



**SNPTEE
SEMINÁRIO NACIONAL
DE PRODUÇÃO E
TRANSMISSÃO DE
ENERGIA ELÉTRICA**

GPT 20
14 a 17 Outubro de 2007
Rio de Janeiro - RJ

GRUPO II

GRUPO DE ESTUDO DE PRODUÇÃO TÉRMICA E FONTES NÃO CONVENCIONAIS – GPT

FERRAMENTAS PARA MONITORAMENTO E DIAGNÓSTICO DE DESEMPENHO DE TURBINAS A GÁS

**Sandro Barros Ferreira* Fabiano A. dos Santos César Celis Belmiro R. Valente
Paula de M.R. Pinto Vinicius P. de Avellar Marcelo Assato Sergio Leal Braga**

**Grupo de Turbinas a Gás e Termelétricas – GT²
INSTITUTO DE ENERGIA DA PUC - IEPUC
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO – PUC-RJ**

RESUMO

O presente trabalho revê o histórico dos principais métodos e técnicas de avaliação do desempenho e diagnóstico de falhas em turbinas a gás. Métodos de avaliação de desempenho de turbinas a gás como aqueles referidos aos fatores de correção, à análise termodinâmica do caminho do gás (GPA, *Gas Path Analysis*) e às redes neurais são apresentados neste texto. Das técnicas de diagnóstico de falhas em turbinas a gás, as baseadas na análise do caminho do gás em modelos lineares, não lineares e em inteligência artificial são apresentadas.

É objetivo deste trabalho, apresentar também o estágio atual do modelo em redes neurais, desenvolvido pelo *Grupo de Turbinas a Gás e Termelétricas – GT²* do Instituto de Energia da PUC-RJ – IEPUC. Este modelo será empregado na avaliação do desempenho e na previsão de falhas das turbinas a gás da usina termelétrica Norte Fluminense – UTENF. As turbinas a gás que compõem o parque da usina são SIEMENS WESTINGHOUSE modelo 501FD com potência ISO de 186 MW, de um eixo e de rotação sincronizada. O modelo em redes neurais, no estágio atual foi treinado para prever o comportamento termodinâmico das turbinas a gás, e apresentou grande acurácia em seus resultados, comparativamente a dados de catálogo da turbina a gás e aos valores calculados pelo software TURBOMATCH, responsável pelo treinamento da rede.

PALAVRAS-CHAVE

Geração Termelétrica, Turbinas a Gás, Diagnóstico de Falhas, Desempenho de Centrais Termelétricas, Redes Neurais.

1.0 - INTRODUÇÃO

É conhecido que o desempenho de uma turbina a gás se deteriora durante sua operação devido à degradação dos componentes através dos quais escoo o gás. As causas mais comuns de degradação são [1]: (i) *Fouling*, a qual consiste na acumulação de depósitos nas superfícies das pás, e que por sua vez dá origem a um aumento da rugosidade, mudanças nos perfis aerodinâmicos e redução da área da garganta de entrada, (ii) *Tip Clearance*, originado como consequência da erosão e que leva a uma diminuição da eficiência e da vazão volumétrica, (iii) erosão, (iv) corrosão e (v) danos produzidos pelo impacto de objetos domésticos (provenientes de desprendimentos das partes em contato com o fluido de trabalho) e estranhos (ingeridos na seção de entrada ao compressor) nos componentes através dos quais escoo o gás. Estas falhas físicas resultam em mudanças no desempenho termodinâmico das turbinas a gás, medido em termos de eficiências e vazões volumétricas dos componentes, as quais por sua vez produzem mudanças nos parâmetros observados da máquina tais como temperatura, pressão, velocidade de rotação e consumo específico de combustível [2].

A fim de manter um alto nível de disponibilidade e confiabilidade das turbinas a gás, uma manutenção efetiva é essencial. 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, baseando-se no monitoramento do comportamento da máquina e no diagnóstico antecipado das falhas [2].

Dentre as diversas abordagens para o monitoramento da condição e o diagnóstico de falhas em turbinas a gás, citando-se a inspeção visual, os exames usando raios X, o monitoramento de vibrações e ruído, o monitoramento da temperatura de exaustão da turbina, entre outras, o diagnóstico baseado na análise de desempenho da turbina a gás é a ferramenta mais poderosa no diagnóstico antecipado da falha. Neste tipo de abordagem, a análise dos parâmetros que caracterizam o caminho percorrido pelo gás na turbina, é capaz de prever a degradação dos componentes em contato direto com o gás [2].

Em um sentido fundamental, o monitoramento do desempenho e diagnóstico de falhas envolve o processamento de medições da condição da máquina. Assim, em todos os métodos de monitoramento do desempenho e diagnóstico de falhas atualmente usados, os quais foram desenvolvidos ao longo das últimas décadas, uma comparação entre o valor de algum parâmetro de uma máquina que está sendo examinada e o valor correspondente de uma máquina considerada como “saudável” é realizada a fim de derivar as conclusões relevantes [3]. Os parâmetros utilizados e a forma de derivá-los é o que caracteriza cada diferente método de diagnóstico [4] (citado por [3]). De maneira geral, as técnicas de monitoramento do desempenho e diagnóstico de falhas das turbinas a gás não têm mudado muito desde a década de 1970, e são centrados no processo conhecido como GPA, *Gas Path Analysis*, ou, em português, Análise do Caminho do Gás [3].

2.0 - MÉTODOS DE AVALIAÇÃO DE DESEMPENHO DE TURBINAS A GÁS

O monitoramento contínuo e em tempo real do desempenho das plantas de potência baseadas em turbinas a gás, teve início na década de 1970. Toda a teoria utilizada na avaliação de desempenho das turbinas a gás foi implementada em modelos que avaliavam a performance da máquina através de fatores de correção fornecidos pelos fabricantes e através da análise termodinâmica do processo. Alguns autores se destacam no desenvolvimento das técnicas de avaliação de desempenho, dentro das referências amplamente reconhecidas e aceitas, incluem-se o livro *Gas Turbine Theory* dos autores Cohen, Rogers e Saravanamuttoo [2], o livro *Gas Turbine Performance* de Walsh e Fletcher [5] e o livro *Gas Turbine Engineer Handbook* do autor Meherwan Boyce [6].

