

JÚLIA BERTELLI DUARTE

**INTELIGÊNCIA ARTIFICIAL APLICADA NO
CONTROLE DE QUALIDADE EM LINHAS DE
PRODUÇÃO**



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA**

2013

JÚLIA BERTELLI DUARTE

**INTELIGÊNCIA ARTIFICIAL APLICADA NO CONTROLE DE
QUALIDADE EM LINHAS DE PRODUÇÃO**

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **MESTRE EM ENGENHARIA MECÂNICA**.

Área de Concentração: Mecânica dos Sólidos e Vibrações.

Orientador: Prof. Dr. Marcus Antonio Viana
Duarte

UBERLÂNDIA – MG
2013

JÚLIA BERTELLI DUARTE

**INTELIGÊNCIA ARTIFICIAL APLICADA NO CONTROLE DE
QUALIDADE EM LINHAS DE PRODUÇÃO**

Dissertação **SUBMETIDA** ao Programa de
Pós-graduação em Engenharia Mecânica da
Universidade Federal de Uberlândia.

Área de Concentração: Mecânica dos Sólidos e
Vibrações.

Banca Examinadora:

Prof. Dr. Marcus Antônio Viana Duarte – UFU (orientador)

Prof. Dr. Valder Steffen Jr – UFU

Prof. Dr. Robson Pederiva – UNICAMP

UBERLÂNDIA, 24 de abril de 2013

*A meus pais, Marcus e Isabel
e aos irmãos Ricardo e André...*

AGRADECIMENTOS

Agradeço primeiramente a Deus, sem Ele nada disso seria possível.

Ao meu pai, mestre e orientador Marcus Duarte, que apesar das divergências, sempre acreditou em minha capacidade, e passou seus conhecimentos e apoio.

À minha família, por sempre apoiar, cobrar e ajudar com os textos.

Aos colegas do LAV, pela ajuda durante o desenvolvimento deste trabalho.

À Universidade Federal de Uberlândia e à Faculdade de Engenharia Mecânica pela oportunidade de desenvolver este trabalho.

Ao CNPq pela ajuda financeira.

À Tecumseh pelos sinais e compressores utilizados neste trabalho.

Duarte, J. B. **Inteligência Artificial Aplicada no Controle de Qualidade em Linha de Produção.** 2013. Numero de folhas. Dissertação de Mestrado. Universidade Federal de Uberlândia. Uberlândia.

Resumo

A indústria tem como um dos principais desafios estabelecer critérios confiáveis para controle de qualidade de seus produtos e serviços. Porém, muitos desses critérios possuem deficiências e parâmetros subjetivos para se classificar e definir a qualidade do produto final, tendo como parâmetro a sensibilidade auditiva dos peritos para esta decisão. Neste trabalho, apresentou-se uma metodologia baseada em redes neurais auto-organizáveis e otimização aplicada a sinais de vibração (sintomas vibroacústicos) que visa tirar a subjetividade do controle de qualidade do produto final. Inicialmente, verificou-se a sensibilidade e a eficiência da rede neural de Kohonen (SOM) e a mesma se mostrou capaz de segregar em grupos, um conjunto de sinais. Para a escolha dos parâmetros, utilizou-se da SOM combinada à técnicas de otimização heurística, como Algoritmo Genético e Evolução Diferencial. Para estes casos, os dados utilizados eram todos controlados, ou seja, conheciam-se, a priori, os grupos conformes e não conformes. Em ambos os casos, conseguiu-se bons resultados na segregação dos grupos, sendo que a técnica de Evolução Diferencial foi considerada melhor uma vez que demanda menos tempo computacional e as funções objetivo tiveram menores valores. Para validar se esses métodos computacionais eram boas ferramentas, uma análise estatística clássica dos sinais foi realizada. Ao comparar os resultados obtidos via métodos computacionais com a análise clássica, observou-se uma coerência entre os mesmos, logo os métodos computacionais para a escolha dos parâmetros se mostrou uma boa ferramenta para avaliação de sinais conformes e não conformes. Em um último momento, desejou-se verificar se para um sistema não controlado, a metodologia desenvolvida era capaz de separar os sinais não conformes dos outros. Neste caso, observou-se a necessidade de uma rede com um número maior de neurônios para que a metodologia funcione. Assim, a partir dos resultados obtidos, é possível ao analista construir critérios passa-não passa em linhas de produção, utilizando apenas de computação, sem a necessidade da pré-existência de sinais dos produtos considerados bons e ruins e da análise desses sinais para se criar um banco de dados.

Palavras Chave: Controle de Qualidade, Redes Neurais Auto-Organizáveis, Algoritmos Genéticos, Evolução Diferencial, Sintomas Vibroacústicos.

Duarte, J. B. **Artificial Intelligence Applied to Quality Control in Production Line.** 2013. Numero de folhas. M. Sc. Dissertation. Universidade Federal de Uberlândia. Uberlândia.

Abstract

A great challenge in industry is to establish reliable criteria for quality control of products and services. However, many of these criteria have shortcomings due to the use of subjective parameters, such as hearing sensitivity of the experts in order to classify and define the final product quality. In this work a methodology based on vibroacoustics symptoms, self-organizing neural networks and optimization is presented to minimize the subjectivity effects of quality control in production lines and manufacturing. Initially, the sensitivity and efficiency of the Kohonen neural network (SOM) to segregate a set of signals using vibroacoustics symptoms correlated with nonconformities of the tested product was found. For the choice of the best symptoms, among a large set of possibilities, the SOM technique combined with heuristic optimization techniques such as Genetic Algorithm and Differential Evolution are used. The use of two optimization techniques to a case in which the groups of conformities and non-conformities were known led to good results in the segregation of groups with emphasis on the Differential Evolution, which required lower computational effort and resulted in lower values for the objective functions. To validate the proposed methodology a classical statistical analysis of the signals was performed. When comparing the results obtained by computational methods with classical analysis a good consistency between them was observed. So the computational methods to choose vibroacoustic parameters, symptoms, proved to be a good tool for quality control. At last, the developed methodology was used to segregate the signals of a small number of defective products of the signals of a large set of acceptable products. The aim of this was to study the possibility of using the methodology without prior knowledge of nonconforming products. In this case, there is a need for a network with a larger number of neurons to get good results. The results demonstrate that it is possible to construct a pass/no-pass symptoms vibroacoustic database to quality control purpose using only artificial intelligence, without the need of pre-existing signal sets of acceptable and not-acceptable products obtained through subjective analysis.

Keywords: Quality Control, Self-organized Map, Genetic Algorithm, Differential Evolution, Vibroacoustic Symptoms.

LISTA DE SÍMBOLOS

Letras Arábigas

- $c(\tau)$: Cepstrum de potência do sinal
 d : Desvio padrão amostral
 dt : Intervalo de tempo de integração
 f : Frequência
 f_r : Frequência da rede
 g : Graus de liberdade
 i : Índice inteiro
 j : Representação de imáganário
 k_e : Número inteiro de baixa ordem
 k_x : Número zero ou número par
 n : Número inteiro, tamanho amostral
 p : Número de par de pólos do motor
 $s(t)$: Sinal no domínio do tempo
 s : Fator de escorregamento, desvio padrão amostral
 $s_{\text{crítico}}$: Desvio padrão crítico de Chauvenet
 t : Tempo, estatística de teste
 t_{hetero} : Estatística de teste para amostras heterocedásticas
 t_{homo} : Estatística de teste para amostras homocedásticas
 $t_{\alpha,n-1}$: Dostribuição t de Student, com $n-1$ graus de liberdade
 $x(iT)$: Sinal no domínio do tempo
 $x(t)$: Sinal com modulação em fase no domínio do tempo
 x_{\min} : Sinal associado ao neurônio com menor ocorrência
 x : Número real
 $\tilde{x}(t)$: Sinal analítico
 \bar{x} : Média
 $y(iT)$: Valor médio dos períodos
 A Amplitude o sinal
 C_s Assimetria, Curtose

- dBA: Curva de ponderação A
- dB_L: Curva de ponderação linear
- F_0 : Estatística de teste
- FB_{af}: Harmônicos superiores do motor
- FC: Fator de crista
- $F_{1-\alpha/2, n_1-1, n_2-1}$: Distribuição de Snedecor, com n_1-1 graus de liberdade no numerador e n_2-1 graus de liberdade no denominador
- H: Transformada de Hilbert
- H₀: Hipótese nula
- H₁: Hipótese alternativa
- M: Número de pontos por período
- M'₃: Momento central de terceira ordem
- M''₃: Momento central de quarta ordem
- N: Número de períodos utilizados para cálculo da média
- N_{min}: Menor número de ocorrências
- R_s: Número de ranhuras do rotor ou estator
- |S(f)|²: Função densidade espectral de potência
- T: Tempo de integração, Comprimento do sinal no tempo, Estatística de teste
- T_{crítico}: Valor atribuído à distribuição t de Student
- X: Vetor em função do tempo

Letras Gregas

- α : Nível de significância
- ϕ : Ângulo de fase
- φ : Ângulo de fase
- λ : Multiplicador de Lagrange
- μ : Média populacional
- σ : Desvio padrão

- σ^2 : Variância
 τ : Deslocamento no tempo, chamado quefrência
 ω : Frequência angular moduladora
 Ω : Frequência angular portadora

Símbolos e Siglas

- \mathfrak{I} : Transformada de Fourier
ED: Evolução Diferencial
GA: Algoritmos Genéticos
NWS: Nível de Potência Sonora
RMS: Valor médio quadrático
SOM: *Self organized map*, ou rede neural auto-organizável
TDA: *Time Domain Avarage*

SUMÁRIO

Capítulo 1 - Introdução	2
1.1. Objetivo	6
1.2. Organização da dissertação	6
Capítulo 2 - Revisão Bibliográfica	6
2.1. Análise em bandas de frequência	6
2.2. Análise de harmônicos superiores do motor elétrico.....	6
2.3. Sintomas no domínio do tempo: Valor RMS, Assimetria, Curtose, Fator de Crista e Cepstrum.	8
2.3.1. Valor médio quadrático (RMS).....	8
2.3.2. Assimetria (Skewness).....	8
2.3.3. Curtose.....	9
2.3.4. Fator de Crista	10
2.3.5. Cepstrum.....	11
2.4. Médias no domínio do tempo - Time Domain Average (TDA)	11
2.5. Análise de Ordem	12
2.6. Envelope	12
2.7. Redes Neurais Artificiais.....	14
2.8. Algoritmos Genéticos.....	15
2.9. Evolução Diferencial.....	16
Capítulo 3 - Metodologia Utilizada	118
3.1. Análise estatística clássica	118
3.1.1. Medição dos Níveis de Potência Sonora NWS	19
3.1.2. Estimativa das Médias e Desvios Padrões Amostrais	19
3.1.3. Critério de Chauvenet.....	19
3.1.4. Teste de Homocedasticidade.....	20
3.1.5. Comparação de Médias Populacionais	21
3.1.6. Gráficos Boxplot	23
3.2. Análise da eficiência e sensibilidade da rede neural.....	24
3.3. Escolha dos parâmetros a ser utilizados como critério em linhas de produção.....	26
3.4. Verificação da viabilidade da SOM em linhas de produção real, sem conhecimento prévio das conformidades e não-conformidades	26
Capítulo 4 - Análise Estatística Clássica	27
4.1. Avaliação da correlação entre a percepção subjetiva do cliente e os valores NWS	

dos compressores	27
4.2. Avaliação dos sintomas e do melhor ponto para colocação do acelerômetro	32
Capítulo 5 - Resultados Para o Estudo da Eficiência da Rede Neural Auto-Organizável e Definição da Quantidade Mínima e Máxima de Sintomas Vibroacústicos	35
5.1. Estudo da eficiência da SOM.....	37
5.2. Definição da quantidade mínima e máxima de sintomas para serem usados como dados de entrada da SOM.	37
Capítulo 6 - Escolha dos parâmetros a ser utilizados como critério em linhas de produção	39
6.1. Resposta ideal esperada pela SOM	39
6.2. Respostas obtidas para a otimização via Algoritmos Genéticos.....	41
6.3. Respostas obtidas para a otimização via Evolução Diferencial.....	47
6.4. Comparação entre os métodos: SOM via Algoritmos Genéticos e SOM via Evolução Diferencial em relação à Análise Estatística Clássica.....	53
Capítulo 7 - Resultados Para o Estudo da Viabilidade da Metodologia em Linhas de Produção sem o Conhecimento Prévio das Não Conformidades	53
Capítulo 8 - Conclusões.....	63
8.1. Trabalhos Futuros	66
REFERÊNCIAS BIBLIOGRÁFICAS	66
Anexo I - Definição dos Sintomas Utilizados	70

CAPÍTULO I

Introdução

Vibração pode ser definida como o pequeno movimento de um ponto oscilando em torno de uma posição de equilíbrio. E a mesma pode ser usada como ferramenta para diversas atividades como manutenção preditiva, integridade estrutural, monitoramento de processos de usinagem e controle de qualidade, dentre outros.

Existem muitos trabalhos desenvolvidos utilizando vibração como ferramenta para manutenção preditiva aplicada a diferentes equipamentos. Hadjiski; Doukovska; Kojnov (2012) utilizaram uma análise de tendência não linear, aplicada aos sinais de vibração, para diagnosticar e fazer manutenção preditiva em sistemas de exaustão. Já Silva (2012), em sua dissertação de mestrado, apresenta um estudo de métodos de detecção de falhas em motores elétricos usando Máquinas de Vetores de Suporte, treinadas a partir de sinais de vibração. Loutas et al (2011) utiliza da combinação de análise online de vibração, emissão acústica e detritos no óleo para conseguir um monitoramento de máquinas rotativas mais efetivo.

Já para integridade estrutural, Shao et al (2012) apresenta uma análise e simulação de fadiga estocástica para sistemas de deslocamento de equipamentos complexos. Neste trabalho, Shao apresenta uma maneira de simular e medir o espectro de carga em um eixo torsional.

Em monitoramento de processos de usinagem, Meola (2009), em sua tese de doutorado, verificou a dificuldade de analisar apenas os níveis de vibrações, uma vez que estes dependem das condições da máquina, e desenvolveu então uma metodologia baseada em análise modal operacional e algoritmo de realização de autosistemas para minimizar as dificuldades encontradas na estimativa indireta das forças de corte via medição de vibrações da máquina.

A indústria tem como um dos principais desafios estabelecer critérios confiáveis para controle de qualidade de seus produtos e serviços. Porém, muitos desses critérios possuem

deficiências e parâmetros subjetivos para se classificar e definir a qualidade do produto final, tendo como parâmetro a sensibilidade dos peritos para esta decisão. O ouvido humano apesar de ser uma ferramenta altamente sensível e largamente utilizada em controle de qualidade, é sensível a problemas emocionais e ambientais (ruídos de fundo), além de não resultar em valores mensuráveis, tanto solicitados e exigidos pelas normas atuais de padronização como pelas normas ISO(9000) e QS(9000).

A fim de tirar a subjetividade dos testes de controle de qualidade da linha de produção, alguns trabalhos foram desenvolvidos pelo Laboratório de Acústica e Vibrações da Universidade Federal de Uberlândia ao longo dos anos, de maneira a auxiliar a indústria a se adequar a estas normas.

Guimarães (2000) analisou as técnicas tradicionais de análise de sinais, em conjunto com o monitoramento das vibrações e ruído. Este analisou diferentes representações de tempo-frequência para procurar detectar as características transientes de sinais de vibração medidos em câmbios veiculares, os quais operavam em rotação constante e variável.

Já Pena (2003), por sua vez, analisou as técnicas não tradicionais para detecção de defeitos de fabricação em câmbios automotivos, uma vez que a utilização de ferramentas clássicas de manutenção preditiva via monitoramento de vibrações não são eficazes devido ao grande número de engrenagens envolvidas, relações de transmissão próximas à unidade e devido ao fato do câmbio ser testado em vazio (Guimarães, 2000). Por isso, este considerou duas técnicas de demodulação e outras duas abordagens que levam em conta a amplitude das frequências de engrenamento e suas bandas laterais.

Após análise de viabilidade das metodologias, escolheu-se duas (a demodulação em amplitude e fase e a abordagem que utiliza de ferramentas estatísticas – curtose, fator de crista e nível médio quadrático – aplicadas às parcelas temporais associadas às frequências de interesse obtidas após aplicação da Transformada Choi-Williams aos sinais) para análise de sensibilidade com sinais simulados e, após, aplicadas aos sinais de vibração obtidos experimentalmente. A demodulação de amplitude e fase mostrou-se eficiente para os dados simulados e também apresentou coerência entre os dados experimentais e os estados previamente conhecidos das caixas de transmissão. A técnica utilizando a Transformada Choi-Williams também se mostrou adequada.

Barreto (2003) procurou, em sua dissertação, definir parâmetros de vibração e ruído para a aceitação dos câmbios em linha de montagem. A técnica utilizada foi a de

demodulação em amplitude e fase, a qual se mostrou eficiente para análise de rumorosidade da quinta marcha.

Meola (2006) utilizou-se de inteligência artificial (redes neurais probabilísticas) e Inferência Fuzzy para monitoramento da qualidade de sinais de vibrações, os quais se mostraram aptos a classificar os sinais coletados para teste, não apresentando diferenças significativas entre os resultados obtidos na classificação.

Para complementar o trabalho de Barreto (2003), Oliveira Filho (2007) procurou desenvolver uma metodologia utilizando filtragem adaptativa como ferramenta de auxílio nos procedimentos de controle de qualidade via monitoramento de vibração e ruído.

Deseja-se agora, neste trabalho, desenvolver uma metodologia, utilizando da análise de sinais e das técnicas já desenvolvidas, que consiga separar os produtos não conformes dos produtos conformes sem a necessidade de se conhecer, a priori, um grupo dos produtos conformes e um grupo dos não conformes.

Como os processos de fabricação estão em constante mudança, os bancos de dados para análise de sinais em linhas de produção se tornam obsoletos muito rapidamente, o que demanda tempo do analista em sempre atualizar o banco de dados e faz com que os sistemas passa-não-passa começem a recusar produtos que na verdade estão bons.

Para desenvolver este trabalho, optou-se por utilizar de técnicas de inteligência artificial, principalmente as redes neurais. As Redes Neurais Artificiais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprendem. A etapa de aprendizagem consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões entre as unidades de processamento que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. Estes métodos para treinamento de redes podem ser agrupados em dois grupos: o Aprendizado Supervisionado, método em que a entrada e a saída desejadas para a rede são fornecidas por um supervisor externo e cujo objetivo é ajustar parâmetros da rede de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos, e o Aprendizado Não Supervisionado, em que não há professor ou supervisor para acompanhar o processo de aprendizado, e somente os padrões de entrada estão disponíveis.

No Aprendizado Não Supervisionado, a partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características de entrada e criar novas classes ou grupos automaticamente.

Um tipo de rede neural com aprendizado não supervisionado é a rede neural artificial competitiva, que são usadas para construir uma representação estatística compacta de um conjunto de dados de entrada não-rotulados, ou seja, é capaz de reconhecer padrões e extrair características comuns e estatisticamente relevantes dos dados de entrada.

Da Cruz (2007), em sua dissertação de mestrado, realizou um estudo comparativo do desempenho de algoritmos de redes neurais competitivas em problemas de quantização vetorial e aplicações correlatas, tais como análise de agrupamentos e compressão de imagens. Este conclui que, independente do algoritmo escolhido, se o mesmo tiver seus parâmetros devidamente ajustados e seus desempenhos avaliados, as diferenças de desempenho entre os mesmos são desprezíveis, ficando como critério de desempate o custo computacional.

Muitos trabalhos já foram desenvolvidos utilizando das redes neurais auto-organizáveis para separação de grupos, em diversas áreas das engenharias. Han; Chen; Qiao (2011) utilizaram de uma rede neural não supervisionada para predizer qualidade de água. Os mesmos autores, em 2012, desenvolveram um modelo preditivo para o controle da concentração de oxigênio dissolvido, utilizando de redes não supervisionadas.

Kaya et al (2008) utilizou-se das redes neurais competitivas de Kohonen (SOM) para classificar os cinco defeitos mais comuns de compressores herméticos. Para este trabalho, a rede foi treinada utilizando vetores que continham dados sobre o nível de pressão sonora, vibração, pressão de pulsação dos compressores para um grande número de compressores defeituosos e saudáveis.

Aliadas às técnicas de inteligência artificial, deseja-se utilizar de técnicas de otimização para auxiliar na escolha do melhor grupo de dados de entrada para treinamento da rede, principalmente os Algoritmos Genéticos e os algoritmos de Evolução Diferencial.

Algoritmos genéticos são largamente utilizados em engenharia. Meng (2012) utilizou-se de GA para otimizar as características de absorção sonora subaquáticas de metamateriais. Oliveira (2012) utilizou-se de algoritmos genéticos em sua tese de doutorado para encontrar a posição do auto falante mais adequada e a pressão acústica que o mesmo deve receber para gerar a menor sensação auditiva possível, aplicadas a controle ativo de ruído em dutos.

Já os algoritmos de Evolução Diferencial (ED) também estão sendo largamente utilizados, principalmente para resolver problemas que possuem mais de um objetivo e não apenas em problemas aplicados à engenharia. Muitos trabalhos apresentando revisões sobre esta técnica juntamente com aplicações foram publicados. Sreedhar; Rajan (2013) apresentam uma revisão sobre ED baseados em problemas multiobjetivos, apresentando os diferentes

tipos de algoritmo de ED para aplicação multiobjetivo. Zhang et al (2013), em seu trabalho, apresenta uma ED adaptativa e multiobjetivo, juntamente com uma rede neural caótica, aplicadas à operações em hidrelétricas, considerando os problemas ambientais.

1.1. Objetivo

Este trabalho tem então, por objetivo, desenvolver uma metodologia baseada em redes neurais artificiais auto-organizáveis e em técnicas de otimização aplicada a sinais de vibração (sintomas vibroacústicos), visando tirar a subjetividade do controle de qualidade do produto final.

1.2. Organização da dissertação

Para tanto, o trabalho é dividido em oito capítulos. No Capítulo I é apresentado o estado da arte, uma breve introdução teórica para situar o tema da dissertação e seus objetivos. No Capítulo II é apresentada uma revisão bibliográfica, bem como o fundamento teórico utilizado para a confecção deste trabalho. O Capítulo III apresenta a metodologia utilizada. Já nos Capítulos IV, V, VI e VII são apresentados e discutidos os resultados obtidos através das diferentes abordagens apresentadas. Por fim, no Capítulo VIII são mostradas as principais conclusões com possíveis trabalhos futuros.

CAPÍTULO II

Revisão Bibliográfica

Apresentam-se, neste capítulo, os fundamentos teóricos utilizados para a realização desta dissertação. Primeiramente, apresentam-se os cálculos estatísticos utilizados na definição dos sintomas vibroacústicos. Apresenta-se também uma breve explicação sobre os métodos de otimização utilizados: Redes Neurais Artificiais, Algoritmos Genéticos e Evolução Diferencial.

2.1. Análise em bandas de frequência

Dado um sinal no domínio da frequência, faz-se a análise em bandas definidas para tentar identificar a região do espectro que é mais sensível à rumorosidade. Uma vez que o espectro é bem distinto, utiliza-se da análise de bandas para identificar os possíveis problemas existentes em compressores rotativos.

2.2. Análise de harmônicos superiores do motor elétrico

A Eq. 2.1 (Brito; Pederiva; Garcia, 2002) é utilizada para calcular os harmônicos superiores do motor elétrico.

$$FB_{af} = f_r \cdot [((nR_s \pm k_e) \cdot (1-s)) / p \pm k_x] \quad (2.1)$$

Onde:

f_r é a frequência da rede, que no Brasil equivale a 60 Hz;

n é um número inteiro;

R_s é o número de ranhuras do rotor ou do estator. Conforme informação do fabricante, os valores de R_s são iguais a 30 para o rotor e 24 para o estator do motor elétrico utilizado no compressor;

k_e é um número inteiro de baixa ordem, no trabalho varia de -3 a 3;

s é o fator de escorregamento;

p é o número de par de pólos do motor, que para o caso em estudo vale um;

k_x é zero ou um número par e, no trabalho, varia de -8 a 8.

É importante ressaltar que os valores de k_e e k_x foram calculados para os compressores utilizados neste trabalho.

2.3. Sintomas no domínio do tempo: Valor RMS, Assimetria, Curtose, Fator de Crista e Cepstrum.

2.3.1. Valor médio quadrático (RMS)

O valor médio quadrático (RMS), também chamado de valor eficaz, é uma das medidas mais importantes de amplitude, pois leva em conta tanto a cronologia da onda, como também considera o valor de amplitude que está diretamente ligado à energia contida na onda, indicando o poder destrutivo da vibração. Este pode ser calculado através da Eq. 2.2.

$$\text{Nível RMS} = \sqrt{\frac{1}{T} \int_0^T X^2(t) dt} \quad (2.2)$$

2.3.2. Assimetria (Skewness)

Assimetria é o grau de desvio, ou afastamento da simetria, de uma distribuição. Se a curva de frequência de uma distribuição tem uma “cauda” mais longa à direita do que à esquerda da ordenada máxima, diz-se que a distribuição é assimétrica à direita ou assimétrica positiva. Se ocorrer o inverso, é uma distribuição assimétrica à esquerda ou negativa. O coeficiente de assimetria é dado pela Eq. 2.3.

$$C_s = \frac{M'_3}{(\sigma^2)^{1.5}} \quad (2.3)$$

Onde M'_3 é o momento central de terceira ordem e σ é o desvio padrão da amostra.

A Fig. 2.1 mostra os diferentes tipos de distribuição assimétrica.

