



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

Fábio Mendes Soares

***Aplicação de Sensores Virtuais na Inferência da Temperatura de
Banho no processo de fabricação de Alumínio primário***

**Belém
2009**

Fábio Mendes Soares

***Aplicação de Sensores Virtuais na Inferência da Temperatura de
banho no processo de fabricação de Alumínio primário***

Dissertação de Mestrado apresentada como requisito para obtenção do título de Mestre em Engenharia Elétrica pela Faculdade de Engenharia da Computação da Universidade Federal do Pará através do Programa de Pós-Graduação em Engenharia Elétrica.

Orientador: Prof. Dr. Roberto Célio Limão de Oliveira

**Belém
2009**

S676a Soares, Fábio Mendes

Aplicação de sensores virtuais na inferência da temperatura de banho no processo de fabricação de alumínio primário / Fábio Mendes Soares; orientador, Roberto Célio Limão de Oliveira.-2009

Dissertação (Mestrado) - Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2009.

1. Inteligência computacional. 2. Processos químicos – modelos matemáticos. 3. Controle de processo I. Orientador. II.Título.

CDD - 22 ed. 006.32

***Aplicação de Sensores Virtuais na Inferência da temperatura de
banho no processo de fabricação de Alumínio primário***

Este trabalho foi julgado em 14 / 12 / 2010 adequado para a obtenção do grau de Mestre em Engenharia Elétrica, e aprovado na sua forma final pela banca examinadora.

Prof. Dr. Roberto Célio Limão de Oliveira (Orientador)
Programa de Pós Graduação em Engenharia Elétrica
Universidade Federal do Pará

Prof. Dr. Antônio Morais da Silveira
Programa de Pós Graduação em Ciência da Computação
Universidade Federal do Pará

Profa. Dra. Adriana Rosa Garcez Castro
Programa de Pós Graduação em Engenharia Elétrica
Universidade Federal do Pará

Prof. Dr. Marcus Vinícius Alves Nunes
Coordenador do Programa de Pós Graduação em
Engenharia Elétrica
Universidade Federal do Pará

Belém

2009

“O Fracasso é a oportunidade de começar de novo inteligentemente.”

Henry Ford, 1888
Empreendedor Estadunidense

AGRADECIMENTOS

Agradeço Aquele que é responsável por minha existência (Deus) e àqueles que são responsáveis pela minha criação que são meus pais Josafá e Maria Alice, que tanto lutaram para me proporcionar uma boa educação! Agradeço ainda a minha tia Nice, meu irmão Flávio, minhas primas e primos Ana Paula, Eliane, André e Adriano que me acompanharam esses longos anos e de certa forma contribuíram para a formação de meu caráter. Agradeço à Jany Kelly, minha namorada, por ter me acompanhado e incentivado na busca de meus objetivos e realização dos meus sonhos.

Agradeço também aos colegas que conheci durante o projeto na Empresa, especialmente ao Marcos Vinícius, Vanilson Gomes, Marcos Castro e Vanderlei Fernandes, que me ajudaram bastante nesse trabalho.

Ao Prof. Roberto Limão, pela orientação e atenção dada a enriquecer e melhorar a qualidade do trabalho.

A meus amigos da Exodus, Harry Cruz, Thiago Moutinho, Ítalo Flexa, Hevertton Kikuchi, Olavo Neto e Éder Rodrigues que sempre me apoiaram na realização dos meus trabalhos com suporte e ajuda na tomada de decisões importantes.

A Universidade Federal do Pará, pela oportunidade oferecida a mim para obter este mestrado, além do apoio dado pelo corpo docente que forneceu o que tinha melhor conteúdo para seus alunos

A comunidade acadêmica internacional que anualmente publica milhares de trabalhos, sem os quais, muito do que aqui está escrito não poderia ser desenvolvido.

LISTA DE ILUSTRAÇÕES E TABELAS

Figura 2.1 Alumínio Puro	8
Figura 2.2 Bauxita - Composto de Alumínio e outros Elementos	8
Figura 2.3 Sequência de ionização da eletrólise	9
Figura 2.4 Cadeia de Produção do Alumínio.....	9
Figura 2.5 Evolução da produção de alumínio no século XX	11
Figura 2.6 Corte transversal de um forno eletrolítico.....	12
Figura 2.7 Elementos Constituintes de um Forno Eletrolítico	12
Figura 2.8 Linha de redução típica.....	13
Figura 2.9 Representação esquemática anodo catodo	14
Figura 2.10 Anodo	14
Figura 2.11 Bloco Catódico.....	14
Figura 2.12 Disposição de fornos em uma sala de redução. (a) tecnologia End-to-End (b) tecnologia side-by-side	16
Figura 2.13 Distância anodo-catodo	16
Figura 2.14 Diagrama esquemático do sistema de controle de Resistência.....	17
Figura 2.15 Anodo Alto	18
Figura 2.16 Anodo Baixo	18
Figura 2.17 Diagrama do processo de química de banho	19
Figura 2.18 Consumo teórico de alumina com o passar do tempo e tipo de alimentação	20
Figura 2.19 Máquina Troca Anodo.....	20
Figura 2.20 Cadinho fazendo sifonamento.....	21
Figura 2.21 Fornos de Redução Cadinho retirando metal durante Corrida	21
Figura 2.22 Termopares utilizados para medição de Temperatura	21
Figura 2.23 Diagrama da infraestrutura de TI e Automação de uma Planta.....	22
Figura 2.24 Grafico mostrando a oscilação de temperatura (em vermelho)	23
Figura 2.25 Variações espaciais de temperatura em um forno	23

Figura 3.1 Diagrama do princípio do sensor virtual	25
Figura 3.2 Processo de Projeto do sensor virtual.....	29
Figura 3.3 Gráfico de Correlação Linear	30
Figura 3.4 Gráfico de Correlação Cruzada.....	30
Figura 3.5 Dados outliers.....	31
Figura 3.6 Distribuição normal dos dados.....	31
Figura 3.7 Gráfico de Correlação entre os pontos das variáveis X e Y, reagrupadas nas componentes principais P1 e P2.....	33
Figura 3.8 Mesmo gráfico, porém com eixos orientados aos coeficientes de correlação mostrando que a componente principal p2 pode ser representada por p1 que possui melhor qualidade de informação.....	33
Figura 3.9 Gráfico de Correlação entre duas variáveis. Nota-se a presença de outliers.	34
Figura 3.10 Representação do modelo de sistema	35
Figura 3.11 Representação modelo não linear com atraso	36
Figura 3.12 Gráfico mostrando a não generalização da Rede para dados que não foram treinados.....	38
Figura 3.13 Gráfico mostrando que o erro das medições está alto.	39
Figura 3.14 Gráfico contendo dados não previstos fora da faixa normal.....	39
Figura 4.1 Neurônio Artificial.....	42
Figura 4.2 Rede monocamada.....	44
Figura 4.3 Topologia de redes neurais multicamadas	45
Figura 4.4 Rede Recorrente monocamada	45
Figura 4.5 Rede Recorrente multicamada.....	46
Figura 4.6 Rede de Elman	46
Figura 4.7 Rede de Hopfield	46
Figura 4.8 Representação Esquemática de um Aprendizado.....	47
Figura 4.9 Aprendizado supervisionado	48
Figura 4.10 Retropropagação do erro.....	49
Figura 4.11 Mínimo local.....	50

