Diana Marcela Martinez Ricardo

Identificação da vazão de gás de uma bomba centrífuga em regime de escoamento multifásico através de dados experimentais.

22/2014

CAMPINAS

2014

UNICAMP

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA

Diana Marcela Martinez Ricardo

Identificação da vazão de gás de uma bomba centrífuga em regime de escoamento multifásico através de dados experimentais

Dissertação de Mestrado apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas para obtenção do título de Mestre em Engenharia Mecânica, na Área de Mecânica dos Sólidos e Projeto Mecânico.

Orientador: Prof. Dr. Janito Vaqueiro Ferreira

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL DA DISSERTAÇÃO DEFENDIDA PELA ALUNA DIANA MARCELA MARTINEZ RICARDO E ORIENTADA PELO PROF. DR JANITO VAQUEIRO FERREIRA.

Janito Vaqueiro Ferreira
ASSINATURA DO ORIENTADOR

CAMPINAS
2014

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

M366i

Martinez Ricardo, Diana Marcela, 1986-
Identificação da vazão de gás de uma bomba centrífuga em regime de escoamento multifásico através de dados experimentais / Diana Marcela Martinez Ricardo. – Campinas, SP : [s.n.], 2014.

Orientador: Janito Vaqueiro Ferreira.
Dissertação (mestrado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Bomba centrifuga. 2. Identificação de sistemas. 3. Escoamento multifásico - Modelos matemáticos. 4. Aprendizado de máquina. 5. Algoritmos genéticos - Processamento de dados. I. Vaqueiro Ferreira, Janito,1961-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Identification of the gas flow of an electric submersible pump under multiphase flow thou experimental data
Palavras-chave em inglês:
Centrifugal pumps
Identification systems
Multiphase flow - Mathematical models
Genetic algorithms
Machine learning
Genetic algorithms - Data processing
Área de concentração: Mecânica dos Sólidos e Projeto Mecânico
Titulação: Mestra em Engenharia Mecânica
Banca examinadora:
Janito Vaqueiro Ferreira [Orientador]
Pablo Siqueira Meirelles
Vicente Lopes Junior
Data de defesa: 26-02-2014
Programa de Pós-Graduação: Engenharia Mecânica

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
COMISSÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA
DEPARTAMENTO DE MECÂNICA COMPUTACIONAL

DISSERTAÇÃO DE MESTRADO ACADEMICO

Identificação da vazão de gás de uma bomba centrífuga em regime de escoamento multifásico através de dados experimentais.

Autor: Diana Marcela Martinez Ricardo

Orientador: Prof. Dr. Janito Vaqueiro Ferreira

A Banca Examinadora composta pelos membros abaixo aprovou esta Dissertação:

Prof. Dr. Janito Vaqueiro Ferreira, Presidente
DMC/FEM/UNICAMP

Prof. Dr. Pablo Siqueira Meirelles
DMC/FEM/UNICAMP

Prof. Dr. Vicente Lopes Junior
UNESP/ ILHA SOLTEIRA

Campinas, 26 de fevereiro de 2014.

Dedico este trabalho aos meus pais, Hector Martinez e Nisfery Ricardo, que fizeram todo o possível para que eu pudesse realizar meus sonhos e a meus irmãos David e Sara pelo apoio e pelo o carinho.

Agradecimentos

Quero começar expressando meus profundos e sinceros agradecimentos a Deus, por permiti-me viver esta nova experiência e pelas bênçãos que recebo dia a dia.

À Universidade Estadual de Campinas por me permitir realizar meus estudos de mestrado no Brasil e a empresa Petrobrás pelo financiamento do projeto.

A meu orientador Janito Vaqueiro Ferreira, pelo apoio, orientação, paciência e disposição dada neste processo de aprendizagem e especialmente pela oportunidade de aprendizagem.

Aos meus pais Hector e Nisfery, pelo apoio que sempre me deram em todo momento da minha vida, pelos valores ensinados e sobre tudo por ser um excelente exemplo de vida a seguir. Ao meu irmão David por estar sempre comigo, por sua confiança, carinho e apoio em todo momento. A minha irmã Sara e demais membros da família pelo apoio e carinho.

A meu namorado German Castañeda, por sua paciência, companhia, apoio e especialmente por sua motivação e ajuda nos momentos difíceis e por me inspirar a ser melhor cada dia, obrigada por estar sempre ao meu lado e pelo amor.

Ao Bernardo Foresti por compartilhar seus conhecimentos e por toda a ajuda brindada para o desenvolvimento desta pesquisa.

A meus companheiros e amigos de aventura Paola Gonzalez, Oscar Rojas, Manuel Arcila, Jenny Lombo, Camilo Ariza, María Fernanda Rodríguez, Olmer Garcia, Marcela Corredor, Sergio Garcia e demais amigos Colombo – Brasileiros pelo apoio e amizade. Finalmente agradecimento profundo a Guilberto Valente por todos os favores recebidos e pela amizade.

"A nossa maior glória

não reside no fato de nunca cairmos,

mas sim em levantarmos sempre depois de cada queda".

Confúcio

Resumo

Ricardo, D. M. M. Identificação da vazão de gás de uma bomba centrífuga em regime de escoamento multifásico através de dados experimentais. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, 2014.107p. Dissertação (Mestrado).

Este trabalho tem como objetivo desenvolver um processo de identificação da vazão de gás em um dos equipamentos usados na indústria petrolífera, às bombas centrífugas submersas (BCS) em regime de escoamento multifásico. Estas bombas apresentam falhas frequentes prematuras quando a vazão de gás é alta, as quais ocorrem por falta de informação do tipo de escoamento bifásico presente na bomba no tempo de operação. Por isto estudos de identificação experimental são requeridos nesta área. Neste contexto a presente pesquisa tem seu foco na obtenção de modelos mediante dados experimentais, recompilados diretamente da resposta do sistema que descrevem o comportamento da vazão de gás na planta de interesse, como: vibração, vazão, elevação entre outros. Estes modelos estão baseados na identificação não paramétrica e no algoritmo de aprendizagem de Máquina de Vetores de Suporte (SVM), onde os parâmetros ocultos da máquina de aprendizagem serão obtidos mediante algoritmos genéticos, visando obter modelos mais representativos.

Palavras Chave: *Bomba centrifuga, Identificação de sistemas, Escoamento multifásico, Aprendizado de máquina, Algoritmos genéticos.*

Abstract

Ricardo, D. M. M. Identification of the gas flow of an electric submersible pump under multiphase flow thou experimental data. Campinas: Department of Mechanical Engineering, University of Campinas, 2014. 107 p. Thesis (Master).

This work develops a process to identify the flow of gas in one of the equipment used in the oil industry, the electric submersible pump (EPS) under multiphase flow. These pumps feature frequent premature failures when the gas flow is high. That occurs due to lack of information on the type of two – phase flow in the pump in operation time. Experimental studies for this identification are required in this area. In this context, the present research focuses on obtaining models by experimental data collected directly from the system response which describes the behavior of the gas flow on the system of interest such as: vibration, fluid, elevation etc. These models are based on nonparametric identification and in learning algorithm support vector machine (SVM), where the hidden parameters of the learning machine will be obtained by genetic algorithms in order to obtain more representative models.

Key Words: *Centrifugal pumps, Identification systems, Multiphase flow – Mathematical models, Genetic algorithms, Machine learning, Genetic algorithms – Data processing.*

Lista de Ilustrações

Figura 3.1 Problema de classificação com dados linearmente separáveis. 12
Figura 3.2 Comportamento da margem da SVM. 13
Figura 3.3 Problema de classificação com dados não separáveis linearmente. 14
Figura 3.4 Comportamento do parâmetro C 15
Figura 3.5 Problema de classificação com modelo não linear 16
Figura 3.6 Funcionamento do *Kernel*..... 17
Figura 3.7 SVMR para um sistema com modelo não linear 21
Figura 3.8 Aumento do espaço de mapeamento de entradas. 22
Figura 4.1 Circuito de testes BCS 27
Figura 4.2 Sistema de aquisição de dados (LMS) e configuração. 28
Figura 4.3 Esquema de montagem dos sensores. 29
Figura 4.4 Procedimento experimental 30
Figura 4.5 Arquitetura da SVM para regressão..... 37
Figura 4.6 Procedimento do algoritmo genético 38
Figura 4.7 Algoritmo de amostragem pelo método de roleta..... 42
Figura 5.1 Sistema massa – mola – amortecedor. 45
Figura 5.2 Forças em cada uma das massas do sistema massa-mola-amortecedor 45
Figura 5.3 Sistema massa – mola – amortecedor a identificar com todos os dados de treinamento. 46
Figura 5.4 Resposta do sistema massa-mola-amortecedor no domínio do tempo. 48
Figura 5.5 Representação espectral do sistema massa-mola-amortecedor 48
Figura 5.6 a) Melhores indivíduos do algoritmo genético. b) Evolução dos parâmetros ocultos da SVMR mediante algoritmo genético. c) Comportamento dos erros de validação e treinamento. 52
Figura 5.7 Resultados da identificação da rigidez com modelo obtido por SVMR com todos os dados característicos do sistema. 53
Figura 5.8 Sistema massa – mola – amortecedor a identificar sem todos os dados de treinamento 53
Figura 5.9 Identificação das rigidezes não incluídas no treinamento da SVMR 55

Figura 5.10 Configuração do circuito de testes de BCS para aquisição de dados 56
Figura 5.11 Representação espectral da BCS com rotação de $1800\,RPM$ e vazão de gás $0-3\,Kg/h$. 57
Figura 5.12 Representação espectral da BCS com rotação de $3000\,RPM$ e vazão de gás $0-3\,Kg/h$. 57
Figura 5.13 Resultados do modelo obtido a partir da representação espectral e a vazão total. 68
Figura 5.14 Resultados do modelo obtido a partir da representação espectral e torque. 69
Figura 5.15 Resultados do modelo obtido a partir da representação espectral e elevação. 69
Figura 5.16 Resultados do modelo obtido a partir da vazão total e torque. 70
Figura 5.17 Resultados do modelo obtido a partir da vazão total e elevação 71
Figura 5.18 Resultados do modelo obtido a partir do torque e elevação. 71
Figura 5.19 Resultados do modelo obtido a partir da representação espectral do sinal de vibração do sistema. 72
Figura 5.20 Resultados do modelo obtido a partir da vazão total. 73
Figura 5.21 Resultados do modelo obtido a partir do torque. 73
Figura 5.22 Resultados do modelo obtido a partir da elevação. 74
Figura 5.23 Resultados do modelo obtido a partir da representação espectral e da vazão total, mas sem os dados de vazão de gás igual a $2\,kg/h$ 75

Lista de Tabelas

Tabela 4.1 Dados da instrumentação utilizada. 27
Tabela 4.2 Posiçãode montagem dos sensores. 29
Tabela 5.1 Configuração do algoritmo genético 50
Tabela 5.2 Parâmetros e MSE dos modelos obtidos pelo algoritmo genético para SVMR com todos os dados de treinamento. 50
Tabela 5.3 Parâmetros e MSE dos modelos obtidos pelo algoritmo genético para SVMR sem todos os dados de treinamento. 54
Tabela 5.4 Amostras de treinamento e saída para cada modelo 58
Tabela 5.5 Configuração do algoritmo genético 59
Tabela 5.6 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 1 (DEP–Q) 60
Tabela 5.7 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 2 (DEP–T) 61
Tabela 5.8 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 3 (DEP–E) 61
Tabela 5.9 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 4 (Q–T) 62
Tabela 5.10 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 5 (Q–E) 63
Tabela 5.11 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 6 (T–E) 63
Tabela 5.12 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 7 (DEP) 64
Tabela 5.13 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 8 (Q) 65
Tabela 5.14 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 9 (T) 65
Tabela 5.15 Parâmetros $C, \sigma 2, \varepsilon$ e MSE dos testes do algoritmo genético para Modelo 10 (E) 66
Tabela 5.16 Parâmetros e MSE dos modelos obtidos pelo método de SVMR para identificação da vazão de gás na BCS. 76

Lista de Abreviaturas e Siglas

Abreviações

AG – Algoritmo Genético.

BCS – Bombas Centrífugas Submersas.

DPE – Representação espectral do sinal de aceleração da BCS.

E – Elevação.

EPS – Electric Submersible Pump.

K – Kernel.

MSE - Erro quadrático médio

SVM – Support Vector Machine (Máquina de Vetores de Suporte).

SVMR – Support Vector Machine Regression (Máquina de Vetores de Suporte para Regressão).

T – Torque.

VS – Vetores de Suporte.

Siglas

A – Matriz semi definida positiva do *kernel* linear

b – Termo de bias

C – Termo de penalização do SVM

C – Matriz de amortecimento

C_i – Cromossomo

e_{val} – Erro de validação

$f(x)$ – Função do modelo

f_i– Função objetivo

G_{yy} – Função de auto-correlação

h_θ – Hipóteses do modelo

$J(\theta)$ – Função de custo

K – Matriz de rigidez

k_1 – Fator do *kernel* rede neural

k_2 – Fator do *kernel* rede neural

$\tilde{L}$– Função de Lagrange

m – Margem.

M – Matriz de massa

N_e – Número de copias esperadas.

p – Fator do *kernel* polinomial.

$\left(P(t)\right)$ – População inicial aleatória de indivíduos

q – Amostras do sinal no domínio do tempo.

S_{yy} – Densidade espectral de potencia.

Q – Vazão total do sistema

u – Parâmetro proporcional de mudança da rigidez.

w – Vetor de pesos da SVM

$\mathrm{x}(i)$– Entradas a SVMR

x_i – Fenótipo

$\mathrm{y}(i)$ – Saída da SVMR

z – Combinação Linear

θ – Parâmetros da Função

α – Multiplicador de Lagrange

$\emptyset$ – Função Kernel

σ^2 – Fator do Kernel Gaussiano

ξ – Dados Errados na Classificação ou Regressão

ε – Fator da Margem SVMR

Sumário

Capítulo 1. Introdução 1

1.1 Introdução 1

1.2 Motivação e contextualização 2

1.3 Proposta de trabalho 3

1.4 Objetivo 3

1.4.1 Atividades da pesquisa 3

1.5 Organização da dissertação 4

Capítulo 2. Revisão Bibliográfica 5

1.6 Bomba centrífuga submersa 5

1.7 Modelagem e identificação de sistemas 6

1.7.1 Identificação de sistemas 6

1.7.2 Revisão bibliográfica de identificação de sistemas. 7

1.8 Aprendizagem de máquina 8

Capítulo 3. Fundamentos Teóricos 11

1.9 Máquinas de vetores de suporte 11

1.9.1 Máquinas de Vetores de suporte para classificação 11

1.9.2 Função *Kernel.* 17

1.9.3 Máquinas de Vetores de suporte para regressão 19

1.10 Algoritmos genéticos 22

1.10.1 Estrutura de um algoritmo genético 23

Capítulo 4. Modelo de identificação de vazão de gás 26

1.11 Planejamento dos experimentos 26

1.11.1 Instrumentação e sistema de aquisição de dados 27

1.11.2 Procedimento experimental 30

1.12 Seleção do modelo 31
1.12.1 SVM Regressão 34
1.12.2 Algoritmo Genético 37
1.12.3 Eleição do critério de estimação 43
1.13 Validação do modelo 43
Capítulo 5. Resultados 44
1.14 Sistema massa-mola-amortecedor 44
1.14.1 Descrição do modelo 44
1.14.2 Obtenção do modelo e resultados 48
1.15 Identificação da vazão de gás numa BCS 55
1.15.1 Ajuste das condições iniciais do circuito de testes de BCS 55
1.15.2 Análise da representação espectral do sistema BCS 56
1.15.3 Modelos não paramétricos obtidos a partir de SVMR 58
1.15.4 Análise de predição da vazão de gás 66
1.15.5 Análise de predição da vazão de gás sem todos os dados de treinamento 74
1.15.6 Comparação dos resultados 75
Capítulo 6. Conclusões e recomendações de trabalhos futuros 78
1.16 Conclusões 78
1.17 Recomendações de trabalhos futuros 79
Referências Bibliográficas 80

Capítulo 1. Introdução

1.1 Introdução

Na indústria de petróleo são frequentemente empregados métodos de elevação artificial como o bombeamento centrífugo submerso, que utilizam conjuntos de bombas centrífugas submersas (BCS) para a produção de óleo e gás. Estes conjuntos de BCS estão compostos por bombas centrífugas submersas que estão associados a selos / protetores e motores. Geralmente estes conjuntos são instalados dentro de um poço produtor de petróleo, ficando em contínuo contato com o fluido (TAKACS, 2009).

A instalação do conjunto BCS em poços satélites submarinos envolve altos custos, os quais, quando associados ao lucro cessante em caso de falha prematura ou mau funcionamento do conjunto BCS, podem causar impactos negativos na empresa. Assim sendo, torna-se indispensável garantir a qualidade e a operação de tais conjuntos (RIBEIRO, 2005).

Em virtude das frequentes falhas apresentadas nos conjuntos BCS causado pela influência da vazão de gás na bomba, foram desenvolvidos e realizados diversos estudos experimentais como, por exemplo, os testes de integração de conjunto de BCS o qual consiste em elaborar uma sequência de testes com o conjunto de BCS integrado e em condições de operação, denominados "*String Tests*". Neles são feitos quinze ensaios elétricos, e o levantamentos de curvas de desempenho (RIBEIRO, 2011). Estes estudos são realizados para entender o comportamento e a influência do gás no funcionamento da BCS, porém tal fenômeno associado a óleo é escasso na literatura. Como os fenômenos existentes ainda não são bem conhecidos neste caso, e os modelos teóricos são de difícil desenvolvimento devido à complexidade do processo, estudos de identificação experimental são requeridos, para a obtenção de um modelo que permita estimar a vazão de gás nestes sistemas, e com este modelo é possível conseguir um conhecimento sobre a dinâmica real do sistema de interesse, tendo assim uma ferramenta importante para a estimação e análise do comportamento dos parâmetros do sistema prevenindo-os de falhas (NELLES, 2001).

Neste projeto é realizado o estudo e aplicação da metodologia de identificação de sistemas mediante algoritmos de aprendizagem de máquinas para obter diferentes modelos preditivos que permitam estimar a vazão de gás do conjunto BCS em operação, onde os

modelos são obtidos a partir de dados experimentais como: vibração, vazão total, torque e elevação, recompilados diretamente da resposta do sistema, e com o objetivo de obter modelos mais representativos ao sistema se estimaram os parâmetros ocultos da máquina de aprendizagem mediante um algoritmo genético.

1.2 Motivação e contextualização

Em alguns sistemas de produção de óleo e gás são frequentemente empregados diversos métodos de elevação artificial os quais garantem a manutenção do escoamento de óleo em todo o processo de produção, diminuindo as perdas de carga e mantendo os níveis de produção do poço. O bombeamento centrífugo submerso é um dos métodos de elevação artificial, onde são empregadas bombas centrífugas em regime de escoamento multifásico posicionadas no final do tubo de produção e seu acionamento é feito por um motor elétrico trifásico. Este método é empregado em poços com fluídos de alta viscosidade e que produzem altas vazões, com alto conteúdo de água a baixa razão de gás – óleo, já que para garantir a eficiência da bomba, escolhe-se um ponto de operação onde a porcentagem de gás nesta não seja superior a 10% de gás livre (vazio). Superar este nível de gás pode causar parada de bombeamento devido ao fenômeno chamado de *gas lock,* efeito considerado como uma das principais limitações do BCS (PARDO 2013). Se forem conhecidas de alguma forma as condições do bombeamento multifásico (porcentagem de gás no escoamento), pode-se alterar o seu ponto de operação para outra velocidade de rotação mais favorável evitando assim este efeito.

Conhecendo esta limitação do sistema, poderia ser interessante desenvolver um modelo baseado nas leis que regem o sistema para identificar de alguma forma a condição de escoamento. Entretanto, conforme mencionado, em poucas situações práticas no poço haverá tempo e conhecimento suficientes para desenvolver um modelo de identificação de gás a partir das equações que regem a física do conteúdo de gás no sistema BCS. Por outro lado, sabe-se que estão disponíveis em tempo real os sinais de entrada e de saída do sistema, fornecendo uma alternativa de se obter um modelo que identifique a vazão de gás na BCS de forma aproximada, possibilitando a alteração para um ponto de operação em tempo real seguro, evitando assim o *gas lock* (SOUZA, 2010).

Desta forma surgiu a motivação deste projeto que é realizar um modelo do sistema BCS através de aprendizagem de máquina que permita a identificação experimental da vazão de gás em uma bomba centrífuga operando em regime de escoamento multifásico, identificando assim as relações entre os diferentes dados característicos do sistema, ou seja, do regime vibratório da carcaça da bomba, com a vazão de gás.

1.3 Proposta de trabalho

Obter um modelo que permita identificar a vazão de gás em uma bomba centrífuga operando em regime de escoamento multifásico, baseado em dados reais de sinais do sistema que descrevam o comportamento da vazão de gás na planta em interesse. Para projetar e garantir que o modelo seja robusto e adequado para o sistema, realizar-se-á uma identificação *off-line*, ou seja, primeiro será feito a aquisição de dados característicos do sistema e posteriormente, realizar-se-á um ajuste do modelo, empregando para isso todo o conjunto de dados. Com este procedimento se pode obter um modelo mais preciso e confiável para a convergência da vazão de gás estimada e a vazão real do sistema (RESENDIZ, 2006).

1.4 Objetivo

O objetivo geral do trabalho é obter um modelo não paramétrico pelo método de aprendizagem de máquina de vetor de suporte (SVM), o qual a partir de dados experimentais identifique a vazão de gás na mistura líquido – gás, sendo bombeada através de uma bomba centrífuga em regime de escoamento multifásico.

1.4.1 Atividades da pesquisa

Para alcançar o objetivo deste trabalho, foram definidas as seguintes tarefas para assim garantir a identificação do parâmetro de interesse a partir da medição de dados experimentais que descrevam o comportamento da vazão de gás no sistema:

- Realizar os experimentos sobre o sistema BCS em estudo para obter os dados de entrada – saída do sistema.
- Estabelecer quais são os dados experimentais que proporcionam maior informação da variação da vazão de gás na bomba e elaborar uma base de dados.

- Desenvolver um modelo não paramétrico a partir da base de dados experimental obtida, aplicando algoritmos de aprendizagem de máquina empregando o método de máquinas de vetor de suporte (SVM).

- Obter os estados ocultos do SVM mediante o ajuste dos parâmetros do algoritmo SVM, por meio de algoritmos genéticos,.

- Estimar diversos modelos com diferentes parâmetros de entrada e comparar os modelos obtidos para apresentar o modelo com melhor desempenho.

1.5 Organização da dissertação

O conteúdo deste trabalho se encontra distribuído em seis capítulos. No capítulo um se apresenta a introdução, a motivação e os objetivos da pesquisa. No capítulo dois se apresenta a revisão bibliográfica dos sistemas de identificação e aprendizagem de máquinas, abordando os conceitos principais a serem tratados neste trabalho como: bomba centrifuga submersa, modelagem e identificação de sistemas e máquina de aprendizagem por vetores de suporte. No capítulo três se apresenta os fundamentos teóricos da aprendizagem de máquina por vetores de suporte para classificação e regressão e os conceitos de algoritmos genéticos. No capítulo quatro se apresenta a metodologia adotada para o desenvolvimento desta pesquisa, mostrando em detalhe cada um dos procedimentos seguidos para a obtenção do modelo que identifica a vazão de gás na mistura líquido – gás da bomba centrífuga. No capítulo cinco se mostram os exemplos de simulação que avaliaram o desempenho da metodologia proposta, além de mostrar os resultados e análises dos modelos obtidos através dos dados reais experimentais. Finalmente no capítulo seis se apresentam as conclusões e as sugestões para trabalhos futuros.

Capítulo 2. Revisão Bibliográfica

Este capítulo é dividido em três seções. Na primeira seção são explicados os conceitos básicos sobre as bombas centrífugas submersas, que é o sistema a ser identificado. Na segunda seção são apresentados os conceitos básicos de modelagem e identificação de parâmetros com sua respectiva revisão bibliográfica. Na terceira seção é exposta uma revisão sobre a aprendizagem de máquinas focada nas máquinas de vetores de suporte (SVM).

1.6 Bomba centrífuga submersa

As bombas centrífugas são máquinas hidráulicas que convertem a energia mecânica vindo do motor elétrico em energia cinética do fluido, cujo princípio de funcionamento é de tipo dinâmico e sua finalidade é poder transportar o fluido de um ponto a outro (MONTE, 2011).

Consequentemente estas bombas são empregadas na elevação artificial de petróleo. Neste tipo de bombeamento, a energia elétrica é transmitida para o fundo do poço através de um cabo elétrico e esta energia elétrica é transformada em energia mecânica através de um motor, o qual está diretamente conectado, por um selo mecânico a uma bomba centrífuga de múltiplos estágios.

Cada estágio da bomba é constituído por duas partes: o rotor e o difusor. O rotor gira a altas rotações proporcionando uma velocidade elevada de saída ao fluido e o difusor pelo princípio de conservação de energia (transformação de energia cinética em potencial) desacelera o fluido e força o retorno do fluido ao centro da bomba aumentando a pressão deste, o qual possibilita que o fluido seja elevado até a superfície.