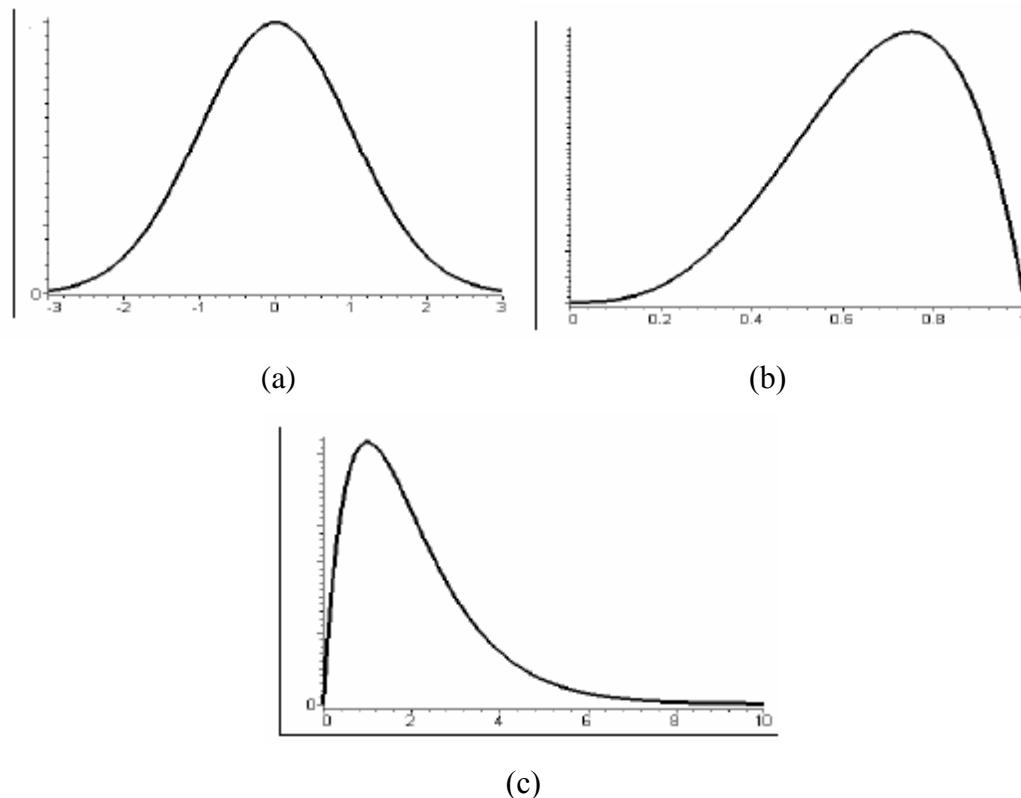


Figura 2.1. Distribuições quanto à assimetria: (a) simétrica; (b) assimétrica negativa; e (c) assimétrica positiva.

2.3.3. Curtose

Curtose é o grau de achatamento de uma distribuição, considerado usualmente em relação à distribuição normal. Esta pode ser calculada utilizando a Eq. 2.4.

$$C_s = \frac{M'_4}{(\sigma^2)^2} \quad (2.4)$$

Onde M'_4 é o momento central de quarta ordem.

A distribuição que tem um pico relativamente alto é chamada leptocúrtica, enquanto que a que possui o topo mais achatado é denominada platicúrtica. Já a distribuição normal, que tem uma forma intermediária, é denominada mesocúrtica. A Fig. 2.2 mostra os tipos de distribuição de acordo com a curtose.

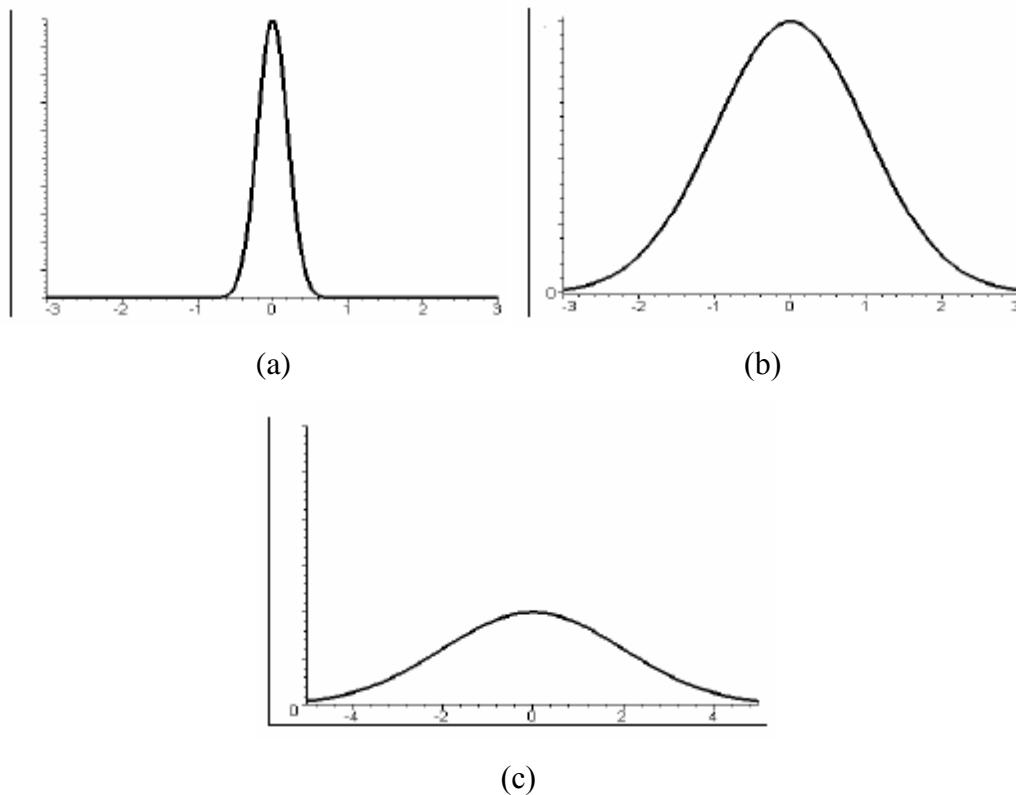


Figura 2.2. Distribuições quanto a curtose: (a) leptocúrtica; (b) mesocúrtica; e (c) platicúrtica.

2.3.4. Fator de Crista

O Fator de Crista (FC), definido pela Eq. 2.5, é muito utilizado para detecção de falhas em rolamentos e é um indicador de ocorrências fora da normalidade.

$$FC = 10 \log_{10} \frac{\text{ValorPico}}{\text{ValorRMS}} \quad (2.5)$$

2.3.5. Cepstrum

O Cepstrum de Potência, dado pelo espectro de potência do logaritmo do espectro de potência do sinal, foi criado originalmente para solucionar o problema geral de deconvolução de dois ou mais sinais e permite que o período de repetição das bandas de modulação seja obtido. Uma definição alternativa desta técnica de análise de sinais é definida por Braun (1986) através da Eq. 2.6.

$$c(\tau) = \mathfrak{I}^{-1} \left\{ \ln |S(f)|^2 \right\} \quad (2.6)$$

Onde: $c(\tau)$ representa o Cepstrum de Potência do sinal; τ é o deslocamento no tempo; \mathfrak{I} é o operador Transformada de Fourier; e $|S(f)|^2$ é a função densidade espectral de potência do sinal $s(t)$.

A princípio existem dificuldades na reconstrução do sinal original devido à perda de informações de fase contida em $c(\tau)$. O parâmetro τ é usualmente chamado quefrência, mas possui unidades de tempo que informam somente a periodicidade observada no espectro devido à escala logarítmica com ênfase na estrutura harmônica de $s(t)$. A alta quefrência representa um pequeno espaçamento entre as frequências repetitivas, e a baixa quefrência indica uma flutuação lenta do padrão de repetição, não possuindo relação com as frequências absolutas de $s(t)$. Estas características fazem do Cepstrum de Potência uma ferramenta de apoio interessante à análise espectral, sendo particularmente útil em sinais que contêm atrasos de fase, ecos, famílias de harmônicos equiespaçados, etc. (BRAUN, 1986).

2.4. Médias no domínio do tempo - Time Domain Average (TDA)

A TDA consiste do cálculo da média de N segmentos de dados periódicos, conforme mostrada na Fig. 2.3, e pode ser calculada através da Eq. 2.7.

$$y(iT) = \frac{1}{N} \sum_{r=0}^{N-1} x(iT - rMT) \quad (2.7)$$

Onde: $y(iT)$ é o valor médio dos períodos do sinal; $x(iT)$ é o sinal no domínio do tempo; N é o número de períodos utilizados para o cálculo da média; M é o número de pontos por período e T é o comprimento do sinal do tempo.

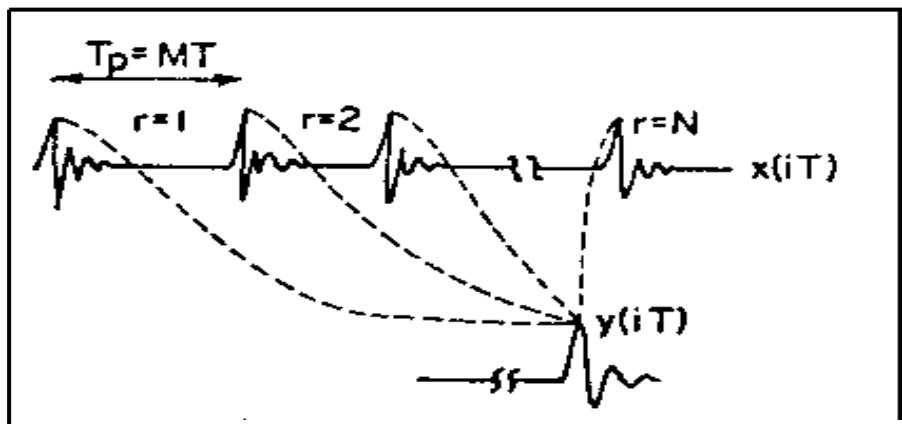


Figura 2.3. Média no domínio do tempo

2.5. Análise de Ordem

Na análise de ordem, calculada a frequência fundamental, que para o estudo é a de rotação do motor, calcula-se o valor da energia (valor médio quadrático) para cada harmônico subsequente até a 280^a ordem.

2.6. Envelope

Um sinal modulado em fase é um sinal que contém informação de fase variante no tempo. Uma representação simples de um sinal com modulação de fase é dado pela Eq. 2.8.

$$x(t) = A \sin(\Omega t + \varphi + \beta \sin(\omega t + \phi)) \quad (2.8)$$

onde:

A é a amplitude do sinal;

Ω é a frequência (angular) portadora;

ω é a frequência (angular) moduladora;

φ e ϕ são ângulos de fase.

A demodulação de um sinal, então, implica na reconstrução do sinal de maneira que o histórico temporal da variação de fase seja extraída do sinal original.

Para a Eq. 2.8, numa primeira aproximação, utilizou-se uma transformada cosseno inversa, o que resultaria num resultado errôneo, visto que a função cosseno, por exemplo, tem como ambiguidade o fato de não haver distinção entre os ângulos do primeiro com o quarto e do segundo com o terceiro quadrantes, respectivamente.

Entretanto, expressando a Eq. 2.8 na forma complexa, resulta na Eq. 2.9.

$$x(t) = Ae^{j[\Omega t + \phi + \beta \sin(\omega t + \varphi)]} \quad (2.9)$$

As características de fase para qualquer instante de tempo podem ser obtidas observando o ângulo entre a parte real e imaginária do sinal complexo para qualquer instante do tempo. Um sinal complexo que carrega as informações de fase é conhecido como sinal analítico.

Utilizando a fórmula de Euler (expressa pela Eq. 2.10), o exemplo dado pela Eq. 2.8 pode ser representado na forma analítica adicionando ao sinal original um seno com a fase instantânea do sinal original multiplicado pela unidade imaginária j .

$$e^{j\theta} = \cos(\theta) + j\sin(\theta) \quad (2.10)$$

Em resumo, para construir um sinal analítico, basta achar uma função que transforme um cosseno em um seno. A função que faz isto é a transformada de Hilbert, sendo que:

$$H[\sin(t)] = -\cos(t)$$

e

$$H[\cos(t)] = \sin(t)$$

onde H é a transformada de Hilbert do sinal.

Em última análise, um sinal analítico pode ser representado, utilizando Hilbert, pela Eq. 2.11.

$$\tilde{x}(t) = x(t) + jH[x(t)] \quad (2.11)$$

É importante salientar que o retorno do comando `hilbert()` do Matlab® já é o sinal analítico (Eq. 2.11).

Para construir um sintoma vibroacústico baseado na ferramenta de demodulação, os passos a seguir são (Duarte, 2005):

- Filtrar o sinal na região de frequência de interesse. Normalmente estas regiões são de ressonância nas altas frequências, pouco influenciada pelos harmônicos de baixa ordem, sempre presentes em sinais de vibração;
- Calcular o sinal analítico (Eq. 2.11);
- Calcular o nível de energia média quadrática e/ou a razão entre os valores máximos e mínimos do módulo do sinal analítico.

2.7. Redes Neurais Artificiais

As redes neurais artificiais, de acordo com Haykin (2001), representam uma tecnologia que tem raízes em muitas disciplinas e encontram aplicações em campos diversos, tais como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle em virtude de ter como propriedade a habilidade de aprender a partir de dados de entrada supervisionados ou não.

Assim, Haykin (2001) define rede neural, vista como uma máquina adaptativa, como:

um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; e forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Casos em que se conhece a entrada e a saída desejada da rede neural, quando do seu treinamento, são chamados de redes neurais de aprendizado supervisionado. Caso tenha-se disponível apenas os padrões de entrada da rede, essas são conhecidas como redes neurais de

aprendizado não supervisionado. De acordo com Silva; Spatti; Flauzino (2010), a maioria das redes com esse padrão não supervisionado se auto-organizam por meio de métodos de treinamento competitivos, os quais tem capacidade de detectar similaridades, regularidades e correlações entre os padrões do conjunto de entrada, agrupando-os em classes, conhecidas como *clusters*.

Essas redes são conhecidas como redes neurais competitivas, e uma das mais difundidas de acordo com Silva; Spatti; Flauzino (2010) são os mapas auto-organizáveis propostos por Teuvo Kohonen, ou simplesmente redes de Kohonen ou SOM (Self-organized Map). Kohonen (1998) publicou um artigo resumindo como funcionam as SOM.

2.8. Algoritmos Genéticos

Algoritmos genéticos (GA) caracterizam um método de otimização heurístico, de caráter aleatório, baseado em uma população genética e foi introduzido por John Holland na década de 1970. De acordo com Kumar et al (2010), os algoritmos genéticos são algoritmos de busca probabilística baseado no mecanismo natural de seleção e evolução e o mesmo sempre é inicializado com uma população. O método consiste na sobrevivência das estruturas melhor adaptadas e na transmissão das características, ou seja, na troca de informações entre cromossomos.

A cada iteração, uma nova cadeia de caracteres, ou população, é gerada usando as melhores características dos elementos da geração anterior.

Basicamente, os GA seguem as seguintes etapas:

- 1º) Geração de uma população inicial com indivíduos escolhidos de maneira aleatória;
- 2º) Avaliação dos indivíduos através do cálculo da função objetivo;
- 3º) Seleção dos indivíduos mais aptos;
- 4º) Aplicação dos operadores genéticos de cruzamento, ou seja, as características dos indivíduos escolhidos são recombinadas, gerando novos indivíduos;
- 5º) Aplicação do operador genético de mutação, ou seja, as características dos indivíduos resultantes do processo de reprodução são alteradas, acrescentando, assim, variedade à população;
- 6º) Geração de uma nova população.

Estas etapas seguem até que um critério de convergência ou de parada seja satisfeito. A Fig. 2.4 mostra o fluxograma para um algoritmo de GA.



Figura 2.4. Estrutura de um Algoritmo Genético Simples.

2.9. Evolução Diferencial

O método de Evolução Diferencial (ED) foi proposto, em 1995, por Storn and Price e é um algoritmo evolutivo usado para resolver problemas de otimização. Uma das principais características dessa metodologia é que esta apresenta uma concepção puramente matemática, baseada em operações vetoriais. Por isso, a mesma é considerada como uma abordagem estrutural (Coelho, 2003 *apud* Lobato, 2008).

O método consiste em gerar aleatoriamente uma população de indivíduos, onde cada indivíduo representa um ponto de busca no espaço de soluções de um determinando problema. Caso não se conheça a priori o problema, a população inicial é gerada através de uma distribuição uniforme.

Basicamente, as ED seguem as seguintes etapas (Lobato, 2008):

1º) Geração da população inicial. Esta deve ter soluções aceitáveis para o problema em estudo e os valores atribuídos às variáveis não violam as fronteiras de projeto;

2º) Seleção de um indivíduo, de maneira randômica, para ser substituído. Seleciona-se três diferentes indivíduos para serem os genitores, e apenas um é selecionado como genitor principal;

3º) Modificação de cada variável do genitor principal, de acordo com uma probabilidade;

4º) Adição da diferença entre as duas outras variáveis, oriundas dos genitores secundários, ao valor atual da variável oriunda do genitor principal, ponderada por uma taxa de perturbação. Este procedimento é conhecido como cruzamento;

5º) Avaliação do vetor resultante. Caso este apresente uma função de adaptação melhor que o genitor principal, ele o substitui, senão, esse vetor é mantido na população.

CAPÍTULO III

Metodologia Utilizada

Apresenta-se, neste capítulo, toda a metodologia utilizada para a identificação dos sinais que são estatisticamente iguais ou não. Em um primeiro momento analisou-se, pelo método estatístico clássico, sinais de compressores avaliados pelos clientes e definidos como bons e ruins pelos mesmos. Vale ressaltar que esses sinais foram adquiridos em uma câmara semianecoica. Em seguida, aos sinais considerados ruins pelos clientes, foram adicionados sinais adquiridos em linha de produção para avaliar a sensibilidade da rede neural auto-organizável de Kohonen (SOM) e verificar a quantidade mínima e máxima de parâmetros de entrada para a rede. Por fim, o mesmo grupo de sinais que foi avaliado pelos clientes foi utilizado para treinar a rede e escolher os parâmetros principais de entrada, através da utilização de técnicas de otimização, tanto os algoritmos genéticos quanto a evolução diferencial.

3.1. Análise estatística clássica

Inicialmente, procurou-se observar a existência de alguma correlação entre a percepção subjetiva dos clientes ao ruído gerado pelos compressores e os Níveis de Potência Sonora (NWS) medidos na câmara semianecoica. Caso existisse de fato uma correlação, seria possível definir sintomas vibroacústicos objetivos para serem utilizados como critério passa-não-passa na sala prova da linha de produção.

Para isto, selecionou-se dois lotes de compressores, sendo que em um deles foram introduzidos defeitos de fabricação, que, após a análise dos clientes finais da Tecumseh, foram divididos num lote composto de compressores considerados bons (11 compressores) e um lote

composto por compressores considerados ruins (14 compressores) pelos clientes. De posse dos dois lotes, os níveis de potência sonora dos mesmos foram medidos numa câmara semianecoica, em conformidade com a norma ISO 3744 - Acoustics – Determination of Sound Power Levels of Noise Sources Using Sound Pressure – Engineering Method in an Essential Free Field over a Reflecting Plane.

3.1.1. Medição dos Níveis de Potência Sonora NWS

Os níveis de potência sonora NWS foram medidos em bandas de 1/3 de oitava centradas entre 100 e 10000 Hz. Os valores de NWS nas bandas de 1/3 de oitava, os valores globais em dBL, os valores globais em dBA e os valores médios de corrente elétrica, resultaram em 24 sintomas para serem comparados.

3.1.2. Estimativa das Médias e Desvios Padrões Amostrais

Medidos os sintomas dos compressores classificados como Bons e Ruins pelos clientes, foram estimados os valores médios através da Eq. 3.1, e os respectivos desvios padrão através da Eq. 3.2, de cada sintoma dos dois grupos.

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (3.1)$$

$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}} \quad (3.2)$$

3.1.3. Critério de Chauvenet

O critério de Chauvenet é um critério de eliminação utilizado para eliminar valores que extrapolam a tendência dominante de uma amostra, garantindo que os resultados sigam uma distribuição Gaussiana. Para aplicar o critério, inicialmente, calcula-se a média das amostras e o desvio padrão do conjunto de dados. O desvio das amostras extremas (maior e menor) é comparado com o desvio padrão, conforme os valores da Tab. 3.1, para se eliminar os pontos duvidosos (caso necessário, repetir os cálculos para as amostras subsequentes). Para a apresentação dos dados finais, um novo valor médio e um novo desvio padrão deverão ser calculados, sem incluir as amostras eliminadas.

O critério foi utilizado neste trabalho somente para o grupo considerado bom de compressores, uma vez que não se deseja ter uma discrepância muito grande dentro do lote de bons, e consistiam em eliminar do grupo os compressores para os quais vários valores de sintoma eram maiores do que a razão d/s crítico. O critério foi utilizado somente para valores de d acima do valor médio amostral.

Tabela 3.1. Tabela de Chauvenet, onde n é o tamanho da amostra, d é o desvio padrão calculado e s crítico é o desvio padrão crítico de Chauvenet.

n	d / s crítico	n	d / s crítico
1	---	16	2,16
2	---	17	2,18
3	---	18	2,20
4	1,54	19	2,22
5	1,65	20	2,24
6	1,73	21	2,26
7	1,80	22	2,28
8	1,85	23	2,30
9	1,91	24	2,31
10	1,96	25	2,33
11	1,99	26	2,35
12	2,03	27	2,36
13	2,06	28	2,37
14	2,10	29	2,38
15	2,13	30	2,39

3.1.4. Teste de Homocedasticidade

Para a comparação dos valores médios das duas populações (Compressores Bons e Compressores Ruins) realizou-se inicialmente um teste de homocedasticidade para definir qual o teste de hipótese sobre igualdade de populações a ser utilizado.

Para testar a alternativa bilateral $H_0: \sigma_1 = \sigma_2$ e $H_1: \sigma_1 \neq \sigma_2$, utiliza-se do fato de que a estatística, mostrada pela Eq. 3.3, é distribuída como uma distribuição F de Snedecor, com $n_1 - 1$ e $n_2 - 1$ graus de liberdade, caso a hipótese nula H_0 seja verdadeira.

$$F_0 = \frac{S_1^2}{S_2^2} \quad (3.3)$$

Portanto, H_0 será rejeitada se a Eq. 3.4 for válida.

$$F_0 > F_{1-\alpha/2, n_1-1, n_2-1} \quad (3.4)$$

Neste trabalho, utilizou-se um nível de significância (α) de 5% para o teste de hipóteses.

3.1.5. Comparação de Médias Populacionais

Para definir se um sintoma vibroacústico pode ser utilizado ou não na classificação dos compressores no quesito ruído, foi utilizado um teste para a diferença entre médias populacionais que corresponde a um teste de hipóteses com hipótese nula de $\mu_1 - \mu_2 = 0$.

Se a hipótese nula for válida, as variáveis t_{homo} e t_{hetero} , calculadas pelas Eq. 3.5 e Eq. 3.6, seguem uma distribuição t de Student para $\mu_1 = \mu_2$.

$$t_{\text{homo}} = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (3.5)$$

$$t_{\text{hetero}} = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (3.6)$$

Onde:

n_1 e n_2 são os tamanhos das amostras 1 e 2, respectivamente; \bar{X}_1 e \bar{X}_2 são os valores médios amostrais; s_1 e s_2 são os valores dos desvios padrões amostrais; t_{homo} é utilizado para testes com amostras homocedásticas com n_1+n_2-2 graus de liberdade; e t_{hetero} é utilizado para testes com amostras heterocedásticas com g graus de liberdade.

$$g = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2} \right)^2}{\left(\frac{s_1^2}{n_1} \right)^2 + \left(\frac{s_2^2}{n_2} \right)^2} - 2$$

Após verificar a existência, ou não, de correlação entre a percepção subjetiva do cliente e as NWS medidas em câmaras semianecoicas, adquiriu-se os sinais de vibração em dois

pontos distintos dos compressores, conforme ilustra a Fig. 3.1. Consideraremos neste trabalho o ponto 1 como sendo a medição na solda e o ponto 2 como sendo a medição na tampa.



Figura 3.1. Pontos de medição da vibração nos compressores.

Os sintomas analisados neste trabalho estão detalhados em anexo. Os mesmos foram divididos em:

- 16 sintomas para análise de harmônicos do motor elétrico;
- 25 sintomas para análise em bandas de 1/3 de oitava entre 40 e 12500 Hz. A banda de 12500 Hz pode ser utilizada, apesar de o acelerômetro ter sido fixado com imã, porque a análise é comparativa e foi utilizada uma placa A/D de 24 bits;
- 14 sintomas para análise em regiões do espectro relacionadas às frequências naturais de componentes do compressor, utilizando sinais de aceleração;
- 14 sintomas para análise em regiões do espectro relacionadas às frequências naturais de componentes do compressor, utilizando sinais de velocidade;
- 11 sintomas para análise em bandas de oitava tendo com frequência fundamental a rotação do motor, utilizando sinais de aceleração;
- 11 sintomas para análise em bandas de oitava tendo com frequência fundamental a rotação do motor, utilizando sinais de velocidade;
- 18 sintomas para análise envelope;
- 17 sintomas para análise da média no domínio do tempo, utilizando sinal de aceleração;

- 16 sintomas para análise da média no domínio do tempo, utilizando sinal de velocidade;
- 14 sintomas para análise no domínio do tempo, utilizando sinal de aceleração;
- 13 sintomas para análise no domínio do tempo, utilizando sinal de velocidade.

O procedimento de análise consistiu de:

- Análise visual de gráficos boxplot (diagrama de caixa e bigodes) com os sinais dos compressores bons e ruins para a definição inicial dos melhores sintomas vibroacústicos a serem utilizados como critério “passa-não-passa” no quesito rumorosidade;
- Comparação, através de teste de hipótese nula e homocedasticidade, de médias dos conjuntos de dados para a escolha dos melhores parâmetros de vibração e ruído a serem utilizados como sintoma para os compressores rotativos.