Figura 4.12 Queda rápida do erro	51
Figura 4.13 Visualização do Efeito dos Mapas Auto organizadores Kohonen	53
Figura 4.14 Rede com Funções de Base Radial (Radial Basis Function).....	53
Figura 4.15 Função de Base Radial.....	54
Figura 4.16 Sequencia de passos do projeto de Rede Neural	55
Figura 5.1 Representação do Layout de uma Redução da Empresa	57
Figura 5.2 Cadeia produtiva de Alumínio interna da Empresa	58
Figura 5.3 Turnos de Operação da Empresa	59
Figura 5.4 Diagrama da Infraestrutura de controle e automação da Empresa	60
Figura 5.5 Representação Esquemática da Inferência de Temperatura atual através de dados atuais disponíveis no sistema de controle e dados passados (últimas medidas de temperatura e outras variáveis que não estão disponíveis online).	63
Figura 5.6 Representação esquemática da simulação da química de banho através do sensor virtual. Com base em dados atuais e passados, o algoritmo simula o próximo valor de temperatura de acordo com a decisão de quanto adicionar no forno.	64
Figura 5.7 Estrutura externa dos dois sensores a serem desenvolvidos	65
Figura 5.8 Estrutura externa dos sistemas em malha fechada.....	66
Figura 5.9Gráfico de Correlação Cruzada das variáveis do controle de resistência com a Temperatura dos Fornos	70
Figura 5.10 Gráfico de Correlação Cruzada das Variáveis do Controle de Alimentação de Alumina com a Temperatura de Banho dos Fornos	71
Figura 5.11 Gráfico de Correlação Cruzada das Variáveis de Miscelânea com Temperatura	71
Figura 5.12 Gráfico de Correlação das Demais Variáveis com a Temperatura de Banho	72
Figura 5.13 Correlação das variáveis VMR e RMR com TMP	74
Figura 5.14 Correlação de A%1 e TUN com TMP	74
Figura 5.15 Correlação de ALF e TMP com TMP	74
Figura 5.16 Correlação ALF3A e TMPLiq com TMP	74
Figura 5.17 Correlação QALr e IncTM com TMP	75
Figura 5.18 Correlação de %TUN e %TOV com TMP.....	75

Figura 5.19 Gráfico mostrando a relação que existe entre TUN e %TUN	76
Figura 5.20 Gráfico indicando a forte relação que a QALr possui com a alimentação.....	77
Figura 5.21 Histograma VMR.....	80
Figura 5.22 Histograma da Variável de Resistência.....	81
Figura 5.23 Histograma IncTM.....	81
Figura 5.24 Histograma %TUN	81
Figura 5.25 Histograma %TOV	82
Figura 5.26 Histograma QALr	82
Figura 5.27 Histograma da variável Alimentação Instantânea (A%1).....	82
Figura 5.28Histograma da variável de Temperatura (TMP).....	83
Figura 5.29 Histograma da variável Percentual de Fluoreto (ALF).....	83
Figura 5.30 Histograma Adição de Fluoreto.....	84
Figura 5.31 Gráfico mostrando a Lacuna causada pela filtragem dos pontos fora da faixa. .	86
Figura 5.32 Layout da Planta da Redução II, com Fornos Selecionados no Período I marcados com pontos verdes	87
Figura 5.33 Layout da Planta da Redução IV com fornos selecionados no período I marcados com pontos verdes	87
Figura 5.34 Layout da Planta da Redução II com fornos selecionados no período II marcados com pontos verdes	88
Figura 5.35 Layout da Redução IV com fornos selecionados no período II marcados com pontos verdes	88
Figura 5.36 Estrutura do Sensor Virtual de Temperatura com as Variáveis de entrada definidas.	90
Figura 5.37 Estrutura do Simulador do Balanço Térmico	90
Figura 5.38 Representação gráfica da normalização min-max em uma variável.....	92
Figura 5.39 Estrutura de Backup do Sensor Virtual	94
Figura 5.40 Estrutura do Sensor Virtual com a Rede Neural Artificial integrada.....	94
Figura 5.41 Representação esquemática completa do simulador de balanço térmico	95

Figura 5.42 Representação de dados manipulados pelo Matlab, na forma de arquivos texto	97
Figura 5.43 Diagrama Interligação do Sensor virtual com a Rede Corporativa como provedor de serviços	97
Figura 6.1 Layout Losangular	99
Figura 6.2 Layout Triangular	99
Figura 6.3 Gráfico de Treinamento do Sensor Virtual Backup I no Forno 126 (Red. II) após Treinamento Parcial T1, T2 e T3	101
Figura 6.4 Gráfico de Treinamento do Sensor Virtual de Backup I no Forno 132 (red. II) após treinamento parcial T1,T2 e T3	102
Figura 6.5 Gráfico do Treinamento do Sensor Virtual de Backup I Forno 248 (red. II) após treinamento parcial T1, T2 e T3	102
Figura 6.6 Gráfico Testes do Sensor Virtual de Backup I no Forno 131 (red. II) após Treinamento T1, T2 e T3.	103
Figura 6.7 Gráfico de Testes do Sensor Virtual de Backup I no forno 338 (Red. II) após Treinamento parcial T1, T2 e T3.....	103
Figura 6.8 Gráfico de Testes do Sensor Virtual de Backup I no forno 148 (Red. IV) após treinamento parcial T1,T2 e T3	104
Figura 6.9 Gráfico de Dispersão dos Registros de Treinamento	104
Figura 6.10 Gráfico de Dispersão dos Registros de Testes Sensor Virtual de Backup 1....	104
Figura 6.11 Resultado do Treinamento do Sensor Virtual Backup II para forno 201 (Red.II) após treinamento parcial.....	105
Figura 6.12 Resultado do Treinamento do Sensor Virtual Backup II para forno 242 (Red. IV) após treinamento parcial.....	106
Figura 6.13 Resultado dos Testes do Sensor Virtual Backup II para o forno 226 (Red. II) .	106
Figura 6.14 Resultado dos Testes do Sensor Virtual de Backup II para forno 339 (Red. II)	107
Figura 6.15 Dispersão dos Registros de Treinamento Sens. Virt. Backup II	107
Figura 6.16 Dispersão dos Registros de Testes do Sens. Virt. Backup II.....	108
Figura 6.17 Resultados do Treinamento Parcial do Sensor Virtual de Backup III para o Forno 331 (Red.II).....	109