O bom funcionamento destas bombas depende muito das propriedades dinâmicas do fluido como densidade e viscosidade, mas o desempenho da bomba não pode ser definido só com estas propriedades, portanto são adotadas simplificações como a velocidade do escoamento média e a obtenção de uma relação entre a altura de elevação e a vazão (Equação de Euler). Mas como o comportamento do escoamento no interior de uma bomba centrífuga submersa (BCS) não apresenta um comportamento linear, como é proposto na

equação de Euler, então se apresentam diversas perdas na BCS, como por exemplo, perdas por fricção causadas pela presença do gás e no pior dos casos resulta numa parada não programada na BCS por quebra devido à bomba ter trabalhado em condições de grande porcentagem de gás no escoamento (MIRANDA, 2013).

1.7 Modelagem e identificação de sistemas

Os modelos que representam o comportamento de aprendizagem do ser humano são formados por observação e experiência permitindo ao ser humano obter conhecimento do comportamento dos sistemas de interesse. Com base nisso, através da história, se vêm desenvolvendo procedimentos que permitam alcançar modelos mediante relações matemáticas que descrevam o funcionamento de muitos sistemas reais o qual é muito útil para o conhecimento e análise dos sistemas (AGUIRRE, 2000).

Quando é necessário reconhecer o comportamento de um sistema em uma determinada condição e com certas entradas, se pode realizar uma série de experimentos sobre o sistema, obtendo o comportamento de cada uma de suas saídas, mediante um modelo que represente o comportamento do sistema físico.

Há duas maneiras de abordar a construção de um modelo: obter o modelo mediante princípios e leis físicas que descrevam a dinâmica do sistema (modelos paramétricos), ou mediante experimentos sobre o processo a ser modelado (modelos não paramétricos) (RODRÍGUEZ, 2005).

Os modelos paramétricos estão compostos por uma série de parâmetros, os quais devem ser ajustados, e nos modelos não paramétricos os modelos não têm parâmetros, ou seja, estão compostos por um conjunto de dados com informações que definem a dinâmica do sistema.

1.7.1 Identificação de sistemas

A identificação de sistemas é uma ferramenta utilizada para obter modelos matemáticos aproximados a partir de um conjunto de dados coletados do sistema de interesse.

Para fazer a identificação de sistemas se deve seguir o seguinte procedimento:

- Primeiro se deve excitar o sistema mediante um sinal de entrada e registrar a saída do sistema durante um intervalo de tempo e desta maneira se obtém os dados de entrada e saída do sistema. Os dados obtidos são pós-processados com a finalidade de corrigir os dados, isto é, remover os ruídos indesejados do sinal, facilitando assim a identificação do sistema.
- Posteriormente se faz a escolha do modelo, que deve ser feita a partir de um conhecimento prévio do funcionamento do processo. Dependendo se conhecemos muito ou pouco do sistema escolheremos entre um modelo de caixa branca, ou um modelo de caixa preta, ou um modelo de caixa cinza (BRAUN, 2001).

Os modelos de caixa branca são obtidos a partir de leis físicas, e para isso é necessário conhecer bem o sistema. Os modelos de caixa preta são obtidos a partir de dados experimentais e para isto pode-se ter pouco ou nenhum conhecimento prévio do sistema. Os modelos de caixa cinza são obtidos mediante leis físicas, o ajuste é feito mediante dados experimentais e se caracteriza por empregar informação auxiliar, que não se encontra no conjunto de dados de identificação.

Depois se faz uma seleção do critério de estimação e se obtém os parâmetros do modelo. Nesta parte se faz uma seleção dos parâmetros que melhor ajustam a resposta do modelo com respeito aos dados de entrada – saída obtidos experimentalmente.

Por último se valida o modelo com o objetivo de determinar se o modelo obtido satisfaz o grau de exatidão requerido (LJUNG, 1999).

1.7.2 Revisão bibliográfica de identificação de sistemas.

O desenvolvimento da identificação surgiu do estudo da teoria de estimação de parâmetros proposta por Gauss em 1809 e por Fisher em 1912. Com base nisso, durante o período de 1920 – 1970 foram desenvolvidas a teoria de processos estocásticos estacionários e a teoria de identificação, tudo isto feito mediante os estudos estatísticos de séries de tempo. Em 1965 foi o começo da identificação paramétrica de sistemas dinâmicos lineares a partir de dados de entrada – saída proposta por (KALMAN, 1965), e em 1967 o senhores Astrom e Bohlim deram origem à técnica de identificação de sistemas em tempo

discreto a partir de dados de entrada – saída, tudo com o propósito de desenhar estratégias de controle de sistemas (ASTROM, 1966), dando um passo ao que hoje em dia se conhece como identificação em subespaços e identificação mediante a predição do erro (GEVERS, 2006). Em 1970 é desenvolvida a metodologia de como realizar a identificação de sistemas por Box e Jenkins, que é empregada ate o dia de hoje (BOX, 1970).

Na década de setenta se considerou pela primeira vez a identificação de sistemas como uma aproximação do sistema real, e por isto nesta década foram desenvolvidos diversos trabalhos com este objetivo, ou seja, desenvolver modelos de aproximação de sistemas (ANDERSON, HAWKES, 1978).

Na década de oitenta os trabalhos feitos têm como objetivo estimar os melhores critérios para realizar a identificação de um sistema, isto com o objetivo de obter um modelo de boa qualidade. Vários trabalhos foram desenvolvidos com este objetivo onde os critérios estimados foram: as condições experimentais, a seleção do tipo de estrutura do modelo e o critério de seleção. A metodologia de trabalho da identificação de sistemas mudou (LJUNG, 1999) e na década de noventa se consideraram novas áreas de interesse como a identificação no domínio da frequência dando um passo à identificação não paramétrica que atualmente é muito empregada e cada dia se emprega mais metodologias que permitam obter modelos mais aproximados ao sistema real e de forma autônoma.

1.8 Aprendizagem de máquina

A aprendizagem de máquina é uma área da inteligência artificial que envolve diversas técnicas computacionais que visam ampliar a automatização e eficiência de processos de aquisição de conhecimento por meio de um computador, a partir de transmissão de informação ou processamento de dados. Seu objetivo principal é descobrir o relacionamento entre as variáveis do sistema (entrada / saída) a partir de amostras (DIETTERICH, 1986).

Existem diferentes subcampos de aprendizado de máquina como: aprendizado supervisionado, aprendizado por reforço e aprendizado não supervisionado. A aprendizagem supervisionada está composta por um conjunto de dados de treinamento que refletem o mapeamento funcional da entrada para a saída, um espaço de hipóteses que são

funções candidatas e um algoritmo de aprendizado que recebe o conjunto de dados de treinamento como argumento e seleciona a hipótese a partir do espaço de hipóteses. Alguns exemplos de aprendizagem supervisionados são as redes neurais e as máquinas de vetores de suporte (ANDREW, 2012).

Entre as múltiplas aplicações de aprendizagem de máquinas que existem está a identificação de sistemas, onde as máquinas de vetores de suporte se destacam por mostrar altos níveis de eficiência em comparação aos outros métodos de aprendizagem (RYCHETSKY, 2001).

O desenvolvimento das máquinas de vetores de suporte (SVM pelas siglas em inglês, *"Support Vector Machine"*) teve início desde meados de 1990 onde foi desenvolvido como um método empregado no âmbito de aprendizagem de máquina, que foi introduzido pela primeira vez pelo senhor Vanking como solução para o problema de classificação (VANKING, 1995), mas a SVM atual para o problema de regressão foi desenvolvida pelo laboratório de AT&T por Vaptnik (VAPTNIK, 1997).

Nos últimos anos estes dois métodos tem demonstrado excelentes resultados em diversos problemas tanto de classificação como de regressão. Por isto a SVM, como ferramenta de identificação de sistemas não lineares, é cada dia mais popular devido principalmente à SVM estar baseada no princípio de minimização de risco estrutural. Este princípio foi proposto também pelo senhor Vanking, que é originado da teoria de aprendizagem estatística, o qual tem demonstrado ter melhores resultados que o princípio de minimização de risco empírico empregado em redes neurais.

Estes bons resultados se devem a que este princípio não padece de mínimos locais e o modelo só depende dos dados com mais informação denominados vetores de suporte. O objetivo principal da SVM é resolver um problema quadrático onde o número de coeficientes é igual ao número de dados de treinamento. Mas quando se tem grandes quantidades de dados, resolver o problema quadrático tem um custo computacional muito alto, que é o maior problema da SVM. Na maioria dos casos que apresentam esta situação, a identificação de sistemas não lineares se realiza de modo off–line.

Na literatura existem algumas técnicas para aplicar a SVM na identificação de sistemas de modo on-line, com os quais se melhora o tempo e o custo computacional. Algumas das possíveis soluções são: decompor o problema em problemas mais simples (OSUMA, 1997), (COLLOBERT, 2001); empregar métodos de otimização, como otimização mínima sequencial (SMO), (PLATT, 2000); e propor algoritmos recursivos para o treinamento da SVM (MARTIN, 2002).

Devido ao crescimento das aplicações das SVM em diferentes espaços de pesquisa, das novas metodologias desenvolvidas com o objetivo de obter um melhor funcionamento e desempenho das SVM e dos bons resultados apresentados por este método, realizar-se-á neste projeto uma implementação da SVM para a identificação da vazão de gás numa BCS de modo off-line.

Capítulo 3. Fundamentos Teóricos

Neste capítulo se apresentam os conceitos teóricos referentes ao estudo do sistema de aprendizagem de máquina empregado para o desenvolvimento deste projeto. Este capítulo esta dividido em duas seções, na primeira seção serão descritos os conceitos teóricos de máquina de vetores de suporte e na segunda seção serão apresentados os conceitos básicos de algoritmos genéticos.

1.9 Máquinas de vetores de suporte

As máquinas de vetores de suporte são um sistema de aprendizagem baseada nas ferramentas estatísticas de otimização que buscam minimizar o risco estrutural, para isto é utilizado um espaço hipótese de funções lineares num espaço de maior dimensão induzido por um *kernel,* no qual as hipóteses são treinadas por um algoritmo. Estas transformações podem ser usadas em diversos problemas de aprendizagem, mas são mais empregadas especificamente em problemas de classificação e regressão.

1.9.1 Máquinas de Vetores de suporte para classificação

No caso de classificação o objetivo geral da SVM é achar um hiperplano que separe de forma ótima os dados de cada uma das classes e encontrar os vetores de suporte. O funcionamento geral de uma SVM para o caso de classificação pode ser visualizada pelos seguintes passos: primeiro se considera um problema de n número de classes de dados que são linearmente separáveis; em seguida a SVM realiza um mapeamento de cada um dos dados de entrada; estes são levados a um espaço de maior dimensão; finalmente acha-se um hiperplano que separe os dados e maximize a margem (m) entre as diferentes classes existentes no sistema (NG, 2012).

O problema de maximizar a margem (m) é um problema de otimização que pode ser resolvido por meio de multiplicadores de *Lagrange*. Para achar o hiperplano ótimo pode-se simplesmente realizar um produto escalar entre as funções que caracterizam o espaço, que é mais conhecido como *Kernel*. A SVM também é caracterizada pelos vetores de suporte (VS) que são combinações de alguns pontos de entrada que permitem escrever a solução do hiperplano de uma maneira mais simples (SABZEKAR, 2009).

Para explicar e compreender o comportamento da SVM em diferentes condições se descreve a seguir três casos distintos para classificação. No primeiro caso os dados são linearmente separáveis, no segundo caso os dados não são linearmente separáveis e no terceiro caso o modelo é não linear.

1.9.1.1 Primeiro caso: dados linearmente separáveis

Considerando o seguinte caso de classificação apresentado na Figura 3.1 onde temos duas classes diferentes de dados, que são linearmente separáveis.

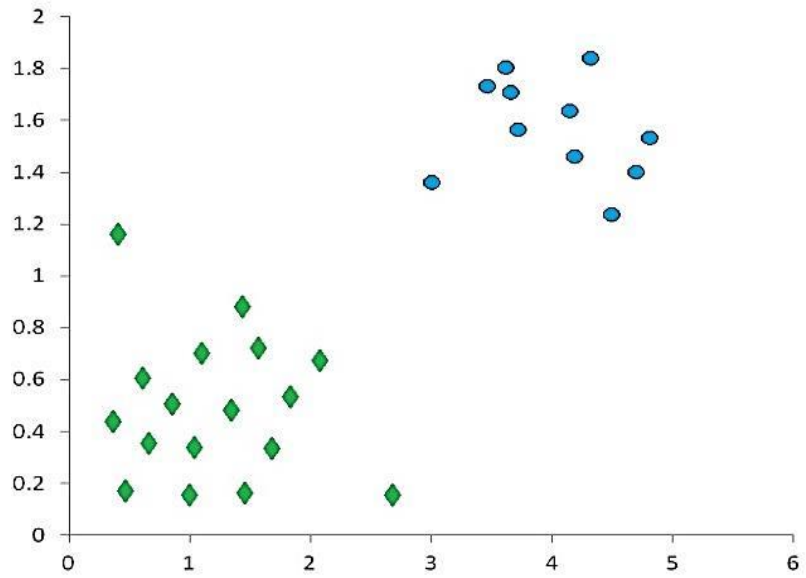

Figura 3.1 Problema de classificação com dados linearmente separáveis.

Para resolver este problema com SVM, consideramos um conjunto de dados de treinamento de N dados compostos por um vetor $x_i \in R^n, i = 1, \dots, l$ e uma etiqueta $y_i \in \{+1, -1\}$, definindo assim o conjunto de treinamento como:

$$\{(x_i, y_i), \cdots, (x_l, y_l)\} \tag{3.1}$$

Um hiperplano que separa as amostras positivas das negativas onde os pontos que se encontram neste hiperplano satisfaz a seguinte equação.

$$w^T x + b = 0 \tag{3.2}$$

onde:

- O vetor w é normal ao hiperplano e é denominado vetor de peso.
- b é o ponto de interseção do hiperplano no eixo y.

Os hiperplanos paralelos ao hiperplano determinado na equação (3.2) são definidos pelas seguintes equações.

$$w^T x + b = 1$$
$$w^T x + b = -1 \qquad (3.3)$$

Na Figura 3.2 se apresenta o comportamento da margem para o problema de classificação por meio de SVM.

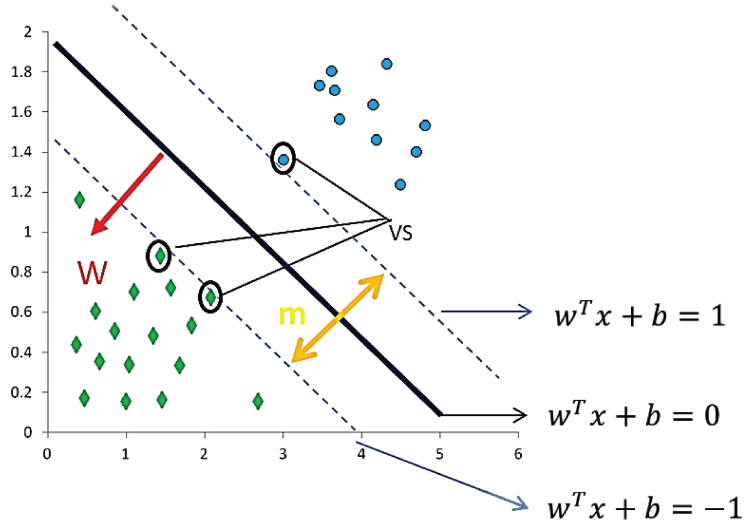

Figura 3.2 Comportamento da margem da SVM.

Para encontrar o melhor hiperplano que separe as duas classes se deve maximizar a margem(m), que é a distância entre os hiperplanos positivo e negativo, onde:

$$m = \frac{2}{\|w\|} \qquad (3.4)$$

O problema da equação (3.4)pode ser definido para o problema de SVM da forma (SMOLA, 2004):

$$\min_{w} \frac{1}{2} \|w\|^2$$
$$\text{Sujeito a } y_i(w^T x_i - b) \geq 1, \forall i = 1 \cdots n \tag{3.5}$$

Para resolver este problema se empregam multiplicadores de Lagrange (α). Esta formulação de Lagrange permite encontrar os máximos e mínimos de uma função de uma ou mais variáveis suscetíveis a uma o mais restrições como é o caso da SVM (Equação (3.5)). Este método permite resolver problemas de otimização, mediante a introdução de uma variável nova (α_i), chamada de multiplicador de Lagrange de tal forma que se construí uma função Lagrangiana tal que:

$$\tilde{L}(\alpha) = \sum_{i=1}^{n} \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j$$
$$\text{Sujeito a } \alpha_i \geq 0 \; e \; \sum_{i=1}^{n} \alpha_i y_i = 0 \tag{3.6}$$

1.9.1.2 Segundo caso: dados não linearmente separáveis

Considerando o mesmo caso de classificação apresentado anteriormente (Figura 3.1) onde temos duas classes diferentes de dados, mas onde os dados de cada classe não podem ser separados linearmente, como se apresenta na Figura 3.3 onde se pode observar que existem alguns dados que não permitem separar linearmente o conjunto de dados.

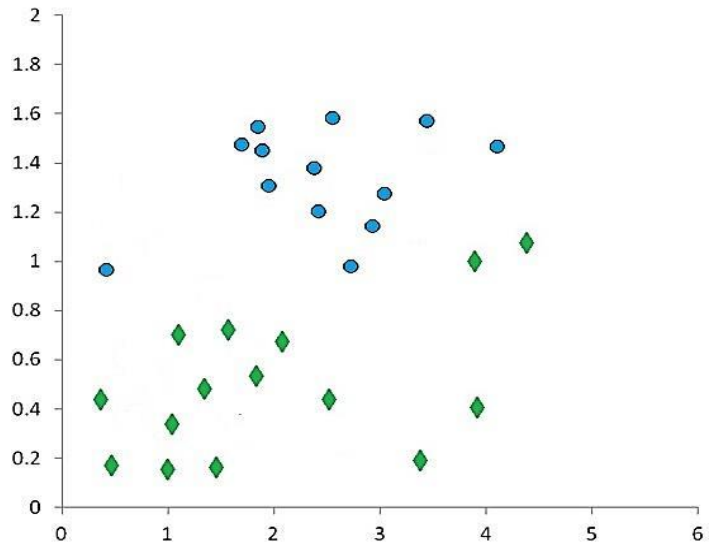

Figura 3.3 Problema de classificação com dados não separáveis linearmente.

Para este tipo de casos a SVM realiza o mesmo procedimento de solução que para o primeiro caso, mas agora se introduzirá um parâmetro a mais que denominaremos de parâmetro C o qual controlará a compensação entre os erros de treinamento e as margens rígidas, criando assim certa flexibilidade na margem da SVM, permitindo alguns erros (ε_i), com as seguintes restrições.

$$\begin{cases} w^T x_i + b \geq 1 - \varepsilon_i & y_i = 1 \\ w^T x_i + b \leq -1 + \varepsilon_i & y_i = -1 \\ \varepsilon_i \geq 0 & \forall_i \end{cases} \tag{3.7}$$

Levando-se em conta que se $\varepsilon_i = 0$ não se apresenta nenhum erro, pode-se definir a função de minimização como:

$$\min_w \frac{1}{2}\|w\|^2 + C\sum_{i=1}^{n} \varepsilon_i$$
$$sujeito\ a \begin{cases} w^T x_i + b \geq 1 - \varepsilon_i & y_i = 1 \\ w^T x_i + b \leq -1 + \varepsilon_i & y_i = -1 \\ \varepsilon_i \geq 0 & \forall_i \end{cases} \tag{3.8}$$

O problema apresentado na equação (3.8) pode ser solucionado utilizando os multiplicadores de *Lagrange* descritas na equação (3.6).

A constante C determinará a precisão da margem flexível, o qual tem influência no desempenho da SVM, já que se C é muito grande pode acontecer problemas de sobre ajuste e se C é muito pequeno pode apresentar problemas de baixo ajuste, como é apresentado na Figura 3.4

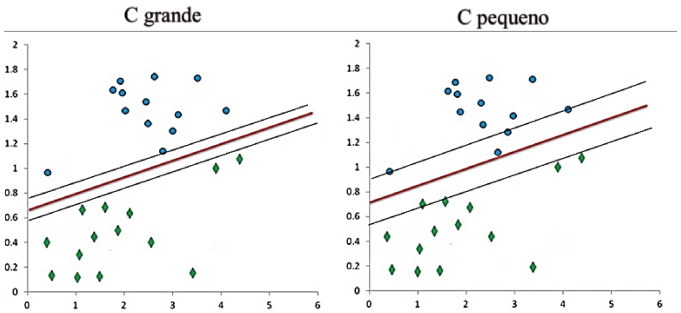

Figura 3.4 Comportamento do parâmetro C

1.9.1.3 Terceiro caso: modelo não linear.

É o caso quando o sistema tem um modelo não linear e onde os dados não podem ser separados linearmente como se apresenta na Figura 3.5. Neste caso é preciso realizar uma mudança de espaço mediante uma função de transformação que aumente a dimensionalidade dos vetores de entrada a um espaço onde se possam separar linearmente por um hiperplano. Esta função é denominada *Kernel.*

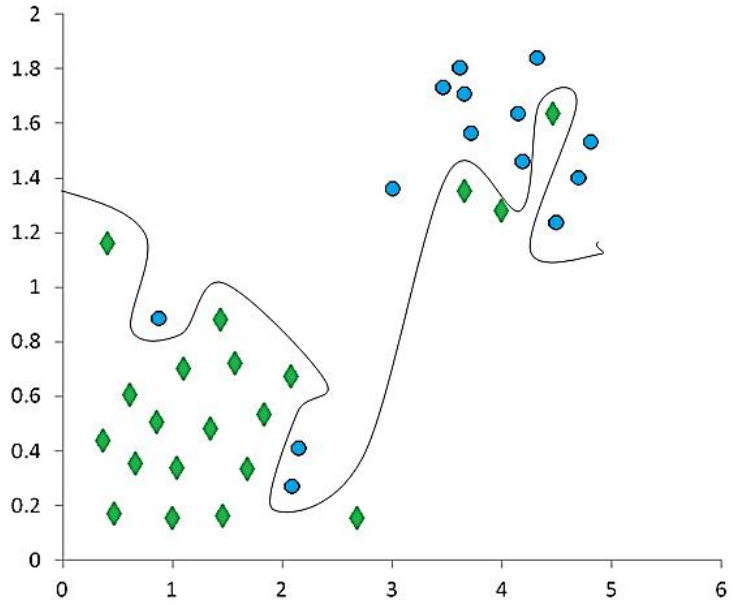

Figura 3.5 Problema de classificação com modelo não linear

Introduzindo o *kernel,* os parâmetros de Lagrange (α) do vetor w passam a ser definidos como:

$$\tilde{L}(\alpha) = \sum_{i=1}^{n} \alpha_i - \frac{1}{2}\sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j = \sum_{i=1}^{n} \alpha_i - \frac{1}{2}\sum_{i,j} \alpha_i \alpha_j y_i y_j k(x_i, x_j) \qquad (3.9)$$

O problema da equação (3.9) é um problema de otimização que pode ser solucionado mediante programação quadrática (GAGO, 2013), obtendo assim.

$$f(x) = \sum_{i=1}^{n} \alpha_i \, y_i k(x_i, x_j) + b, \qquad (3.10)$$

1.9.2 Função *Kernel.*

Em base as limitações computacionais existentes nas máquinas de aprendizagem e com o objetivo de poder dar solução aos problemas com modelos não lineares, se propõe uma solução alternativa por meio da implantação de uma função *kernel* permitindo à máquina de aprendizagem aprender a função objetivo mediante uma mudança da representação da função, isto é, realizar um mapeamento do espaço de entradas a um novo espaço de características $F = \{\emptyset(x,z) \mid x \in X \,\&\, z \in Z\}$ ·:

$$x = \{x_1, x_2, \cdots, x_n\} \rightarrow \emptyset(x) = \{\emptyset(x)_1, \emptyset(x)_2, \cdots \emptyset(x)_n\}$$
$$z = \{z_1, z_2, \cdots, z_n\} \rightarrow \emptyset(z) = \{\emptyset(z)_1, \emptyset(z)_2, \cdots \emptyset(z)_n\} \qquad (3.11)$$

onde para todo $x \in X$ existe um $\emptyset$ que mapeia todas as entradas (X) e para todo $z \in Z$ existe um $\emptyset$ que mapeia todas as entradas (Z) no espaço de caraterísticas F de maneira implícita, além de treinar a máquina de aprendizagem (SVM). Na Figura 3.6 se apresenta o funcionamento do mapeamento realizado pelo *Kernel.*

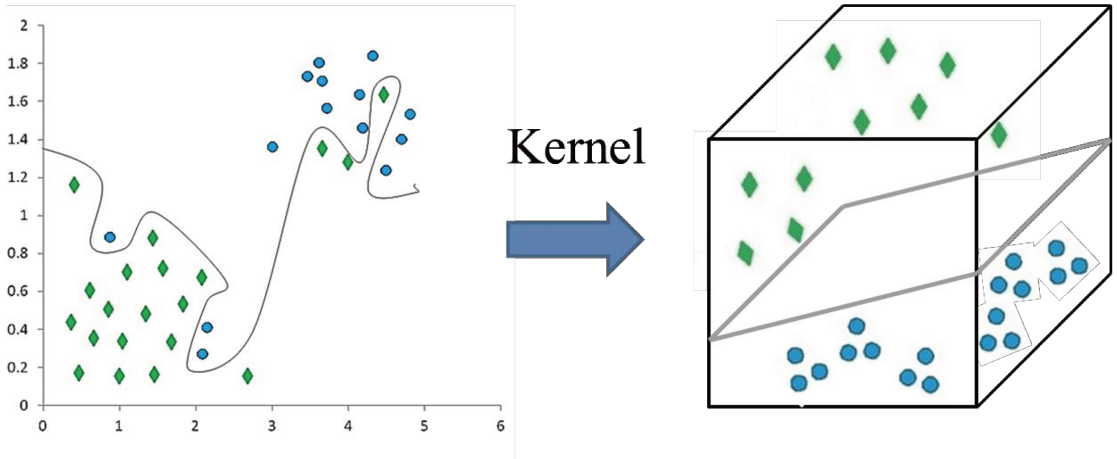

Figura 3.6 Funcionamento do *Kernel*

Para realizar o treinamento da máquina de aprendizagem só é preciso ter a matriz do *Kernel* a qual denotaremos com a letra (K).

$$K(x,z) = \langle \emptyset(x)_i \cdot \emptyset(z)_j \rangle_{i,j=1}^{n} \qquad (3.12)$$

onde (x, z) são as entradas e $\left(\emptyset_i(x), \emptyset_j(z)\right)$ são o espaço de características.