3.1.6. Gráficos Boxplot

Os gráficos boxplot, conhecidos como diagramas de caixas e bigodes, é uma ferramenta que condensa em um único gráfico, um conjunto de informações estatísticas a respeito da distribuição de um conjunto de dados.

Dentre elas, pode-se destacar:

- Uma grande qualidade da mediana, em relação à média, reside no fato de que a mesma é menos sensível a valores extremos, o que é muito útil em análise que envolve dados com grandes dispersões, como é o caso do estudo de sinais oriundos de componentes com defeito;
- A distância entre as linhas do primeiro e terceiro quartil e a mediana dá uma idéia sobre o nível de achatamento da distribuição;
- A diferença entre os comprimentos das caixas superior e inferior é um indicativo da assimetria da distribuição;
- A distância entre os bigodes e a mediana é um indicativo das “excursões fora da média” do grupo de dados;
- As cruzes estão normalmente relacionadas a problemas na aquisição dos dados.

A Fig. 3.2 mostra um exemplo de gráfico boxplot, onde:

- *a* indica o valor da mediana (linha vermelha);
- *b* são os valores que estão fora dos bigodes (cruz vermelha);

- c é o bigode superior, e indica o valor mínimo de dados que é maior que o primeiro quartil menos 1,5 vezes o comprimento do interquartil (diferença entre os valores do terceiro quartil (e) e o primeiro quartil (f));
- d é o bigode inferior, e indica o valor máximo dos dados que é menor que o terceiro quartil mais uma constante vezes o comprimento do interquartil;
- e é a linha superior da caixa e indica o terceiro quartil (25% dos dados estão acima dessa linha);
- f é a linha inferior da caixa e indica o primeiro quartil (25% dos dados estão abaixo dessa linha);

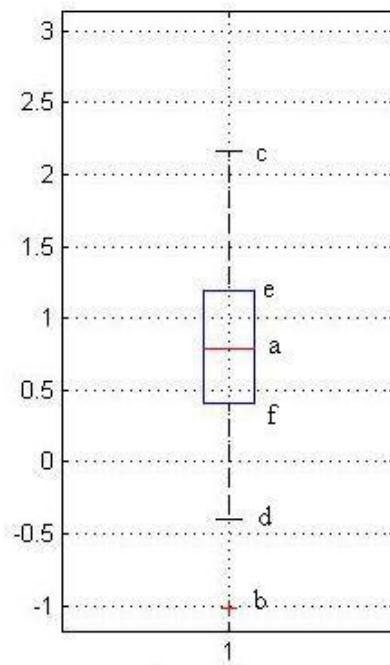


Figura 3.2. Exemplo de um gráfico do tipo boxplot.

Ao analisar o gráfico do tipo boxplot, a caixa e a mediana dos sintomas dos compressores considerados bons devem se localizar preferencialmente abaixo da caixa dos compressores considerados ruins.

3.2. Análise da eficiência e sensibilidade da rede neural

Para avaliar a eficiência e a sensibilidade da rede neural SOM, utilizou-se de dois grupos muito distintos de sinais: o primeiro grupo composto de sinais adquiridos em linha de

produção; e o segundo composto por seis sinais de compressores considerados ruins pelos clientes, adquiridos em uma câmara semianecoica. Como os sinais foram adquiridos de maneira diferente, sabe-se que os mesmos são completamente diferentes.

Como dado de entrada da rede neural, calculou-se os sintomas para cada um dos sinais, totalizando 144 sintomas por sinal. A rede utilizada foi a *newc* do programa MATLAB®, que é uma rede neural auto-organizável baseada nos mapas de Kohonen, configurada para fazer uma separação em dois grupos, ou seja, utilizou-se dois neurônios. Como parâmetros de configuração da rede foram utilizados:

Para verificar a eficiência da rede, utilizou-se de todos os sintomas como parâmetros de entrada.

Já para a análise de sensibilidade, os mesmos sinais da linha de produção e da câmara foram utilizados. Neste caso, utilizou-se de uma otimização heurística para a seleção dos sintomas vibroacústicos. Como o número de sinais dos compressores considerados ruins era conhecido, a função objetivo era minimizar a diferença quadrática entre o menor grupo da saída da rede neural e a quantidade de sinais ruins.

Então, para definir o número mínimo de sintomas, o critério foi se a otimização convergia ou não. Já para o número máximo de sintomas, como não foi considerado uma função de desigualdade onde os parâmetros não podiam ser iguais, caso a otimização retornasse como resultado valores iguais de parâmetro, o mesmo não era necessário. Assim, a quantidade de parâmetros podia ser reduzida.

Para a análise de sensibilidade utilizou-se apenas de otimização feita por algoritmo genético, e o algoritmo utilizado foi o *ga* do programa MATLAB®, com a seguinte configuração:

- população com tamanho de 50;
- fração de cruzamento de 0,8;
- intervalo de migração de 20;
- fração de migração de 0,2;
- fator de penalidade de 100;
- 100 gerações.

O critério de parada utilizado foi a minimização da função objetivo.

3.3. Escolha dos parâmetros a ser utilizados como critério em linhas de produção

Os mesmos foram definidos através da utilização de otimizadores heurísticos e, após o fim da otimização, uma análise dos boxplots dos sintomas escolhidos foi realizada. Neste trabalho, utilizou-se o algoritmo genético e a evolução diferencial. Os sinais utilizados foram os obtidos na câmara semianecoica, classificados pelos clientes como bons ou ruins.

Das funções objetivo tentadas, a melhor foi: sabendo-se que os sinais considerados bons foram colocados primeiro que os sinais considerados ruins, o objetivo era fazer com que o otimizador aproximasse dessa configuração, ou seja, forçar a rede neural a separar os grupos da maneira como foram montados.

Para o algoritmo genético, as configurações utilizadas foram as mesmas utilizadas no tópico anterior.

Já para o algoritmo de evolução diferencial, as configurações utilizadas foram:

- critério de parada de 10^{-20} ;
- tamanho da população de 50;
- 100 gerações;
- taxa de perturbação de 0,5;
- probabilidade de cruzamento de 0,8;
- estratégia 7 (ver Lobato, 2008).

3.4. Verificação da viabilidade da SOM em linhas de produção real, sem conhecimento prévio das conformidades e não-conformidades

Após validar a metodologia e comparar os sintomas escolhidos pelo método estatístico clássico com os escolhidos pela combinação rede neural SOM e métodos heurísticos (GA e ED), desejou-se verificar a aplicabilidade da metodologia em linhas de produção, ou seja, desejou-se avaliar a possibilidade de usar a metodologia para identificar os produtos conformes e não conformes em linhas de produção, sem o conhecimento prévio da quantidade de defeituosos e dos sintomas mais representativos.

Para isso, desenvolveu-se um programa em C++, apenas para a combinação SOM e GA. Para testar a viabilidade, calculou-se os 144 sintomas para os 192 compressores testados na linha de produção. Os sinais de vibrações utilizados para o computo dos sintomas foram

adquiridos com uma frequência de aquisição de 32.768 Hz durante cinco segundos para cada compressor. Dentre os compressores testados em linha estavam os compressores considerados ruins pelos clientes. O GA utilizado foi com uma população de 50 indivíduos e 200 gerações.

A função objetivo escolhida é mostrada na Eq. 3.7.

$$\text{Obj}(x) = N_{\text{Min}}^2 + \lambda(x_i = x_j) + \lambda(T(x_{\text{Min}})/T_{\text{critico}}) \quad (3.7)$$

Onde N_{Min} é o menor número de ocorrências entre todos os neurônios, $\lambda(x_i = x_j)$, é uma penalidade para quando se encontra sintomas repetidos e vale 100 se $x(i)=x(j)$, $\lambda(T(x_{\text{Min}})/T_{\text{critico}}) = (5 - T(x_{\text{Min}})/T_{\text{critico}})^2$ é uma penalidade para os casos em que a média populacional de um sintoma relacionado aos dados de menor ocorrência seja igual à média das demais ocorrências, para o mesmo sintoma e é aplicada quando a razão $T(x_{\text{min}})/T_{\text{critico}}$ é menor que cinco. Utiliza-se um teste para diferenças de média explicado em no subcapítulo 3.1 com 5% de significância. O valor da razão até cinco foi escolhida uma vez que, segundo Hines et al (2006), tem-se bastante confiança na hipótese alternativa ou seja, quando as médias populacionais são mesmo diferentes.

Sabe-se que, em um lote de produtos, a quantidade de produtos defeituosos é mínima. Assim, acredita-se que, após o treinamento de uma rede competitiva com N neurônios, o neurônio com o menor número de ocorrências (N_{min}) terá selecionado os sinais dos produtos não conformes (segregados). Outra característica dos sintomas do conjunto segregado é a de que a média populacional dos sintomas para este conjunto será diferente da média populacional do conjunto composto pelos outros produtos, ou seja, um teste t para comparação das médias entre o conjunto segregado e os demais $T(x_{\text{min}})$ dividido por T_{critico} será bem maior do que a unidade, onde T_{critico} é a o valor da função distribuição de probabilidade t para o nível de significância α escolhido. Inseriu-se, também, a penalidade para os sintomas repetidos porque ao deixar o programa livre, sem a penalização, a partir de seis parâmetros de entrada, os sintomas começam a se repetir.

CAPÍTULO IV

Análise Estatística Clássica

Os resultados da análise estatística clássica são apresentados neste capítulo. Foram avaliados sinais de compressores classificados e definidos pelos clientes como bons e ruins. Vale ressaltar que esses sinais foram adquiridos em uma câmara semianecoica, obedecendo à norma ISO 3744.

4.1. Avaliação da correlação entre a percepção subjetiva do cliente e os valores NWS dos compressores

A utilização do critério de Chauvenet somente para os valores de d acima do crítico e para o conjunto de dados considerados bons pelos clientes permitiu a eliminação dos dados de um compressor, resultando em dois conjuntos de 11 compressores bons e 14 ruins.

Na Tab. 4.1 estão listados os 24 sintomas estudados e respectivas razões $F/F_{0.975,10,13}$ utilizados no teste de homocedasticidade.

Da análise da Tab. 4.1, observa-se que apenas para duas bandas de frequência (1250 e 10000 Hz), as amostras são homocedásticas, ou seja, a razão $F/F_{0.975,10,13}$ é menor que um. Nas bandas de 500 e 630 Hz, observa-se uma grande diferença entre os desvios padrões estimados para a amostra dos compressores bons ($s_{500}= 1,35$ e $s_{630}=1,31$) e os estimados para o grupo de compressores ruins ($s_{500}= 3,51$ e $s_{630}=4,30$). Isto é evidenciado pelo fato de que ambas as bandas apresentaram razões $F/F_{0.975,10,13}$ muito maiores que um, o que indica uma grande dispersão dos valores dos sintomas dos compressores ruins.

Tabela 4.1. Teste de Homocedasticidade para os sintomas estudados

Sintoma	F/F _{0,975,10,13}	Sintoma	F/F _{0,975,10,13}
100 Hz	4,39	1600 Hz	2,48
125 Hz	2,16	2000 Hz	1,12
160 Hz	2,03	2500 Hz	2,14
200 Hz	2,68	3150 Hz	2,62
250 Hz	2,00	4000 Hz	1,48
315 Hz	1,22	5000 Hz	1,86
400 Hz	1,62	6300 Hz	1,99
500 Hz	6,71	8000 Hz	1,90
630 Hz	10,34	10000 Hz	0,46
800 Hz	2,78	dBL	3,29
1000 Hz	1,19	dBA	2,99
1250 Hz	0,96	Corrente	1,52

Na Tab. 4.2 estão listados os 24 sintomas estudados e respectivas razões $t/t_{0,95,23}$ utilizados no teste para comparação de médias. Pode-se observar que as maiores diferenças entre as médias foram para as bandas de frequência centradas entre 315 e 500 Hz e as bandas centradas em 800 e 6300 Hz. É interessante observar também que o teste de hipóteses foi recusado para os valores globais dBL e dBA, sendo que o último é um bom estimador da sensação auditiva do ouvido humano.

Somando-se os níveis de energia sonora nas bandas de 315 a 500 Hz, resultou num sintoma cuja razão $t/t_{0,95,23}$ é de 4,35, ou seja, é um excelente sintoma para avaliar a qualidade acústica dos compressores estudados. O sintoma de NWS na banda de 315 a 500 Hz para os compressores bons e ruins é apresentado no boxplot da Fig. 4.1.

Tabela 4.2. Comparação das Médias dos sintomas estudados

Sintoma	$t/t_{0,95,23}$	Sintoma	$t/t_{0,95,23}$
100 Hz	0,14	1600 Hz	1,75
125 Hz	0,81	2000 Hz	0,43
160 Hz	0,08	2500 Hz	1,22
200 Hz	0,21	3150 Hz	0,98
250 Hz	1,30	4000 Hz	2,08
315 Hz	2,23	5000 Hz	1,65
400 Hz	2,54	6300 Hz	2,15
500 Hz	2,51	8000 Hz	1,49
630 Hz	1,51	10000 Hz	0,70
800 Hz	2,56	Dbl	1,75
1000 Hz	0,24	dBA	1,62
1250 Hz	0,68	Corrente	0,48

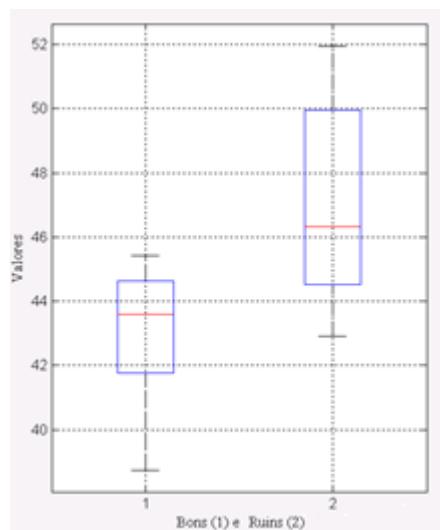


Figura 4.1. Boxplot para o sintoma NWS na banda de 315 a 500 Hz.

Nas Fig. 4.2 e 4.3 são mostrados os diagramas de caixa para os sintomas NWS nas bandas de 800 e 6300 Hz, respectivamente.

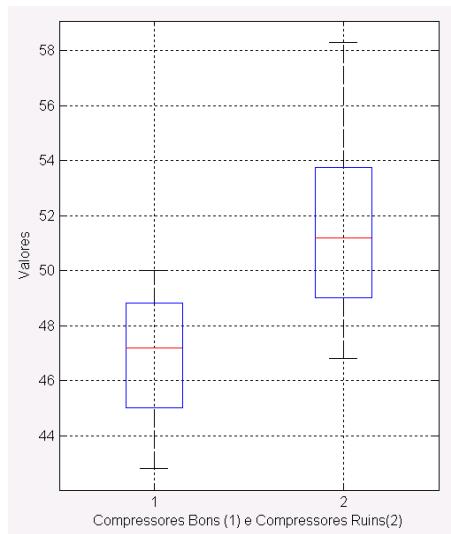


Figura 4.2. Gráfico de caixas para o sintoma NWS na banda de 800 Hz.

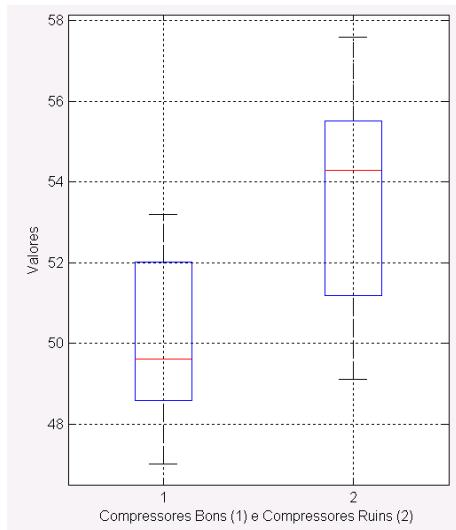


Figura 4.3. Gráfico de caixas para o sintoma NWS na banda de 6300 Hz.

Da análise das três figuras, observa-se que há uma boa correlação entre a percepção de ruído do cliente com os valores de NWS nas bandas de 315 a 500 Hz e nos valores de 800 e 6300 Hz, uma vez que nas três figuras a caixa dos compressores considerados bons se encontra abaixo dos considerados ruins e as medianas dos bons não cruzam com a caixa do grupo dos ruins.

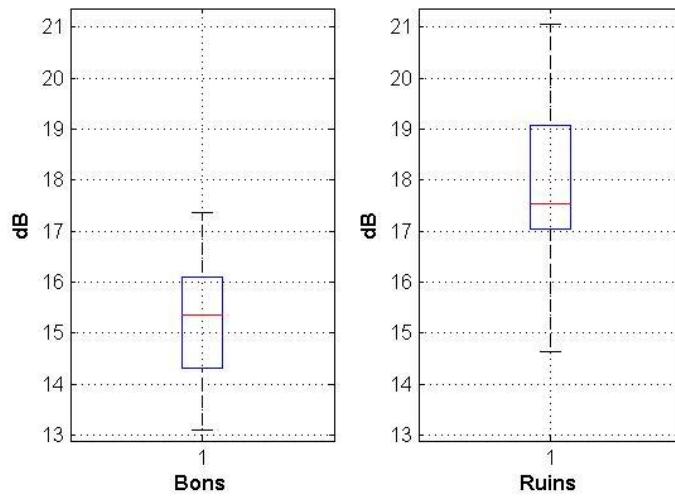
4.2. Avaliação dos sintomas e do melhor ponto para colocação do acelerômetro

Na Tab. 4.3 estão listados os melhores sintomas analisados e respectivas razões $t/t_{0.95,n}$ utilizados no teste para comparação de médias para o ponto 1. Todos os valores estão em dB (Referência 1).

Tabela 4.3. Comparação das médias dos melhores sintomas estudados para o ponto 1.

Sintoma	Descrição	$t/t_{0.95,n}$
116	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 12.000 Hz	2,79
115	Nível de energia do envelope filtrado com filtro passa-alta em 12.000 Hz	2,54
114	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 10.000 Hz	2,42
98	Oitavo conjunto de harmônicos de passagem das ranhuras do rotor	2,16
112	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 8.000 Hz	2,15
84	Segundo conjunto de harmônicos de passagem das ranhuras do estator.	2,08
110	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 6.000 Hz	1,99
5	K4 ($10\log_{10}(RMS * Curtose)$)	1,80
3	Curtose	1,78
4	Fator de Crista	1,68

Da análise da tabela, o melhor resultado entre todos os sintomas é o sintoma 116, relativo à diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 12.000 Hz. Na Fig. 4.4 é mostrado o diagrama boxplot para tal sintoma.



4.4. Diagrama boxplot para o sintoma 116.

Observa-se na Fig. 4.4 uma diferença de 2 dB entre as medianas, além da não existência de valores fora do bigode (ausência de cruz vermelha). Observa-se que o interquartil (caixa azul que mostra a variância da amostra) é mais estreito e está distante entre si, o que torna este sintoma muito bom para ser utilizado na montagem de uma máscara passa-não-passa.

Vale ressaltar que as medianas de alguns sintomas possuíam boa diferença no diagrama boxplot, porém, por possuírem valores fora do bigode, foram reprovados quando realizadas as comparações das médias amostrais.

Na Fig. 4.5 é mostrado o diagrama boxplot para o melhor sintoma calculado para os harmônicos superiores do motor, ou seja, o sintoma 98.

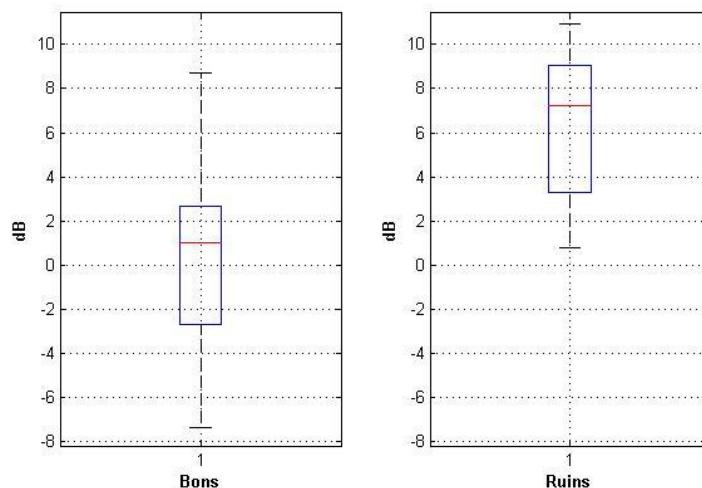


Figura 4.5. Diagrama boxplot para o sintoma 98.

Ao analisar a figura, nota-se que a diferença das medianas é de 6 dB, sendo que o terceiro quartil do conjunto dos bons não cruza com o primeiro quartil do conjunto dos ruins, o que torna este sintoma excelente como critério “passa-não-passa”.

Na Fig. 4.6 é mostrado o diagrama boxplot para o melhor sintoma calculado para os sintomas no domínio do tempo, utilizando os sinais de aceleração, ou seja, o sintoma 5.

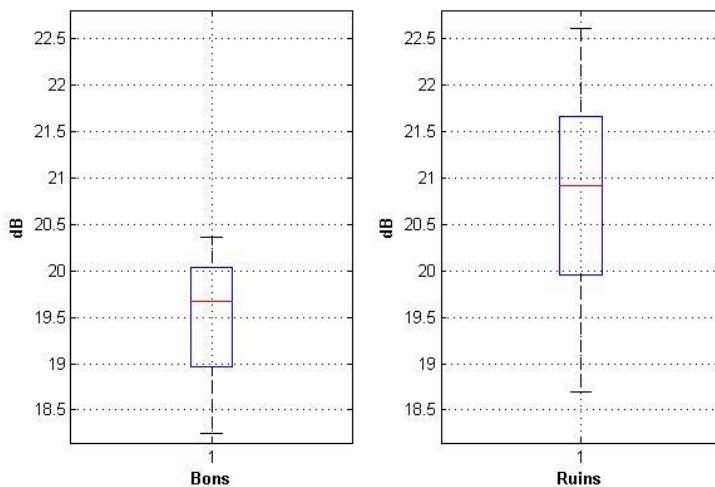


Figura 4.6. Diagrama boxplot para o sintoma 5.

Ao analisar a Fig. 4.6, percebe-se que a variação da mediana é muito pequena, da ordem de 1 dB. A diferença das médias é então explicada pela análise do interquartil dos dados considerados bons, que possui pouca variação, da ordem de 1 dB.

Na Tab. 4.4 estão listados os melhores sintomas analisados e as respectivas razões $t/t_{0.95,n}$ utilizados no teste para comparação de médias, para o ponto 2. Deve-se ressaltar que todos os sintomas são valores médios quadráticos.

Tabela 4.4. Comparação das médias dos melhores sintomas estudados para o ponto 2.

Sintoma	Descrição	$t/t_{0.95,n}$
161	Filtro de 1/3 de oitava centrado em 2.000 Hz	2,39
45	TDA filtrado abaixo de 40 Hz, do sinal de velocidade	2,09
49	TDA filtrado na banda de 1000 a 4000 Hz, do sinal de velocidade	2,06
50	TDA filtrado acima de 500 Hz, do sinal de velocidade	2,01
32	TDA filtrado na banda de 1000 a 4000 Hz, do sinal de aceleração	1,95
162	Filtro de 1/3 de oitava centrado em 2500 Hz	1,43

O melhor resultado, para o ponto 2, é o sintoma 161. Na Fig. 4.7 está mostrado o diagrama boxplot para tal sintoma.

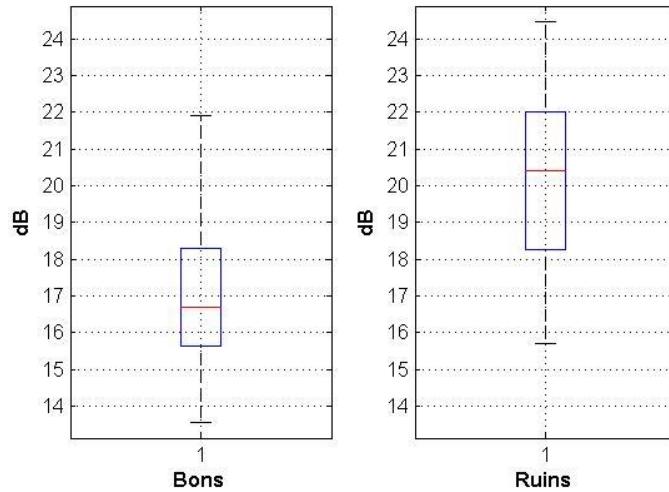


Figura 4.7. Diagrama boxplot para o sintoma 161.

A diferença entre as medianas, observada na Fig. 4.7, é da ordem de 3 dB, que em conjunto com a não interseção do terceiro com o primeiro quartil torna este sintoma um bom critério “passa-não-passa”.

Comparando as Tab. 4.3 e 4.4, observa-se que as medições no ponto 1 resultaram em uma maior quantidade de sintomas válidos a serem utilizados como sintomas de rumorosidade do compressor estudado. Assim, para todos os cálculos e análises posteriores adquiriu-se os sinais com o acelerômetro localizado no ponto um, ou seja, na solda.

Como para o ponto um não foi escolhido nenhum sintoma relacionado aos valores em terço de oitava, os mesmos não foram mais considerados nas etapas posteriores, o que resultou em 144 sintomas para análise.

CAPÍTULO V

Resultados Para o Estudo da Eficiência da Rede Neural Auto-Organizável e Definição da Quantidade Mínima e Máxima de Sintomas Vibroacústicos

Os resultados do estudo da eficiência da rede neural auto-organizável de Kohonen, bem como a análise de sensibilidade da rede, ou seja, a definição da quantidade mínima e máxima de sintomas vibroacústicos necessárias, são apresentadas neste capítulo. Para tanto, adicionou-se aos sinais adquiridos em linha de produção seis sinais de compressores considerados ruins pelos clientes, medidos em uma câmara semianecoica. Como os sinais foram adquiridos de maneira diferente, sabe-se com certeza que, entre os grupos, os sinais são estatisticamente distintos. Assim, foi possível determinar se a rede neural auto-organizável era mesmo capaz de separar os sinais em dois grupos estatisticamente diferentes.

