



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Mecânica

GERMAN EFRAIN CASTAÑEDA JIMENEZ

Controle Especialista Aplicado ao Bombeio Centrífugo Submerso

CAMPINAS

2019

GERMAN EFRAIN CASTAÑEDA JIMENEZ

Controle Especialista Aplicado ao Bombeio Centrífugo Submerso

Tese apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Doutor em Engenharia Mecânica, na Área de Mecatrônica.

Orientador: Prof. Dr. Janito Vaqueiro Ferreira

ESTE TRABALHO CORRESPONDE À VERSÃO FINAL DA TESE DEFENDIDA PELO ALUNO GERMAN EFRAIN CASTAÑEDA JIMENEZ, E ORIENTADA PELO PROF. DR. JANITO VAQUEIRO FERREIRA.

CAMPINAS

2019

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Luciana Pietrosanto Milla - CRB 8/8129

C274c Castañeda Jimenez, German Efrain, 1988-
Controle especialista aplicado ao bombeio centrífugo submerso / German Efrain Castañeda Jimenez. – Campinas, SP : [s.n.], 2019.

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

1. Bomba centrífuga submersa. 2. Sistemas especialistas. 3. Algoritmos genéticos. 4. Controle automático. I. Ferreira, Janito Vaqueiro, 1961-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Expert control applied to electric submersible pumps

Palavras-chave em inglês:

Electric submersible pump

Expert systems

Genetic algorithms

Automatic control

Área de concentração: Mecatrônica

Titulação: Doutor em Engenharia Mecânica

Banca examinadora:

Janito Vaqueiro Ferreira [Orientador]

Romis Ribeiro de Faissol Attux

João Antonio Pereira

Marcos Pellegrini Ribeiro

Euripedes Guilherme de Oliveira Nobrega

Data de defesa: 16-12-2019

Programa de Pós-Graduação: Engenharia Mecânica

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0003-3886-0914>

- Currículo Lattes do autor: <http://lattes.cnpq.br/2295152819478386>

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

TESE DE DOUTORADO ACADÊMICO

Controle Especialista Aplicado ao Bombeio Centrífugo Submerso

Autor: German Efrain Castañeda Jimenez

Orientador: Prof. Dr. Janito Vaqueiro Ferreira

A Banca Examinadora composta pelos membros abaixo aprovou esta Tese:

Prof. Dr. Janito Vaqueiro Ferreira

DMC/FEM/UNICAMP

Prof. Dr. Romis Ribeiro de Faissol Attux

DCA/FEEQ/UNICAMP

Dr. João Antonio Pereira

FEIS/UNESP

Dr. Marcos Pellegrini Ribeiro

Cenpes-Petrobrás

Prof. Dr. Euripedes Guilherme de Oliveira Nobrega

DMC/FEM/UNICAMP

A Ata de Defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

Campinas, 16 de Dezembro de 2019.

Dedico este trabalho a meus pais, German Castañeda e Amparo Jimenez, por ter-me guiado pelo caminho do sucesso e as minhas irmãs Carolina e Lorena pelo apoio.

AGRADECIMENTOS

A Deus pela oportunidade.

A meu orientador Prof. Dr. Janito Vaqueiro Ferreira, pelo apoio, pela dedicação e pelos conselhos ao longo do projeto.

A minha família pelo apoio constante, independentemente da distância. Aos meus pais e minhas irmãs agradecimentos infinitos, que me apoiaram em cada momento desta etapa na minha vida.

Aos meus amigos, Oscar Rojas, Beto, Suranny Jimenez, Ramiro Chamorro, Bernardo e demais amigos no Brasil e no exterior que fizeram parte deste processo. Um agradecimento especial e com grande carinho a Paola Gonzalez pela companhia e sua amizade incondicional.

A todos os professores e colegas do DMC e do LabeDIM da FEM, que ajudaram de forma direta e indireta na conclusão deste trabalho.

Principalmente quero agradecer à minha companheira de aventura Diana Martinez, por seu apoio, paciência, amor, por sua amizade, e por ser a força de meu dia a dia, a motivação, por ser minha fonte de inspiração e alegria nesta etapa de minha vida.

À Universidade Estadual de Campinas por fornecer um local para o desenvolvimento de meu projeto, ao programa de estudante-convênio de Pós-Graduação (PEC-PG) e ao Cenpes-Petrobrás pelo apoio econômico.

*“Tudo deveria se tornar o mais simples possível,
mas não simplificado.”
(Albert Einstein)*

*“O entusiasmo é a maior força da alma.
Conserva-o e nunca te faltará poder
para conseguires o que desejas.”
(Napoleão Bonaparte)*

RESUMO

Na indústria do petróleo, é comum o uso de bombas centrífugas submersas (BCS) para elevar o óleo até a superfície. Normalmente as bombas BCS operam com fluido bifásico “gás-líquido”. A presença de grandes quantidades de gás dentro da bomba gera instabilidades que deterioram o desempenho da bomba, o que pode causar até mesmo a interrupção da produção. Assim, nesta pesquisa, utilizou-se um controle especialista que tem como núcleo um sistema complexo adaptativo, o qual a partir da experiência pode gerar conhecimento sobre o funcionamento da BCS. Deste modo, o sistema especialista pode ser capaz de controlar o sistema BCS mantendo-o numa condição estável. Baseado em um modelo não-linear de uma BCS, que representa o comportamento da bomba operando com vazão bifásica, foi treinado um sistema especialista usando um algoritmo genético que gera um conjunto de regras (conhecimento adquirido) que com o tempo controlará e manterá o sistema BCS em condições operacionais seguras. No início do treinamento, o sistema de controle criado por algoritmos genéticos gerou comportamentos erráticos. No entanto, ao longo do tempo, o sistema especialista começou a entender o desempenho do sistema BCS, levando-o para condições estáveis. Além disso, se colocarmos o sistema BCS em condições instáveis, o sistema de controle o coloca de volta em condições seguras. O controle especialista, através do conhecimento adquirido com a experiência, possibilita manter uma BCS trabalhando com fluidos bifásicos em condições estáveis, o que permite evitar danos e paradas repentinas do equipamento durante a produção de petróleo.

Palavras-chaves: Bomba Centrífuga Submersa; Sistemas Especialistas; Algoritmos Genéticos; Sistema de Controle; Sistemas Complexos Adaptativos.

ABSTRACT

In the oil industry, it is common to use electric submersible pumps (ESP) to lift oil to the surface. It is usual for ESP to operate with biphasic fluid flow “gas-liquid”. The presence of large amounts of gas within the pump generates instabilities and a deterioration in the performance of the pump, which can even cause production to be interrupted. Thus, in this research we aimed to use a control system, which has as its core an adaptive complex system, to generate knowledge about the operation of the ESP. In this way the expert system was able to control the ESP keeping it in the best possible condition. Based on a nonlinear model of an ESP, which represents the behavior of the pump operating with two-phase flow, has trained an expert system using a genetic algorithm that generate a set of rules (acquired knowledge) that over time would control and maintain the ESP in safe operating conditions. At the beginning of the training, the expert system created by genetic algorithms generated erratic behaviors. However, over the time, the expert system began to understand the performance of the ESP system and set it to stable conditions. Furthermore, if the ESP system starts to operate in unstable conditions, the control system sets it back within safe conditions. The expert control, through acquired knowledge with experience, may keep an ESP that is working with biphasic fluids in stable condition, which avoids equipment damage sudden stops during the oil production.

Keywords: Electric Submersible Pump; Expert System; Genetic Algorithms; Control System; Adaptive Complex System.

LISTA DE ILUSTRAÇÕES

| | |
|---|----|
| Figura 1.1 – Arquitetura da proposta | 24 |
| Figura 2.1 – Estágio de BCS. | 26 |
| Figura 2.2 – Representação das curvas de desempenho. | 27 |
| Figura 2.3 – Representação das curvas de desempenho de elevação com escoamento multifásico. | 28 |
| Figura 2.4 – Representação das curvas de desempenho de eficiência com escoamento multifásico. | 29 |
| Figura 2.5 – Representação das curvas de desempenho de potência com escoamento multifásico. | 29 |
| Figura 2.6 – Estrutura básica de um sistema com realimentação | 30 |
| Figura 2.7 – Passos básicos para o desenvolvimento de um sistema de controle. | 32 |
| Figura 2.8 – Diagrama de blocos de um PID industrial com heurística. | 35 |
| Figura 2.9 – Diagrama de um sistema especialista baseado em regras. | 37 |
| Figura 2.10–Sistema classificador interagindo com o ambiente. | 39 |
| Figura 2.11–Subsistemas do sistema classificador interagindo com o ambiente. | 41 |
| Figura 2.12–Diagrama de fluxo do subsistema de tratamento de regras e mensagens. | 41 |
| Figura 2.13–Diagrama de fluxo do subsistema de apropriação de crédito. | 42 |
| Figura 2.14–Diagrama de fluxo do subsistema de descoberta de novas regras. | 44 |
| Figura 2.15–Diagrama de fluxo do algoritmo genético. | 45 |
| Figura 2.16–Ilustração de um cromossomo. | 46 |
| Figura 2.17–Exemplo do mapeamento da função fitness | 47 |
| Figura 2.18–Seleção método da roleta | 49 |
| Figura 2.19–Exemplo de crossover com n pontos de corte. | 50 |
| Figura 2.20–Exemplo de mutação simples. | 50 |
| Figura 2.21–Problema de regressão linear com SVM. | 53 |
| Figura 2.22–Mapeamento de alta dimensionalidade. | 56 |
| Figura 3.1 – Representação da malha de controle para o sistema BCS. | 57 |
| Figura 3.2 – Arquitetura proposta para o controlador especialistas. | 58 |
| Figura 3.3 – Atividades básicas para o processo de identificação. | 60 |
| Figura 3.4 – Diagrama de blocos do modelo da BCS. | 60 |
| Figura 3.5 – Bias e Variância com Respeito aos Modelos. | 61 |
| Figura 3.6 – Diagrama esquemático da bancada do LabVIP. | 64 |
| Figura 3.7 – Diagrama de blocos do algoritmo de predição. | 64 |
| Figura 3.8 – Diagrama de blocos para a função de transição de estados. | 65 |
| Figura 3.9 – Diagrama de blocos do sistema complexo adaptativo. | 66 |
| Figura 3.10–Gráfico de áreas de reconmpesa | 70 |

| | |
|---|-----|
| Figura 3.11–Diagrama de blocos do sistema supervisorio. | 72 |
| Figura 3.12–Interface usuário máquina do sistema especialista. | 74 |
| Figura 4.1 – Curva de desempenho do ΔP empregando modelos SVMr | 76 |
| Figura 4.2 – Curva de desempenho de W_m empregando modelos SVMr | 77 |
| Figura 4.3 – Curva de desempenho do η empregando modelos SVMr | 77 |
| Figura 4.4 – Desempenho filtro de partículas. | 79 |
| Figura 4.5 – Desempenho filtro de partículas associado à abertura da válvula choke. | 80 |
| Figura 4.6 – Trajetórias tomadas pelo sistema de controle para sair da operação em <i>surging</i> | 82 |
| Figura 4.7 – Evolução do erro do sistema de controle na Simulações 1 com 2% e 4% de fração de vazio. | 83 |
| Figura 4.8 – Trajetórias tomadas pelo sistema de controle para sair de altas rotações. | 85 |
| Figura 4.9 – Evolução do sistema de controle na simulação 2. | 86 |
| Figura 4.10–Trajetórias tomadas pelo sistema de controle para sair de baixas rotações. | 88 |
| Figura 4.11–Evolução do sistema de controle na simulação 3. | 89 |
| Figura 4.12–Trajetórias tomadas pelo sistema de controle para sair de elevações baixas. | 91 |
| Figura 4.13–Evolução do sistema de controle na simulação 4. | 92 |
| Figura 4.14–Trajetórias tomadas pelo sistema de controle na simulação 5. | 94 |
| Figura 4.15–Evolução dos erros do sistema de controle na simulação 5. | 95 |
| Figura 4.16–Evolução do sistema com respeito aos limites no teste 1, simulação 5 | 96 |
| Figura 4.17–Evolução do sistema com respeito aos limites no teste 2, simulação 5 | 97 |
| Figura 4.18–Curva de desempenho do ΔP empregando os modelos SVM | 99 |
| Figura 4.19–Curva de desempenho de W_m empregando os modelos SVM | 99 |
| Figura 4.20–Curva de desempenho do η empregando os modelos SVM | 100 |
| Figura 4.21–Desempenho do filtro de partículas. | 101 |
| Figura 4.22–Trajetória tomada pelo sistema de controle | 104 |
| Figura 4.23–Evolução do erro do sistema de controle | 105 |
| Figura 4.24–Trajetória tomada pelo sistema de controle | 106 |
| Figura 4.25–Evolução do erro do sistema de controle | 107 |
| Figura A.1 – Diagrama esquemático da instrumentação da bancada do LabVIP. | 117 |
| Figura A.2 – Painel de instrumentos | 120 |
| Figura A.3 – Processo de geração de aplicação em tempo real | 121 |
| Figura A.4 – Interface de usuário no ControlDesk | 122 |
| Figura A.5 – Conversor PWM a 5V | 123 |
| Figura A.6 – Circuito conversor PWM a 5V | 123 |
| Figura A.7 – Bancada basculante do LabVIP | 124 |
| Figura A.8 – Desenho da capsula com o conjunto BCS | 124 |
| Figura A.9 – Injetor de ar fabricado para injeção de ar próximo ao <i>intake</i> da bomba | 125 |
| Figura A.10–Injetor de ar instalado na bomba BCS | 125 |
| Figura A.11–Curva de desempenho da bomba P43 para várias rotações | 126 |

| | |
|--|-----|
| Figura A.12–Curvas de desempenho da bomba P43 | 126 |
| Figura A.13–Oscilações na vazões de saída da BCS. | 128 |
| Figura A.14–Oscilações na pressão de saída da BCS. | 129 |
| Figura A.15–Oscilações na corrente de saída da BCS. | 129 |
| Figura B.1 – Representação do genótipo de cada indivíduo artificial. | 130 |
| Figura C.1 – IHM para aquisição de dados da bomba BCS P43 | 132 |

LISTA DE TABELAS

| | |
|--|-----|
| Tabela 2.1 – Exemplo Classificadores | 40 |
| Tabela 3.1 – Matriz de testes | 63 |
| Tabela 3.2 – Componentes do classificador | 69 |
| Tabela 3.3 – Regras para obter os valores da função do R | 71 |
| Tabela 4.1 – Parâmetros da SVMr e desempenho da estimação das curvas de desempenho da BCS. | 76 |
| Tabela 4.2 – Parâmetros do filtro de partículas | 78 |
| Tabela 4.3 – Limites de operação da BCS | 80 |
| Tabela 4.4 – Condições iniciais do AG | 81 |
| Tabela 4.5 – Incrementos dos atuadores | 81 |
| Tabela 4.6 – Condições iniciais para a simulação 1 | 81 |
| Tabela 4.7 – Condições iniciais para a simulação 2 | 84 |
| Tabela 4.8 – Condições iniciais para a simulação 3 | 87 |
| Tabela 4.9 – Condições iniciais para a simulação 4 | 90 |
| Tabela 4.10–Condições iniciais para a simulação 5 | 93 |
| Tabela 4.11–Parâmetros da SVM, e desempenho da estimação das curvas de desempenho da BCS. | 98 |
| Tabela 4.12–Parâmetros do filtro de partículas | 101 |
| Tabela 4.13–Regras para a função do R | 102 |
| Tabela 4.14–Limites de operação do conjunto BCS | 103 |
| Tabela 4.15–Condições iniciais do AG | 103 |
| Tabela 4.16–Incrementos dos atuadores | 103 |
| Tabela 4.17–Condições iniciais para o experimento 1 com o sistema BCS do LabVIP | 104 |
| Tabela 4.18–Condições iniciais para o experimento 2 com o sistema de BCS do LabVIP | 106 |
| Tabela A.1 – Componentes da bancada do LabVIP | 118 |
| Tabela B.1 – Condições iniciais do AG | 130 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|--------|---|
| AG | Algoritmo genético |
| BCS | Bomba Centrífuga Submersa ou Bombeio Centrífugo Submerso |
| BEP | Ponto de melhor eficiência |
| IA | Inteligência artificial |
| LabVIP | Laboratório de vibrações na área de petróleo |
| SAC | Subsistema de Apropriação de Crédito |
| SDNR | Subsistema de descobertas de novas regras |
| STRM | Subsistema de Tratamento de Regras e Mensagens |
| SVM | <i>Support Vector Machine</i> (Máquina de Vetores de Suporte) |
| SVMr | <i>Support Vector Machine for regression</i> (Máquina de Vetores de Suporte para regressão) |

LISTA DE SÍMBOLOS

| | |
|---------------------------|--|
| α_g | Porcentagem de gás ou fração de vazio |
| α_i e α_i^* | Multiplicadores de Lagrange |
| ε | Precisão da margem da SVM |
| η | Eficiência da bomba |
| $\tilde{\eta}$ | Eficiência estimada da bomba |
| $\phi(\cdot)$ | Função de <i>fitness</i> |
| ω_{eixo} | Rotação do eixo |
| σ_g | Massa específica do gás |
| σ_l | Massa específica do líquido |
| τ_{eixo} | Torque aplicado no eixo |
| ξ_i e ξ_i^* | Variáveis de relaxamento da SVM |
| ΔP | Diferencial de pressão |
| # | Não importa ou <i>don' t care</i> |
| a_i | <i>i</i> -ésimo individuo |
| b | Bias ou ponto de intersecção no eixo <i>y</i> |
| d_0 | Coefficiente referente à energia do classificador |
| d_1 | Coefficiente referente à parte não específica do classificador |
| d_2 | Coefficiente referente à parte específica do classificador |
| $e(t)$ | Sinal de erro |
| $f(x)$ | Função do Modelo |
| k_d | Ganho derivativo |
| k_i | Ganho integral |
| k_p | Ganho proporcional |

| | |
|-------------------|---|
| p | Probabilidade |
| $r(t)$ | Sinal de referência |
| $u(t)$ | Sinal do esforço de controle |
| $v(t)$ | Sinal do ruído de medição |
| $w(t)$ | Sinal do ruído do sistema |
| x | Vetor de estados |
| \tilde{x}_k | Vetor de estados estimados |
| $y(t)$ | Sinal controlado ou sinal de saída |
| C | Parâmetro que penalização da SVM |
| $C(\cdot)$ | Função do controlador |
| $H(\cdot)$ | Função do sensor |
| M | Especificidade do classificador respeito à mensagem |
| $P(\cdot)$ | Função da planta |
| P_{in} | Pressão na entrada da BCS |
| P_{out} | Pressão na saída da BCS |
| \tilde{P}_{out} | Pressão estimada na saída da BCS |
| Q_g | Vazão volumétrica de gás |
| Q_l | Vazão volumétrica de líquido |
| Q_t | Vazão volumétrica total do fluido |
| \tilde{Q}_t | Vazão volumétrica total do fluido estimada |
| R_t | Valor da recompensa ou punição do classificador no instante t |
| S_t | Energia ou <i>strength</i> do classificador no instante t |
| T_{in} | Temperatura na entrada da BCS |
| T_{out} | Temperatura na saída da BCS |
| W_h | Potência hidráulica |
| \tilde{W}_h | Potência hidráulica estimada |

| | |
|---------|--|
| W_m | Potência mecânica |
| Bid | Lançe do classificador |
| eBid | Lançe efetivo do classificador |
| Spec | Especificidade do classificador respeito ao número de <i>don' t care</i> (#) |
| tax_v | Taxa de vida dos classificadores |

SUMÁRIO

| | | |
|----------|---|-----------|
| 1 | Introdução | 21 |
| 1.1 | Introdução | 21 |
| 1.2 | Motivação | 22 |
| 1.3 | Proposta de Trabalho | 23 |
| 1.3.1 | Objetivo Geral | 23 |
| 1.3.2 | Atividades Específicas | 23 |
| 1.4 | Arquitetura | 23 |
| 1.4.1 | Organização da Tese | 24 |
| 2 | Aspectos Teóricos | 25 |
| 2.1 | Bomba Centrífuga Submersa | 25 |
| 2.1.1 | Escoamento Bifásico em Bombas | 25 |
| 2.1.2 | Desempenho de BCS Operando com Mistura Bifásica gás-líquido | 27 |
| 2.2 | Conceitos básicos do Controle | 30 |
| 2.3 | Estado da Arte no Controle de Produção de Petróleo | 32 |
| 2.4 | Controle Especialistas | 35 |
| 2.4.1 | Sistemas Especialistas | 36 |
| 2.4.1.1 | Base de dados do sistema | 37 |
| 2.4.1.2 | Base de regras | 38 |
| 2.4.1.3 | Motor de inferência | 38 |
| 2.4.1.4 | Interface de usuário | 38 |
| 2.5 | Sistemas Complexos Adaptativos | 39 |
| 2.5.1 | Subsistema de Tratamento de Regras e Mensagens | 40 |
| 2.5.2 | Subsistema de Apropriação de Crédito | 41 |
| 2.5.3 | Subsistema de Descoberta de Novas Regras | 43 |
| 2.6 | Algoritmos Genéticos | 44 |
| 2.6.1 | Representação | 45 |
| 2.6.2 | Função de <i>Fitness</i> | 46 |
| 2.6.3 | Mecanismo de Seleção | 47 |
| 2.6.3.1 | Seleção Proporcional | 48 |
| 2.6.4 | Operadores Genéticos | 48 |
| 2.6.4.1 | Operador de Crossover | 49 |
| 2.6.4.2 | Operador Mutação | 49 |
| 2.7 | Filtro de Partículas | 50 |
| 2.8 | Máquinas de Vetores de Suporte | 52 |
| 3 | Controle Especialista Aplicado ao Sistema de BCS | 57 |
| 3.1 | Arquitetura do Controle Especialista para o Controle da BCS | 58 |

| | | |
|----------|--|------------|
| 3.2 | Modelagem da Bomba BCS | 59 |
| 3.2.1 | Estrutura do Modelo | 59 |
| 3.2.1.1 | Regulação dos Modelos Mediante Bias/Variância | 61 |
| 3.2.2 | Obtenção de Dados Experimentais | 62 |
| 3.2.2.1 | Circuito de Testes de BCS | 63 |
| 3.3 | Aplicação do Algoritmo de Predição | 64 |
| 3.3.1 | Aplicação do Filtro de Partículas | 65 |
| 3.4 | Aplicação dos Sistemas Complexos Adaptativos | 66 |
| 3.4.1 | Representação dos Classificadores | 69 |
| 3.4.2 | Aplicação da Função de Recompensa e Punição | 69 |
| 3.4.3 | Algoritmo Genético para Descoberta de Novas Regras | 71 |
| 3.5 | O Sistema Supervisório | 72 |
| 4 | Análise e Interpretação dos Resultados | 75 |
| 4.1 | Análise de Resultados de Simulação | 75 |
| 4.1.1 | Análise dos Modelos das Curvas de Desempenho | 75 |
| 4.1.2 | Análise do Filtro de Partículas para Estimação da Vazão de Fluido . . . | 78 |
| 4.1.3 | Análise da interação do Controle Especialista com o Sistema Complexo Adaptativo | 78 |
| 4.1.3.1 | Simulação 1 | 81 |
| 4.1.3.2 | Simulação 2 | 84 |
| 4.1.3.3 | Simulação 3 | 87 |
| 4.1.3.4 | Simulação 4 | 90 |
| 4.1.3.5 | Simulação 5 | 93 |
| 4.2 | Análise de Resultados na Bancada de Testes do LabVIP | 98 |
| 4.2.1 | Análise dos Modelos das Curvas de Desempenho | 98 |
| 4.2.2 | Análise do Filtro de Partículas para Estimação da Vazão de Fluido . . . | 100 |
| 4.2.3 | Análise do Controle Especialistas com o Sistema Complexo Adaptativo | 102 |
| 4.2.3.1 | Experimento 1 no LabVIP | 104 |
| 4.2.3.2 | Experimento 2 no LabVIP | 106 |
| 5 | Conclusões | 108 |
| 6 | Trabalhos Futuros | 111 |
| | Referências | 112 |
| | ANEXO A Bancada de Teste do LabVIP | 117 |
| A.1 | Sistema de Controle e Supervisão da Bancada Basculante | 121 |
| A.2 | Estrutura Física da Bancada do LabVIP | 123 |
| A.3 | Procedimentos Operacionais para o Conjunto de BCS do LabVIP | 125 |
| A.3.1 | Procedimentos de Operação do Conjunto BCS utilizados LabVIP | 127 |

| | | |
|----------------|--|------------|
| A.3.1.1 | Partida | 127 |
| A.3.1.2 | Parada | 127 |
| A.3.1.3 | Limitações de Operação do Conjunto BCS no LabVIP | 127 |
| ANEXO B | Algoritmos Genéticos para Otimização dos Hiperparâmetros da SVM | 130 |
| ANEXO C | Aquisição de Dados Bomba BCS P43 | 131 |

1 INTRODUÇÃO

1.1 Introdução

Os métodos de elevação artificial são fundamentais na indústria do petróleo, sendo empregados para fornecer energia ao fluido no reservatório quando a pressão do poço não é suficiente para levar o fluido até a superfície, ou quando se quer aumentar a vazão de produção do poço acima da vazão natural do mesmo. Existem vários métodos disponíveis para aumentar a energia dos poços, por exemplo o uso de gás comprimido injetado desde a superfície para ajudar a elevar o fluido desde o poço até a superfície; ou o uso de bombas localizadas submersas no fluido do poço para aumentar a pressão com o objetivo de superar as perdas ocorridas no caminho até a superfície.

Os métodos de bombeio podem ser classificados empregando o princípio operacional da bomba usada. Os métodos mais empregados são o bombeio mecânico, que emprega uma bomba de vareta, o bombeio centrífugo submerso (BCS), o bombeio por cavidades progressivas (BCP), o bombeio hidráulico (BH) e a elevação pneumática (em inglês *gas lift*, GL). A seleção do método de bombeio adequado para cada poço depende de vários fatores como por exemplo as características do fluido, a profundidade, a complexidade do reservatório e a vazão.

O bombeio centrífugo submerso é o segundo método de elevação artificial globalmente empregado, visto que existem mais de 100.000 instalações ao redor do mundo, mas é o método com maior quantidade de produção de petróleo (ZHU; ZHANG, 2018). O bombeio centrífugo submerso emprega um motor elétrico submerso no fluido de produção que aciona uma bomba centrífuga de múltiplos estágios. A energia é fornecida ao motor desde a superfície até o fundo do poço por um cabo elétrico, o qual está junto à coluna de produção (TAKACS, 2017).

As bombas BCS são empregadas para se obter uma produção de petróleo com vazões muito altas, mas precisam ser operadas dentro de janelas estreitas de condições de operação. Além disto, quando o fluido sendo bombeado pela BCS tem variação da densidade, viscosidade e presença de uma fase gasosa, estes fatores podem afetar bastante o desempenho da bomba BCS.

Quando o BCS opera com fluido com presença de baixas frações de gás em elevadas vazões de líquido, o desempenho da bomba tem um comportamento similar ao escoamento monofásico. Em contrapartida, quando a fração de gás livre no escoamento é elevada, ela causa uma severa degradação no desempenho da bomba, já que surgem bolsas de gás que deterioram o aumento da pressão da bomba. Esta condição cria a pressão de *surging* ou até um bloqueio

de escoamento no rotor da bomba causando que a vazão seja nula. Este fenômeno é conhecido como *gas locking*.

De acordo com (MORRISON *et al.*, 2014) e (LEA *et al.*, 1982), quando o desempenho da bomba se degrada, compromete a refrigeração da mesma, do motor e sobrecarrega componentes mecânicos, como eixos e rolamentos, o que pode levar a bomba a uma parada prematura. Esta parada causa uma interrupção na sua produção levando a indústria petrolífera a ter prejuízos econômicos. É necessário evitar que a bomba opere nestas condições e, portanto, deseja-se ajustar os parâmetros de funcionamento da bomba de forma a controlar as suas condições para que a bomba opere sempre em condições favoráveis, sendo esta a motivação desta pesquisa.

1.2 Motivação

As bombas centrífugas submersas são equipamentos importantes da indústria petrolífera, sendo um dos equipamentos mais empregados para a elevação artificial. Todos estes equipamentos, de forma geral, apresentam ao longo do seu funcionamento desgastes que os levam inevitavelmente a limitar o seu tempo de vida útil. Isto faz com que a bomba centrífuga submersa seja obrigatoriamente substituída por uma nova. Esta operação de intervenção para troca da bomba, além da interrupção da produção, tem custos elevados, o que se traduz num prejuízo crescente e proporcional ao tempo de execução da operação.

É bem conhecido pela indústria esta necessidade de troca dos equipamentos quando termina a vida útil dos mesmos, e os gastos adjuntos desta necessidade fazem parte do custo de produção. No entanto, quando o equipamento sofre falhas prematuras por trabalhar em regimes indesejados, isto gera prejuízos para a companhia. Um dos motivos do mal funcionamento das bombas é a presença de grandes quantidades de gás no fluido de produção, o qual pode fazer com que a bomba opere na região denominada de *surging*, trabalhando com lubrificação deficiente e gerando sobre esforços nos seus componentes mecânicos, o que danifica-os prematuramente.

Devido à necessidade de se prolongar a vida útil em operação das bombas centrífugas submersas, o presente trabalho apresenta uma metodologia para identificar o ponto de operação da bomba. Isso permite atuar na rotação da mesma e nas válvulas na linha de produção em benefício de evitar regimes indesejados como o *surging* e manter a bomba operando em regimes adequados e até mesmo desejados de operação como ponto de maior produção ou de maior eficiência. Desta forma este trabalho propõe uma metodologia de controle, a qual, empregando conhecimento a priori sobre o processo e o conhecimento auto adquirido pelo sistema de controle, mantém a bomba BCS operando fora de regimes indesejados e ao mesmo tempo busca o ponto de máxima eficiência conhecido como BEP.

1.3 Proposta de Trabalho

1.3.1 Objetivo Geral

O objetivo do trabalho é projetar, simular e implementar um sistema de controle que permita manter um sistema de bombeio centrífugo submerso operando com fluido bifásico (água-gás) trabalhando em condições seguras. Este controle deve manter a bomba centrífuga submersa fora da zona de *surging*, dentro das limitações definidas pelo usuário e perto do ponto de máximo desempenho da bomba.

1.3.2 Atividades Específicas

Para alcançar o objetivo deste trabalho, foram definidas as seguintes tarefas para desenvolver um sistema de controle especialista:

- Desenvolver modelos não lineares que representem as curvas de desempenho da bomba centrífuga submersa operando com fluido bifásico (água-gás) a partir de dados reais adquiridos diretamente de uma bomba BCS.
- Desenvolver uma metodologia para identificar variáveis que não podem ser medidas diretamente na bomba BCS com a finalidade de prever o ponto real de operação da bomba.
- Projetar um sistema de controle que mantenha o sistema BCS trabalhando em condições seguras.
- Validar experimentalmente o sistema de controle especialista projetado.

1.4 Arquitetura

Na Figura 1.1 é apresentada a arquitetura proposta, na qual, a partir de dados experimentais da bomba BCS, são treinados modelos não paramétricos com o objetivo de representar as curvas de desempenho da mesma, e assim poder estimar qualquer um de seus pontos de operação. A partir dos modelos não paramétricos e dados adquiridos diretamente do sistema, é estimado o ponto de operação da bomba. Além disso, empregando os modelos não paramétricos, são estimados tanto o ponto de *surging* quanto o ponto de BEP para a condição atual de operação da bomba BCS.

Paralelamente ao descrito anteriormente, é realizado o projeto de controle, no qual o controlador projetado emprega o ponto de operação estimado da bomba, o ponto de BEP e o ponto de *surging*, para realizar o correspondente esforço de controle sobre o sistema BCS.