São três os principais métodos de se avaliar a performance das turbinas a gás: o método dos fatores de correção [3-5], o método de análise do caminho do gás (GPA, *Gas Path Analysis*) [2] e o método de redes neurais [1,6].

O método dos parâmetros de correção se baseia em corrigir a curva de desempenho da turbina a gás em seu ponto de projeto através de fatores de correção disponibilizados pelo fabricante da turbina a gás. Esses fatores corrigem as condições de temperatura, pressão, umidade, carga, degradação entre outros. Inseridos os fatores de correção às condições de projeto obtém-se o novo padrão de operação do equipamento. Tipicamente o cálculo da curva da correção prevê a potência gerada, as taxas do calor e a temperatura de exaustão da turbina.

O método de análise do caminho do gás (GPA, *Gas Path Analysis*) é baseado na análise termodinâmica do processo. A avaliação termodinâmica do caminho do gás prediz o comportamento com maior nível de requinte e complexidade que os demais métodos, por ser fenomenológico.

Por fim tem-se o método de avaliação da performance de turbinas a gás baseado em redes neurais, este método baseia-se no treinamento de uma rede neural artificial (RNA) a fim de que esta reproduza o funcionamento da máquina térmica. Para tal a rede neural recebe informações de operação da turbina a gás e é treinada a inferir novas condições de funcionamento baseadas em sua experiência.

O trabalho de [7], apresenta a Tabela 1, nesta é feito um comparativo entre os três métodos de avaliação de desempenho de turbinas a gás.

Tabela 1 - Vantagens e Desvantagens das Técnicas de Monitoramento do Desempenho de Turbinas a Gás.

Método	Vantagens	Desvantagens
Fatores de Correção	<ul style="list-style-type: none"> Fácil implementação; Alta acurácia dentro do range das curvas de operação da turbina a gás. 	<ul style="list-style-type: none"> Não apresenta informação sobre a performance dos sub-sistemas da turbina a gás; Baixa acurácia a valores fora do range das curvas de operação da turbina a gás.
Análise do Caminho do Gás - GPA	<ul style="list-style-type: none"> Aplicável a qualquer range de operação da turbina a gás; Fornecer a performance dos sub-sistemas da turbina a gás. 	<ul style="list-style-type: none"> Maior dificuldade de implementação; Não pode ser tão exato quanto o método dos fatores de correção.
Redes Neurais	<ul style="list-style-type: none"> Não são requeridas informações sobre as curvas de operação da turbina a gás; Forte tolerância a não-acurácia dos valores mensurados. 	<ul style="list-style-type: none"> Baixa acurácia a valores fora do range de treinamento da rede; Não é baseado nos princípios termodinâmicos (não fenomenológico).

3.0 - MÉTODOS DE DIAGNÓSTICO DE FALHAS EM TURBINAS A GÁS BASEADAS NO GPA

No processo de diagnóstico de falhas baseado no GPA, calculam-se as variações nos valores dos parâmetros de desempenho dos componentes (por exemplo: eficiência e vazão volumétrica) dados um conjunto de medições (por exemplo, temperatura, pressão, velocidade de rotação e consumo de combustível) através da máquina [7]. A partir desta matriz de desvio, diversas técnicas são empregadas na análise destas informações, buscando-se a origem da falha ou indicando a tendência desta. A seguir são descritas as diversas metodologias de diagnóstico

de falhas em turbinas a gás baseadas no GPA, que durante as três últimas décadas foram desenvolvidas. Esta descrição das metodologias será feita seguindo a classificação apresentada em [8].

3.1 Métodos baseados em modelos lineares

Estes métodos 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 [7]. Assim, as equações linearizadas seguem a forma da equação 1, a seguir:

$$z = Hx \quad \text{Equação 1}$$

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 [8]:

$$\Delta x = H^{-1} \Delta z \quad \text{Equação 2}$$

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 falhas em turbinas a gás [8]. Marinai et al. [7] salientam 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 têm que ser menor ou igual ao número de parâmetros medidos no componente. Caso contrário, outras técnicas de diagnóstico devem ser usadas. Este requerimento é às vezes difícil de satisfazer devido ao número limitado de medições disponíveis [8]. As principais limitações deste método são [7]: (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.

Ao longo dos anos, algumas melhoras foram feitas para estimar os valores dos Δx através do uso da teoria da estimação ótima, tais como o processo de estimação por erro mínimo ou máxima probabilidade, técnicas WLSs (*weighted-least-squares*) filtros de Kalman, entre outras [8]. Estas técnicas também apresentam diversas limitações, como salientado em [7], uma das quais é o efeito de “*smearing*”, i.e., a distribuição dos valores das falhas sobre outros componentes diferentes ao componente que está sendo considerado na análise. A suposição de linearidade se torna completamente falsa quando as causas das deteriorações dos componentes se afastam da condição para a qual a matriz foi calculada. Esta consideração levou ao desenvolvimento dos modelos não lineares, os quais serão apresentados na seção seguinte [7].

3.2 Métodos baseados em modelos não lineares

Uma maneira de melhorar a precisão das estimativas 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 por [9]. 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 tomando 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 [7].