Figura 6.18 Resultados do Treinamento parcial do Sensor Virtual de Backup III para forno 445 (Red.IV)	109
Figura 6.19 Resultados dos Testes do Sensor Virtual de Backup III para forno 315 (Red. II)	110
Figura 6.20 Resultados dos Testes do Sensor Virtual de Backup III para forno 349 (Red. II)	110
Figura 6.21 Dispersão dos registros de treinamento parcial.....	111
Figura 6.22 Dispersão dos registros de testes do sensor virtual backup III.	111
Figura 6.23 Resultado do Treinamento Redes Neurais Sensor Virtual Principal Forno 132 (Red.II)	112
Figura 6.24 Resultados Treinamento Sensor Virtual Principal Forno 133 (Red.II).....	113
Figura 6.25 Resultado dos Testes Sensor Virtual Principal para Forno 132 (Red.II)	113
Figura 6.26 Resultados dos Testes do Sensor Virtual Principal para Forno 133 (Red.II) ...	114
Figura 6.27 Dispersão dos Registros de Treinamento do Sensor Virtual Principal.....	114
Figura 6.28 Dispersão dos Pontos de Testes do Sensor Virtual Principal	115
Figura 6.29 Testes do Sensor Virtual com Backup no Forno 132 (Red.II).....	116
Figura 6.30 Testes do Sensor Virtual com Backup no Forno 133 (Red.II).....	116
Figura 6.31 Dispersão dos Registros de Testes com Backup	117
Figura 6.32 Resultado do Treinamento do Simulador Térmico Forno 136 (Red.II).....	118
Figura 6.33 Resultado do Treinamento do Simulador de Balanço Térmico – forno 213 (Red.II)	119
Figura 6.34 Teste Simulador de Balanço Térmico – Forno 351 (Red. IV)	119
Figura 6.35 Teste Simulador Térmico Forno 352 Red.IV	120
Figura 6.36 Gráfico de Dispersão dos Registros de Treinamento	120
Figura 6.37 Gráfico de Dispersão dos Registros de Testes	120
Figura 6.38 Validação do Sensor Virtual no Forno 204 (Red.II). Erro MSE 14,91. Caso Comum.	121
Figura 6.39 Validação do Sensor Virtual no Forno 201 (Red. II). Erro MSE 8,24. Caso ótimo.	122
Figura 6.40 Validação Sensor Virtual no Forno 252 (Red.II), Erro MSE: 22,45. Caso ruim.	122

Figura 6.41 Gráfico de Dispersão dos registros de validação do sensor virtual.....	123
Figura 6.42 Resultados do Sensor Virtual com realimentação – Forno 208 (Red.II). Erro MSE: 28,36.....	123
Figura 6.43 Resultados do Sensor Virtual com realimentação – Forno 134 (Red.II). Erro MSE: 33,15.....	124
Figura 6.44 Dispersão dos Registros de Validação com realimentação.....	124
Figura 6.45 Validação Sensor Virtual com Backup Forno 231 (Red. IV). Erro MSE: 5,45. .	125
Figura 6.46 Validação Sensor Virtual com Backup Forno 136 (Red.II). Erro MSE: 3,28.....	126
Figura 6.47 Resultado de Validação do Sensor Virtual para Forno 252 (Red.IV). Erro MSE: 6,29.	126
Figura 6.48 Dispersão dos Registros de Validação do Sensor Virtual com Backup	127
Figura 6.49 Validação do Sensor Virtual com Realimentação Forno 134 (Red.II). Erro: 21,77.	127
Figura 6.50 Validação do Simulador Térmico Forno 113 (Red.IV). Erro MSE: 12,25 (sem realimentação), 26,87 (com realimentação)	128
Figura 6.51 Validação do Simulador de Balanço Térmico Forno 441 (Red.II). Erro MSE: 15,43 (sem realimentação); 45,88 (com realimentação)	128
Figura 6.52 Dispersão dos Registros de validação do Simulador de Balanço Térmico sem realimentação	129
Figura 6.53 Dispersão dos Registros de Validação do Simulador de Balanço Térmico com realimentação	129
Figura 6.54 Validação do Simulador Térmico com realimentações e medidas a cada 64 e 96 horas, forno 113 (Red.IV). Erro MSE: 14,52 (Realim. 64h), 14,59 (Realim. 96h).	130
Figura 6.55 Validação do Simulador Térmico com realimentações e medidas a cada 64 e 96 horas, forno 441 (Red.II). Erro MSE: 11,8 (Realim. 64h), 12,99 (Realim. 96h).....	130
Figura 6.56 Erro espúrio ocorrido na simulação do Balanço Térmico	135
Figura 6.57 Principais erros espúrios ocorridos no Sensor virtual.....	135
Figura 6.58 Variações muito bruscas na temperatura real do forno 132 (Red.II).....	137
Figura 6.59 Erro sistêmico ocorrido no simulador de balanço térmico para forno 347 (Red.II)	138
Figura 6.60 Testes de Validação do Sensor Virtual com retreino forno 244 (Red.II)	139

Figura 6.61 Validação Sensor Virtual após retreino – forno 252 (Red.II).....	139
Figura 6.62 Validação do Sensor Virtual após retreino forno 252 (Red.IV)	140
Figura 6.63 Dispersão de Registros do Sensor Virtual após retreino	140
Figura 6.64 Validação do Simulador Térmico após retreino por seção - Forno 351 (Red.IV)	141
Figura 6.65 Validação do Simulador Térmico após Retreino – Forno 441 (Red.II).....	142
Figura 6.66 Dispersão dos Registros do Simulador Térmico com retreino.	142
Figura 6.67 Validação do Simulador Térmico após retreino com realimentação 96h Forno 352 (red.IV).....	143
Figura 6.68 Validação do Simulador Térmico após Retreino com realimentação 96h Forno 441 (red.II).....	143
Figura 6.69 Dispersão dos Registros do Simulador Térmico com realimentação 96h e retreino	144
Figura A 1 Resumo do Procedimento de medida de Temperatura.....	153
Figura A 2 Layout dos Anodos na cuba	153
Tabela 1-1. Metodologia do Trabalho	6
Tabela 2-1 As vinte maiores fábricas de alumínio no mundo [Fonte: World Aluminium, 2007]	10
Tabela 2-2 Os 10 maiores países produtores de alumínio no mundo. [Fonte: World Aluminium, 2007].....	11
Tabela 2-3 Composição química normal desejável dos fornos	13
Tabela 2-4 Lista de variáveis com seus respectivos valores ideais de operação	15
Tabela 2-5 Variáveis no Controle de Resistência do Forno	17
Tabela 2-6 Variáveis envolvidas na química de banho	19
Tabela 4-1 Funções de Ativação comuns	43
Tabela 5-1. Áreas da Empresa	57
Tabela 5-2 Variáveis do Sistema Score	61