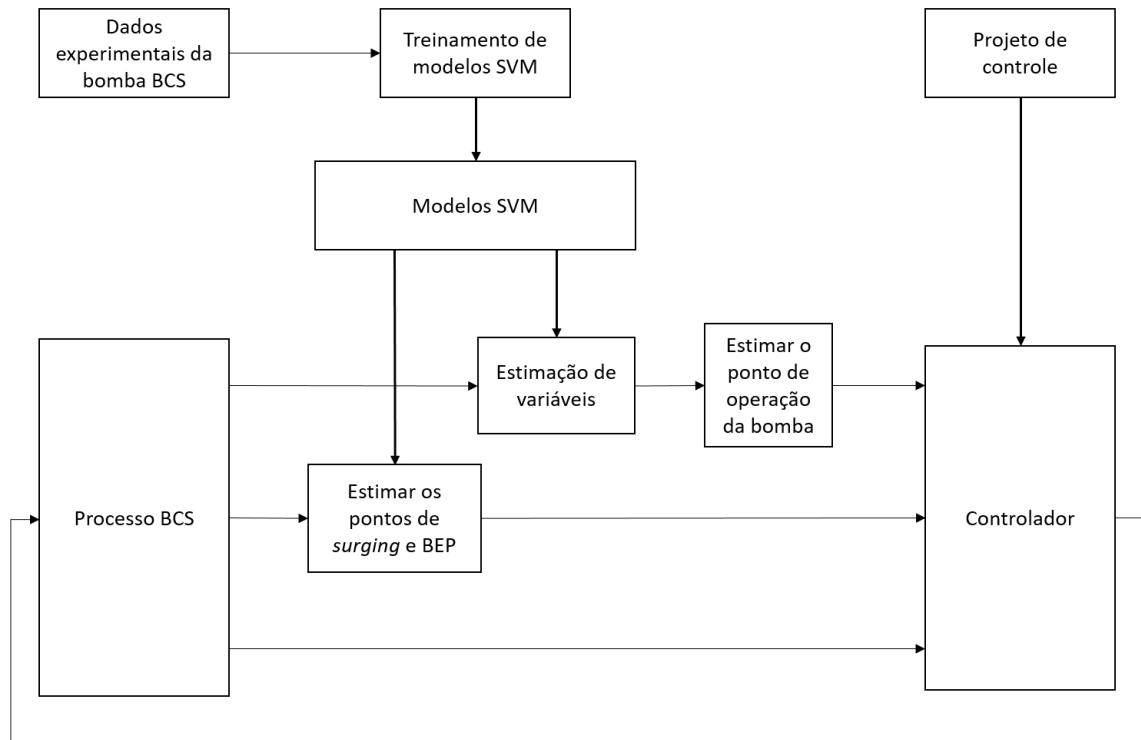


Figura 1.1: Arquitetura da proposta

1.4.1 Organização da Tese

O Capítulo 1 apresenta uma visão geral das bombas centrífugas submersas operando com fluidos bifásicos.

O Capítulo 2 apresenta os aspectos teóricos para o desenvolvimento do controle especialista e a teoria de cada uma das metodologias baseadas na inteligência artificial empregadas para projetar cada um dos componentes internos do controlador.

O Capítulo 3 apresenta como é aplicada a teoria apresentada no Capítulo 2 para desenvolver cada um dos componentes do controle especialista aplicado à operação de uma bomba BCS. Também é descrita a bancada utilizada para o modelamento e para a validação experimental.

O Capítulo 4 apresenta as análises e a interpretação de resultados referente ao controlador especialista interagindo com o sistema BCS.

O Capítulo 5 apresenta as conclusões da pesquisa, assim como sugestões para trabalhos futuros.

2 ASPECTOS TEÓRICOS

Nesse capítulo, abordam-se conceitos relacionados às técnicas empregadas para a estruturação do sistema de controle, partindo do conceito de controle especialista até conceitos necessários para implementar cada um dos módulos do sistema de controle, tal como o filtro de partículas para poder estimar variáveis não disponíveis no sistema a ser controlado, as máquinas de vetores de suporte com a finalidade de obter os modelos correspondentes ao desempenho da bomba de BCS e de como operam os sistemas complexos adaptativos em conjunto com algoritmos genéticos para poder gerar automaticamente o conhecimento necessário sobre o sistema.

2.1 Bomba Centrífuga Submersa

As bombas são máquinas rotativas hidráulicas que realizam trabalhos sobre um fluido com a finalidade de transportá-lo de um ponto a outro. A bomba centrífuga submersa (BCS) é acionada por um motor elétrico que fornece energia cinética ao fluido que é convertida parcialmente em energia potencial. Principalmente as BCS são bombas de múltiplos estágios instalados em série, seus rotores são de tipo fechado e são de fluxo misto ou radial (MONTE, 2011).

Os estágios de uma BCS são compostos por dois componentes básicos: rotor e difusor. O rotor é constituído por um conjunto de pás confinadas por paredes, onde as pás e paredes formam os canais do rotor. O difusor é o componente fixo à carcaça da bomba.

Como pode ser observado na Figura 2.1, o fluido entra no rotor na direção axial com velocidade baixa. Ao encontrar-se com as pás, e devido à elevada velocidade de rotação do rotor, o fluido é acelerado tangencialmente e sua velocidade é aumentada, convertendo o torque aplicado pela bomba ao fluido em energia cinética. O fluido em alta velocidade deixa o rotor e entra no difusor, parte estacionária da bomba, onde ocorre a conversão de parte da energia cinética em energia potencial devido à qual o fluido diminui a velocidade (WHITE, 1999).

2.1.1 Escoamento Bifásico em Bombas

O escoamento bifásico é constituído por diferentes parâmetros dimensionais e adimensionais que são apresentados a seguir:

- Vazão Volumétrica de gás Q_g : é o volume de gás por unidade de tempo sendo injetado na bomba na temperatura e pressão da sucção. Em bancadas experimentais a vazão volumétrica de gás é medida por um medidor de vazão geralmente colocado antes da injeção na bomba, e em condições diferentes de pressão e temperatura de sucção,




Figura 2.1: Estágio de BCS.

sendo necessário portanto calcular a vazão volumétrica na entrada da bomba mediante a conservação de massa apresentada na Equação 2.1 onde σ_g é a massa específica do gás na sucção da bomba, $\sigma_{g,mv}$ é a massa específica do gás no medidor de vazão e $Q_{g,mv}$ é a vazão volumétrica de gás no medidor de vazão (MONTE, 2011).

$$Q_g = \frac{Q_{g,mv} \sigma_{g,mv}}{\sigma_g} \quad (2.1)$$

- Vazão volumétrica de líquido Q_l : é a razão entre a vazão mássica de líquido G_l e a massa específica do líquido σ_l conforme apresentado na Equação 2.2.

$$Q_l = \frac{G_l}{\sigma_l}, \quad (2.2)$$

- Vazão Volumétrica total do fluido Q_t : é o volume total de fluido composto pela soma da vazão volumétrica de gás Q_g e da vazão volumétrica de líquido Q_l , ambas obtidas à pressão e temperatura da sucção da bomba conforme mostrado na Equação 2.3.

$$Q_t = Q_g + Q_l \quad (2.3)$$

- Porcentagem de gás ou fração de vazão α_g : é a razão entre a vazão volumétrica de gás e a vazão volumétrica total conforme mostrada na Equação 2.4:

$$\alpha_g = \frac{Q_g}{Q_t} = \frac{Q_g}{Q_g + Q_l}, \quad (2.4)$$

A fração volumétrica de gás está associada à condição de não escorregamento entre as fases, ou seja, quando as velocidades locais das fases são iguais. De modo geral, essa condição é válida para o escoamento de pequenas bolhas dispersas carregadas por uma

fase líquida contínua que ocorre comumente em escoamentos com elevadas vazões de líquido (MONTE, 2011).

2.1.2 Desempenho de BCS Operando com Mistura Bifásica gás-líquido

O desempenho das bombas é representado normalmente em três curvas características como ilustrado na Figura 2.2, que, conforme a API RP 11S, são geradas com água a 60°F e com uma rotação de 3500 rpm.

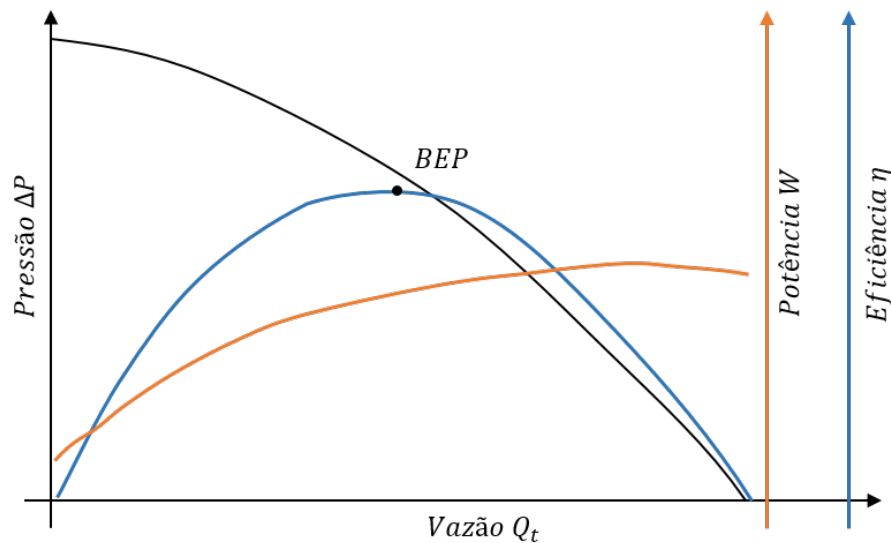


Figura 2.2: Representação das curvas de desempenho.

O ΔP é dado pela diferença entre a pressão de entrada da bomba e de sua saída, ou seja, o incremento da pressão cedida pela bomba.

A potência mecânica W_m pode ser calculada por:

$$W_m = \omega \tau_{eixo}, \quad (2.5)$$

na qual ω é a rotação do eixo da bomba e τ_{eixo} é o torque aplicado no eixo da bomba.

A potência cedida ao fluido ou potência hidráulica W_h é dada por:

$$W_h = \Delta P Q_t, \quad (2.6)$$

A razão entre potência hidráulica e potência mecânica descreve a eficiência da bomba na forma (MORRISON *et al.*, 2014):

$$\eta = \frac{\Delta P Q}{\omega \tau_{eixo}} = \frac{W_h}{W_m}, \quad (2.7)$$

A curva da eficiência apresenta um pico máximo conhecido como ponto de melhor eficiência (BEP) (ver Figura 2.2). Normalmente as condições apropriadas para uma ótima operação das bombas, sem sacrificar a transferência de energia ao fluido, ocorrem em torno do BEP.

O gás dissolvido no fluido presente no reservatório é produzido juntamente com o petróleo líquido, por isto é comum a utilização de bombas operando com escoamento bifásico líquido-gás. A energia cinética transferida ao fluido pelas máquinas hidráulicas é proporcional à massa específica, portanto a presença de gás na sucção da bomba deteriora o aumento de pressão do fluido, ao ser bombeado (LEA *et al.*, 1982; MONTE, 2011).

As Figuras 2.3, 2.4 e 2.5, apresentam as curvas de desempenho de uma bomba operando com escoamento líquido-gás com diferentes porcentagens de gás, sendo ΔP o diferencial de pressões entre a saída e a entrada da BCS, η a eficiência, W a potência e Q_t a vazão de fluido.

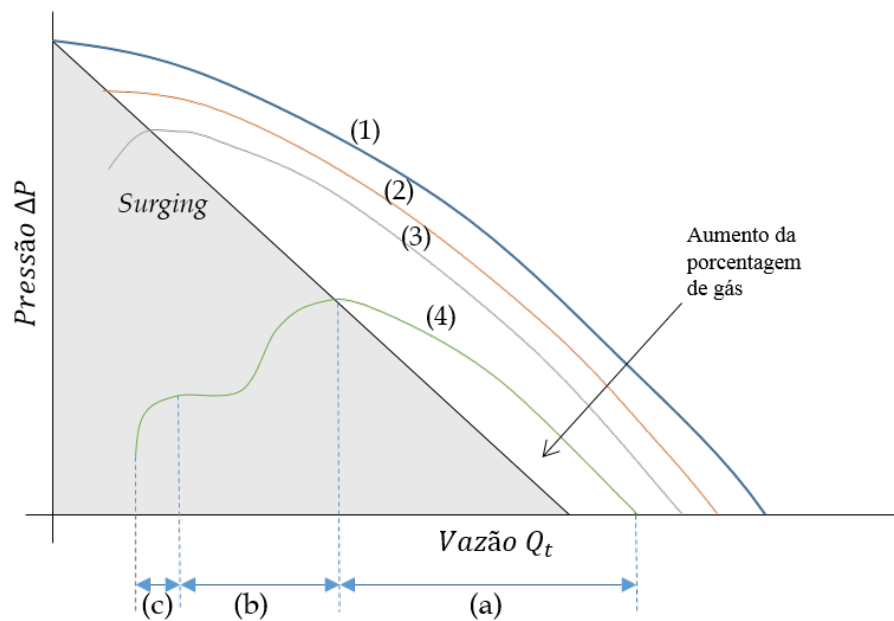


Figura 2.3: Representação das curvas de desempenho de elevação com escoamento multifásico.

A curva (1) nas figuras representa a operação da bomba com escoamento monofásico. A curva (2) representa o comportamento da bomba com um aumento da porcentagem de gás, onde se observa apenas uma pequena diminuição da capacidade de elevação, eficiência e potência, já que a quantidade de gás ainda é mínima e o fluido tem um comportamento homogêneo, ou seja, as bolhas se encontram dispersas no líquido.

A curva (3) apresenta uma curva característica quando a presença de gás na mistura é maior, evidenciando um ponto máximo na curva de elevação (Figura 2.3). Este ponto máximo é conhecido como ponto de “*surging*”, caracterizado por uma diminuição considerável na sua capacidade de bombeamento. Nessas condições o escoamento não é mais homogêneo, ou seja,




Figura 2.4: Representação das curvas de desempenho de eficiência com escoamento multifásico.

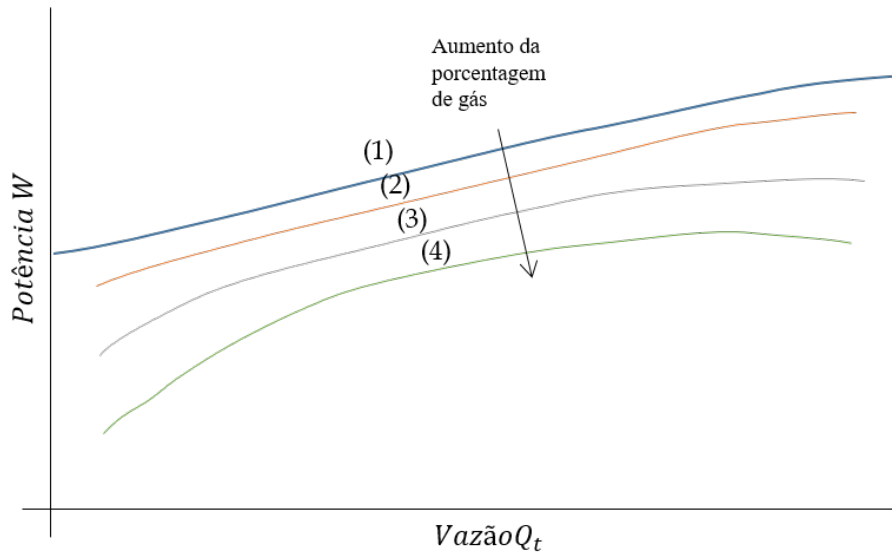


Figura 2.5: Representação das curvas de desempenho de potência com escoamento multifásico.

o líquido e o gás na mistura multifásica escoam separadamente.

Quando existe uma elevada presença de gás no escoamento a curva de elevação apresenta novas instabilidades (Figura 2.3). A curva (4) apresenta três regiões distintas de operação. A região (a) apresenta uma operação estável, o que indica que a mistura é homogênea. A região (b) inicia o ponto de *surging* apresentando uma queda de pressão na capacidade de bombeamento. A presença de grande quantidade de gás livre em baixas vazões pode causar o bloqueio da área disponível ao escoamento no rotor da bomba, fazendo com que a vazão seja nula, fenômeno conhecido como *'gas locking'*. Esta grande instabilidade se destaca na região (c) da curva (4).

2.2 Conceitos básicos do Controle

O controle automático tem se transformado em parte importante dos processos modernos por se buscar eliminar o fator humano e assim tornar os processos mais eficientes e executáveis no menor tempo possível. Outro fato a se ter em conta para automatizar diferentes processos é o risco que representa a presença de uma pessoa enquanto o processo é executado. Pelos avanços na teoria de controle pode-se obter desempenhos ótimos dos sistemas dinâmicos melhorando a produtividade, facilitando a carga de muitos processos manuais e repetitivos, e por isto é importante que os engenheiros e pesquisadores tenham conhecimento nesta área.

Na Figura 2.6 é apresentado a estrutura básica de um sistema de controle com realimentação.




Figura 2.6: Estrutura básica de um sistema com realimentação

A seguir são apresentadas as definições básicas para entender cada um dos componentes de um sistema de controle (OGATA, 2002; GEROMEL; PALHARES, 2004):

Sinal de referência: o sinal $r(t)$ representa o objetivo do projeto de controle, ou seja, em um sistema de controle bom a saída controlada em malha fechada deve atingir ou se aproximar ao sinal $r(t)$.

Variável controlada: o sinal $y(t)$ é a grandeza que é controlada, ou seja, é a saída do sistema o qual se quer corrigir ou limitar a partir de um valor desejado $r(t)$.

Variável manipulada: o sinal $u(t)$ é a grandeza que o controlador modifica para afetar a variável controlada $y(t)$.

Perturbações: os sinais $w(t)$ e $v(t)$ são sinais exógenos que tendem a afetar o valor da saída do sistema. O sinal $w(t)$ representa perturbações que atuam na mesma faixa de frequências do sinal $r(t)$. O sinal $v(t)$ representa ruídos normalmente de alta frequência introduzidos pelo sensor ou dispositivo de medida.

Planta: o $P(.)$ representa um equipamento ou partes dele, que, trabalhando em conjunto, tem como objetivo executar uma operação. Pode-se chamar de planta qualquer objeto

físico a ser controlado.

Controle: o $C(\cdot)$ representa uma função, operação ou programa que se quer projetar com o objetivo de reduzir a diferença entre a saída $y(t)$ e o sinal de referência $r(t)$.

Sensor: o dispositivo de medição $H(\cdot)$ que transforma um estímulo físico ou químico em outra grandeza física.

Processo: é um desenvolvimento contínuo, seja ele natural ou gerado de forma artificial. Consiste em uma série de ações ou movimentos controlados para obter um resultado desejado. Numa plataforma marítima de petróleo o processo seria o conjunto de ações e componentes necessários para levar o petróleo do fundo do poço até a plataforma.

Sistema: uma combinação de componentes que trabalham em conjunto para realizar um objetivo determinado. Um sistema não é necessariamente físico.

Ao projetar um sistema de controle, a eficiência resultante deste vai depender da similaridade do modelo com o fenômeno físico a controlar. Quando se modelam fenômenos físicos muito complexos, o modelo matemático não consegue representar completamente o comportamento dos mesmos, já que o modelo foi simplificado com os parâmetros fundamentais do sistema. Em outras palavras, o processo de modelagem acrescenta erros e incertezas no desenho de sistemas de controle, pela simplificação aplicada no processo de modelagem, o que ocorre, por exemplo, ao tentar representar o sistema real por um sistema linear ou invariante no tempo. Por isto é que a teoria de controle clássica perde aplicabilidade com sistemas reais complexos como sistemas não lineares, variantes no tempo ou sistemas MIMO (Multi-Input Multi-Output) (OGATA, 2002; RODRÍGUEZ; LÓPEZ, 1996).

Na procura de controlar sistemas MIMO, se levou a empregar problemas de desenho clássicos de realimentação SISO (single-input single-output) com incertezas não estruturadas que podem se generalizar de forma confiável a sistemas MIMO (DOYLE; STEIN, 1981). Na década de oitenta foi apresentado o controle robusto para solucionar sistemas com retroalimentação multivariáveis empregando LQR/LTR para obter controladores H_2 e H_∞ (STEIN; ATHANS, 1987; DOYLE *et al.*, 1989). Outros autores propõem sistemas adaptativos empregando máquinas que se auto programam, empregando sistemas classificadores e algoritmos genéticos para criar ou descobrir novas regras (GOLDBERG, 1985).

Os sistemas de controle podem ser obtidos mediante um procedimento passo a passo apresentado na Figura 2.7, partindo desde o modelo físico até a validação do sistema com o controle (SKOGESTAD; POSTLETHWAITE, 2007).

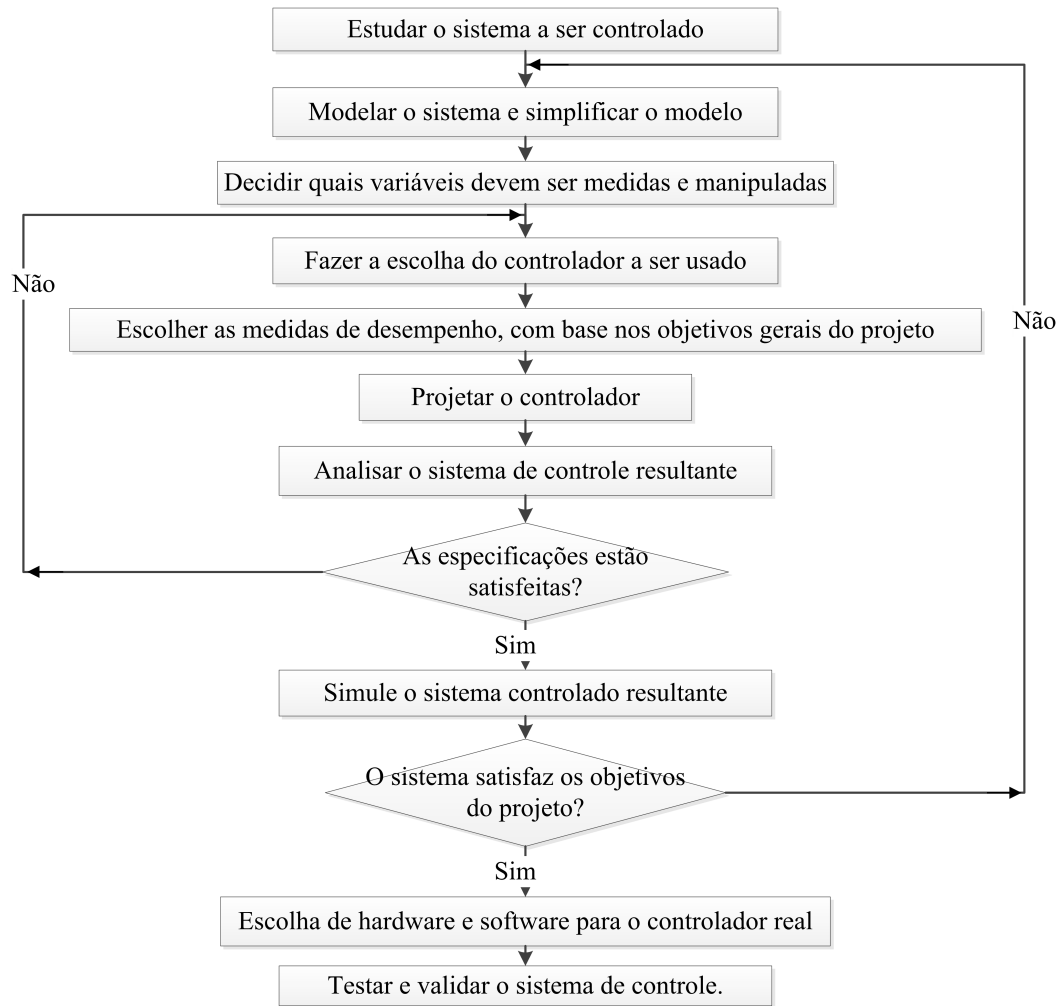


Figura 2.7: Passos básicos para o desenvolvimento de um sistema de controle.

2.3 Estado da Arte no Controle de Produção de Petróleo

Segundo a literatura, uma das primeiras formas de prever o comportamento ou desempenho das bombas mecânicas empregadas para a elevação artificial em poços é empregar um dinamômetro na superfície, o qual registra o valor das forças que estão atuando na extremidade superior da haste de bombeio, traçando uma carta dinamométrica de superfície que representa graficamente os efeitos gerados pela carga atuante na bomba de fundo propagada pela coluna de hastes. Na década de 90 muitos pesquisadores desenvolveram modelos matemáticos ou métodos com a finalidade de gerar cartas dinamométricas na superfície que representassem bem o comportamento da bomba de fundo e assim controlar seu funcionamento com a finalidade de prolongar a vida de trabalho da bomba e o desempenho da mesma.

Barreto Filho, em 1993, apresentou um método iterativo para gerar cartas dinamométricas de fundo a partir de dados reais com a finalidade de diagnosticar o comportamento do bombeio, tendo em conta na sua modelagem o amortecimento gerado pela interação entre a haste-fluido e a tubulação. Também seu método determina o deslocamento em

relação à posição de qualquer ponto da coluna de haste e dos esforços ali atuantes, permitindo assim gerar a carta dinamométrica em qualquer profundidade. Barreto Filho diz que o seu método pode ser empregado como uma rotina para o diagnóstico de um sistema de bombeio mecânico já que dependendo das distorções nas cartas pode-se prever o que está acontecendo com o sistema de bombeio (FILHO, 1993).

Na busca de otimizar a produção de óleo e gás, a automação e o controle de sistemas têm um papel muito importante, ajudando na redução de custos e tempos de operação. No final dos anos 80, foi desenvolvido pela Companhia Baker e implementado em vários países um sistema de automação convencional para o bombeio mecânico, que se destacou por adquirir localmente a carta dinamométrica de superfície, por calcular a carta de fundo correspondente, e por analisar estas cartas, fazendo o controle de bomba-desliga ("pump-off") do poço. Rodrigues em 1996 empregou algoritmos de inteligência artificial propondo um sistema inteligente para elevação de poços e controle de processos petrolíferos (SIEP) para gerenciar os processos da produção de petróleo (RODRIGUES, 1996). Este sistema foi desenvolvido para um poço de bombeio mecânico empregando dados reais medidos no poço. O sistema automático proposto por Rodrigues após testado em laboratórios e simuladores apresentou bons resultados para o diagnóstico de problemas nos poços.

Com o uso de sensores de fundo, capazes de medir distintas variáveis no poço como a corrente no motor, a temperatura do motor e a pressão de fundo, Ordoñez em 2008 consegue manter o nível do anular perto à sucção da bomba e também monitorar as golfadas da bomba com aparelhos de manutenção do equipamento. Ordoñez conseguiu seus objetivos empregando um inversor de frequência e um controlador com tabela de ganhos (ORDOÑEZ, 2008; ORDOÑEZ *et al.*, 2008). No mesmo ano Gao e Tian buscaram otimizar a produção dos poços diminuindo a energia da unidade de bombeio. Os autores propõem controlar a rotação da bomba BCS e a abertura da válvula de choke com controladores PI onde o set-point é definido por um sistema inteligente baseado no caso de Gao, em máquinas de vetores de suporte (GAO *et al.*, 2008) e no de Tian em redes neurais (TIAN *et al.*, 2008). Os dois autores chegam à mesma conclusão de que o sistema inteligente consegue melhorar a eficiência da produção otimizando a eficiência de trabalho das unidades de bombeio.

Quintaes, em 2010, e Costa, em 2012, apresentaram controladores inteligentes baseados em regras para controlar a vazão e a submergência da bomba, controlando a rotação da bomba e a válvula de choke (QUINTAES *et al.*, 2010; COSTA, 2012). Estas regras foram criadas empregando a literatura e especialistas na área. O autor diz que a vazão e a submergência são variáveis contrárias, ou seja, quando aumenta a vazão a submergência diminui tendo que dar prioridade de controle a uma das variáveis. Ele também busca manter a temperatura do motor da BCS em um estado ótimo para evitar o superaquecimento através de uma vazão mínima de refrigeração na carcaça do motor, evitando falhas prematuras no poço.

Em 2013 Sharma e Glemestad estudaram um modelo não-linear para manter as

condições da bomba estáveis, ou seja, o modelo depende da condição da bomba e gera set-points para que os controladores PI atuem na válvula de choke e na rotação do motor da BCS para levar a bomba a uma melhor condição de operação (SHARMA; GLEMMESTAD, 2013a; SHARMA; GLEMMESTAD, 2013b). Sharma conclui em sua pesquisa que a válvula de choke deve estar 100% aberta para manter uma vazão ótima através do controle da rotação do motor.

Pavlov e Binder em 2014 empregaram controle preditivo baseado no modelo do sistema (MCP) porque, segundo os autores, este controlador pode ser usado em sistemas complexos com múltiplas variáveis e com diferentes restrições (PAVLOV *et al.*, 2014; BINDER *et al.*, 2014). As pesquisas tiveram como objetivo manter as bombas dentro de faixas estáveis para prolongar a vida útil das mesmas, mantendo restrições na corrente elétrica no motor da BCS. Também os pesquisadores consideraram como prioridade manter a pressão na sucção da bomba estável e a pressão de saída maior na cabeça do poço para evitar o bloqueio da produção.

Há outros grupos de pesquisa trabalhando em controladores adaptativos para melhorar o desempenho dos poços de petróleo. Souza em 2014 apresenta um controlador PID onde os ganhos do controlador são atualizados automaticamente por um modelo supervisor não linear baseado em regras (SOUZA *et al.*, 2014). Hussein em 2015 apresenta uma metodologia de controle baseado em um PI adaptativo onde os ganhos do controlador são atualizados dependendo do ponto de operação da bomba observando uma tabela de ganhos previamente pré-programada (HUSSEIN *et al.*, 2015).

Em 2016 Pineda, partindo de um conjunto de dados experimentais, construiu um modelo dinâmico de uma bomba BCS operando com gás-líquido empregando redes neurais artificiais. Com esse modelo e empregando o método inverso direto, o autor modelou outra rede neural artificial, e com essa rede conseguiu controlar a operação da bomba num ponto de operação predefinido, ajustando a velocidade de rotação da bomba (PINEDA, 2016). Em 2018, Barrera empregando a metodologia de controle inverso-direto e redes neuro-fuzzy, treinou um sistema de controle para manter uma bomba BCS operando com mistura bifásica (líquido-líquido) no ponto de máxima eficiência, empregando a velocidade de rotação como variável de controle (SALAMANCA, 2018).

Do resumo apresentado podemos dizer que existe uma grande preocupação por melhorar o desempenho dos equipamentos instalados nos poços, chegando a criar nos últimos anos sensores de fundo que ajudam a monitorar o funcionamento da bomba no poço, disponibilizando para um grande número de pesquisadores as ferramentas necessárias para desenvolver sistema autônomos, capazes de controlar algumas das variáveis da produção, melhorando o desempenho das bombas e aumentando sua vida útil operacional.

2.4 Controle Especialistas

O conceito de controle especialista foi proposto por Åström e seu grupo em 1984 (ÅSTRÖM *et al.*, 1986). Eles apresentaram como a lógica de um sistema de controle pode ser substituído por um sistema especialista. Ou seja, é introduzido no circuito de realimentação um sistema especialista como sistema de controle.

Os fatores heurísticos são importantes para o bom desempenho de um controlador, mas devido à dificuldade na análise teórica ou até a falta de informação, os pesquisadores podem perder interesse neste assunto. Por exemplo, considerando um controlador PID dado pela equação linear:

$$u(t) = k_p e(t) + k_i \int^t e(t) dt + k_d \frac{de(t)}{dt}, \quad (2.8)$$

sendo $u(t)$ o sinal de controle e $e(t)$ o sinal de erro, e empregando a teoria de controle clássica, podem-se determinar os valores adequados dos ganhos k_p , k_i e k_d para controlar uma planta específica, mas no projeto de controle do PID são consideradas variáveis tais como: a interface do operador, problemas operativos (como comutar entre manual e autônomo), transientes entre mudança de parâmetros, efeitos de atuadores não lineares, máximos e mínimos, etc. A implementação de um PID industrial operacional a partir da equação 2.8 deve conter uma heurística que considere as regras e condições de contorno apresentados na Figura 2.8 (ÅSTRÖM *et al.*, 1986).