Já para a análise de sensibilidade, os mesmos sinais da linha de produção e da câmara foram utilizados. Neste caso, utilizou-se de uma otimização heurística para a seleção dos sintomas vibroacústicos. Como o número de sinais dos compressores considerados ruins era conhecido, a função objetivo era minimizar a diferença quadrática entre o menor grupo da saída da rede neural e a quantidade de sinais ruins. As únicas restrições do problema eram os valores mínimo e máximo que os parâmetros de entrada do algoritmo genético podia valer.

Então, para definir o número mínimo de sintomas o critério foi se a otimização convergia ou não. Já para o número máximo de sintomas, como não foi considerado uma função de desigualdade onde os parâmetros não podiam ser iguais, caso a otimização retornasse como resultado valores iguais de parâmetro, o mesmo não era necessário. Assim, a quantidade de parâmetros podia ser reduzida.

5.1. Estudo da eficiência da SOM

A Fig. 5.1 mostra o resultado obtido ao utilizar a rede neural *newc* do MATLAB®. Como parâmetros de entrada, utilizou-se de todos os sintomas, totalizando 144 sintomas e foram escolhidos dois neurônios, ou seja, desejava-se saber se a rede conseguiria dividir os sinais em dois grupos estatisticamente diferentes.

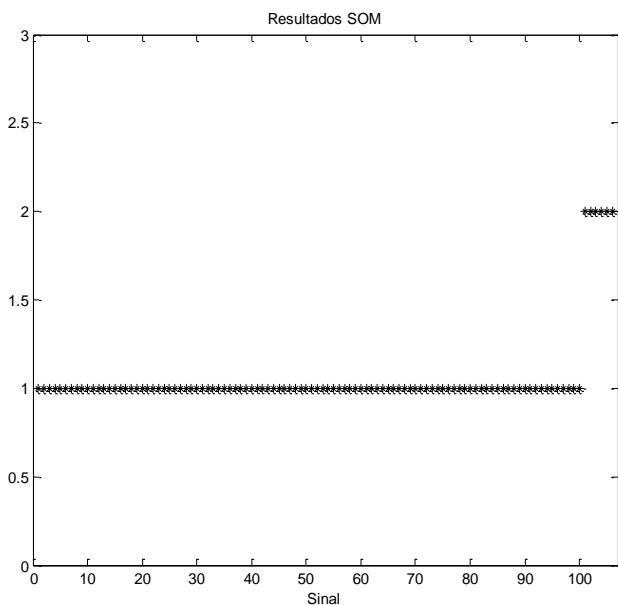


Figura 5.1. Resultado obtido com a rede neural e 144 parâmetros de entrada.

Pela análise da Fig. 5.1, observa-se que a rede separou os sinais em dois grupos: um e dois. Como montou-se os dados de maneira a deixar os 100 sinais da linha de produção no inicio e os seis sinais diferentes por último, pode-se concluir que a rede neural utilizada é capaz de identificar e separar os grupos estatisticamente diferentes ao utilizar todos os sintomas vibroacústicos.

5.2. Definição da quantidade mínima e máxima de sintomas para serem usados como dados de entrada da SOM.

Após verificar a eficiência da rede neural implementada pelo MATLAB®, optou-se por verificar a sensibilidade da rede e o número de parâmetros necessários, uma vez que o cálculo

de todos os sintomas dispende tempo computacional e não se faz necessária a utilização de todos os sintomas para que a rede consiga identificar os padrões.

Assim, de posse dos 100 sinais da linha de produção e seis sinais da câmara semianecoica, utilizou-se de algoritmo genético para analisar essa sensibilidade. Como se conhecia a quantidade de sinais medidos na câmara, a função objetivo era minimizar a diferença quadrática entre o menor grupo da saída da rede neural e a quantidade desses sinais. Colocou-se como restrição apenas os valores mínimo e máximo dos parâmetros, ou seja, x devia variar entre 1 e 144 (número total de sintomas) e deixou-se o algoritmo livre para escolher valores de x iguais. Desse modo, foi possível verificar a quantidade de parâmetros necessários.

A Tab. 5.1 apresenta os resultados obtidos com as otimizações tanto da função objetivo quanto dos valores obtidos para x . Vale ressaltar que escolheu-se inicialmente fazer a otimização até 12 parâmetros em função da capacidade computacional disponível, uma vez que o computador possuía 12 núcleos, e que foram feitas diversas otimizações uma vez que a população inicial de GA é escolhida de maneira randômica.

Tabela 5.1. Resultados obtidos pela GA.

Número de Parâmetros Utilizados	Valor da função objetivo	Sintomas Escolhidos
1	$8,1162 \cdot 10^{-13}$	88
2	$8,1162 \cdot 10^{-13}$	95; 114
3	$8,1162 \cdot 10^{-13}$	73; 95; 137
4	$8,1162 \cdot 10^{-13}$	5; 84; 88; 141
5	$8,1162 \cdot 10^{-13}$	1; 23; 38; 83; 98
6	$8,1162 \cdot 10^{-13}$	1; 1; 1; 1; 62; 111
7	$8,1162 \cdot 10^{-13}$	1; 1; 1; 1; 1; 1; 2
8	$8,1162 \cdot 10^{-13}$	1; 1; 1; 1; 1; 1; 1; 2
9	$8,1162 \cdot 10^{-13}$	1; 1; 1; 1; 1; 1; 1; 2; 4
10	$8,1162 \cdot 10^{-13}$	6; 20; 33; 36; 68; 71; 78; 83; 90; 119
11	$8,1162 \cdot 10^{-13}$	1; 1; 1; 1; 1; 1; 1; 1; 2; 3; 4
12	$8,1162 \cdot 10^{-13}$	1; 1; 1; 1; 1; 1; 1; 1; 2; 3; 3; 4

Da análise da Tab. 5.1 pode-se concluir que a partir de seis sintomas, o algoritmo começa a repetir os sintomas, e não converge mais. Para o número de parâmetros iguais a 10, observa-se que o mesmo converge, ou seja, não há nenhum valor de sintoma repetido. Porém, ao refazer a otimização, o mesmo não convergiu. Assim, como para este caso o início da otimização influencia diretamente no resultado, o mesmo não pode ser considerado como sendo o número máximo de sintomas necessário.

Observa-se também na tabela que, para apenas um sintoma, a otimização convergiu, ou seja, a função objetivo vale zero. Ao refazer as otimizações para este caso, a cada otimização o valor do parâmetro x variava, modificava. Assim, utilizar apenas um parâmetro como critério é perigoso uma vez que existem ruídos espúrios que podem comprometer a qualidade do sinal e algum de seus sintomas.

Assim, ficou definido que o número mínimo de sintomas a ser utilizados como dados de entrada é dois e o máximo cinco, partindo-se da premissa de que o número de produtos não-conformes fossem, a priori, desconhecidos.

CAPÍTULO VI

Escolha dos parâmetros a serem utilizados como critério em linhas de produção

Os resultados obtidos através da utilização de otimizadores heurísticos, GA e ED, bem como a análise dos boxplots dos sintomas escolhidos são apresentados neste capítulo. Uma comparação dos sintomas escolhidos via otimização e através da análise estatística clássica também é apresentada.

Inicialmente, apresenta-se a resposta ideal esperada, para a saída da rede neural, ou seja, como a rede deveria separar os sinais. Após, os resultados obtidos via GA e ED são analisados, bem como uma comparação entre os otimizadores. Por fim, uma comparação entre os resultados obtidos via otimização e via análise estatística clássica é apresentada.

6.1. Resposta ideal esperada pela SOM

A Fig. 6.1 mostra a resposta ideal da saída da rede neural auto-organizável. Esta resposta foi utilizada como função objetivo para todas as otimizações.

Da análise da figura, nota-se que, em teoria, a rede deve separar em dois grupos distintos, o primeiro com os primeiros 11 sinais sequenciais e o segundo grupo composto pelos últimos sinais. O valor um e dois depende da saída da rede e não tem grande relevância para o trabalho, ou seja, não importa qual grupo obtém o valor um ou dois.

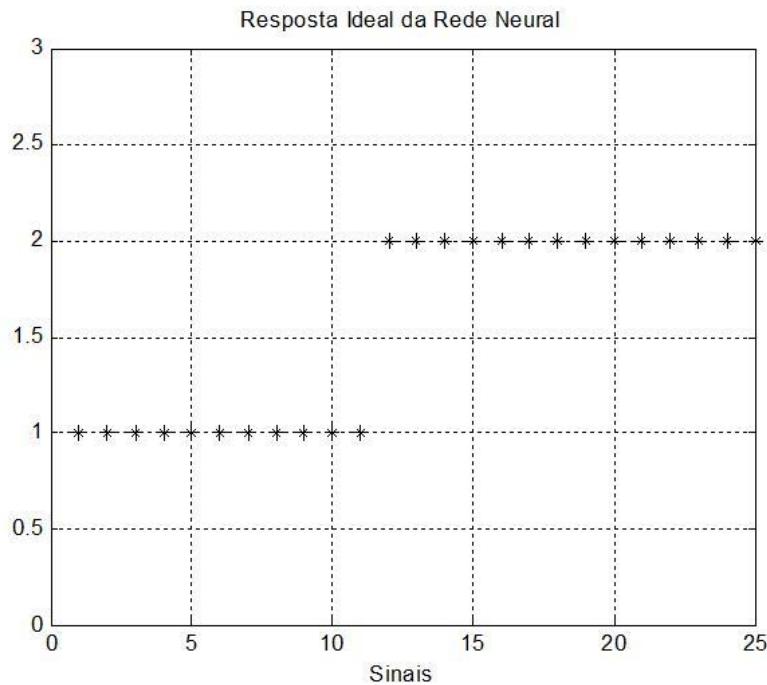


Figura 6.1. Resposta esperada para a saída da rede SOM.

6.2. Respostas obtidas para a otimização via Algoritmos Genéticos

A Tab. 6.1 apresenta os resultados obtidos, número de parâmetros de entrada, valor da função objetivo e sintomas escolhidos para a otimização via GA. Vale ressaltar que foram feitas otimizações apenas de dois a cinco parâmetros, pois verificou-se anteriormente que com o aumento dos parâmetros, a otimização já não converge mais, para este caso.

Tabela 6.1. Resultados obtidos via GA

Número de Parâmetros	Função Objetivo	Sintomas Escolhidos
2	886	42; 116
3	478	10; 38; 116
4	503	39; 102; 116; 142
5	634	18; 34; 50; 80; 86

Da análise da Tab. 6.1, observa-se que para três parâmetros, obteve-se a menor função objetivo, e após, já começa a aumentar novamente essa função. Então, para otimizar via

algoritmos genéticos, a melhor escolha é para três parâmetros. Observa-se também na tabela que o sintoma 116 repete em quase todos os casos. Este sintoma, para a análise estatística clássica, também foi eleito como o melhor sintoma para se classificar compressores.

A Fig. 6.2 mostra as saídas da rede neural obtidas para cada um dos casos.

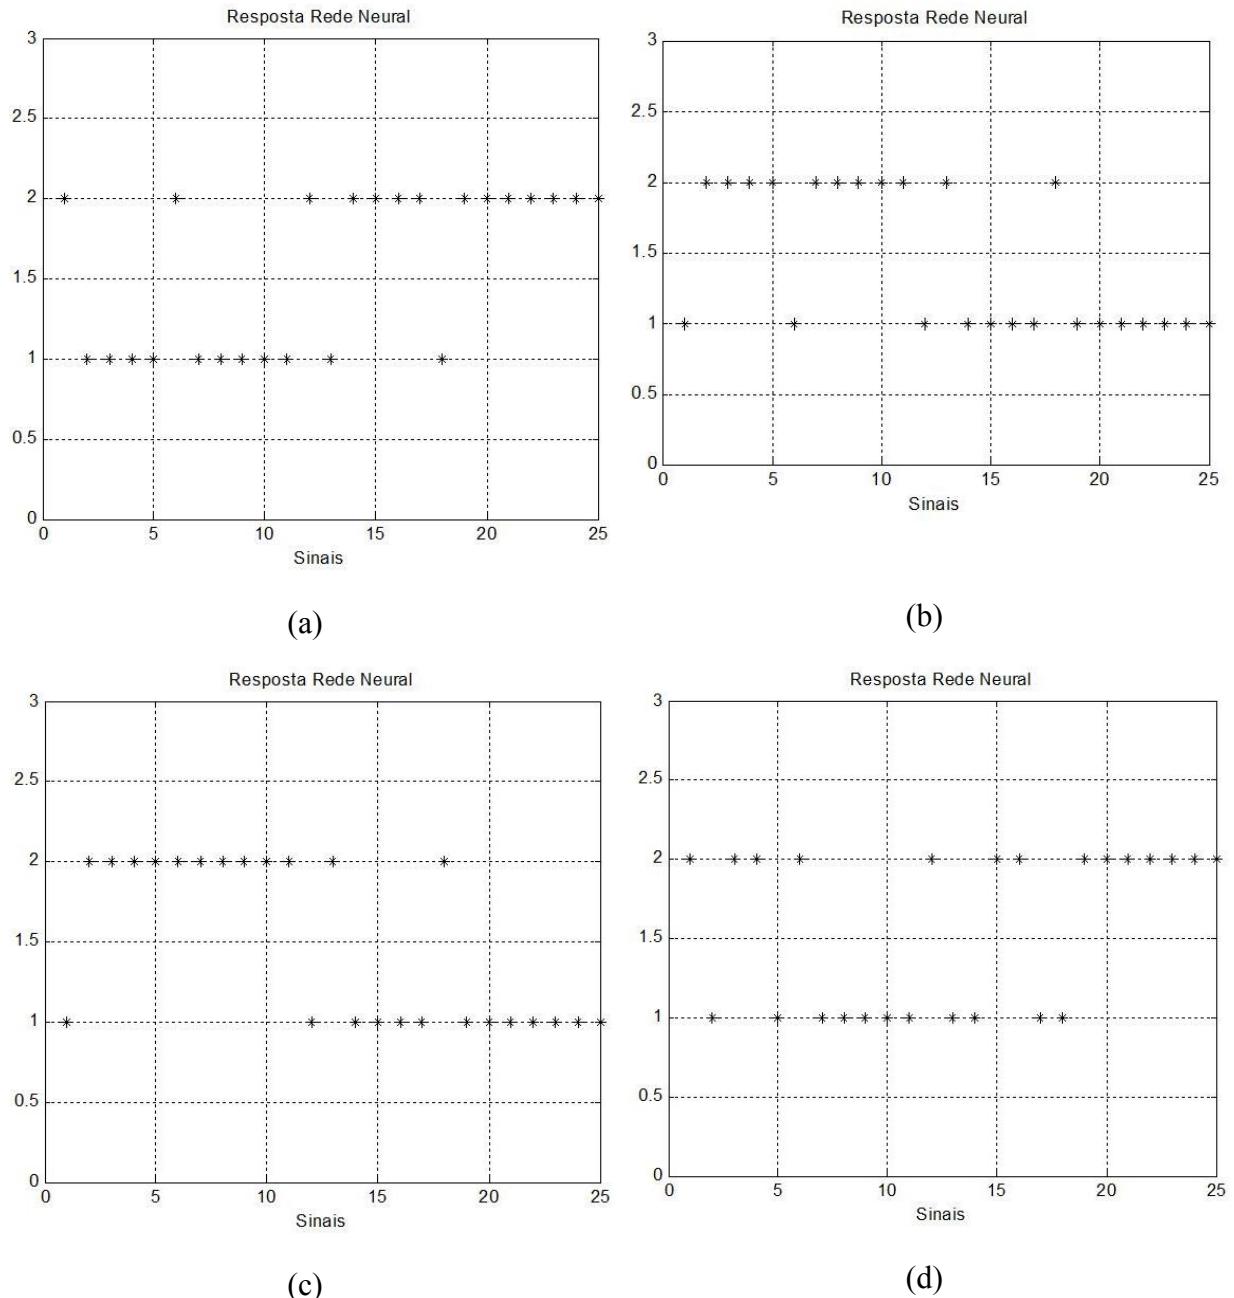
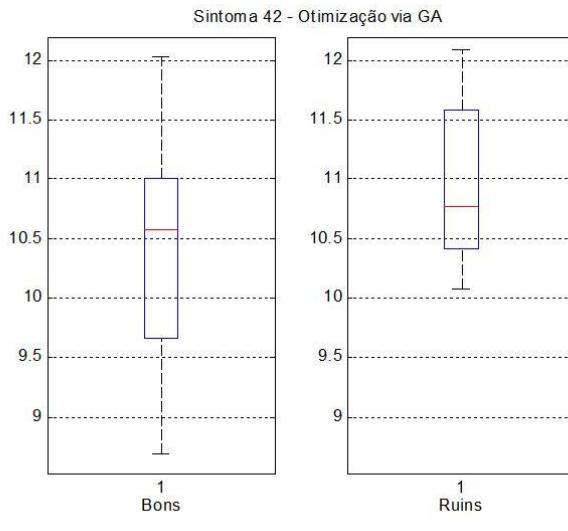


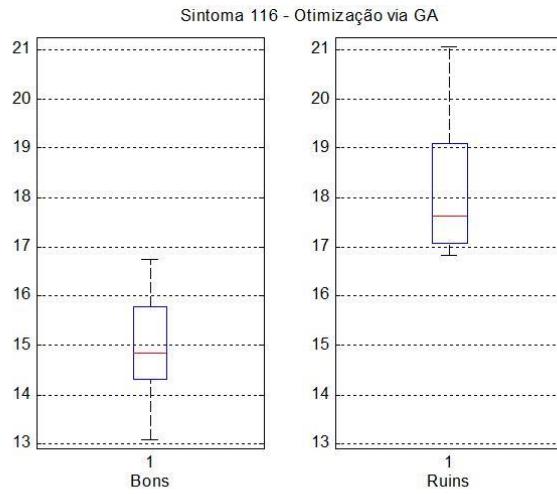
Figura 6.2. Respostas da saída da SOM para: (a) dois parâmetros, (b) três parâmetros, (c) quatro parâmetros e (d) cinco parâmetros de entrada para otimização via GA.

Da análise da Fig. 6.2, ao compará-las com a Fig. 6.1, observa-se que ao utilizar três e quatro sintomas, a resposta fica mais próxima da ideal. Já para cinco parâmetros, como já foi observado na Tab. 6.1, os resultados não foram de acordo com o esperado.

Os gráficos boxplot para cada síntoma escolhido e para cada caso são apresentados nas Fig. 6.3 a Fig. 6.6.

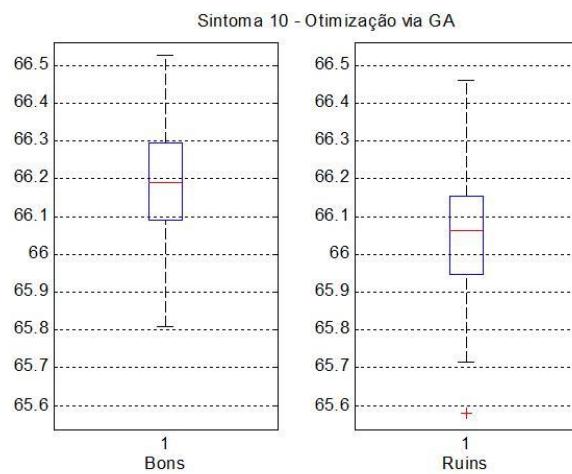


(a)

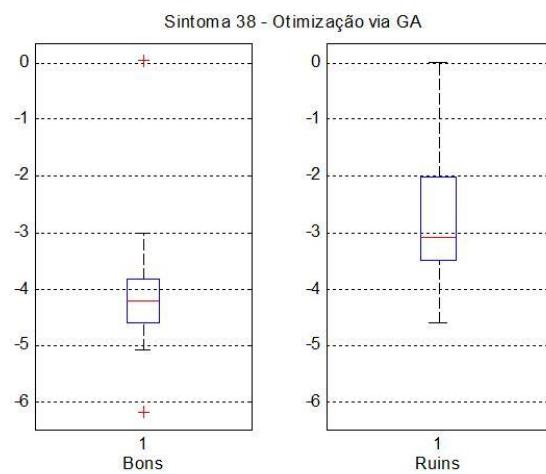


(b)

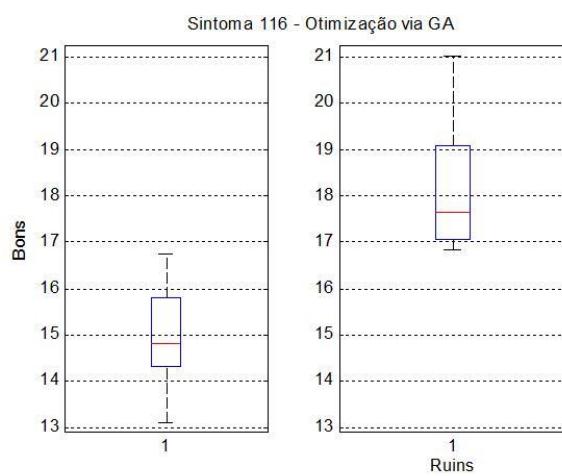
Figura 6.3. Sintomas escolhidos para a otimização com dois parâmetros de entrada.



(a)



(b)



(c)

Figura 6.4. Sintomas escolhidos para a otimização com três parâmetros de entrada.

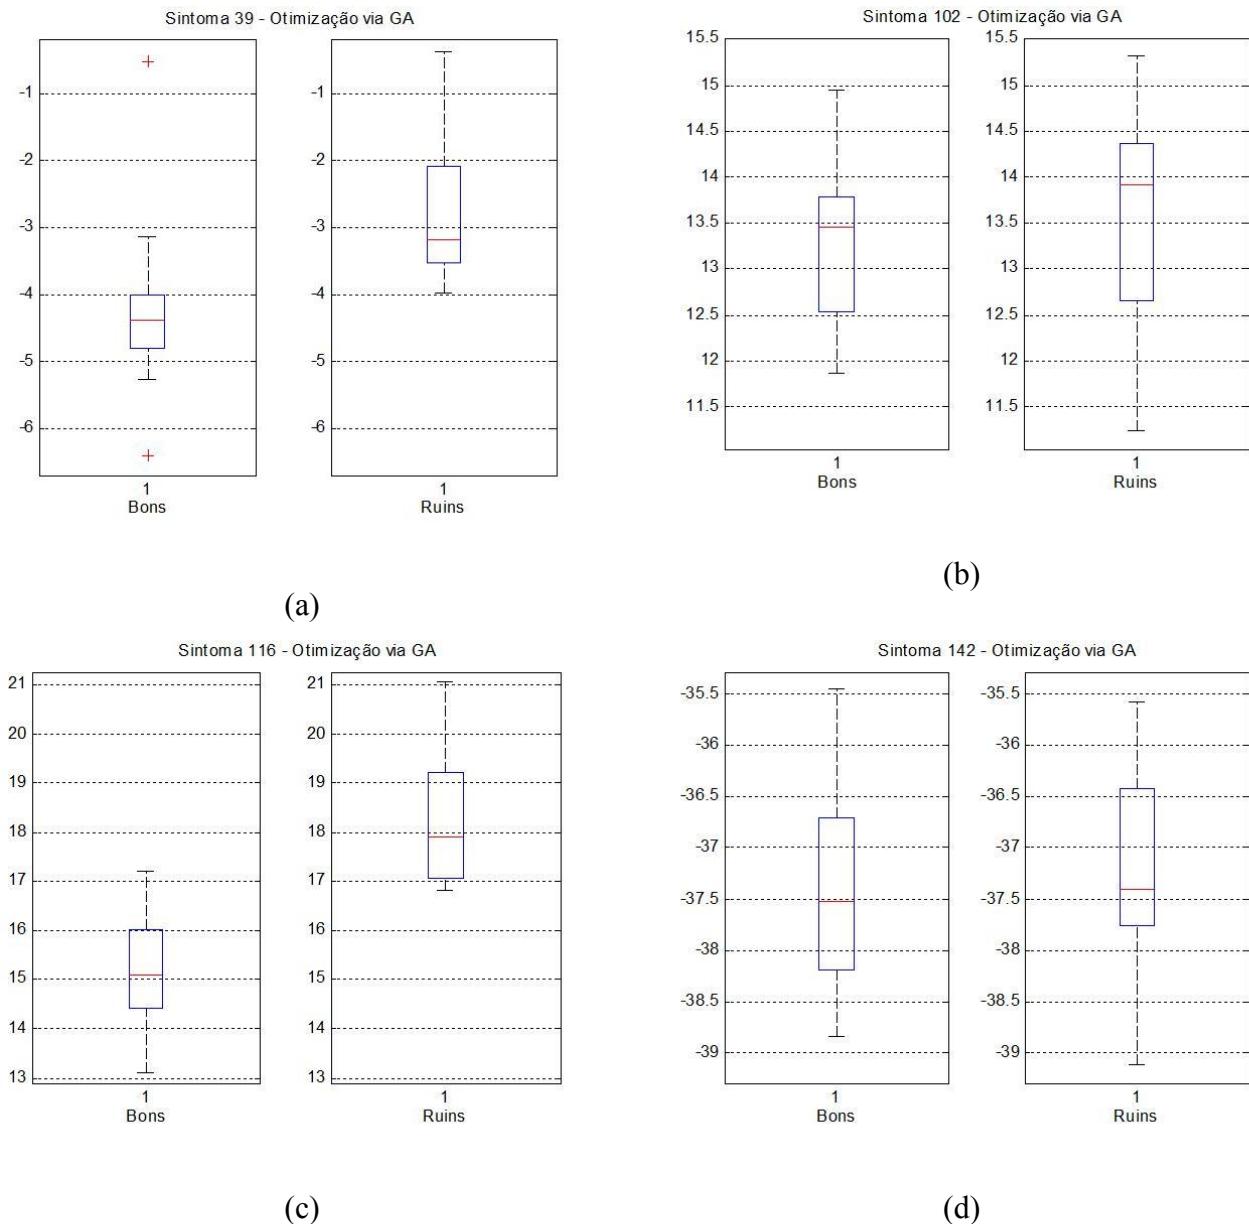


Figura 6.5. Sintomas escolhidos para a otimização com quatro parâmetros de entrada.