A fim de superar as limitações deste tipo de abordagem, quando somente um número limitado de medições está disponível e na presença de incertezas de medição (ruído e outras), técnicas de estimação como a versão não linear do método de filtros de Kalman e a abordagem de WLSs são usadas na prática [7]. As técnicas de filtragem mais comumente usadas são a EKF, *Extended Kalman Filter*, e a IEKF, *Iterated Extended Kalman Filter*. No entanto, foi demonstrado que ambas as técnicas produzem estimativas sub-ótimas devido à linearização das funções objetivo [7]. O diagnóstico das turbinas a gás também pode ser realizado minimizando a função objetivo através do uso de algoritmos genéticos [8]. Esta técnica será descrita com maior detalhe nas seções seguintes.

3.3 Métodos baseados em inteligência artificial

3.3.1 Redes neurais artificiais

As Redes Neurais Artificiais (RNAs), constituem um conjunto de paradigmas de representação de modelos matemáticos ou de classificação de feições, baseado no funcionamento de neurônios do cérebro humano.

O neurônio de uma RNA é representado segundo a Figura 1, na qual destacam-se: (i) Os sinais de entrada, x_i ; (ii) Os pesos associados às sinapses, w_k ; (iii) O combinador linear da saída, Σ ; (iv) O limiar, θ_k ; (v) A função de ativação, $\phi(\cdot)$ e (vi) Os sinais de saída, y_k . Onde,

$$y_k = \sum_{j=1}^p w_{kj} x_j \quad \text{Equação 3}$$

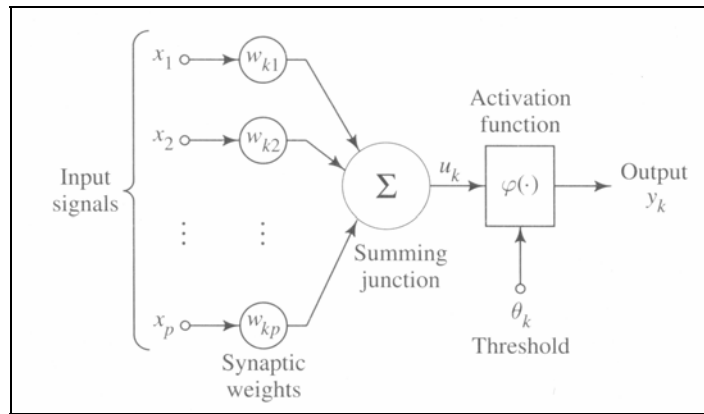


Figura 1 - Diagrama esquemático do modelo matemático do neurônio de uma RNA [10].

Na literatura, há diversos exemplos de aplicações de RNAs na detecção de falhas em turbinas a gás. Em geral, todos os experimentos utilizam um arcabouço comum:

- Há um programa (de computador) que implementa um modelo matemático que reproduz o funcionamento da turbina, que é utilizado para validar o experimento.
- Na entrada da RNA são utilizados valores teoricamente oriundos de sensores que são dispostos em vários pontos da turbina de forma a medir grandezas (pressão, temperatura, fluxo e etc.) relevantes à turbina, que ocorrem nos pontos em exame. De fato, o programa de simulação é que fornece os valores empregados.

Em [6] são utilizadas RNAs para poder superar limitações da técnica de GPA que decorrem da existência de sensores defeituosos. Os autores ressaltam, também, a capacidade das RNAs de aprender relacionamentos não lineares que surgem entre a degradação dos componentes das turbinas e o desvio, do comportamento esperado, apresentado pelos parâmetros de funcionamento destas, segundo o que fora definido pelos fabricantes.

Observa em [6] que as técnicas que empregam análise de caminho do gás (GPA) são bastante limitadas na presença de alguns contextos: (i) quando há sensores defeituosos; (ii) quando se verifica a presença de ruído nos sensores; (iii) quando há a presença de falhas combinadas no compressor e na turbina, concomitantemente.




Figura 2 - RNA empregada por [6] (por simplicidade, não foram indicadas todas as conexões da camada de entrada com a camada escondida)

A RNA empregada por [6] foi do tipo MLFF¹ com seis nós na entrada, vinte nós em uma camada escondida e um (às vezes dois) nós na saída. Para o treinamento, supervisionado, foi empregado o algoritmo de Newton com a modificação de Levenberg-Marquadt.

Em [11] é desenvolvido um modelo híbrido de diagnóstico de defeitos, o HDM (Hybrid Diagnosis Model), que é empregado tanto para identificar não conformidades no desempenho de componentes da turbina, quanto para identificar falhas nos sensores dispostos nesses componentes.

¹ MLFF – *Multiple Layers Feed Forward Network* – Rede de múltiplas camadas com alimentação progressiva.

O HDM consiste, funcionalmente, de dois estágios: o primeiro, qualitativo, baseado na utilização sucessiva de distintas redes neurais, que objetiva, dado um padrão (amostra oriunda dos sensores dispostos na turbina) de entrada do HDM, classificar qual (se alguma) a classe de defeito associada a esse padrão; e, o segundo, quantitativo, baseado em algoritmos genéticos, que objetiva estabelecer o *quantum* do defeito associado ao padrão apresentado na entrada do HDM, uma vez conhecida a classe do defeito. Reitere-se que cada padrão pode apresentar desde o funcionamento normal (saudável) da turbina, até uma situação de anormalidade enquadrada dentre uma das seguintes: (i) Defeito em sensores apenas; (ii) Defeito em componentes apenas; (iii) Defeito em sensores e componentes não simultâneos². A alta confiabilidade do HDM conforme resultados de [11] indica que ele representa uma estratégia segura para o desenvolvimento de um sistema de diagnóstico de defeitos em turbinas a gás.

É proposto em [12] uma solução para o contexto no qual há a presença simultânea de defeito num componente e no sensor associado a este componente. Sua abordagem se baseia no emprego de uma rede neural distinta daquela empregada em [11], que empregou o paradigma da alimentação progressiva com retro propagação (*feed forward back propagation*). Em [12] são propostas redes neurais baseadas no paradigma denominado Redes Neurais Probabilísticas (RNPs), ou *probabilistic neural networks*.