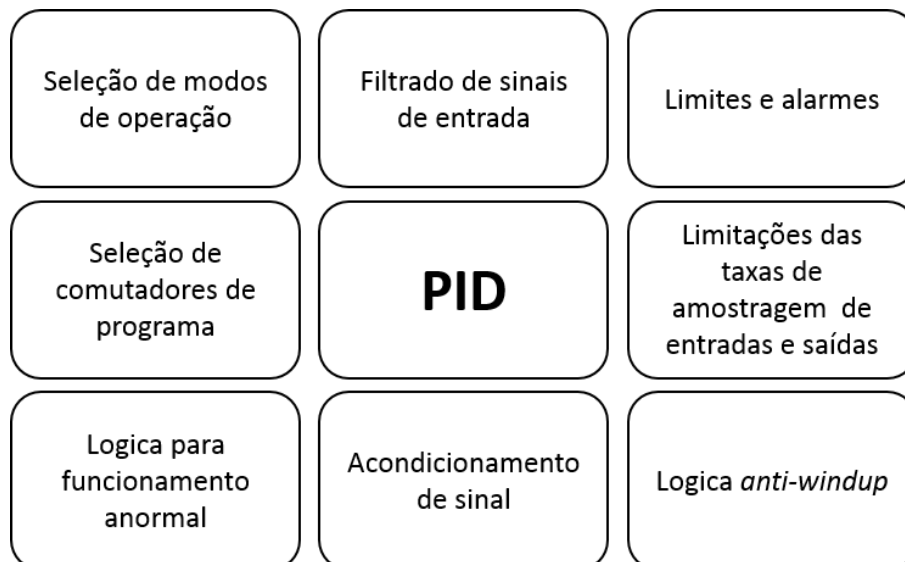


Figura 2.8: Diagrama de blocos de um PID industrial com heurística.

Pode-se dizer que a teoria de PID não leva em conta que problemas reais como limites de operação, modos de operação e mudanças no sinal de referência podem saturar o controlador, devendo por isso fazer parte do sistema de controle a heurística.

O controle especialista tem como objetivo codificar representações de conhecimento e capacidades de decisão para obter decisões inteligentes e recomendações de forma automática em vez de pré-programar a lógica que estuda cada caso em particular. Portanto, é útil procurar ferramentas que possam ajudar a resolver o problema de controle, levando em conta que projetar sistemas combinando uma variedade de algoritmos implica na preparação e adaptação destes para obter os diferentes objetivos de controle (ÅSTRÖM *et al.*, 1986).

A ideia básica do controle especialista, segundo Årzén, é ter como objetivos (ÅRZÉN, 1989):

- poder controlar processos que são variáveis no tempo, processos não lineares e processos que estão expostos a diferentes perturbações;
- definir uma quantidade mínima de conhecimento prévio do sistema;
- utilizar o conhecimento prévio das variáveis;
- inserir especificações do desempenho do sistema, por exemplo: tempo de pico, máximo sobressinal ou *Overshoot*, tempo de estabilização, tempo de subida, etc,
- acumular com o tempo a quantidade de conhecimento do sistema, e como consequência melhorar o respectivo controle;
- realizar o diagnóstico do desempenho do controle e dos componentes;
- manter uma comunicação com o usuário e disponibilizar informação sobre o processo;
- organizar o conhecimento na estrutura do controle e da heurística de uma forma que o permitir modificações e extensões.

2.4.1 Sistemas Especialistas

Os sistemas especialistas são uma área da inteligência artificial (IA) que começaram a surgir no final da década de 1960, devido às ambições de desenvolver "computadores pensantes"(SAJJA; AKERKAR, 2010).

Buchanan define os sistemas especialistas como programas que raciocinam com informações simbólicas e usam procedimentos de inferência heurísticos (não algorítmicos) (BUCHANAN, 1986).

O princípio dos sistemas especialistas é a experiência, ou seja, o conhecimento específico de um ser humano que é transmitido e armazenado num computador. O conhecimento armazenado pode ser usado como assessoramento por outro usuário, ou até o próprio

computador pode fazer inferências ou dar uma solução específica para um determinado problema (LIAO, 2005).

O problema chave é como representar o conhecimento humano nos sistemas especialistas. Por isto, tem sido estudado alguns métodos tais como: representações com cálculos lógicos de primeira ordem, representação procedural, representação com redes semânticas, representação por regras e representação por quadros (ÅSTRÖM *et al.*, 1986).

Os sistemas especialistas baseados em regras são normalmente empregados para o controle de processos. Segundo Åström, um sistema especialista baseado em regras é composto por quatro componentes principais, os quais são apresentados na Figura 2.9:

1. Base de regras;
2. Base de dados do sistema;
3. Motor de inferência; e,
4. Interface de usuário.

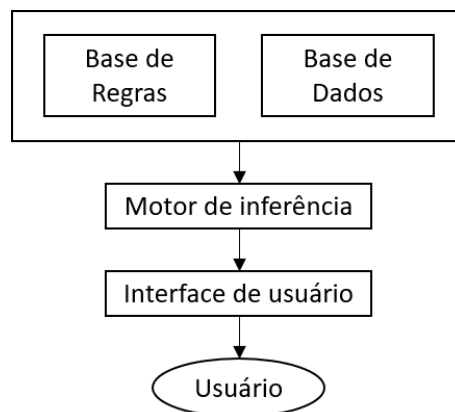


Figura 2.9: Diagrama de um sistema especialista baseado em regras.

2.4.1.1 Base de dados do sistema

A base de dados do sistema é onde são armazenados os fatos, as evidências, as hipóteses e os objetivos para o processo de controle. Os fatos armazenados na base de dados podem ser dados estáticos como os erros de medição, os limites de operação, alarmes, processos operacionais, planejamentos, possíveis configurações, entre outros. As evidências armazenadas na base de dados podem incluir dados dinâmicos dos sensores, reportes de instrumentação de engenharia, reportes do laboratório e de ensaios.

Pelo que foi mostrado anteriormente, a experiência prévia do processo a controlar possui um papel importante, pois, este conhecimento é a base para se criar hipóteses e assim estimar variáveis ou estados do sistema.

Os objetivos armazenados na base de dados do sistema é que definem o desempenho do sistema de controle, tais como: manter o sistema estável e procurar os pontos ótimos de operação, determinando assim a lei de controle.

2.4.1.2 Base de regras

A base de regras empregadas no controle de processos é normalmente descrita na forma: “se (situação) então (ação)”.

A “situação” representa os fatos, as evidências, as hipóteses e os objetivos da base de dados. A “ação” nos sistemas especialistas podem gerar novas informações na base de dados ou modificá-las, pode também gerar a ação de controle ou mesmo modificar a estrutura do controlador. Um exemplo de regras para o processo podem ser:

- se (rotação BCS $> 3600rpm$ ou rotação BCS $< 2400rpm$) então (ajustar rotação da BCS)
- se (perda de pressão) então (ajustar válvula 1 ou ajustar rotação da BCS)
- se (eficiência baixa) então (ajustar rotação da BCS ou ajustar válvula 1)
- se (motor BCS em sobrecarga) então (desligar BCS)
- etc...

Cabe salientar que as representações das regras vão depender da codificação adotada para o projeto.

2.4.1.3 Motor de inferência

Na inteligência artificial, o motor de inferência é uma ferramenta que ao ser estimulada pode gerar decisões ou ações. Ou seja, o motor de inferência é quem decide (a partir da base de dados, os fatos, as evidências, as hipóteses e os objetivos) como as regras vão ser selecionadas. Este motor de inferências pode ser construído empregando diferentes estratégias (HORVITZ *et al.*, 1988), por exemplo o uso de árvores de decisão (KIM; PEARL, 1983), ou o uso de regras conformadas por ações ligadas a condições (ÅSTRÖM *et al.*, 1986).

2.4.1.4 Interface de usuário

A interface de usuário neste tipo de sistema (sistemas especialistas) está dividida em duas partes. Uma parte onde é realizado o projeto do sistema que contém ferramentas como o editor de regras e o navegador de regras, que por sua vez são necessários para a construção e o desenvolvimento da base de conhecimento do sistema. A outra parte é a interface do usuário durante o tempo de execução, que contém explicações de como foi tomada uma decisão, qual é

o erro do algoritmo em execução, o qual também permite o rastreamento de como são usadas as regras.

2.5 Sistemas Complexos Adaptativos

Os sistemas complexos adaptativos foram propostos por Holland (HOLLAND, 1995; HOLLAND, 1998). Estes sistemas se baseiam nos processos em que a natureza fornece solução aos problemas. Este tipo de técnica faz parte da computação natural. Normalmente o sistema complexo adaptativo consta de um sistema classificador, o qual está constituído por regras, que interagindo com o ambiente pode criar e evoluir as mesmas (BOOKER *et al.*, 1989). O ambiente é composto por modelos de problemas do mundo real, não-estacionários e normalmente de otimização e controle (VARGAS, 2000), que no estudo desta tese é o sistema BCS.

O sistema classificador interage com o ambiente através de mensagens recebendo-as do ambiente através de sensores, e atua sobre ele empregando atuadores como é apresentado na Figura 2.10. Quando o sensor recebe a mensagem do ambiente, este deve codificá-lo à linguagem do sistema classificador. O sistema classificador compara a mensagem obtida com as suas regras e seleciona uma delas levando em conta sua “energia”. A regra selecionada gera uma ação sobre o sistema através dos atuadores. Finalmente o ambiente fornece uma retroalimentação ao sistema classificador com respeito à ação executada pela regra e esta é “recompensada” ou “punida” de acordo com o resultado da ação.

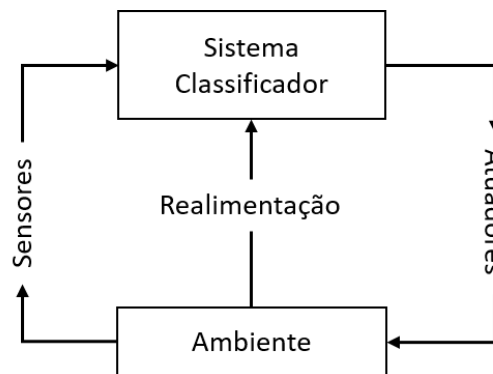


Figura 2.10: Sistema classificador interagindo com o ambiente.

Neste trabalho os classificadores são vetores formados pela concatenação de elementos pertencentes ao conjunto $\{N, Z, P, \#\}$, sendo:

- N quando o valor medido pelo sensor é Negativo;
- Z quando o valor medido pelo sensor é Zero;
- P quando o valor medido pelo sensor é Positivo;

- # o ‘don’t care’, pode assumir qualquer valor. O # faz o papel do coringa num jogo de cartas.

Os classificadores são representados como ilustrado na Tabela 2.1. Cada classificador tem uma parte ligada às condições “se” (por exemplo: se o ΔP é Negativo, a rotação não importa, quantidade de gás é Positiva, a pressão de entrada é Zero e a vazão de fluido não importa ou “(N#PZ#)”) e uma parte ligada às ações “então” (por exemplo: então diminuir a rotação e abrir a válvula ou “(NP)”). Cada classificador possui um valor de energia que representa sua força ou qualidade durante o processo evolutivo. A energia de cada classificador é inicializada num valor definido pelo usuário no início do treinamento do sistema complexo adaptativo.

Tabela 2.1: Exemplo Classificadores

| ID | Classificador (se) ... : (Então) ... | Energia |
|-------|---|---------|
| a_1 | $N\#PZ\# : PN$ | 80.5 |
| a_2 | $PNP\#N : ZP$ | 95,3 |
| a_3 | $PPP\#Z : PP$ | 45.5 |
| a_4 | $NZZZN : PZ$ | 63.5 |

Internamente, os sistemas classificadores dividem-se em três subsistemas distintos e interativos (ver figura 2.11):

- Subsistema de Tratamento de Regras e Mensagens
- Subsistema de Apropriação de Crédito
- Subsistema de Descoberta de Novas Regras

Descreve-se, a seguir, cada um destes subsistemas.

2.5.1 Subsistema de Tratamento de Regras e Mensagens

A figura 2.12 representa o fluxo interno do subsistema de tratamento de regras e mensagens (STRM). Após receber uma mensagem do ambiente e ser codificada na linguagem do sistema classificador, o subsistema seleciona os classificadores que se identificam com a mensagem, os quais são enviados ao subsistema de apropriação de crédito. Os classificadores que não se identificam com a mensagem são qualificados com uma taxa de vida. Isto permite após um certo tempo que os indivíduos que não são úteis para o processo sejam substituídos por novos classificadores fornecidos pelo subsistema de descoberta de novas regras.

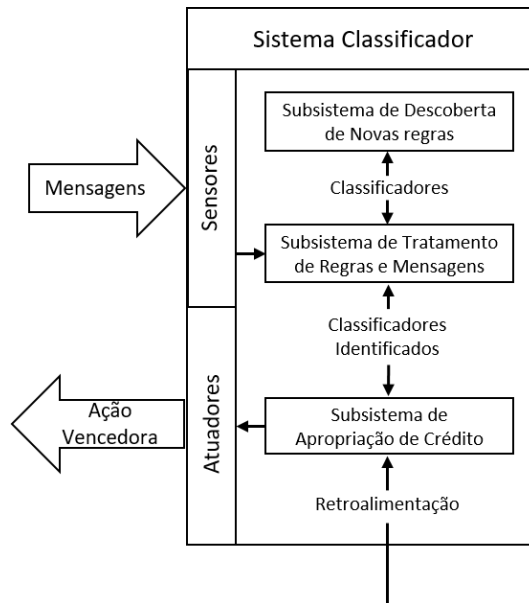


Figura 2.11: Subsistemas do sistema classificador interagindo com o ambiente.

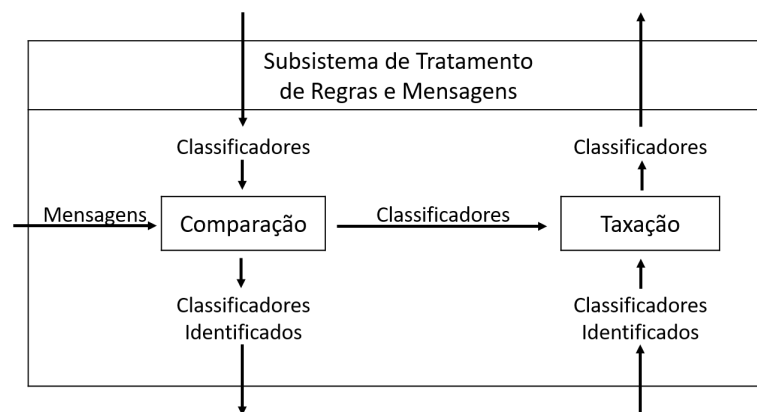


Figura 2.12: Diagrama de fluxo do subsistema de tratamento de regras e mensagens.

Para seleccionar os classificadores que se identificam com a mensagem o STRM compara cada classificador um a um com a mensagem, verificando célula a célula se o valor corresponde ou não à mensagem recebida. Os classificadores mais específicos são seleccionados. A especificidade de cada classificador é calculada empregando a equação 2.9:

$$M = \frac{l - n}{l} \quad (2.9)$$

na qual l é o comprimento do vetor e n é o número de células que não concordam. Lembrando que o “#” aceita qualquer valor na célula.

2.5.2 Subsistema de Apropriação de Crédito

Na figura 2.13 é apresentado o fluxo interno do subsistema de apropriação de crédito (SAC), o qual após receber os classificadores identificados no STRM, gera uma competição

entre eles para decidir quem atuará no ambiente. O ambiente dará uma realimentação ao SAC e assim este pode premiar ou punir a regra que fez a ação no ambiente.

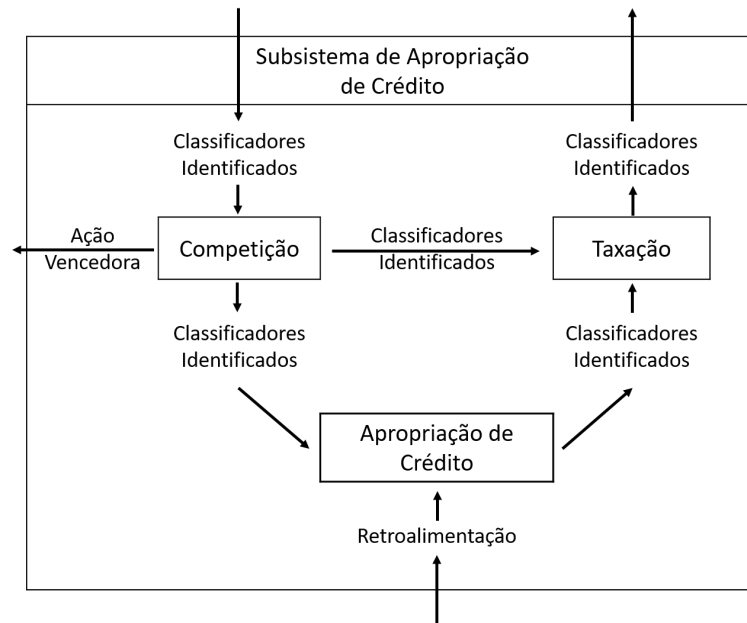


Figura 2.13: Diagrama de fluxo do subsistema de apropriação de crédito.

A competição entre os classificadores é realizada mediante um leilão onde a regra com o maior lance efetivo “*eBid*” será o vencedor e terá o direito a atuar no ambiente. O lance efetivo é dado pela equação 2.10:

$$eBid_t = Bid_t + \sigma_{Bid} * N_t \quad (2.10)$$

na qual o $eBid_t$ é o lance efetivo, o Bid_t é o lance da regra, o N_t é uma modulação caracterizada por um ruído com distribuição gaussiana de média 0 e variância 1, e o σ_{Bid} é um parâmetro específico que determina o nível de perturbação no Bid_t .

O lance da regra Bid_t é dado pela equação 2.11:

$$Bid_t = d_0 * (d_1 + d_2 * Spec) * S_t \quad (2.11)$$

na qual d_0 é o coeficiente referente à energia do classificador ($0 < d_0 < 1$); d_1 é o coeficiente referente à parte não específica do classificador ($0 < d_1 < 1$); d_2 é o coeficiente referente à parte específica do classificador ($0 < d_2 < 1$); $Spec$ é a especificidade do classificador, associada à proporção de símbolos “#” no classificador; e S_t é a energia ou “*strength*” do classificador no instante t .

A especificidade do classificador é definida pela equação 2.12:

$$Spec = \frac{l - N_{\#}}{l} \quad (2.12)$$

na qual l corresponde ao comprimento do vector e $N_{\#}$ corresponde ao número de células que contem “#”.

Ao indivíduo que ganha a competição é cobrado o valor de seu próprio Bid_t , já que tem o privilégio de atuar sobre o ambiente. A cada indivíduo que participou na competição é cobrada uma taxa de participação Tax_{bid} , que é equivalente à seu próprio Bid_t , como é apresentado na equação 2.13:

$$Tax_{bid} = Bid_{tax} * Bid_t \quad (2.13)$$

na qual Bid_{tax} é uma constante aplicada sobre o Bid do classificador.

Após o classificador atuar sobre o ambiente este responderá fornecendo uma retroalimentação para o sistema classificador. De acordo com os objetivos do projeto, o subsistema de apropriação de crédito tem a responsabilidade de definir o valor da recompensa ou punição R_t e incorporar este valor à energia do classificador. A Equação 2.14 representa a nova energia dos classificadores a cada instante de tempo (GOLDBERG, 1987b):

$$S_{t+1} = (1 - tax_v)s_t + R_t - Bid_t - Tax_{bid} \quad (2.14)$$

na qual S_t é a energia ou “*strength*” no instante t ; tax_v é a taxa de vida a qual é paga por todos os classificadores; R_t é o valor baseado na retroalimentação dada pelo ambiente e só é atribuída ao classificador que atuou no ambiente; o Bid_t é o lance do classificador que ganhou na competição e só é pago pelo classificador vitorioso no instante t ; e a Tax_{bid} é a taxa de participação na competição, paga pelos classificadores que participaram da mesma.

2.5.3 Subsistema de Descoberta de Novas Regras

O subsistema de descobertas de novas regras (SDNR) é um algoritmo genético (AG), o qual produz uma nova geração de classificadores, tratando os classificadores como indivíduos artificiais e empregando operadores genéticos. Este subsistema é ativado depois que o sistema especialista tenha atuado no processo um número i de iterações para dar tempo que os classificadores sejam punidos ou premiados pelo SAC modificando a energia deles, e assim poder empregar a energia como função ojetivo no AG (VARGAS, 2000).

Como é apresentado na Figura 2.14, o SDNR recebe os classificadores, realiza uma seleção dos mais aptos, ou seja, os classificadores com maior energia, e a partir dos melhores é construída uma geração de filhos, os quais são inseridos na população de classificadores substituindo os indivíduos com pior energia, procedimento este chamado de recomposição. Durante a recomposição, os indivíduos com a menor energia são trocados por filhos com os quais tenham afinidade, e estes filhos introduzidos terão a energia herdada dos pais. Na seção seguinte 2.6 é apresentado em detalhe o AG.

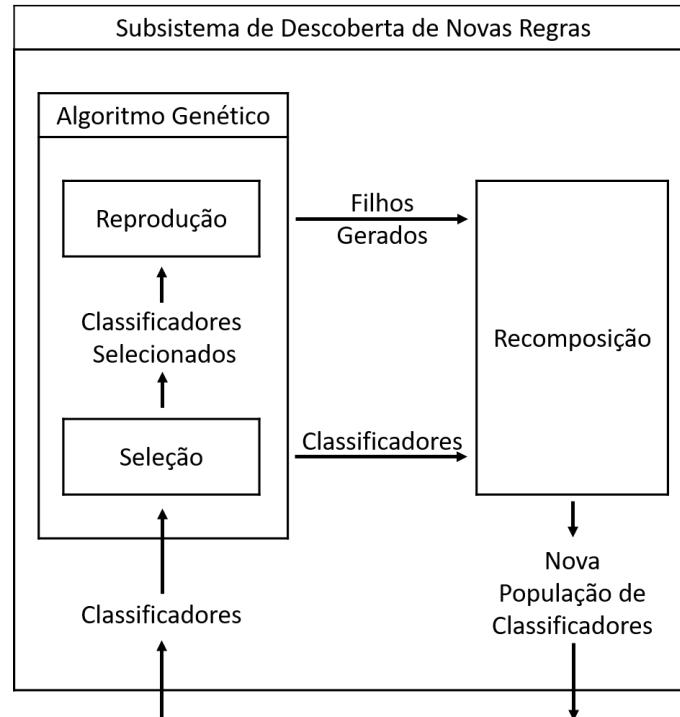


Figura 2.14: Diagrama de fluxo do subsistema de descoberta de novas regras.

2.6 Algoritmos Genéticos

As atividades computacionais motivadas pela biologia levaram a comunidade a criar uma área conhecida como “computação evolutiva”, da qual os algoritmos genéticos são um exemplo (MITCHELL, 1998). A computação evolutiva está baseada no processo de competição natural, no qual um conjunto de indivíduos compete por recursos limitados e seleção natural. Indivíduos mais adaptados têm maior probabilidade de sobreviver e propagar seu material genético. Uma medida de adaptação pode ser dada pela habilidade de uma população de indivíduos de antecipar o seu ambiente e agir a favor de responder os requerimentos associados aos prognósticos realizados (ATMAR, 1994).

Os algoritmos genéticos (AG) são um conjunto de regras e processos finitos baseados na genética, ou seja, são algoritmos de busca baseados na mecânica da genética, os quais operam indivíduos artificiais construídos com cadeias de caracteres da mesma maneira que a genética opera com os cromossomos em uma população de organismos. Em outras palavras, os algoritmos genéticos fazem que uma população de indivíduos artificiais obedeçam a lei darwiniana da sobrevivência dos mais aptos (GOLDBERG, 1987a; VARGAS, 2000).

A Figura 2.15 apresenta um diagrama de fluxo do algoritmo genético. Como se pode apreciar na figura, o primeiro passo é gerar uma população inicial, a qual está conformada por n indivíduos pertencentes ao espaço de busca com uma representação adequada ao problema a otimizar. O segundo passo é avaliar a população, e para isto, é necessário ter uma função de “*fitness*”, a qual atribuirá um valor de adaptação a cada um dos indivíduos. No terceiro

passo entramos no ciclo evolutivo, que aplica operadores genéticos nos indivíduos artificiais, empregando o valor de adaptação para realizar uma seleção dos indivíduos melhor adaptados usando um operador de busca, para serem os “Pai” da nova geração. A partir dos indivíduos selecionados, “os Pais”, e empregando um operador de recombinação são gerados os novos indivíduos, “Filhos”. Na evolução natural existem erros na recombinação dos indivíduos gerando mutações, aspecto este que é simulado no AG usando um operador de mutação. Os filhos e filhos que sofreram a mutação vão ser inseridos na população gerando uma nova população. Neste ponto, é aplicada a função de *fitness*, e o ciclo reprodutivo começa de novo até atingir a condição de parada.

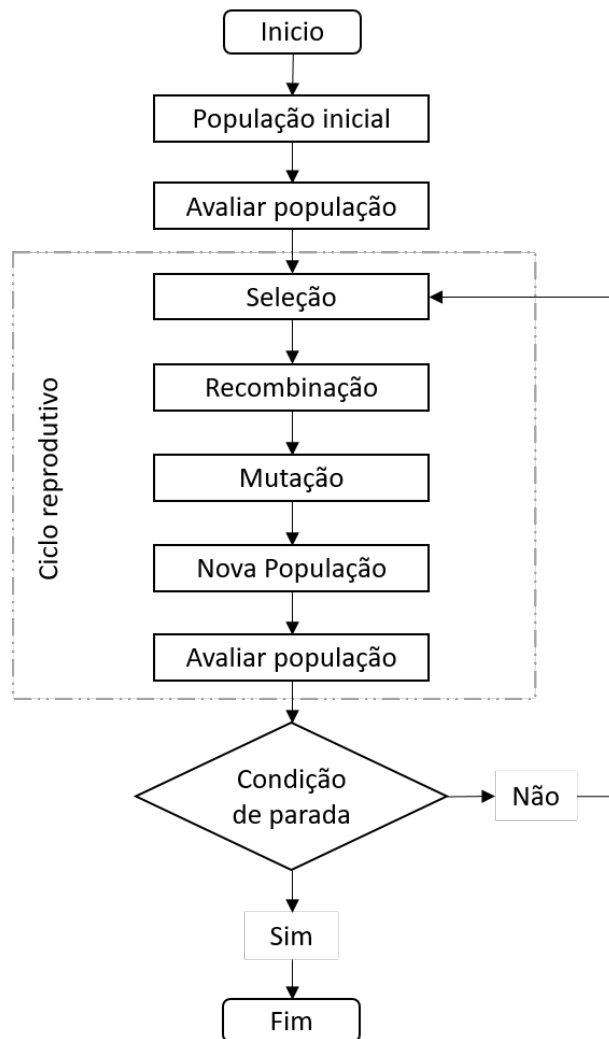


Figura 2.15: Diagrama de fluxo do algoritmo genético.

2.6.1 Representação

A representação é a forma de codificar ou representar as possíveis soluções de um problema em estudo. A estrutura vai depender do problema e também do método de busca. Tanto a eficiência quanto a dificuldade ou a complexidade do método de busca

dependem da representação, sendo assim a seleção da representação adequada em conjunto com os operadores genéticos são fatores críticos na implementação do algoritmo genético (MITCHELL, 1998).

O cromossomo é conhecido, nos algoritmos genéticos, como um candidato a ser solução do problema codificado num arranjo de caracteres. Os genes são um caráter que codifica um elemento particular da solução candidata (um exemplo neste projeto pode ser o estado de um sensor ou a ação de controle num atuador). Os alelos são os valores possíveis que pode conter cada lócus, por exemplo: $\{N, Z, P, \#\}$. O lócus é a posição do gene no arranjo de caracteres. A Figura 2.16 apresenta um cromossomo com cada um do seus componentes.




Figura 2.16: Ilustração de um cromossomo.

A maioria de aplicações de algoritmos genéticos empregam indivíduos haploides, ou seja, indivíduos com um único cromossomo.

2.6.2 Função de *Fitness*

É necessário dar um valor de adaptação a cada um dos indivíduos para ter a noção de quão bem ou mal adaptados estão ao problema em estudo. Por esta necessidade, um algoritmo genético começa na definição de uma função objetivo, o qual, é o problema de otimização a ser resolvido. A função de fitness realiza um mapeamento da função objetivo num intervalo positivo.

Um exemplo de como a função *fitness* mapeia a função objetivo num intervalo positivo. Tendo como exemplo o problema de otimização dado pela equação 2.15:

$$\min_{y \in [-\pi, \pi]} (f(y)) \quad (2.15)$$

na qual $f(y)$ pode ser dado pela equação 2.16:

$$f(y) = 0,1 * \sin(32y) - e^{-|y|} \quad (2.16)$$

Uma função *fitness* adequada para o problema é apresentada na equação 2.17:

$$\phi(f(y)) = \frac{1}{1 + f(y) - f_{min}} \quad (2.17)$$

na qual f_{min} é o mínimo global da função objetivo $f(y)$, e no caso que o mínimo global não seja conhecido é empregado o mínimo até a iteração atual. Como podemos ver na Figura 2.17 a função *fitness* mapeia a função objetivo $f(y)$ no intervalo positivo $[0, 1]$, atribuindo o maior valor ao melhor indivíduo.




Figura 2.17: Exemplo do mapeamento da função *fitness*

2.6.3 Mecanismo de Seleção

O mecanismo de seleção é um dos aspectos mais importantes a se levar em conta no momento de projetar um algoritmo genético, porque é a forma de selecionar os indivíduos da população que formarão a próxima geração. O propósito da seleção é dar prioridade aos indivíduos mais bem adaptados com a esperança que os descendentes tenham uma melhor adaptação que os seus pais (MITCHELL, 1998).

A seleção tem um conceito conhecido como pressão seletiva que é relacionado com o tempo de dominância do operador. Segundo Back o tempo de dominância ou “*takeover*” é definido pelo número de gerações que demora o melhor indivíduo em ser copiado e preencher toda a população (BACK, 1994). Um processo seletivo muito forte pode fazer com que indivíduos sub-ótimos se apoderem da população, reduzindo, conseqüentemente, a diversidade necessária para gerar uma mudança em favor do progresso da população; por outro lado, uma seleção fraca causaria uma evolução muito lenta.

Existe uma grande discussão sobre a seleção já que não existe uma norma que dite que mecanismo ou que método deve ser usado para cada problema. Na literatura podemos encontrar diferentes métodos de seleção. (BACK, 1994) no seu trabalho discute os mecanismos de seleção mais importantes comparando-os com respeito a sua pressão seletiva, entre eles encontramos: seleção proporcional, seleção por torneio, ranking linear entre outros.

Neste trabalho vamos levar em conta o mecanismo de seleção proporcional, já que este método prioriza a seleção aos indivíduos melhor adaptados ao problema, ou seja, às regras

que tiveram um bom desempenho ao interagir com o ambiente, ao mesmo tempo que apresenta uma pequena probabilidade de que indivíduos pior adaptados sejam selecionados, o que ajuda a manter a diversidade da população. Dita diversidade é importante no desenvolvimento da base das regras do sistema especialista, já que se poucas regras chegassem a dominar a população, elas não teriam a capacidade de controlar o sistema.

2.6.3.1 Seleção Proporcional

A seleção proporcional foi introduzida nos algoritmos genéticos por Holland: os indivíduos são selecionados empregando probabilidade proporcional ao valor de *fitness* (BÄCK; HOFFMEISTER, 1991). Esta probabilidade pode ser dada por:

$$p_i = \frac{\phi(a_i)}{\sum_{j=1}^{\lambda} \phi(a_j)} \quad (2.18)$$

na qual p_i é a probabilidade do indivíduo i , $\phi(a_i)$ é o valor de *fitness* para o mesmo indivíduo, e λ é o tamanho da população.

É indispensável ajustar o valor do *fitness* como foi estudado na sub-seção 2.6.2 pois a Equação 2.18 falha para valores negativos e também para problemas de minimização.