Tabela 5-3 Algumas das variáveis mantidas pelo sistema Sisred	62
Tabela 5-4 Variáveis, que, segundo a equipe de processo, possuem alguma influência no balanço térmico	66
Tabela 5-5 Médias diárias dos dados do Score armazenados na base de dados do Sisred	67
Tabela 5-6 Dados do Sisred cadastrados em pontos temporais específicos.....	68
Tabela 5-7 Ajuste feito nas variáveis do Score para compor uma base única.....	68
Tabela 5-8 Tabela das variáveis com seus respectivos coeficientes de correlação	73
Tabela 5-9 Tabela de desvio padrão das Correlações	76
Tabela 5-10 Variáveis de Entrada do modelo. A variável ALF[k-1] utilizada é produzida por um sistema de inferência de fluoreto desenvolvido por Frost e Karri.	78
Tabela 5-11 Quantidade de Registros Pesquisada	78
Tabela 5-12 Limites Operacionais das Variáveis	79
Tabela 5-13 Valores Mínimos, Máximos, Médios e Desvios Padrão das Variáveis	80
Tabela 5-14 Tabela novos limites para as variáveis, após filtragem 3 sigma	84
Tabela 5-15 Ajuste feito nos limites das variáveis %TUN, TMP e ALF.....	85
Tabela 5-16 Quantidade de Registros por Redução e período	85
Tabela 5-17 Quantidade fornos cujos registros estão totalmente dentro da faixa operacional	87
Tabela 5-18 Quantidade de registros por redução e período após a filtragem de fornos	89
Tabela 5-19 Distribuição dos Registros e Fornos utilizados para Testes e Validação	89
Tabela 5-20 Parametros de Treinamento utilizados para as Redes Neurais do Modelo	92
Tabela 5-21 Infraestrutura de TI da Empresa	96
Tabela 6-1 Configurações das Redes utilizadas com melhor desempenho	101
Tabela 6-2 Erros MSE das Redes após treinamento parcial	101
Tabela 6-3 Configuração das Redes usadas como backup II	105
Tabela 6-4 Erros MS das redes após treinamento parcial.....	105
Tabela 6-5 Configuração das Redes Neurais usadas para Sens. Virtual Backup III	108
Tabela 6-6 Erro MSE das Redes após treinamento parcial.....	108
Tabela 6-7 Configurações das Redes Neurais Utilizadas para o Sensor Principal.....	112

Tabela 6-8 Erro MSE e número de épocas de treinamento em cada uma das redes.....	112
Tabela 6-9 Erro MSE das Redes simuladas com Backup	115
Tabela 6-10 Configuração das Redes Neurais usadas para o simulador de Balanço Térmico	117
Tabela 6-11 Erro MSE das Redes Neurais do Simulador de Balanço Térmico	118
Tabela 6-12 Alguns registros do Sensor virtual com estimação errada.....	131
Tabela 6-13 Alguns Registros do Simulador Balanço Térmico com estimação errada. Em destaque os registros em que a estimação errada foi dada sem realimentação.	132
Tabela 6-14 Configuração das Redes Neurais utilizadas para retreino.....	133
Tabela 6-15 Resultado do retreinamento das redes apresentadas	133
Tabela 6-16 Alguns registros de testes nos fornos treinados	133
Tabela 6-17 Resultado dos testes para outros fornos.....	134
Tabela 6-18 Alguns registros de erros espúrios com entradas similares.....	135
Tabela 6-19 Faixa de variáveis escolhida para consultar comportamento da temperatura	136
Tabela 6-20 Freqüência de ocorrência de erros espúrios para as entradas similares.....	136
Tabela 6-21 Erro MSE geral do sensor virtual por seção.	141
Tabela 6-22 Erro MSE dos Simuladores Térmicos.....	144

GLOSSÁRIO

Aditivo Químico	Sais preparados especialmente para auxiliar no processo de Fabricação de Alumínio Primário
Algoritmo de Treinamento	Método matemático utilizado para encontrar parâmetros ótimos que reproduzam um determinado conjunto de saídas a partir de entradas. Ver também Treinamento .
Alimentação	Procedimento de adição de alumina nos Fornos Eletrolíticos.
Alumina	Principal Insumo na produção de alumínio. Também conhecida como Óxido de Alumínio, é extraída a partir da Bauxita.
Alumínio Primário	Alumínio na sua forma mais pura, podendo ser adaptado por outras indústrias para diversas finalidades.
Anodo	Extremidade positiva de um meio eletrólito, na qual são depositadas partículas eletricamente negativas do processo. No processo de fabricação de alumínio primário, é representado por um bloco de coque e piche fabricados a partir de carbono.
Aprendizado	Procedimento pelo qual uma estrutura computacional inteligente realiza um “aprendizado” do meio o qual se deseja controlar ou supervisionar.
Balanço Térmico	Equilíbrio termodinâmico do forno eletrolítico para manter a temperatura estável próxima do desejado.
Banho Químico	Material utilizado como meio fundido durante a eletrólise da alumina, geralmente composto por criolita. Ver Criolita .
Bauxita	Matéria Prima da Alumina, uma das formas mais abundantes do alumínio na natureza.
Bias	Parâmetro que possui influência na saída de um neurônio, independente de suas entradas.
Cadinho	Repositório para armazenagem de metal líquido extraído dos fornos eletrolíticos

Camada	Estrutura de múltiplos neurônios que operam em paralelo com o mesmo conjunto de entradas, compartilhando mesmos atributos.
Catodo	Extremidade negativa do meio eletrólito, na qual se acumulam partículas eletricamente positivas.
Criolita	Material utilizado como meio fundido na eletrólise da alumina. Ver também Banho Químico.
Eficiência de Corrente	Medida da produção atual de corrente dividida pela produção real de corrente.
Eletrólise	Processo pelo qual uma molécula polarizada é separada através da passagem de corrente elétrica, necessitando de um meio fundente para ocorrer a reação.
Eletrólito	Meio no qual ocorre a Eletrólise
Estimação	Processo de cálculo de uma determinada grandeza indiretamente, com base em outras que possuam influência.
Filtragem de Dados	Técnica utilizada para retirar dados que possam conter ruídos ou informações incorretas sobre o processo.
Fluoreto de Alumínio	Principal aditivo químico utilizado para manutenção do balanço térmico.
Forno Eletrolítico	Estruturas especialmente preparadas para receber os elementos que compõem eletrólito e para permitir o processo de fabricação de alumínio.
Framework	Conjunto de programas, estruturas e procedimentos especialmente utilizados como auxiliares na construção de programas de computador complexos.
Função de Ativação	Função matemática com comportamento não linear utilizada para cálculo da saída dos neurônios, reproduzindo tal como acontece em neurônios reais.
Inferência	Mesmo que estimação .