É descrito em [12] a forma de se produzir os padrões de dados para entrada na rede neural probabilística, com defeitos nos sensores e nos componentes. Nesta os defeitos (*faults*) são introduzidos em diversos pontos da operação, da mesma forma que o ruído, σ . Constatou-se que a qualidade do diagnóstico dos defeitos dos componentes da turbina é fundada na qualidade da medição dos parâmetros resultantes da operação da turbina, assim é de crucial relevância que a etapa inicial do diagnóstico seja a validação dos sensores [12]. Somente após validados os sensores será possível passar a mensurar se algum componente da turbina apresenta algum não conformidade [12].

Por meio do treinamento adequado da RNP, conseguiu-se detectar defeitos nos sensores variando de $\pm 0,4\%$ até $\pm 0,8\%$, o que é um resultado extremamente satisfatório, particularmente se comparado com o resultado obtido por outros métodos [12]. Por fim, uma vez que seja detectado que houve a presença de defeito no sensor, este efeito é filtrado e a medição filtrada é enviada para a rede neural probabilística, esta que ainda assim consegue identificar se algum componente apresenta, ou não, defeito.

3.3.2 Algoritmos genéticos

A pesquisa de novas técnicas com a capacidade de levar em consideração o ruído de medição e as características particulares dos sensores (*sensor bias*), e ao mesmo tempo com a capacidade de preservação da natureza não linear do sistema, levou ao desenvolvimento dos métodos de diagnóstico baseados em técnicas de otimização, entre os quais se encontra o método de diagnóstico baseado em algoritmos genéticos, GA (*Genetic Algorithm*) [13].

O método de diagnóstico baseado em algoritmos genéticos é uma abordagem teoricamente similar àqueles métodos baseados em modelos não lineares. Em outras palavras, GAs 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 (ou função custo), a qual é a diferença entre os valores dos parâmetros dependentes medidos e estimados, atinge seu mínimo valor [8].

Como indicado anteriormente, o método de diagnóstico baseado em algoritmos genéticos baseia-se numa técnica de otimização, a qual, em termos gerais, consiste em obter um conjunto de parâmetros dependentes a partir de um modelo de desempenho da turbina a gás, através da implantação de conjuntos de falhas conhecidas, e logo comparar estes com os valores medidos nos componentes da turbina a gás. O conjunto de parâmetros obtidos das simulações que mais se aproxima ao conjunto obtido através das medições indica as falhas correspondentes [13]. O diagrama esquemático da estratégia seguida nesta metodologia é mostrado na Figura 3.

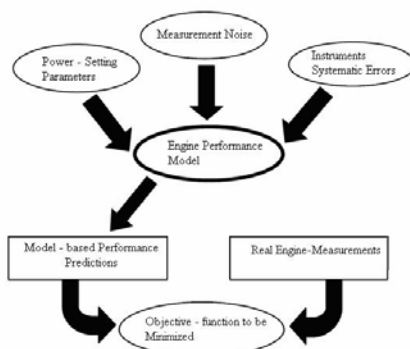


Figura 3 - Diagrama esquemático do algoritmo de diagnóstico [7].

² Quanto a esta restrição, ver o trabalho de [12].

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 [2]: (i) a não necessidade de funções que possuam derivadas, i.e., qualquer função pode ser otimizada, (ii) o uso de rotinas de busca global, as quais evitam a obtenção de resultados errados originados pela presença de mínimos/máximos locais, (iii) são apropriados para problemas de diagnóstico com um limitado número de instrumentos de medição, entre outras. Em [14] relatam o uso desta técnica de diagnóstico com relativo sucesso em turbinas a gás de ciclo simples, como também descrevem sua aplicação para o caso de ciclos avançados de turbinas. Os autores salientam que os resultados, quando comparados a aqueles obtidos através do uso de um modelo de desempenho desenvolvido pela Rolls-Royce, apresentam um alto nível de precisão ainda na presença de ruídos de medição e dos sensores.

Mais recentemente em [9] apresentam um trabalho no qual indicam que, apesar das tremendas vantagens que oferecem os métodos de diagnóstico baseados em algoritmos genéticos, eles sofrem de tempos de convergência prolongados para a detecção das falhas. A fim de superar esta deficiência, os autores propõem uma melhora à técnica, à qual chamam de “*Evolution Strategy*” ou simplesmente ES. No trabalho é indicado que a forma na qual é definida a função objetivo a ser minimizada afeta o tempo de convergência e o grau de precisão da solução obtida. O que caracteriza a metodologia de melhora proposta, é o uso de parâmetros de estratégia, os quais controlam as faixas dos respectivos parâmetros objetivo (chame-se probabilidade de mutação e outros) que estão sendo considerados. Após analisar os resultados, os autores concluem que o uso da técnica proposta faz a convergência da solução mais rápida e mais precisa.

3.3.3 *Sistemas especialistas*

Um sistema especialista, ES (*Expert System*), é um programa computacional que representa e raciocina com conhecimento em relação a um tema específico com a finalidade de resolver problemas ou dar conselhos [2]. Em outras palavras, um ES é um programa computacional que simula o trabalho de um humano com expertise em um tema específico [15]. ESs estão compostos por três partes principais: (i) conhecimento base, (ii) sistema de inferência ou dedução, e (iii) interface com o usuário. 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, os quais reproduzem o comportamento da máquina quando uma ou mais falhas ativas afetam um ou mais componentes [15].

Diferentes ESs 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. Finalmente, têm-se ESs que guiam o usuário até a detecção da falha requerendo, em cada etapa, informação particular dos parâmetros da máquina [15]. Uma detalhada revisão dos diferentes tipos de ESs utilizados para o diagnóstico de turbinas a gás é mostrado por [8]. No trabalho de [8] são ressaltados 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. Isto constitui um padrão de reconhecimento/correlação, uma das metodologias usadas em ESs. O tipo mais comum de ES usado em diagnóstico de falhas das turbinas a gás são os sistemas baseados em conhecimento e regras [8], exemplos deste tipo de sistemas são aqueles descritos em [16].