Um método amplamente empregado na seleção proporcional é o método da roleta (*roulette-wheel sampling* em inglês). Este consiste em dar uma porcentagem de uma roleta a cada indivíduo proporcional a seu valor de *fitness*, ou seja, aos indivíduos melhor adaptados é atribuída uma porção maior da roleta. Pelo contrário, aos piores adaptados é atribuída uma porção relativamente menor da roleta. A roleta é girada e alguns indivíduos sorteados são selecionados. Este método dá uma pequena oportunidade aos indivíduos menos adaptados a serem selecionados com a finalidade de se manter a diversidade da população. Por exemplo, levando em conta o problema apresentado na Figura 2.18 a roleta foi girada quatro vezes; as duas primeiras rodadas os indivíduos a_2 e a_4 foram selecionados como pais, e nas duas seguintes foram selecionados os indivíduos a_2 e a_3 como pais. O indivíduo a_1 não foi selecionado no sorteio. Porém quanto maior for o número de rodadas, os resultados médios serão mais próximos ao esperado (MITCHELL, 1998).

2.6.4 Operadores Genéticos

Existe uma grande variedade de operadores genéticos tanto de *crossover* quanto de mutação. A seleção dos mesmos depende em grande parte da representação dos indivíduos adotada para o problema. Larranaga apresenta uma variedade de operadores genéticos para indivíduos onde a estrutura do cromossomo é conformada por estados ordenados em forma de vetores, e a solução do problema pode ser achada combinando a estrutura dos indivíduos ou mudando os estados de um ponto ou fragmentos da estrutura do cromossomo (LARRANAGA *et al.*, 1996).

| ID | Cromossomo | Energia | <i>Fitness</i> | Porcentagem |
|-------|----------------|---------|----------------|-------------|
| a_1 | $N\#PZ\# : PN$ | 80.5 | 0.049 | 18.14% |
| a_2 | $PNP\#N : ZP$ | 95,3 | 0.175 | 65.24% |
| a_3 | $PPP\#Z : PP$ | 45.5 | 0.018 | 6.7% |
| a_4 | $NZZZN : PZ$ | 63.5 | 0.026 | 9.9% |




Figura 2.18: Seleção método da roleta

A seguir será feita uma análise sobre o operador de crossover e o operador de mutação empregados neste projeto. É necessário fazer uma seleção adequada de operadores genéticos dentre os amplamente empregados para problemas com representações similares à adotada neste projeto.

2.6.4.1 Operador de Crossover

Os operadores de crossover trocam partes das estruturas (cromossomo) de dados de dois ou mais indivíduos “pais selecionados aleatoriamente” para produzir descendentes “filhos”. Quando o cromossomo é conformado por uma cadeia de caracteres pode-se empregar crossover de 1 ou n pontos de corte, os quais são o número de vezes que a cadeia de caracteres dos indivíduos “pais” vão se cortar para realizar o cruzamento em sua estrutura. Os pontos de corte são selecionados de forma aleatória. Na Figura 2.19 é apresentado um exemplo comparando o crossover de 1 ponto com o crossover de 2 pontos empregando os mesmos dois pais para obter dois filhos.

2.6.4.2 Operador Mutação

Na natureza, a mutação são trocas na sequência dos nucleotídeos do material genético de um organismo. Baseado nisto, o princípio do operador genético é executar um processo onde um ou mais dos alelos de um gene é trocado ou modificado de forma aleatória

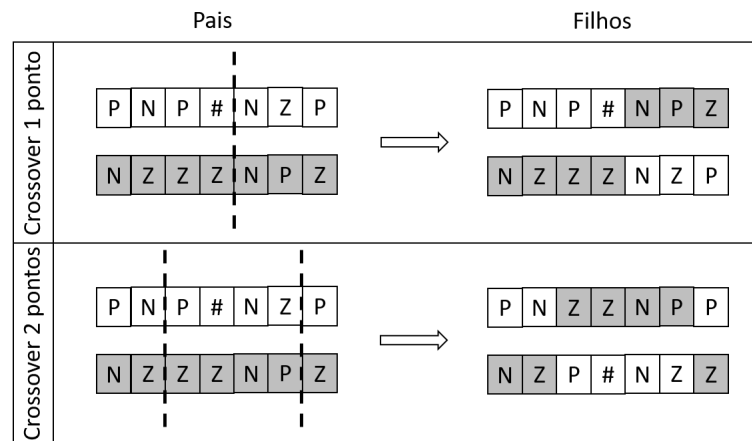


Figura 2.19: Exemplo de crossover com n pontos de corte.

por outro com a finalidade de criar um novo indivíduo a partir de um indivíduo existente (JONG, 1975; HOLLAND, 1975).

Para decidir se um indivíduo sofre a mutação ou não, normalmente é usada uma probabilidade de mutação p_m . Esta probabilidade é atribuída a cada indivíduo, e em geral é baixa.

Existem diferentes métodos de mutação, os quais variam dependendo de como trocamos a estrutura do cromossomo dos indivíduos. Por exemplo: pode-se mudar um gene no cromossomo (conhecida como mutação simples); ou alterando um determinado número de genes selecionados de forma aleatória (conhecida como mutação aleatória) (VARGAS, 2000). Na Figura 2.20 é apresentado um exemplo de como funciona a mutação simples num indivíduo, trocando o alelo N do quinto gene pelo alelo $\#$.




Figura 2.20: Exemplo de mutação simples.

2.7 Filtro de Partículas

O filtro de partículas e o método recursivo de Monte Carlo permitem obter uma solução bayesiana ótima de sistemas modelados mediante equações de estados não-gaussianas e não-lineares. O filtro de partículas calcula a probabilidade posterior dos estados do sistema de maneira sequencial, empregando dados de observação (GENÇAĞA *et al.*, 2005; GORDON *et al.*, 1993).

Num problema de estimação em tempo discreto, considerando um vetor de estados x_k que evolui de acordo com:

$$x_k = f_k(x_{k-1}, w_k) \quad (2.19)$$

na qual f_k é a função do modelo não-linear de transição dos estados e w_k é uma variável com ruído branco e média zero que é independente dos estados atuais e passados. As medições y_k estarão disponíveis. Estas medições estão relacionadas com o vetor de estados x_k através da equação de observação:

$$y_k = h_k(x_k, v_k) \quad (2.20)$$

na qual h_k é a função de medição e v_k é outra variável com ruído branco e média zero que é independente dos estados atuais e passados (GENÇAĞA *et al.*, 2005; GORDON *et al.*, 1993).

O objetivo da estimação de estados é calcular de maneira sequencial o vetor de estados x_k a partir das medições y_k . Para isto é necessário achar a função de probabilidade $p(x_k | y_{1:k})$ do estado x_k dadas a medições sequenciais $y_{1:k-1} = \{y_i : i = 1, \dots, k-1\}$.

Pode-se supor que a função probabilidade $p(x_{k-1} | y_{1:k-1})$ no instante $k-1$ é conhecida. Então, empregando-se o modelo do sistema, é possível obter a função de probabilidade no instante k (GENÇAĞA *et al.*, 2005):

$$p(x_k | y_{1:k-1}) = \int p(x_k | x_{k-1}) p(x_{k-1} | y_{1:k-1}) dx_{k-1} \quad (2.21)$$

No instante k a medição y_k estará disponível e assim a função de probabilidade pode ser atualizada de maneira sequencial empregando as medições anteriores com a equação a seguir:

$$p(x_k | y_{1:k}) = \frac{p(y_k | x_k) p(x_k | y_{1:k-1})}{p(y_k | y_{1:k-1})} \quad (2.22)$$

na qual o denominador é dado por:

$$p(y_k | y_{1:k-1}) = \int p(y_k | x_k) p(x_k | y_{1:k-1}) dx_k \quad (2.23)$$

Normalmente em sistemas não-lineares é possível não haver expressões analíticas para descrever as variáveis do sistema. Assim, as variáveis podem ser representadas como amostras, amostras estas que são chamadas de partículas (GENÇAĞA *et al.*, 2005).

A função de probabilidade $p(x_k | y_{1:k})$ pode ser dada em termo das partículas x_k^i através da equação 2.24:

$$p(x_k | y_{1:k}) = \sum_{i=1}^N w_k^i \delta(x_k - x_k^i) \quad (2.24)$$

na qual w_k^i é o peso da partícula i , e $\delta(\cdot)$ é a função delta de Dirac. Os pesos são definidos pela Equação 2.25, na qual temos que definir a densidade $q(x_k^i | y_{1:k})$ em que as partículas podem ser obtidas.

$$w_k^i \propto \frac{p(x_k^i | y_{1:k})}{q(x_k^i | y_{1:k})} \quad (2.25)$$

Do mesmo modo que na equação 2.22, os pesos podem ser atualizados de maneira sequencial empregando-se a medição y_k e os estados anteriores x_{k-1} empregando-se a equação 2.26:

$$w_k^i \propto w_{k-1}^i \frac{p(y_k | x_k^i) p(x_k^i | x_{k-1}^i)}{q(x_k^i | x_{k-1}^i, y_k)} \quad (2.26)$$

A estimação do vetor de estados \tilde{x}_k é o valor médio de $p(x_k | y_{1:k})$ que é calculado empregando-se as partículas x_k^i e seu peso associado w_k^i como é mostrado na equação 2.27 (GAGO, 2013).

$$\tilde{x}_k = \sum_{i=1}^N x_k^i w_k^i \quad (2.27)$$

2.8 Máquinas de Vetores de Suporte

As máquinas de vetores de suporte (SVM, do inglês *Support Vector Machines*) são algoritmos de aprendizagem de máquinas supervisionadas para problemas de classificação e regressão. Bernhard E. Boser, Isabelle M. Guyon e Vladimir N. Vapnik sugeriram em 1992 uma maneira de desenvolver classificadores não lineares é aplicado uma função chamada de “kernel” para o problema de margem máxima (BOSER *et al.*, 1992), em 1995 Vladimir Vapnik e colaboradores foram os primeiros a empregar o nome de máquinas de vetores de suporte (VAPNIK *et al.*, 1997; ZHANG; LEI, 2013).

Para o caso de máquinas de vetores de suporte para regressão (SVMr) tem-se um conjunto de dados de treinamento dado por:

$$D_t = \{(x_i, y_i)\}_{(i=1,2,\dots,m)} \quad (2.28)$$

na qual cada $x_i \in \mathbb{R}^n$ representa uma amostra dos dados de entrada e cada $y_i \in \mathbb{R}$ um objetivo. O objetivo da SVM é achar uma função $f(x)$ que tenha como máximo um ε de erro dos objetivos

reais das amostras y_i . Ou seja, estimar os coeficientes de regressão de $f(x)$ com os requisitos dados (STOEAN *et al.*, 2006; SMOLA; SCHÖLKOPF, 2004).

Seja um conjunto de dados representado na Figura 2.21. Suponha-se que um modelo de regressão linear possa ajustar os dados de treinamento da Figura 2.21, cuja função $f(x)$ tem a forma:




Figura 2.21: Problema de regressão linear com SVM.

$$f(x) = \langle w, x \rangle + b \quad (2.29)$$

Na qual $w \in \mathbb{R}^n$ é a inclinação do plano de regressão e $b \in \mathbb{R}$ é o ponto onde a superfície intersecta o eixo y . A SVM tem como objetivo aproximar uma função $f(x)$ aos dados de treinamento com uma precisão ϵ , pode ser escrita matematicamente como:

$$|y_i - (\langle w, x_i \rangle + b)| \leq \epsilon, i = 1, 2, \dots, m \quad (2.30)$$

ou

$$\begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon \\ \langle w, x_i \rangle + b - y_i \leq \epsilon \end{cases}, i = 1, 2, \dots, m \quad (2.31)$$

Ao mesmo tempo, a SVMr tenta obter a menor margem que contenha a maioria dos dados com a menor inclinação, isto é, w com a condição:

$$\min_w \frac{1}{2} \|w\|^2 \quad (2.32)$$

O problema de otimização no caso de SVMr linear é dado por:

$$\left\{ \begin{array}{l} \min_w \frac{1}{2} \|w\|^2 \\ \text{sujeito a } \left\{ \begin{array}{l} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon \end{array} \right. , i = 1, 2, \dots, m \end{array} \right. \quad (2.33)$$

As funções $f(x)$ normalmente podem conter ruído, então para que a SVMr possa aproximar as funções e permitir erros, são acrescentadas variáveis de relaxamento ξ_i e ξ_i^* na condição de aproximação dos dados de treinamento ligados a cada uma das amostras, na forma (STOEAN *et al.*, 2006; SMOLA; SCHÖLKOPF, 2004; ZHANG; LEI, 2013):

$$\left\{ \begin{array}{l} \min_w \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \\ \text{sujeito a } \left\{ \begin{array}{l} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{array} \right. , i = 1, 2, \dots, m \end{array} \right. \quad (2.34)$$

Na qual $C > 0$ é um parâmetro que penaliza os erros permitidos, ou seja, C determina o equilíbrio entre a curvatura da função $f(x)$ com respeito à quantidade de derivações máximas permitidas por ε . O problema apresentado na equação 2.34 pode ser resolvido empregando-se a formulação dual e a programação quadrática (ZHANG; LEI, 2013). A ideia é construir uma função de Lagrange da função objetivo acrescentando-se um conjunto de variáveis chamadas de multiplicadores de Lagrange. A formulação correspondente é apresentada na forma (SMOLA; SCHÖLKOPF, 2004):

$$L = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) - \sum_{i=1}^m (\eta_i \xi_i + \eta_i^* \xi_i^*) - \sum_{i=1}^m \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x_i \rangle + b) - \sum_{i=1}^m \alpha_i^* (\varepsilon + \xi_i^* - y_i + \langle w, x_i \rangle + b) \quad (2.35)$$

com

$$\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0 \quad (2.36)$$

Na qual L é a função de Lagrange e $\alpha_i, \alpha_i^*, \eta_i, \eta_i^*$ são os multiplicadores de Lagrange. Derivando-se a função de Lagrange em relação às variáveis principais (b, w, ξ_i, ξ_i^*) obtém-se:

$$\frac{\partial L}{\partial b} = \sum_{i=1}^m (\alpha_i^* - \alpha_i) = 0 \quad (2.37)$$

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^m (\alpha_i - \alpha_i^*) x_i = 0 \quad (2.38)$$

$$\frac{\partial L}{\partial \xi_i} = C - \alpha_i - \eta_i = 0 \quad (2.39)$$

$$\frac{\partial L}{\partial \xi_i^*} = C - \alpha_i^* - \eta_i^* = 0 \quad (2.40)$$

Substituindo 2.37, 2.38, 2.39 e 2.40 em 2.35 se obtém o problema de otimização dual:

$$\max \left[-\frac{1}{2} \sum_{i,j}^m (\alpha_i^* - \alpha_i) (\alpha_j^* - \alpha_j) \langle x_i, x_j \rangle - \varepsilon \sum_{i,j}^m (\alpha_i^* + \alpha_i) + \sum_{i,j}^m y_i (\alpha_i^* - \alpha_i) \right] \quad (2.41)$$

$$\text{sujeito a } \begin{cases} \sum_{i,j}^m (\alpha_i^* - \alpha_i) = 0 \\ \alpha_i^*, \alpha_i \in [0, C] \end{cases}$$

Depois de solucionar o problema dual, a decisão ótima pode ser obtida por (ZHANG; LEI, 2013):

$$f(x) = \sum_{i=1}^m (\alpha_i^* - \alpha_i) \langle x_i, x \rangle + b \quad (2.42)$$

A equação 2.42 é chamada de expansão de máquinas de vetores de suporte (ZHANG; LEI, 2013). Num certo sentido a complexidade da representação de uma função SVM é independente do número de dimensões do espaço de entradas, e depende só do número de vetores de suporte (SVs).

Os problemas não lineares são mais comuns nas aplicações práticas. A forma de resolver este tipo de problema é usando uma função *kernel* ou núcleo. A função *Kernel* computa o produto interno dos dados de entrada em algum espaço de características para resolver o problema de otimização quadrática (CORTES; VAPNIK, 1995; VAPNIK *et al.*, 1997), melhorando assim a capacidade da máquinas de vetores de suporte linear de representar a relação não linear no espaço de entrada original. A função de decisão ótima com o *kernel* é dada por:

$$f(x) = \sum_{i=1}^m (\alpha_i^* - \alpha_i) K(x_i, x) + b \quad (2.43)$$

Na qual $K(x_i, x)$ é a função de *kernel*. Quanto maior for a dimensão do espaço de descrição, o *kernel* vai apresentar uma maior probabilidade de obter um hiperplano. Ao transformar o espaço de entrada em um espaço superior (teoricamente de dimensão infinita), é possível obter uma separação das classes mediante hiperplanos. Na Figura 2.22 mostra-se um exemplo do funcionamento geral de uma função de *kernel*, onde o conjunto de pontos no espaço de entrada

é um problema não linear, mas depois de aplicar a transformação empregando uma função de *kernel* é possível que na nova representação surjam estruturas lineares.


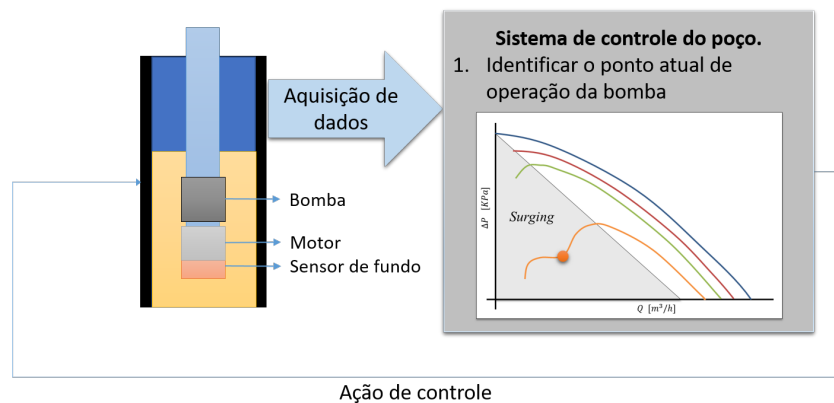


Figura 2.22: Mapeamento de alta dimensionalidade.

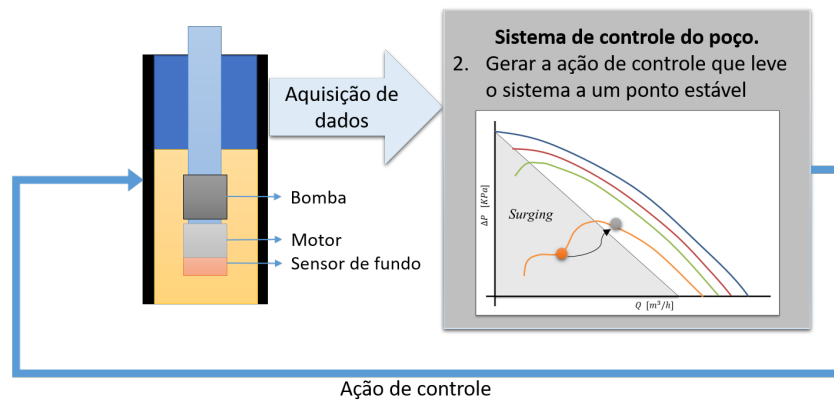
Um *kernel* é uma função simétrica de duas variáveis onde a matriz cujos elementos são $K(x_i, x)$ tem que ser semidefinida positiva. As funções que satisfazem essa condição definem implicitamente um mapeamento do espaço de entrada para o espaço superior introduzindo não linearidades por médio de uma modificação direta (PÉREZ-CRUZ; BOUSQUET, 2004).

3 CONTROLE ESPECIALISTA APLICADO AO SISTEMA DE BCS

Após entender o desempenho da bomba BCS operando com fluidos bifásicos pode-se estabelecer o objetivo de controle, o qual é manter a bomba operando dentro de uma zona segura de operação, e levar a bomba de um ponto inseguro (área de *surging*, por exemplo) para uma zona segura como é apresentado na Figura 3.1. Tudo isto deve ser feito pelo sistema de controle.



(a) Identificação do ponto de operação



(b) Ajuste do ponto de operação

Figura 3.1: Representação da malha de controle para o sistema BCS.

A Figura 3.1 apresenta a malha de controle. A partir de um conjunto de dados que são adquiridos do processo, o sistema de controle identifica o ponto atual de operação e posteriormente gera a ação de controle para garantir o bom funcionamento do sistema.

É proposto empregar um controle especialista, como é apresentado na seção 2.4, que pode ser construído empregando ferramentas ou algoritmos trabalhando em conjunto com um sistema especialista que tenham a capacidade de resolver o problema de controle. Nesta tese, o sistema especialista é obtido empregando-se um sistema complexo adaptativo, o qual permite criar o conhecimento necessário para controlar o sistema BCS.

Para construir o sistema de controle, propõe-se que a partir de dados experimentais, obtidos da bomba BCS empregada no processo, sejam obtidos modelos que ajudem a construir as curvas de desempenho da bomba, como é apresentado na seção 3.3. Os modelos são obtidos empregando-se máquinas de vetores de suporte para regressão (SVMr).

Os modelos obtidos mediante as SVM são empregados para estimar a vazão total de fluido fazendo-se uso de um filtro de partículas como é apresentado na seção 3.3. Além disto, os modelos SVM são empregados para calcular o ponto de *surging* (na curva de elevação) e o ponto de BEP (nas curvas de eficiência), nas quais o sistema BCS está operando como é apresentado na seção 3.5.

Conhecendo os pontos de operação de interesse tais como: o ponto estimado de operação da bomba, o ponto de BEP e o ponto de *surging*, o sistema complexo adaptativo pode ser treinado, como é apresentado na seção 3.4, o qual interagindo com o sistema BCS aprende a controlar o mesmo.

Neste capítulo é apresentada a arquitetura do controlador proposto para controlar o sistema BCS, onde é descrito cada um dos componentes que constituem o controlador especialista.

3.1 Arquitetura do Controle Especialista para o Controle da BCS

A arquitetura proposta para o controle especialista está apresentada na Figura 3.2, a qual é baseada na arquitetura proposta por (ÅRZÉN, 1989).

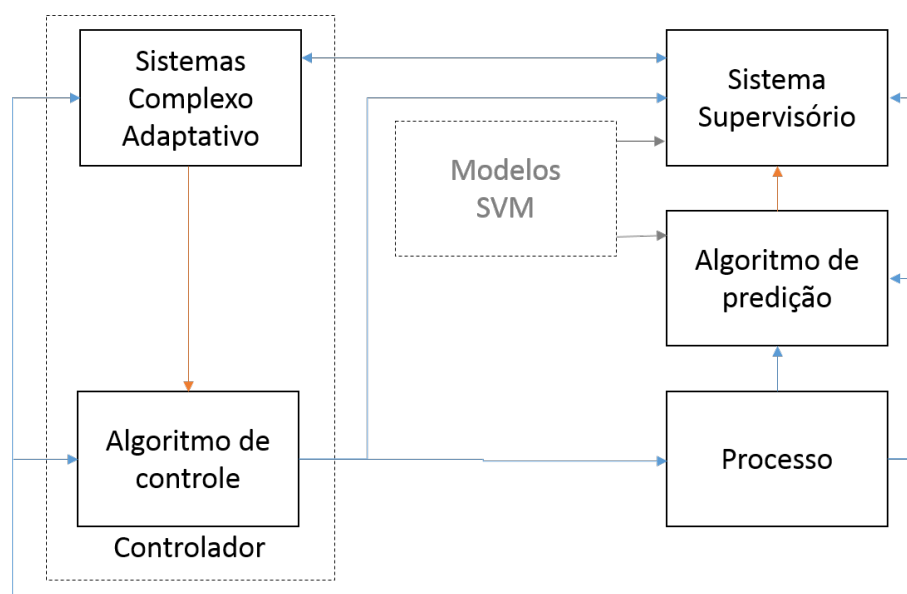


Figura 3.2: Arquitetura proposta para o controlador especialistas.

Da Figura 3.2 pode-se apreciar cinco componentes principais do controlador:

- **Processo:** representa o processo real, neste caso é o sistema BCS.

- **Algoritmo de controle:** responsável em decodificar a ação solicitada pelo sistema complexo adaptativo e gerar a ação de controle correspondente sobre o processo.
- **Sistema Complexo Adaptativo:** base de conhecimento gerada automaticamente a partir do conhecimento a priori e a experiência adquirida com o tempo ao interagir com o processo.
- **Algoritmo de predição:** gera variáveis não mensuráveis diretamente do sistema, o algoritmo de predição emprega um filtro de partículas como preditor.
- **Sistema Supervisório:** algoritmo que tem a interface de usuário que permite ao usuário supervisionar tanto sistema de controle quanto o processo. O sistema supervisório é onde se definem os limites de funcionamento e os alarmes. Também é onde se encontra o algoritmo que calcula o BEP para a curva do sistema BCS de acordo com sua pressão de entrada na BCS P_{in} , sua fração de vazio na mistura α , e sua rotação da BCS ω_{BCS} .

Como é apresentado na Figura 3.2, tanto o algoritmo de predição quanto o sistema supervisório precisam de modelos que representem as curvas de desempenho da bomba a ser controlada. Na seção 3.2 é apresentado como foi obtido o modelo para a bomba BCS em teste.

3.2 Modelagem da Bomba BCS

Nesta seção é apresentada a metodologia para a modelagem da BCS, obtendo se um modelo geral não linear e não paramétrico composto por submodelos de logica inacessível de cada uma das curvas de desempenho da bomba.

Para obter o modelo que possa representar o comportamento do sistema neste caso não linear, estático e determinístico, vamos considerar a Figura 3.3 na qual são apresentadas as atividades básicas para a identificação de um sistemas (LJUNG, 1999).

3.2.1 Estrutura do Modelo

A estrutura do modelo geral da BCS está baseada em um modelo de logica inacessível como é apresentado na Figura 3.4, cujas entradas são: a pressão de admissão na BCS P_{in} , a fração de vazio da mistura α , a rotação ω_{BCS} , e a vazão da mistura água-gás Q_t , e como dados de saída: a pressão de descarga gerada pela BCS P_{out} , a potência mecânica W_m e a eficiência η . O modelo geral é obtido através da aplicação de máquinas de vetores de suporte para regressão, o qual gera um modelo independente para P_{out} e W_m . A eficiência η é calculada empregando-se a teoria apresentada na subseção 2.1.2, tal qual é apresentado na Figura 3.4.

Os modelos estão representados por:

$$\tilde{P}_{out} = h(P_{in}, \alpha, \omega_{BCS}, Q_t) \quad (3.1)$$

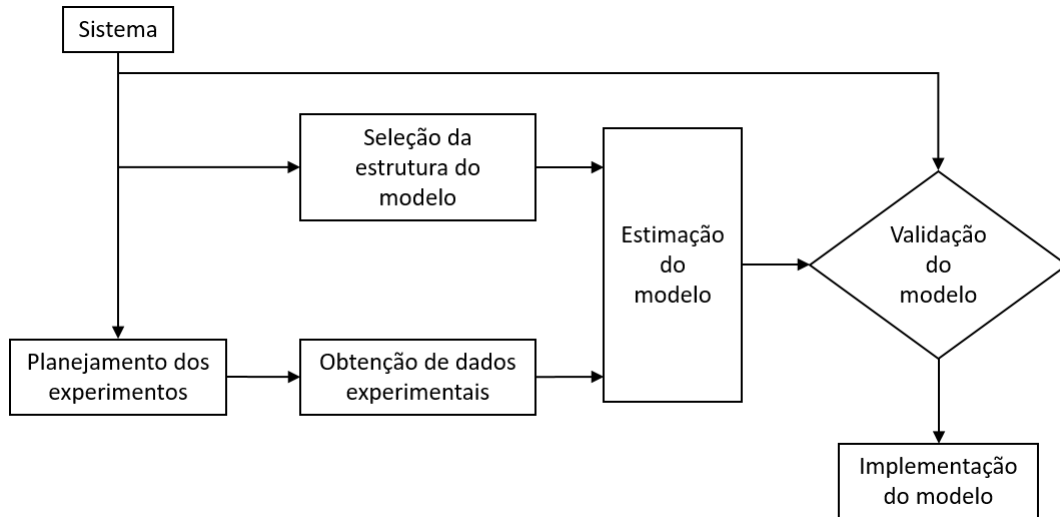


Figura 3.3: Atividades básicas para o processo de identificação.

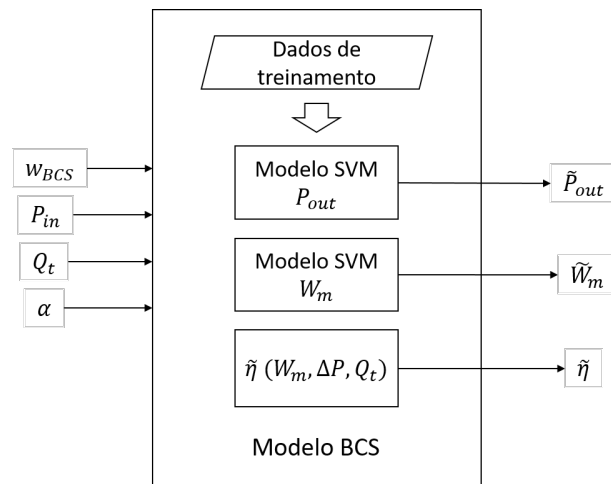


Figura 3.4: Diagrama de blocos do modelo da BCS.

$$\tilde{W}_{me} = h(P_{in}, \alpha, \omega_{BCS}, Q_t) \quad (3.2)$$

$$\tilde{\eta} = \frac{(\tilde{P}_{out} - P_{in}) Q_t}{\tilde{W}_m} \quad (3.3)$$

Sendo \tilde{P}_{out} , \tilde{W}_{me} e $\tilde{\eta}$ os valores estimados pelo modelo e $h(\cdot)$ a função não paramétrica do modelo obtida pelo treinamento da SVMr.

Com o objetivo de obter os melhores parâmetros para o treinamento da SVM (o C da penalidade, o σ do “kernel” gaussiano e o ε da margem), utilizaram-se algoritmos genéticos (ver Anexo B), já que o espaço de procura destes algoritmos é maior que uma busca rigorosa por validação cruzada, e devido a quantidade de dados disponíveis, o custo computacional é menor (CHANG; LIN, 2011). Para o treinamento do modelo de SVMr utilizou-se os “toolboxes” de distribuição gratuita (SVMLIB) executadas no MatLab.

3.2.1.1 Regulação dos Modelos Mediante Bias/Variância

É necessário saber se os modelos SVMr apresentam problemas de bias (subajuste) ou variância (sobreajuste), para melhorar o modelo. Uma forma de solucionar este problema é ter hipóteses em um nível intermediário de complexidade, já que dá o menor erro generalizado (ANDREW, 2012). A Figura 3.5 apresenta os erros de validação e os erros de treinamento com respeito aos modelos obtidos do algoritmo, por exemplo, os diferentes modelos obtidos de SVMr variando o parâmetro de penalização C .

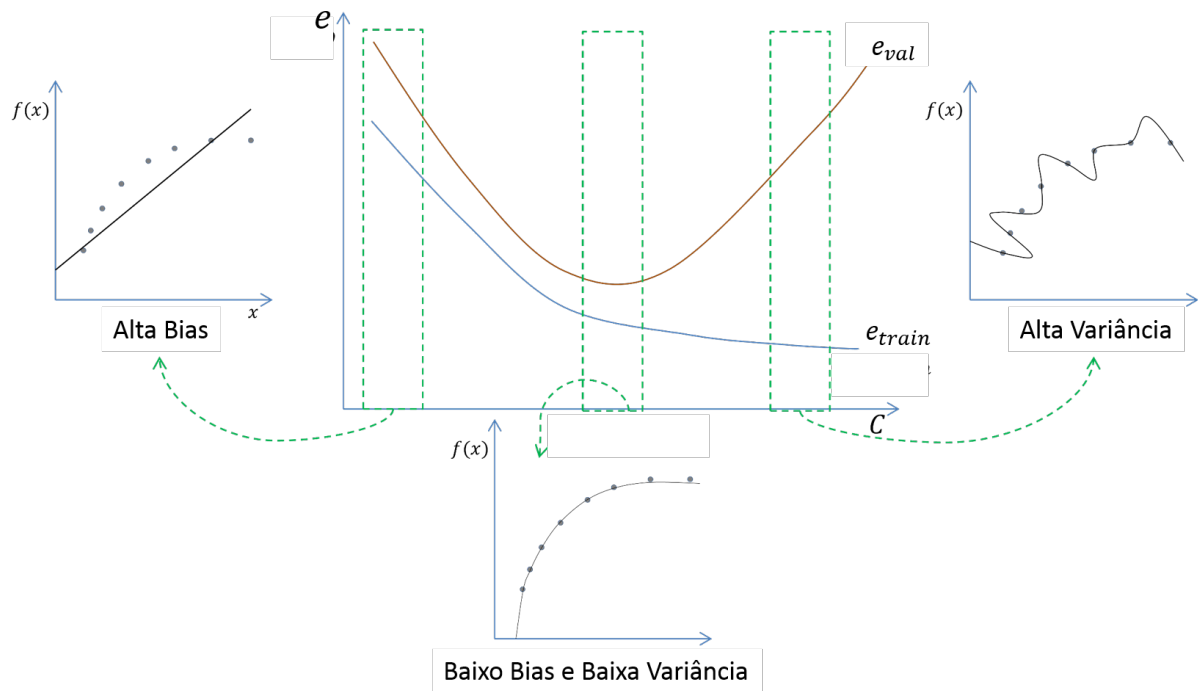


Figura 3.5: Bias e Variância com Respeito aos Modelos.