Uma vez definida a matriz K, a hipótese pode ser calculada avaliando ao menos n vezes a matriz K como se indica na seguinte equação:

$$f(x) = \sum_{i=1}^{n} \alpha_i y_i K\left(x_i, x_j\right) + b \tag{3.13}$$

Algumas das propriedades e das condições que devem cumprir a função *Kernel* para definir o espaço de características são:

1. Simetria

$$K(x, z) = \langle \emptyset(x) \cdot \emptyset(z) \rangle = \langle \emptyset(z) \cdot \emptyset(x) \rangle = \sum_{i=1}^{n} \emptyset_i(x) \emptyset_i(z) = K(z, x) \tag{3.14}$$

2. Desigualdade de Cauchy – Schwarz

$$\begin{aligned} K(x, z)^2 = \langle \emptyset(x) \cdot \emptyset(z) \rangle^2 &\leq \|\emptyset(x)\|^2 \|\emptyset(z)\|^2 \\ &= \langle \emptyset(x) \cdot \emptyset(x) \rangle \langle \emptyset(z) \cdot \emptyset(z) \rangle = K(x, x) K(z, z) \end{aligned} \tag{3.15}$$

onde $\| \, . \, \|^2$é a norma Euclidiana.

3. Teorema de Mercer

   Seja X um subconjunto compacto de $\mathbb{R}^n$. Seja K uma função simétrica contínua tal que o operador $T_K: L_2(X) \to L_2(X)$

$$(T_K f)(\cdot) = \int_X K(\cdot, x) f(x) dx \tag{3.16}$$

   é positivo, isto é:

$$\int_{X \times X} K(x, z) f(x) f(z) dx dz \geq 0 \ , \qquad \forall f \in L_2(X) \tag{3.17}$$

   onde L_2 é a norma euclidiana definida como: $\|x\|_2 = \sqrt{\sum_{i=1}^{n} |x_i|^2}$.

A partir disto se pode expandir $K(x,z)$ em uma série com convergência uniforme sobre $X \times X$ em termos de T_K, funções próprias $\emptyset_j \in L_2(X)$, normalizando de tal forma que $\|\emptyset_i\|_{L_2} = 1$ isto é que tenha norma L_2 finita, e os valores próprios associados positivos $\lambda_i \geq 0$

$$K(x,z) = \sum_{i=1}^{\infty} \lambda_i \emptyset_i(x) \emptyset_i(z) \tag{3.18}$$

A seguir se mostram alguns dos diferentes tipos de Kernel existentes:

- Kernel Linear

$$K(x,z) = \langle A_x \cdot A_z \rangle = x^T A^T A_Z = x^T B_z \tag{3.19}$$

Onde $B = A^T A$ é uma matriz semi - definida positiva.

- Kernel Polinomial

$$K(x,z) = (\langle x,z \rangle + 1)^p \tag{3.20}$$

onde o parâmetro a estimar é p.

- Kernel Gaussiano

$$K(x,z) = \exp\left(-\frac{\|x-z\|^2}{2\sigma^2}\right) \tag{3.21}$$

onde o parâmetro a estimar é σ^2

- Kernel Rede Neural

$$K(x,z) = tanh(k_1 \langle x,z \rangle + k_2) \tag{3.22}$$

onde os parâmetros a estimar são k_1 e k_2

1.9.3 Máquinas de Vetores de suporte para regressão

As máquinas de vetores de suporte para regressão têm como objetivo encontrar uma função $f(x)$ que tenha um desvio mínimo (ε) com respeito à saída y_i de cada um dos dados de treinamento. Por isto para o desenvolvimento deste trabalho se utilizou uma

máquina de vetores de suporte para regressão (SVMR). A seguir se explica com mais detalhe o funcionamento da SMVR, mediante um exemplo similar ao apresentado na seção 1.9.1. (ZHANG, 2013)

Considerando um problema de aproximação de dados, aonde se tem um conjunto de dados de treinamento $\{x_i, y_i\}$ onde $x \epsilon \mathbb{R}^n$ e $y \in \mathbb{R}$, que são os dados a serem aproximados mediante uma função linear $f(x)$ e cujo objetivo é encontrar o vetor de pesos mínimo (STONEAN, 2006).

$$\begin{aligned} f(x) &= \langle w \cdot x \rangle + b \\ &= x^T w + b \\ &= \sum_{i=1}^{n} w_i x_i + b \end{aligned} \tag{3.23}$$

onde: O conjunto de dados de treinamento são $x = \{x_1, x_2, \cdots, x_n\}$ e $y = \{y_1, y_2, \cdots, y_n\}$, o vetor de peso é $w = \{w_1, w_2, \cdots w_n\}$, e b é o número de bias.

Para garantir o objetivo deste problema se deve minimizar o vetor w pela norma Euclidiana $\|w\|^2$. Definindo assim o problema de otimização como:

$$\min_{w} \frac{1}{2} \|w\|^2 \tag{3.24}$$

Sujeito as seguintes condições:

$$|y_i - (\langle w \cdot x_i \rangle + b)| \leq \varepsilon, \qquad i = 1,2, \cdots m \tag{3.25}$$

ou

$$\begin{cases} y_i - (\langle w \cdot x_i \rangle + b) \leq \varepsilon \\ y_i - (\langle w \cdot x_i \rangle + b) \geq -\varepsilon \end{cases} \tag{3.26}$$

Igualmente ao caso de SVM para classificação, pode acontecer que a função $f(x)$ linear, não seja capaz de ajustar todos os dados de treinamento, daí que a SVMR pode admitir alguns erros (ξ_i e ξ_i^*) sujeitos as seguintes condições de aproximação:

$$\begin{cases} y_i - \langle w \cdot x_i \rangle + b \leq \varepsilon + \xi_i \\ y_i - (\langle w \cdot x_i \rangle + b) \geq -\varepsilon + \xi_i^* \end{cases} \tag{3.27}$$

Também é introduzido o parâmetro C que indica a penalidade dos erros e a minimização dos erros é feita mediante a soma de cada um dos indicadores de erro.

$$C\sum_{i=1}^{n}(\xi_i + \xi_i^*) \tag{3.28}$$

Finalmente o problema da SVMR pode ser descrito pela equação (3.29), onde se deve encontrar w e b de modo que se minimize w (STOEAN, 2006):

$$\begin{gathered}\min_{w}\frac{1}{2}\|w\|^2 + C\sum_{i=1}^{n}(\xi_i + \xi_i^*)\\ Sujeito\ a\begin{cases} y_i - \langle w\cdot x_i\rangle + b \leq \varepsilon + \xi_i \\ y_i - (\langle w\cdot x_i\rangle + b) \geq -\varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0\end{cases}\end{gathered} \tag{3.29}$$

No caso que o sistema seja não linear se deve realizar um mapeamento dos dados de treinamento $(x \in X)$, ao espaço de maior dimensão F através de um mapeamento não linear $\emptyset: X \to F$, onde se possa realizar uma regressão linear. O procedimento é igual ao apresentado na seção 1.9.1.3 e o *kernel* é definido de igual forma ao da seção 3.1.2.

Com o objetivo de exibir o comportamento de cada um dos parâmetros da SVMR para um problema não linear se considera o seguinte exemplo. Na Figura 3.7 se apresenta um problema onde o modelo é não linear.

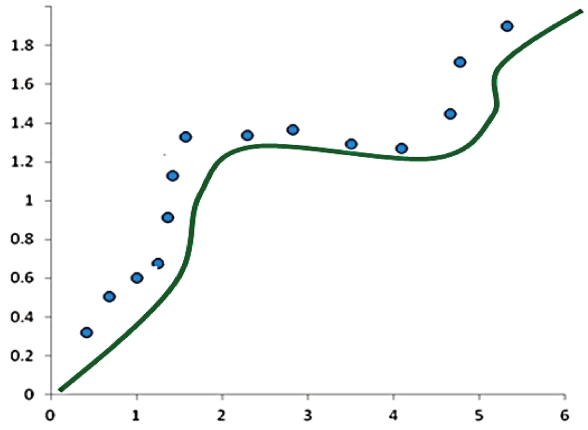

Figura 3.7 SVMR para um sistema com modelo não linear

Como se observa na Figura 3.7 temos um sistema não linear onde a SVMR deve realizar um mapeamento de cada um dos dados com a finalidade de estimar a saída do sistema para cada um dos dados de treinamento.

Como o sistema é não linear, o mapeamento deve ser feito em um espaço de maior dimensão. Para este caso o aumento da dimensão do espaço de mapeamento se realiza mediante um *Kernel* de tipo gaussiano, no qual estimamos o parâmetro σ^2 que determinará a largura da gaussiana (equação (3.21)). Na Figura 3.8 se amostra a transformação do espaço de mapeamento e o *Kernel*. Obtém-se portanto, a regressão linear do sistema notando que os dados que contém maiores informações são os que geram o regressor denominado vetores de suporte.

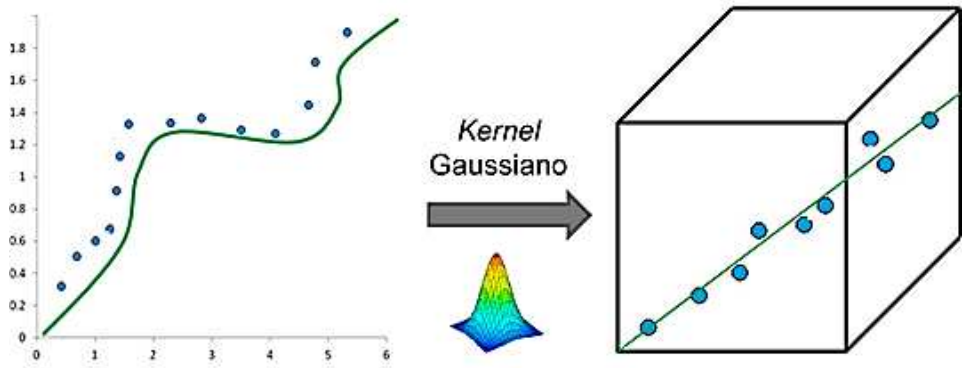

Figura 3.8 Aumento do espaço de mapeamento de entradas.

1.10 Algoritmos genéticos

Os algoritmos genéticos são outro avanço da inteligência artificial onde se tenta realizar uma replica do comportamentobiológico mediante técnicas computacionais. Estes algoritmos são inspirados na forma como os seres vivos sobrevivem e passa seu material genético de geração em geração, onde os únicos indivíduos que sobrevivem são os mais fortes e onde os princípios de seleção estão baseados nos postulados de Darwin (SMITH, 2002).

Por semelhança a este processo natural, os algoritmos genéticos são capazes de dar solução a diversos problemas do mundo real, onde a evolução destas soluções depende da realização de uma adequada codificação.

Os princípios básicos dos algoritmos genéticos foram estabelecidos por Holland (1975) (HOLLAND, 1975) o qual tinha dois objetivos. O primeiro foi explicar detalhadamente o processo adaptativo dos sistemas e o segundo foi desenhar um sistema artificial que mantinha as estruturas mais significativas dos sistemas evolutivos dos sistemas naturais. Mas foi em 1967 que este algoritmo recebeu o nome de algoritmo genético com o trabalho de Bagley (BAGLEY, 1967). Com base nestes trabalhos e a partir daí foram desenvolvidos diversas aplicações com algoritmos genéticos mais sofisticados (GOLDBERG, 1989).

1.10.1 Estrutura de um algoritmo genético

Antes de realizar a explicação da estrutura básica de um algoritmo genético se comentará brevemente o processo biológico adaptativo dos organismos vivos. Todos os organismos estão compostos por uma ou mais células e cada uma delas possui um ou mais cromossomos, ou seja, moléculas de DNA que contêm as instruções genéticas dos organismos. Um cromossomo pode se dividir em genes que são blocos funcionais de DNA que codificam uma proteína. Os genes são os que determinam os traços característicos dos indivíduos que são hereditários.

Toda a informação hereditária de um organismo se encontra no genoma. A partir do genoma se pode definir o genótipo, que é o conjunto de genes que contém um genoma. O genótipo da lugar ao fenótipo que são as características observáveis de um organismo, cujo nível de sobrevivência dependerá da avaliação e adaptação do genótipo.

A maioria dos organismos que se reproduzem sexualmente conservam seus cromossomos por pares, que são recombinados ou cruzados no processo de reprodução sexual, gerando assim uma nova descendência que está sujeita a mutações, que são modificações nos cromossomas causados por erros de cópia.

A estrutura e aplicação dos conceitos anteriores no caso o término do cromossoma, se refere à estrutura de dados que representa uma possível solução para o problema. Para garantir o bom funcionamento do algoritmo genético (AG) é preciso primeiro decidir como os cromossomos ou indivíduos serão codificados (CHAPMAN, 1994).

Os indivíduos podem se codificar de várias formas, mediante zeros e uns, mediante números reais ou mediante números inteiros. Neste trabalho se utilizará uma série binária de b bits, onde cada bit da série representa os genes que são as características da solução. Por exemplo, a representação do cromossoma pode ser 01101. A partir desta codificação se explicará a estrutura do AG.

Tendo claro como se representa cada cromossomo se deve criar uma população inicial aleatória de indivíduos $\left(P(t)\right)$ de M tiras binárias. A avaliação do desempenho para cada indivíduo é feita mediante uma função objetivo ou função *Fitness*, que é definida a partir dos parâmetros envolvidos no problema específico e cujo objetivo será calcular a probabilidade de seleção de cada indivíduo, gerando assim novas populações com indivíduos evoluídos, cujo critério de parada é o número de gerações.

Os operadores genéticos básicos são: seleção, crossover e a mutação.

Para o processo de recombinação é necessário selecionar os pais dos indivíduos que formarão a nova geração. Esta seleção permite orientar a procura dos pontos mais promissores, ou seja, que garante a seleção dos indivíduos com maior adaptação ao problema. O operador de seleção não produz novos indivíduos, só determina que indivíduos serão reproduzidos deixando filhos e em que quantidade.

Existem vários mecanismos de seleção entre os quais temos: seleção proporcional, elitista, aleatória, por diversidade, bi-classista, por torneio, Steady-Sate, por Ranking e a seleção baseada em pesos ou de roleta (Roulette Wheel) que é a mais utilizada.

No método de roleta a cada cromossomo é atribuído uma probabilidade de seleção que é proporcional ao seu índice de aptidão, onde os cromossomas ou indivíduos com maior índice ocuparão uma maior porcentagem dos que aqueles indivíduos com menor índice. A roleta é girada conforme o tamanho da população.

O crossover ou operador de recombinação é um dos operadores mais importantes dos algoritmos genéticos, já que este troca o material genético ou genes entre dois membros (pais) produzindo novos descendentes (filhos).

Existem várias formas de fazer o crossover entre as quais temos o crossover uniforme, crossover simples e o crossover duplo. O crossover uniforme possui um número variável de pontos de cruzamento. O crossover simples possui um ponto de cruzamento escolhido de forma aleatório e o crossover duplo possui dois pontos de cruzamento.

A seguir é explicado o funcionamento do crossover simples. Tendo um par de pais p e q representados por l bits, se escolhe aleatoriamente um ponto $k \in \{1, \cdots, l-1\}$ e a partir deste ponto se trocam os bits da direita dessa posição entre os dois indivíduos, obtendo os descendentes s e v, como se mostra a seguir:

$$\begin{array}{ll} \vec{p} = (p_1, \cdots, p_{k-1}, p_k, \cdots, p_l) & \vec{s} = (p_1, \cdots, p_{k-1}, q_k, \cdots, q_l) \\ \vec{q} = (q_1, \cdots, q_{k-1}, q_k, \cdots, q_l) & \vec{v} = (q_1, \cdots, q_{k-1}, p_k, \cdots, p_l) \end{array} \tag{3.30}$$

A mutação é realizada com o objetivo de alterar a informação genética dos indivíduos a fim de garantir a diversidade, prevenindo que todas as soluções estejam em um só ponto local. O papel da mutação é secundário no algoritmo genético já que só troca ocasionalmente um bit de alguns indivíduos selecionados aleatoriamente.

Existem diversas formas de realizar a mutação, uma delas é definindo uma taxa ou percentagem de mutação que decidirá se o gene é modificado ou não. No caso em que o indivíduo seja selecionado se modificará um bit do gene. Por exemplo, no caso de codificações binárias se o gene é 0 será trocado para 1. A taxa não deve ser nem alta nem baixa, só tem que ter um valor onde se garanta a diversidade dos cromossomos.

Capítulo 4. Modelo de identificação de vazão de gás

Neste capítulo se apresentam os procedimentos feitos para obter um modelo de identificação da vazão de gás numa bomba centrífuga submersa operando com escoamento bifásico gás – líquido, a partir de dados experimentais obtidos diretamente do sistema a identificar.

Deve-se levar em conta que o modelo desenvolvido para este determinado sistema será uma representação experimental aproximada de apenas algumas características do sistema real, mas que permite obter um conhecimento sobre a dinâmica do comportamento da vazão de gás numa BCS. Para o desenvolvimento deste modelo foram empregadas várias atividades as quais são explicadas com maior detalhe a seguir.

1.11 Planejamento dos experimentos

A identificação de sistemas implica fazer experimentações diretamente com o sistema a ser modelado. Por isto é necessário levar em conta que, em geral, é muito custoso realizar experimentos com processos industriais em tempo real. Portanto foi necessário selecionar uma técnica viável do ponto de vista do tipo experimental.

Para a realização dos experimentos e coleta de dados foi empregado uma montagem experimental de um circuito de testes de BCS no laboratório LABPETRO do Centro de Estudos de Petróleo (CEPETRO). Este circuito está dividido em geral por quatro partes. A primeira parte está composta por uma zona de tanques e uma bomba *booster* que controla a pressão na entrada da BCS. A segunda parte esta composta por um motor elétrico, um torquímetro, um sistema de sucção, uma bomba centrífuga submersa (BCS) e um sistema de descarga. A terceira parte está composta por um compressor de ar onde o ar é comprimido e medido antes de ser injetado na BCS. A quarta parte está composta por diferentes tipos de sensores e um sistema de aquisição de dados próprio do laboratório. Na Figura 4.1 se apresenta um diagrama das diferentes partes que compõem o circuito de testes de BCS.

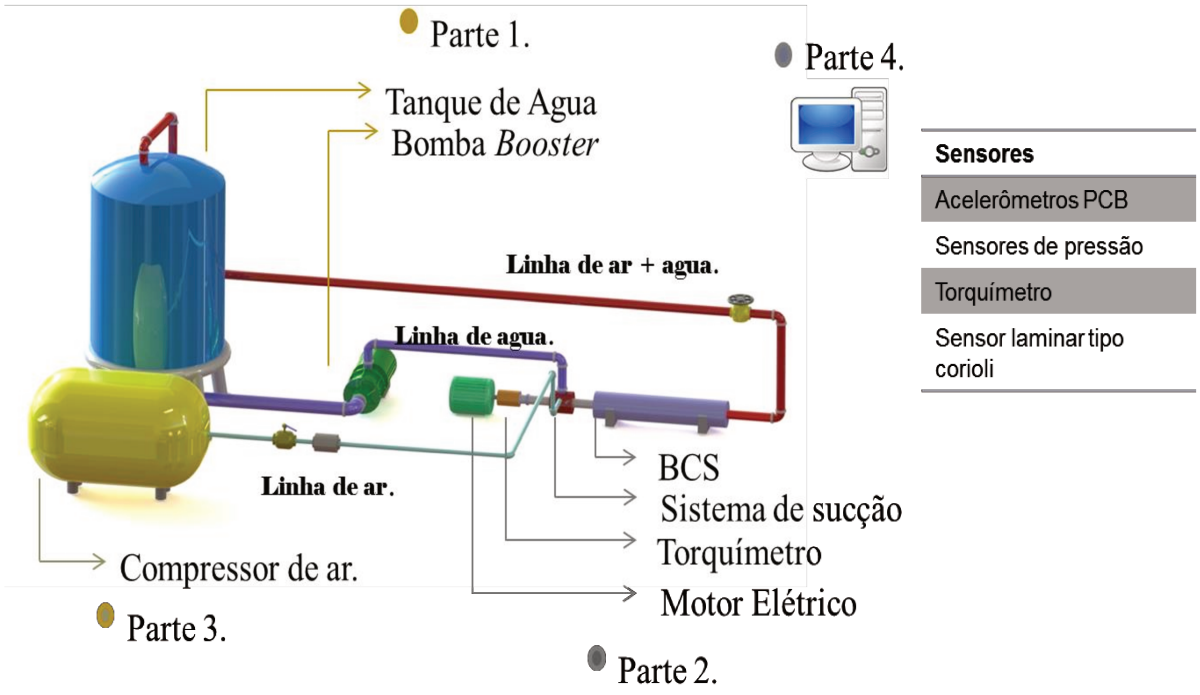

Figura 4.1 Circuito de testes BCS

1.11.1 Instrumentação e sistema de aquisição de dados

Para atingir a aquisição de dados primeiro se realizou uma seleção de instrumentos e sensores a qual foi baseada nas características e requisitos exigidos pelo sistema a identificar como: forma e material da carcaça da bomba, distâncias, sensibilidades, dados eletrônicos e conexões. A seguir, são apresentados na Tabela 4.1 os detalhes da instrumentação empregada.

Tabela 4.1 Dados da instrumentação utilizada.

Nome	Quantidade	Maraca / Modelo
Acelerômetro	5	PCB 352C65
Acelerômetro tri axial	2	PCB 356A15
Cabeça de impedância	1	PCB 288D01
Sistema de aquisição	1	LMS *scada mobile*
Laptop	1	Asus G73Sw

O sistema de aquisição de dados esta composto por um sistema LMS o qual é um sistema SCADA (*Supervisory Control and Data Acquisition*) que são sistemas com um *software* dedicado para monitorar variáveis de sistemas. Este sistema foi selecionado porque conta com 32 canais de entrada e dois canais de saída, sua aquisição de dados é ótima já que a taxa de amostragem é até $204.8\ kHz$ por canal e, além disso, é um sistema especializado para trabalhar com sinais de vibrações e ruído. Na Figura 4.2 se apresenta o sistema de aquisição de dados (LMS) e sua configuração.

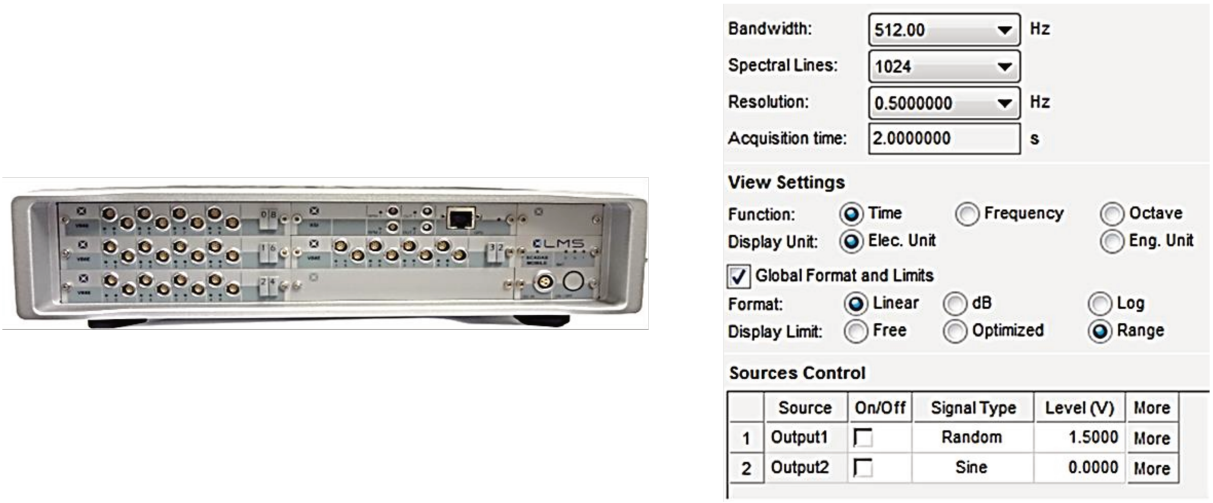

Figura 4.2 Sistema de aquisição de dados (LMS) e configuração.

Para as medições a BCS foi instrumentada para poder monitorar os sinais de vibração da carcaça da BCS. A instrumentação foi feita em quatro trechos conforme é esquematizado na Figura 4.3. Os acelerômetros foram instalados nas posições mostradas na Tabela 4.2.