Infraestrutura de TI e Automação	Conjunto de recursos usados para manter operante um processo de automação industrial.
Inteligência Computacional	Paradigma computacional no qual programas de computador desenvolvem facilidades de resolver problemas complexos de difícil modelagem matemática.
Linha	Conjunto de estruturas operacionais, que compartilham os mesmos recursos, e são operadas pela mesma equipe. Também conhecida Linha de Produção.
Linha de Redução	Linha de Produção de Alumínio que compartilha mesmos parâmetros, como alumina e corrente elétrica.
Lombo	Parte do Banho químico que se solidifica na lateral dos fornos eletrolíticos
Modelagem	Tentativa de reprodução de um processo de forma matemática e determinística.
Neurônio Artificial	Estrutura de processamento simples, que reproduzem o comportamento aproximado de neurônios reais, recebendo entradas e ativando saídas.
Oscilação	Medida do quanto um forno está variando em relação aos seus parâmetros de resistência e alimentação.
Outlier	Registros nos quais ao menos uma variável se encontra fora da faixa normal de operação.
Química de Banho	Subprocesso na fabricação de alumínio que consiste em manter a composição química do eletrólito estável.
Parque Tecnológico de TI e Automação	Área de Abrangência da Infraestrutura de TI de Automação .
Pesos	Conexões entre neurônios, que possuem habilidade de modificar as entradas dos mesmos, sendo considerados parâmetros da Rede Neural.

Pontos fora da Faixa	Mesmo que <i>outlier</i> .
Redes Neurais Artificiais	Estrutura Computacional dedicada para simular uma rede de neurônios, que a partir de certas entradas, reproduz saídas desejadas ou esperadas.
Regressores	Dados utilizados para identificação de parâmetros de um sistema.
Sensor Virtual	Programa computacional com a capacidade de estimar ou inferir alguma grandeza.
Setpoint	Valor alvo para uma determinada variável
Sifonamento	Procedimento de retirada do metal líquido dos fornos eletrolíticos
Sinapses	Conexões entre neurônios, que são estruturas que contem pesos.
Técnica de Inteligência Computacional	Abordagem prática da inteligência computacional na forma de algoritmos e programas de computador.
Termopar	Sensor de temperatura para faixas extremas.
Treinamento	Procedimento de aprendizagem de uma rede neural artificial.
Tratamento de Gases	Procedimento de reaproveitamento dos gases produzidos no processo de fabricação de alumínio primário.

LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

%ALF3	<i>Percentual de Fluoreto em Excesso no Banho Químico</i>
%AL2O3	<i>Percentual de Alumina em Excesso no Banho Químico</i>
%CAF2	<i>Percentual de Fluorita em Excesso no Banho Químico</i>
%Pur	<i>Pureza do Metal</i>
%TOV	<i>Percentual de tempo em alimentação Over</i>
%TUN	<i>Percentual de tempo em alimentação Under</i>
A%1	<i>Percentual de Alimentação Instantânea de Alumina</i>
AL2O3	<i>Alumina</i>
ALF/ALF3	<i>Fluoreto de Alumínio</i>
ALF3A	<i>Fluoreto Adicionado no Banho</i>
ATN 7.0	<i>Nó remoto da Rede de Automação da Redução</i>
CAF / CAF2	<i>Fluoreto de Cálcio (Fluorita)</i>
CAF2A	<i>Fluorita Adicionada no Banho</i>
CLP	<i>Controlador Lógico Programável</i>
DeltaR	<i>Delta de Resistência</i>
DeltaT	<i>Delta de Temperatura</i>
E[x]	<i>Esperança da Variável X</i>
EAN	<i>Efeito Anódico</i>
ECO	<i>Eficiência de Corrente</i>
EMF	<i>Tensão Efetiva de Reação</i>

ERP	<i>Enterprise Resource Planning (Sistema de Gestão Empresarial)</i>
f^{k-1}_i	<i>Função de ativação do neurônio i da camada $k-1$</i>
IM	<i>Corrente Elétrica de Linha Real</i>
IncOS	<i>Incremento de Resistência por Oscilação</i>
IncTM	<i>Incremento de Resistência por Temperatura</i>
IncTr	<i>Incremento de Resistência por Troca de Anodo</i>
LOI	<i>Perda na Ignição (Loss On Ignition)</i>
max_x	<i>Valor máximo da Variável X</i>
min_x	<i>Valor mínimo da Variável X</i>
NA2CO3	<i>Carbonato de Sódio (Barrilha)</i>
NA2CO3A	<i>Barrilha adicionada no Banho Químico</i>
NaN	<i>Valor não numérico (Not An Number)</i>
NBA	<i>Nível de Banho</i>
net^k_i	<i>Somatório das entradas ponderadas do neurônio i da camada k</i>
NME	<i>Nível de Metal</i>
NULL	<i>Valor nulo ou inexistente</i>
OPC	<i>Ole for Process Control (OLE para Controle de Processos)</i>
Prod	<i>Produção</i>
QALR	<i>Quantidade de Alumina alimentada</i>
QNX	<i>Sistema Operacional Variante do Linux</i>
RMR	<i>Resistência Real de Forno</i>
Score	<i>Sistema de Controle de Reduções</i>

Sisred	<i>Sistema de Supervisão de Reduções</i>
SWT	<i>Oscilação de Forno</i>
Tanh	<i>Tangente Hiperbólica</i>
TEA	<i>Tempo de Efeito Anódico</i>
TI	<i>Tecnologia da Informação</i>
TMP	<i>Temperatura dos Fornos</i>
TMPLiq	<i>Temperatura de Líquidos</i>
TOV	<i>Tempo de alimentação Over</i>
TUN	<i>Tempo de alimentação Under</i>
uOhm	<i>Micro Ohm (unidade de Resistência)</i>
VIDA	<i>Tempo de Operação de Forno</i>
VMR	<i>Tensão Real de Forno</i>
w_{ij}^k	<i>Peso que conecta a entrada i da camada k ao neurônio j</i>
x_i^k	<i>Entrada i da camada k</i>
σ_x	<i>Desvio Padrão da Variável X</i>
σ_j^k	<i>Retropropagação do erro do neurônio j da camada k</i>