Em [16] são apresentados vários tipos de ESs para diagnóstico de turbinas a gás. Um dos ES apresentados em [16] é um tipo particular onde o usuário é requerido a fornecer os sintomas apresentados pela máquina, logo o sistema consulta a base de conhecimento e indica a causa ou possíveis causas que podem estar originando os sintomas. Se mais de uma possível causa é encontrada para o sintoma apresentado, o usuário é requerido a fornecer informações adicionais dos parâmetros dos componentes da máquina até que a causa correta seja isolada e determinada. No trabalho também é indicado que quando a informação usada pelo ES é incorreta ou incompleta, ou os sintomas são ambíguos, os ESs estocásticos são os mais apropriados [16]. Neste tipo de ESs, o conhecimento base contém informação relacionada à probabilidade de que um conjunto de sintomas possa ser atribuído a um tipo específico de falha. Os autores concluem o trabalho salientando que os ESs apresentados são altamente interativos, e que ao mesmo tempo podem ser efetivamente utilizados no processo de *training* do pessoal envolvido nas atividades de manutenção [16].

3.3.4 *Métodos baseados em lógica fuzzy*

Lógica *fuzzy* é um método para formalizar a capacidade humana de raciocínio impreciso. Este raciocínio representa a habilidade humana de raciocinar aproximadamente e de fazer julgamentos levando em consideração certos graus de incerteza [8]. Recentemente estas metodologias têm sido concebidas tomando a vantagem de uma forma conveniente de mapeamento entre os vetores de entrada e de saída (i.e., padrão de reconhecimento) na presença de incertezas [7]. Os métodos baseados em lógica *fuzzy*, quando utilizados em forma conjunta com técnicas tais como ESs, redes neurais, algoritmos genéticos e outras, podem ser usados eficientemente para o diagnóstico de falhas de turbinas a gás [8].

Na última década diversos trabalhos foram realizados em relação ao uso de lógica *fuzzy* para o diagnóstico de falhas em turbinas a gás, tal como descrito por [7,8]. Um destes trabalhos, realizado por [17], apresenta um ES baseado em lógica *fuzzy* para o isolamento de falhas em turbinas a gás. O sistema usa quatro medições básicas (temperatura de exaustão da turbina, baixa e alta velocidade de rotação e vazão de combustível) e regras desenvolvidas a partir de um modelo de coeficientes de influência, via uma abordagem linear, para detectar e isolar cinco tipos específicos de falhas, levando em conta as incertezas das medições. O objetivo do processo é identificar o componente com a falha, sem quantificar a deterioração. Os resultados do trabalho mostram que a porcentagem de sucesso, em identificar e isolar o componente com falha, foi de quase 100%. Assim, o autor conclui que o sistema desenvolvido é suficientemente robusto e que produz resultados aceitáveis para tamanhos de falha que são consideravelmente diferentes das falhas implantadas para o desenvolvimento da regra *fuzzy* básica.

Similarmente a outras metodologias de diagnóstico de falhas em turbinas a gás, a lógica *fuzzy* apresenta algumas limitações, tal como descrito em [7], entre as quais podem ser mencionadas: (i) sua incapacidade de fazer estimativas confiáveis fora da faixa de dados para a qual esta foi desenvolvida, o que implica que uma grande quantidade de condições de falhas de operação encontradas e previstas é requerida para o desenvolvimento do sistema, (ii) o aumento do número de regras com o aumento da complexidade do processo de estimação, embora algumas estratégias de redução de regras possam ser adotadas, e (iii) a dependência direta dos resultados obtidos ao *trade-off* entre o tempo computacional e o objetivo do processo, levando sempre em consideração que, no diagnóstico de falhas, a precisão na identificação e o isolamento do componente com falha é mais importante que exatidão da estimação.

4.0 - DESENVOLVIMENTO DA RNA PARA AVALIAÇÃO DE DESEMPENHO E DIAGNÓSTICO DAS TURBINAS A GÁS DA UTENF (RNA-UTENF).

A revisão realizada sobre os métodos e as técnicas de avaliação de desempenho e diagnóstico apresentados, compôs o cabedal técnico necessário ao passo agora apresentado, o de desenvolvimento de uma rede neural artificial para reproduzir o funcionamento das turbinas a gás da UTE Norte Fluminense que será a base de um sistema de diagnóstico para estes equipamentos.

Nesta fase preliminar de desenvolvimento da RNA-UTENF, optou-se por tomar como ponto de partida o trabalho de [11]. A RNA-UTENF será implementada, de forma evolutiva, segundo três arquiteturas sistêmicas distintas: (i) Sistema interpretado em MATLAB; (ii) Sistema compilado em MATLAB COM Builder; (iii) Sistema Integrado em C#.NET.

A rede neural criada pelo sistema interpretado MATLAB possui seus pesos e bias (tendências) internos determinados aleatoriamente, o que implica no erro inicial ser imprevisível, embora geralmente, muito elevado.

Uma vez criada a rede, ela pode ser treinada. O treinamento pode ser entendido, de forma simples, como o procedimento (ou algoritmo) iterativo que, uma vez executado, permitirá obter a rede neural otimizada que forneça o menor erro (ϵ). O treinamento da rede prossegue, ao longo das iterações $1, 2, \dots, k$, denominadas *epochs*, desde que satisfeitas as condições de um número máximo de *epochs* (iteraões) não ter sido atingido, do erro mínimo definido no âmbito do conjunto de treinamento ainda não ter sido alcançado e do erro calculado no âmbito do conjunto de validação diminua desde a iteração (ou treinamento) anterior até a atual. O aumento do erro quando calculado no conjunto de validação indica que a rede neural está perdendo a capacidade de generalização em detrimento da memorização estrita dos padrões apresentados para o treinamento.