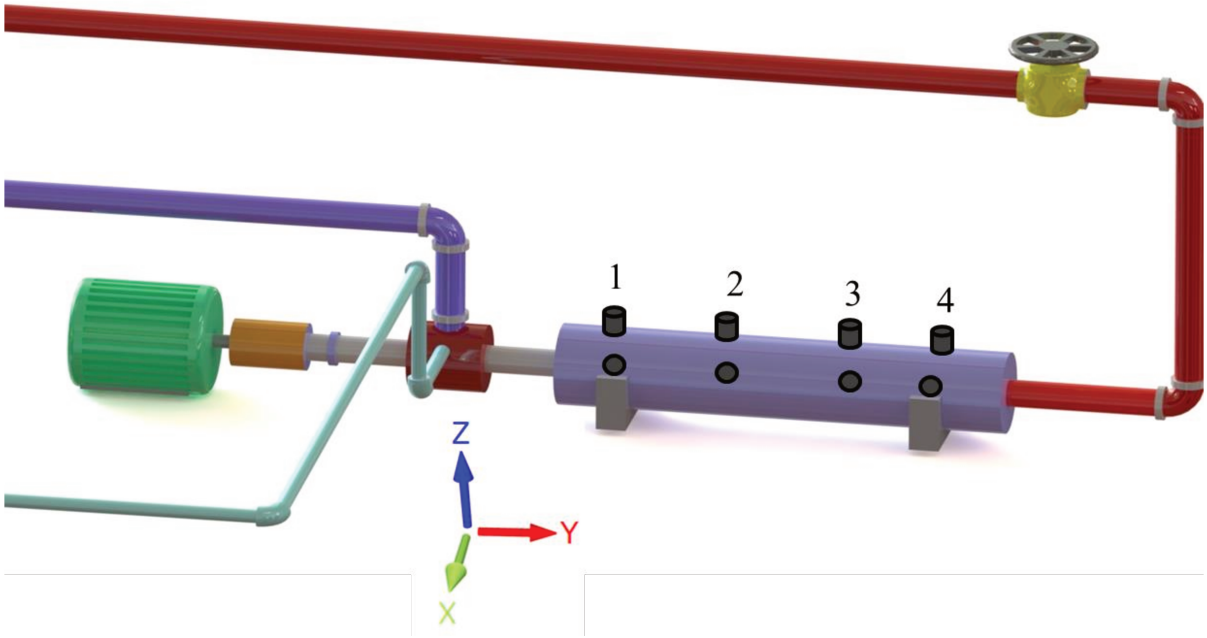

Figura 4.3 Esquema de montagem dos sensores.

Tabela 4.2 Posiçãode montagem dos sensores.

Posição longitudinal	Posição angular	Eixo de medição
1	0	X
1	0	Y
1	0	Z
1	90	X
2	0	Z
2	90	X
3	0	Z
3	90	X
4	0	X
4	0	Y
4	0	Z
4	90	X

1.11.2 Procedimento experimental

Os ensaios experimentais realizados têm como objetivo obter os sinais de saída da BCS operada com diferentes condições de operação como rotações, pressões e vazões, que para este caso de identificação será o sinal de entrada de excitação do sistema. Os resultados destes experimentos são os sinais que representam a resposta da BCS no domínio do tempo com entrada conhecida ao sistema, gerando assim uma base de dados que posteriormente permitirá identificar o parâmetro de interesse. Os procedimentos experimentais adotados são apresentados a seguir e mostrados na Figura 4.4.

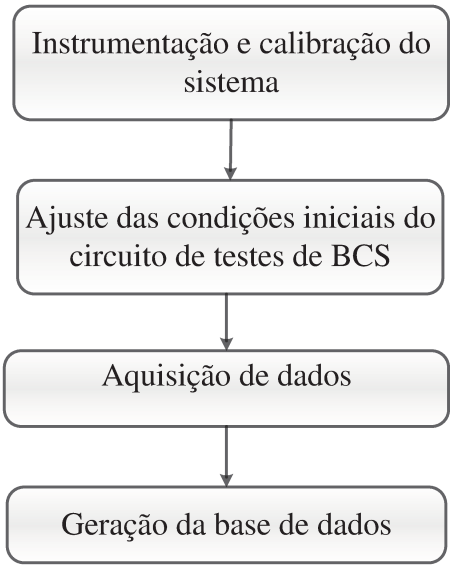

Figura 4.4 Procedimento experimental

O primeiro passo é instrumentar e calibrar o circuito de testes de BCS com os sensores escolhidos anteriormente e incluindo também a calibração e configuração do sistema de aquisição de dados (LMS), garantido a representação ou visualização certa do sinal de saída do sistema, ou seja, que não apresentem nenhum erro de digitalização. O segundo passo é o ajuste das condições inicias do circuito de testes de BCS como rotação da BCS (1800RPM e 3000RPM), pressão de entrada na BCS (100 kPa e 200 kPa)e a vazão de gás (0-3 Kg/h). Para isto se deve ligar a bomba *booster* e posteriormente à bomba BCS deixando fixa a rotação da BCS, depois se ajusta a rotação da bomba *booster* que será estabelecida quando o fluido apresentar uma pressão positiva na sucção da BCS e o diferencial de pressões seja

nulo, posteriormente se regula a vazão volumétrica de gás desejada para o ensaio, e caso a pressão de sucção seja alterada deve-se ajustar de novo a rotação da bomba *booster*. Uma vez que o sistema se estabilize pode-se fazer a aquisição dos dados durante um intervalo de 30 segundos, sendo repetida a aquisição duas vezes para uma mesma condição. O terceiro passo é gravar todos os dados e fazer a exportação para o *Software* que permita fazer o pós-processamento dos sinais adquiridos e assim poder gerar a base de dados, que neste caso é o software *Matlab*. Este procedimento é repetido cada vez que as condições iniciais operacionais da BCS sejam modificadas.

1.12 Seleção do modelo

A seleção do modelo de identificação foi baseada numa revisão preliminar dos diferentes métodos existentes para identificação de sistemas não lineares onde se empregam dados no domínio do tempo e no domínio da frequência que são divididos em métodos paramétricos e não paramétricos. Da mesma forma se faz necessário o conhecimento do processo de funcionamento do sistema a ser identificado, o qual apresenta dois objetivos: como primeiro objetivo o de fazer o processamento dos sinais obtidos no processo experimental e assim poder efetuar a representação espectral dos sinais; e como segundo objetivo o de desenvolver um método de identificação não paramétrico (WELLSTEAD, 1981).

Levando-se em conta esta revisão realizada foi selecionado e desenvolvido um método de caixa preto não paramétrico o qual tem diferentes entradas como: a representação espectral do sinal de vibração do sistema (BCS), a vazão total, o torque e a elevação e como saída a representação gráfica da estimação da vazão de gás na BCS (FASSOIS, 2007). O procedimento de como é obtida a representação espectral do sinal de vibração da BCS é mostrado a seguir.

Para o processamento dos sinais de vibração do sistema (BCS) analisam-se inicialmente as características dos sinais obtidos pelo sistema de aquisição de dados. Concluiu-se assim que são sinais com ruído onde seu comportamento futuro no domínio do tempo não pode ser previsto e muda dependendo das condições iniciais do circuito de teste para BCS.

Identificadas e definidas às características dos sinais de vibração do sistema adquiridos se procede a realizar a representação espectral dos mesmos.

A representação espectral dos sinais de vibração do sistema foi caracterizada por seu valor médio quadrático, conhecido como potência, cuja distribuição no domínio da frequência é a densidade espectral de potência. Esta é definida pelo espectro via transformada de Fourier Finita e por sua função de correlação, já que esta definição é implementada quando se trabalha com equipamentos e técnicas digitais na análise dos sinais de medição, que empregam algoritmos discretos, como é este caso (BLACKMAN,1958).

O procedimento para calcular e fazer a representação espectral é mostrado à seguir:

1. Adquirir o sinal de vibração do sistema (BCS).
2. Dividir o sinal de vibração do sistema (BCS) em q amostras.

$$y_k(t,T) = \begin{cases} x(t), & t_k \leq t \leq t_k + T \\ 0, & fora\ do\ intervalo \end{cases} \tag{4.1}$$

3. Definir a transformada de Fourier Finita (TFF) num intervalo T.

$$Y_k(f,T) = \int_{-\infty}^{\infty} y_k(t,T) e^{-i2\pi f t} dt = \int_{t_k}^{t_k+T} y(t)\, e^{-i2\pi f t} dt \tag{4.2}$$

4. Obter a densidade espectral de potência.

$$S_{yy}^{(2)}(f) = \lim_{T\to\infty} \lim_{q\to\infty} \frac{1}{qT} \sum_{k=1}^{q} |Y_k(f,T)|^2 \tag{4.3}$$

5. Definir a função de auto correlação da densidade espectral de potência, calculada através de média temporal cuja representação no domínio da frequência é dada pela transformada de Fourier, tanto para frequências positivas como negativas.

$$S_{yy}^{(3)}(f) = \int_{-\infty}^{\infty} R_{yy}(\tau) e^{-i2\pi f t}\, dt \tag{4.4}$$

6. Definir da função de auto correlação da densidade espectral de potência, mas só para frequências positivas e aplicar o teorema da conservação de energia do sinal.

$$G_{yy}(f) = 2S_{yy}(f), \qquad f \geq 0$$
$$G_{yy}(f) = 0, \qquad f \leq 0 \tag{4.5}$$

7. Diminuir o erro de *leakage*. Para isto se empregou um janelamento de tipo Hanning com ponderação de 1/4 o qual gerou uma atenuação 3/8 na potência do sinal e por tal motivo o resultado é multiplicado por 3/8.

$$\overline{G_r} \cong \frac{3}{8} G_r \tag{4.6}$$

onde G_r é o sinal janelado.

8. Definir a amplitude da densidade espectral de potência. Esta é obtida a partir da média dos valores absolutos dos coeficientes da Transformada discreta de Fourier ao quadrado e dividindo o resultado pela resolução de frequência, considerando-se que a resolução em frequência esta dada por: $\Delta f = \frac{f_s}{N} = \frac{1}{T}$
9. Análises dos resultados obtidos.
10. Definição das representações espectrais mais características do sistema.

Depois de finalizado o procedimento de representação espectral foi escolhido o resultado da função de auto correlação da densidade espectral de potência para frequências positivas, avaliado só nas frequências de rotação do motor da bomba e seus respectivos múltiplos. Por exemplo, se a bomba está trabalhando com uma rotação fixa de $1800RPM$ as frequências avaliadas serão: 30 Hz, 60 Hz, 90 Hz, 120 Hz, por que são as frequências que apresentam mudanças significativas na representação espectral com respeito à variação da vazão de gás na BCS. Com os parâmetros obtidos neste processo se obtém um conjunto de dados novos os quais serão as entradas para nosso sistema de identificação.

O método de identificação não paramétrico de caixa preta implementado nesta pesquisa foi desenvolvido através de algoritmos de aprendizagem de máquinas, mais

especificamente com o toolbox (SVMLIB) de distribuição gratuita o qual foi executado no MatLab. Este toolbox de aprendizagem de máquina de vetores de suporte para regressão (*Support Vector Machine Regression,* por suas siglas em inglês (SVMR)), permite identificar sistemas não lineares, como é nosso caso. Por isto foi empregando para o desenvolvimento deste trabalho. Além disso, nos últimos anos este método de aprendizagem de máquina tem sido muito aplicado, já que apresenta melhores resultados no funcionamento e grandes vantagens com respeito aos outros métodos de aprendizagem de máquina. Isto se deve por não apresentar mínimos locais e seu modelo esta sujeito só aos dados com mais informação denominados vetores de suporte.

1.12.1 SVM Regressão

As máquinas de Vetores de suporte são sistemas para treinar máquinas de aprendizagem tanto para classificação como para regressão. Este sistema de aprendizagem está baseado no uso de um espaço de hipóteses de funções lineares, que são avaliadas num espaço de maior dimensão induzido por um *kernel*, no qual as hipóteses são treinadas através de um algoritmo, cujo objetivo principal é representar a saída correta do sistema dependendo da entrada do sistema real.

Para a utilização deste método SVMR nesta pesquisa foi adotado um procedimento que será detalhado a seguir.

Primeiro foram definidos os dados de entrada e saída do modelo de aprendizagem, que serão denominadas amostras de treinamento. As entradas estarão constituídas pelos dados de auto correlação da densidade espectral de potência para frequências positivas do sinal de vibração da BCS, avaliado só nas frequências de rotação do motor da bomba e seus respectivos múltiplos, obtidas da representação espectral do sinal de vibração da BCS, que denominamos $x(i)$, e a saída será a vazão de gás na BCS, denominada $y(i)$.

Definido a entrada e a saída (x, y) se procede a dividir o conjunto de dados de entrada em subconjuntos distribuídos da seguinte forma: 60% das amostras para treinamento do algoritmo de aprendizagem (x_{trein}, y_{trein}), 20% das amostras para testes (x_{test}, y_{test})e os 20% restantes para validação do modelo(x_{val}, y_{val}). Estes subconjuntos garantem a seleção de bons parâmetros para se projetar o modelo sem problemas de baixo ajuste ou de sobre

ajuste. Com estes subconjuntos e a saída $y(i)$, ficam definidas as amostras de treinamento para a SVMR, com os respectivos erros para estes subconjuntos dados por:

$$e_{trein} = \frac{1}{2m_{trein}} \sum_{i=1}^{m_{trein}} (h_\theta(x_{trein}) - y_{trein})^2$$
$$e_{test} = \frac{1}{2m_{test}} \sum_{i=1}^{m_{test}} (h_\theta(x_{test}) - y_{test})^2 \qquad (4.7)$$
$$e_{val} = \frac{1}{2m_{val}} \sum_{i=1}^{m_{val}} (h_\theta(x_{val}) - y_{val})^2$$

onde h_θ é a hipóteses a avaliar.

Obtidos as amostras de treinamento se procede a definir os parâmetros necessários para projetar uma máquina de vetores de suporte regressão (SVMR), cujo objetivo principal é estimar a vazão de gás na BCS. Para isto se deve achar uma função $f(x)$ que tenha um mínimo erro de estimação. Para este propósito a formulação da SVMR é a seguinte: se considera o conjunto de treinamento $\big(x(i) \cdot, y(i)\big)$ de N dados $(1 \leq i \leq N)$, onde $x(i) \in \mathbb{R}$ e $y(i) \in \mathbb{R}$ além de ser uma função dependente de $x(i)$, e se considera uma função de perda como se mostra na equação (4.8)

$$f(x,\theta) = \langle \theta, x \rangle + b$$
$$f(x,\theta) = y^{(i)} \qquad y^{(i)} \epsilon\, \mathbb{R}\, \forall i \qquad (4.8)$$

Onde se realiza o produto interno entre $x = \{x_1, x_2, \dots x_n\}$ e o vetor de peso (θ) mais o bias (b). Com a equação (4.8) procura-se achar o menor valor de θ possível, o que é basicamente um problema de otimização. Para se obter este menor parâmetro se fez uma minimização Euclidiana $(\|\theta\|^2)$ como se mostra na equação (4.9). Acha-se assim uma nova variável de sensibilidade chamada (ε).

$$\min_\theta \frac{1}{2} \|\theta\|^2$$
$$sujeito\ a: y_i - (\langle \theta \cdot x_i \rangle + b) \leq \varepsilon \qquad (4.9)$$
$$y_i - (\langle \theta \cdot x_i \rangle + b) \geq -\varepsilon$$

Com a equação anterior se obtém a função $f(x)$ que se aproxima a todos os pares (x_i, y_i) com uma precisão ε, significando dizer que o problema convexo é factível (SMOLA, 2004).

É interessante ressaltar que a ideia básica da SVM para regressão é realizar um mapeamento dos dados de treinamento $x \in X$, a um espaço de maior dimensão F através de um mapeamento não linear devido ao fato do conjunto de dados de treinamento não ser possível de ser separado de forma linear, que é o caso em questão. Por tal motivo é necessário fazer uma transformação de espaço mediante uma função de transformação aumentando a dimensão dos vetores de entrada para um espaço onde se podem separar os dados de forma linear por meio de um hiperplano denominado *kernel* onde neste caso foi selecionado um *kernel Gaussiano,* definido como se mostra na equação (4.10)

$$\text{Kernel Gaussiano} = e^{-\left(\frac{|x-x_i|^2}{2\sigma^2}\right)} \tag{4.10}$$

Depois de achar o melhor hiperplano se procede a maximizar a margem (m) com o objetivo de obter os vetores de suporte que são os dados que contém a maior informação possível para gerar o regressor. Para este problema foram empregados multiplicadores de *Lagrange* junto com o *kernel Gaussino*, como se mostra na equação (4.11).

$$L(\alpha) = \alpha_i - \frac{1}{2}\alpha_i\alpha_j y_i y_j \, k(x_i, x_j) \tag{4.11}$$

Na Figura 4.5 se observa a arquitetura da SVM para regressão.

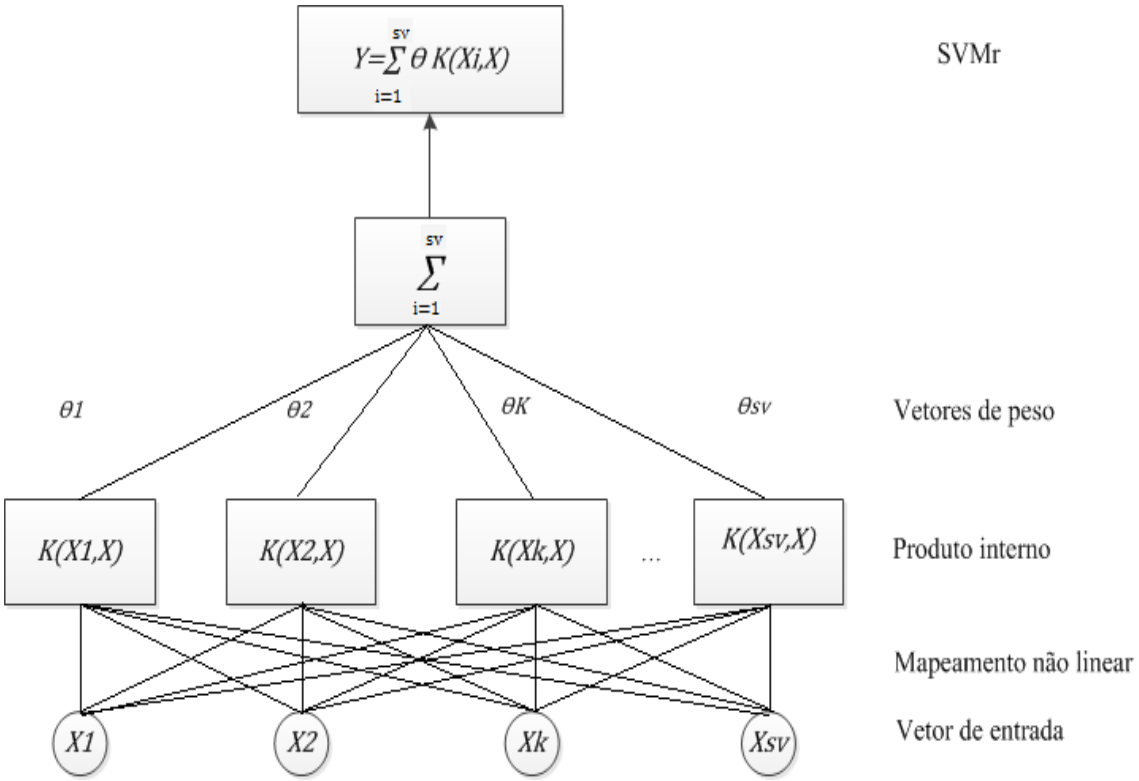

Figura 4.5 Arquitetura da SVM para regressão.

Por último se atinge os melhores valores dos parâmetros ocultos da SVM para regressão as quais são o parâmetro C que determina o apuramento da margem isto é o parâmetro de regularização, o σ que é o parâmetro da função *kernel gaussiano,* e o parâmetro ε da margem. Os parâmetros C e σ definem a margem de aceitação da estimação e o ε define a insensibilidade da margem.

A obtenção destes parâmetros é feita mediante o desenvolvimento de um algoritmo genético que será apresentado na seguinte seção.

1.12.2 Algoritmo Genético

Os algoritmos genéticos são métodos robustos de pesquisa e otimização, os quais estão baseados nos processos genéticos dos organismos vivos, proporcionando-lhes uma capacidade de criar soluções para diversos problemas. A evolução que caracteriza este método permite-lhe obter as melhores soluções para um determinado problema e deste modo melhorar a capacidade de previsão de parâmetros. Além disto algumas pesquisas estão sendo realizadas para estimar os parâmetros ocultos da SVMR com algoritmos

genéticos para obter a solução de diferentes problemas (YU, 2009), (ZHENYUE, 2009), (SAINI, 2010). Por estes motivos o algoritmo genético foi selecionado para estimar os parâmetros ocultos da SVMR $(C, \varepsilon, \sigma^2)$ e com estes parâmetros ótimos poder realizar o respectivo treinamento, melhorando assim o rendimento da SVMR e obtendo um modelo mais representativo. Na Figura 4.6 se amostra o procedimento do algoritmo genético.

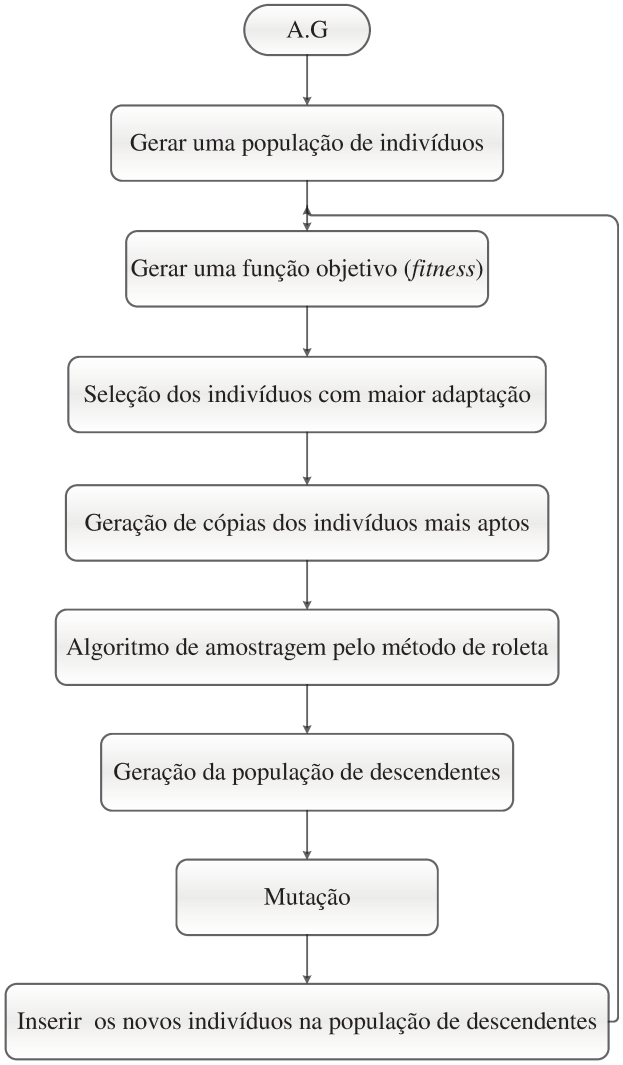

Figura 4.6 Procedimento do algoritmo genético

O procedimento para a estimação destes parâmetros $(C, \varepsilon, \sigma^2)$ consiste em fazer o treinamento por algoritmo genético através dos seguintes passos. Primeiro é criado uma população de indivíduos $(p(t) = \{x_1^t \dots x_n^t\})$, onde cada um dos indivíduos representa uma possível solução. Em seguida, a função objetivo (*fitness*) é criada. Esta função minimiza o

erro de validação da SVMR e avalia o desempenho de cada um dos indivíduos, permitindo assim ordenar do melhor para o pior indivíduo da população em um grau contínuo de adaptação.

$$fitness = \min e_{val} \tag{4.12}$$

onde o erro de validação (e_{val}) é calculado como se apresenta na equação (4.7).

Para isto é criado um ponto de busca $\overrightarrow{x_k} = (x_{k1}, x_{k2}, \dots, x_{kn})$, onde cada um dos n componentes do vetor $\overrightarrow{x_k}$ é codificado em binário, empregando b bits, depois a representação binária de cada parâmetro é unida em uma única faixa, obtendo indivíduos de comprimento $l = nb$.

Logo é gerado o operador de seleção o qual permite orientar a busca dos pontos mais provisórios, ou seja, os que têm maior adaptação, para isto é criado uma população intermediária do mesmo tamanho da população inicial, reproduzindo com mais cópias os indivíduos mais aptos e eliminando ou restringindo um número menor de cópias os indivíduos pior aptos. Os indivíduos selecionados serão propagados.

Para manter a população constante se realizou um algoritmo de amostragem pelo método de roleta. Primeiro se determina a somatória(s) das adaptações de toda a população, depois se relaciona um a um os indivíduos com segmentos contínuos da reta real $[0, s]$, garantindo que cada segmento seja igual em tamanho a seu grau de adaptação, logo se gera um número aleatório que esteja no segmento e adquire a informação do indivíduo a partir do número aleatório gerado e se repete o processo até obter o número de amostras desejadas.

Em seguida se implementa um algoritmo de recombinação que troca o material genético dos indivíduos que chamamos pais produzindo descendentes, ou seja os filhos. Este operador permite que em alguns casos não se de a recombinação e se mantenham os pais. Para esta recombinação se seleciona um par de pais de l bits, e é escolhido aleatoriamente um ponto k que a partir deste ponto são trocados os bits da direita entre os pais, obtendo assim os novos descendentes.