SUMÁRIO

AGRADECIMENTOS	6
LISTA DE ILUSTRAÇÕES E TABELAS	7
ABSTRACT	2
1. INTRODUÇÃO	3
1.1. APRESENTAÇÃO DO CENÁRIO	3
1.2. OBJETIVOS E JUSTIFICATIVA	4
1.3. METODOLOGIA E ESTRUTURA DO TRABALHO	5
2. PROCESSO DE FABRICAÇÃO DE ALUMÍNIO PRIMÁRIO	8
2.1. O PROCESSO HALL HÉROULT	9
2.1.1. FORNO ELETROLÍTICO	11
2.1.2. BANHO ELETROLÍTICO	13
2.1.3. ADITIVOS QUÍMICOS UTILIZADOS	13
2.1.4. ANODO E CATODO	13
2.2. ESTRATÉGIAS DE CONTROLE	14
2.2.1. CONTROLE DE RESISTÊNCIA DOS FORNOS	16
2.2.2. QUÍMICA DE BANHO	18
2.2.3. CONTROLE DA ALIMENTAÇÃO DE ALUMINA	19
2.2.4. INSTRUMENTAÇÃO E AUTOMAÇÃO	20
2.3. PROBLEMAS ENFRENTADOS	22
2.3.1. VARIAÇÕES DE TEMPERATURA E MEDIÇÃO	23
2.4. CONSIDERAÇÕES FINAIS	24
3. USO DE SENSORES VIRTUAIS NA INDÚSTRIA	25
3.1. APLICAÇÕES	26
3.1.1. INDÚSTRIA QUÍMICA	27
3.2. PROJETO DE SENSOR VIRTUAL	27

3.2.1. MODELAGEM FÍSICA (CAIXA BRANCA)	28
3.2.2. MODELAGEM BASEADA EM INTELIGÊNCIA ARTIFICIAL (CAIXA PRETA) 28	
3.2.3. MODELAGEM HÍBRIDA (CAIXA CINZA)	28
3.2.4. COLETA DE DADOS DE PLANTA	29
3.2.5. ESCOLHA DA ESTRUTURA DO MODELO	35
3.2.6. VALIDAÇÃO DO MODELO	37
3.2.7. VALIDAÇÃO DO SENSOR VIRTUAL	38
3.2.8. AJUSTES E MELHORAMENTOS	38
3.3. IMPLEMENTAÇÃO E INTEGRAÇÃO DE SENSORES VIRTUAIS COM APLICAÇÕES 40	
3.3.1. MEMÓRIA	40
3.3.2. LINGUAGEM DE PROGRAMAÇÃO	40
3.3.3. PADRONIZAÇÕES.....	41
3.3.4. CONTEXTO DA APLICAÇÃO	41
3.3.5. TOLERÂNCIA A FALHAS.....	41
3.4. CONSIDERAÇÕES FINAIS.....	41
4. REDES NEURAIS ARTIFICIAIS	42
4.1. CARACTERÍSTICAS	42
4.2. ARQUITETURAS.....	43
4.2.1. REDES <i>FEEDFORWARD</i> MONOCAMADAS	44
4.2.2. REDES <i>FEEDFORWARD</i> MULTICAMADAS	44
4.2.3. REDES RECORRENTES.....	45
4.3. APRENDIZADO.....	47
4.3.1. APRENDIZADO SUPERVISIONADO	48
4.3.2. APRENDIZADO NÃO-SUPERVISIONADO	52
4.4. PROJETO DE REDE NEURAL.....	54
4.5. CONSIDERAÇÕES FINAIS.....	55

5.	PROJETO DO SENSOR VIRTUAL DE TEMPERATURA.....	56
5.1.	A EMPRESA - EMPRESA	56
5.1.1.	PARQUE INDUSTRIAL	56
5.1.2.	ESTRUTURA ORGANIZACIONAL.....	57
5.1.3.	TURNOS E ROTINAS ADMINISTRATIVAS NO PROCESSO DE REDUÇÃO 58	
5.1.4.	INFRAESTRUTURA DE CONTROLE E AUTOMAÇÃO DAS REDUÇÕES	59
5.2.	LEVANTAMENTO DE REQUISITOS PARA O SENSOR VIRTUAL.....	63
5.3.	COLETA E ANÁLISE DE DADOS	66
5.3.1.	PRÉ-PROCESSAMENTO DOS DADOS	67
5.3.2.	ESCOLHA DAS VARIÁVEIS	68
5.3.3.	PESQUISA DOS DADOS.....	78
5.3.4.	TRATAMENTO DOS DADOS.....	79
5.3.5.	SEPARAÇÃO DOS DADOS PARA TREINAMENTO, TESTES E VALIDAÇÃO 89	
5.4.	DEFINIÇÃO DA ESTRUTURA DO MODELO.....	89
5.4.1.	ESCOLHA DA ARQUITETURA DA REDE NEURAL	91
5.4.2.	ESCOLHA DO ALGORITMO DE TREINAMENTO	91
5.4.3.	CONFIGURAÇÃO DE PARÂMETROS DA REDE NEURAL.....	91
5.4.4.	BACKUP DO SENSOR VIRTUAL.....	93
5.4.5.	ESTRUTURA FINAL DO SISTEMA.....	94
5.5.	IMPLEMENTAÇÃO DOS SENSORES EM SOFTWARE	95
5.5.1.	REQUISITOS NÃO FUNCIONAIS.....	95
5.5.2.	MATLAB.....	96
5.6.	INTEGRAÇÃO COM FERRAMENTAS DE GESTÃO.....	97
5.7.	CONSIDERAÇÕES FINAIS.....	98
6.	RESULTADOS.....	99
6.1.	TREINAMENTO.....	100