Para realizar a regulação do modelo, as amostras obtidas do sistema real são colocadas de forma aleatória em três grupos, para calcular: o erro de treinamento e_{train} , erro de validação e_{val} e erro de teste e_{test} . Portanto a divisão dos dados adotada é da seguinte forma: 60% para treinamento (x_{train}, y_{train}) , 20% para validação (x_{val}, y_{val}) e 20% para teste (x_{test}, y_{test}) .

Os erros são dados por:

$$e_{train} = \frac{1}{2n_{train}} \sum_{i=1}^{n_{train}} (h(x_{train})_i - y_{train_i})^2 \quad (3.4)$$

$$e_{val} = \frac{1}{2n_{val}} \sum_{i=1}^{n_{val}} (h(x_{val})_i - y_{val_i})^2 \quad (3.5)$$

$$e_{test} = \frac{1}{2n_{test}} \sum_{i=1}^{n_{test}} (h(x_{test})_i - y_{test_i})^2 \quad (3.6)$$

sendo $h(x)$ o modelo a ajustar, x como dados de entrada, y como valores esperados e n como número de amostras.

Fazendo um mapeamento dos modelos obtidos alterando-se os hiperparâmetros (C, σ, ε) , é calculado o erro de validação e de treinamento para cada combinação possível, para procurar os parâmetros que apresentem um menor valor intermediário onde o modelo apresente baixo bias e baixa variância.

3.2.2 Obtenção de Dados Experimentais

Para obter os dados de treinamento a partir do sistema real é empregado uma bancada de testes para bombas BCS (ver Subseção 3.2.2.1). Da bancada são adquiridas as seguintes variáveis:

- Rotação do eixo da BCS ω_{BCS}
- Pressão na sucção da bomba BCS P_{in}
- Pressão na descarga da bomba BCS P_{out}
- Temperatura na sucção da bomba BCS T_{in}
- Temperatura na descarga da bomba BCS T_{out}
- Vazão mássica de ar G_g
- Vazão mássica de líquido G_l
- Vazão volumétrica de ar Q_g
- Vazão volumétrica líquido Q_l
- Corrente no motor da BCS A_{BCS}
- Fração de vazio α
- Torque da BCS τ_{BCS} (no caso da bancada contar com sensor de torque)

Para adquirir os dados de cada curva é utilizada a matriz de testes mostrada na Tabela 3.1. Foram fixadas a rotação do eixo da BCS, a pressão na sucção da bomba BCS e a fração de vazio na mistura. Após a fixação destes parâmetros, uma varredura é feita na vazão do líquido obtendo os pontos da curva correspondente.

A matriz de testes apresentada na Tabela 3.1 foi proposta levando-se em consideração as limitações dadas pela bancada de testes (mais detalhes dos dados ver anexo A). Como pode-se notar à baixas rotações a fração de vazio máxima que foi possível medir

na bancada foi de 6%, pois o sistema apresentava oscilações fortes quando era selecionada uma fração de vazio maior. Estas oscilações podem causar danos no equipamento ou até destruir o mesmo, por isto não era recomendado operar o equipamento naquelas condições. Aumentando-se a rotação foi possível coletar dados com maiores frações de vazio, por exemplo, na rotação de 3000 rpm foi possível obter dados com 8% de fração de vazio, no entanto, em rotações maiores a bomba operava com vazões de fluido maiores, exigindo maiores quantidades de ar acima da capacidade da bancada, para manter a fração de vazio constante. O volume de ar estava limitado à capacidade do compressor que fornecia ar à bancada, o que impedia operações a rotação acima de 3300rpm para obter dados associados.

Tabela 3.1: Matriz de testes

| ω_{BCS} [RPM] | P_{in} [KPa] | α [%] |
|----------------------|-------------------|--------------|
| 2400 | [100,200,300,400] | [0,2,4,6] |
| 2700 | [100,200,300,400] | [0,2,4,6] |
| 3000 | [100,200,300,400] | [0,2,4,6,8] |
| 3300 | [200,400] | [0,2,4] |

3.2.2.1 Circuito de Testes de BCS

O circuito de testes de BCS é constituído basicamente pelo conjunto BCS, os tanques de água e ar, tubulações, uma bomba booster, válvulas de vazão e instrumentação conforme apresenta o diagrama esquemático da bancada na Figura 3.6. No Anexo A, é descrito cada um dos componentes da bancada do LabVIP.

Na bancada de testes da Figura 3.6, é mostrada uma bomba *booster* (M1), a qual bombeia a água do tanque (TK1) para a linha de baixa pressão (pressão máxima de 10 bar) de testes com o objetivo de vencer as perdas de carga associadas à tubulação e acessórios. A bomba *booster* tem a função de também controlar a pressão na entrada da BCS. Este controle de pressão é realizado mediante o controle da rotação do eixo da bomba. Antes de entrar na admissão da bomba BCS o fluido passa por um medidor de vazão (Q1). O ar é utilizado como fração gasosa, é comprimido e injetado na sucção da BCS, passando também por um medidor de vazão (Q2). O controle da vazão de gás é realizado por uma válvula (V4) após o medidor de vazão (Q2).

O fluido multifásico é bombeado de volta ao tanque (TK1) de água por uma linha de alta pressão (pressão máxima 20bar) onde é realizada a separação gravitacional das fases da mistura. A vazão de fluido é controlada por uma válvula (V2) ou válvula instalada na tubulação de recalque, dita válvula é conhecida como “*choke*”. O acionamento da BCS é realizado por um motor (M2) de indução trifásico controlado por um variador de frequência (VSD2). No circuito de testes também são medidas as pressões (P2 e P3) e temperaturas (T1 e T2) na entrada e saída

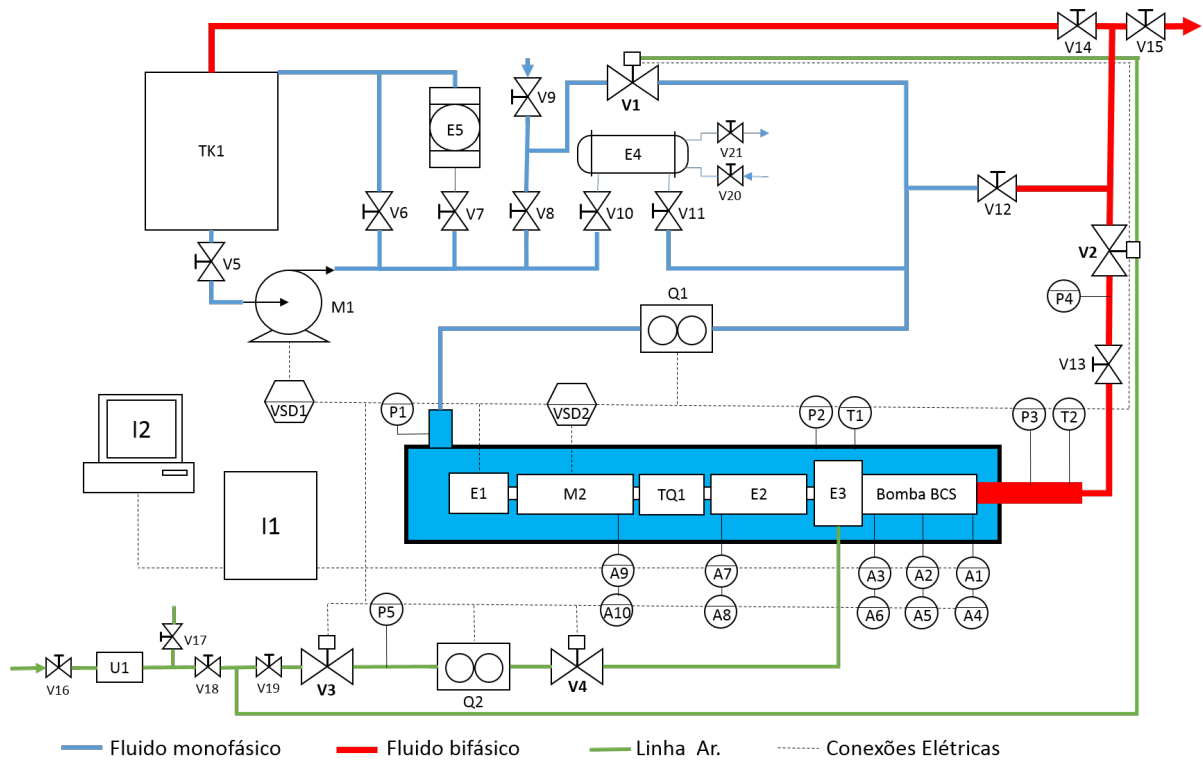


Figura 3.6: Diagrama esquemático da bancada do LabVIP.

da BCS, o torque (TQ1) no eixo de acionamento da bomba, e a corrente do motor elétrico, a qual é medida empregando as saídas analógicas do inversor de frequência do motor da BCS.

3.3 Aplicação do Algoritmo de Predição

O algoritmo de predição baseado nos dados adquiridos diretamente do sistema BCS prediz a vazão total $Q_{t_{ident}}$ empregando um filtro de partículas. A partir do valor $Q_{t_{ident}}$, é possível calcular a potência hidráulica P_h , e a eficiência da bomba η_{ident} . Além disto, o algoritmo de predição também fornece a potência mecânica W_m da bomba BCS. A Figura 3.7 apresenta o diagrama de blocos implementado do algoritmo de predição.




Figura 3.7: Diagrama de blocos do algoritmo de predição.

3.3.1 Aplicação do Filtro de Partículas

A finalidade do filtro de partículas neste projeto é estimar as variáveis que não podem ser adquiridas diretamente do sistema. Neste caso a variável estimada é a vazão total da mistura Q_t (líquido + gás). Supondo que esta variável depende da pressão na sucção da bomba BCS P_{in} , da rotação do eixo da BCS ω_{BCS} , da fração de vazio α e do seu estado anterior Q_{k-1} como é mostrado na Figura 3.8, pode-se dizer que a função de transição de estados é dada através da equação 3.7.




Figura 3.8: Diagrama de blocos para a função de transição de estados.

$$\begin{aligned} Q_{t_k}^i &= f_k(Q_{k-1}, P_{in_k}, \omega_{BCS_k}, \alpha_k, w_k) \\ Q_{t_k}^i &= A * Q_{k-1}^i + B * P_{in_k} + C * \omega_{BCS_k} + D * \alpha_k + w_k \end{aligned} \quad (3.7)$$

Sendo $Q_{t_k}^i$ a i -ésima partícula no instante k , A a matriz dinâmica do sistema, B , C e D um fator de escala para P_{in} , ω_{BCS} e α respectivamente e w_k é ruído branco com media zero que é independente dos estados atuais e passados correspondente ao ruído do sistema.

No sistema pode-se medir diretamente a pressão na descarga da bomba BCS P_{out} . Além disso, é possível calcular a potência mecânica W_m empregando-se a rotação do eixo ω_{BCS} e o torque da BCS τ_{BCS} , o que possibilita ter como funções de medições a:

$$\tilde{P}_{out_e k}^i = h(P_{in}, \alpha, \omega_{BCS}, Q_{t_k}^i) \quad (3.8)$$

$$\tilde{W}_{m k}^i = h(P_{in}, \alpha, \omega_{BCS}, Q_{t_k}^i) \quad (3.9)$$

Sendo $\tilde{P}_{out_e k}^i$ e $\tilde{W}_{m k}^i$ os valores estimados pelo modelo $h(\cdot)$ obtidos pela SVMr para cada uma das partículas $Q_{t_k}^i$ no instante k .

A partir das medições estimadas pelas equações (3.8) e (3.9) para cada partícula $Q_{t_k}^i$ e os valores medidos diretamente do sistema real no instante k para P_{out} e W_m , a probabilidade de distribuição para cada medição é calculada da forma (ISARD; BLAKE, 1998):

$$p(P_{out_k}, W_{m_k} | Q_{t_k}^i) = \frac{1}{\sqrt{2\pi\nu_k}} \exp \left[- \left(\frac{(P_{out_k} - \tilde{P}_{out_e k}^i)^2}{2\nu_k^2} + \frac{(W_{m_k} - \tilde{W}_{m k}^i)^2}{2\nu_k^2} \right) \right] \quad (3.10)$$

Sendo v_k um ruído branco com media zero, o qual é independente dos estados atuais e passados correspondentes ao ruído das medições.

Os pesos w_k^i de cada partícula é atualizado na forma:

$$w_k^i \propto w_{k-1}^i p(P_{out_k}, W_{m_k} | Q_{t_k}^i) \quad (3.11)$$

Empregando-se os pesos w_k^i associado a cada partícula são geradas novas partículas realizando uma re-amostragem aleatória das partículas. Cabe salientar que as partículas com os maiores pesos associados têm maior probabilidade de serem re-amostradas.

A predição ou estimação da vazão total da mistura Q_{t_k} no instante k podem ser atualizadas empregando-se as partículas $Q_{t_k}^i$ e seu peso associado w_k^i na forma:

$$\tilde{Q}_{t_k} = \sum_{i=1}^N Q_{t_k}^i w_k^i \quad (3.12)$$

3.4 Aplicação dos Sistemas Complexos Adaptativos

O sistema complexo adaptativo é o núcleo do controle especialista, já que é quem decide a ação de controle que vai atuar no sistema BCS. Na Figura 3.9 é apresentado o diagrama de blocos implementado do sistema complexo adaptativo.

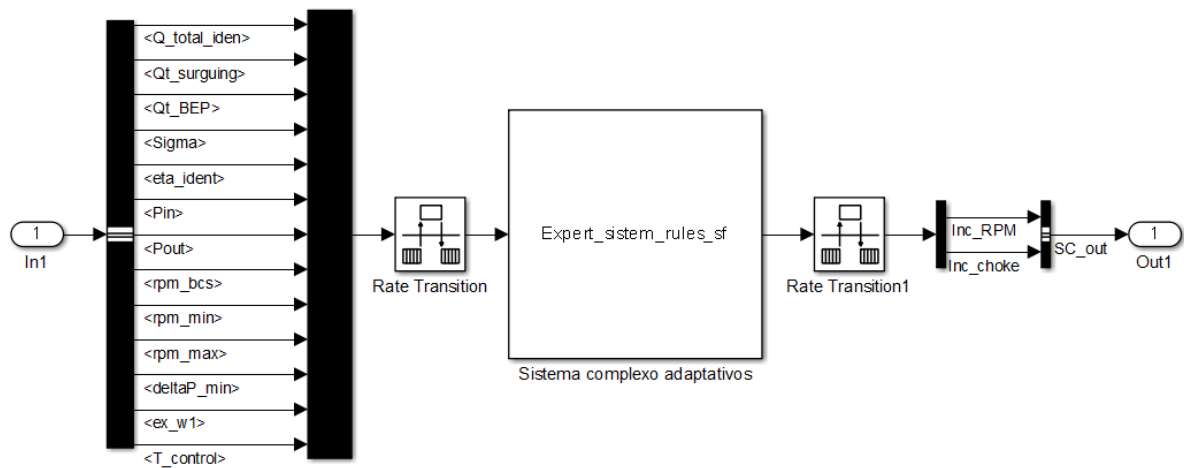


Figura 3.9: Diagrama de blocos do sistema complexo adaptativo.

Como pode-se notar na Figura 3.9 temos como entradas no sistema complexo adaptativo:

- $Q_{t_{ident}}$ vazão total de liquido identificada, variável calculada pelo algoritmo de predição.
- $Q_{t_{surguing}}$ vazão do ponto de *surguing*, variável calculada pelo sistema supervisorio.

- Q_{tBEP} vazão do ponto de BEP, variável calculada pelo sistema supervisorio.
- α sinal da fração de vazio, variável adquirida diretamente do sistema¹.
- η_{ident} eficiência identificada da bomba, valor calculado pelo algoritmo de predição.
- P_{in} pressão na sucção da bomba BCS, variável adquirida diretamente do sistema.
- P_{out} pressão na descarga da bomba BCS, variável adquirida diretamente do sistema.
- ω_{BCS} sinal de rotação do eixo da BCS, valor imposto pelo controlador à bomba.
- ω_{min} rotação mínima admitida na bomba, definida no sistema supervisorio pelo usuário.
- ω_{max} rotação máxima admitida na bomba, definida no sistema supervisorio pelo usuário.
- ΔP_{min} diferencial de pressão mínimo admitido na bomba, definido no sistema supervisorio pelo usuário.
- ex_{w1} sinal de comutação do sistema complexo adaptativo, definido no sistema supervisorio pelo usuário.
- $T_{control}$ sinal de comutação do controle especialista, definido no sistema supervisorio pelo usuário.

Como saídas do sistema complexo adaptativo temos:

- inc_{rpm} sinal que indica ao controlador para aumentar, diminuir ou manter a rotação na bomba BCS.
- inc_{choke} sinal que indica ao controlador para abrir, fechar ou manter a válvula de *choke*.

O sistema complexo adaptativo implementado para gerar a base de regras é um processo iterativo no qual um conjunto de classificadores compete entre eles para ter o privilégio de interagir com o ambiente (sistema BCS) pagando com a sua energia pelo direito de atuar. Dependendo do resultado, o sistema recompensa ou pune o classificador vencedor aumentando ou diminuindo a sua energia. Após uma época interativa, ou seja, um número de iterações, um algoritmo genético (AG) cria novas regras (filhos) empregando os melhores classificadores, ou seja, os que tem maior energia, como pais destes. Os filhos gerados são inseridos na base de regras tomando o lugar dos piores classificadores. Os passos do processo iterativo são:

Passo 1: criar base de regras aleatórias;

¹ A fração de vazio para este projeto de controle é considerada conhecida, já que existem projetos na área que estão trabalhando em estimar esta variável adquirindo dados diretamente da bomba BCS em operação como (RICARDO *et al.*, 2018).

- Passo 2: receber a mensagem do ambiente;
- Passo 3: codificar a mensagem na linguagem do classificador;
- Passo 4: seleccionar os classificadores que se identificam com a mensagem, ou seja, os classificadores que tem a maior especificidade M (ver subsecção 2.5.1);
- Passo 5: realizar competição:
- calcular o lance de cada competidor (ver subsecção 2.5.2)
 - Obter o vencedor e apontar seu lance Bid_t
 - calcular taxas dos participantes e do vencedor Tax_{bid}
- Passo 6: atuar sobre o ambiente;
- Passo 7: receber retroalimentação do ambiente;
- Passo 8: calcular recompensa ou punição do classificador vencedor R_t ;
- Passo 9: atualizar energia dos classificadores S_{t+1} , e cobrar taxa de vida tax_v :
- $[S_{t+1} = (1 - tax_v)s_t + R_t - Bid_t - Tax_{bid}]$ para o vencedor
 - $[S_{t+1} = (1 - tax_v)s_t - Tax_{bid}]$ para os classificadores participantes da competição e
 - $[S_{t+1} = (1 - tax_v)s_t]$ para os classificadores restantes
- Passo 10: se não for o fim de uma época iterativa retornar ao passo 2;
- Passo 11: executar processo evolutivo;
- seleccionar indivíduos mais aptos (maior S_t) para aplicação do AG
 - aplicar os operadores genéticos para gerar filhos
 - inserir filhos gerados na população substituindo os indivíduos mais fracos (menor S_t)
- Passo 12: Retornar ao passo 2.

Na subsecção 3.4.1 é apresentado como o sistema complexo adaptativo representa as mensagens recebidas do ambiente, na subsecção 3.4.2 é apresentado como foi construída a função de recompensa e punição, e a subsecção 3.4.3 apresenta como foi aplicado o algoritmo genético para descoberta de novas regras.

3.4.1 Representação dos Classificadores

Os classificadores, que fazem parte da base de regras do sistema especialista, são representados empregando-se os elementos pertencentes a $\{N, Z, P, \#\}$ o que significa que o sinal tem um valor {Negativo, Zero ou nulo, Positivo, não importa}. Cada regra tem uma parte ligada às condições (se), e uma parte ligada às ações (então). Por exemplo: Se Q_{ident} é positivo & α é positivo & P_{out} não importa, então incremento positivo a inc_{rpm} & incremento zero a inc_{choke} . Este exemplo de regra é representado como $(PP\# : PZ)$.

Um classificador completo para este trabalho está conformado por vinte e dois (22) componentes pertencentes às condições e dois (2) componentes associados as ações. A Tabela 3.2 representa um classificador ou regra completa, onde S é a energia ou “strength” do classificador, a diferença $\Delta * _t = * _t - * _{t-1}$ é empregada para que o sistema tenha uma noção se a variável está mudando. Os erros apresentados na Tabela 3.2 são dados por:

$$e_{Q_{surging}} = Q_{id} - Q_{surging} \quad (3.13)$$

$$e_{Q_{BEP}} = Q_{id} - Q_{BEP} \quad (3.14)$$

$$e_{\omega_{min}} = \omega_{BCS} - \omega_{min} \quad (3.15)$$

$$e_{\omega_{max}} = \omega_{BCS} - \omega_{max} \quad (3.16)$$

$$e_{\Delta P_{min}} = (P_{out} - P_{in}) - \Delta P_{min} \quad (3.17)$$

Tabela 3.2: Componentes do classificador

| ID | Classificador (se) : | (Então) | S |
|-------|---|-------------------------|-----|
| a_1 | $e_{Q_{surging}}, \Delta e_{Q_{surging}}, e_{Q_{BEP}}, \Delta e_{Q_{BEP}}, \alpha, \Delta \alpha, Q_{id}, \Delta Q_{id},$ $\eta, \Delta \eta, P_{in}, \Delta P_{in}, P_{out}, \Delta P_{out}, \omega_{BCS}, \Delta \omega_{BCS}, e_{\omega_{min}},$ $\Delta e_{\omega_{min}}, e_{\omega_{max}}, \Delta e_{\omega_{max}}, e_{\Delta P_{min}}, \Delta e_{\Delta P_{min}}$ | $inc_{rpm} inc_{choke}$ | 100 |

3.4.2 Aplicação da Função de Recompensa e Punição

Para criar a função de recompensa e punição são empregados os sinais que tem informação do *surging* ($e_{Q_{surging}}, \Delta e_{Q_{surging}}$) do ponto de BEP ($e_{Q_{BEP}}, \Delta e_{Q_{BEP}}$) e dos limites impostos ao sistema ($e_{\omega_{min}}, \Delta e_{\omega_{min}}, e_{\omega_{max}}, \Delta e_{\omega_{max}}, e_{\Delta P_{min}}, \Delta e_{\Delta P_{min}}$). Com estes sinais e levando-se




Figura 3.10: Gráfico de áreas de recompensa .

em conta as zonas apresentadas na Figura 3.10 podem ser criadas regras para decidir se a ação realizada pelo classificador foi ruim ou boa.

As regras empregadas para obter a função R estão definidas na Tabela 3.3. O objetivo das regras apresentadas na tabela é: se o ponto de operação está numa zona ruim e o classificador mantém a condição ou piora a condição, o classificador é punido; se o classificador movimenta o ponto de operação tentando sair da condição ruim, é recompensado. Também, se o classificador procura o ponto de BEP ou se mantém nele, é recompensado.

Como é prioridade sair de zonas ruins, as regras que não estão apresentadas na Tabela 3.3 não importam para calcular os valores da função R , ou seja, se o sinal $e_{Q_{surging}}$ é positivo P , isso significa que a bomba se encontra fora da zona de *surging*, então não importa se o ponto de operação muda enquanto permanecer fora do *surging*, pelo qual o valor de $R_{Q_{surging}} = 0$. O mesmo acontece com os outros sinais, enquanto estiver fora da zona ruim não importa.

O valor da função de recompensa e punição R é dado por:

$$R = (R_{Q_{surging}} + R_{Q_{BEP}} + R_{\omega_{min}} + R_{\omega_{max}} + R_{\Delta P_{min}}) * Taxa_r \quad (3.18)$$

Sendo R_{Sinal} o valor da recompensa e punição para cada sinal, os quais são calculados com a Tabela 3.3. A $Taxa_r$ é um fator de recompensa que garante que no caso de recompensar o classificador, o valor da recompensa seja maior que o lance *Bid* dado para garantir que o classificador recupere seu lance com um ganho.

Tabela 3.3: Regras para obter os valores da função do R

| $Sinal$ | e_{Sinal} | Δe_{Sinal} | R_{Sinal} |
|------------------|-------------|--------------------|-------------|
| $Q_{surging}$ | N | N | -1.5 |
| | N | Z | -1 |
| | N | P | 1 |
| Q_{BEP} | N | P | 1 |
| | N | N | -0.2 |
| | Z | Z | 1.5 |
| | P | N | 1 |
| | P | P | -0.2 |
| ω_{min} | N | N | -1 |
| | N | Z | -1 |
| | N | P | 1 |
| ω_{max} | P | N | 1 |
| | P | Z | -1 |
| | P | P | -1 |
| ΔP_{min} | N | N | -1 |
| | N | Z | -1 |
| | N | P | 1 |

3.4.3 Algoritmo Genético para Descoberta de Novas Regras

Após o grupo de classificadores terem interagido com o ambiente um certo número de iterações, e a sua energia S ter sido mudada dependendo do seu desempenho, o algoritmo genético calcula a função de ϕ empregando as energias associadas dos classificadores na forma:

$$\phi = \frac{S - (\min S)}{\max S - \min S} \quad (3.19)$$

Dependendo do valor do fitness são selecionados n_{pais} empregando-se o método da roleta apresentado na subseção 2.6.3. Dois pais, empregando-se crossover de um ponto, são cruzados dependendo da probabilidade do *crossover* P_C com a finalidade de gerar dois filhos. Os filhos resultantes podem sofrer uma mutação dependendo da probabilidade de mutação P_M . A mutação é feita numa única célula, ou seja, mutação simples, a qual seleciona uma única posição e trocam o seu valor por qualquer outro, ambos de forma aleatória.

O conjunto de filhos com os filhos que sofreram mutação obtidos, são inseridos no grupo de classificadores trocando-os pelos classificadores pior adaptados, ou seja, os que contém a menor energia associada.

3.5 O Sistema Supervisório

O sistema supervisório contém a interface de usuário que o permite supervisionar tanto o sistema de controle quanto o processo. O sistema supervisório é onde se definem os limites de funcionamento tais como: rotação mínima rpm_{min} da BCS, rotação máxima rpm_{max} da BCS para garantir que a bomba trabalhe dentro dos parâmetros de rotação fornecidos pelo fabricante, e a diferença de pressão mínima ΔP_{min} a qual garante que a energia fornecida pela bomba seja suficiente para levar o fluido até o reservatório de estoque. O sistema supervisório calcula o ponto de BEP e o ponto de *surging* para a curva na qual se encontra o sistema BCS de acordo com a pressão de entrada na BCS P_{in} , a fração de vazio na mistura α e a rotação da BCS ω_{BCS} . A partir dos pontos de BEP e *surging* são calculadas a vazão do BEP Q_{tBEP} e a vazão do *surging* $Q_{t_{surging}}$.

A Figura 3.11 mostra o diagrama de blocos implementado no sistema supervisório, o qual possui como entradas as variáveis do sistema BCS e do algoritmo de predição. Como saídas tem-se os comandos de controle: $T_{control}$ para comutar de modo manual ou controlado pelo controlador especialista e ex_{w1} que vem a ser quem ativa ou desativa o sistema complexo adaptativo e também permite reiniciar as regras do mesmo, os limites de operação e as vazões onde se encontram o BEP Q_{tBEP} e o *surging* $Q_{t_{surging}}$.

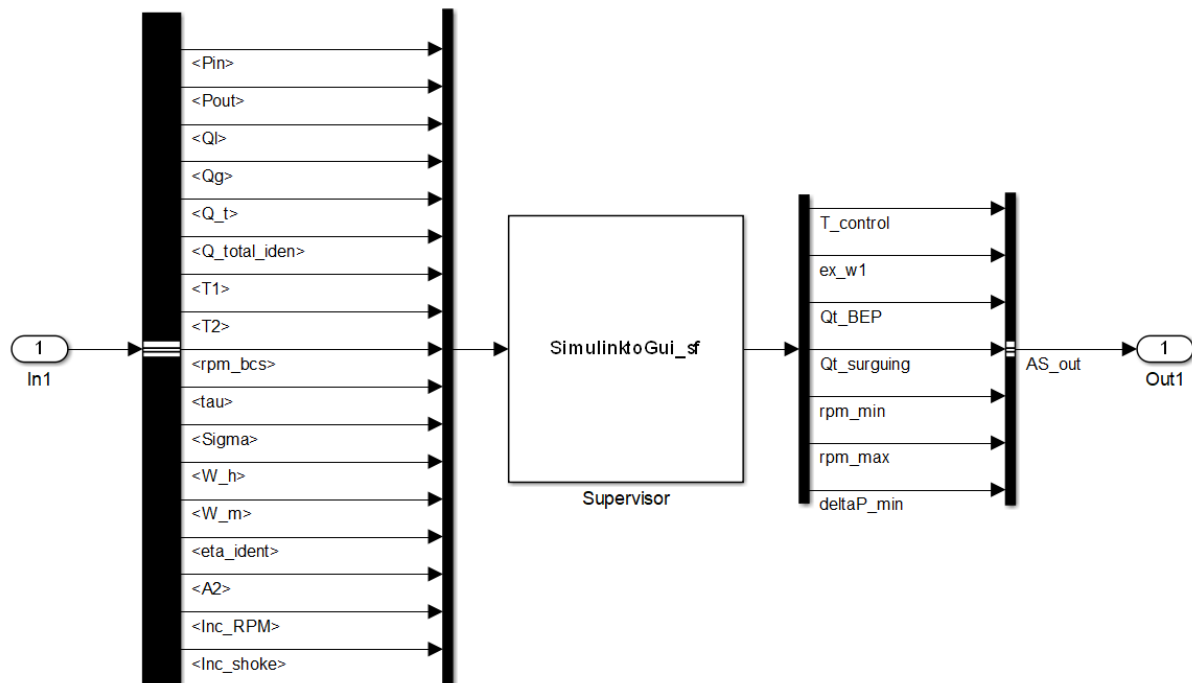


Figura 3.11: Diagrama de blocos do sistema supervisório.

Na Figura 3.12 é apresentada a interfase de usuário implementada, a qual fornece ao usuário as seguintes informações:

- (1) Curvas de desempenho da bomba ΔP , potência mecânica e eficiência da bomba. Em cada curva é apresentado o ponto de operação real da bomba (O), o ponto de operação estimado da bomba(O), o ponto de *surging* (X) e o ponto de BEP (X).
- (2) Variáveis da bomba BCS tanto as adquiridas diretamente do sistema, quanto as estimadas pelo sistema de controle.
- (3) Sinais no tempo da P_{in} , P_{out} e ΔP .
- (4) Sinais no tempo da fração de vazio σ , a vazão identificada, a vazão desejada ou seja a vazão do ponto de *surging*, a vazão real (sinal coletado diretamente do sistema), o erro entre o sinal da vazão real e a identificada para se verificar o funcionamento do identificador, e o erro entre a vazão identificada e a vazão desejada para visualizar o desempenho do controle especialista, cujo objetivo do sistema de controle é minimizar este erro.
- (5) Eficiências da bomba, tanto a real, quanto a máxima da curva da condição atual da bomba. Também são fornecidos os erros da eficiência para verificar o desempenho do controlador especialista.