Para evitar a perda de diversidade é realizado um processo de mutação cujo objetivo é inverter ocasionalmente um bit de acordo a uma porcentagem definida. Com todo este procedimento se garante que a população convergirá a uma solução ótima para a estimação dos parâmetros $(C, \varepsilon, \sigma^2)$ garantindo um bom treinamento da SVMR com parâmetros ideais.

1.12.2.1 Exemplo de algoritmo genético

A seguir se apresenta um exemplo que explica cada um dos passos do algoritmo genético. Primeiro se cria um conjunto de indivíduos de número m que é a população inicial, cada indivíduo é codificado de forma binária (C_i) empregando b bits. Com a decodificação obtemos o fenótipo (X_i^t), como se apresenta a seguir:

$$m = 4 \quad \begin{array}{cc} C_i & X_i \\ 01101 & 13 \\ 11000 & 24 \\ 01000 & 8 \\ 10011 & 19 \end{array}$$

Segundo, a função objetivo (*fitness*) é criada dependendo do problema a ser resolvido. Para este caso dado um cromossomo C_i^te seu fenótipo X_i^t podemos obter sua adequação f_i^t como:

$$f_i^t = e_{val}(C_i^t) = f(X_i^t)$$

onde cada indivíduo é avaliado com respeito à função objetivo (*fitness*), que para este caso é o erro de validação (e_{val}) dado pela equação (4.13).

$$e_{val} = \frac{1}{2m_{val}} \sum_{i=1}^{m_{val}} (h_\theta(x_{val}) - y_{val})^2 \qquad (4.13)$$

onde (x_{val}, y_{val}) são os dados de validação que correspondem ao 20% de todos os dados recoletados, e h_θ é a hipótese a avaliar.

C_i	X_i	$fitness$
01101	13	169
11000	24	576
01000	8	64
10011	19	361

Obtendo assim a soma total da função objetivo (f_i) que para este exemplo é: 1170.

Logo é criada a população intermediária que tem que ser do mesmo tamanho da população inicial, reproduzindo com mais cópias aos indivíduos mais aptos e eliminando ou restringindo um numero menor de cópias aos indivíduos pior aptos. Para isto primeiro se define $(\%\ total)$ como:

$$(\%\ total) = \frac{fitness}{f_i} * 100 \tag{4.14}$$

Depois definimos a media de adaptação da população como:

$$\overline{f_t} = \frac{PA}{m} \tag{4.15}$$

onde PA é a somatória de cada um dos resultados de $\%\ total$. Neste caso $PA = 100$.

Finalmente obtemos o número de copias (N_e) de cada indivíduo para a próxima geração como:

$$N_e[i] = \frac{f_i}{\overline{f_t}} \tag{4.16}$$

Obtendo:

C_i	X_i	$fitness$	$\%\ Total$	$\#de\ copias$
01101	13	169	14.4	1
11000	24	576	49.2	2
01000	8	64	5.2	0
10011	19	361	30.9	1
		$f_i = 1170$	$PA = 100$	

Depois se aplica o algoritmo de amostragem pelo método de roleta.

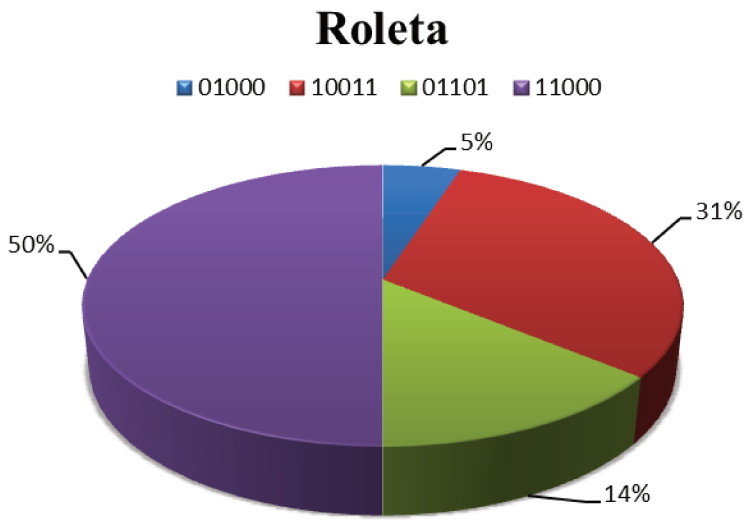

Figura 4.7 Algoritmo de amostragem pelo método de roleta

Para implementar o algoritmo de recombinação que troca o material genético dos indivíduos para produzir descendentes, primeiro se seleciona um par de pais de l bits.

$$Pais \begin{cases} 01000 \\ 01101 \end{cases}$$

Depois é escolhido aleatoriamente um ponto k que a partir deste ponto são trocados os bits da direita entre os pais, obtendo assim os novos descendentes.

$$Pais \begin{cases} 010 \vdots 00 \\ 011 \vdots 01 \end{cases}$$

$$Filhos \begin{cases} 010 \vdots 01 \\ 011 \vdots 00 \end{cases}$$

Para o processo de mutação cujo objetivo é inverter ocasionalmente um bit, primeiro se seleciona um indivíduo de forma aleatória e se inverte o bit.

$$\begin{array}{c} 01100 \\ 01000 \end{array}$$

Finalmente a partir de esta nova população gerada o procedimento é repetido até que a populaçãoconvirja.

1.12.3 Eleição do critério de estimação

Para estabelecer quais são os dados experimentais que proporcionam maior informação a mudança da vazão de gás na bomba, serão obtidos diferentes modelos mediante o algoritmo de identificação desenvolvido nesta pesquisa. Estes modelos se caracterizaram porque as entradas ao sistema a identificar (porcentagem de gás) serão trocadas para cada um dos modelos obtidos e porque os estados ocultos da SVM serão obtidos mediante algoritmos genéticos.

Considerando a base de dados gerada no processo de aquisição de dados e as condições da BCS no processo real da indústria, foram selecionados os seguintes dados como entradas ao sistema a identificar como: a representação espectral do regime vibratório da carcaça da bomba (VDE), a somatória da vazão de ar e água (vazão total), o torque e a elevação, lembrando que a saída do sistema é a vazão de gás. Com estas novas entradas e saídas realizar-se-á o treinamento da SVMR, e assim serão obtidos mais modelos para a identificação de vazão de gás.

1.13 Validação do modelo

A validação do modelo consiste em avaliar e comprovar se o modelo obtido no processo de identificação possui uma gama satisfatória de precisão. Para isto a técnica empregada foi à de estimação do erro quadrático médio MSE e do coeficiente de correlação as quais permitiram fazer uma comparação dos resultados obtidos com cada modelo, e assim selecionar o melhor modelo que identifique a vazão de gás no sistema de interesse.

Capítulo 5. Resultados

Neste capítulo são apresentados os resultados obtidos dos modelos desenvolvidos pelo método de aprendizagem de máquinas SVMR para dois exemplos teste e para a identificação da vazão de gás em uma bomba centrífuga em regime de escoamento multifásico.

1.14 Sistema massa-mola-amortecedor

A fim de avaliar o desempenho da técnica pesquisada neste projeto foram propostos inicialmente dois exemplos de aplicação. Trata-se de um sistema massa-mola-amortecedor de três graus de liberdade onde cada massa do sistema é excitada com uma força variável. Neste sistema a matriz de rigidez (K) é multiplicada por uma variável (u), que é o parâmetro proporcional de mudança da rigidez do sistema, que varia no intervalo de $[1-2]$ com um incremento de 0.01. Isto é feito com o objetivo de se ter uma variável dinâmica no sistema, a qual será identificada mediante o desenvolvimento de um modelo não paramétrico de caixa preta obtido a partir do treinamento de uma SVMR.

Para obter o modelo do primeiro exemplo o treinamento da SVMR foi feito com todos os dados que caracterizam o sistema, ou seja, o treinamento da SVMR contém todos os dados da variável a identificar. Para obter o modelo do segundo exemplo o treinamento da SVMR é feito sem todos os dados que caracterizam o sistema, ou seja, foi removida uma região de dados da variável que se deseja identificar. Esta região de dados removidos será empregada como dados de testes, isto com a finalidade de se avaliar o comportamento do método quando não se contam com todos os dados característicos do sistema a identificar.

1.14.1 Descrição do modelo

Considera-se um sistema mecânico massa-mola-amortecedor de três graus de liberdade, apresentado na Figura 5.1. O sistema é composto por três massas (M_1, M_2, M_3) onde cada uma delas é afetada por uma força (F_1, F_2, F_3) em cada grau de liberdade (y_1, y_2, y_3) respectivamente e a variação das forças aplicadas em cada uma das massas é apresenta na Figura 5.2, onde as forças que afetam cada uma das massas, que são as entradas do sistema, são assumidas como ruído branco.

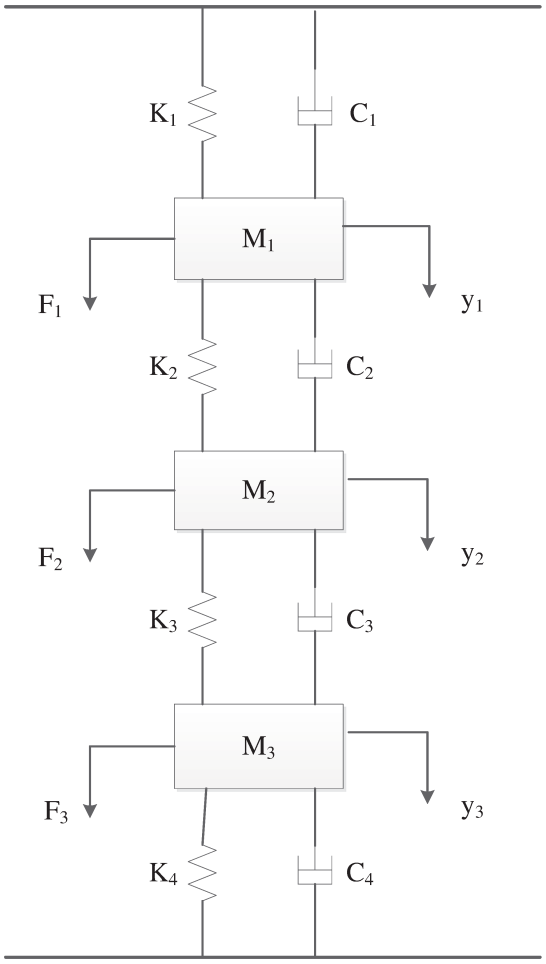

Figura 5.1 Sistema massa – mola – amortecedor.

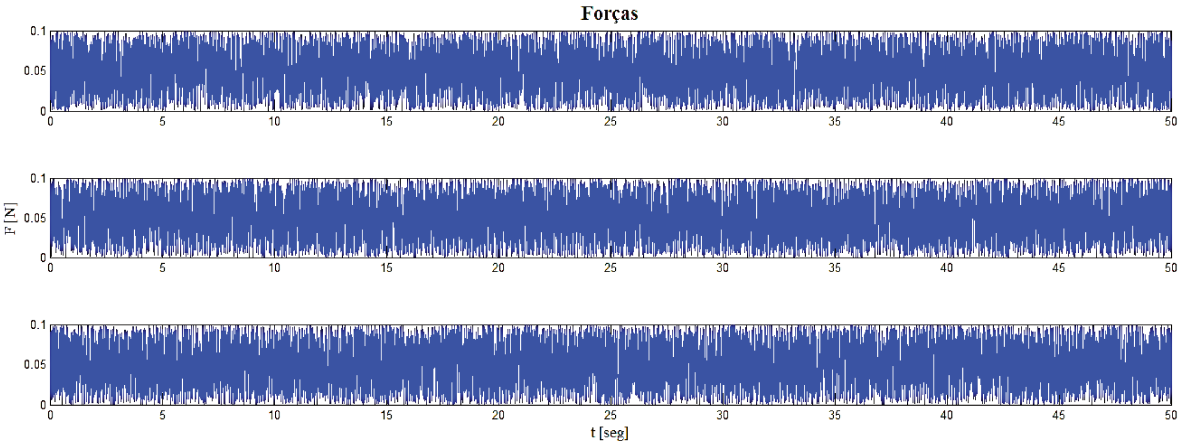

Figura 5.2 Forças em cada uma das massas do sistema massa-mola-amortecedor

O sistema é descrito pela equação diferencial de movimento (5.1)

$$M\ddot{y} + C\dot{y} + uKy = F \qquad (5.1)$$

Para o primeiro exemplo o sistema a identificar é apresentado na Figura 5.3 onde se pode notar que o parâmetro que se deseja identificar u aumenta a rigidez de cada uma das molas do sistema proporcionalmente e cujo modelo será obtido a partir do conhecimento de todos os dados que caracterizam ao sistema. A equação diferencial de movimento do sistema a identificar é obtida da equação (5.2).

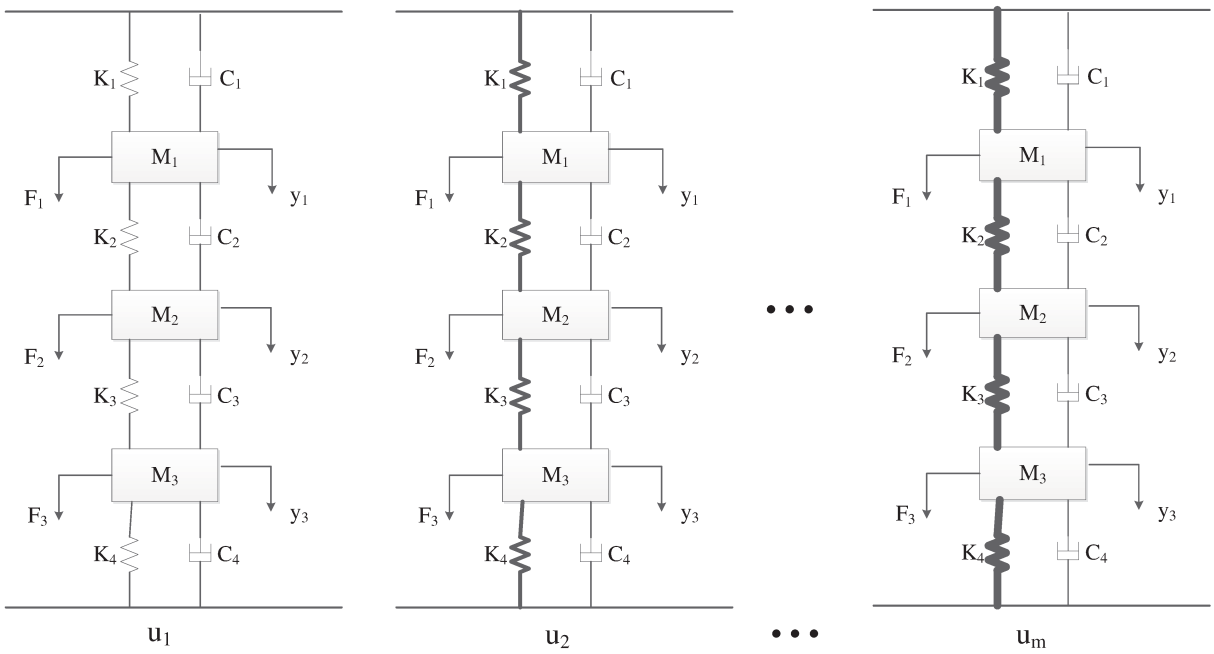

Figura 5.3 Sistema massa – mola – amortecedor a identificar com todos os dados de treinamento.

O modelo e os valores hipotéticos do sistema são:

$$M\ddot{y} + C\dot{y} + uKy = F \qquad (5.2)$$

$$\begin{bmatrix} M_1 & 0 & 0 \\ 0 & M_2 & 0 \\ 0 & 0 & M_3 \end{bmatrix} \ddot{y} + \begin{bmatrix} C_1 + C_2 & -C_2 & 0 \\ -C_2 & C_2 + C_3 & -C_3 \\ 0 & -C_3 & C_3 + C_4 \end{bmatrix} \dot{y}$$

$$+ u \begin{bmatrix} K_1 + K_2 & -K_2 & 0 \\ -K_2 & K_2 + K_3 & -K_3 \\ 0 & -K_3 & K_3 + K_4 \end{bmatrix} y = F$$

A matriz de massa M é:

$$M = \begin{bmatrix} M_1 & 0 & 0 \\ 0 & M_2 & 0 \\ 0 & 0 & M_3 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 3 \end{bmatrix} \tag{5.3}$$

A Matriz de rigidez K é:

$$K = u \begin{bmatrix} K_1 + K_2 & -K_2 & 0 \\ -K_2 & K_2 + K_3 & -K_3 \\ 0 & -K_3 & K_3 + K_4 \end{bmatrix}$$

$$K = u_i \begin{bmatrix} 6000 & -4000 & 0 \\ -4000 & 12000 & -8000 \\ 0 & -8000 & 8000 \end{bmatrix} \tag{5.4}$$

onde $u_i = \{u_1, u_2, \dots, u_m\} \quad para\ o\ intervalo\ de\ [1 - 2]\ com\ incremento\ de\ 0.01$

Matriz de amortecimento C é:

$$C = \begin{bmatrix} C_1 + C_2 & -C_2 & 0 \\ -C_2 & C_2 + C_3 & -C_3 \\ 0 & -C_3 & C_3 + C_4 \end{bmatrix} = \begin{bmatrix} 0.2 & -0.1 & 0 \\ -0.1 & 0.2 & -0.1 \\ 0 & -0.1 & 0.1 \end{bmatrix} \tag{5.5}$$

A resposta no tempo do sistema massa - mola - amortecedor obtida é mostrada na Figura 5.4. Da análise da figura podemos concluir que o sistema apresenta um sinal de resposta com muito ruído e que seu comportamento não é bem definido no domínio do tempo, por isto a representação espectral do sinal será obtida pelo método de densidade espectral de potencia definido na seção 4.2. Na Figura 5.5 se apresentada à representação espectral do sistema obtida.

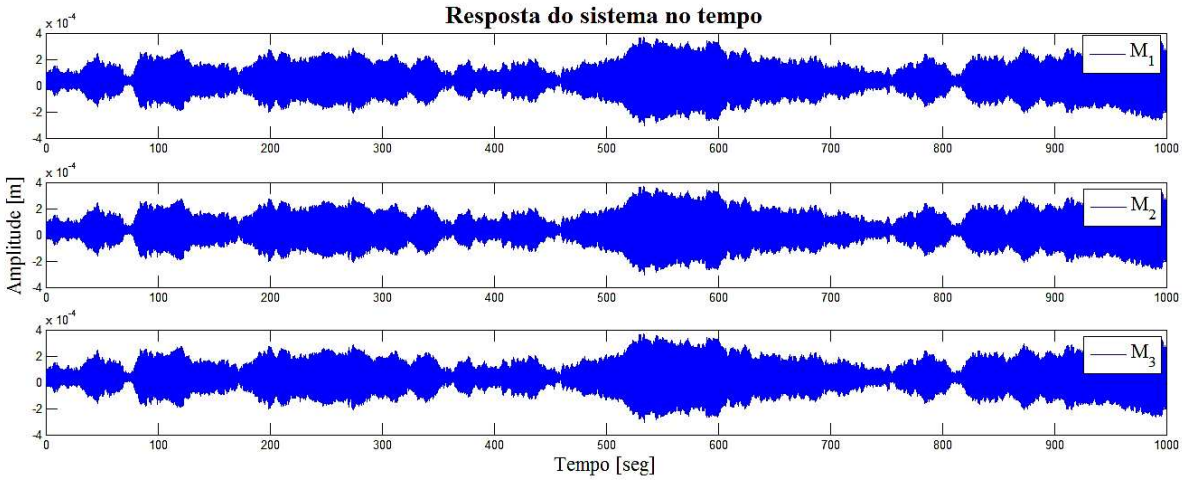

Figura 5.4 Resposta do sistema massa-mola-amortecedor no domínio do tempo.

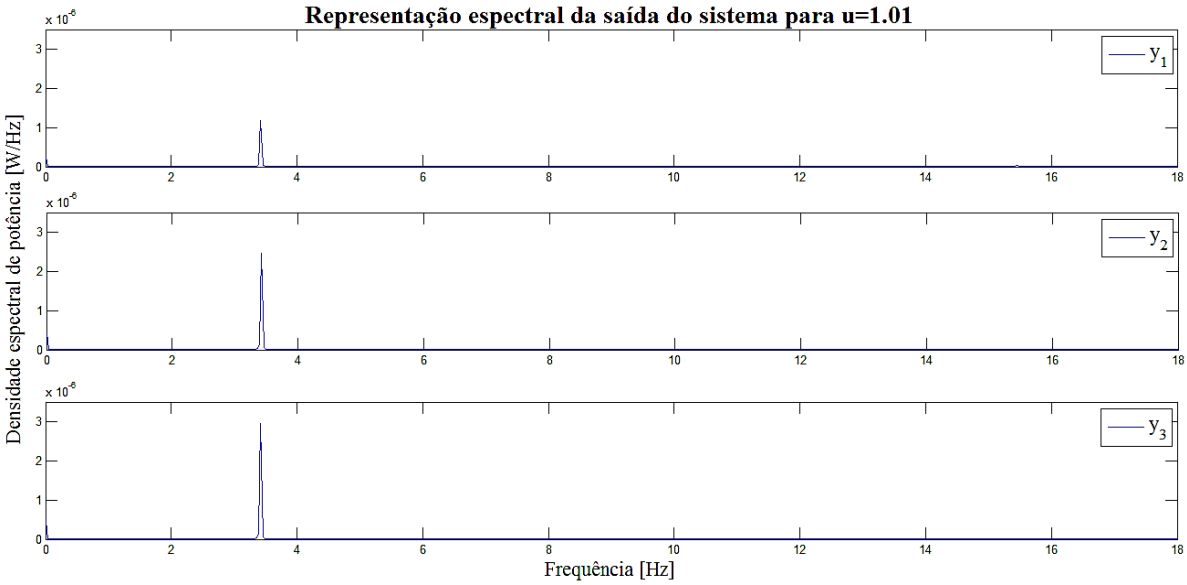

Figura 5.5 Representação espectral do sistema massa-mola-amortecedor

1.14.2 Obtenção do modelo e resultados

Obtida a representação espectral do sistema para o primeiro exemplo se procede a definir os parâmetros de entrada e saída do sistema para posteriormente poder fazer o treinamento da SVMR. Neste caso os dados de entrada são todas as representações espectrais obtidas para cada uma das massas e a saída é a variável dinâmica a identificar, ou seja, o parâmetro proporcional *u* das rigidezes das molas do sistema.

Para atingir os melhores parâmetros da SVMR se realizarão vários testes com o algoritmo genético desenvolvido nesta pesquisa com a metodologia proposta na seção 4.2.2, tudo com o objetivo de achar o melhor modelo para o sistema. Os testes realizados com o algoritmo genético tem a seguinte configuração apresentada na Tabela 5.1.

Os parâmetros obtidos para a SVMR $(C, \sigma^2, \varepsilon)$ por meio das configurações apresentadas na Tabela 5.1 são expostas na Tabela 5.2 além do erro quadrático médio pelas siglas em inglês (MSE *mean squared error*) que indica a relação entre a variável a identificar e a variável identificada pelo modelo obtido e o coeficiente de correlação indicando a eficiência deste.

O erro quadrático médio MSE é obtido da seguinte maneira:

$$MSE = \sum_{i=1}^{n} \frac{(y(i) - y_{ireal})^2}{n} \tag{5.6}$$

onde, $y(i)$ é a saída predita pelo modelo obtido mediante o algoritmo de SVMR para uma entrada (i); y_{ireal} é o valor real da saída para a entrada (i) e n é o número de valores analisados.

O coeficiente de correlação (r^2) é obtido da seguinte maneira:

$$r^2 = 1 - \frac{\sum_{i=1}^{n}(y(i) - y_{ireal})^2}{\sum_{i=1}^{n}(y(i) - y_{media})^2} \tag{5.7}$$

onde, $y(i)$ é a saída predita pelo modelo obtido mediante o algoritmo de SVMR para uma entrada (i); y_{ireal} é o valor real da saída para a entrada (i), y_{media} é a média dos valores e n é o número de valores analisados.

O coeficiente de correlação varia no intervalo de 0 a 1, onde quanto mais perto de 1 esteja o resulta do (r^2) indicara que o modelo obtido é mais eficiente ou seja que o relacionamento entre a entrada e a saída do modelo é forte.

O modelo não apresenta correlação quando $r^2 < 0.3$, se considera um relacionamento leve quando $0.3 \leq r^2 < 0.5$, um relacionamento moderado quando $0.5 \leq r^2 < 0.7$ e finalmente um relacionamento forte quando $0.7 \leq r^2 \leq 1$.

Tabela 5.1 Configuração do algoritmo genético

Modelo	N^o. De Gerações	N^o. De Indivíduos	N^o. De Genes	Probabilidade De Cruzamento	Probabilidade De Mutação
1	100	10	10	50	10
2	500	10	10	50	10
3	1000	10	10	50	10
4	100	100	10	40	20
5	500	100	10	40	20
6	1000	10	10	40	20
7	1000	100	10	60	10
8	50	10	10	60	10

Tabela 5.2 Parâmetros e MSE dos modelos obtidos pelo algoritmo genético para SVMR com todos os dados de treinamento.

