Analisando os resultados, é possível constatar que a ferramenta baseada em MLP criada por Dambrosio et al. [15], testada em um modelo matemático previamente desenvolvido pelo autor, detecta 100% das falhas ocasionadas por uma única condição e 70% das falhas ocasionadas pela combinação de mais de uma condição.

Sampath e Singh [16] desenvolveram um modelo híbrido de diagnóstico de defeitos, que é empregado tanto para identificar não conformidades no desempenho de componentes da turbina, quanto para identificar falhas nos sensores dispostos nesses componentes. O modelo híbrido consiste de dois estágios: o primeiro é baseado na utilização sucessiva de redes neurais distintas, que, dado um padrão de entrada do modelo, determina qual classe de defeito é associada a este padrão; já o segundo estágio, baseado em algoritmos genéticos, estabelece a severidade do defeito associado ao padrão apresentado na entrada do modelo, uma vez conhecida a classe do defeito.

Segundo os mesmos autores, cada padrão de dados de operação pode caracterizar desde o funcionamento “saudável” da turbina até uma anormalidade dentre as seguintes: defeito em sensores apenas; defeito apenas em componentes – dividido em defeito em um único componente e defeito em múltiplos componentes; e defeito em sensores e componentes (não concomitantes).

Das redes neurais empregadas, uma era auto-associativa com cinco camadas, onde três eram escondidas, que foi utilizada para a classificação do sensor defeituoso, sendo as outras redes de múltiplas camadas. Foram utilizadas redes com quatro camadas: uma de entrada; uma de saída; e duas escondidas (cada qual com 25 ou 30 neurônios). O paradigma de rede neural utilizado foi o da alimentação progressiva com retropropagação e o algoritmo de treinamento empregado foi o do gradiente conjugado.

Os resultados obtidos na classificação dos defeitos presentes nas turbinas apresentaram uma média de confiabilidade de 99%. A alta confiabilidade do modelo híbrido indica que este representa uma estratégia segura para o desenvolvimento de um sistema de diagnóstico de defeitos em turbinas.

Matuck et al. [17] desenvolveram um modelo não linear baseado em redes neurais para o diagnóstico de turbinas a gás. O modelo de rede

neural utilizado foi uma MLP implementada no programa Matlab, com algoritmo de retropropagação para uma, duas ou três camadas escondidas, com dois a dez neurônios para cada camada escondida, a fim de verificar qual a melhor arquitetura para cada detecção de falha em particular.

Foram utilizados como dados de entrada das redes neurais dados “medidos”, obtidos através de um programa computacional que simula turbinas a gás. Estes dados foram divididos em três partes: metade para treinamento, 25% para validação e 25% para teste das redes neurais.

Para cada tipo de falha (simples, dupla ou tripla) foi observada qual seria a melhor configuração. No caso de falhas simples, todas as redes neurais treinadas por [17] apresentaram boa capacidade de reconhecimento de falhas. Para falhas duplas, as redes neurais apresentaram maior dificuldade em classificar corretamente os dados. Para detecção de falhas triplas foram necessários maiores tempos de treinamento das redes neurais, devido à maior complexidade das interpolações. Mesmo não atingindo o erro mínimo estabelecido, todo conjunto de dados de teste foi classificado corretamente.

A bibliografia revisada apresenta os principais métodos de diagnóstico de falhas em turbinas a gás, além dos resultados obtidos com a aplicação da metodologia de Redes Neurais Artificiais na detecção destas falhas, mostrando a possibilidade de aplicação desta metodologia no equipamento escolhido para este estudo.

Os trabalhos com RNA apresentados servem de base para o desenvolvimento desta dissertação com o uso de redes neurais do tipo MLP. Além disso, a idéia apresentada por Sampath e Singh de se utilizar dois grupos distintos para diagnosticar falhas (classificação e quantificação) também foi utilizada, mas apenas com o uso de RNAs.