Observa-se na Fig. 6.3 que o sintoma que comanda a escolha da rede neural é o sintoma 116, onde existe uma diferença de 3 dB entre as medianas, os gráficos não se cruzam, ou seja, não tem valores iguais, além da não existência de valores fora do bigode. Observa-se também que o interquartil dos sinais considerados bons se encontram abaixo dos considerados ruins, o que era esperado. Já o sintoma 42, o diagrama dos sinais considerados bons engloba todo o diagrama dos considerados ruins e a diferença entre as medianas não é significativa, em torno de 0,5 dB.

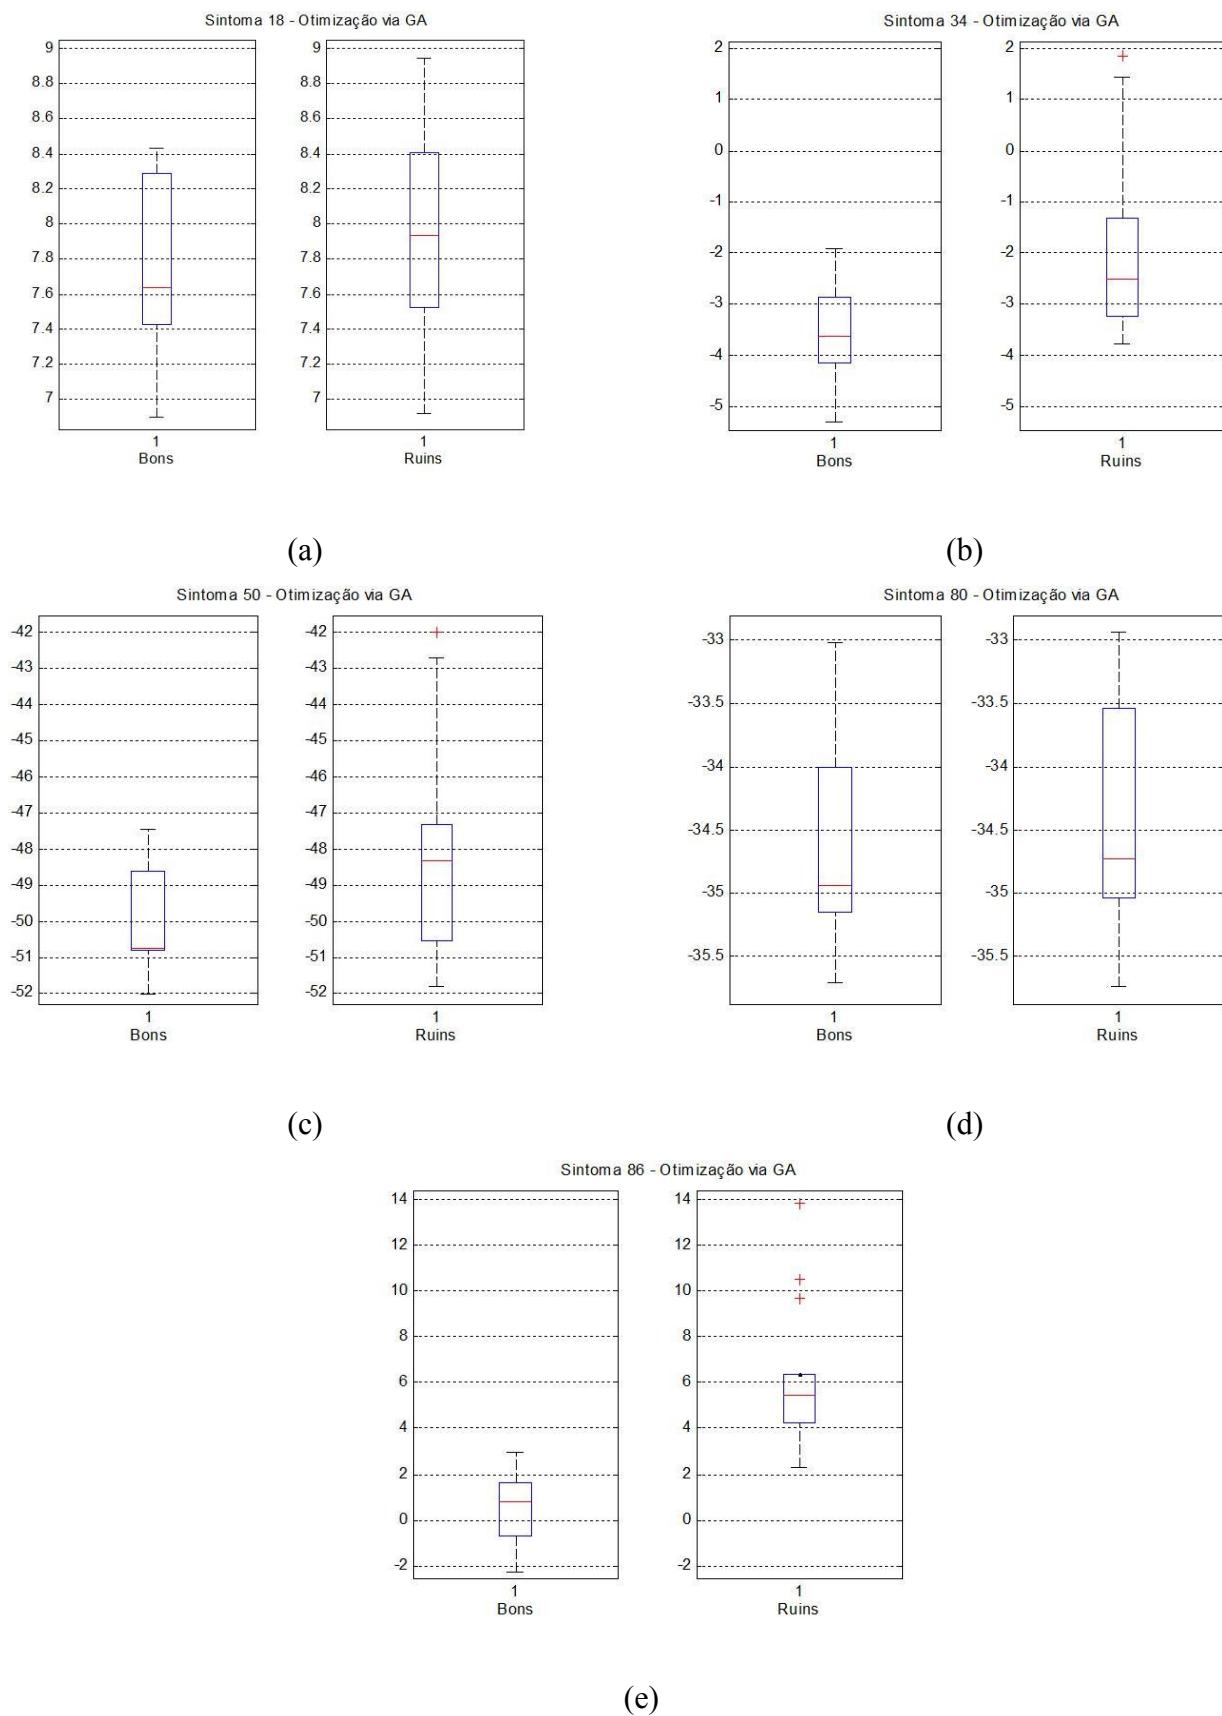


Figura 6.6. Sintomas escolhidos para a otimização com cinco parâmetros de entrada.

Ao analisar a Fig. 6.4, apenas o sintoma 116 é relevante, e apresenta uma diferença de 3 dB entre as medianas. Já o sintoma 10 não tem nenhuma contribuição pois a diferença entre as medianas é insignificante e o diagrama dos sinais bons está acima dos sinais ruins. O sintoma 38 possui valores fora do bigode (cruz) e por isso não é um bom sintoma.

Já da análise da Fig. 6.5, em todos os sintomas, o diagrama dos sinais considerados bons estão abaixo do diagrama dos sinais considerados ruins, porém apenas o sintoma 116 é relevante e comanda a otimização da rede.

Observa-se, por fim, na Fig. 6.6 que apenas o sintoma 86 é relevante, com uma diferença de 4 dB entre as medianas, porém o mesmo possui valores fora dos bigodes para os sinais considerados ruins.

6.3. Respostas obtidas para a otimização via Evolução Diferencial

A Tab. 6.2 apresenta os resultados obtidos, número de parâmetros de entrada, valor da função objetivo e sintomas escolhidos para a otimização via ED.

Tabela 6.2. Resultados obtidos via ED

Número de Parâmetros	Função Objetivo	Sintomas Escolhidos
2	245	4; 114
3	245	114; 117; 144
4	254	104; 116; 134; 144
5	254	71; 80; 106; 116; 144

Da análise da Tab. 6.2, observa-se que a função objetivo se manteve estável entre todos os parâmetros de entrada. O sintoma 144 é o que repete em quase todos os casos. Os sintomas calculados via técnica de envelope, como o 114, 116 e 117, também foram escolhidos como bons sintomas para a classificação via técnica de estatística clássica. Para dois parâmetros de entrada, os sintomas escolhidos foram os mesmos para a estatística clássica.

A Fig. 6.7 mostra as saídas da rede neural obtidas para cada um dos casos.

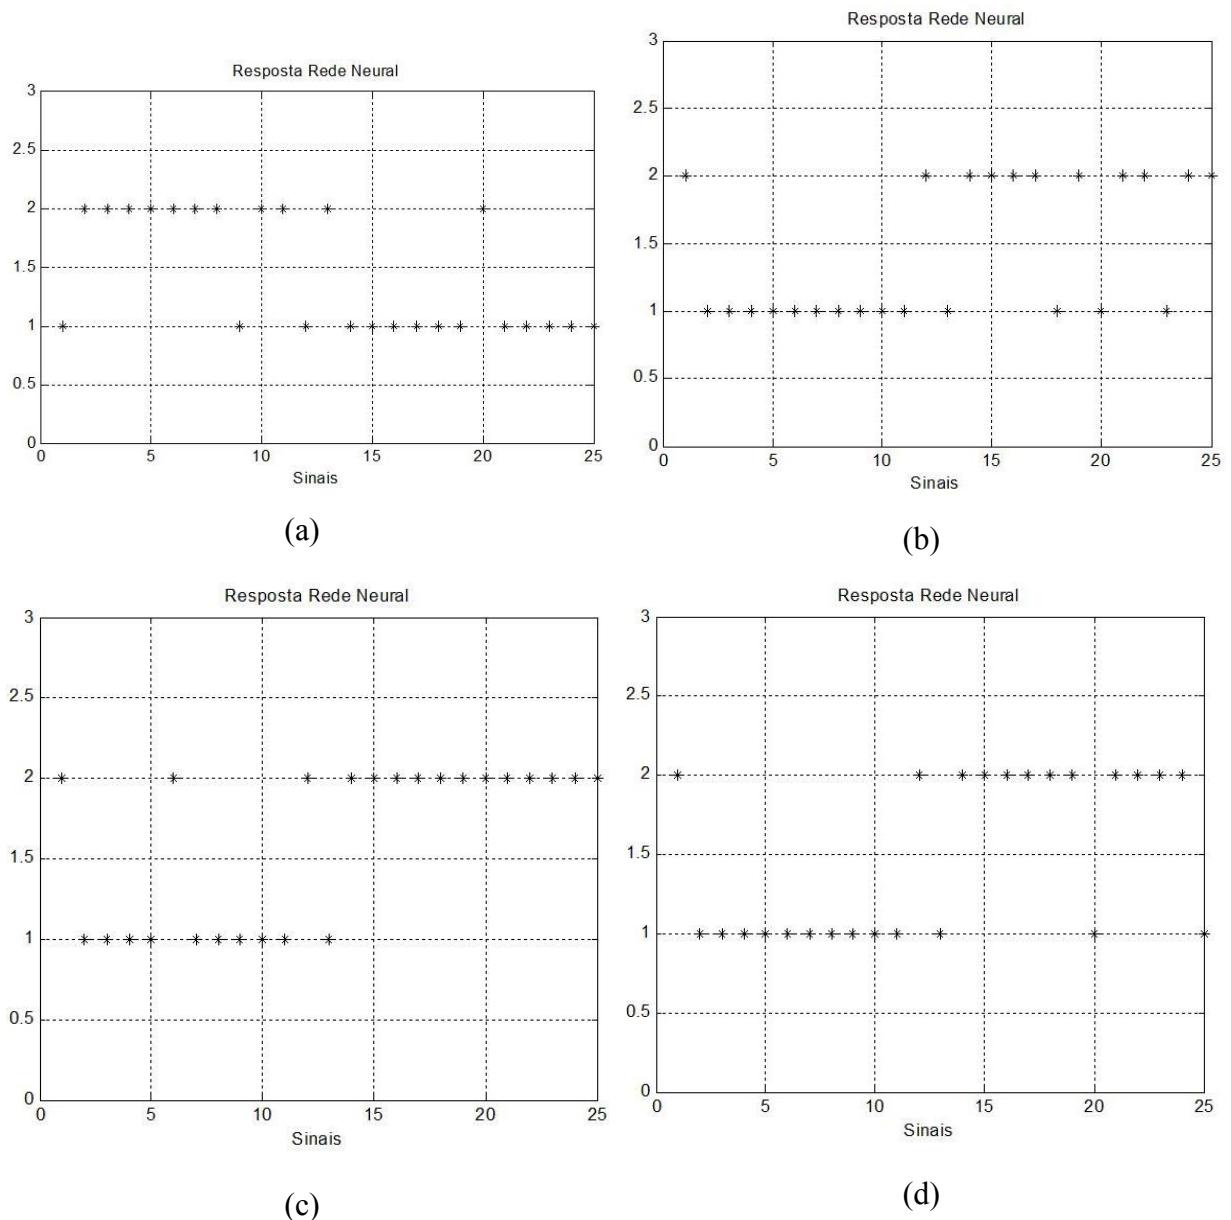
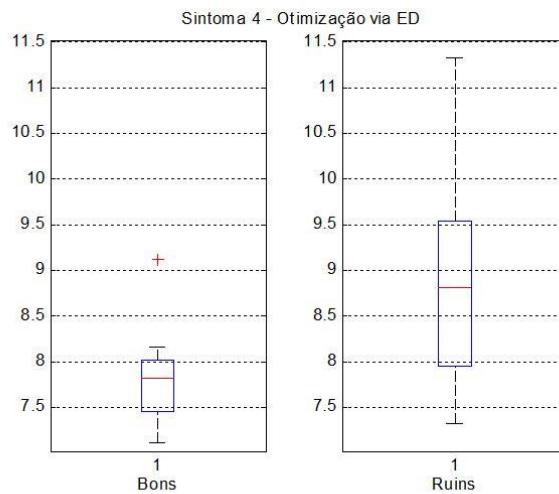
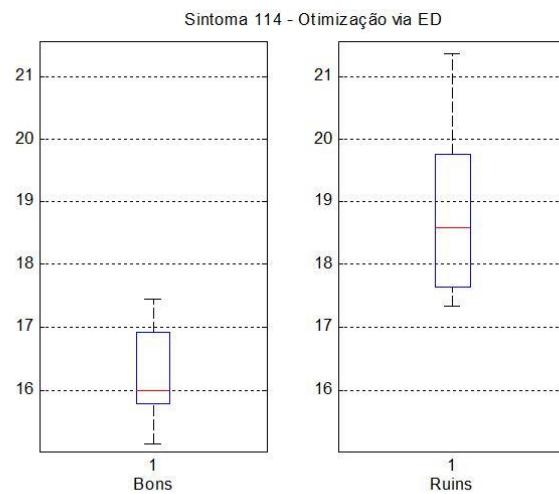


Figura 6.7. Respostas da saída da SOM para: (a) dois parâmetros, (b) três parâmetros, (c) quatro parâmetros e (d) cinco parâmetros de entrada para otimização via ED.

Da análise da Fig. 6.7, ao compará-las com a Fig. 6.1, observa-se que ao utilizar cinco sintomas, a resposta fica mais próxima da ideal. Porém, para todos os casos, a função objetivo obteve resultados semelhantes e a divisão nos dois grupos foi bem coerente com a esperada. Os gráficos boxplot para cada sintoma escolhido e para cada caso são apresentados nas Fig. 6.8 a Fig. 6.11.



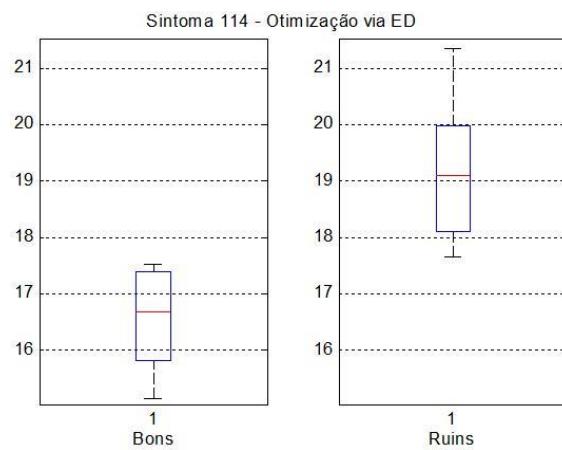
(a)



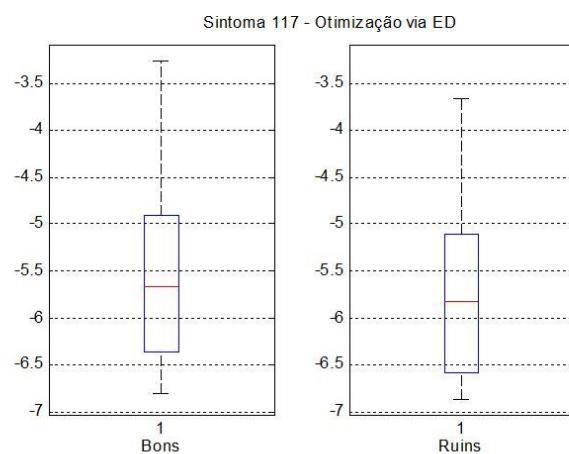
(b)

Figura 6.8. Sintomas escolhidos para a otimização com dois parâmetros de entrada.

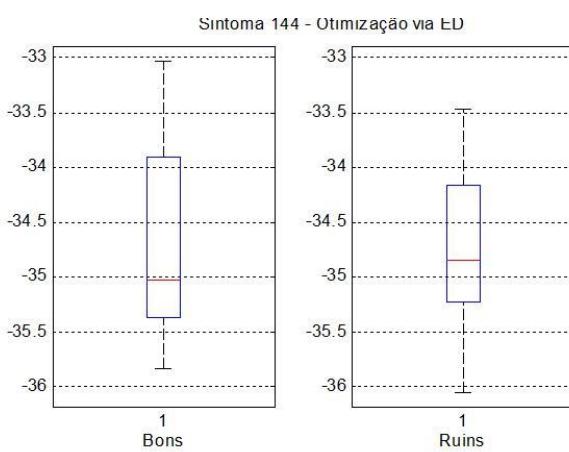
Observa-se na Fig. 6.8 que o sintoma que comanda a escolha da rede neural é o sintoma 114, onde existe uma diferença de 3,5 dB entre as medianas, os gráficos não se cruzam, ou seja, não tem valores iguais, além da não existência de valores fora do bigode. Observa-se também que o interquartil dos sinais considerados bons se encontram abaixo dos considerados ruins, o que era esperado. Já para o sintoma 4, a diferença entre as medianas não é significativa, em torno de 1 dB, e este possui valores fora dos bigodes para os sinais considerados bons. Porém, a combinação desses dois sintomas parece ser boa como critério passa-não-passa.



(a)



(b)



(c)

Figura 6.9. Sintomas escolhidos para a otimização com três parâmetros de entrada.

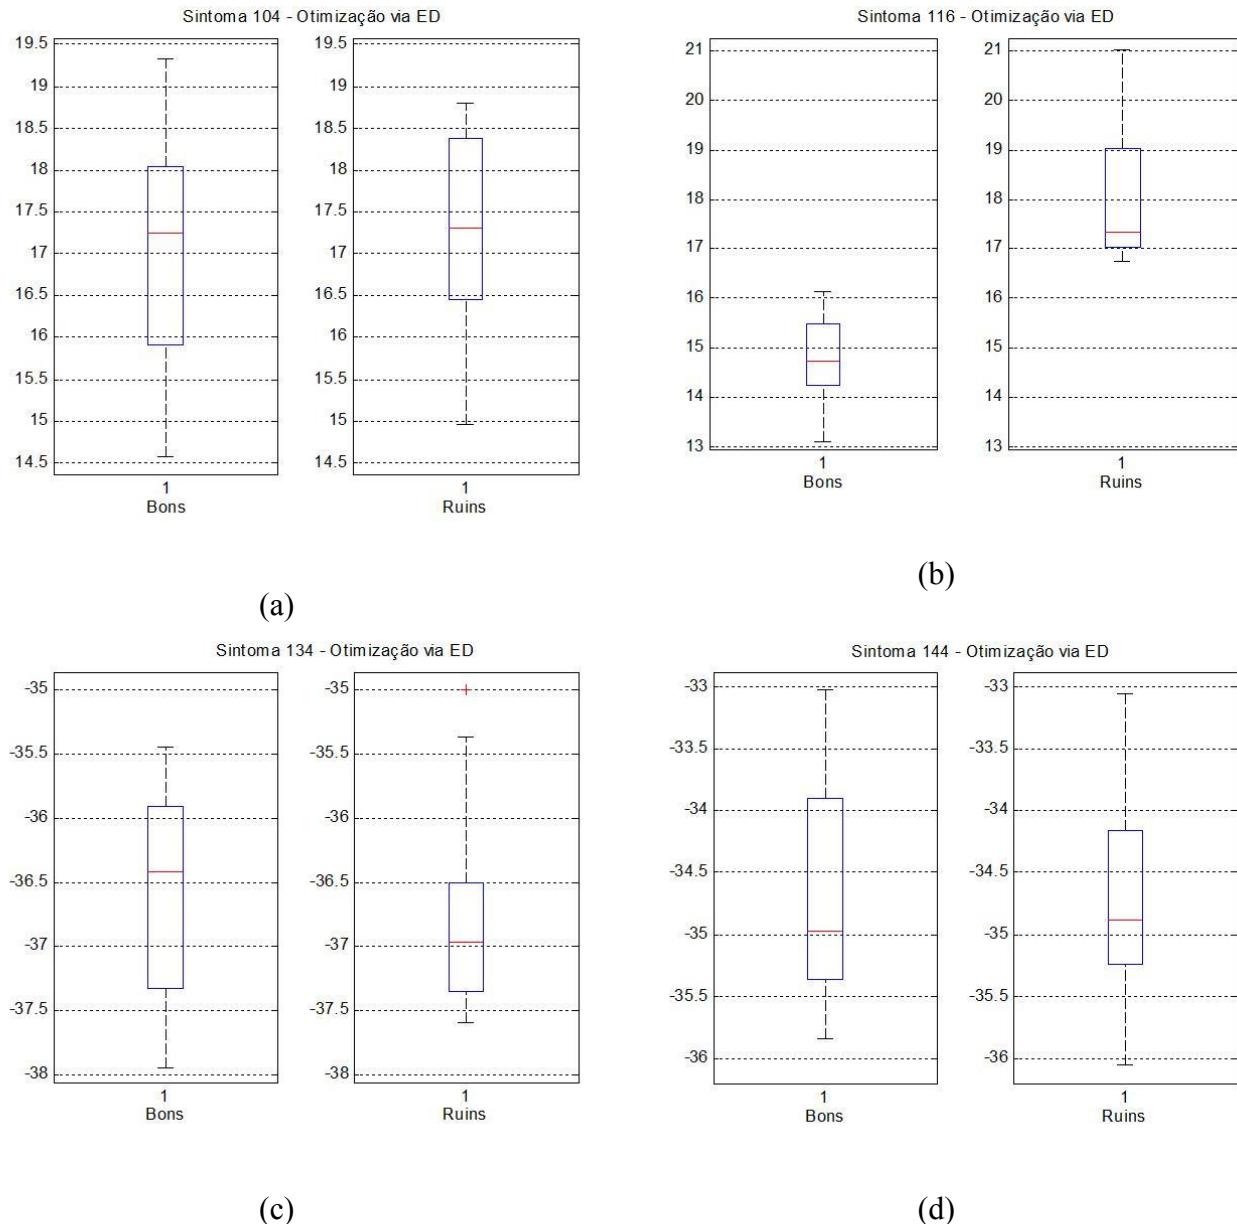


Figura 6.10. Sintomas escolhidos para a otimização com quatro parâmetros de entrada.

Ao analisar a Fig. 6.9, apenas o sintoma 114 é relevante, e apresenta uma diferença de 3 dB entre as medianas. Já o sintoma 144 não tem nenhuma contribuição pois a diferença entre as medianas é insignificante e o diagrama dos sinais bons engloba todo o diagrama dos sinais ruins. O sintoma 117 também não é um bom sintoma, para este caso, pois o diagrama dos sinais bons está acima dos sinais ruins.