As curvas de desempenho apresentadas na Figura 3.12 são obtidas empregando os modelos expostos na subseção 3.2.1. A partir da curva de pressão diferencial pode-se obter o ponto de *surging* $\Delta P_{surging}$ na forma:

$$\Delta P_{surging} = \max[P_{out_e}(P_{in}, \alpha, \omega_{BCS}, Q) - P_{in}] \quad (3.20)$$

Sendo que a variável $\Delta P_{surging}$ está associada a um máximo na curva de desempenho. A partir da pressão diferencial máxima é obtida a vazão na qual ocorre o *surging* $Q_{t\ surging}$, variável de entrada no sistema complexo adaptativo.

Para obter o ponto onde ocorre o BEP é calculada a eficiência máxima η_{max} empregando-se a curva de desempenho da forma:

$$\eta_{max} = \max[\eta_e(P_{in}, \alpha, \omega_{BCS}, Q)] \quad (3.21)$$

Uma vez calculado η_{max} é obtida a vazão na qual ocorre o BEP $Q_{t\ BEP}$, que também é uma variável de entrada no sistema complexo adaptativo.

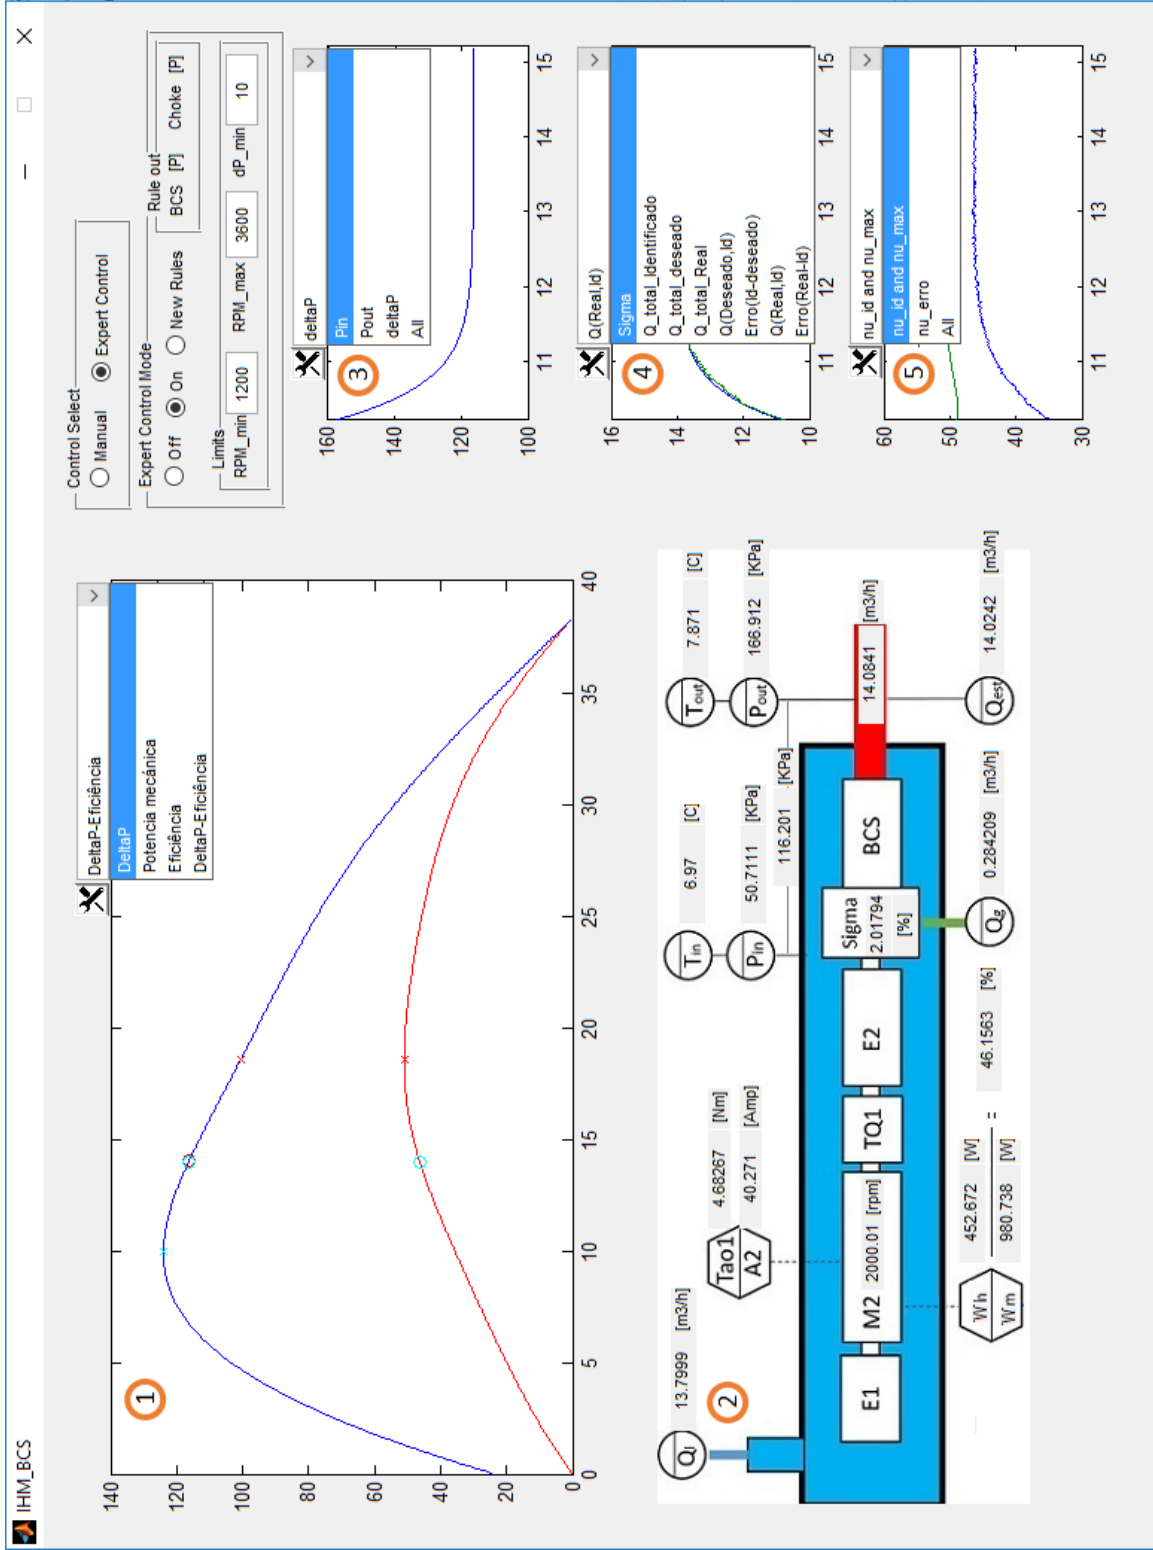


Figura 3.12: Interface usuário máquina do sistema especialista.

4 ANÁLISE E INTERPRETAÇÃO DOS RESULTADOS

Para analisar os resultados dos métodos propostos, este capítulo está dividido em duas seções, na primeira seção são apresentados os resultados obtidos empregando-se um modelo de simulação para a bancada de testes, na segunda seção são apresentados os resultados empregando-se a bancada real descrita no anexo A. Cada seção é dividida em três subseções, isto com a finalidade de estudar independentemente o desempenho de:

- Modelos das curvas de desempenho empregando SVM.
- Filtro de partículas para estimação da vazão de fluido.
- Controle especialista com sistema complexo adaptativo.

4.1 Análise de Resultados de Simulação

Para validar inicialmente os métodos propostos foram empregados dados extraídos da dissertação de um mestrado de Monte (MONTE, 2011), no qual Monte adquiriu dados de uma bomba GN 7000 da Schlumberger. Essa base de dados contém condições de operação para: rotações de $[1200, 1800, 2400]rpm$, pressões de $[50, 100, 200]kPa$ e frações de vazio de $[0, 2, 4, 6, 8, 10]\%$. O conjunto de dados contém 712 amostras, as quais foram divididas em três (3) conjuntos: Um de 500 amostras para treinamento (70% das amostras), e outros dois conjuntos de 106 amostra (15% das amostras) para validação e teste. Para estudar o desempenho do sistema de controle proposto foi empregado o modelo de simulação de uma bancada de testes proposta por Jimenez (JIMENEZ *et al.*, 2014).

4.1.1 Análise dos Modelos das Curvas de Desempenho

Os desempenhos dos modelos das curvas de desempenho da BCS que foram obtidos empregando máquinas de vetores de suporte são apresentados na Tabela 4.1. Os hiperparâmetros C da regularização, o σ^2 do *kernel* gaussiano e o ε da margem da SVM foram otimizados mediante algoritmos genéticos clássicos (ou seja, *crossover* de um único ponto, e mutação simples), o qual emprega o erro de validação para otimizar os parâmetros da SVM (ver Anexo B).

Dos erros apresentados na Tabela 4.1 pode-se dizer que os modelos têm a capacidade de interpolar os valores tanto para P_{out} quanto para o W_m com erros reduzidos, já que o erro de teste é de $\pm 2.78kPa$ o que representa 1.39 % na interpolação para o P_{out} e o erro de teste de $34.24W$ representando ± 1.71 % na interpolação para o W_m . Após calcular a eficiência da bomba η com os valores interpolados pelos modelos SVMr foi alcançado um erro

Tabela 4.1: Parâmetros da SVMr e desempenho da estimação das curvas de desempenho da BCS.

| Modelo | C | σ^2 | ϵ | e_{train} | e_{val} | e_{test} |
|-------------------|----------|------------|------------|--------------|--------------|--------------|
| \tilde{P}_{out} | 907,3015 | 0.17392 | 0.034105 | 3.4180 [kPa] | 2.7888 [kPa] | 2.7809 [kPa] |
| \tilde{W}_m | 112.9336 | 0.6134 | 0.1694 | 36.1666 [W] | 32.1769 [W] | 34.2496 [W] |
| $\tilde{\eta}$ | - | - | - | 2.579 [%] | 2.4609 [%] | 2.9040 [%] |

de teste de 2.90% na predição. É empregado o erro de teste como parâmetro para determinar o desempenho da interpolação dos modelos, porque o conjunto de dados de teste não é empregado para construí-los.

As Figuras 4.1, 4.2 e 4.3 apresentam a comparação de dados reais com dados obtidos a partir dos modelos baseados em SVM. Estas curvas dão uma ideia do bom comportamento dos modelos para diferentes frações de vazio. As curvas apresentadas são para uma condição de operação de 50 kPa na entrada da bomba rodando a 2400 RPM.




Figura 4.1: Curva de desempenho do ΔP empregando modelos SVMr

A metodologia proposta para obter os modelos para estimar as curvas de desempenho de uma bomba BCS empregando máquinas de vetores de suporte a partir de dados reais apresentou um bom desempenho, já que permitiu estimar valores que estão contidos dentro dos limites de treinamento. Cabe lembrar que os algoritmos de aprendizado supervisionado não são considerados bons extrapoladores, ou seja, bons para estimar parâmetros fora dos seus limites de treinamento. Devido a este fato, é recomendável manter o sistema (BCS) dentro dos limites de interpolação dos modelos BCS para obter um bom desempenho do mesmo.




Figura 4.2: Curva de desempenho de W_m empregando modelos SVMr




Figura 4.3: Curva de desempenho do η empregando modelos SVMr

4.1.2 Análise do Filtro de Partículas para Estimação da Vazão de Fluido

Os parâmetros empregados para o filtro de partículas são apresentados na Tabela 4.2, sendo n o número de partículas, w a covariância do ruído do sistema, v covariância do ruído do sensor, A a matriz dinâmica do sistema (considerado como sistema de primeira ordem), B , C e D fatores de escala para P_{in} , ω_{BCS} e do α respectivamente. As Figuras 4.4 e 4.5 apresentam o filtro de partículas estimando a vazão total de fluido.

Tabela 4.2: Parâmetros do filtro de partículas

| Parâmetro | Valor |
|-----------|--------------|
| n | 100 |
| w | 0.1 |
| v | 1 |
| A | 0.9802 |
| B | 0.1464 |
| C | $4.09e - 05$ |
| D | 0.01037 |

A Figura 4.4 mostra o comportamento do filtro de partículas quando é variada a rotação, a fração de vazio e a pressão de admissão. Como se pode notar, o filtro consegue prever corretamente o valor da vazão total de fluido empregando 100 partículas. O erro de estimação aumenta quando a pressão na admissão da bomba aumenta, apesar disso a vazão continua sendo estimada corretamente, já que o erro de predição se mantém entre $\pm 0.015 [m^3/s]$.

Na Figura 4.5 é mostrado o desempenho do filtro quando é ajustada a válvula de choke. Abrir e fechar esta válvula causa grandes variações na vazão de fluido. O filtro de partículas neste caso apresenta um bom desempenho estimando corretamente a vazão mesmo quando as variações da mesma sejam grandes.

É esperado que a dispersão do erro de predição do filtro de partículas seja afetado quando a vazão de fluido varia rapidamente, ou seja, quando a válvula choke é ajustada, o filtro de partículas é bastante afetado com as variações na pressão da entrada da bomba BCS. Esse comportamento em relação à pressão pode ser causado pela falta de dados de treinamento para os modelos SVMr com maiores valores na pressão, o que limita os modelos empregados. Cabe salientar que o erro de predição pode ser diminuído empregando um maior número de partículas para a predição, porém este aumento de partículas precisaria de uma capacidade computacional maior.

4.1.3 Análise da interação do Controle Especialista com o Sistema Complexo Adaptativo

Com a finalidade de analisar o desempenho do controlador especialista interagindo com um sistema BCS, foram realizadas simulações para testar a resposta do controlador.




Figura 4.4: Desempenho filtro de partículas.

O controle especialista deve manter o sistema em condições seguras nas simulações, ou seja, mantendo-o operando próximo ao ponto de BEP considerando que o sistema complexo adaptativo (a base de conhecimento baseado em regras) começa o treinamento com regras aleatórias nos seguintes pontos críticos de operação especificamente:

- 1 *Surging*;
- 2 Rotação acima da rotação máxima permitida;
- 3 Rotação abaixo da rotação mínima permitida;
- 4 Diferencial de pressão abaixo do mínimo permitido;
- 5 *Surging*, condições dinâmicas no poço.




Figura 4.5: Desempenho filtro de partículas associado à abertura da válvula choke.

Os limites de operação para o sistema BCS definidos para os experimentos estão apresentados na Tabela 4.3.

Tabela 4.3: Limites de operação da BCS

| Parâmetro | Valor |
|------------------|----------|
| ω_{max} | 2400 RPM |
| ω_{min} | 1200 RPM |
| ΔP_{min} | 20 kPa |

As condições iniciais empregadas para o algoritmo genético, o qual gera as novas regras, são apresentadas na Tabela 4.4. O algoritmo realiza 20 iterações para gerar um novo conjunto de regras, ou seja, uma geração é equivalente a 20 iterações do sistema complexo adaptativo interagindo com o ambiente. Foi fixado que uma iteração leva-se 1s para ser completada, ou seja, a regra que venceu na competição tem o direito de interagir por um segundo com o ambiente.

Os incrementos fixados para variar tanto a abertura da válvula choke quanto a rotação da BCS estão apresentados na Tabela 4.5.

Tabela 4.4: Condições iniciais do AG

| Parâmetro | Valor |
|-----------------------------------|-------|
| Tamanho da população a_i | 2000 |
| Probabilidade de Mutação p_M | 0.1 |
| Probabilidade de cruzamento p_c | 1 |
| Número de filhos n_f | 100 |

Tabela 4.5: Incrementos dos atuadores

| Parâmetro | Valor |
|--------------------------------|-------------|
| Incremento BCS inc_{BCS} | $5[rpm/s]$ |
| Incremento choke inc_{choke} | $0.2[\%/s]$ |

4.1.3.1 Simulação 1



A primeira simulação envolveu um teste de desempenho do controlador especialista quando o sistema BCS estava operando numa condição dentro da zona de *surging*. O treinamento do sistema complexo adaptativo foi inicializado neste ponto de operação. Na Tabela 4.6 são apresentadas as condições iniciais para a simulação. A simulação consta de dois testes, cada um deles para frações de vazão diferentes, neste caso de 2% e 4%.

Tabela 4.6: Condições iniciais para a simulação 1

| Teste | α | P_{in} | <i>choke</i> | ω_{BCS} | Q_t |
|-------|----------|----------|--------------|----------------|--------------|
| 1 | 2% | 50 kPa | 15% | 1800RPM | $4.61 m^3/h$ |
| 2 | 4% | 50 kPa | 15% | 1800RPM | $3.97 m^3/h$ |

Na Figura 4.6 são apresentadas as trajetórias tomada pelo sistema de controle para sair da operação em *surging*. A Figura 4.6 (a) para a fração de vazão de 2% e a Figura 4.6 (b) para a fração de vazão de 4%.

A Figura 4.7 mostra o erro entre a vazão real na BCS relacionado à vazão do ponto de BEP. Também são mostrados os ajustes realizados pelo controle especialista na rotação da bomba e na abertura da válvula choke para atingir o BEP. A Figura 4.7 (a) mostra os resultados obtidas para o teste 1 (fração de vazão de 2%), e a Figura 4.7 (b) mostra os resultados do teste 2 (fração de 4%). Como se pode notar nos dois testes, o sistema de controle proposto foi capaz de retirar a bomba da operação da zona de *surging* e leva-la a operar próximo ao ponto de BEP. Também pode-se notar com a fração de vazão maior, o sistema de controle apresentou maior dificuldade para manter a bomba BCS no BEP. Esse comportamento já era esperado, já que

(a) Trajetória tomada pelo sistema de controle para $\alpha = 2\%$ (b) Trajetória tomada pelo sistema de controle para $\alpha = 4\%$ Figura 4.6: Trajetórias tomadas pelo sistema de controle para sair da operação em *surgin*



(a) Erro do sistema de controle para $\alpha = 2\%$ (b) Erro do sistema de controle para $\alpha = 4\%$

Figura 4.7: Evolução do erro do sistema de controle na Simulações 1 com 2% e 4% de fração de vazio.

com a maior quantidade de gás livre na mistura de fluido bifásico, o sistema tende a ser mais sensível a mudanças tanto para a rotação da BCS, quanto para mudanças na abertura da válvula choke.

4.1.3.2 Simulação 2

A segunda simulação permitiu visualizar o desempenho do controlador especialista em um treinamento com o sistema BCS operando numa condição fora da rotação máxima permitida. Na Tabela 4.7 são apresentadas as condições iniciais para a simulação. Essa simulação constou de dois testes, cada um deles para as frações de vazio, de 2% e de 4%.

Tabela 4.7: Condições iniciais para a simulação 2

| Teste | α | P_{in} | choke | ω_{BCS} | Q_t |
|-------|----------|----------|-------|----------------|-------------------------|
| 1 | 2% | 50kPa | 50% | 2600RPM | 20.51 m ³ /h |
| 2 | 4% | 50kPa | 50% | 2600RPM | 20.59 m ³ /h |

Na Figura 4.8 são mostradas as trajetórias tomadas pelo sistema de controle para operar numa rotação permitida. As Figuras 4.8 (a) e (b) mostram as trajetórias tomadas para as frações de vazio de 2% e 4%. Como pode-se notar nas figuras, o ponto inicial de operação está fora da zona de *surging* para forçar o sistema de controle a não utilizar inicialmente as regras de sair da zona de *surging*, resultando em uma melhor a simulação e se manter em rotações permitidas.

A Figura 4.9 mostra como o sistema de controle altera a rotação da bomba BCS a cada iteração. Também é mostrada a variação feita pelo controle especialista à abertura da válvula choke, e finalmente é apresentado o erro relacionado a vazão do ponto de BEP. Na Figura 4.9 (a) são mostrados os resultados obtidos do primeiro teste com uma fração de vazio de 2%, e na Figura 4.9 (b) os resultados para o segundo teste, onde a bomba opera com uma fração de 4%. Como pode-se notar nos dois casos o sistema de controle proposto levou a bomba a operar dentro dos limites de rotação e a atingir o seu ponto de BEP. Também foi observado o mesmo efeito da simulação 1, com o aumento da fração de vazio, o sistema de controle apresenta uma maior dificuldade para manter a bomba BCS no ponto do BEP, já que naquela condição de operação, apresenta maiores oscilações perto deste ponto para a condição de 4% de fração de vazio.



(a) Trajetória tomada pelo sistema de controle para $\alpha = 2\%$ (b) Trajetória tomada pelo sistema de controle para $\alpha = 4\%$

Figura 4.8: Trajetórias tomadas pelo sistema de controle para sair de altas rotações.



(a) Evolução do sistema controlado para $\alpha = 2\%$ (b) Evolução do sistema controlado para $\alpha = 4\%$

Figura 4.9: Evolução do sistema de controle na simulação 2.

4.1.3.3 Simulação 3

A terceira simulação permitiu visualizar o desempenho do controlador especialista em um treinamento com o sistema BCS operando numa condição fora da rotação mínima permitida. Na Tabela 4.8 são apresentadas as condições iniciais para a simulação. essa simulação constou de dois testes, cada um deles para frações de vazio diferentes, neste caso de 2% e 4%.

Tabela 4.8: Condições iniciais para a simulação 3

| Teste | α | P_{in} | <i>choke</i> | ω_{BCS} | Q_t |
|-------|----------|----------|--------------|----------------|------------------------|
| 1 | 2% | 50kPa | 50% | 1100RPM | 11.73m ³ /h |
| 2 | 4% | 50kPa | 50% | 1100RPM | 11.70m ³ /h |

Na Figura 4.10 são amostrados as trajetórias tomadas pelo sistema de controle para entrar numa rotação permitida para as duas condições de operação, A Figura 4.10 (a) mostra o teste 1 com uma fração de vazio de 2% e a Figura 4.10 (b) mostra o teste 2 com uma fração de vazio de 4%. Como pode-se notar nas figuras, o ponto inicial foi colocado fora da zona de *surgings* para forçar o sistema de controle represente melhor a simulação de se manter em rotações permitidas. E para evitar que o limite de ΔP_{min} interferisse nas simulações, este foi fixado em 10kPa.

A Figura 4.11 mostra como evoluiu a rotação da bomba BCS a cada iteração, também são mostradas as variações realizadas pelo controle especialista durante a abertura da válvula choke e o erro associado ao ponto de BEP, já que este último representa um dos parâmetros de desempenho do sistema de controle. A Figura 4.11 (a) mostra os resultados do teste com fração de vazio de 2%, e a Figura 4.11 (b) mostra os resultados do teste com fração de vazio de 4%. Como pode-se notar nos dois casos o sistema de controle proposto consegue colocar a bomba operando dentro dos limites de rotação e colocar a bomba operando próximo ao ponto de BEP. Nesta simulação, o sistema, ao tentar colocar a bomba operando no ponto de BEP, tende a ultrapassar o limite de rotação, retornado às condições de operação permitidas. O que demonstra que o sistema de controle foi capaz de manter o sistema BCS operando em condições seguras, e se for possível manter o sistema no ponto de BEP.

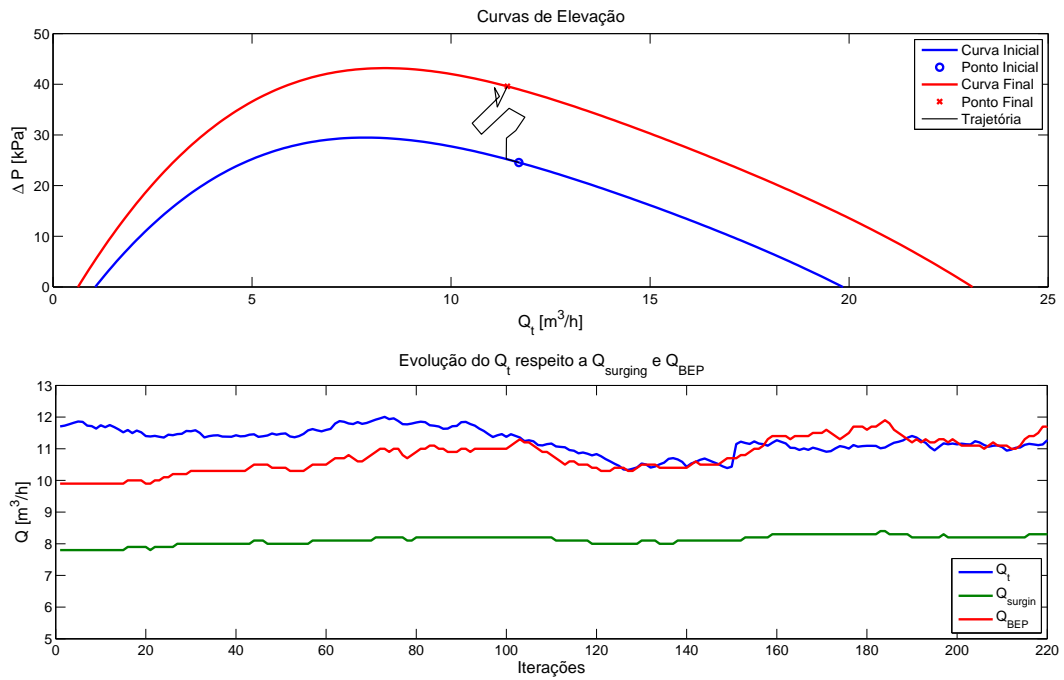
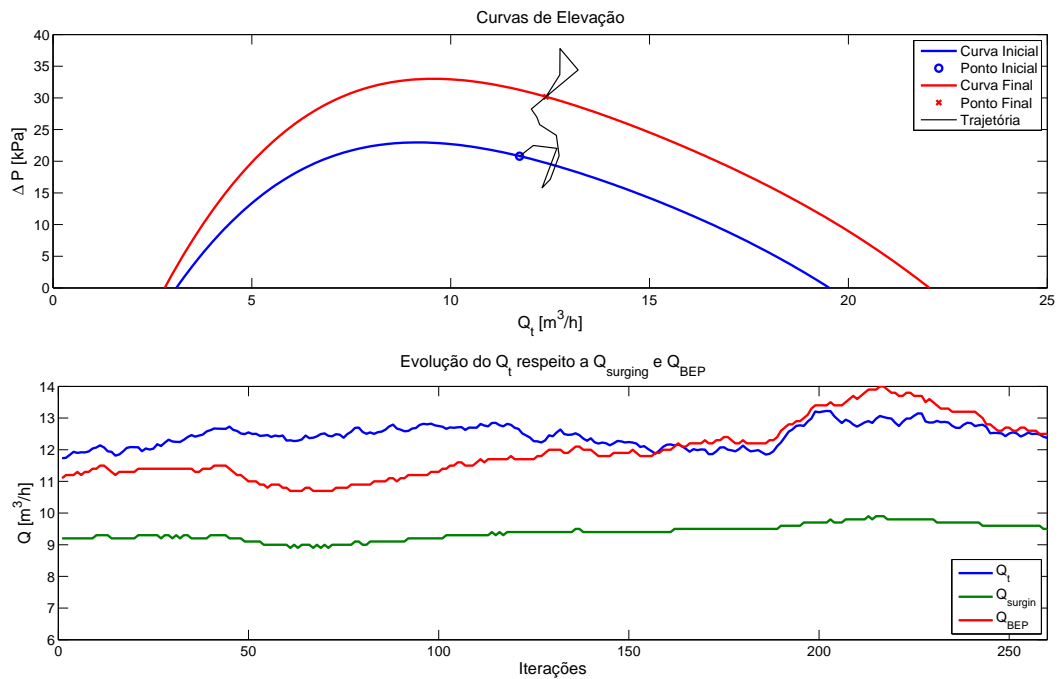
(a) Trajetória tonada pelo sistema de controle para $\alpha = 2\%$ (b) Trajetória tomada pelo sistema de controle para $\alpha = 4\%$

Figura 4.10: Trajetórias tomadas pelo sistema de controle para sair de baixas rotações.



(a) Evolução do sistema controlado para $\alpha = 2\%$ (b) Evolução do sistema controlado para $\alpha = 4\%$

Figura 4.11: Evolução do sistema de controle na simulação 3.

4.1.3.4 Simulação 4

A quarta simulação permitiu visualizar o desempenho do controlador especialista em um treinamento com o sistema BCS operando em uma condição abaixo do ΔP_{min} permitido. Na Tabela 4.9 são apresentadas as condições iniciais para a simulação. Essa simulação constou de dois testes, cada um deles para frações de vazios diferentes, neste caso de 2% e 4%. Para visualizar corretamente o desempenho do sistema de controle sair de um ΔP baixo, o limite mínimo permitido na elevação foi fixado em $40kPa$.

Tabela 4.9: Condições iniciais para a simulação 4

| Teste | α | P_{in} | <i>choke</i> | ω_{BCS} | ΔP |
|-------|----------|----------|--------------|----------------|------------|
| 1 | 2 % | 50 kPa | 75 % | 1400RPM | 30.62 kPa |
| 2 | 4 % | 50 kPa | 75 % | 1400RPM | 26.99 kPa |

Na Figura 4.12 são mostradas as trajetórias tomadas pelo sistema de controle para sair de um ΔP baixo. A Figura 4.12 (a) mostra o teste com a fração de vazio de 2 % e a Figura 4.12 (b) com fração de vazio de 4%. Como se pode notar na figura, o ponto inicial foi ajustado fora da zona de *surging* para forçar o sistema de controle a representar melhor a simulação, se mantendo acima de uma elevação permitida.

A Figura 4.13 mostra como evoluiu o diferencial de pressão na bomba BCS a cada iteração, também são mostrados os esforços de controle realizados pelo controle especialista tanto na rotação da bomba quanto na abertura da válvula, e finalmente mostra como último parâmetro, o erro relacionado com o ponto de BEP, já que este último representa um dos parâmetros de desempenho do sistema de controle. Na Figura 4.13 (a) são mostrados os resultados da bomba operando com uma fração de vazio de 2%, e na Figura 4.13 (b) são mostrados os resultados para a fração de 4%. Como pode-se notar nos dois casos o sistema de controle proposto foi capaz de fazer com que a bomba não operasse com um ΔP baixo mantendo o sistema BCS nos parâmetros permitidos e próximo do ponto de BEP. Quando o sistema BCS opera fora dos limites, o sistema de controle sempre retornar as condições de operação nos limites permitidas.



(a) Trajetória tomada pelo sistema de controle para $\alpha = 2\%$ (b) Trajetória tomada pelo sistema de controle para $\alpha = 4\%$

Figura 4.12: Trajetórias tomadas pelo sistema de controle para sair de elevações baixas.



(a) Evolução do sistema controlado para $\alpha = 2\%$ (b) Evolução do sistema controlado para $\alpha = 4\%$

Figura 4.13: Evolução do sistema de controle na simulação 4.

4.1.3.5 Simulação 5

A quinta simulação buscou testar o desempenho do sistema de controle em condições dinâmicas do reservatório, ou seja, com variações contínuas tanto de pressão de admissão da BCS (P_{in}) como também de fração de vazio (α). Decidiu-se que as variações dos parâmetros devem ser dadas por:

$$P_{in_k} = 25 \sin \left(2 * \pi \frac{1}{3000} k \right) + 125 \quad (4.1)$$

$$\alpha_k = \sin \left(2 * \pi \frac{1}{600} k \right) + 2 \quad (4.2)$$

Na Tabela 4.10 são apresentadas as condições iniciais para a simulação. Para garantir que o sistema mostre que é capaz de sair da zona de *surging*, a simulação é inicializada num ponto dentro dessa zona. A simulação constou de dois testes, cada um deles considerando diferentes condições iniciais de pressão, $125kPa$ e $170kPa$, nos dois casos foi utilizada uma fração de vazio de 2% como condição inicial.