6.1.1. SENSOR VIRTUAL	100
6.1.2. SIMULADOR DE BALANÇO TÉRMICO	117
6.2. VALIDAÇÃO	121
6.2.1. SENSOR VIRTUAL SEM O BACKUP	121
6.2.2. SENSOR VIRTUAL COM BACKUP	125
6.2.3. SIMULADOR DE BALANÇO TÉRMICO	128
6.3. AJUSTES E MELHORAMENTOS	130
6.4. TRATAMENTO DOS ERROS.....	132
6.4.1. RETREINAMENTO DAS REDES NEURAI.....	132
6.4.2. ANÁLISE DETALHADA DOS TIPOS DE ERROS.....	134
6.5. IMPLEMENTAÇÃO DE AJUSTES E VALIDAÇÃO	138
6.5.1. SENSOR VIRTUAL	138
6.5.2. SIMULADOR DE BALANÇO TÉRMICO	141
6.6. CONSIDERAÇÕES FINAIS.....	145
7. CONCLUSÃO	146
7.1. LIMITAÇÕES E DIFICULDADES.....	146
7.2. BENEFÍCIOS ESPERADOS.....	146
7.3. TRABALHOS FUTUROS.....	147
7.3.1. PROJETO DE SENSORES VIRTUAIS PARA OUTRAS VARIÁVEIS.....	147
7.3.2. CONSTRUÇÃO DE SENSORES VIRTUAIS COM OUTRAS TÉCNICAS DE REDES NEURAI	147
7.3.3. SISTEMA INTEGRADO DE ESTIMAÇÃO DE TEMPERATURA.....	147
REFERÊNCIAS.....	148
APÊNDICES.....	152
APÊNDICE A DESCRIÇÃO DO PROCEDIMENTO DE MEDIDA DE TEMPERATURA	153
APÊNDICE B.....	155
APÊNDICE C.....	163

ANEXO I..... 166

RESUMO

As indústrias buscam a todo o momento reduzir seus gastos operacionais para aumentar seus lucros e sua competitividade. Uma boa gestão é o fator mais importante, porém uma boa gestão é feita com auxílio de ferramentas que permitam o acesso às informações relevantes para o processo, que tenham bastante influência na tomada de decisões estratégicas, com o menor custo possível. O uso de sensores virtuais tem sido aplicado cada vez mais nas indústrias. Por ser flexível, ele pode ser adaptado a qualquer tipo de medição, promovendo uma redução de custos operacionais sem comprometer, e em alguns casos até melhorar, a qualidade da informação gerada. Como estão totalmente baseados em software, não estão sujeitos a danos físicos como os sensores reais, além de permitirem uma melhor adaptação a ambientes hostis e de difícil acesso. A razão do sucesso destes tipos de sensores é a utilização de técnicas de inteligência computacional, as quais têm sido usadas na modelagem de vários processos não lineares altamente complexos. Atualmente, muitas indústrias já utilizam com sucesso os sensores virtuais, e este trabalho explora a sua utilização, em conjunto com as Redes Neurais Artificiais, em um processo químico em uma importante indústria de alumínio brasileira cujo controle é muito difícil pois é muito difícil extrair medidas da planta dada sua natureza corrosiva e cujas medições exigem certo custo operacional além de estarem sujeitas a ruídos. A aplicação dos sensores virtuais poderá reduzir os intervalos de medições bem como os custos operacionais. Ao longo deste trabalho será apresentada a metodologia de como projetar o sensor virtual utilizando o processo químico como estudo de caso, seguindo a literatura recomendada.

Palavras Chave: *Sensores Virtuais, Indústria, Processo Químico, Balanço Térmico, Predição de Temperatura, Sensores por Software, Inteligência computacional, Indústria Metaúrgica.*

ABSTRACT

Nowadays, industries worldwide are looking forward to enlarge their profits and become more competitive. A good management is a key factor to accomplish the company's target, however all management decisions are supported by tools that provide good and relevant information for the process, which usually influences decision making strategically. Soft Sensors have been applied in industries which are aiming that target and its use has been growing lately. A soft sensor can be adapted to any application regarding variable measurement, therefore reducing operational costs without compromising the current information quality, and in some cases, better results can be obtained. Since they are software based, they are not subjected to physical damages as real sensors are, so they can be adapted virtually to hostile environments. The key of this kind of sensor success is the use of computational intelligence techniques, which has been heavily used in nonlinear and highly complex process modeling. Currently, many industries already use them successfully, and this work exploits its use with Neural Networks in a chemical process in an important Brazilian Aluminum Smelter whose control is very hard to maintain once it is not easy to retrieve information from the plant due to its corrosive nature and whose measurements require some operational resources. The usage of soft sensors within it may reduce costs and delays of measures drastically. A case of use of the soft sensor for temperature measure is presented on this work, since its design through implementation at production, according to a researched methodology.

Key Words: *Soft Sensors, Industry, Chemical Process, Thermal Balance, Temperature Prediction, Software-based Sensors, Computational Intelligence, Metallurgical Industry.*

1. INTRODUÇÃO

Este capítulo mostra a introdução do contexto do trabalho e a metodologia utilizada.

1.1. APRESENTAÇÃO DO CENÁRIO

Após a revolução industrial, o mundo capitalista sofreu forte mudança. Os processos de produção passaram a ser de larga escala, no qual saiam produtos bons e baratos, porém o seu controle produtivo tornara-se mais desafiador [Stearns, 2007]. Diversos especialistas nos processos auxiliavam as empresas na busca do ponto de maximização dos lucros.

Foi nesse período que as disciplinas de engenharia de produção e controle industrial apareceram [Stearns, 2007]. Os processos passaram a ter modelagem matemática, possibilitando um controle mais determinístico, para se evitar os problemas que ameaçavam a competitividade das indústrias. Após o uso dos computadores, não apenas o processo poderia ser modelado, mas programado e até simulado [Aguirre, 2004]. As disciplinas de controle digital permitiram o desenvolvimento de técnicas de controle menos sensível, dada amostragem de variáveis.

Porém, o controle eficiente do sistema era fortemente baseado em instrumentações, medidores [Ogata, 2007; Dunn, 2005], que tinham a responsabilidade de coletar tais dados em tempo real. Dependendo da variável a ser medida, os equipamentos poderiam ser muito caros e deveriam ser robustos o suficiente para suportar as condições hostis do local, além de fornecer dados reais com o mínimo de ruído possível. Assim, o custo operacional do processo cresceu à medida que a produção cresceria. Esse problema seria solucionado com o aparecimento das técnicas computacionais inteligentes e de mineração de dados [Haykin, 1999; Ogata, 2007; Dunn, 2005].

Uma forte pesquisa desse assunto ocorreu após a metade do século XX, cujos resultados apresentavam sucesso na identificação de padrões até então invisíveis ou impercebíveis numa simples análise [Haykin, 1999]. Essas técnicas começaram a ser utilizadas na modelagem de processos não lineares e complexos e bons resultados começaram a aparecer. Mas o uso destas técnicas se mostrou eficiente na identificação de variáveis correlatas entre si, que mais tarde evoluíram na constituição de um instrumento virtual ou sensor virtual [Fortuna et al, 2007]. Através de variáveis em tempo real, era possível saber indiretamente o valor de outras variáveis sem a necessidade de instrumentação. Isso possibilitaria uma redução drástica nos custos operacionais da empresa, além de permitir uma simulação da planta sem prejudicar a produção.