O estágio atual do projeto de desenvolvimento de uma ferramenta para o diagnóstico de turbinas a gás, descrito neste trabalho, é o de criação da RNA interpretada em ambiente MATLAB. Assim nesta etapa do projeto, o modelo implementado da RNA tem somente o propósito de reproduzir o funcionamento das turbinas a gás, sem a inserção dos modelos de falhas. Ressalta-se esta primeira implementação é fundamental para validar a premissa básica do projeto, que é a viabilidade de se empregar redes neurais para realizar o diagnóstico de falhas em turbinas a gás.

4.1 Obtenção de padrões para treinamento da RNA

O mecanismo de treinamento da RNA empregado, a partir do MATLAB, é bastante singelo, entretanto há dois elementos que podem se tornar críticos nesse treinamento, a saber, o tempo de treinamento e, a dificuldade de obter padrões – ou pares de vetores (*entrada, saída*) = (\vec{x}, \vec{y}) – para o treinamento. Para obter padrões que representem à operação normal das turbinas, nos limites operacionais plausíveis da planta utilizou-se o software TURBOMATCH, acadêmico, desenvolvido na Universidade de Cranfield, Reino Unido. Os padrões que representem falhas nas turbinas e falhas dos sensores, individualmente ou em pares serão implementados em uma próxima etapa segundo dados obtidos em publicações técnicas [2-5,9,14,18-20] entre outros.

Desse modo a RNA criada, foi treinada utilizando o algoritmo de treinamento denominado BFGS³, descrito em ([10], pp. 139-140), que emprega uma abordagem quase-Newton. A escolha deste algoritmo se deveu ao fato do mesmo apresentar grande capacidade de otimização da rede neural, com convergência ao mínimo global (erro mínimo global); utilização de menos memória que o algoritmo de Levenberg-Marquardt, este que foi empregado em [14]. Nesse sentido, é interessante registrar que, mesmo utilizando um Pentium 4, com 1 GigaByte de memória, o MATLAB acusou memória insuficiente para utilizar o algoritmo de Levenberg-Marquardt.

O modelo de turbina a gás para o treinamento da RNA, construído no software TURBOMACH, tem 185 MW de potência, vazão mássica de ar na entrada do compressor de 486 kg/s, razão de pressão de 16, desvio 15% da massa de entrada do compressor para o sistema de resfriamento do expensor, perda de pressão no combustor de 10%, com temperatura de entrada no expensor de 1300°C e eficiências isentrópicas de 90% e 91% do compressor e expensor respectivamente.

5.0 - RESULTADOS E DISCUSSÕES

O conjunto de dados utilizados no treinamento da RNA foi obtido através de um estudo paramétrico do modelo implementado no TURBOMACH, neste variou-se a temperatura ambiente, o ângulo das IGV's e a potência de saída requerida. A matriz para o treinamento da rede tinha 28.561 pontos e um conjunto aleatório de valores para os pesos e *bias* da rede neural, porém houve uma significativa diferença, o número máximo de *epochs* definido (que foi de 400) sendo este superado em 242. Este treinamento alcançou um erro máximo quadrático de 0,0001049.

³ De Broyden-Fletcher-Goldfarb-Shanno, seus autores.

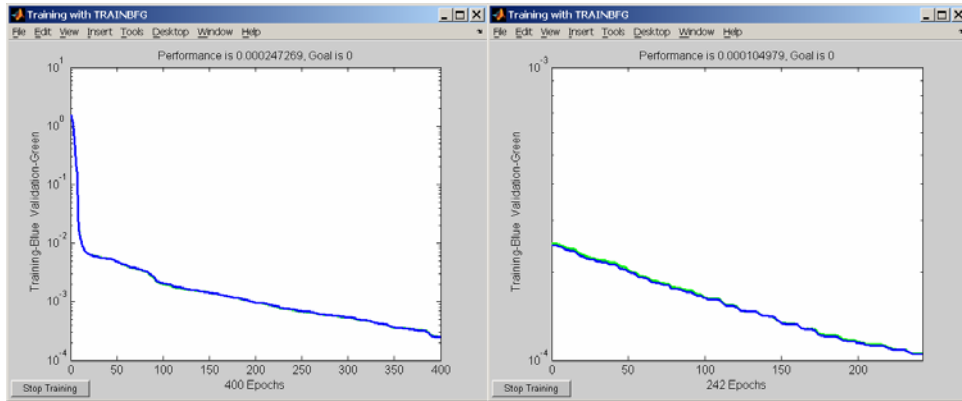


Figura 4 – Treinamento interrompido devido à perda de generalização, contudo em patamar de erro esperado para o modelo.

A Figura 6 apresentada ao final deste trabalho ilustra a arquitetura proposta para a RNA-UTENF. A Tabela 2 apresenta os resultados da RNA-UTENF.

Tabela 2 – Comparação entre os resultados calculados pela rede neural e os obtidos pelo TURBOMATCH.