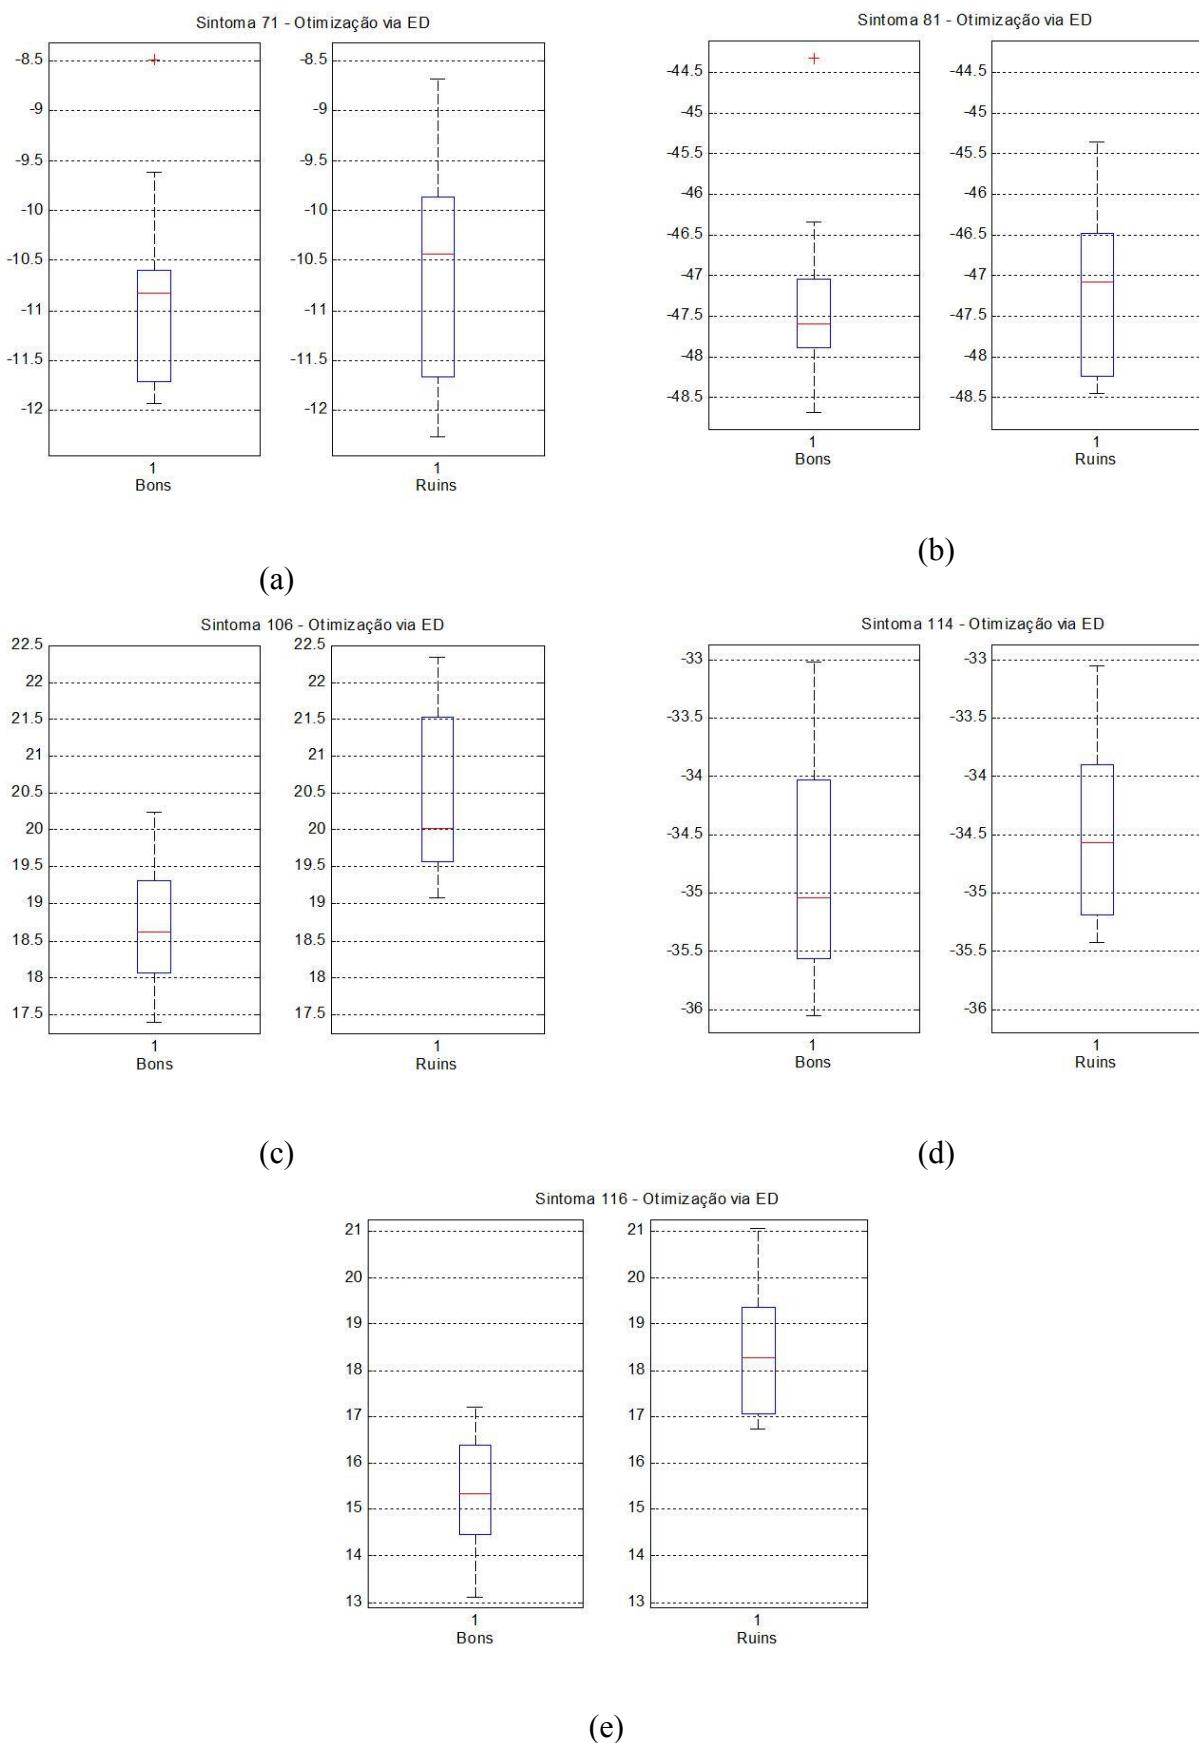


Figura 6.11. Sintomas escolhidos para a otimização com cinco parâmetros de entrada.

Já da análise da Fig. 6.10, apenas o sintoma 116 é relevante e comanda a otimização da rede, uma vez que o diagrama dos sinais bons se encontra abaixo dos sinais ruins, e a diferença entre as medianas é de 3 dB, aproximadamente.

Observa-se, por fim, na Fig. 6.11 que o melhor sintoma é o 116, com uma diferença de 3 dB entre as medianas, sem valores fora do bigode. O sintoma 106 também é um bom parâmetro, uma vez que existe uma diferença entre as medianas de 1,5 dB, e as caixas não se encontram, sendo que o diagrama dos sinais considerados bons está abaixo dos considerados ruins.

6.4. Comparação entre os métodos: SOM via Algoritmos Genéticos e SOM via Evolução Diferencial em relação à Análise Estatística Clássica.

Ao comparar todos os resultados, observa-se que os métodos computacionais, ou seja, os métodos que utilizam a rede neural auto-organizável com uma otimização heurística para a escolha dos parâmetros, se mostrou uma boa ferramenta para avaliação de sinais conformes e não conformes.

A ED se mostrou melhor que a GA, uma vez que as funções objetivo tiveram menores valores, além de gastar um menor tempo computacional.

CAPÍTULO VII

Resultados Para o Estudo da Viabilidade da Metodologia em Linhas de Produção sem o Conhecimento Prévio das Não Conformidades

Neste capítulo são apresentados os resultados obtidos quando avaliada a possibilidade de utilizar a combinação das redes neurais auto-organizáveis e otimização heurística para identificar os produtos em linhas de produção quanto à sua qualidade, ou seja, se estão ou não em conformidade com a exigência de mercado. A rede utilizada foi a de Kohonen (SOM) e o otimizador utilizado foi algoritmos genéticos (GA). Vale ressaltar que os resultados foram obtidos sem o conhecimento prévio dos sinais não conformes.

A Tab. 7.1 apresenta os valores obtidos para a função objetivo, mostrada na Eq. 3.7, o menor número de ocorrência entre os neurônios, N_{Min} , e os sintomas escolhidos pela GA para uma rede neural com três neurônios.

Analizando os resultados mostrados na Tabela 7.1, observa-se que, ao aumentar o número de sintomas utilizados no treinamento da rede neural, aumenta-se N_{min} (Eq. 3.7) e consequentemente, o valor da função objetivo. As Tab. 7.2, 7.3, 7.4 e 7.5 mostram os valores obtidos quando utilizados quatro, cinco, seis e oito neurônios, respectivamente, para o treinamento da rede neural.

Da análise dessas tabelas, observa-se que, com o aumento do número de neurônios, os valores da função objetivo foram decaindo. Por exemplo, para três neurônios e três sintomas, a função objetivo vale 22,8. Já para oito neurônios e três sintomas, a função objetivo vale 8,9.

Assim, ao comparar os resultados obtidos nas Tab. 7.2, 7.3, 7.4 e 7.5 com os da Tab. 7.1, conclui-se que três neurônios são insuficientes para classificar o problema abordado, uma vez que há um aumento considerável da função objetivo com o aumento do número de sintomas.

Tabela 7.1. Resultados da otimização para uma rede com três neurônios.

Quantidade de Sintomas	N_{Min}	Função Objetivo	Sintomas
2	3	18,7	43; 107
3	2	22,8	76; 207; 108
4	4	25,7	14; 18; 38; 122
5	5	33,6	103; 105; 121; 125; 128
6	2	35,3	3; 17; 60; 76; 107; 115; 121
8	8	67,6	33; 50; 52; 54; 58; 75; 103; 106
10	11	121	15; 34; 49; 57; 63; 103; 105; 119; 124; 141
12	10	111,9	15; 23; 27; 40; 41; 50; 52; 55; 75; 78; 119; 128

Tabela 7.2. Resultados da otimização para uma rede com quatro neurônios.

Quantidade de Sintomas	N_{Min}	Função Objetivo	Sintomas
2	4	16	18; 102
3	4	19,4	110; 130; 141
4	4	16	18; 62; 72; 126
5	4	22,7	18; 37; 106; 129; 133
6	5	31,9	14; 78; 104; 109; 112; 120
8	6	38,9	15; 41; 49; 57; 65; 121; 130; 139
10	6	37,2	5; 17; 41; 66; 111; 115; 118; 120; 130; 141
12	7	49	5; 60; 65; 76; 79; 93; 106; 108; 118; 125; 133; 141
14	8	75,2	7; 29; 31; 34; 39; 50; 52; 56; 57; 65; 66; 105; 133; 142

Tabela 7.3. Resultados da otimização para uma rede com cinco neurônios.

Quantidade de Sintomas	N_{Min}	Função Objetivo	Sintomas
2	2	10,7	106; 108
3	2	22	90; 117; 125
4	2	21,8	63; 108; 133; 139
5	4	18,4	66; 104; 110; 121; 142
6	4	26,4	50; 80; 103; 132; 133; 141
8	5	34,3	1; 15; 87; 96; 107; 111; 126; 130
10	6	37,4	3; 49; 51; 53; 57; 69; 93; 123; 135; 140
12	5	42,3	50; 57; 58; 90; 95; 107; 121; 122; 126; 127; 135; 137
14	6	48,7	10; 43; 54; 75; 78; 110; 112; 121; 123; 126; 128; 136; 137; 142

Tabela 7.4. Resultados da otimização para uma rede com seis neurônios.

Quantidade de Sintomas	N_{Min}	Função Objetivo	Sintomas
2	3	10	2; 5
3	2	7,6	17; 108; 133
4	4	16,1	52; 137; 138; 139
5	3	19,4	24; 51; 63; 109; 133
6	4	16,1	5; 49; 50; 53; 137; 138
8	5	25	7; 11; 21; 50; 52; 66; 105; 128
10	5	26	3; 5; 32; 35; 40; 42; 75; 110; 114; 140
12	5	30,4	15; 35; 38; 50; 52; 64; 101; 110; 118; 128; 139; 140
14	5	35,5	5; 36; 41; 42; 50; 80; 90; 93; 122; 123; 135; 136; 137; 141

Tabela 7.5. Resultados da otimização para uma rede com oito neurônios.

Quantidade de Sintomas	N_{Min}	Função Objetivo	Sintomas
2	2	7,6	108; 132
3	2	8,9	66; 103; 107
4	4	16	15; 120; 135; 138
5	2	11,9	105; 107; 129; 135; 143
6	2	4,9	68; 105; 107; 111; 127; 128
8	3	17,9	22; 51; 53; 54; 65; 67; 83; 141
10	4	19,1	9; 21; 27; 54; 63; 69; 80; 101; 109; 130
12	6	36	34; 36; 44; 46; 49; 58; 64; 101; 103; 119; 135; 136
14	5	34,6	19; 35; 38; 48; 53; 65; 69; 74; 78; 109; 116; 126; 129; 136

Os resultados mostrados nas Tab. 7.2 a 7.4 convergem para um número de não conformidades variando entre 5 e 6 com o aumento do número de sintomas utilizados na otimização, o que condiz com o esperado.

Já as oscilações observadas para N_{Min} na Tab. 7.5 podem ser explicadas através da análise da Fig. 7.1. Esta apresenta as ocorrências em função dos neurônios onde os sinais foram classificados e da posição dos sinais, para os oito neurônios.

Da análise da Fig. 7.1, conclui-se que a rede neural está superdimensionada, ou seja, não é necessário utilizar esta grande quantidade de neurônios para conseguir selecionar os sinais não conformes. Nota-se que existem dois neurônios competindo entre si, ambos com três ocorrências cada.

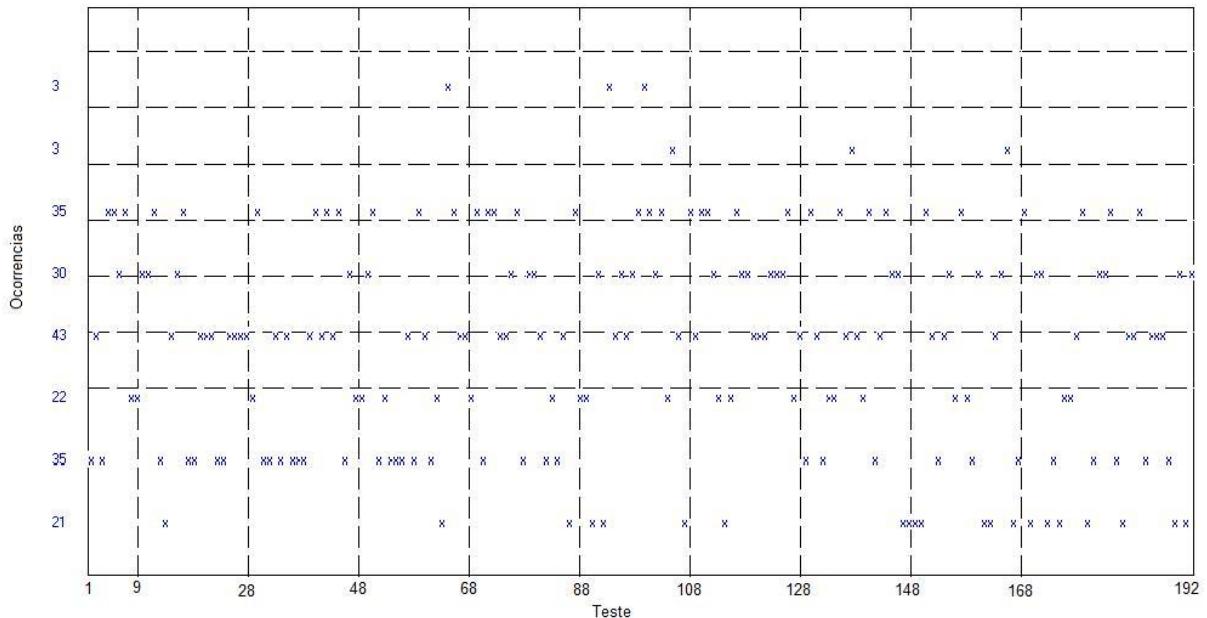


Figura 7.1. Gráfico da distribuição dos sinais feita pela rede neural, para oito neurônios e oito sintomas.

Após verificar que três e oito neurônios não devem ser utilizados, realizou-se otimizações agora com a função objetivo alterada, ou seja a Eq. 3.7 foi substituída pela Eq. 7.1. Restringiu-se as otimizações para 10 sintomas.

$$\text{Obj}(x) = (N_{\text{Min}} - 6)^2 + \lambda(x_i = x_j) + \lambda(T(x_{\text{Min}})/T_{\text{critico}}) \quad (7.1)$$

Esta alteração foi feita visando maximizar as diferenças entre os testes de hipóteses para diferença das médias t, uma vez que acredita-se que exista seis sinais não conformes no conjunto testado. A Tab. 7.6 apresenta os resultados para este caso.

Ao analisar os resultados apresentados na Tab. 7.6, juntamente com os diagramas boxplot e com a distribuição dos neurônios em função dos sinais, decidiu-se eliminar a otimização com quatro neurônios, uma vez que a mesma não atingiu o objetivo e apresentou o maior valor para a função objetivo, e a otimização com sete neurônios, uma vez que a mesma ficou superdimensionada, dividindo o menor grupo em dois outros.

Tab. 7.6. Resultados de otimização para 10 sintomas.

Quantidade de Neurônios	N_{Min}	Função Objetivo	Sintomas
4	7	2,1	1; 17; 66; 103; 112; 118; 120; 126; 130; 141
5	7	1	1; 35; 40; 41; 50; 67; 76; 79; 122; 134
6	6	0	1; 15; 19; 50; 57; 63; 65; 119; 121; 124
7	7	1	32; 34; 41; 44; 50; 58; 76; 80; 123; 140

Assim, para finalizar, mostra-se na Tab. 7.7 os resultados obtidos para a otimização com cinco e seis neurônios, e variou-se também a quantidade de sintomas entre oito e nove sintomas. O número elevado de sintomas é para garantir a segregação, uma vez que um número baixo de sintomas pode identificar problemas de aquisição de sinais como um sinal ruim.

Tab. 7.7. Resultados de Otimização com alvo em N_{Min} igual a 6.

Quantidade de Neurônios	N_{Min}	Função Objetivo	Sintomas
5 (9 Sintomas)	7	1	14; 19; 37; 61; 63; 69; 77; 80; 138
6 (9 Sintomas)	7	1	31; 34; 35; 48; 53; 74; 57; 101; 136
5 (8 Sintomas)	7	1	15; 19; 35; 40; 50; 53; 57; 138
6 (8 Sintomas)	6	0	53; 54; 66; 80; 109; 121; 135; 141

Ao analisar a tabela, percebe-se que os resultados foram bastante coerentes. E a otimização realizada com seis neurônios e oito sintomas (Tab. 7.7) e seis neurônios e 10 sintomas (Tab. 7.6) conseguiram convergir e resultar numa função objetivo igual a zero.

As Fig. 7.2 e 7.3 mostram as ocorrências em função dos neurônios onde os sinais foram classificados e da posição dos sinais, para cinco neurônios e oito sintomas e seis neurônios e oito sintomas, respectivamente.

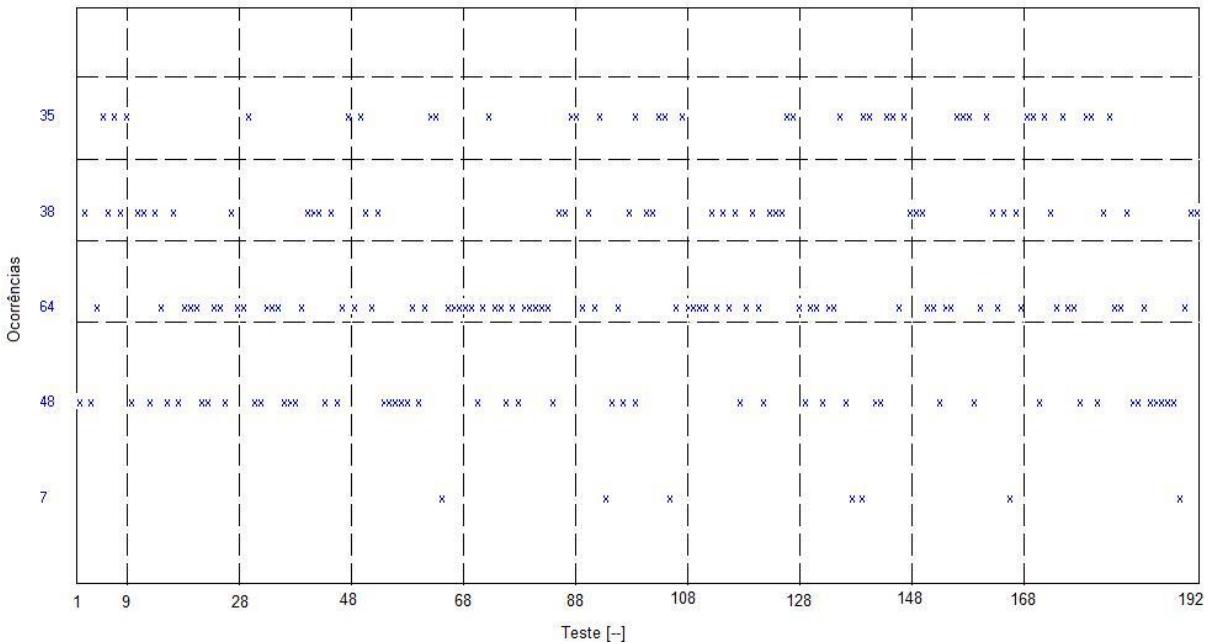


Figura 7.2. Gráfico da distribuição dos sinais feita pela rede neural, para cinco neurônios e oito sintomas.

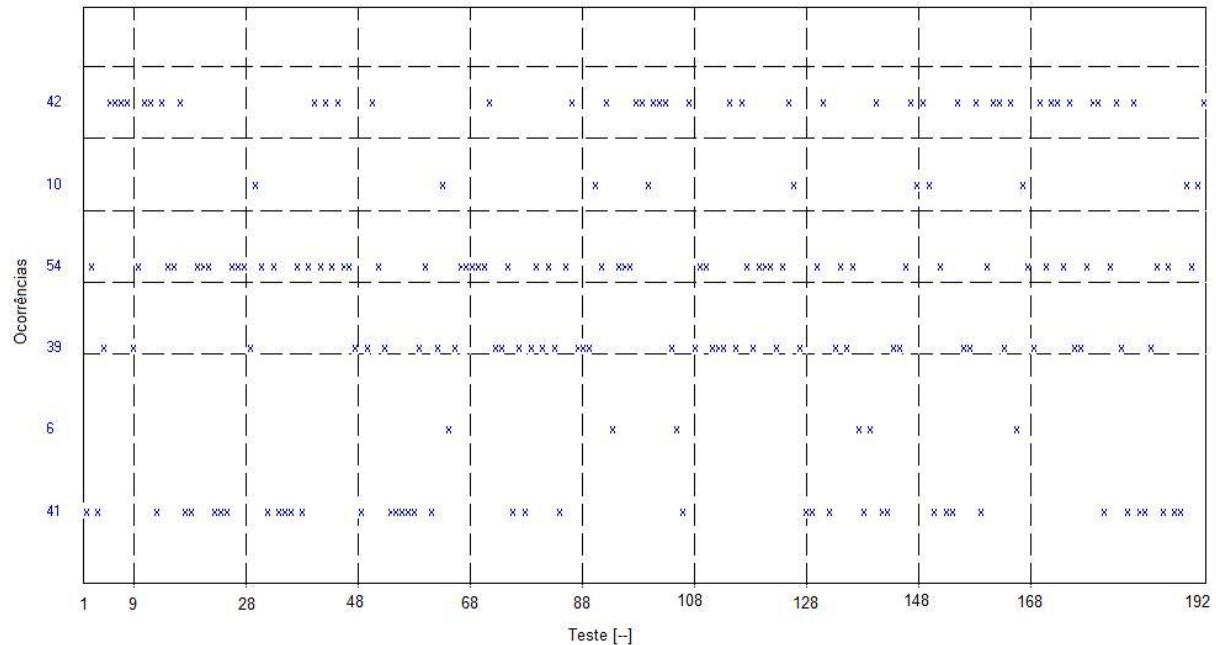


Figura 7.3. Gráfico da distribuição dos sinais feita pela rede neural, para seis neurônios e oito sintomas.

Ao comparar as Fig. 7.2 e 7.3 observa-se que o sinal que difere é o sinal 191 na rede com cinco neurônios. Este resultado foi observado em outras otimizações realizadas, incluindo casos para a rede com seis neurônios. Apesar de não ser um dos seis sinais não

conformes, introduzidos no lote estudado, este sinal gerou uma dúvida quanto à existência de outro sinal diferente.

As Fig. 7.4 e 7.5 mostram os gráficos boxplot dos sintomas escolhidos pela GA relativos ao grupo com menor ocorrência, ou seja, N_{Min} , à direita, comparados com os sintomas relativos aos outros sinais, à esquerda, para os casos com cinco e seis neurônios, respectivamente, ambos testados com oito sintomas.