	Parâmetros da SVMR			MSE De Treinamento	Coeficiente De Correlação
	C	σ^2	ε		
Modelo 1	825.1162	0.14648	0.00118	3.12E-06	0.999966
Modelo 2	8.0215	0.46896	0.00015	9.98E-06	0.99993
Modelo 3	**916.3682**	**0.011658**	**0.0009651**	**2.01E-06**	**0.999978**
Modelo 4	142.0947	0.048431	0.00055	2.62E-06	0.999973
Modelo 5	1000.665	0.033112	0.00058	2.72E-06	0.99997
Modelo 6	676.7305	0.15015	0.00115	3.36E-06	0.999967
Modelo 7	32.1641	0.14401	0.00047	3.97E-06	0.999967
Modelo 8	1016.204	0.15106	0.00135	3.16E-06	0.999964

Pela análise da Tabela 5.2 se pode concluir que o melhor modelo obtido é o numero três já que apresenta um erro quadrático médio de 2.01E-0.6 e um coeficiente de correlação de 0.999978 o que indica que o modelo do SVMR foi totalmente treinado para estimar a variação da rigidez da mola, presente no sistema massa – mola – amortecedor.

Na Figura 5.6 é apresentado o comportamento de cada um dos parâmetros a estimar da SVMR pelo método de algoritmos genéticos com sua respectiva média. Além disto, se apresenta o comportamento dos erros de validação e treinamento.

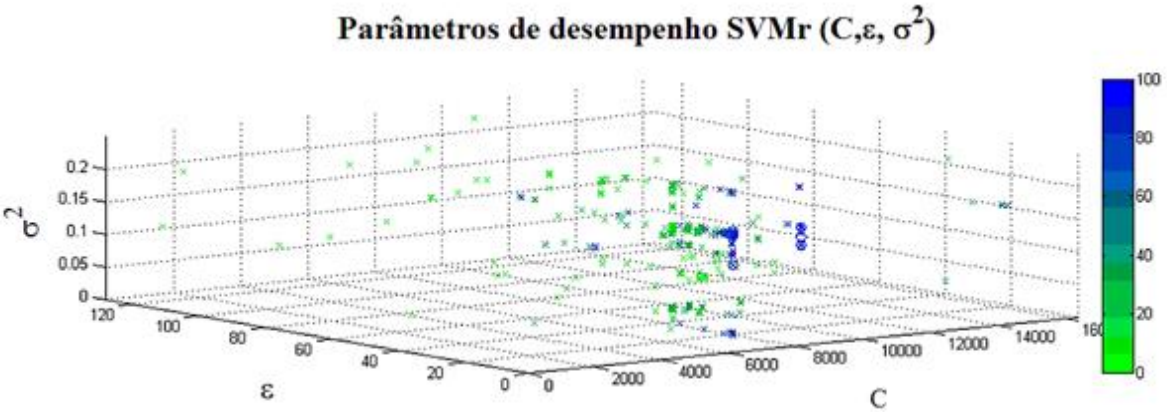

a)

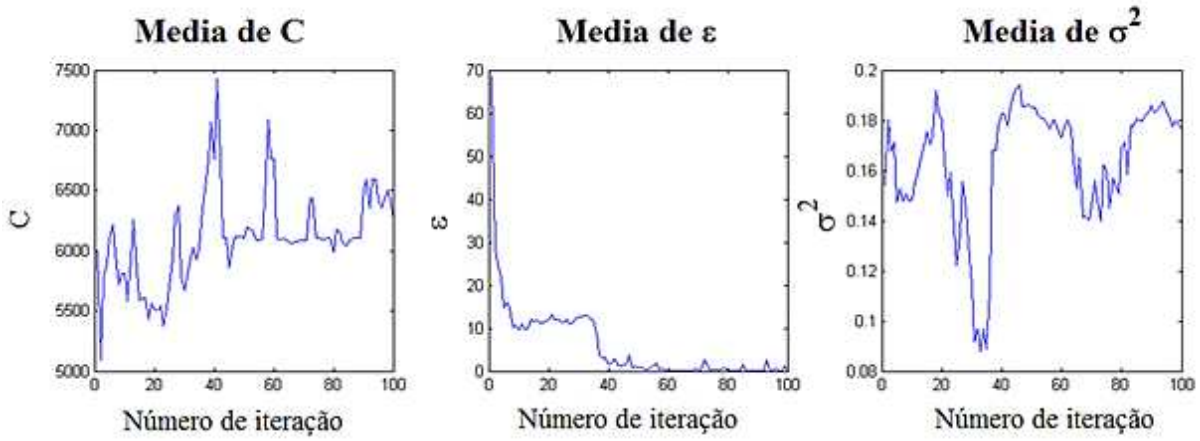

b)

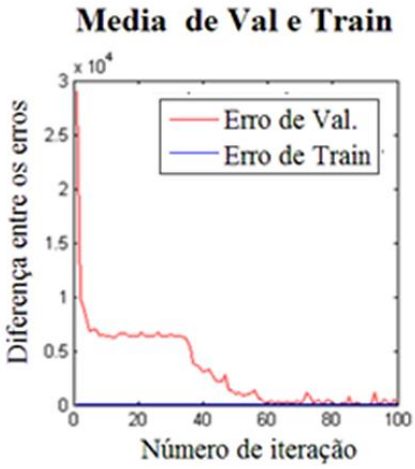

c)

Figura 5.6 a) Melhores indivíduos do algoritmo genético. b) Evolução dos parâmetros ocultos da SVMR mediante algoritmo genético. c) Comportamento dos erros de validação e treinamento.

Na Figura 5.7 se apresenta o resultado do modelo obtido para a identificação do parâmetro proporcional u das rigidezes do sistema massa – mola – amortecedor com respeito a um número determinado de mostras utilizadas para testar o desempenho do modelo obtido a partir dos dados de treinamento da SVMR (m_{train}). Os dados de cor vermelha representam os dados de testes, ou seja os parâmetros a identificar, e em cor azul representam os resultados de identificação do modelo obtido com SVMR para um sistema massa – mola – amortecedor. Desta Figura 5.7 concluímos que o modelo obtido identifica o parâmetro de interesse e que apresenta um bom desempenho quando o algoritmo implementado é treinado com todos os dados característicos do sistema.

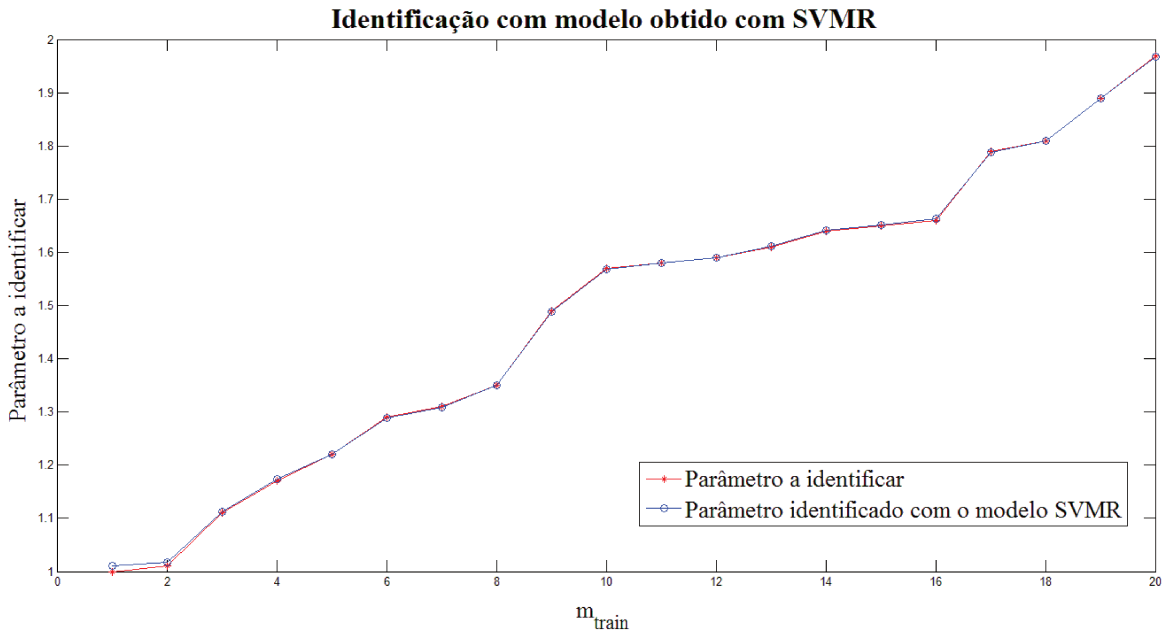

Figura 5.7 Resultados da identificação da rigidez com modelo obtido por SVMR com todos os dados característicos do sistema.

Para o segundo exemplo foi considerado o mesmo sistema massa – mola – amortecedor e o mesmo parâmetro a identificar do primeiro exemplo, mas a definição das entradas de treinamento para a SVMR foram modificadas, já que foram removidos os dados compreendidos na faixa de $u = [1.16 - 1.24]$ da variável dinâmica do sistema, isto é o parâmetro a identificar (rigidez do sistema) como se apresenta na Figura 5.8 .

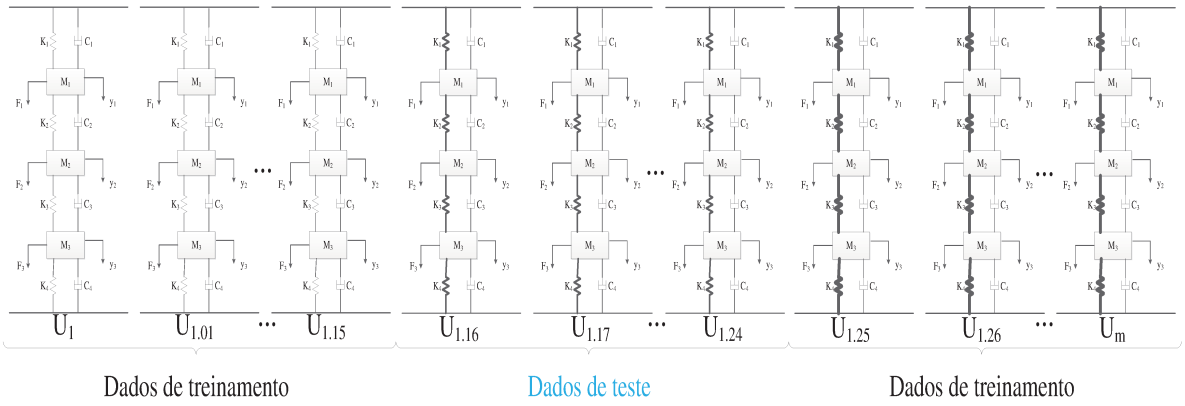

Figura 5.8 Sistema massa – mola – amortecedor a identificar sem todos os dados de treinamento

Realizou-se os mesmos testes com o algoritmo genético e com a mesma configuração que no primeiro exemplo (Tabela 5.1), obtendo-se assim os seguintes modelos apresentados na Tabela 5.3

Tabela 5.3 Parâmetros e MSE dos modelos obtidos pelo algoritmo genético para SVMR sem todos os dados de treinamento.

	Parâmetros da SVMR			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ^2**	**ε**		
Modelo 1	322.9297	2.2554	2.96E-05	2.41E-04	0.861375
Modelo 2	524.4189	0.92856	0.0004935	3.23E-05	0.959419
Modelo 3	**938.3027**	**0.92087**	**0.0005441**	**2.43E-05**	**0.968476**
Modelo 4	611.5127	0.93549	0.0004447	3.50E-05	0.955001
Modelo 5	**524.2646**	**1.0038**	**0.0004404**	**2.84E-05**	**0.963918**
Modelo 6	355.322	1.0719	0.0004427	3.13E-05	0.959808
Modelo 7	178.1309	2.2645	1.67E-05	2.39E-04	0.868352
Modelo 8	678.7002	0.93735	0.0005434	3.03E-05	0.962781

Pela análise da Tabela 5.3 se conclui que se obtiveram dois modelos ótimos para a identificação da variação da rigidez neste sistema os quais são o modelo três e cinco que apresentam um erro quadrático médio de 2.43E-0.5 e 2.84 E-05 e um coeficiente de correlação de 0.968476 e 0.963918 respectivamente, o que indica que o modelo obtido com a SVMR identifica a variação de rigidez presente no sistema massa – mola – amortecedor apesar de não ter sido treinado com todos os dados que caracterizam o sistema de interesse. Na Figura 5.9 se apresenta os resultados da identificação de todas rigidezes do sistema dos dados de teste, ou seja, mesmo das rigidezes não incluídos no treinamento da SVMR. Concluindo assim que, apesar do fato de que a SVMR não ter sido treinada para identificar estes dados, o modelo obtido consegue identificar estes dados com um erro de 2.43E-0.5.

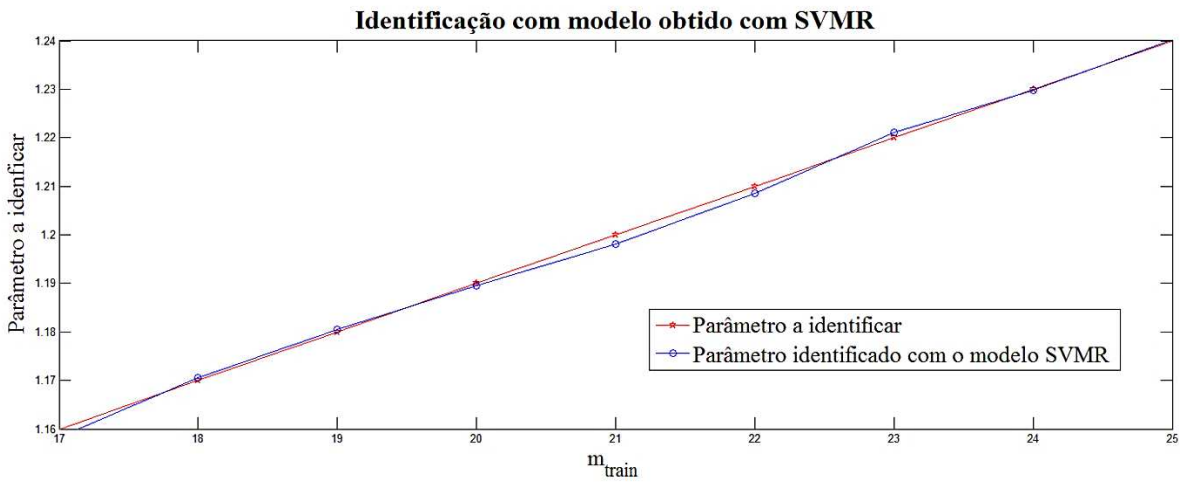

Figura 5.9 Identificação das rigidezes não incluídas no treinamento da SVMR

1.15 Identificação da vazão de gás numa BCS

Nesta sessão se expõem os resultados dos modelos obtidos pelo método de aprendizagem de máquina (SVMR) para a identificação da vazão de gás numa BCS J200N seguindo a metodologia proposta no Capítulo 4.

1.15.1 Ajuste das condições iniciais do circuito de testes de BCS

Para a aquisição dos dados de entrada e saída do sistema foram realizados vários experimentos com o circuito de testes de BCS do LABPETRO, o qual apresenta as seguintes configurações das condições iniciais de funcionamento do circuito de teste. Para o primeiro experimento as condições foram rotação da BCS a $1800\ RPM$ com pressão de entrada de $100\ kPa$ e as vazões de gás foram de $0\frac{Kg}{h}$, $1\frac{Kg}{h}$, $2\frac{Kg}{h}$, e $3\frac{Kg}{h}$, respectivamente. Para o segundo experimento a rotação da BCS ficou igual, mas a pressão de entrada da BCS mudou de $100\ kPa$ para $200\ kPa$ e as vazões de gás foram de $0\frac{Kg}{h}$, $1\frac{Kg}{h}$, $2\frac{Kg}{h}$, e $3\frac{Kg}{h}$, respectivamente. Para o terceiro experimento a rotação da BCS foi mudada de $1800\ RPM$ para $3000\ RPM$ com pressão de entrada de $100\ kPa$ e as vazões de gás foram de $0\frac{Kg}{h}$, $1\frac{Kg}{h}$, $2\frac{Kg}{h}$, e $3\frac{Kg}{h}$, respectivamente. Para o último experimento a rotação da BCS ficou igual ao do terceiro experimento de $3000\ RPM$ e a pressão de entrada foi de $200\ kPa$ com as vazões de gás de $0\frac{Kg}{h}$, $1\frac{Kg}{h}$, $2\frac{Kg}{h}$, e $3\frac{Kg}{h}$, respectivamente. Obtendo-se um total de

aquisição de dados de 16 diferentes condições iniciais do circuito de testes de BCS. Na Figura 5.10 se apresenta a configuração do circuito de testes de BCS para aquisição de dados.

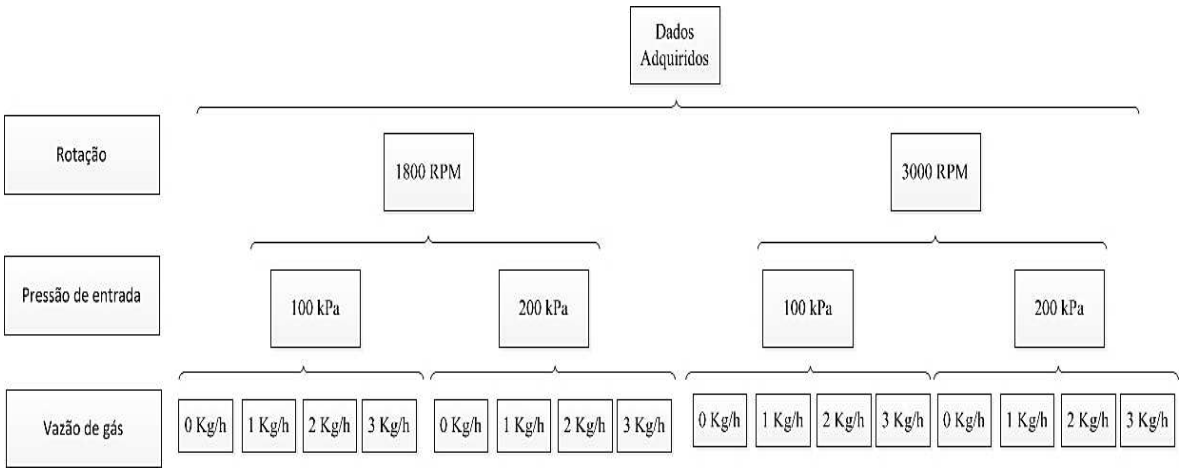

Figura 5.10 Configuração do circuito de testes de BCS para aquisição de dados

1.15.2 Análise da representação espectral do sistema BCS

Para realizar as análises da representação espectral da saída do sistema, primeiro se obtiveram as representações espectrais para cada um dos sinais adquiridos empregando o método explicado na sessão 1.12. Obtidas estas representações se procede a analisar cada um dos resultados, com o objetivo de achar similaridades e diferenças em cada uma delas, e assim poder obter e selecionar as propriedades mais relevantes da representação espectral, conseguindo assim caracterizar o comportamento da vazão de gás na BCS.

Realizado a análise da taxa de variação entre média quadrática e a frequência ao longo todos os sinais, se conclui que são apresentadas frequências particulares do sistema quando as condições iniciais de rotação da BCS são modificadas, por exemplo, quando esta se encontra operando com rotação de $1800\ RPM$ as frequências particulares do sistema se apresentam em $30\ Hz, 60\ Hz, 90\ Hz\ e\ 120\ Hz$ e quando é quando a BCS se encontra operando com rotação de $3000\ RPM$ as frequências particulares mudam para $50\ Hz, 100\ Hz, 150\ Hz\ e\ 200\ Hz$ independentemente da vazão de gás com a que está operando a BCS. A partir destes dados são definidas as amostras de treinamento principais para a SVMR. Na Figura 5.11 e na Figura 5.12 se apresenta a representação espectral do

sistema quando a rotação da BCS é 1800 RPM e 3000 RPM respectivamente, para cada uma das diferentes condições de vazão de gás.

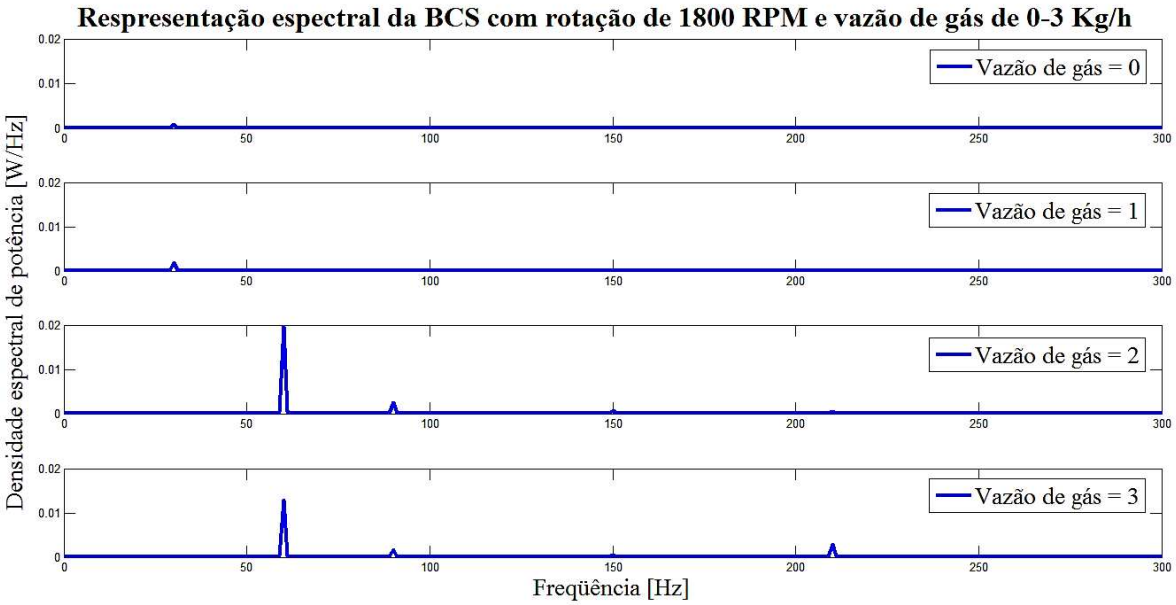

Figura 5.11 Representação espectral da BCS com rotação de 1800 RPM e vazão de gás $0 - 3\ Kg/h$.

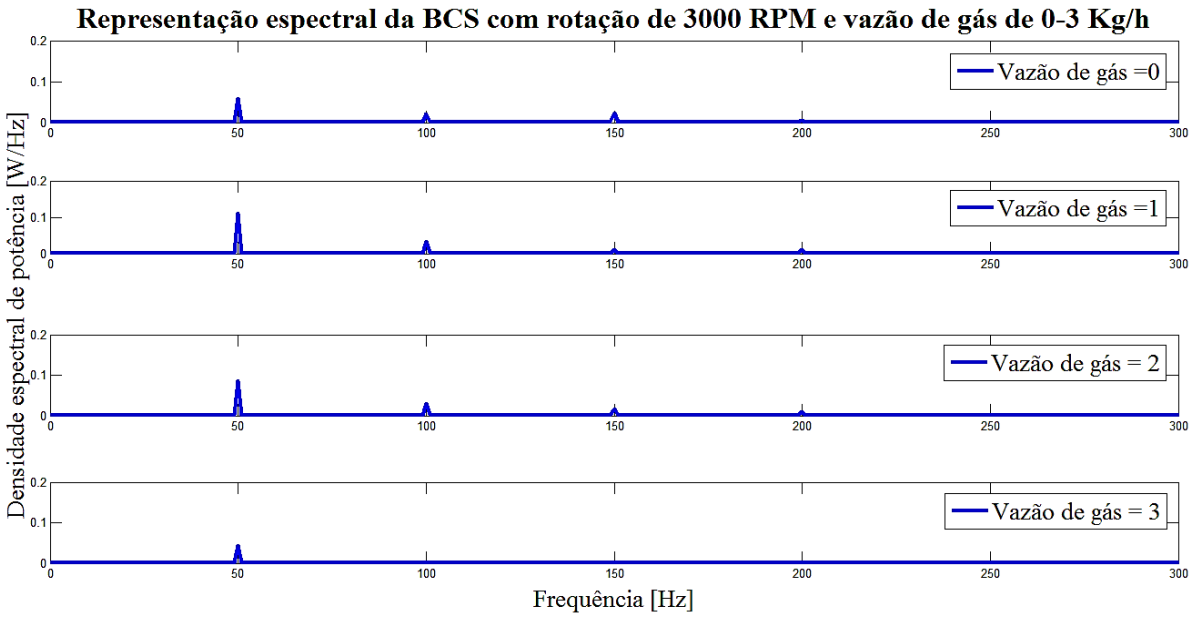

Figura 5.12 Representação espectral da BCS com rotação de 3000 RPM e vazão de gás $0 - 3\ Kg/h$.

1.15.3 Modelos não paramétricos obtidos a partir de SVMR

O método de aprendizagem de máquina de vetores de suporte para regressão (SVMR) foi aplicado com o objetivo de obter um modelo não paramétrico de caixa preta, que estime a vazão de gás numa BCS, a partir de diferentes parâmetros característicos do sistema. Devido aos diferentes sinais adquiridos, podem-se construir diferentes modelos que utilizam diferentes tipos de sinais como entrada. Com esse propósito foram escolhidos, estimados e testados dez diferentes tipos de modelos, que têm distintos conjuntos de amostras de treinamento, como se apresenta na Tabela 5.4.

Tabela 5.4 Amostras de treinamento e saída para cada modelo

Modelo	Amostras de treinamento para SVMR	Saída
1	Representação espectral do sinal de vibração da BCS e a vazão total.	Vazão de gás
2	Representação espectral do sinal de vibração da BCS e torque	Vazão de gás
3	Representação espectral do sinal de vibração da BCS e elevação	Vazão de gás
4	Vazão total e torque	Vazão de gás
5	Vazão total e elevação	Vazão de gás
6	Torque e elevação	Vazão de gás
7	Representação espectral do sinal de vibração da BCS	Vazão de gás
8	Vazão total	Vazão de gás
9	Torque	Vazão de gás
10	Elevação	Vazão de gás

Para a obtenção de todos os modelos primeiramente foram realizados todos os experimentos com as condições inicias do circuito de teste de BCS apresentado na seção 1.15.1 e para cada um dos dados de vibração da carcaça da BCS foi obtido à representação espectral, seguindo a metodologia apresentada na seção 1.12.