Grandeza	Simulado	Original	Varição %
Trabalho mecânico [W]	112.047.431,14	110.149.640,00	1,7%
Empuxo líquido [N]	3.168,87	3.138,12	1,0%
Potência equivalente ao empuxo líquido [W]	112.072.724,96	110.351.976,00	1,6%
Vazão de combustível [kg s⁻¹]	76.148,11	76.147,00	0,0%
Consumo específico de combustível [mg/J]	674.775,62	691.308,00	-2,4%
Consumo específico equivalente de combustível [mg/J]	675.230,42	690.040,00	-2,1%
Trabalho mecânico específico	340.481,56	345.384,16	-1,4%
Potência equivalente específica	341.550,74	346.018,59	-1,3%
Eficiência térmica mecânica	0,3435	0,3354	2,4%

O erro máximo de 2,4% apresentado pela RNA-UTENF é o patamar até o qual um desvio de funcionamento da turbina a gás pode ser detectado. O presente trabalho obteve êxito dentro da premissa inicial de validar o uso de redes neurais artificiais para a avaliação de desempenho de turbinas a gás. Assim parti-se para uma nova etapa no projeto do sistema de diagnóstico e análise de desempenho, que é construir um modelo termodinâmico preciso aos detalhes para o treinamento da RNA, que produzirá um cenário de pontos mais refinado para o treinamento, concluindo o sistema de avaliação de desempenho. Quanto ao sistema de diagnóstico, uma matriz de desvios e erros será construída de forma a quando o sistema detectar uma anomalia ou tendência esta possa ser filtrada até a causa, segundo técnicas de inteligência artificial.

6.0 - CONCLUSÃO

Evidentemente, cada método de diagnóstico tem suas vantagens e desvantagens. Um sumário com as particularidades de cada método e sua comparação entre elas é apresentado a seguir. Em [8] é feita uma análise comparativa dos diversos métodos de diagnóstico e salienta que (i) os métodos baseados em modelos lineares e não lineares têm um claro significado físico, enquanto que os métodos, tais como redes neurais e ESs baseados em regras, são gerados usando conhecimento experimental; (ii) os métodos baseados em inteligência artificial são mais complexos quando comparados aos métodos baseados em modelagem; (iii) os métodos baseados em modelos lineares e não lineares, baseados no GPA, as redes neurais (uma vez treinadas) e os ESs baseados em regras (uma vez criadas as bibliotecas com as regras) realizam o processo de diagnóstico muito mais rápido que os métodos baseados em modelos não lineares seja com otimização convencional ou usando algoritmos genéticos; e (iv) todos os métodos, exceto os métodos GPA baseados em modelagem linear e não linear, podem lidar com ruídos de medições e dos sensores (sensor biases). A Figura 5 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.

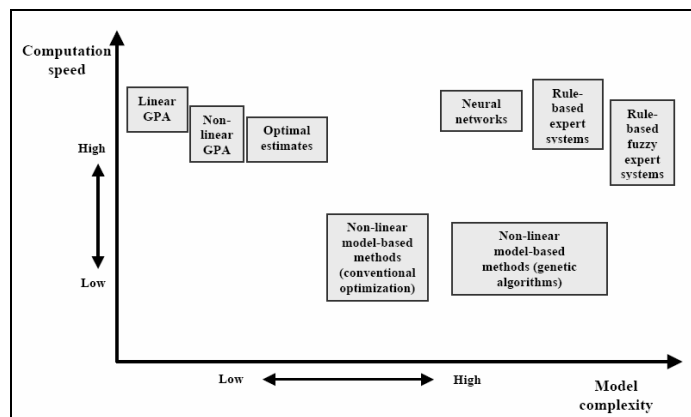


Figura 5 - Comparação dos métodos de diagnóstico [8].

Uma análise comparativa, realizada por [19], entre as diferentes metodologias de diagnóstico, para o qual consideram os conceitos de técnicas MFI (*Multiple Fault Isolation*). Estas técnicas são descritas como sendo mais adequadas para deteriorações graduais, o qual implica que todos os componentes da máquina se deterioram lentamente e

técnicas SFI (*Single Fault Isolation*), as quais são descritas como sendo mais adequadas para deteriorações rápidas, que por sua vez implicam 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 SFI, devido a estes aproximarem todas as possíveis soluções com um limitado número de casos usados para treinar o sistema. As técnicas baseadas em inteligência artificial não apresentam o problema de "smearing", i.e., a tendência de distribuir as falhas sobre um grande número de componentes e sensores, e, pelo contrário, elas têm uma boa capacidade de "concentração" para identificar o componente com falha. Os algoritmos baseados em inteligência artificial podem requerer um considerável tempo computacional, tanto no cálculo real como no caso dos algoritmos genéticos, como na fase de treinamento; caso das redes neurais. Em relação os sistemas baseados em lógica *fuzzy*, estes precisam de um grande número de regras, envolvendo não linearidades entre entradas e saídas. Porém, é possível reduzir o número de regras requerido através do uso de um apropriado algoritmo de aprendizado. As redes neurais artificiais, os sistemas expertos e os sistemas baseados em lógica *fuzzy* não apresentam soluções aceitáveis fora da faixa de variabilidade para a qual estas técnicas foram treinadas ou configuradas.

É importante salientar que não existe atualmente uma única técnica de diagnóstico que possa lidar com todos os problemas reais que acontecem nas aplicações práticas. Algumas técnicas são complementares e cada uma tem suas vantagens e limitações.

Este projeto é parte de um contexto de desenvolvimento de ferramentas computacionais que vem sendo executado na PUC-Rio em parceria com diversas termelétricas. O *software* de diagnóstico é uma destas ferramentas e imprime um novo ritmo de desenvolvimento deste tipo de produto no mercado termelétrico brasileiro.

7.0 - AGRADECIMENTOS

Os autores agradecem à UTE NORTE FLUMINENSE pelo apoio financeiro ao projeto, através do projeto "Desenvolvimento de Ferramenta para monitoramento e diagnóstico de turbinas a gás" no âmbito da Lei 9.991/2000.