Tabela 4.10: Condições iniciais para a simulação 5

| Teste | α | P_{in} | <i>choke</i> | ω_{BCS} | Q_t | ΔP |
|-------|----------|----------|--------------|----------------|------------------------|------------|
| 1 | 2% | 125kPa | 15% | 1800RPM | 6.032m ³ /h | 96.4kPa |
| 2 | 2% | 170kPa | 15% | 1800RPM | 6.992m ³ /h | 109.1kPa |


Na Figura 4.14 são mostradas as trajetórias tomadas pelo sistema de controle durante o teste 1 (Figura 4.14 (a)) e o teste 2 (Figura 4.14 (b)), onde os dois testes foram inicializados na zona de *surging*.

A Figura 4.15 mostra os erros entre a vazão real na BCS relacionados à vazão do ponto de BEP. Também são mostradas as variações obtidas pelo controle especialista na rotação da bomba e na abertura da válvula choke para colocá-la em operação no ponto de BEP.

No início dos dois testes realizados nessa simulação, o controlador especialista tendia a atuar de forma aleatória, este comportamento é mais notado nessa simulação do que nas simulações anteriores, o que já era esperado, já que no começo do treinamento as regras geradas são aleatórias e o sistema complexo adaptativo precisa algumas iterações para-se adaptar ao problema. Após algum de um tempo e o AG ter criado novas regras, o sistema de controle passa a ter a capacidade de retirar a operação da bomba da zona de *surging*, colocando-a em uma zona de operação segura. Além disso, o sistema especialista foi capaz de manter o sistema em operações próximo ao ponto de BEP, apesar de se variar continuamente as condições do reservatório.




(a) Trajetória tomada pelo sistema de controle no teste 1




(b) Trajetória tomada pelo sistema de controle no teste 2

Figura 4.14: Trajetórias tomadas pelo sistema de controle na simulação 5.



(a) Evolução do erro do sistema de controle teste 1



(b) Evolução do erro do sistema de controle teste 2

Figura 4.15: Evolução dos erros do sistema de controle na simulação 5.

Na Figura 4.16 (para o teste 1) e na Figura 4.17 (para o teste 2) são mostrados os comportamentos do sistema com respeito aos limites impostos pelo usuário. No primeiro teste (Figura 4.16) o sistema de controle tentar forçar uma operação no ponto de BEP, levou o sistema BCS a sair dos limites permitidos em diferentes ocasiões, neste caso de rotação mínima, e em consequência de diferencial de pressão mínimo. Apesar disso, o sistema de controle foi capaz de retornar a operação da bomba dentro desses limites. No teste 2 (Figura 4.17) o sistema especialista sempre foi capaz de manter o sistema BCS operando dentro dos limites permitidos.




Figura 4.16: Evolução do sistema com respeito aos limites no teste 1, simulação 5




Figura 4.17: Evolução do sistema com respeito aos limites no teste 2, simulação 5

Analisando-se os resultados obtidos de todas as simulações feitas em cada um dos testes em conjunto, pode-se inferir que o controlador especialista apresentou um bom desempenho em diferentes condições. Isso considerando que cada um dos testes foi inicializado em diferentes condições operacionais e os conjuntos de regras são inicialmente gerados de forma aleatória para cada um desses testes.

4.2 Análise de Resultados na Bancada de Testes do LabVIP

Para validar experimentalmente os métodos apresentados foi empregada a bancada de testes para BCS do LabVIP. Essa bancada foi projetada a partir de um conjunto BCS fornecido pelo centro de pesquisa da Petrobras (CENPES) (ver Anexo A), da qual foram coletados dados para gerar uma base de dados para os treinamentos dos modelos baseados nas curvas de desempenho de um conjunto de BCS. A base de dados obtida obedece a matriz de testes apresentada na subseção 3.2.2. Uma descrição dos dados está mostrada no Anexo C.

O conjunto de dados contém 787 amostras, a quais foram divididos em três (3) conjuntos: um de 551 amostras para treinamento (70% das amostras), e outros dois de 118 amostras (15% das amostras) para validação e teste.

4.2.1 Análise dos Modelos das Curvas de Desempenho

A Tabela 4.11 apresenta o desempenho dos modelos das curvas de desempenho da BCS empregando máquinas de vetores de suporte. Os parâmetros C da regularização, o σ^2 do “kernel” gaussiano e o ϵ da margem da SVM foram otimizados mediante algoritmos genéticos clássicos (ver Anexo B).

Tabela 4.11: Parâmetros da SVM, e desempenho da estimação das curvas de desempenho da BCS.

| Modelo | C | σ^2 | ϵ | e_{train} | e_{val} | e_{test} |
|-------------------|----------|------------|------------|---------------|---------------|---------------|
| \tilde{P}_{out} | 872.2471 | 0.04119 | 0.10039 | 15.7228 [kPa] | 15.7165 [kPa] | 14.8234 [kPa] |
| \tilde{W}_m | 111.0869 | 0.11689 | 0.073116 | 23.8932 [W] | 25.5681 [W] | 42.0029 [W] |
| $\tilde{\eta}$ | - | - | - | 2.4240 [%] | 1.6661 [%] | 1.7377 [%] |

Baseando-se nos erros apresentados na Tabela 4.11 pode-se inferir que os modelos apresentam boa capacidade de interpolar valores que não foram empregados no treinamento dos modelos, tanto para P_{out} quanto para W_m , já que apresentaram erros reduzidos, de teste de $\pm 14.8 kPa$ no modelo de P_{out} e de $42W$ para o modelo de W_m . Após calcular a eficiência da bomba η com os valores interpolados pelos modelos SVMr, foi obtido um erro, com o conjunto de dados de teste de 1.73% na estimação da eficiência. O erro de teste é empregado como um parâmetro para determinar o desempenho da interpolação dos modelos, já que o conjunto de dados de teste não se aplica à construção dos modelos.

As Figuras 4.18, 4.19 e 4.20 apresentam uma comparação entre os dados reais e os dados obtidos a partir dos modelos baseados em SVM. Estas curvas demonstram um bom comportamento dos modelos para diferentes frações de vazão. As curvas apresentadas são relacionadas a condição de operação com pressão de $300 kPa$ na admissão da bomba operando




Figura 4.18: Curva de desempenho do ΔP empregando os modelos SVM




Figura 4.19: Curva de desempenho de W_m empregando os modelos SVM




Figura 4.20: Curva de desempenho do η empregando os modelos SVM

a 2700 RPM. É possível notar que as curvas de desempenho para a potência apresentam uma discrepância maior.

Como foi exposto anteriormente, os algoritmos de aprendizado supervisionados não são bons extrapoladores. Devido a este fato, só são apresentadas nas Figuras 4.18, 4.19 e 4.20 interpolações próximas aos limites impostos pelos dados de treinamento. Como é descrito no Anexo A a bancada do LabVIP apresenta fortes oscilações em baixas vazões de fluido com a presença de ar na mistura, por isto é necessário evitar operar naquelas condições para aumentar a vida útil da bancada de testes para o conjunto de BCS.

4.2.2 Análise do Filtro de Partículas para Estimação da Vazão de Fluido

Os parâmetros empregados para o filtro de partículas são apresentados na Tabela 4.12, sendo n o número de partículas, w a covariância do ruído do sistema, v covariância do ruído do sensor, A a matriz dinâmica do sistema (considerado como sistema de primeira ordem), B , C e D fatores de escala para P_{in} , ω_{BCS} e α respectivamente (foi empregada a mesma matriz dinâmica das partículas do modelo de simulação). A Figura 4.21 apresenta o filtro de partículas estimando-se a vazão total de Fluido.

A Figura 4.21 mostra o comportamento do filtro de partículas quando é variada a abertura da válvula de choke, a rotação, a fração de vazio e a pressão de entrada. Como se pode notar, o filtro consegue prever corretamente o valor da vazão total de fluido empregando 100 partículas. O erro de estimação tendeu a aumentar quando a vazão de fluido bifásico era baixa e apresentava quantidades de gás consideráveis, apesar disso, o filtro continuou prevendo corretamente a vazão total de fluido, já que o erro de predição se manteve entre $\pm 1E - 3 [m^3/s]$.

Tabela 4.12: Parâmetros do filtro de partículas

| Parâmetro | Valor |
|-----------|--------------|
| n | 100 |
| w | 10 |
| v | 1 |
| A | 0.9802 |
| B | 0.1464 |
| C | $4.09e - 05$ |
| D | 0.01037 |




Figura 4.21: Desempenho do filtro de partículas.

Como pode ser notado na Figura 4.21, quando é ajustada a válvula choke, abrindo-a ou fechando-a ocorrem grandes variações na vazão de fluido. Neste caso, o filtro de partículas apresentou um bom desempenho predizendo corretamente a vazão mesmo quando os ajustes da válvula foram grandes. O filtro de partículas foi afetado pelas fortes variações na fração de vazio, já que o sistema BCS é bem sensível quando se tem ar na mistura e presença de ruídos de medição no sistema. Este erro de predição pode ser reduzido aumentando o número de partículas, o que geraria a necessidade de uma maior capacidade computacional.

4.2.3 Análise do Controle Especialistas com o Sistema Complexo Adaptativo

Com a finalidade de analisar o desempenho do controlador especialista interagindo com um sistema real de BCS foram realizados dois experimentos. Em ditos experimentos o controle especialista deve manter o sistema em condições perto ao ponto de BEP tendo em conta que o sistema complexo adaptativo (a base de conhecimento baseado em regras) começa o treinamento, com regras aleatórias. Para isto foi preciso dar prioridade às regras da função de recompensa ou punição do subsistema de apropriação de credito “*R*” para as regras referentes ao BEP, como é apresentado na Tabela 4.13.

Os limites de operação para o sistema BCS definidos para o experimento são apresentados na Tabela 4.14.

As condições iniciais empregadas para o algoritmo genético, o qual gera as novas

Tabela 4.13: Regras para a função do *R*

| <i>Sinal</i> | e_{Sinal} | Δe_{Sinal} | R_{Sinal} |
|------------------|-------------|--------------------|-------------|
| $Q_{surging}$ | <i>N</i> | <i>N</i> | -1.5 |
| | <i>N</i> | <i>Z</i> | -1 |
| | <i>N</i> | <i>P</i> | 1 |
| Q_{BEP} | <i>N</i> | <i>P</i> | 2.5 |
| | <i>N</i> | <i>N</i> | -0.5 |
| | <i>Z</i> | <i>Z</i> | 4 |
| | <i>P</i> | <i>N</i> | 2.5 |
| | <i>P</i> | <i>P</i> | -0.5 |
| ω_{min} | <i>N</i> | <i>N</i> | -1 |
| | <i>N</i> | <i>Z</i> | -1 |
| | <i>N</i> | <i>P</i> | 1 |
| ω_{max} | <i>P</i> | <i>N</i> | 1 |
| | <i>P</i> | <i>Z</i> | -1 |
| | <i>P</i> | <i>P</i> | -1 |
| ΔP_{min} | <i>N</i> | <i>N</i> | -1 |
| | <i>N</i> | <i>Z</i> | -1 |
| | <i>N</i> | <i>P</i> | 1 |

Tabela 4.14: Limites de operação do conjunto BCS

| Parâmetro | Valor |
|------------------|----------|
| ω_{max} | 3200 RPM |
| ω_{min} | 2600 RPM |
| ΔP_{min} | 100 kPa |

regras, são apresentadas na Tabela 4.15. Esse algoritmo executa 20 iterações para gerar um novo conjunto de regras, ou seja, uma geração é equivalente a 20 iterações do sistema complexo adaptativo interagindo com o ambiente. Foi fixado um tempo de 120s por iteração, dando tempo para que o sistema BCS se estabilizar após ter sido ajustado pelo sistema de controle. Uma geração levou 2400s para ser concluída.

Tabela 4.15: Condições iniciais do AG

| Parâmetro | Valor |
|-----------------------------------|-------|
| Tamanho da população a_i | 2000 |
| Probabilidade de Mutação p_M | 0.1 |
| Probabilidade de cruzamento p_c | 1 |
| Numero de filhos n_f | 100 |

Os incrementos empregados para variar tanto a abertura da válvula choke quanto a rotação da BCS são apresentados na Tabela 4.16.

Tabela 4.16: Incrementos dos atuadores

| Parâmetro | Valor |
|--------------------------------|----------------|
| Incremento BCS inc_{BCS} | 0.1 [rpm/s] |
| Incremento choke inc_{choke} | $3e - 4$ [%/s] |

4.2.3.1 Experimento 1 no LabVIP

O experimento teve o objetivo de testar o desempenho do controlador especialista num sistema BCS real que está operando fora do ponto de máxima eficiência (BEP). O treinamento do sistema complexo adaptativo foi inicializado considerando uma alta vazão de fluido. Na Tabela 4.17 são apresentadas as condições iniciais para o experimento.

Tabela 4.17: Condições iniciais para o experimento 1 com o sistema BCS do LabVIP

| Teste | α | P_{in} | choke | ω_{BCS} | Q_t |
|-------|----------|----------|-------|----------------|------------------------------|
| 1 | 3% | 250kPa | 50% | 2900RPM | $0.0081\text{ m}^3/\text{s}$ |

Para este experimento foi fixada a fração de vazio em 3% durante o experimento, no caso da pressão de admissão da bomba BCS, foi imposta uma rotação fixa na bomba *booster* garantindo uma pressão inicial de 250kPa. Ao fixar a rotação da bomba era esperado que a pressão tende-se a aumentar durante o experimento em baixas vazões de fluido.




Figura 4.22: Trajetória tomada pelo sistema de controle

Na Figura 4.22 é mostrada a trajetória tomada pelo sistema de controle para achar o ponto de BEP, a Figura 4.23 mostra o erro entre a vazão real na BCS relacionado à vazão do ponto de BEP, também são mostrados os ajustes feitos pelo controle especialista na rotação da bomba e na abertura da válvula choke para colocar a bomba operando na condição de BEP.

Como pode-se mostrar, o sistema de controle, nas primeiras 40 iterações do treinamento das regras, oscilou entorno da condição inicial e após essas iterações ele foi capaz de colocar a bomba operando no ponto de BEP, mantendo-se oscilando entorno desta condição de operação.




Figura 4.23: Evolução do erro do sistema de controle

Já era esperado que o sistema oscilasse entorno do ponto desejado, já que as regras só decidem a direção para onde o sistema deveria operar, executa a ação por um tempo definido (neste caso 120s) com uma velocidade fixa, no momento que terminar a ação o sistema avalia a condição atual e calcula novos parâmetros para operar nas condições predefinidas. Ou seja, em quanto o sistema de controle estiver executando uma ação, ele não fará correções na trajetória.

4.2.3.2 Experimento 2 no LabVIP

No experimento 2, o treinamento do sistema complexo adaptativo foi inicializado considerando uma baixa vazão de fluido. Na Tabela 4.18 são apresentadas as condições iniciais para o experimento.

Tabela 4.18: Condições iniciais para o experimento 2 com o sistema de BCS do LabVIP

| Teste | α | P_{in} | choke | ω_{BCS} | Q_t |
|-------|----------|----------|-------|----------------|--------------------------|
| 1 | 5% | 278 kPa | 25% | 2900 RPM | 0.0017 m ³ /s |

Neste experimento foi selecionada a vazão mássica de ar em 1g/s variando-se a fração de vazio, a qual aumentava em baixas vazões de fluido, o que por sua vez aproximava o experimento de uma condição de um reservatório real. Para manter a pressão de admissão de entrada da bomba BCS foi imposta uma rotação fixa na bomba *booster* garantindo-se uma pressão inicial de 278 kPa. A se fixar a rotação da bomba era esperado que a pressão apresentasse variações durante o experimento tendendo a aumentar em baixas vazões de fluido.




Figura 4.24: Trajetória tomada pelo sistema de controle

A Figura 4.24 apresenta a trajetória tomada pelo sistema de controle para colocar a bomba operando no ponto de BEP. Na Figura 4.25 é mostrado o erro entre a vazão real na BCS relacionado à vazão do ponto de BEP. Na Figura 4.24 também são mostrados os ajustes feitos




Figura 4.25: Evolução do erro do sistema de controle

pelo controle especialista na rotação da bomba e na abertura da válvula choke para colocar a bomba operando na condição de BEP. Além disto, são mostradas as variações observadas na fração de vazio e na pressão de admissão na bomba BCS. Como pode-se notar, o sistema de controle executou pelo menos 120 iterações para colocar a bomba operando próximo ao ponto de BEP a partir da condição inicial. Após um certo tempo, entorno de 20 iterações (uma geração) o sistema manteve-se oscilando entorno deste.

Ao se permitir nessa simulação a variação da fração de vazio, era esperado que o sistema de controle utilizasse mais tempo para se estabilizar. Este comportamento também ocorreu na simulação 5, realizada no simulador alterando-se o comportamento do reservatório durante a simulação. Levando isso em conta é esperado que com um maior tempo do sistema de controle interagindo com a bancada BCS o desempenho melhore.

5 CONCLUSÕES

Este trabalho propõe uma solução para o controle da produção de petróleo quando o método de elevação empregado no poço é o bombeio centrífugo submerso. O sistema proposto é um sistema de controle especialista, cujo núcleo de regras é gerado empregando-se sistemas complexos adaptativos, os quais devido à sua capacidade de aprender a partir da experiência podem gerar soluções a condições não planejadas.

Uma das dificuldades inerentes do bombeio centrífugo submerso é a presença de gás na mistura de fluido bombeado. Como foi exposto neste trabalho, altas quantidades de gás passando pela bomba podem causar danos aos componentes mecânicos da mesma, provocando no pior dos casos a paradas prematuras na produção decorrente da falha do sistema BCS. Tendo em mente este fato, é proposta uma metodologia que permitisse identificar o ponto de operação da bomba, e posteriormente dependendo deste, gerar um esforço de controle para manter a bomba BCS operando dentro de seus parâmetros de desempenho com a finalidade de prolongar a sua vida útil.

Para se detectar o ponto de operação da bomba é preciso ter acesso à modelos da bomba que representem o desempenho da mesma. Neste trabalho é proposto empregar métodos de aprendizado de máquinas para modelar as curvas de desempenho da bomba, as quais são: curva de elevação - vazão, curva de potência mecânica - vazão e a curva de eficiência - vazão, partindo-se de uma operação real. O método de aprendizado empregado neste trabalho, máquinas de vetores de suporte para regressão, permitiu gerar satisfatoriamente modelos das curvas de desempenho empregando dados experimentais adquiridos diretamente da bomba BCS para diferentes pontos de operação (pressão, vazão, rotação e frações de vazio). Os erros baixos de predição ate mesmo, com dados que não foram empregados para o treinamento, dos modelos obtidos apresentaram um bom ajuste operacional da bomba.

Existem variáveis físicas que não podem ser medidas diretamente na bomba como sua vazão total de fluido e sua fração de vazio. Outras variáveis como a pressão de admissão, pressão de saída da bomba e temperatura no reservatório podem ser medidas atualmente empregando-se sensores de fundo. A potência da bomba pode ser calculada a partir da corrente do motor do conjunto BCS, a qual é mensurável através do inversor de frequência da bomba. Neste trabalho a fração de vazio é considerada conhecida, já que existem trabalhos para estimar esta variável. Para estimar a vazão total de líquido passando pela bomba foi empregado um filtro de partículas, o qual a partir de variáveis conhecidas, como o diferencial de pressão na bomba, a fração de vazio, sua rotação e sua potência, foi capaz de fornecer uma aproximação bastante boa do valor de vazão de líquido bombeado pelo sistema.

O sistema de controle proposto envolve um controlador especialista, que emprega

os modelos das curvas de desempenho, variáveis mesuráveis e variáveis estimadas pelo filtro de partículas para prever o ponto real de operação da bomba, e conseqüentemente executar um sistema especialista baseado em regras e tomar a decisão necessária para manter a bomba operando numa condição dentro dos parâmetros permitidos. Neste trabalho o sistema especialista foi empregado para desenvolver um sistema complexo adaptativo.

O sistema especialista adaptativo desenvolvido foi capaz de gerar novas regras empregando algoritmos genéticos, cujo desempenho foi testado empregando-se um modelo dinâmico de uma bancada de testes para BCS, desenvolvido num trabalho prévio por Jimenez (JIMENEZ *et al.*, 2014). Com o modelo de simulação, o controle especialista foi submetido a cinco (5) simulações para testar seu comportamento quando a bomba sai dos limites permitidos.

Em um dos experimentos testou-se o desempenho do sistema de controle com a bomba operando num ponto dentro da zona de *surging*. O experimento demonstrou que o sistema de controle foi capaz de retirar a bomba da operação da zona de *surging* após certo número de iterações, mantendo-a fora do mesmo.

Nos três casos utilizados para se testar os limites impostos pelo usuário, os limites máximos e mínimos de rotação na BCS e um limite de diferencial mínimo de pressão, o controlador especialista foi capaz de levar o sistema BCS para fora das condições dos limites até as condições permitidas e seguras de operação.

Além de levar o sistema BCS para fora de condições não permitidas o controlador especialista foi capaz de manter o sistema BCS próximo ao ponto de máxima eficiência ou BEP. Conforme o esperado, o sistema de controle não foi capaz de estabilizar a operação da bomba no BEP, já que não era uma prioridade porque no sistema complexo adaptativo tinha sido definido como prioridade sair da zona de *surging* e de condições não permitidas, em segundo caso se manter no BEP. Estas regras foram assim definidas com a finalidade de dar mais flexibilidade ao sistema especialista em sua tomada de decisões.

Na simulação que o controle especialista foi submetido a mudanças contínuas no reservatório, ou seja, a variações contínuas na pressão de admissão da bomba e na fração de vazio, o sistema de controle foi capaz de manter a bomba BCS fora das zonas de operação não permitidas. No caso em que as condições do reservatório forçaram o sistema a operar nas regiões não permitidas, o controlador após algum tempo foi capaz de intervir para retirar a operação da bomba destas zonas não desejadas. O experimento mostrou também que o sistema de controle foi capaz manter o ponto de operação da bomba próximo ao ponto de BEP.

O sistema de controle foi testado numa bancada de testes para sistemas BCS, na qual focou-se em testar o desempenho do controlador mantendo o equipamento operando próximo ao ponto de BEP. Os resultados do experimento e das simulações mostraram que o sistema de controle foi capaz de levar a bomba operando próximo do ponto de BEP e mantê-la operando entorno deste ponto.

Finalmente, a metodologia proposta neste trabalho permitiu conhecer o ponto de operação da bomba viabilizando o controle da mesma para assegurar condições seguras de operação, garantindo um bom funcionamento da bomba. Nesta metodologia também se comprovou que um sistema de controle especialista auto treinado tem a capacidade de controlar o sistema BCS mantendo-o em condições seguras. Levando-se em conta o exposto, pode-se concluir que a metodologia proposta é viável de ser aplicada principalmente em sistemas complexos, e sistemas nos quais se tem pouco conhecimento a priori do seu funcionamento.

6 TRABALHOS FUTUROS

Neste trabalho foi imposto como ponto referência de controle de operação o ponto de BEP, mas a indústria também seleciona o ponto de vazão máxima permitido pelo fabricante da bomba, tornando-o um outro caso de interesse a ser estudado, empregando-se sistemas especialistas.

Um trabalho interessante que pode melhorar o desempenho do sistema complexo adaptativo é somente criar regras factíveis, tanto na geração aleatória de regras quanto pelo sistema de descoberta de novas regras, em vez de permitir a criação de regras infactíveis com a esperança que sejam descartados pelo processo evolutivo.

Num poço de petróleo existem diversas limitações de produção conhecidas, por exemplo: a vazão máxima admissível pelo reservatório, o controle do nível dinâmico do reservatório e a submergência da bomba. Sugere-se estudar os efeitos dessas limitações e adicioná-las no controlador especialista.

REFERÊNCIAS

- ANDREW, N. Introduction to machine learning. In: **Machine learning Course**. [S.l.: s.n.], 2012.
- ÅRZÉN, K.-E. An architecture for expert system based feedback control. **Automatica**, Elsevier, v. 25, n. 6, p. 813–827, 1989.
- ÅSTRÖM, K. J.; ANTON, J. J.; ÅRZÉN, K.-E. Expert control. **Automatica**, Elsevier, v. 22, n. 3, p. 277–286, 1986.
- ATMAR, W. Notes on the simulation of evolution. **IEEE Transactions on Neural Networks**, IEEE, v. 5, n. 1, p. 130–147, 1994.
- BACK, T. Selective pressure in evolutionary algorithms: A characterization of selection mechanisms. In: IEEE. **Proceedings of the first IEEE conference on evolutionary computation. IEEE World Congress on Computational Intelligence**. [S.l.], 1994. p. 57–62.
- BÄCK, T.; HOFFMEISTER, F. Extended selection mechanisms in genetic algorithms. 1991.
- BINDER, B. J. T. *et al.* Embedded model predictive control for an electric submersible pump on a programmable logic controller. In: IEEE. **2014 IEEE Conference on Control Applications (CCA)**. [S.l.], 2014. p. 579–585.
- BOOKER, L. B.; GOLDBERG, D. E.; HOLLAND, J. H. Classifier systems and genetic algorithms. **Artificial intelligence**, Elsevier, v. 40, n. 1-3, p. 235–282, 1989.
- BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A training algorithm for optimal margin classifiers. In: ACM. **Proceedings of the fifth annual workshop on Computational learning theory**. [S.l.], 1992. p. 144–152.
- BUCHANAN, B. G. Expert systems: working systems and the research literature. **Expert systems**, Wiley Online Library, v. 3, n. 1, p. 32–50, 1986.
- CHANG, C.-C.; LIN, C.-J. Libsvm: A library for support vector machines. **ACM transactions on intelligent systems and technology (TIST)**, Acm, v. 2, n. 3, p. 27, 2011.
- CORTES, C.; VAPNIK, V. Support-vector networks. **Machine learning**, Springer, v. 20, n. 3, p. 273–297, 1995.
- COSTA, R. d. O. **Controle aplicado a poços com método de elevação e bombeio centrífugo submerso**. Tese (Doutorado) — Universidade Federal do Rio Grande do Norte, 2012.
- DOYLE, J.; STEIN, G. Multivariable feedback design: Concepts for a classical/modern synthesis. **IEEE Trans. On Automatic Control**, Vol AC-26, No 1, pp 4-16, 1981.
- DOYLE, J. C. *et al.* State-space solution to standard h_2 and h_∞ control problem. **IEEE Transaction on Automatic Control**, Vol 31, No 8, pp831-846, 1989.
- FILHO, M. d. A. B. **Geração de carta dinamometrica de fundo para diagnostico do bombeio mecanico em poços de petroleo**. Dissertação (Mestrado) — FEM/UNICAMP, 1993.

GAGO, M. F. A. **Modelo de juntas soldadas por FSW utilizando métodos de aprendizagem de máquina através de dados experimentais**. Dissertação (Mestrado) — FEM/UNICAMP, 2013.

GAO, M. *et al.* Beam-pumping unit energy-saving control system based on support vector machine. In: IEEE. **2008 IEEE International Conference on Automation and Logistics**. [S.l.], 2008. p. 1864–1869.

GENÇAÇA, D.; KURUOĞLU, E. E.; ERTÜZÜN, A. Estimation of time-varying autoregressive symmetric alpha stable processes by particle filters. In: IEEE. **2005 13th European Signal Processing Conference**. [S.l.], 2005. p. 1–4.

GEROMEL, J. C.; PALHARES, A. G. **Análise linear de sistemas dinâmicos: teorias, ensaios práticos e exercícios**. [S.l.]: Edgard Blucher, 2004.

GOLDBERG, D. E. Dynamic system control using rule learning and genetic algorithms. In: **IJCAI**. [S.l.: s.n.], 1985. v. 85, p. 588–592.

GOLDBERG, D. E. Computer-aided pipeline operation using genetic algorithms and rule learning. part i: Genetic algorithms in pipeline optimization. **Engineering with Computers**, Springer, v. 3, n. 1, p. 35–45, 1987.

GOLDBERG, D. E. Computer-aided pipeline operation using genetic algorithms and rule learning. part ii: Rule learning control of a pipeline under normal and abnormal conditions. **Engineering with Computers**, Springer, v. 3, n. 1, p. 47–58, 1987.

GORDON, N. J.; SALMOND, D. J.; SMITH, A. F. Novel approach to nonlinear/non-gaussian bayesian state estimation. In: IET. **IEE proceedings F (radar and signal processing)**. [S.l.], 1993. v. 140, n. 2, p. 107–113.

HOLLAND, J. H. **Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence**. [S.l.]: United States of America: University of Michigan Press, 1975.

HOLLAND, J. H. **Hidden orderhow adaptation builds complexity**. [S.l.: s.n.], 1995.

HOLLAND, J. H. **Emergence: From Chaos to Order**. [S.l.]: Oxford University Press, 1998.

HORVITZ, E. J.; BREESE, J. S.; HENRION, M. Decision theory in expert systems and artificial intelligence. **International journal of approximate reasoning**, Elsevier, v. 2, n. 3, p. 247–302, 1988.

HUSSEIN, H.; AL-DURRA, A.; BOIKO, I. Design of gain scheduling control strategy for artificial gas lift in oil production through modified relay feedback test. **Journal of the Franklin Institute**, Elsevier, v. 352, n. 11, p. 5122–5144, 2015.

ISARD, M.; BLAKE, A. Condensation-conditional density propagation for visual tracking. **International journal of computer vision**, Springer, v. 29, n. 1, p. 5–28, 1998.

JIMENEZ, G. E. C. *et al.* **Simulação do controle de escoamento multifásico em uma bomba centrífuga submersa-BCS**. Dissertação (Mestrado) — FEM/UNICAMP, 2014.

JONG, K. A. D. Analysis of the behavior of a class of genetic adaptive systems. 1975.

- KIM, J.; PEARL, J. A computational model for causal and diagnostic reasoning in inference systems. In: **International Joint Conference on Artificial Intelligence**. [S.l.: s.n.], 1983. p. 190–193.
- LARRANAGA, P. *et al.* Learning bayesian network structures by searching for the best ordering with genetic algorithms. **IEEE transactions on systems, man, and cybernetics-part A: systems and humans**, IEEE, v. 26, n. 4, p. 487–493, 1996.
- LEA, J. F.; BEARDEN, J. *et al.* Effect of gaseous fluids on submersible pump performance. **Journal of Petroleum Technology**, Society of Petroleum Engineers, v. 34, n. 12, p. 2–922, 1982.
- LIAO, S.-H. Expert system methodologies and applications—a decade review from 1995 to 2004. **Expert systems with applications**, Elsevier, v. 28, n. 1, p. 93–103, 2005.
- LJUNG, L. **System Identification: Theory for the User, Second Edition, Upper Saddle River**. [S.l.]: Prentice Hall PTR, 1999.
- MITCHELL, M. **An introduction to genetic algorithms**. [S.l.]: MIT press, 1998.
- MONTE, W. V. **Estudo Experimental de Bombas de BCS Operando com Escoamento Bifásico Gás-Líquido**. Dissertação (Mestrado) — FEM/UNICAMP, 2011.
- MORRISON, G. *et al.* Performance evaluation of a multiphase electric submersible pump. In: OFFSHORE TECHNOLOGY CONFERENCE. **Offshore Technology Conference**. [S.l.], 2014.
- OGATA, K. **Modern Control Engineering, 4a Ed.** [S.l.]: Pearson Education International, 2002.
- ORDOÑEZ, B. **Proposta de controle de operação de poços com bombeio mecânico através da pressão de fundo**. Tese (Doutorado) — Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Engenharia de Automação e Sistemas, 2008.
- ORDOÑEZ, B. *et al.* Sucker-rod pumping system: Simulator and dynamic level control using bottom hole pressure. In: IEEE. **2008 IEEE International Conference on Emerging Technologies and Factory Automation**. [S.l.], 2008. p. 282–289.
- PAVLOV, A. *et al.* Modelling and model predictive control of oil wells with electric submersible pumps. In: IEEE. **2014 IEEE Conference on Control Applications (CCA)**. [S.l.], 2014. p. 586–592.
- PÉREZ-CRUZ, F.; BOUSQUET, O. Kernel methods and their potential use in signal processing. **IEEE Signal Processing Magazine**, IEEE, v. 21, n. 3, p. 57–65, 2004.
- PINEDA, L. R. **Controle do ponto de operação de bombas centrífugas submersas em escoamento líquido-gás usando redes neurais**. Dissertação (Mestrado) — FEM/UNICAMP, 2016.
- QUINTAES, O.; SALAZAR, A.; FONTES, F. Unidade de bombeio mecânico inteligente. In: **Rio Oil and Gas Expo and Conference, Rio de Janeiro**. [S.l.: s.n.], 2010.