Depois para atingir os melhores parâmetros ocultos da SVMR $(C,\ \sigma^2, \varepsilon)$, foram feitos vários testes com o algoritmo genético. Os testes foram realizados para cada um dos dez modelos obtidos (Tabela 5.4), isto com o objetivo de obter o modelo mais representativo para cada conjunto de amostras de treinamento. As configurações do algoritmo genético para cada um dos testes feitos são apresentadas na Tabela 5.5

Tabela 5.5 Configuração do algoritmo genético

Teste	N^o. De Gerações	N^o. De Indivíduos	N^o. De Genes	Probabilidade De Cruzamento	Probabilidade De Mutação
1	100	10	10	50	10
2	500	10	10	50	10
3	1000	10	10	50	10
4	100	100	10	40	20
5	500	100	10	40	20
6	1000	10	10	40	20
7	1000	100	10	60	10
8	50	10	10	60	10

A seguir se apresentam os resultados dos testes realizados com o algoritmo genético para cada dos modelos mostrados na Tabela 5.4, lembrando que as configurações do algoritmo genético são apresentadas na Tabela 5.5. As tabelas dos resultados apresentam os melhores parâmetros ocultos da SVMR, o MSE e o coeficiente de correlação para cada teste obtido.

Estas tabelas de resultados permitem fazer a seleção dos melhores parâmetros ocultos da SVMR. Esta seleção é baseada nas análises do MSE e do coeficiente de correlação, já que o teste que apresenta menor MSE e maior coeficiente de correlação será selecionado para realizar a predição da vazão de gás na BCS a partir de cada uma das amostras de treinamento de cada um dos modelos obtidos.

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo um, obtido a partir do sinal de vibração da BCS (DEP) e

os dados de vazão total do sistema (Q), é mostrado na Tabela 5.6, onde é mostrado o MSE e o coeficiente de correlação para cada um dos testes.

Da Tabela 5.6 se conclui que o teste mais representativo e que apresenta os melhores parâmetros da SVMR é o teste sete. Por tal motivo este é selecionado para realizar a predição da vazão de gás na BCS a partir destas amostras de treinamento (DEP-Q).

Tabela 5.6 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 1 (DEP–Q)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	436.1309	0.042542	0.0008044	0.0208452	0.98652
2	473.162	0.038422	0.023394	0.0233315	0.985202
3	17.3955	0.13342	0.051046	0.0162857	0.987068
4	127.4648	0.064209	0.0002129	0.0201325	0.986039
5	406.3018	0.04245	0.0006127	0.0215538	0.986109
6	16.8369	0.13257	0.0008943	0.0198583	0.984552
7	**20.6982**	**0.12735**	**0.0011065**	**0.0183586**	**0.985736**
8	259.6094	0.76529	0.18766	0.0249491	0.981987

Os resultados dos testes do algoritmo genético para o segundo modelo obtido utilizando como sinais de entrada a do sinal de vibração da BCS (DEP), e os dados de torque da BCS (T) são apresentados na Tabela 5.7. Desta tabela se conclui que o teste mais representativo e que apresenta os melhores parâmetros da SVMR é o teste número sete. Por tal motivo este é selecionado para realizar a predição da vazão de gás na BCS a partir destas amostras de treinamento (DEP-T).

Tabela 5.7 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 2 (DEP–T)

Teste	Parâmetros da SVMR			MSE De Treinamento	Coeficiente De Correlação
	C	σ²	ε		
1	13.7148	0.15637	0.0063324	0.0616903	0.954339
2	409.8184	0.29434	0.049561	0.189912	0.87336
3	381.0254	0.29526	0.04239	0.192379	0.87147
4	15.9092	0.12524	0.0053823	0.0838854	0.936522
5	16.2422	0.1257	9.39E-05	0.0843269	0.936146
6	12.9727	0.13266	0.0055804	0.0779107	0.94084
7	**15.9346**	**0.12549**	**0.0022812**	**0.0844747**	**0.935938**
8	899.417	0.020599	0.20044	0.29559	0.816489

Para o modelo três, obtido a partir de um conjunto de amostras de treinamento composto pela representação espectral do sinal de vibração da BCS (DEP) e da elevação do sistema (E), efetivarem-se os mesmos testes com o algoritmo genético, obtendo assim os seguintes resultados mostrados na Tabela 5.8. Desta tabela pode-se concluir que o teste que apresenta os melhores parâmetros e resultados é o número três. Por tal motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (DEP-E).

Tabela 5.8 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 3 (DEP–E)

Teste	Parâmetros da SVMR			MSE De Treinamento	Coeficiente De Correlação
	C	σ²	ε		
1	427.5488	0.10223	0.03246	0.17529	0.838857
2	868.9893	0.35391	0.000459	0.121131	0.8767

3	**473.7939**	**0.34518**	**0.074518**	**0.102317**	**0.896298**
4	952.9922	0.12671	0.12671	0.165773	0.846495
5	131.0049	0.10788	0.03137	0.179045	0.835184
6	362.6367	0.17523	0.024695	0.145932	0.860707
7	1011.8867	0.054199	0.028274	0.251044	0.785371
8	790.9082	0.5271	0.061536	0.105291	0.89565

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo quatro, obtido a partir dos dados de vazão total do sistema (Q) e os dados de torque (T), é mostrado na Tabela 5.9. Desta tabela são selecionados os parâmetros do teste número dois, para realizar a predição da vazão de gás na BCS a partir destas amostras de treinamento.

Tabela 5.9 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 4 (Q–T)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	253.3418	27.0407	0.23417	0.122834	0.962676
2	**574.6387**	**30.9907**	**0.007884**	**0.076135**	**0.967746**
3	323.7061	2.5895	0.02565	0.385352	0.794546
4	542.9971	2.3485	0.23	0.32145	0.82175
5	346.3789	2.4423	0.13165	0.405873	0.787261
6	102.0166	0.67581	0.079176	0.0626092	0.935823
7	442.8633	0.35736	0.04074	0.0852572	0.91228
8	377.0283	0.23724	0.13019	0.0903028	0.909621

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo cinco, obtido a partir dos dados de vazão total do sistema (Q) e os dados de elevação (E), é mostrado na Tabela 5.10. Desta tabela pode-se concluir que o teste que apresenta os melhores parâmetros e resultados é o número quatro. Por tal

motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (Q-E).

Tabela 5.10 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 5 (Q–E)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	862.3916	0.3645	0.17371	0.0243379	0.981364
2	453.25	0.37164	0.199	0.0262205	0.977987
3	63.6787	2.0262	0.010337	0.015448	0.988204
4	**14.3223**	**1.6673**	**1.6673**	**0.0027186**	**0.997835**
5	958.9482	0.062256	0.036156	0.0290642	0.973901
6	84.4941	2.0132	0.002945	0.0154786	0.988373
7	15.5137	1.5928	0.037672	0.0032255	0.997382
8	1003.4121	0.5209	0.078489	0.0148345	0.987243

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo seis, obtido a partir dos dados de torque (T) e elevação (E), é mostrado na Tabela 5.11. Desta tabela pode-se concluir que o teste que apresenta os melhores parâmetros e resultados é o número dois. Por tal motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (T-E).

Tabela 5.11 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 6 (T–E)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	480.1514	14.5077	0.21961	0.290524	0.867541
2	**55.2373**	**2.1935**	**0.017038**	**0.0582373**	**0.957628**

3	74.5732	2.157	0.001689	0.08208	0.939957
4	419.9189	1.4638	0.000194	0.131895	0.905233
5	310.1367	1.5534	0.000171	0.121403	0.912315
6	453.8496	1.4105	0.00179	0.121277	0.913091
7	391.5742	1.4918	0.000161	0.129205	0.907006
8	518.0098	9.6691	0.027868	0.205894	0.865565

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo sete, obtido a partir só da representação espectral do sinal de vibração da BCS (DEP) é mostrado na Tabela 5.12. Desta tabela pode-se concluir que o teste que apresenta os melhores parâmetros e resultados é o número quatro. Por tal motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (DEP).

Tabela 5.12 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 7 (DEP)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	939.3994	1.0387	0.082227	0.0335462	0.985751
2	4.1201	0.37491	0.098856	0.0267531	0.979687
3	27.5605	0.077759	0.18617	0.0662519	0.958991
4	**4.0615**	**0.46387**	**0.092493**	**0.0227341**	**0.983381**
5	1.3652	0.3291	0.085524	0.0364938	0.973796
6	797.3701	0.46368	0.16897	0.0335603	0.975823
7	1.3906	0.31128	0.091193	0.0378409	0.97246
8	1.1191	0.38748	0.12529	0.0360269	0.976995

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo oito, obtido a partir só dos dados de vazão total (Q) é mostrado na Tabela 5.13. Desta tabela pode-se concluir que o teste que apresenta os

melhores parâmetros e resultados é o número quatro. Por tal motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (Q).

Tabela 5.13 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 8 (Q)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	243.085	23.8771	0.088396	3.77972	0.264653
2	132.6504	27.95	0.23053	1.99958	0.383019
3	114.9063	28.2244	0.23017	1.69332	0.419499
4	**8.7568**	**30.8573**	**0.23944**	**0.930973**	**0.597239**
5	544.6904	18.6309	0.24792	6.84046	0.173505
6	552.1699	17.769	0.20936	5.87611	0.193349
7	779.2969	17.444	0.24066	9.46782	0.135698
8	39.2412	20.2637	0.1979	1.02393	0.594607

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo nove, obtido a partir só dos dados de torque (T) é mostrado na Tabela 5.14 Desta tabela pode-se concluir que o teste que apresenta os melhores parâmetros e resultados é o número seis. Por tal motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (T).

Tabela 5.14 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 9 (T)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	222.0576	31.4477	0.2433	1.76595	0.118913
2	130.4248	28.939	0.22283	0.505886	0.591408

3	380.2734	24.8227	0.15088	3.60741	0.0060937
4	864.7832	20.6908	0.24619	11.7387	0.0875351
5	106.0449	31.6868	0.24614	0.216416	0.785168
6	**777.7852**	**31.4954**	**0.2435**	**0.161045**	**0.830727**
7	31.9404	30.6926	0.24999	0.439125	0.552554
8	999.6221	21.152	0.20358	0.18808	0.805586

Os resultados obtidos do algoritmo genético para a obtenção dos melhores parâmetros ocultos da SVMR para o modelo dez, obtido a partir só dos dados de elevação (E) é mostrado na Tabela 5.15. Desta tabela pode-se concluir que o teste que apresenta os melhores parâmetros e resultados é o número sete. Por tal motivo este teste é selecionado para realizar a predição da vazão de gás na BCS a partir das amostras de treinamento (E).

Tabela 5.15 Parâmetros $(C, \sigma^2, \varepsilon)$e MSE dos testes do algoritmo genético para Modelo 10 (E)

Teste	**Parâmetros da SVMR**			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ²**	**ε**		
1	248.1338	20.8164	0.065623	0.972497	0.420331
2	533.5264	21.5535	0.069262	0.894939	0.421331
3	115.3066	16.5001	0.21036	0.995387	0.41264
4	270.7725	18.7052	0.009585	1.11707	0.366867
5	0.098633	8.3023	0.17761	1.10344	0.498158
6	0.92285	27.6428	0.15162	0.658766	0.647611
7	**903.9834**	**1.2263**	**0.23811**	**0.44138**	**0.710258**
8	644.3975	2.2837	0.18782	0.458096	0.717177

1.15.4 Análise de predição da vazão de gás

Para realizar a análise de predição da vazão de gás para cada um dos modelos obtidos se realizou uma análise de desempenho de cada conjunto de dados e desta forma pode-se avaliar a capacidade de generalização de cada modelo, ou seja, definir qual é o desempenho

do modelo para um conjunto de dados não contemplados no treinamento da obtenção do modelo. Para isto se empregou o conjunto de dados de teste que é o de 20 % dos dados totais do conjunto de dados, o qual é equivalente para estes modelos a 17 dados, as quais mudam para cada caso e para cada modelo.

Para observar o comportamento de generalização de cada um dos dez modelos obtidos se realizou a comparação entre a vazão de gás a identificar e a vazão de gás identificada com o modelo SVMR para cada uma das amostras de teste. A seguir se apresenta os resultados obtidos para cada modelo, mediante um diagrama de barras, onde é possível observar a diferença entre a vazão de gás a identificar apresentada de cor vermelho, e a vazão de gás identificada pelo modelo obtido a partir de uma SVMR apresentada em cor azul, isto para cada amostra de teste.

O primeiro modelo obtido tem como conjunto de amostras de treinamento para a SVMR a representação espectral do sinal de aceleração que representa o regime vibratório da carcaça da bomba e os dados de vazão total do sistema, ou seja, a soma da vazão de ar e a vazão de água. Os resultados deste modelo são apresentados na Figura 5.13.

A partir deste resultado mostrado na Figura 5.13, se pode concluir que os parâmetros ocultos atingidos na Tabela 5.6 para o treinamento da SVMR são adequados já que o modelo obtido tem uma boa estimação da vazão de gás na BCS além de que os dados escolhidos como entradas do sistema apresentam boas características de estimação do comportamento da vazão de gás na BCS, já que o modelo só apresenta um erro de teste de 0.58%, o qual indica que o modelo tem uma boa generalização.

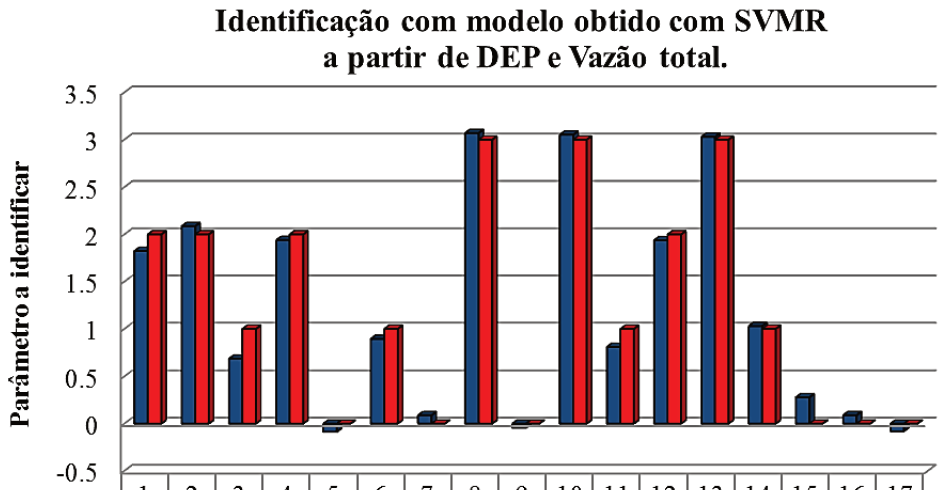

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMr	1.82	2.09	0.68	1.94	-0.1	0.89	0.09	3.07	-0	3.05	0.81	1.94	3.03	1.03	0.28	0.09	-0.1
Vazão de gás a identificar	2	2	1	2	0	1	0	3	0	3	1	2	3	1	0	0	0

Figura 5.13 Resultados do modelo obtido a partir da representação espectral e a vazão total.

O segundo modelo foi obtido a partir de um conjunto de amostras de treinamento composto pela representação espectral do sinal de aceleração que representa o regime vibratório da carcaça da bomba e os dados de torque da BCS. Os resultados deste modelo são apresentados na Figura 5.14. Desta diferença entre a vazão de gás a identificar e a vazão de gás identificada como o modelo SVMR é possível concluir que o modelo obtido proporciona uma boa estimação da vazão de gás na BCS, com erro de teste de 2.79%, portanto podemos dizer que os dados de torque são representativos e influentes para estimar com certa segurança o comportamento da vazão de gás na BCS.

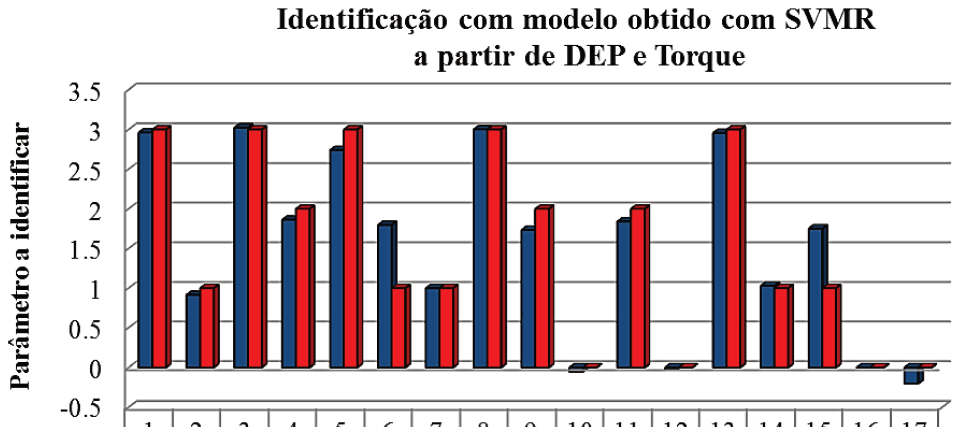

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMr	2.96	0.91	3.03	1.86	2.74	1.8	1	3	1.73	-0	1.84	-0	2.96	1.03	1.75	-0	-0.2
Vazão de gás a identificar	3	1	3	2	3	1	1	3	2	0	2	0	3	1	1	0	0

Figura 5.14 Resultados do modelo obtido a partir da representação espectral e torque.

O terceiro modelo foi obtido a partir de um conjunto de amostras de treinamento composto pela representação espectral do sinal de aceleração que representa o regime vibratório da carcaça da bomba e da elevação do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.15. Desta diferença é possível concluir que o modelo obtido proporciona uma boa estimação da vazão de gás na BCS, mas apresenta um erro maior ainda do que a outros dois modelos apresentados anteriormente, mais o modelo é bom, com um erro de teste de 3.41%.

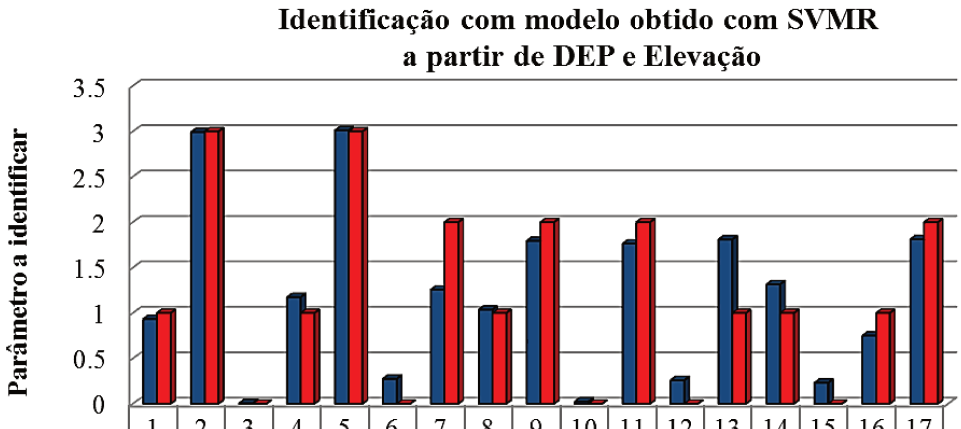

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMr	0.93	2.99	0.01	1.18	3.01	0.27	1.26	1.04	1.8	0.02	1.76	0.26	1.81	1.32	0.23	0.75	1.81
Vazão de gás a identificar	1	3	0	1	3	0	2	1	2	0	2	0	1	1	0	1	2

Figura 5.15 Resultados do modelo obtido a partir da representação espectral e elevação.

O quarto modelo foi obtido a partir de um conjunto de amostras de treinamento composto pela vazão total e o torque do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.16. Destes resultados se pode concluir que a estimação é boa e que o erro de teste é de 2.53%. O que indica que o modelo estima corretamente a vazão de gás com estas amostras de treinamento.

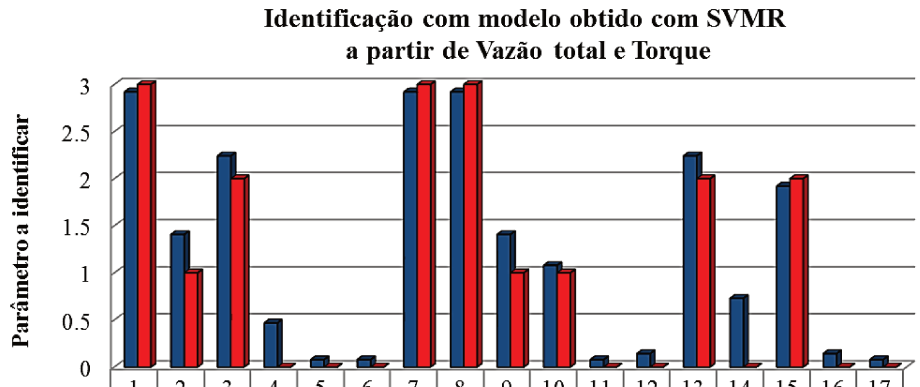

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	2.9	1.4	2.2	0.5	0.1	0.1	2.9	2.9	1.4	1.1	0.1	0.1	2.2	0.7	1.9	0.1	0.1
Vazão de gás a identificar	3	1	2	0	0	0	3	3	1	1	0	0	2	0	2	0	0

Figura 5.16 Resultados do modelo obtido a partir da vazão total e torque.

O quinto modelo foi obtido a partir de um conjunto de amostras de treinamento composto pela vazão total e elevação do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.17. Destes resultados se pode concluir que a estimação é muito boa já que o erro de teste é de 0.09%. A partir de este resultado de erro de teste se pode dizer que estas amostras de treinamento são as que representam melhor o comportamento da vazão de gás nesta BCS, já que apresentam uma boa generalização de dados.

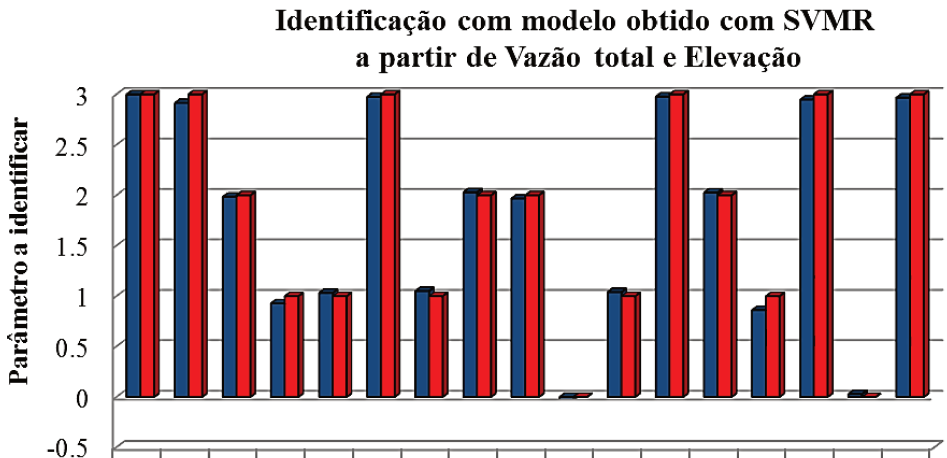

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	3	2.92	1.99	0.93	1.03	2.98	1.05	2.03	1.97	-0	1.04	2.98	2.03	0.86	2.95	0.03	2.97
Vazão de gás a identificar	3	3	2	1	1	3	1	2	2	0	1	3	2	1	3	0	3

Figura 5.17 Resultados do modelo obtido a partir da vazão total e elevação

O sexto modelo foi obtido a partir de um conjunto de amostras de treinamento composto pelos dados de torque e elevação do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.18. Destes resultados se pode concluir que a estimação é boa já que o erro de teste é de 1.94%.

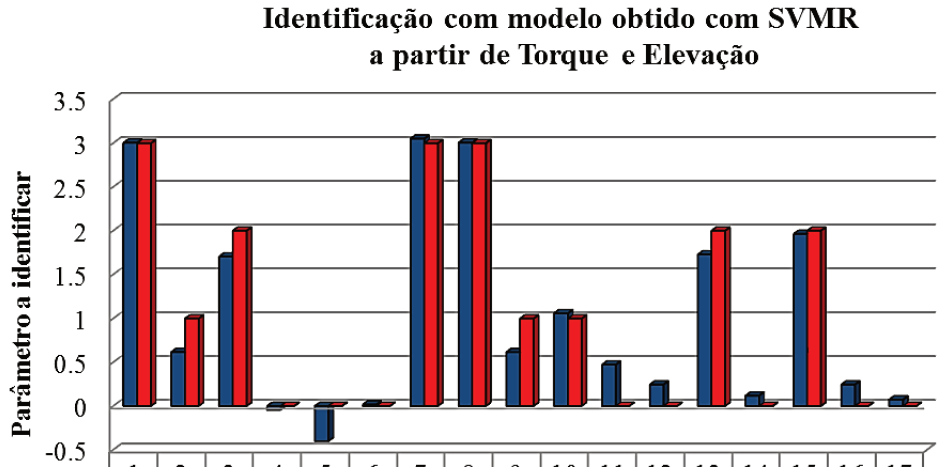

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	3	0.62	1.7	-0	-0.4	0.02	3.05	3.01	0.62	1.06	0.47	0.25	1.73	0.12	1.96	0.25	0.07
Vazão de gás a identificar	3	1	2	0	0	0	3	3	1	1	0	0	2	0	2	0	0

Figura 5.18 Resultados do modelo obtido a partir do torque e elevação.