8.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Chang-duk, K., Fa-young, K., Myoung-cheol, K., and Seon-hee, K., Intelligent Performance Diagnostics of a Gas Turbine Engine using user-friendly Interface Neural Networks *Aircraft Engineering and Aerospace Technology*, vol. 76, pp. 391-397, 2004.
- [2] H. Cohen, G.F.C. Rogers, and H.I.H. Saravanamutoo. *Gas Turbine Theory 4TH Edition*, Longman Group Limited, 1996.
- [3] M.P. Boyce. *Gas Turbine Engineer Handbook 2ª Ed.*, EUA: Gulf Professional Publishing, 2002.
- [4] Boyce, M. P., Phillips, J. N., Grandmont, J., and Angello, L., "Simplified, On-line Performance Monitoring of Simple Cycle Gas Turbines using Spreadshet-Based Calculations," *ASME TURBOEXPO*, Vienna - Austria, 2004.
- [5] P.P. Walsh and P. Fletcher. *Gas Turbine Performance*, Inglaterra: Blackwell Science Ltd., 1998.
- [6] Ghoreyshi, M. , Pilidis, P., and Ramsden, K. W., "Diagnostics of a Small Jet Engine – Neural Networks Approach," *ASME TURBOEXPO*, 2005.
- [7] Mathioudakis, K., Stamatis, A., Tsalavoutas, A., and Aretakis, N., "Instructing the Principles os Gas Turbine Performance Monitoring and Diagnostics by Means of Interactive Computer Models," *ASME TURBOEXPO*, Munique - Alemanha, 2000.
- [8] Li, Y. G., Performance Analysis Based Gas Turbine Diagnostics: A Review *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, vol. 216, pp. 363-377, Sep, 2005.
- [9] Ogaji, S. O. T. and Singh, R., " Study of the Optimisation of Measurement Sets for Gas Path Fault Diagnosis in Gas Turbines," *Proceedings of ASME Turbo Expo 2002*, Amsterdam, Netherlands, June 2002.
- [10] S. Haykin. *Neural Networks*, New York, NY: Macmillan College Publishing Company,
- [11] Sampath, S. and Singh, R., ""An integrated fault diagnostics model using genetic algorithm and neural networks," *Proceedings of ASME Turbo Expo 2004 - Power for Land, Sea and Air*.
- [12] Romessis, C. and Mathioudakis, K., "Setting up of a probabilistic neural network for sensor fault detection including operation with component faults," *Proceedings of ASME Turbo Expo 2002*.
- [13] Can Gulen, S. and Paolucci, S., "Real-Time On-Line Performance Diagnostics of Heavy-Duty Industrial Gas Turbine," *ASME TURBOEXPO*, Munique - Alemanha, 2000.
- [14] Sampath, S., Gulati, A., and Singh, R., "Fault Diagnostics Using Genetic Algorithm for Advanced Cycle Gas Turbine," *Proceedings of ASME Turbo Expo 2002*, Amsterdam, Netherlands, June 2002.
- [15] DePold, H., Siegel, J., and Hull, J., "Metrics for Evaluating the Accuracy of Diagnostic Fault Detection Systems," *ASME TURBOEXPO*, Vienna - Austria, 2004.
- [16] Spina, P. R. , Torella, G., and Venturini, M., "The Use of Expert Systems for Gas Turbine Diagnostics and Maintenance," *Proceedings of ASME Turbo Expo 2002*, Amsterdam, The Netherlands, June 2002.
- [17] Ganguli, R., "Application of Fuzzy Logic for Fault Isolation of Jet Engines," *Proceedings of ASME Turbo Expo 2001*, New Orleans, Louisiana, US, June 2001.
- [18] Ogaji, S. O. T., Sampath, S., Marinai, L., Singh, R., and Probert, S. D., Evolution Strategy for Gas-Turbine Fault-Diagnoses *Applied Energy*, vol. 81, pp. 222-230, 2005.
- [19] Marinai, L., Probert, D., and Singh, R., Prospects for Aero Gas Turbine Diagnostics: A Review *Applied Energy*, vol. 79, pp. 109-126, 2004.
- [20] Palade V. , Bocaniala C.D. , and Jain L.C. *Computacional Intelligence in Fault Diagnosis*, EUA: Springer Science, 2006.

9.0 - DADOS BIOGRÁFICOS

PhD. Sandro Barros Ferreira

sandro@ituc.puc-rio.br
Doutorado (2002) em Thermal Power – University of Cranfield, CITECH*, UK.
Mestrado (1998) e Graduação (1996) em Eng. Mecânica pela Universidade Federal de Itajubá, UNIFEI, Brasil.
Empresa: PONTIFÍCIA UNIVER. CATÓLICA DO RIO DE JANEIRO, desde 2002.
Coordenador de Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

MSc. Fabiano Alves dos Santos

fasantos@ituc.puc-rio.br
Doutorando (2006) em Engenharia Mecânica – PUC-RJ, Brasil.
Eng. de Pesquisa em Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

MSc. César Celis

ccelis@ituc.puc-rio.br
Mestrado (2006) em Engenharia Mecânica – PUC-RJ, Brasil.
Eng. de Pesquisa em Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

MSc. Belmiro Rufino Valente

belmiro@rdc.puc-rio.br
Mestrado (1996) em Engenharia Mecânica – PUC-RJ, Brasil.
Consultor em Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

Dr. Marcelo Assato

assato@ituc.puc-rio.br
Doutor (2001) em Engenharia Mecânica – ITA, Brasil.
Eng. de Pesquisa em Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

Engª. Paula de Mello Ribeiro Pinto

paula_mello@rdc.puc-rio.br
Mestranda (2007) em Engenharia Mecânica – PUC-RJ, Brasil.
Engª. de Pesquisa em Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

Eng. Vinicius P. de Avellar

vavellar@ituc.puc-rio.br
Mestrando (2007) em Engenharia Mecânica – PUC-RJ, Brasil.
Eng. de Pesquisa em Projetos de P&D do INST. DE ENERGIA DA PUC-RJ.

DSc. Sergio Leal Braga

slbraga@mec.puc-rio.br
Professor Associado do Departamento de Engenharia Mecânica da PUC-Rio
Pós-doutorado pela Purdue University, EUA (1989)
Doutorado pela Pontifícia Universidade Católica do Rio de Janeiro (1985)




Figura 6 – Arquitetura da primeira versão do modelo da RN UTEN