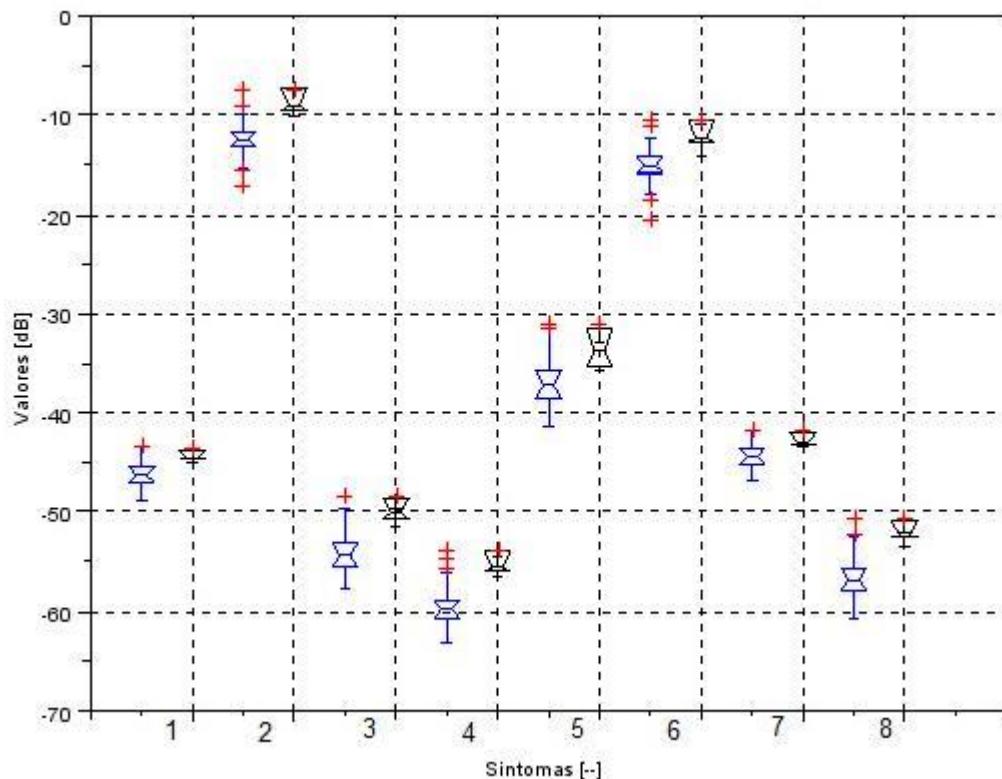


Figura 7.4. Gráficos boxplot para a otimização com cinco neurônios e oito sintomas.

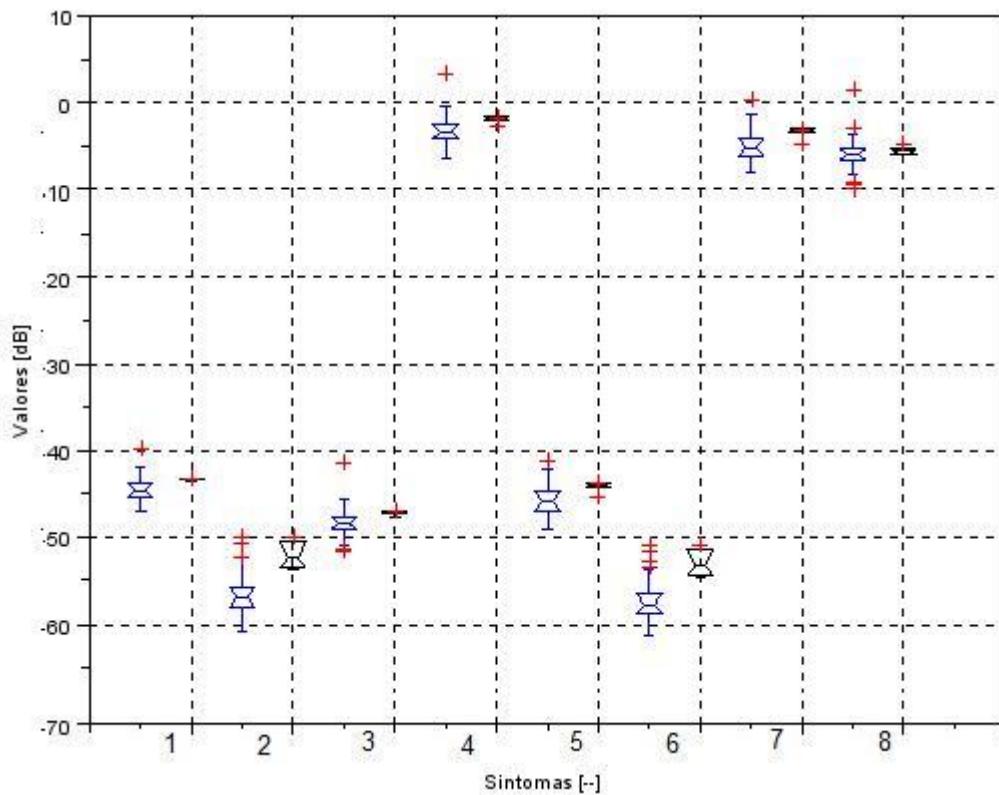


Figura 7.5. Gráficos boxplot para a otimização com seis neurônios e oito sintomas.

Ao analisar as figuras, observa-se uma boa separação entre os diagramas relativos à N_{Min} e os diagramas relativos aos outros sinais. Observa-se que os diagramas do grupo maior, que é considerado bom, estão sempre abaixo do grupo considerado não conforme, o que é um bom indicativo da eficácia da metodologia.

Em uma análise final, observa-se que os sintomas escolhidos pelos algoritmos de otimização variam em função do número de neurônios e quantidade de parâmetros de entrada utilizados. Ao avaliar todas as otimizações analisadas neste capítulo, os sintomas que mais se repetiram foram, respectivamente, sintoma 107 (nível de energia do envelope filtrado acima de 4000 Hz), sintoma 51 (nível de energia do TDA filtrado acima de 1000 Hz, para o sinal de velocidade), sintoma 134 (filtro passa banda entre 1000 e 4000 Hz, para o sinal de velocidade) e sintoma 141 (filtro passa alta acima de 5000 Hz, para o sinal de velocidade).

Já ao analisar apenas a Tab. 7.7, os sintomas que mais se repetiram foram: sintoma 53 (TDA filtrado acima de 3000 Hz, para o sinal de velocidade), sintoma 19 ($K_4(10\log_{10}(RMS*Curtose))$, para o sinal de velocidade), sintoma 80 (filtro passa banda entre 50 e 8100 Hz, para o sinal de velocidade) e sintoma 138 (filtro passa alta acima de 2000 Hz, para o sinal de velocidade).

Os sintomas mais frequentes são coerentes com as não conformidades que foram induzidas nos compressores, principalmente o roçamento de eixo, que são caracterizadas pelas altas frequências.

CAPÍTULO VIII

Conclusões

Para o caso em estudo, ou seja, para a análise de compressores, as principais conclusões tiradas neste trabalho foram:

- Da análise estatística clássica, conclui-se que o ouvido humano é um excelente sensor para controle de qualidade;
- A rede neural auto-organizável SOM é capaz de identificar e separar os grupos estatisticamente diferentes ao utilizar todos os sintomas vibroacústicos calculados para este trabalho;
- Ao comparar todos os resultados, observa-se que os métodos computacionais se mostraram uma boa ferramenta para avaliação de sinais conformes e não conformes, para este caso;
- A partir dos resultados obtidos, é possível ao analista construir critérios passa-não passa em linhas de produção, utilizando de computação, sem a necessidade da pré-existência de sinais dos produtos considerados bons e ruins e da análise desses sinais para se criar um banco de dados. Vale ressaltar que, para evitar defeitos oriundos de aquisição de sinais, deve-se fazer a aquisição automatizada;

Como conclusões secundárias, pode-se destacar:

- Existe uma boa correlação entre a percepção subjetiva de ruído do cliente com os valores de NWS nas bandas de 315 a 500 Hz e de 800 a 6300 Hz;
- Da análise estatística clássica, os principais sintomas analisados para o ponto de medição próximo ao ponto de solda foram: 116, 115, 114, 98, 112, 84, 110, 5, 3 e 4;
- Ao avaliar a sensibilidade da SOM com algoritmo genético, percebe-se que a partir de seis sintomas, o algoritmo começa a repetir os sintomas, e não converge mais;

- Para apenas um sintoma, a otimização convergiu, porém, a cada nova otimização, o valor do parâmetro x mudava. Assim, utilizar apenas um parâmetro como critério é perigoso uma vez que existem ruídos espúrios que podem comprometer a qualidade do sinal e algum de seus sintomas;
- De uma primeira análise, definiu-se que o número mínimo de sintomas a ser utilizados como dados de entrada é dois e o máximo cinco;
- Ao avaliar os resultados obtidos pela combinação SOM e otimização via GA, observa-se que a melhor escolha é para três parâmetros, uma vez que essa configuração obteve o menor valor da função objetivo;
- O sintoma 116 repete em quase todos os casos em que se fez a otimização via GA. Este sintoma, para a análise estatística clássica, também foi eleito como o melhor sintoma para se classificar compressores;
- Já ao analisar os resultados obtidos pela combinação SOM e otimização via ED, observou-se que a função objetivo se manteve estável entre todos os parâmetros de entrada, ou seja, não existe uma melhor configuração;
- O sintoma 144 é o que repete em quase todos os casos em que se fez a otimização via ED. Os sintomas calculados via técnica de envelope, como o 114, 116 e 117, também foram escolhidos como bons sintomas para a classificação via técnica de estatística clássica. Para dois parâmetros de entrada, os sintomas escolhidos foram os mesmos para a estatística clássica;
- Ao comparar todos os resultados, observa-se que os métodos computacionais se mostraram uma boa ferramenta para avaliação de sinais conformes e não conformes, para este caso;
- A ED se mostrou melhor que a GA, uma vez que as funções objetivo tiveram menores valores, além de gastar um menor tempo computacional;
- Ao simular a linha de produção, verificou-se a necessidade de se utilizar mais neurônios para a rede neural, uma vez que o número de não conformidades é muito menor que o número de sinais conformes, e a rede, ao utilizar apenas dois neurônios, tende a dividir os sinais em grupos uniformes. Foi observada, também, uma queda nos valores da função objetivo e o número de não conformidades se estabilizou em função do aumento do número de neurônios;

- As melhores escolhas para a simulação da linha de produção foram: rede neural com cinco neurônios e oito parâmetros de entrada e a rede neural com seis neurônios e oito parâmetros de entrada;
- Os sintomas mais frequentes para a simulação da linha de produção são coerentes com as não conformidades induzidas nos compressores, principalmente o roçamento de eixo, que são caracterizadas pelas altas frequências;

8.1. Trabalhos Futuros

Propõe-se aplicar a metodologia desenvolvida, ou seja, a combinação de redes neurais auto-organizáveis e otimização, em uma linha real de produção, para verificar a eficiência da mesma.

Propõe-se também, aplica-la em diferentes sistemas e linhas, e não só apenas para compressores, como por exemplo, na análise de eletroencefalogramas, para classificar se um sinal de um cérebro é bom ou se existe alguma doença.

REFERÊNCIAS BIBLIOGRÁFICAS

- Barreto, R.A., “Definição de Parâmetros de Vibração e Ruído para Aceitação de Câmbios Automotivos em Linhas de Montagem.”, Florianópolis – SC, Universidade Federal de Santa Catarina – Engenharia Mecânica, 2003, 115p. Dissertação de Mestrado.
- Braun, S., “Mechanical Signature Analysis – Theory and Applications.”, Ed. Academic Press, London, 1986.
- Brito, J. N., Pederiva, R., Garcia, E.M., “Desenvolvimento de um Sistema Especialista para Diagnóstico de Problemas em Motores Elétricos.”, II Congresso Nacional de Engenharia Mecânica, CONEM, João Pessoa – PB, 2002.
- Da Cruz, M.A., “Avaliação de Redes Neurais Competitivas em Tarefas de Quantização Vetorial: Um Estudo Comparativo.”, Fortaleza – CE, Universidade Federal do Ceará – Engenharia de Teleinformática, 2007, 119p. Dissertação de Mestrado.
- Duarte, M. A. V., “Apostila de Análise de Sinais.”, Universidade Federal de Uberlândia, 2005.
- Guimarães, T.A., “Análise Tempo-Frequência de Sinais de Vibração Aplicada à Detecção de Falhas em Caixas de Câmbio.”, Uberlândia – MG, Universidade Federal de Uberlândia – Engenharia Mecânica, 2000, 95 p. Dissertação de Mestrado.
- Hadjiski, M. B., Doukovska, L.A., Kojnov, S. L., “Nonlinear Trend Analysis of Mill Fan System Vibrations for Predictive Maintenance and Diagnostics.”, INTL Journal of Electronics and Telecommunications, Vol. 58, nº 4, pp. 351-356, 2012
- Han, H.G., Chen, Q.L., Qiao, J.F., “An Efficient Self-organizing RBF Neural Network for Water Quality Prediction.”, Neural Network, vol. 24, pp. 717 – 725, 2011.
- Han, H.G., Qiao, J.F., Chen, Q.L., “Model Predictive Control of Dissolved Oxygen Concentration Based on a Self-organizing RBF Neural Network.”, Control Engineering

Practice, vol. 20, pp. 465 – 476, 2012.

Haykin, S., “Redes Neurais – Princípios e Prática.”, 2^a Ed., Ed. Bookman, Porto Alegre, 2001.

Hines, W. W., Montgomery, D. C., Goldsman, D. M., Borror, C. M., Probabilidade e Estatística na Engenharia.”, 4^a Ed., LTC Editora, Rio de Janeiro, 2006.

ISO 3744/2010 - Acoustics - Determination of Sound Power Levels of Noise Sources Using Sound Pressure - Engeenering Method in an Essential Free Field over a Reflecting Plane.

Kaya, A., Germen, E., Ünlü, U., Toprak, S., “Fault Classification in Hermetic Compressors Using Self-organizing Map.”, International Compressor Engineering Conference at Purdue, 2008.

Kohonen, T., “The Self-organizing Map.”, Neurocomputing, vol. 21, pp. 1 – 6, 1998.

Kumar, M., Husian, M., Upreti, N., Gupta, D., “Genetic Algorithm: Review and Application.”, International Journal of Information Technology and Knowledge Management, vol. 2, nº 2, pp. 451 – 454, 2010.

Lobato, F. S., “Otimização Multi-objetivo para o Projeto de Sistemas de Engenharia.”, Uberlândia – MG, Universidade Federal de Uberlândia, Engenharia Mecânica, 2008, 354 p. Tese de Doutorado.

Loutas, T.H., Roulias, D., Pauly, E., Kostopoulos, V., “The Combined use of Vibration, Acoustic Emission and Oil Debris On-line Monitoring Towards a More Effective Condition Monitoring or Rotating Machinery.”, Mechanical Systems and Signal Processing, vol. 25, pp. 1339 – 1352, 2011.

Meng, H., Wen, J., Zhao, H., Wen, X., “Optimization of Locally Resonant Acoustic Metamaterials on Underwater Sound Absorption Characteristics.”, Journal of Sound and Vibration, vol. 331, pp. 4406 – 4416, 2012.

Meola, T., “Monitoramento em Tempo Real da Qualidade de Sinais de Vibrações Utilizando Inteligência Artificial.”, Uberlândia – MG, Universidade Federal de Uberlândia, Engenharia Mecânica, 2006, 118 p. Dissertação de Mestrado.

Meola, T., “Proposta De Uma Metodologia Baseada Em Análise Modal Operacional Para

Monitoramento De Fim De Vida De Ferramentas De Corte.”, Uberlândia – MG, Universidade Federal de Uberlândia, Engenharia Mecânica, 2009, 175 p. Tese de Doutorado.

Oliveira Filho, R.H., “Uma Proposta de Ferramenta para Controle de Qualidade em Linha de Produção e Montagem de Câmbios Automotivos Utilizando Filtragem Adaptativa.”, Uberlândia – MG, Universidade Federal de Uberlândia – Engenharia Mecânica, 2007, 157 p. Dissertação de Mestrado.

Oliveira, E. L., “Controle Ativo de Ruído Aplicado a Dutos com Propagação de Modos Acústicos de Alta Ordem via Particionamento Axial.”, Uberlândia – MG, Universidade Federal de Uberlândia, Engenharia Mecânica, 2012, 130 p. Tese de Doutorado.

Pena, J.L.O., “Um Estudo sobre o Uso de Técnicas Não-Tradicionais Aplicadas à Detecção de Defeitos de Fabricação em Câmbios Automotivos.”, Uberlândia – MG, Universidade Federal de Uberlândia, 2003, 166p. Tese de Doutorado.

Shao, X., Cao, L., Liu, G., Zhi, J., Tian, G., Liu, J., “Analysis and Simulation of Stochastic Fatigue Reliability for Running System of Complicated Equipments”, Quality, Reliability, Risk, Maintenance, and Safety Engineering (ICQR2MSE), 2012 International Conference on, pp. 983 – 986, 2012

Silva, I. N., Spatti, D. H., Flauzino, R. A., “Redes Neurais Artificiais para Engenharia e Ciências Aplicadas”, Artliber Editora Ltda, São Paulo, 2010.

Silva, V. A. D., “Detecção de Falhas em Motores Elétricos Através das Máquinas de Vetores de Suporte.”, Campinas – SP, Universidade Estadual de Campinas, 2012, 117p. Dissertação de Mestrado.

Sreedhar, D., Rajan, B. M. R., “Differential Evolution based Multiobjective Optimization – A Review.”, International Journal of Computer Applications, vol. 63, nº 15, pp. 14 – 19, 2013.

Zhang, H., Zhou, J., Fang, N., Zhang, R., Zhang, Y., “An Efficient Multi-objective Adaptive Differential Evolution With Chaotic Neuron Network and its Application on Long-term Hydropower Operation With Considering Ecological Environment Problem.”, International Journal of Electrical Power & Energy Systems, vol. 45, Issue 1, pp. 60 – 70, 2013.

ANEXO I

Definição dos Sintomas Utilizados

Apresenta-se aqui cada sintoma utilizado neste trabalho bem como os programas desenvolvidos em MATLAB®, para o cálculo dos mesmos. Os números dos sintomas são relativos à ordem em que foram calculados.

A Tabela A1 mostra os 14 sintomas relacionados aos sintomas calculados no domínio do tempo, para os sinais de aceleração. Posteriormente, o programa é apresentado.

Tabela A1. Sintomas calculados no domínio do tempo para os sinais de aceleração

Sintoma	Descrição
1	Nível RMS em função do desvio padrão (sinal AC)
2	Assimetria
3	Curtose
4	Fator de Crista
5	K4 ($10\log_{10}(RMS \cdot Curtose)$)
6	Máximo do Cepstrum do sinal na faixa de 100 Hz a 12.000 Hz
7	Máximo do Cepstrum do sinal na faixa de 1.000 Hz a 12.000 Hz
8	Máximo do Cepstrum do sinal na faixa de 1.500 Hz a 12.000 Hz
9	Máximo do Cepstrum do sinal na faixa de 2.000 Hz a 12.000 Hz
10	Soma do Cepstrum do sinal na faixa de 100 Hz a 12.000 Hz
11	Soma do Cepstrum do sinal na faixa de 1.000 Hz a 12.000 Hz
12	Soma do Cepstrum do sinal na faixa de 1.500 Hz a 12.000 Hz
13	Soma do Cepstrum do sinal na faixa de 2.000 Hz a 12.000 Hz
14	Nível RMS em função da amplitude do sinal (Sinal DC)

```

function [S]=sintoma_tempo(Y,dt)
n=length(Y(1,:));
S=zeros(n,14);
for i=1:n,
    y=Y(:,i);
    S(i,1)=10*log10(std(y-mean(y)));
    S(i,2)=skewness(y);
    S(i,3)=kurtosis(y);
    S(i,4)=10*log10(max(abs(y)))-S(i,1);
end

```

```

S(i,5)=S(1)+10*log10(S(i,3));
S1=Cepstro(y,32768,dt);
S(i,6)=10*log10(max(S1(100:12000)));
S(i,7)=10*log10(max(S1(1000:12000)));
S(i,8)=10*log10(max(S1(1500:12000)));
S(i,9)=10*log10(max(S1(2000:12000)));
S(i,10)=10*log10(sum(S1(100:12000)));
S(i,11)=10*log10(sum(S1(1000:12000)));
S(i,12)=10*log10(sum(S1(1500:12000)));
S(i,13)=10*log10(sum(S1(2000:12000)));
S(i,14)=10*log10(sqrt(sum(y.^2))/n));

```

end

Os sintomas numerados de 15 a 27 estão relacionados aos sintomas calculados no domínio do tempo, para os sinais de velocidade. A Tabela A2 mostra os 13 sintomas relacionados aos sintomas calculados no domínio do tempo, para os sinais de velocidade. O programa utilizado para o cálculo também é apresentado.

Tabela A2. Sintomas calculados no domínio do tempo para os sinais de velocidade.

Sintoma	Descrição
15	Nível RMS em função do desvio padrão (sinal AC)
16	Assimetria
17	Curtose
18	Fator de Crista
19	K4 (10log10(RMS*Curtose))
20	Máximo do Cepstrum do sinal na faixa de 100 Hz a 12.000 Hz
21	Máximo do Cepstrum do sinal na faixa de 1.000 Hz a 12.000 Hz
22	Máximo do Cepstrum do sinal na faixa de 1.500 Hz a 12.000 Hz
23	Máximo do Cepstrum do sinal na faixa de 2.000 Hz a 12.000 Hz
24	Soma do Cepstrum do sinal na faixa de 100 Hz a 12.000 Hz
25	Soma do Cepstrum do sinal na faixa de 1.000 Hz a 12.000 Hz
26	Soma do Cepstrum do sinal na faixa de 1.500 Hz a 12.000 Hz
27	Soma do Cepstrum do sinal na faixa de 2.000 Hz a 12.000 Hz

```

function [S]=sintoma_tempo_v(Y,dt)
n=length(Y(1,:));
S=zeros(n,13);
for i=1:n,
    y=integraA(Y(:,i),dt);
    S(i,1)=10*log10(std(y-mean(y)));
    S(i,2)=skewness(y);
    S(i,3)=kurtosis(y);
    S(i,4)=10*log10(max(abs(y))-S(i,1));
    S(i,5)=S(1)+10*log10(S(i,3));
    S1=Cepstro(y,32768,dt);
    S(i,6)=10*log10(max(S1(100:12000)));
    S(i,7)=10*log10(max(S1(1000:12000)));
    S(i,8)=10*log10(max(S1(1500:12000)));

```

```

S(i,9)=10*log10(max(S1(2000:12000)));
S(i,10)=10*log10(sum(S1(100:12000)));
S(i,11)=10*log10(sum(S1(1000:12000)));
S(i,12)=10*log10(sum(S1(1500:12000)));
S(i,13)=10*log10(sum(S1(2000:12000)));

end

```

Os sintomas numerados de 28 a 44 estão relacionados com os cálculos de TDA, para os sinais de aceleração. A Tabela A3 especifica esses sintomas e programa utilizado para o cálculo também é apresentado.

Tabela A3. Sintomas calculados de TDA para os sinais de aceleração.

Sintoma	Descrição
28	TDA filtrado com filtro passa-baixa em 40 Hz
29	TDA filtrado com filtro passa-baixa em 200 Hz
30	TDA filtrado com filtro passa-baixa em 1.000 Hz
31	TDA filtrado com filtro passa-baixa em 2.000 Hz
32	TDA filtrado na banda de 1.000 Hz a 4.000 Hz
33	TDA filtrado com filtro passa-alta em 500 Hz
34	TDA filtrado com filtro passa-alta em 1.000 Hz
35	TDA filtrado com filtro passa-alta em 2.000 Hz
36	TDA filtrado com filtro passa-alta em 3.000 Hz
37	TDA filtrado com filtro passa-alta em 4.000 Hz
38	TDA filtrado com filtro passa-alta em 5.000 Hz
39	TDA filtrado com filtro passa-alta em 6.000 Hz
40	TDA filtrado com filtro passa-alta em 7.000 Hz
41	Nível RMS do TDA global
42	Diferença entre o nível RMS do sinal global e o nível RMS do TDA global
43	Razão entre o nível RMS do sinal global e o nível RMS do TDA global
44	Nível RMS do sinal global

```

function [S]=sintoma_tda1(Y,dt)
n=length(Y(1,:));
S=zeros(n,17);
for i=1:n,
y=Y(:,i);
y_tda=tda(y,dt);
rms=std(y-mean(y));
y=y_tda;
[B A]=butter(1,2*40*dt);
yf=filter(B,A,y);
S(i,1)=std(yf-mean(yf));
[B A]=butter(1,2*200*dt);
yf=filter(B,A,y);
S(i,2)=std(yf-mean(yf));
[B A]=butter(1,2*1000*dt);
yf=filter(B,A,y);
S(i,3)=std(yf-mean(yf));

```

```

[B A]=butter(1,2*2000*dt);
yf=filter(B,A,y);
S(i,4)=std(yf-mean(yf));
[B A]=butter(1,2*[1000 4000]*dt);
yf=filter(B,A,y);
S(i,5)=std(yf-mean(yf));
[B A]=butter(1,2*500*dt, 'high');
yf=filter(B,A,y);
S(i,6)=std(yf-mean(yf));
[B A]=butter(1,2*1000*dt, 'high');
yf=filter(B,A,y);
S(i,7)=std(yf-mean(yf));
[B A]=butter(1,2*2000*dt, 'high');
yf=filter(B,A,y);
S(i,8)=std(yf-mean(yf));
[B A]=butter(1,2*3000*dt, 'high');
yf=filter(B,A,y);
S(i,9)=std(yf-mean(yf));
[B A]=butter(1,2*4000*dt, 'high');
yf=filter(B,A,y);
S(i,10)=std(yf-mean(yf));
[B A]=butter(1,2*5000*dt, 'high');
yf=filter(B,A,y);
S(i,11)=std(yf-mean(yf));
[B A]=butter(1,2*6000*dt, 'high');
yf=filter(B,A,y);
S(i,12)=std(yf-mean(yf));
[B A]=butter(1,2*7000*dt, 'high');
yf=filter(B,A,y);
S(i,13)=std(yf-mean(yf));
S(i,14)=std(y_tda-mean(y_tda));
S(i,15)=rms-S(i,14);
S(i,16)=rms/std(y_tda-mean(y_tda));
S(i,17)=rms;
end
S=10*log10(S);

```

Os sintomas numerados de 45 a 60 estão relacionados com os cálculos de TDA, para os sinais de velocidade. A Tabela A4 especifica esses sintomas e programa utilizado para o cálculo também é apresentado.