- RICARDO, D. M. M. *et al.* Multiphase gas-flow model of an electrical submersible pump. **Oil & Gas Science and Technology–Revue d’IFP Energies nouvelles**, EDP Sciences, v. 73, p. 29, 2018.
- RODRIGUES, P. A. **Estudo de um sistema inteligente para elevação de poços e controle de processos petrolíferos**. Tese (Doutorado) — FEM/UNICAMP, 1996.
- RODRÍGUEZ, F. R.; LÓPEZ, S. M. **Control Adaptativo y Robusto**. [S.l.]: Universidad de Sevilla, 1996.
- SAJJA, P. S.; AKERKAR, R. Advanced knowledge based systems: model, applications & research. **TMRF e-Book**, v. 1, p. 50–73, 2010.
- SALAMANCA, L. F. B. **Controle de bombas centrífugas submersas para operação no ponto de melhor eficiência**. Dissertação (Mestrado) — FEM/UNICAMP, 2018.
- SHARMA, R.; GLEMMESTAD, B. Nonlinear optimization and control of an electric submersible pump lifted oil field. In: IEEE. **2013 5th International Conference on Modelling, Identification and Control (ICMIC)**. [S.l.], 2013. p. 26–31.
- SHARMA, R.; GLEMMESTAD, B. Optimal control strategies with nonlinear optimization for an electric submersible pump lifted oil field. 2013.
- SKOGESTAD, S.; POSTLETHWAITE, I. **Multivariable Feedback Control Analysis and design**. [S.l.]: Wiley New York, 2007. v. 2.
- SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and computing**, Springer, v. 14, n. 3, p. 199–222, 2004.
- SOUZA, L. F. *et al.* Elevação de petróleo por bcs via técnica de controle fuzzy pid supervisor. In: **XX Congresso Brasileiro de Automática**. [S.l.: s.n.], 2014. p. 4203–4209.
- STEIN, G.; ATHANS, M. The lqr/ltr procedure for multivariable feedback control design. **IEEE Transaction on Automatic Control, Vol AC-32, No 2, pp 105-113**, 1987.
- STOEAN, R. *et al.* Evolutionary support vector regression machines. In: IEEE. **2006 Eighth International Symposium on Symbolic and Numeric Algorithms for Scientific Computing**. [S.l.], 2006. p. 330–335.
- TAKACS, G. **Electrical submersible pumps manual: design, operations, and maintenance**. [S.l.]: Gulf professional publishing, 2017.
- TIAN, J. *et al.* Energy-saving control system of beam-pumping unit based on wavelet neural network. In: IEEE. **2008 Fourth International Conference on Natural Computation**. [S.l.], 2008. v. 5, p. 509–513.
- VAPNIK, V.; GOLOWICH, S. E.; SMOLA, A. J. Support vector method for function approximation, regression estimation and signal processing. In: **Advances in neural information processing systems**. [S.l.: s.n.], 1997. p. 281–287.
- VARGAS, P. A. **SISTEMAS CLASSIFICADORES PARA REDUÇÃO DE PERDAS EM REDES DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**. Tese (Doutorado) — Universidade Estadual de Campinas, 2000.

WHITE, M. F. **Fluid Mechanics**. [S.l.]: 4th ed, McGraw-Hill, pp 711-768, 1999.

YU, Q.; LIU, Y.; RAO, F. Parameter selection of support vector regression machine based on differential evolution algorithm. In: IEEE. **2009 Sixth International Conference on Fuzzy Systems and Knowledge Discovery**. [S.l.], 2009. v. 2, p. 596–598.

ZHANG, H.; LEI, Y. Bsp-based support vector regression machine parallel framework. In: IEEE. [S.l.], 2013. p. 329–334.

ZHU, J.; ZHANG, H.-Q. A review of experiments and modeling of gas-liquid flow in electrical submersible pumps. **Energies**, Multidisciplinary Digital Publishing Institute, v. 11, n. 1, p. 180, 2018.

ANEXO A – BANCADA DE TESTE DO LABVIP

O diagrama esquemático da bancada do LabVIP é apresentado na Figura A.1.

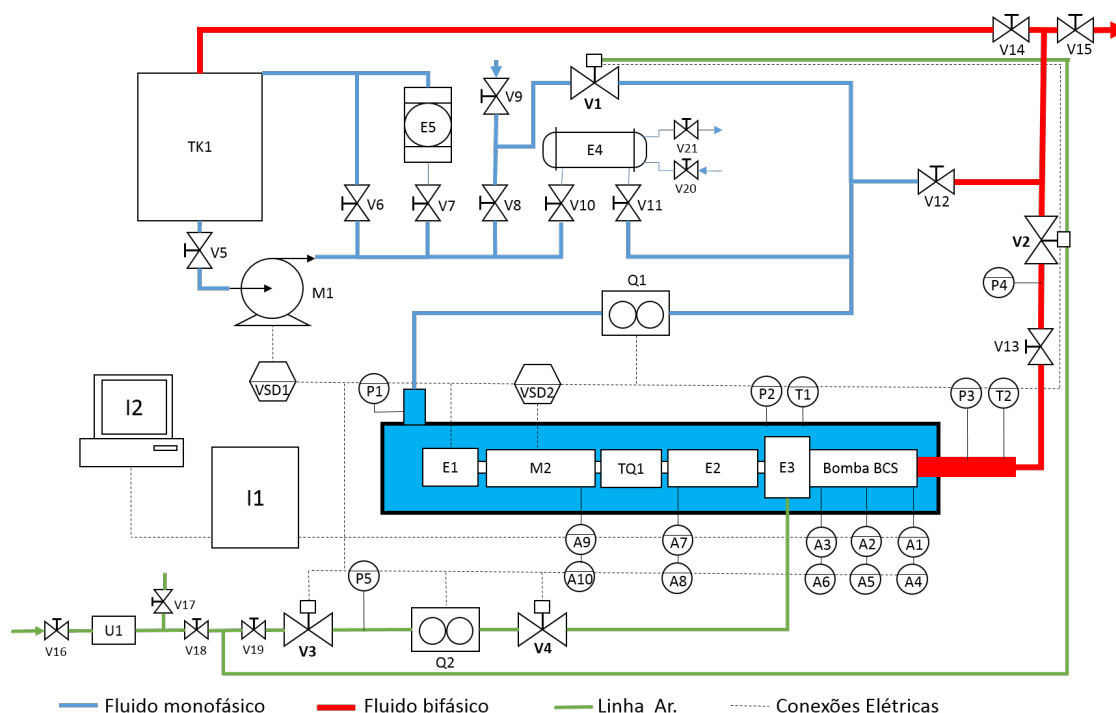


Figura A.1: Diagrama esquemático da instrumentação da bancada do LabVIP.

Na bancada, uma bomba *booster* (M1) bombeia a água do tanque (TK1) para a linha de baixa pressão (pressão máxima de 10 bar) com o objetivo de compensar as perdas de carga devidas à tubulação e acessórios, a bomba *booster* também tem a função de controlar a pressão na entrada da BCS. O ajuste de pressão da bomba *booster* é realizado mediante controle da rotação do eixo da bomba empregando o inversor de frequência (VSD1). Antes de ser admitido na bomba BCS, o líquido passa por um medidor de vazão (Q1). O ar utilizado como parte gasosa é comprimido e injetado na sucção da BCS empregando o misturador (E3), cuja vazão é medida pelo medidor de vazão (Q2). O controle da vazão de gás é realizado por uma válvula (V4) que fica depois do medidor de vazão (Q2). O fluido multifásico é bombeado de volta ao tanque de água por uma linha de alta pressão (pressão máxima 20bar) onde é realizada a separação gravitacional das fases da mistura. A vazão de fluido é controlada por uma válvula (V2) conhecida como válvula choke, instalada na tubulação de recalque. O acionamento da BCS é realizado por um motor (M2) de indução trifásico controlado por um inversor de frequência (VSD2). No circuito de testes também são medidas as pressões (P2 e P3), temperaturas (T1 e T2) na entrada e saída da BCS, torque (TQ1) no eixo de acionamento da bomba e a corrente do motor elétrico através do inversor do motor da BCS (VSD2).

Tabela A.1: Componentes da bancada do LabVIP

| Id | Equipamento | Modelo | Descrição |
|-----------|---|------------------------------|---|
| M1 | Conjunto motor-bomba (<i>booster</i>) | Imbil Ita 65-160 | Bomba centrífuga <i>booster</i> de um estágio e motor elétrico WEG de 20 hp e 3600 rpm |
| | Motor elétrico (<i>booster</i>) | WEG | Acionamento da BCS, trifásico 380 V, 60 Hz, 50 hp, 3555 rpm. |
| VSD1 | Inversor de frequência (<i>booster</i>) | WEG GFW-09 | Trifásico, 20 hp, 440 V, 60 Hz, microprocessado com display digital e comando através de teclado (acionamento da <i>booster</i>) |
| M2 | Motor bomba BCS | 450 FMH | Motor 450 FMH 31 hp/445 V/45 A |
| BCS | Bomba BCS | P43 SSD | Bomba com <i>intake</i> integrado P43 SSD 9 estágios |
| E1 | Sensor de fundo | – | Sensor de fundo |
| E2 | Protetor BCS | FSFB3 | Selo Protetor FSFB3 duas câmaras |
| E3 | Injetor Ar | – | Injetor de Ar |
| VSD2 | Inversor de frequência (BCS) | WEG CFW-11 | Inversor de frequência Trifásico, 380-480v, 70A microprocessado com display digital e comando através de teclado (acionamento da BCS) |
| TQ1 | Torquímetro | T22 | transdutor de torque T22 /1KNM |
| TK1 | Tanque | Retap 4000L | Tanque, de água, cilíndrico com capacidade de 4 m ³ . |
| E4 | Trocador de calor | JPX Ø 273x1200 | Tipo casco/tubos, capacidade térmica 37000 kcal/h e área de troca de 7,8 m ² . |
| E5 | Filtro de água | HE-FC-SS4-130T-SPEED 6-S1 | Filtro de água da MICRILINE |
| Q1 | Medidor líquido | F300S355 - CQBZP ZZZZ | Sensor de vazão tipo Coriolis com transmissor de vazão 1700R12ABZPZZZPK |
| Q2 | Medidor Ar | CMFS015 - M313N2 BZPCZZ | Sensor de vazão tipo Coriolis com transmissor de vazão 1700R12ABZPZZZPK |
| P1 | Pressão na entrada da cápsula | 1502B01 - FJ500PSIG | Sensor de pressão 0-500 PSI |
| P2 | Pressão de admissão da BCS | 1502B01 - FJ500PSIG | Sensor de pressão 0-500 PSI |

Tendo em conta a Figura A.1, os distintos componentes empregados na bancada estão apresentados na Tabela A.1.

| Id | Equipamento | Modelo | Descrição |
|-----------|--|---------------------|--|
| P3 | Pressão na descarga da BCS | 1502B01 - FJ500PSIG | Sensor de pressão 0-500 PSI |
| P4 | Pressão na válvula choke | 1502B01 - FJ500PSIG | Sensor de pressão 0-500 PSI |
| P5 | Pressão na linha de ar | 1502B01 - FJ500PSIG | Sensor de pressão 0-500 PSI |
| T1 | Temperatura de admissão da BCS | PT100 | PT100 com transmissor C201 análogo programável com 2-fios de transmissão ajustado de 0C a100C |
| T2 | Temperatura na saída da BCS | PT100 | PT100 com transmissor C201 analógico programável com 2-fios de transmissão ajustável de 0C a100C |
| A1-A10 | Sensor de vibração | 604B11 | Acelerômetro triaxial piezotronics |
| V1 | Válvula de controle de temperatura | DN 120 | Válvula de controle tipo globo, 3" com posicionador E/P NT100I |
| V2 | Válvula de controle da vazão de fluido (choke) | DN 120 | Válvula de controle tipo globo, 3" com posicionador E/P NT100I |
| V3 | Válvula de controle de pressão de ar | HORA BR225 | Válvula globo de controle proporcional de 2 vias |
| V4 | Válvula de controle da vazão de gás | HORA BR225 | Válvula globo de controle proporcional de 2 vias |
| V5-V21 | Válvulas de passo | – | Válvulas tipo globo on/off |
| I1 | Painel de instrumentos | – | – |
| I2 | <i>Desktop</i> | – | Computador empregado para visualização de variáveis e controle |

Os Atuadores e sensores estão todos acondicionados no painel de instrumentos, no qual se encontram as fontes de tensão para energizar os instrumentos, conversores de sinal, amplificadores e filtros todos conectados com o sistema de controle e supervisão. Na Figura

A.2 é mostrado o painel de instrumentos.



Figura A.2: Painel de instrumentos

O sistema de controle e supervisão está embarcado num processador dSpace MicroAutobox II. Este sistema de supervisão se encontra detalhado na seção A.1. Devido ao fato do dSpace trabalhar com níveis lógicos, de 0-5V nas suas portas de entradas e saídas, e os sensores e atuadores terem diferentes tipos de sinais de medição e atuação, como 0-10V e 4-20mA, foi necessário o uso de conversores analógicos para adequar os diferentes sinais de cada um dos dispositivos empregados, como é apresentado a seguir:

Atuadores:

- Válvulas de controle com sinal de atuação 4-20mA, em conjunto com conversor analógico com entrada de 0-5V e saída de 4-20mA.
- Inversores de frequência para controle das bombas com sinal de atuação 0-10V, em conjunto com um conversor analógico com entrada de 0-5v e saída de 0-10V.

Sensores e transdutores:

- Transdutores de pressão com sinal de medição 0-10V, em conjunto com um conversor analógico com entrada de 0-10V e saída de 0-5V.
- Sensores de vazão com sinal de medição 4-20mA, em conjunto com um conversor analógico com entrada de 4-20mA e saída de 0-5V.

- Transdutores de temperatura com sinal de medição 4-20mA, em conjunto com um conversor analógico com entrada de 4-20mA e saída de 0-5V.

Uma das vantagens de utilizar este tipo de conversores analógicos é desacoplar os sinais insolando-os dos equipamentos, melhorando sua qualidade e reduzindo sua contaminação.

A.1 Sistema de Controle e Supervisão da Bancada Basculante

Para desenvolver o sistema de controle e supervisão foi empregado o sistema MicroAutoBox com uma placa dSPACE DS-1511. Sendo que o software para fazer o acompanhamento e monitoramento o CONTROLDESK da dSPACE.

Para desenvolver a aplicação em tempo real com a placa dSPACE, em uma primeira etapa foi necessário gerar um modelo no Simulink, usando blocos dSPACE RTI (*Real Time Interface*) de interface I/O, para em seguida compila-lo em linguagem C e carregado na aplicação de tempo real (ver Figura A.3).

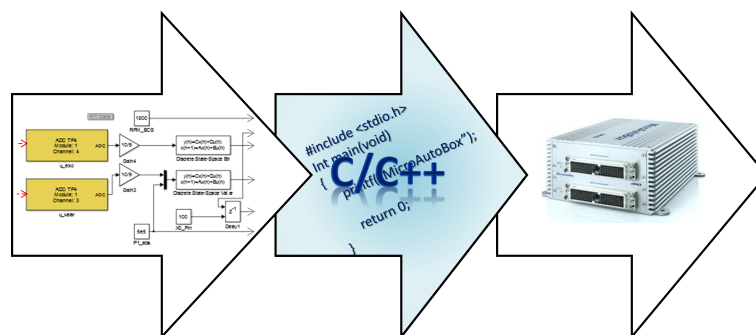


Figura A.3: Processo de geração de aplicação em tempo real

O MicroAutoBox é composto de uma placa DS-1511 com processador IBM PPC 750GL, 900MHz, dezesseis (16) canais de entradas analógicas de 16 bits com faixa de 0V-5V, quatro (4) canais de saída analógica de 12 bits com faixa de 0V-4.5V e com a possibilidade de usar conversores DAC (*Digital Analog Converter*) ou ADC (*Analog Digital Converter*) e entrada e saída digital.

O CONTROLDESK é um software usado para acompanhar a aquisição, visualização e monitoramento de dados, podendo-se alterar alguns de seus parâmetros e variáveis de modo contínuo. Ele executa todas as tarefas necessárias, em um único ambiente de trabalho, desde o início do experimento até seu fim, apresentando uma interface simples para iniciar, validar e acompanhar o comportamento dos modelos de operação e controle com ferramentas de automação, instrumentação virtual e com a vantagem de execução em tempo real. A Figura A.4 mostra a interface desenvolvida no ControlDesk para o controle das variáveis da bancada, e do modo remoto dedicado para os testes do controle especialista seja de forma

manual ou automática, desenvolvido para as simulações e experimentos. A interface pode visualizar cada um dos sinais adquiridos da bancada e parâmetros, os quais possibilitam um melhor entendimento do funcionamento do sistema em geral.

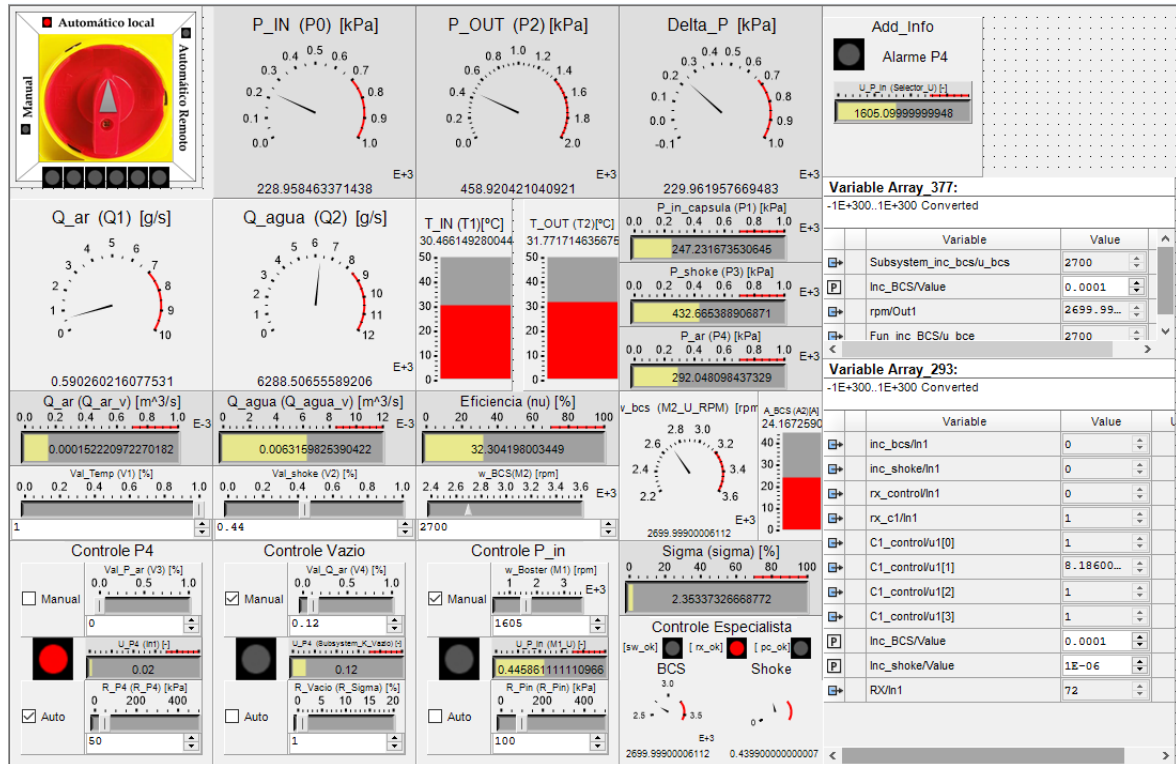


Figura A.4: Interface de usuário no ControlDesk

O programa implementado no Simulink do Matlab e embarcado no MicroAutobox II emprega quatro saídas DAC para controlar as válvulas e 2 PWM para gerar mais duas saídas analógicas empregando um conversor PWM a 0-5V que é mostrado na Figura A.5, cujo circuito conta com quatro conversores. O desenho do circuito é mostrado na Figura A.6.

O programa de simulação no MicroAutobox II emprega 12 canais ADC para receber os sinais dos sensores da bancada, cada um deles processados por seus respectivos condicionadores de sinal.

A partir dos dados adquiridos pelos sensores o programa calcula os seguintes parâmetros de desempenho da bomba; a pressão diferencial, a potência elétrica, a potência mecânica, a eficiência e a fração de vazio. O sistema também controla a pressão de admissão da bomba BCS, a pressão da linha de ar e a fração de vazio. É empregada uma porta serial para realizar a comunicação da MicroAutobox com o computador que executa o sistema especialista para controlar o ponto de operação do conjunto BCS.




Figura A.5: Conversor PWM a 5V




Figura A.6: Circuito conversor PWM a 5V

A.2 Estrutura Física da Bancada do LabVIP

O Laboratório de vibrações na área de petróleo, LabVIP, é um laboratório de pesquisa e desenvolvimento de técnicas para o monitoramento e controle das condições de operação das bombas empregadas no bombeio centrifugo submerso, mediante dados experimentais coletados diretamente do sistema, vinculado ao departamento de Engenharia Mecânica da UNICAMP.

O laboratório conta com uma bancada basculante (ver Figura A.7) para testar conjuntos BCS. O conjunto BCS conta com um sensor de fundo, motor, selo protetor e bomba, o qual está contido dentro de uma cápsula que permite simular a condição operacional da bomba como ocorre em um poço de petróleo. A cápsula foi projetada e construída pelo Centro de Pesquisas Leopoldo Américo Miguez de Mello -CENPES, o qual é o Centro de Pesquisa da Petrobras. A Figura A.8 mostra o desenho da cápsula. A bancada foi instrumentada para operar com escoamento multifásico ar-água em diferentes frações.

Para simular a parte gasosa da mistura, foi adicionada uma linha para injeção de ar através de um filtro e duas válvulas de controle, uma para controlar a pressão do ar na entrada do medidor de vazão e outra para controlar a vazão de gás na BCS. Para se garantir que todo o fluxo mássico que esta entrando na bomba está sendo corretamente medido pelo medidor de vazão, foi fabricado um injetor (ver Figura A.9 e Figura A.10) que permite injetar o ar o mais



Figura A.7: Bancada basculante do LabVIP




Figura A.8: Desenho da capsula com o conjunto BCS

próximo possível da sucção da bomba.



Figura A.9: Injetor de ar fabricado para injeção de ar próximo ao *intake* da bomba



Figura A.10: Injetor de ar instalado na bomba BCS

A.3 Procedimentos Operacionais para o Conjunto de BCS do LabVIP

O conjunto BCS do LabVIP está composto por uma bomba modelo P43 de 9 estágios da série 400 fabricada pela Baker Hugnes. A Figura A.11 apresenta as curvas de desempenho da bomba para várias rotações operando com água. A Figura A.12 apresenta as curvas de desempenho da bomba operando com água à rotação de 3500 rpm.




Figura A.11: Curva de desempenho da bomba P43 para várias rotações

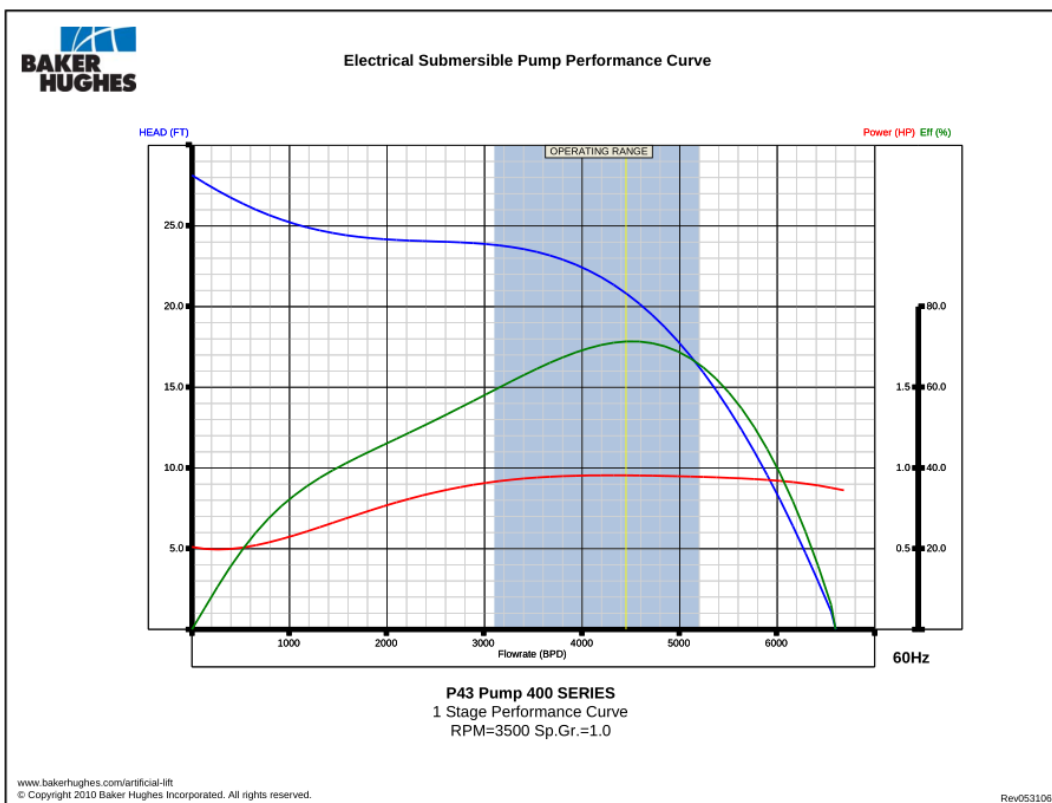


Figura A.12: Curvas de desempenho da bomba P43

A.3.1 Procedimentos de Operação do Conjunto BCS utilizados LabVIP

A.3.1.1 Partida

1. Verificar que as válvulas manuais entre a bomba *booster* e a injeção de líquido estejam completamente abertas.
2. Verificar que a linha de ar esteja com uma pressão mínima de 8 bar.
3. Fechar válvula de controle da fração de vazio.
4. Posicionar a abertura da válvula choke em 45% aberta no IHM.
5. Posicionar a rotação da *booster* em 1000 rpm no IHM e dar partida da bomba *booster* em modo remoto.
6. Dar partida no conjunto BCS no modo remoto (com inversor de frequência acelerando o motor de 0 a 2400 rpm em 30 s).
7. Estabelecer a vazão em $Q_{BEP} = 5442\text{g/s}$ ajustando-a operando a válvula choke.
8. Verificar se a pressão diferencial $\Delta P \approx 246\text{kPa}$ se a capsula estiver na horizontal, na vertical uma perda de carga adicional de $\approx 100\text{kPa}$. Se estiver muito baixa, aproximadamente um 60% do valor especificado, a bomba pode estar operando com o sentido de giro invertido, nesse caso desligar e corrigir.
9. Manter a pressão na sucção sempre acima de 100kPa .

A.3.1.2 Parada

1. Mudar o ponto de operação até atingir o ponto de BEP ($Q_{BEP} = 5442\text{g/s}$), na rotação de 2400 rpm.
2. Desligar o BCS em rampa (2400 a 0 rpm em 30 s, o que já deve estar programado no inversor de frequência da BCS).
3. Desligar a bomba *booster*.

A.3.1.3 Limitações de Operação do Conjunto BCS no LabVIP

Para manter o equipamento operando adequadamente sem reduzir sua vida útil, é necessário ter em conta as seguintes limitações:

1. A taxa máxima de variação na rotação da bomba BCS é $\Delta_{rpm} = 1\text{rpm/s}$.
2. A taxa máxima de variação na abertura da válvula choke é $\Delta_{choke} = 0.01\%/s$.

3. Os ajustes na rotação da bomba *booster* tem que ser lentamente ajustados.
4. A injeção de ar na cápsula deve ser feita gradual e lentamente, garantindo que a bomba BCS não trabalhe em vazio.
5. Verificar continuamente que a injeção de ar requerido na cápsula não gere quedas de pressão nas linhas de ar do laboratório abaixo de 400 kPa, pois pressões inferiores podem causar falha de funcionamento das válvulas de controle pneumáticas.
6. Verificar continuamente a pressão da linha de ar que alimenta a cápsula esteja pelo menos 50kPa acima da pressa de admissão da bomba BCS para evitar entrada de água na linha de ar.
7. O conjunto BCS está limitado a realizar 20 partidas, quando esse número for atingido, é necessário fazer uma manutenção no equipamento.

Durante o levantamento das curvas de desempenho do equipamento o conjunto apresentou fortes oscilações na vazão, na pressão na descarga da bomba e na corrente no motor quando estava operando com mistura bifásica (frações de vazio acima de 2%) em baixas vazões de líquido. As Figuras A.13, A.14 e A.15 mostra esse comportamento, o qual pode causar boqueio de gás na sucção da bomba. Sendo que este comportamento impossibilita a operação no ponto de pressão máxima das curvas bifásicas em extitsurging.




Figura A.13: Oscilações na vazões de saída da BCS.




Figura A.14: Oscilações na pressão de saída da BCS.




Figura A.15: Oscilações na corrente de saída da BCS.

ANEXO B – ALGORITMOS GENÉTICOS PARA OPTIMIZAÇÃO DOS HIPERPARÂMETROS DA SVM

A seleção dos hiperparâmetros (C, σ^2 e ϵ) é parte crucial dos algoritmos de SVMr, porque destes parâmetros dependem a efetividade do algoritmo (YU *et al.*, 2009). Essa seleção pode ser feita de forma automática mediante algoritmos genéticos (AG).

A metodologia empregada para otimizar os hiperparâmetros segue a teoria apresentada na seção 2.6 do Capítulo 2.

Para a representação dos indivíduos artificiais, os indivíduos artificiais contêm três características (C, σ^2 e ϵ), onde o genótipo de cada indivíduo está dado em números binários como é mostrado na Figura B.1.




Figura B.1: Representação do genótipo de cada indivíduo artificial.

O mecanismo de seleção empregado é o método da roleta, o qual emprega como função *fitness* o erro de validação, empregado para realizar a regulação dos modelos SVMr (ver seção 3.2).

Os operadores genéticos selecionados são o *crossover* simples e a mutação simples expostas na seção 2.6 do Capítulo 2.

Os parâmetros do algoritmo genético para obter cada um dos modelos são apresentados na Tabela B.1

Tabela B.1: Condições iniciais do AG

| Parâmetro | Valor |
|---|-------|
| Tamanho da população a_i | 200 |
| Probabilidade de mutação p_M | 0.2 |
| Probabilidade de cruzamento p_c | 0.5 |
| Número de genes por características n_g | 10 |
| Gerações g | 1000 |

ANEXO C – AQUISIÇÃO DE DADOS BOMBA BCS P43

Para adquirir os dados do sistema foi empregado um programa no Simulink do Matlab, em que os dados são adquiridos através de uma porta serial da MicroAutobox II. O programa coleta dados com um tempo de amostragem de 0.1s. O programa armazena os dados numa variável por um tempo predefinido pelo usuário e posteriormente o valor médio calculado é guardado num arquivo .txt. Os dados armazenados são:

- Rotação do eixo da BCS ω_{BCS} ;
- Pressão na sucção da bomba BCS P_{in} ;
- Pressão na descarga da bomba BCS P_{out} ;
- Temperatura na sucção da bomba BCS T_{in} ;
- Temperatura na descarga da bomba BCS T_{out} ;
- Vazão mássica de ar G_g ;
- Vazão mássica de líquido G_l ;
- Vazão volumétrica de ar Q_g ;
- Vazão volumétrica líquido Q_l ;
- Corrente no motor da BCS A_{BCS} ; e,
- Fração de vazão α .

Cada ponto da curva é obtido empregando a interface de usuário (IHM) mostrada na Figura C.1, a qual permite guardar os pontos e simultaneamente apresenta os pontos adquiridos na base de dados atual.




Figura C.1: IHM para aquisição de dados da bomba BCS P43