O sétimo modelo foi obtido a partir de um conjunto de amostras de treinamento composto pelos dados da representação espectral do sinal de vibração do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.19. Destes resultados se pode concluir que a estimação é boa já que o erro de teste é de 0.89%. Além de isto se pode dizer que só com os dados de vibração se pode caracterizar o comportamento da vazão de gás na BCS, obtendo assim um modelo com bons resultados de generalização.

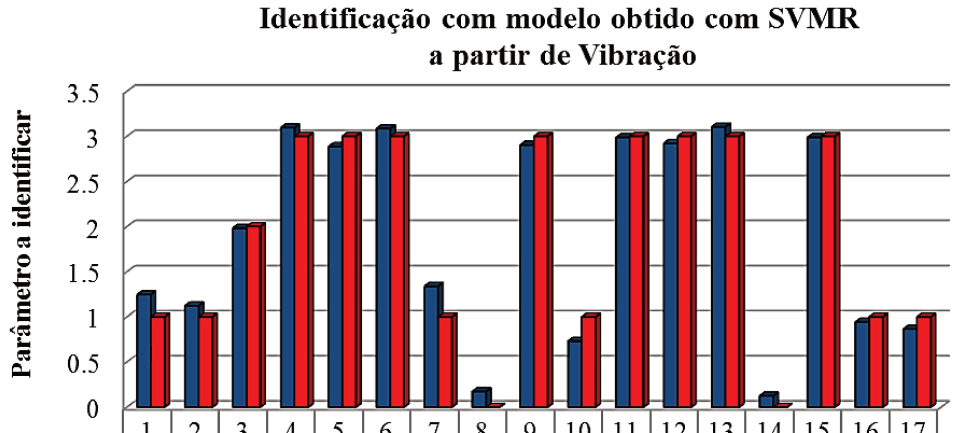

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	1.25	1.12	1.98	3.1	2.89	3.09	1.34	0.17	2.9	0.73	2.99	2.92	3.11	0.12	2.99	0.95	0.87
Vazão de gás a identificar	1	1	2	3	3	3	1	0	3	1	3	3	3	0	3	1	1

Figura 5.19 Resultados do modelo obtido a partir da representação espectral do sinal de vibração do sistema.

O oitavo modelo foi obtido a partir de um conjunto de amostras de treinamento composto pelos dados da vazão total do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.20. Destes resultados se pode concluir que a estimação não é boa já que o erro de teste é de 31%. A partir desde erro de teste se pode dizer que os dados de vazão total não conseguem caracterizar bem o comportamento da vazão de gás na BCS.

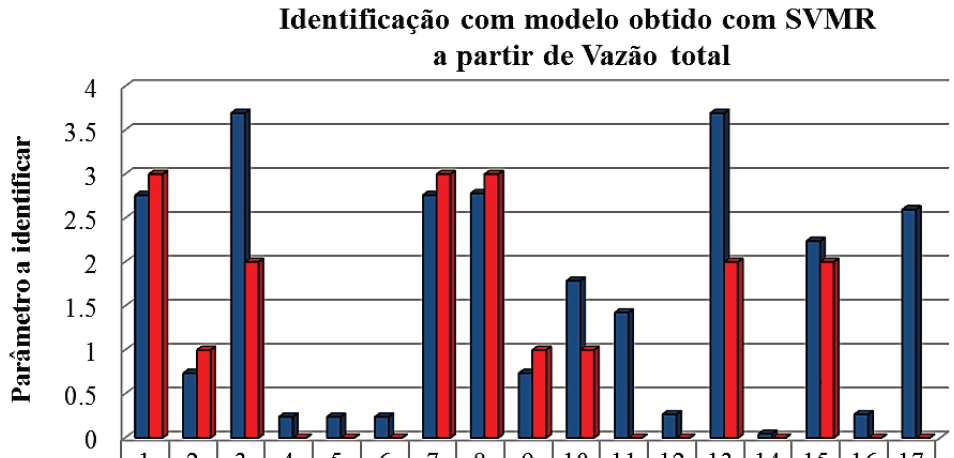

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	2.76	0.73	3.69	0.24	0.24	0.24	2.76	2.78	0.73	1.79	1.42	0.27	3.69	0.04	2.24	0.27	2.6
Vazão de gás a identificar	3	1	2	0	0	0	3	3	1	1	0	0	2	0	2	0	0

Figura 5.20 Resultados do modelo obtido a partir da vazão total.

O nono modelo foi obtido a partir de um conjunto de amostras de treinamento composto pelos dados de torque do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.21. Destes resultados se pode concluir que a estimação é boa já que o erro de teste é de 5.36%. Além de isto se pode dizer que os dados de torque conseguem representar o comportamento da vazão de gás na BCS.

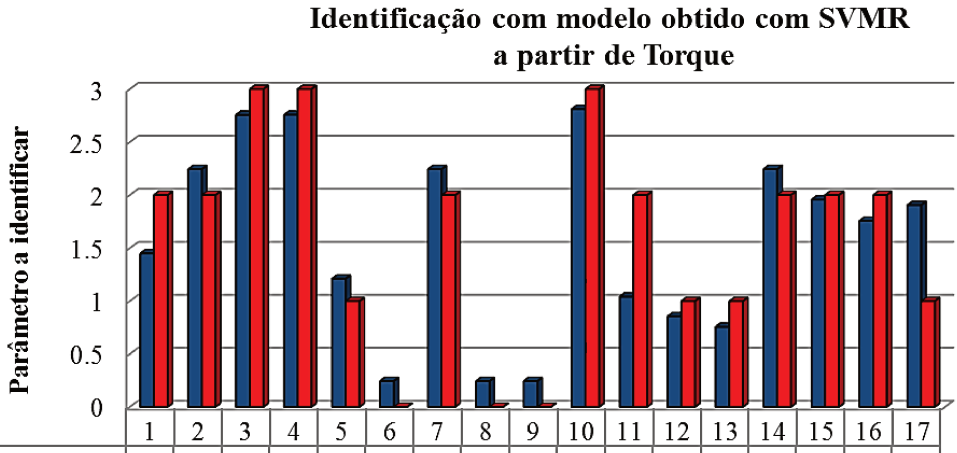

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	1.45	2.24	2.76	2.76	1.21	0.24	2.24	0.24	0.24	2.81	1.04	0.86	0.76	2.24	1.96	1.76	1.9
Vazão de gás a identificar	2	2	3	3	1	0	2	0	0	3	2	1	1	2	2	2	1

Figura 5.21 Resultados do modelo obtido a partir do torque.

O décimo modelo foi obtido a partir de um conjunto de amostras de treinamento composto pelos dados de elevação do sistema. Os resultados do modelo obtido a partir deste conjunto de amostras são apresentados na Figura 5.22. Destes resultados se pode concluir que a estimação não é boa já que o erro de teste é de 15%. Além de isto se pode dizer que os dados de elevação não conseguem representar bem o comportamento da vazão de gás na BCS.

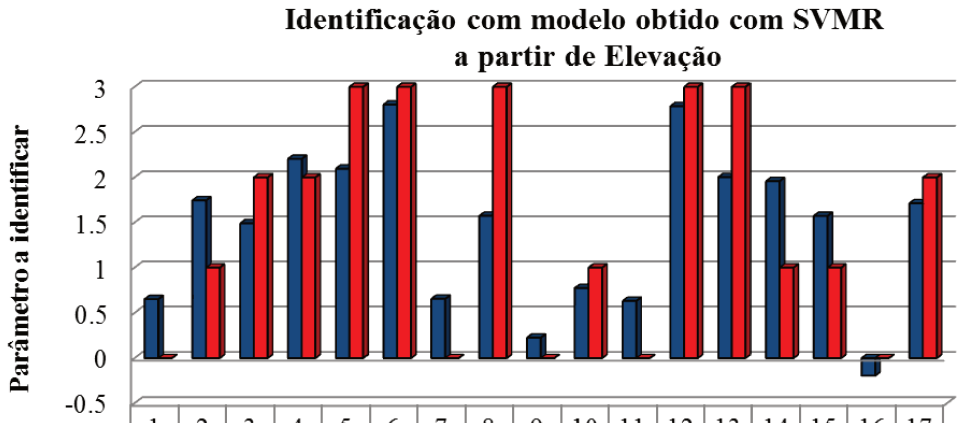

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17
Vazão de gás identificada com modelo SVMR	0.65	1.74	1.49	2.2	2.1	2.81	0.65	1.57	0.22	0.77	0.63	2.79	2	1.96	1.57	-0.2	1.71
Vazão de gás a identificar	0	1	2	2	3	3	0	3	0	1	0	3	3	1	1	0	2

Figura 5.22 Resultados do modelo obtido a partir da elevação.

1.15.5 Análise de predição da vazão de gás sem todos os dados de treinamento

Com o objetivo de avaliar o desempenho da SVMR quando não se contam com todos os dados de treinamento que caracterizem o sistema de interesse (BCS), se obteve um modelo com um conjunto de treinamento composto pela densidade espectral de vazão de gás igual a $0\ kg/h$, $1\ kg/h$ e $3\ kg/h$ respectivamente e vazão total do sistema para as mesmas condições de vazão de gás, ou seja, não se levou em conta para o conjunto de amostras de treinamento da SVMR a representação espectral e vazão total da BCS para quando a vazão de gás é igual a $2\ kg/h$. Os resultados deste modelo são apresentados na Figura 5.23.

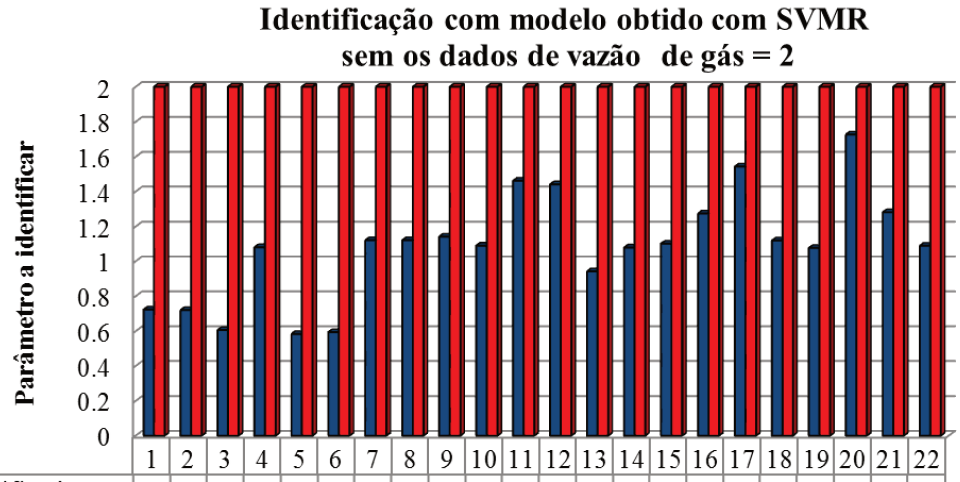

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22
Vazão de gás identificada com modelo SVMr	0.7	0.7	0.6	1.1	0.6	0.6	1.1	1.1	1.1	1.1	1.5	1.4	0.9	1.1	1.1	1.3	1.5	1.1	1.1	1.7	1.3	1.1
Vazão de gás a identificar	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2

Figura 5.23 Resultados do modelo obtido a partir da representação espectral e da vazão total, mas sem os dados de vazão de gás igual a 2 kg/h

Na Figura 5.23 se observam os dados da vazão de gás a estimar, em cor vermelho e os dados da vazão de gás estimada com o modelo obtido sem todos os dados de treinamento, em cor azul. Com estes resultados se quer avaliar a capacidade de generalização deste modelo, para isto se empregou um conjunto de dados de teste que é o 20 % dos dados totais do conjunto de dados, o qual é equivalente para este modelo a 22 dados. A partir destes resultados se pode concluir que a estimação não é boa já que o erro de teste é de 30.77 %. Além disso, é observável que quando não se tem todos os dados de treinamento e este conjunto de dados não é suficientemente representativo, o modelo obtido com SVMR não atinge a estimação do parâmetro de interesse, e com isto concluímos que os modelos obtidos com SVMR não apresentam bons resultados de generalização quando se deseja fazer interpolações muito grandes, mas quando a interpolação é pequena e o conjunto de dados é representativo à variável a estimar, como a do exemplo 2 apresentado na seção 1.14.2, os modelos obtidos por SVMR atingem muito bem a estimação de parâmetros.

1.15.6 Comparação dos resultados

A fim de avaliar o desempenho de cada um dos modelos obtidos, foi realizada uma análise do erro quadrático médio MSE e do coeficiente de correlação de cada um dos

modelos. Na Tabela 5.16Tabela 5.16 se apresentam os melhores parâmetros para à SVMR, o MSE e o coeficiente de correlação para cada um dos modelos.

Tabela 5.16 Parâmetros e MSE dos modelos obtidos pelo método de SVMR para identificação da vazão de gás na BCS.

	Parâmetros da SVMR			**MSE De Treinamento**	**Coeficiente De Correlação**
	C	**σ^2**	**ε**		
Modelo 1 (DEP e Q)	20.6982	0.12735	0.0011065	1.84E-02	0.985736
Modelo 2 (DEP e T)	13.7148	0.15637	0.0063324	6.16E-02	0.954339
Modelo 3 (DEP e E)	473.7939	0.34518	0.074518	0.102317	0.896298
Modelo 4 (Q e T)	574.6387	30.9907	0.078848	0.076135	0.967746
Modelo 5 (Q e E)	**14.3223**	**1.6673**	**1.6673**	**0.0027186**	**0.997835**
Modelo 6 (T e E)	55.2373	2.1935	0.017038	0.0582373	0.957628
Modelo 7 (DEP)	4.0615	0.46387	0.092493	0.0227341	0.983381
Modelo 8 (Q)	8.7568	30.8573	0.23944	0.930973	0.597235
Modelo 9 (T)	777.7852	31.4954	0.2435	0.161045	0.830727
Modelo 10 (E)	903.9834	1.2263	0.23811	0.44138	0.710258
Modelo 11 (DEP e Q)	804.417	0.29169	0.15278	9.23E-01	0

Da Tabela 5.16 se conclui que o modelo com melhores resultados é o modelo cinco obtido a partir da vazão total e elevação, já que apresentou um erro quadrático médio de 0.0027186 e um coeficiente de correlação de 0.997835. A partir destes resultados e dos resultados obtidos na seção 1.15.4 podemos estabelecer que todos os dados experimentais proporcionam boa informação da mudança da vazão de gás na bomba, já que os erros de teste são bons para a maioria dos modelos obtidos, e que quando não se tem um bom conjunto de dados de treinamento para à SVMR o modelo obtido não apresenta bons resultados na estimação.

Capítulo 6. Conclusões e recomendações de trabalhos futuros

1.16 Conclusões

Bombas centrífugas submersas (BCS) são geralmente utilizadas em sistemas de produção de óleo e gás. Estas bombas apresentam falhas frequentes prematuras quando por falta de informação do tipo de escoamento bifásico operam com alta vazão de gás. Devido a este fato, existe a necessidade real de se obter um modelo matemático que estime a quantidade de gás sendo bombeada informando se está fora ou dentro do ponto de operação seguro da bomba. Neste trabalho se implementou uma metodologia de identificação de sistemas com a finalidade de se obter um modelo que permita estimar a vazão de gás neste tipo de sistemas.

O principal objetivo deste trabalho foi o de apresentar um modelo não paramétrico baseado no método de aprendizagem de máquina de vetores de suporte, que foi estudado e aplicado ao sistema (BCS), mostrando a possibilidade do uso de algoritmos de aprendizagem de máquina para se obter um modelo que estime a vazão de gás no sistema a partir de dados experimentais.

Este estudo levou às seguintes conclusões:

1. Obtiveram-se diferentes modelos não paramétricos mediante algoritmos de aprendizagem de máquinas SVMR, que estimam a vazão de gás numa BCS, baseados em diversos dados experimentais como: análises de vibração, vazão total, torque e elevação às quais foram definidas como as entradas do sistema a identificar.
2. Definiram-se quais são as frequências particulares de vibração do sistema BCS, mediante a análise da taxa de variação dos sinais adquiridos, concluindo-se que as frequências particulares do sistema mudam de acordo as condições iniciais de rotação da BCS.
3. Estabeleceu-se que os dados mais representativos a mudança do parâmetro de interesse (vazão de gás) são a vazão total de fluido na BCS e a elevação, já que o modelo obtido com estas amostras de treinamento apresentou um MSE de treinamento de 0.0027186 e um coeficiente de correlação de 0.997835.

4. Os modelos obtidos a partir de SVMR tem melhor desempenho quando a quantidade de dados de treinamento é significativamente representativa ao comportamento do sistema e não é limitada.
5. Os parâmetros de treinamento da máquina de vetores para regressão foram estimados mediante o desenvolvimento de um algoritmo genético, garantindo assim que o modelo obtido tem a melhor representação do sistema.

1.17 Recomendações de trabalhos futuros

Baseados nos resultados deste trabalho são sugeridos algumas recomendações para trabalhos futuros.

- Para ter uma melhor precisão na estimação da vazão de gás na BCS mediante o modelo obtido, se sugere ter um maior número de amostras experimentais de entrada e saída do sistema aumentando deste modo o desempenho dos vetores de suporte para regressão.
- Realizar testes de desempenho do modelo. Um destes testes pode ser trocando o fluido na bomba e assim efetuar uma comparação do comportamento do gás na bomba verificando se o modelo obtido inicialmente com o primeiro fluído estima corretamente o parâmetro desejado. Outro teste seria de testar uma outra bomba com as mesmas características nas mesmas condições de ensaio realizadas e utilizar o modelo desenvolvido para predizer o comportamento do gás na bomba.
- Estimar os parâmetros de treinamento do SVM com outros métodos de otimização.
- Efetuar estudos e implementações com métodos de identificação paramétrica.
- Desenvolver modelos de identificação com outros algoritmos de aprendizagem de máquinas como redes neurais, regressões polinomiais entre outros e fazer uma comparação de resultados.

Referências Bibliográficas

AGUIRRE, L.A, Introdução à identificação de sistemas técnicas lineares e não lineares aplicadas a sistemas reais, 2 Ed, Editorial UFMG, 2000.

ANDERSON, B.D.O, MOORE, J.B, HAWKES, R.M, Model approximations via prediction error identification, Automatica, Vol. 14, Issue 6, pp. 615-622,1978.

ASTROM, K . J, BOHLIM T , Numerical identification of linear dynamic systems from normal operating records, Theory of self-adaptive control system, pp. 1-96, 1966.

BAGLEY, J.D, The behavior of adaptive systems which employ genetic and correlation algorithms, PhD Thesis, University of Michigan, 1967.

BLACKMAN, R., TUKEY, J., Measurement of power spectral dover, New York, From the point of view of communication engineering, 1958.

BRAUN, S., EWINS, D.,RAO, S., Encyclopedia of vibration. Vol. 1 pp. 673-685, 2001

BOX, G. E. P. and PIERCE D. A., Distribution of residual autocorrelations in autoregressive – integrated moving average time series models, Journal of the American statistical association, Vol. 65, No. 332, pp. 1509 – 1526, 1970

CHAPMAN, C. D., SAITOU, K., JAKIELA, M., Genetic algorithms as an approach to configuration and topology design, ASME Journal of mechanical design, vol. 116, pp. 1005-1012, 1994.

COLLOBERT, R., BENGIO, S., SVMTorch: Support vector machines for large - scale regression problems, J. Machine Learning Res., Vol.1 pp. 143-160, 2001.

DIETTERICH, T., Learning at the knowledge level, J. Machine Learning., Vol. 1 pp. 287-315,1986.

FASSOIS, SPILIOS D.,SAKELLARIOU, J.,T., Time-series methods for fault identification and identification in vibrating structures. Philosophical transactions A, the royal society, pp. 411-448, 2007.

GAGO, M. F. A. Modelo de Juntas Soldadas por FSW utilizando Métodos de Aprendizagem de Máquina através de Dados Experimentais. Campinas: Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Dissertação (Mestrado), 2013.

GEVERS, M., A personal view on the development of system identification, A 30- year journey through an exciting field, Control systems, IEEE, Vol. 26, Issue 6, pp. 93-105,2006.

GOLDBERG, D., Genetic algorithms in search, optimization, and machine learning 1st, Addison-Wesley, Logman publishing Co, 1989.

HO, B.L, KALMAN,R.E, Effective construction of linear state – variable models from input – out functions, NTRS,1965.

HOLLAND, J. H, Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence, Oxford, England: U Michigan Press. VIII 183pp. 1975.

LJUNG, L., System identification, theory for the user. Pretince Hall PTR, second edition, 1999.

MARTIN, M . On – line support vector machines for function approximation. Technical report, , Universidat Politècnica de Catalunya, Departament de Llengatges i sistemes informatics, 2002.

MIRANDA, G., P., Estudo experimental sobre bomba centrífuga operando com fluido viscoso e escoamento bifásico gás líquido, Dissertação de mestrado FEM/UNICAMP, 2013.

MONTE, W., V., Estudo experimental de bombas de BCS operando com escoamento bifásico Gás-líquido, Dissertação de mestrado FEM/UNICAMP, 2011.

NG, ANDREW, Introduction to Machine Learning. Machine learning Course, Coursera based into Standford University, 2012.

NELLES, O., Nonlinear system identification, Springer-Verlag Berlin Heidelberg, 2001.

OSUMA, E., FREUND, R., GIROSI, F, An improved training algorithm for support vector machines, Neural Networks for Signal Processing VII. Proceedings of the 1997 IEEE Workshop, pp 276-285, 1997.

PARDO, M., Estudo de uma bomba centrífuga submersa (BCS) como medidor de vazão, Dissertação de mestrado, FEM/UNICAMP, 2013.

PLATT, J.C, Fast training of support vector machines using sequential minimum optimization, Advances in Kernel methods – support vector learning, MIT Press Cambridge, MA, USA, pp. 185-208, 1999.

RESENDIZ, J. A., Las máquinas de vectores de soporte para identificación en línea, Centro de investigación y de estudios avanzados del instituto politécnico nacional, departamento de control automático, tesis de maestría en ciencias, México, 2006.

RIBEIRO M.P., SILVA P.,MATOS J. S., SILVA J.E., Field applications of subsea electrical submersible pumps in Brazil, Offshore technology conference, Houston Texas, 2005.

RIBEIRO M.P., Testes de integração (*string test*) de conjunto de BCS. Comunicação técnica Petrobras, CT/TEE060/11, 2011.

RODRÍGUEZ, R. D, BORDÓNS, A.C, Análisis y control de sistemas em espacio de estado, identificación de sistemas, control adaptativo, control predictivo, Apuntes de Ingeniería de control, 2005.

RYCHETSKY, M. Algorithms and Architectures for machine learning based on regularized neural networks and support vector approaches, Shaker Verlag GmbH, Germany, 2001.

SABZEKAR, M., NAGHIBZADEH, M., SADOGHI, H., EFFATI S. Emphatic constraints support vector machines for Multi-class classification. Computer Modeling and Simulation 2009. EMS'09 Third UKSim European Symposium, pp. 118-123, 2009.

SAINI, L. M., AGGARWAL, S.K., KUMAR,A., Parameter optimisation using genetic algorithm for support vector machine based price – forecasting model in national electricity markert, Generation, transmission & distribution, IET, Vol. 4, pp 36 - 49,2010.

SMITH, J.L, Genetic algorithms, Handbook of global optimization, Vol. 2, pp 275 – 362, 2002.

SMOLA, J, S. SCHOLKOPF, B. A tutorial on support vector regression, Kluwer Academic Publishers. Manufactured in the Netherlands, Statistics and computing 14, pp 199-222, 2004

SOUZA, C., Simulação do escoamento monofásico em um estágio de uma bomba centrífuga utilizando técnicas de fluidodinâmica computacional. Tese de doutorado, UFRN, 2010.

STONEAN R., DUMITRESCU D., PREUSS M., Evolutionary support vector regression machines, Symbolic and Numeric Algorithms for Scientific Computing, 2006. SYNASC '06. Eighth International Symposium, pp. 330-335, 2006.

TAKACSM, G., Electrical submersible pumps manual: design, operations, and maintenance. 1ed. Gulf Professional publishing, 2009.

VAPTNIK, V. N, The nature of statical learning theory, Springer Verlag New York,Wiley,p 189 1995.

VAPTINIK,V.N, GOLOWICH, S., and SMOLA, A. Support vector method for function approximation regression, estimation, and signal processing, Mozer M, Jordam m, petschet, editors, Advances in neural information processing systems 9, pp. 281-287, 1997.

WELLSTEAD, P., Non-parametric methods of system identification, Automatica ,Vol.17, Issue 1, pp. 55-59,1981.

YU, Q., LIU, Y., RAO F. Parameter selection of support vector regression machine based on differential evolution algorithm. Fuzzy Systems and Knowledge Discovery, 2009. FSKD '09. Sixth International Conference, pp. 596-598, 2009.

ZHANG, H., LEI Y., BSP- based support vector regression machine parallel framework, Computer and Information Science (ICIS), 2013 IEEE/ACIS 12th International Conference, pp. 329-334, 2013

ZHENYUE, H., CONGLI, M., Soft sensor modeling using SVR based on genetic algorithm and akaike information criterion, intelligent human-machine systems and cybernetics, 2009. IHMC’09. International conference, Vol. 2, pp. 123-127, 2009.