Tabela A4. Sintomas calculados de TDA para os sinais de velocidade.

Sintoma	Descrição
45	TDA filtrado com filtro passa-baixa em 40 Hz
46	TDA filtrado com filtro passa-baixa em 200 Hz
47	TDA filtrado com filtro passa-baixa em 1.000 Hz
48	TDA filtrado com filtro passa-baixa em 2.000 Hz
49	TDA filtrado na banda de 1.000 Hz a 4.000 Hz
50	TDA filtrado com filtro passa-alta em 500 Hz
51	TDA filtrado com filtro passa-alta em 1.000 Hz
52	TDA filtrado com filtro passa-alta em 2.000 Hz
53	TDA filtrado com filtro passa-alta em 3.000 Hz
54	TDA filtrado com filtro passa-alta em 4.000 Hz
55	TDA filtrado com filtro passa-alta em 5.000 Hz
56	TDA filtrado com filtro passa-alta em 6.000 Hz
57	TDA filtrado com filtro passa-alta em 7.000 Hz
58	Nível RMS do TDA global
59	Diferença entre o nível RMS do sinal global e o nível RMS do TDA global
60	Razão entre o nível RMS do sinal global e o nível RMS do TDA global

```

function [S]=sintoma_tda1_v(Y,dt)
n=length(Y(1,:));
S=zeros(n,16);
for i=1:n,
    y=integraA(Y(:,i),dt);
    y_tda=tda(y,dt);
    rms=std(y-mean(y));
    y=y_tda;
    [B A]=butter(1,2*40*dt);
    yf=filter(B,A,y);
    S(i,1)=std(yf-mean(yf));
    [B A]=butter(1,2*200*dt);
    yf=filter(B,A,y);
    S(i,2)=std(yf-mean(yf));
    [B A]=butter(1,2*1000*dt);
    yf=filter(B,A,y);
    S(i,3)=std(yf-mean(yf));
    [B A]=butter(1,2*2000*dt);
    yf=filter(B,A,y);
    S(i,4)=std(yf-mean(yf));
    [B A]=butter(1,2*[1000 4000]*dt);
    yf=filter(B,A,y);
    S(i,5)=std(yf-mean(yf));
    [B A]=butter(1,2*500*dt,'high');
    yf=filter(B,A,y);
    S(i,6)=std(yf-mean(yf));
    [B A]=butter(1,2*1000*dt,'high');
    yf=filter(B,A,y);
    S(i,7)=std(yf-mean(yf));
    [B A]=butter(1,2*2000*dt,'high');
    yf=filter(B,A,y);
    S(i,8)=std(yf-mean(yf));
    [B A]=butter(1,2*3000*dt,'high');
    yf=filter(B,A,y);
    S(i,9)=std(yf-mean(yf));

```

```

[B A]=butter(1,2*4000*dt, 'high');
yf=filter(B,A,y);
S(i,10)=std(yf-mean(yf));
[B A]=butter(1,2*5000*dt, 'high');
yf=filter(B,A,y);
S(i,11)=std(yf-mean(yf));
[B A]=butter(1,2*6000*dt, 'high');
yf=filter(B,A,y);
S(i,12)=std(yf-mean(yf));
[B A]=butter(1,2*7000*dt, 'high');
yf=filter(B,A,y);
S(i,13)=std(yf-mean(yf));
S(i,14)=std(y_tda-mean(y_tda));
S(i,15)=rms-S(i,14);
S(i,16)=rms/std(y_tda-mean(y_tda));
end
S=10*log10(S);

```

Os sintomas numerados de 61 a 71 estão relacionados às bandas de oitava tendo como frequência fundamental a rotação do motor, para os sinais de aceleração. A Tabela A5 caracteriza estes sintomas e o programa usado para o cálculo é apresentado posteriormente.

Tabela A5. Sintomas calculados relacionados às bandas de oitava para os sinais de aceleração.

Sintoma	Descrição
61	Nível RMS do sinal com filtro de oitava aplicado ao 1º harmônico
62	Nível RMS do sinal com filtro de oitava aplicado ao 2º harmônico
63	Nível RMS do sinal com filtro de oitava aplicado ao 4º harmônico
64	Nível RMS do sinal com filtro de oitava aplicado ao 8º harmônico
65	Nível RMS do sinal com filtro de oitava aplicado ao 16º harmônico
66	Nível RMS do sinal com filtro de oitava aplicado ao 32º harmônico
67	Nível RMS do sinal com filtro de oitava aplicado ao 64º harmônico
68	Nível RMS do sinal com filtro de oitava aplicado ao 128º harmônico
69	Nível RMS do sinal filtrado na banda entre a frequência fundamental e 8.100 Hz
70	Nível RMS do sinal com filtro de oitava aplicado a $\frac{1}{2}$ de harmônico
71	Nível RMS do sinal com filtro de oitava aplicado ao $\frac{1}{4}$ de harmônico

```

function [S]=sintoma_oitava(Y,dt)

n=length(Y(1,:));
S=zeros(n,11);
for i=1:n,
    y=Y(:,i);
    freq=freq_rot(y,57,dt);
    [B A]=butter(1,2*freq*[1-.35 1+.35]*dt);
    yf=filter(B,A,y);
    S(i,1)=std(yf-mean(yf));
    [B A]=butter(1,2*freq*2*[1-.35 1+.35]*dt);
    yf=filter(B,A,y);
    S(i,2)=std(yf-mean(yf));
    [B A]=butter(1,2*freq*4*[1-.35 1+.35]*dt);
    yf=filter(B,A,y);

```

```

S(i,3)=std(yf-mean(yf));
[B A]=butter(1,2*freq*8*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,4)=std(yf-mean(yf));
[B A]=butter(1,2*freq*16*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,5)=std(yf-mean(yf));
[B A]=butter(1,2*freq*32*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,6)=std(yf-mean(yf));
[B A]=butter(1,2*freq*64*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,7)=std(yf-mean(yf));
[B A]=butter(1,2*freq*128*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,8)=std(yf-mean(yf));
[B A]=butter(1,2*[freq*(1-.35) 8100]*dt);
yf=filter(B,A,y);
S(i,9)=std(yf-mean(yf));
[B A]=butter(1,2*freq*[1-.35 1+.35]*dt/2);
yf=filter(B,A,y);
S(i,10)=std(yf-mean(yf));
[B A]=butter(1,2*freq*[1-.35 1+.35]*dt/4);
yf=filter(B,A,y);
S(i,11)=std(yf-mean(yf));
end
S=10*log10(S);

```

Os sintomas numerados de 72 a 82 estão relacionados às bandas de oitava tendo como frequência fundamental a rotação do motor, para os sinais de velocidade. A Tabela A6 caracteriza estes sintomas e o programa usado para o cálculo é apresentado posteriormente.

Tabela A6. Sintomas calculados relacionados às bandas de oitava para os sinais de aceleração.

Sintoma	Descrição
72	Nível RMS do sinal com filtro de oitava aplicado ao 1º harmônico
73	Nível RMS do sinal com filtro de oitava aplicado ao 2º harmônico
74	Nível RMS do sinal com filtro de oitava aplicado ao 4º harmônico
75	Nível RMS do sinal com filtro de oitava aplicado ao 8º harmônico
76	Nível RMS do sinal com filtro de oitava aplicado ao 16º harmônico
77	Nível RMS do sinal com filtro de oitava aplicado ao 32º harmônico
78	Nível RMS do sinal com filtro de oitava aplicado ao 64º harmônico
79	Nível RMS do sinal com filtro de oitava aplicado ao 128º harmônico
80	Nível RMS do sinal filtrado na banda entre a frequência fundamental e 8.100 Hz
81	Nível RMS do sinal com filtro de oitava aplicado a ½ de harmônico
82	Nível RMS do sinal com filtro de oitava aplicado ao ¼ de harmônico

```

function [S]=sintoma_oitava_v(Y,dt)

n=length(Y(1,:));
S=zeros(n,11);
for i=1:n,

```

```

y=integraA(Y(:,i),dt);

freq=freq_rot(y,57,dt);
[B A]=butter(1,2*freq*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,1)=std(yf-mean(yf));
[B A]=butter(1,2*freq*2*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,2)=std(yf-mean(yf));
[B A]=butter(1,2*freq*4*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,3)=std(yf-mean(yf));
[B A]=butter(1,2*freq*8*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,4)=std(yf-mean(yf));
[B A]=butter(1,2*freq*16*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,5)=std(yf-mean(yf));
[B A]=butter(1,2*freq*32*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,6)=std(yf-mean(yf));
[B A]=butter(1,2*freq*64*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,7)=std(yf-mean(yf));
[B A]=butter(1,2*freq*128*[1-.35 1+.35]*dt);
yf=filter(B,A,y);
S(i,8)=std(yf-mean(yf));
[B A]=butter(1,2*[freq*(1-.35) 8100]*dt);
yf=filter(B,A,y);
S(i,9)=std(yf-mean(yf));
[B A]=butter(1,2*freq*[1-.35 1+.35]*dt/2);
yf=filter(B,A,y);
S(i,10)=std(yf-mean(yf));
[B A]=butter(1,2*freq*[1-.35 1+.35]*dt/4);
yf=filter(B,A,y);
S(i,11)=std(yf-mean(yf));
end
S=10*log10(S);

```

Os sintomas numerados de 83 a 98 estão relacionados aos harmônicos do motor elétrico. A Tabela A7 caracteriza estes sintomas e o programa usado para o cálculo é apresentado posteriormente.

Tabela A7. Sintomas calculados relacionados aos harmônicos do motor elétrico para os sinais de aceleração.

Sintoma	Descrição
83	Primeiro conjunto de harmônicos de passagem das ranhuras do estator.
84	Segundo conjunto de harmônicos de passagem das ranhuras do estator.
85	Terceiro conjunto de harmônicos de passagem das ranhuras do estator.
86	Quarto conjunto de harmônicos de passagem das ranhuras do estator.
87	Quinto conjunto de harmônicos de passagem das ranhuras do estator.
88	Sexto conjunto de harmônicos de passagem das ranhuras do estator.
89	Sétimo conjunto de harmônicos de passagem das ranhuras do estator.
90	Oitavo conjunto de harmônicos de passagem das ranhuras do estator.
91	Primeiro conjunto de harmônicos de passagem das ranhuras do rotor.
92	Segundo conjunto de harmônicos de passagem das ranhuras do rotor.
93	Terceiro conjunto de harmônicos de passagem das ranhuras do rotor.
94	Quarto conjunto de harmônicos de passagem das ranhuras do rotor.
95	Quinto conjunto de harmônicos de passagem das ranhuras do rotor.
96	Sexto conjunto de harmônicos de passagem das ranhuras do rotor.
97	Sétimo conjunto de harmônicos de passagem das ranhuras do rotor.
98	Oitavo conjunto de harmônicos de passagem das ranhuras do rotor.

```

function [S]=sintoma_motor(Y,dt)
n=length(Y(1,:));
S=zeros(n,16);
for i=1:n,
    y=Y(:,i);
    freq_bas=freq_rot(y,60,dt);
    [C freq]=espectro(y,y,32768,16384,dt);
    s=(60.-freq_bas)/60. ;
    [Ym]=motor_harm(60.,s,1,24,1,freq,C(:,1));
    S(i,1)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,2,freq,C(:,1));
    S(i,2)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,3,freq,C(:,1));
    S(i,3)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,4,freq,C(:,1));
    S(i,4)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,5,freq,C(:,1));
    S(i,5)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,6,freq,C(:,1));
    S(i,6)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,7,freq,C(:,1));
    S(i,7)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,24,8,freq,C(:,1));
    S(i,8)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,30,1,freq,C(:,1));
    S(i,9)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,30,2,freq,C(:,1));
    S(i,10)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,30,3,freq,C(:,1));
    S(i,11)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,30,4,freq,C(:,1));
    S(i,12)=sum(Ym);
    [Ym]=motor_harm(60.,s,1,30,5,freq,C(:,1));

```

```

S(i,13)=sum(Ym);
[Ym]=motor_harm(60.,s,1,30,6,freq,C(:,1));
S(i,14)=sum(Ym);
[Ym]=motor_harm(60.,s,1,30,7,freq,C(:,1));
S(i,15)=sum(Ym);
[Ym]=motor_harm(60.,s,1,30,8,freq,C(:,1));
S(i,16)=sum(Ym);
end
S=10*log10(S);

```

Os sintomas numerados de 99 a 116 estão relacionados à análise de envelope. A Tabela A8 especifica os sintomas utilizados para esta análise. O programa utilizado para o cálculo também é apresentado.

Tabela A8. Sintomas calculados relacionados à análise de envelope.

Sintoma	Descrição
99	Nível de energia do envelope filtrado com filtro passa-baixa em 100 Hz
100	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-baixa em 100 Hz
101	Nível de energia do envelope filtrado com filtro passa-banda entre 1.000 Hz e 3.000 Hz
102	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-banda entre 1.000 Hz e 3.000 Hz
103	Nível de energia do envelope filtrado com filtro passa-banda entre 2.000 Hz e 6.000 Hz
104	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-banda entre 2.000 Hz e 6.000 Hz
105	Nível de energia do envelope filtrado com filtro passa-alta em 2.000 Hz
106	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 2.000 Hz
107	Nível de energia do envelope filtrado com filtro passa-alta em 4.000 Hz
108	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 4.000 Hz
109	Nível de energia do envelope filtrado com filtro passa-alta em 6.000 Hz
110	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 6.000 Hz
111	Nível de energia do envelope filtrado com filtro passa-alta em 8.000 Hz
112	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 8.000 Hz
113	Nível de energia do envelope filtrado com filtro passa-alta em 10.000 Hz
114	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 10.000 Hz
115	Nível de energia do envelope filtrado com filtro passa-alta em 12.000 Hz
116	Diferença entre máximo e mínimo do envelope filtrado com filtro passa-alta em 12.000 Hz

```
function [S]=sintoma_envelope(Y,dt)
```

```

n=length(Y(1,:));
S=zeros(n,14);
for i=1:n,
    y=Y(:,i);
    [B A]=butter(2,2*100*dt);
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,1)=std(yh-mean(yh));
    S(i,2)=max(yh)-min(yh);
    [B A]=butter(2,2*[1000 3000]*dt);
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,3)=std(yh-mean(yh));
    S(i,4)=max(yh)-min(yh);
    [B A]=butter(2,2*[2000 6000]*dt);
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,5)=std(yh-mean(yh));
    S(i,6)=max(yh)-min(yh);
    [B A]=butter(2,2*2000*dt,'high');
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,7)=std(yh-mean(yh));
    S(i,8)=max(yh)-min(yh);
    [B A]=butter(2,2*4000*dt,'high');
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,9)=std(yh-mean(yh));
    S(i,10)=max(yh)-min(yh);
    [B A]=butter(2,2*6000*dt,'high');
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,11)=std(yh-mean(yh));
    S(i,12)=max(yh)-min(yh);
    [B A]=butter(2,2*8000*dt,'high');
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,13)=std(yh-mean(yh));
    S(i,14)=max(yh)-min(yh);
    [B A]=butter(2,2*10000*dt,'high');
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,15)=std(yh-mean(yh));
    S(i,16)=max(yh)-min(yh);
    [B A]=butter(2,2*12000*dt,'high');
    yf=filter(B,A,y);
    yh=abs(hilbert(yf));
    S(i,17)=std(yh-mean(yh));
    S(i,18)=max(yh)-min(yh);

end
S=10*log10(S);

```

Os sintomas numerados de 117 a 130 foram calculados em função de regiões do espectro relacionadas às frequências naturais de componentes do compressor, utilizando sinais de aceleração.

A Tabela A9 especifica os sintomas utilizados para esta análise. O programa utilizado para o cálculo também é apresentado.

Tabela A9. Sintomas calculados em função de regiões do espectro relacionadas às frequências naturais de componentes do compressor, para os sinais de aceleração.

Sintoma	Descrição
117	Nível de energia do sinal filtrado com filtro passa-baixa em 40 Hz
118	Nível de energia do sinal filtrado com filtro passa-baixa em 200 Hz
119	Nível de energia do sinal filtrado com filtro passa-baixa em 1.000 Hz
120	Nível de energia do sinal filtrado com filtro passa-baixa em 2.000 Hz
121	Nível de energia do sinal filtrado com filtro passa-banda entre 1.000 e 4.000 Hz
122	Nível de energia do sinal filtrado com filtro passa-alta em 500 Hz
123	Nível de energia do sinal filtrado com filtro passa-alta em 1.000 Hz
124	Nível de energia do sinal filtrado com filtro passa-alta em 2.000 Hz
125	Nível de energia do sinal filtrado com filtro passa-alta em 3.000 Hz
126	Nível de energia do sinal filtrado com filtro passa-alta em 4.000 Hz
127	Nível de energia do sinal filtrado com filtro passa-alta em 5.000 Hz
128	Nível de energia do sinal filtrado com filtro passa-alta em 6.000 Hz
129	Nível de energia do sinal filtrado com filtro passa-alta em 7.000 Hz
130	Nível de energia do sinal filtrado com filtro passa-banda entre 500 e 7.000 Hz

```

function [S]=sintoma_banda(Y,dt)
n=length(Y(1,:));
S=zeros(n,14);
for i=1:n,
    y=Y(:,i);
    [B A]=butter(1,2*40*dt);
    yf=filter(B,A,y);
    S(i,1)=std(yf-mean(yf));
    [B A]=butter(1,2*200*dt);
    yf=filter(B,A,y);
    S(i,2)=std(yf-mean(yf));
    [B A]=butter(1,2*1000*dt);
    yf=filter(B,A,y);
    S(i,3)=std(yf-mean(yf));
    [B A]=butter(1,2*2000*dt);
    yf=filter(B,A,y);
    S(i,4)=std(yf-mean(yf));
    [B A]=butter(1,2*[1000 4000]*dt);
    yf=filter(B,A,y);
    S(i,5)=std(yf-mean(yf));
    [B A]=butter(1,2*500*dt,'high');
    yf=filter(B,A,y);
    S(i,6)=std(yf-mean(yf));
    [B A]=butter(1,2*1000*dt,'high');
    yf=filter(B,A,y);
    S(i,7)=std(yf-mean(yf));
    [B A]=butter(1,2*2000*dt,'high');
    yf=filter(B,A,y);
    S(i,8)=std(yf-mean(yf));
    [B A]=butter(1,2*3000*dt,'high');

```

```

yf=filter(B,A,y);
S(i,9)=std(yf-mean(yf));
[B A]=butter(1,2*4000*dt,'high');
yf=filter(B,A,y);
S(i,10)=std(yf-mean(yf));
[B A]=butter(1,2*5000*dt,'high');
yf=filter(B,A,y);
S(i,11)=std(yf-mean(yf));
[B A]=butter(1,2*6000*dt,'high');
yf=filter(B,A,y);
S(i,12)=std(yf-mean(yf));
[B A]=butter(1,2*7000*dt,'high');
yf=filter(B,A,y);
S(i,13)=std(yf-mean(yf));
[B A]=butter(1,2*[500 7000]*dt);
yf=filter(B,A,y);
S(i,14)=std(yf-mean(yf));
end
S=10*log10(S);

```

Os sintomas numerados de 131 a 144 são calculados em função das regiões do espectro relacionadas às frequências naturais de componentes do compressor, utilizando sinais de velocidade. A Tabela A10 apresenta os sintomas calculados. Posteriormente, o programa utilizado é apresentado.

Tabela A10. Sintomas calculados em função de regiões do espectro relacionadas às frequências naturais de componentes do compressor, para os sinais de velocidade.

Sintoma	Descrição
131	Nível de energia do sinal filtrado com filtro passa-baixa em 40 Hz
132	Nível de energia do sinal filtrado com filtro passa-baixa em 200 Hz
133	Nível de energia do sinal filtrado com filtro passa-baixa em 1.000 Hz
134	Nível de energia do sinal filtrado com filtro passa-baixa em 2.000 Hz
135	Nível de energia do sinal filtrado com filtro passa-banda entre 1.000 e 4.000 Hz
136	Nível de energia do sinal filtrado com filtro passa-alta em 500 Hz
137	Nível de energia do sinal filtrado com filtro passa-alta em 1.000 Hz
138	Nível de energia do sinal filtrado com filtro passa-alta em 2.000 Hz
139	Nível de energia do sinal filtrado com filtro passa-alta em 3.000 Hz
140	Nível de energia do sinal filtrado com filtro passa-alta em 4.000 Hz
141	Nível de energia do sinal filtrado com filtro passa-alta em 5.000 Hz
142	Nível de energia do sinal filtrado com filtro passa-alta em 6.000 Hz
143	Nível de energia do sinal filtrado com filtro passa-alta em 7.000 Hz
144	Nível de energia do sinal filtrado com filtro passa-banda entre 500 e 7.000 Hz

```

function [S]=sintoma_banda_v(Y,dt)
n=length(Y(1,:));
S=zeros(n,14);
for i=1:n,
    y=integraA(Y(:,i),dt);
    [B A]=butter(1,2*40*dt);

```

```

yf=filter(B,A,y);
S(i,1)=std(yf-mean(yf));
[B A]=butter(1,2*200*dt);
yf=filter(B,A,y);
S(i,2)=std(yf-mean(yf));
[B A]=butter(1,2*1000*dt);
yf=filter(B,A,y);
S(i,3)=std(yf-mean(yf));
[B A]=butter(1,2*2000*dt);
yf=filter(B,A,y);
S(i,4)=std(yf-mean(yf));
[B A]=butter(1,2*[1000 4000]*dt);
yf=filter(B,A,y);
S(i,5)=std(yf-mean(yf));
[B A]=butter(1,2*500*dt,'high');
yf=filter(B,A,y);
S(i,6)=std(yf-mean(yf));
[B A]=butter(1,2*1000*dt,'high');
yf=filter(B,A,y);
S(i,7)=std(yf-mean(yf));
[B A]=butter(1,2*2000*dt,'high');
yf=filter(B,A,y);
S(i,8)=std(yf-mean(yf));
[B A]=butter(1,2*3000*dt,'high');
yf=filter(B,A,y);
S(i,9)=std(yf-mean(yf));
[B A]=butter(1,2*4000*dt,'high');
yf=filter(B,A,y);
S(i,10)=std(yf-mean(yf));
[B A]=butter(1,2*5000*dt,'high');
yf=filter(B,A,y);
S(i,11)=std(yf-mean(yf));
[B A]=butter(1,2*6000*dt,'high');
yf=filter(B,A,y);
S(i,12)=std(yf-mean(yf));
[B A]=butter(1,2*7000*dt,'high');
yf=filter(B,A,y);
S(i,13)=std(yf-mean(yf));
[B A]=butter(1,2*[500 7000]*dt);
yf=filter(B,A,y);
S(i,14)=std(yf-mean(yf));
end
S=10*log10(S);

```

Os sintomas numerados de 145 a 169 estão relacionados com a análise em bandas de 1/3 de oitava entre 40 e 12.500 Hz. A Tabela A11 especifica os sintomas calculados para esta análise e posteriormente, o programa utilizado é apresentado.

Tabela A11. Sintomas calculados para análise em bandas de 1/3 de oitava.

Sintoma	Descrição
145	Filtro de 1/3 de oitava centrado em 40 Hz
146	Filtro de 1/3 de oitava centrado em 63 Hz
147	Filtro de 1/3 de oitava centrado em 80 Hz
148	Filtro de 1/3 de oitava centrado em 100 Hz
149	Filtro de 1/3 de oitava centrado em 125 Hz
150	Filtro de 1/3 de oitava centrado em 160 Hz
151	Filtro de 1/3 de oitava centrado em 200 Hz
152	Filtro de 1/3 de oitava centrado em 250 Hz
153	Filtro de 1/3 de oitava centrado em 315 Hz
154	Filtro de 1/3 de oitava centrado em 400 Hz
155	Filtro de 1/3 de oitava centrado em 500 Hz
156	Filtro de 1/3 de oitava centrado em 630 Hz
157	Filtro de 1/3 de oitava centrado em 800 Hz
158	Filtro de 1/3 de oitava centrado em 1.000 Hz
159	Filtro de 1/3 de oitava centrado em 1.250 Hz
160	Filtro de 1/3 de oitava centrado em 1.600 Hz
161	Filtro de 1/3 de oitava centrado em 2.000 Hz
162	Filtro de 1/3 de oitava centrado em 2.500 Hz
163	Filtro de 1/3 de oitava centrado em 3.150 Hz
164	Filtro de 1/3 de oitava centrado em 4.000 Hz
165	Filtro de 1/3 de oitava centrado em 5.000 Hz
166	Filtro de 1/3 de oitava centrado em 6.000 Hz
167	Filtro de 1/3 de oitava centrado em 8.000 Hz
168	Filtro de 1/3 de oitava centrado em 10.000 Hz
169	Filtro de 1/3 de oitava centrado em 12.000 Hz

```

function [S]=sintoma_oitava_terc(Y,dt)
f_oit=[40 63 80 100 125 160 200 250 315 400 500 630 800 1000 1250 1600 2000
2500 3150 4000 5000 6000 ...
8000 10000 12500];
nn=length(f_oit);
n=length(Y(1,:));
S=zeros(n,nn);
for i=1:n,
y=Y(:,i);
[C,freq]=espectro(y,y,16384,8192,dt);
[terc]=terc_oitava(freq,C(:,1));
for j=1:nn, S(i,j)=terc(j); end
end
S=10*log10(S);

```