Os sensores virtuais são o principal assunto deste trabalho. É apresentado um caso de utilização destes sensores, sendo mostradas todas as etapas, desde a sua concepção até a sua validação, com dados reais de uma planta de fabricação de alumínio primário no Brasil. O caso apresentado envolve a medição indireta da temperatura de fornos eletrolíticos e a simulação do balanço térmico dos mesmos a partir de sensores virtuais. As medidas de temperatura são feitas em intervalos muito longos de tempo e por instrumentação cara, dada a natureza corrosiva do forno. A proposta é oferecer alternativas para obter a temperatura usando tais técnicas de inferência.

1.2. OBJETIVOS E JUSTIFICATIVA

Por serem baseados em Software, os Sensores Virtuais são capazes de estimar valores de variáveis que são muito difíceis de ser obtidas em tempo real, além de envolver um alto custo. Estes sensores geralmente são utilizados na estimação de variáveis como temperatura e composição química, cujo tempo de resposta é lento, e na maioria das vezes são necessárias análises em laboratório [Zanata,2005]. Além disso, os sensores virtuais trazem o benefício da previsão das próximas medidas com base em decisões atuais [Fortuna, 2007].

Este trabalho propõe a utilização de sensores virtuais para estimação em tempo real da temperatura dos fornos de redução de alumínio, cuja consequência traria benefícios a Indústria, principalmente no controle da composição química de banho de processo, que é diretamente responsável pela produção.

Os sensores virtuais normalmente possuem tempo de resposta baixo e boa precisão por serem baseados em software, utilizando os dados de processo como base de conhecimento [Fortuna et al, 2007; Aguirre, 2004; Zanata, 2005]. Os trabalhos já publicados na área [Branco, 2004; Pereira, 2005; Branco, 2006; Amos, 2005; Assis et al, 2000; Castro, 2001; Soares, 2009; Soares, 2010] mostram resultados satisfatórios para processos químicos. Tais processos já possuem disponíveis variáveis em tempo real para realizar o controle, como tensão, corrente, resistência, oscilação, entre outras. Utilizando esses dados on-line, serão feitas inferências das variáveis não contínuas.

Assim, de forma geral, o objetivo é a estimação indireta do valor de temperatura atual e futuro com base na situação atual do forno, para que o controle da química de banho seja melhorado.

De forma específica, objetiva-se:

- I. Identificar padrões de comportamento entre as variáveis de processo que se quer determinar via sensor virtual, a fim de se escolher quais dados devem ser usados na construção do modelo.
- II. Selecionar e filtrar dados reais de processo a fim de se retirar dados ruidosos e permitir uma análise mais simplificada do processo.
- III. Implementar um modelo lógico de inferência para as variáveis, contendo variáveis de entrada e saída, e possibilitando que sua implementação possa ser feita em qualquer linguagem de programação;
- IV. Implementação em software do sensor virtual já validado.

1.3. METODOLOGIA E ESTRUTURA DO TRABALHO

O trabalho segue uma Metodologia específica para construção de sensores virtuais, conforme definida em [Fortuna et al,2007]. Como a natureza do processo é muito complexa e não linear [Prasad,1999;Welch,2000], a identificação das variáveis do modelo requer uma boa pesquisa junto à equipe de processo, necessária para se ter um domínio mínimo do processo. A experiência que a equipe já possui no processo deve ser aproveitada para se determinar de forma preliminar quais variáveis têm maior influência sobre a temperatura.

Uma boa pesquisa bibliográfica é conveniente para se atualizar nos trabalhos já feitos na área e em áreas afins, a fim de se determinar a metodologia recomendada, uma vez que muitos deles compartilham a mesma maneira de se projetar o sensor, variando-se apenas a tecnologia ou a técnica computacional utilizada. Essa pesquisa deve envolver as três áreas deste trabalho que são o controle do processo de química de banho, sensores virtuais e as Técnicas de Computação Inteligente.

O próximo passo é a escolha e filtragem de dados para análise e formação de um modelo inicial. Através de testes e simulações em software, as estimações das variáveis são obtidas e logo submetidas à validação, tanto pela equipe de processo quanto pelos dados coletados de validação. A partir daí, novos modelos são produzidos a fim de se obter melhores resultados.

A tabela a seguir mostra as atividades desenvolvidas para atingir cada objetivo elencado:

Objetivo	Método/Atividade
I	Entrevistas com a equipe de Processo da Empresa (técnicos de processo, engenheiros de processo, operadores, etc.) Pesquisa de literatura sobre o Processo Químico em questão. Utilizar métodos de correlação entre as variáveis para identificar comportamentos entre elas.
II	Utilizar técnicas de filtragem de dados Escolher dados mais estáveis e fiéis que representam de forma genérica a natureza do processo.
III	Determinar uma técnica computacional mais adequada na formação do sensor. Implementar uma estrutura de modelo com as respectivas variáveis em questão. Simular os dados coletados e realizar ajustes nos parâmetros do modelo. Validar, segundo dados já coletados e junto à equipe de processo, os resultados obtidos, havendo até a possibilidade de se modificar a estrutura do modelo.
IV	Análise sobre o ambiente de TI e Automação da Planta, e viabilizar a construção de um software que disponibilizará os resultados obtidos em tempo real. Possibilitar uma nova “calibração” do sensor, utilizando dados mais recentes, de forma a impedir que casos não previstos durante sua concepção ocorram e prejudiquem o desempenho do sensor.

Tabela 1-1. Metodologia do Trabalho

Este trabalho foi organizado em sete capítulos, objetivando publicar de forma bem direta os procedimentos utilizados e como os resultados foram obtidos, porém apresentando de forma sólida os pilares desse trabalho, que são o Processo Químico em questão, no caso o processo de fabricação de Alumínio primário, os Sensores virtuais e a Técnica Computacional Utilizada, nesse caso as Redes Neurais Artificiais.

Os capítulos ficam organizados da seguinte maneira:

- **Capítulo 1:** Mostra a motivação que deu origem ao trabalho, os objetivos e a metodologia aplicada e a fundamentação teórica preliminar necessária.
- **Capítulo 2:** É apresentado de forma sucinta e simplificada o processo de fabricação de alumínio primário, citando-se as dificuldades enfrentadas.
- **Capítulo 3:** Apresenta os sensores virtuais na sua forma mais genérica, explicando conceitos específicos sobre tais ferramentas.
- **Capítulo 4:** São apresentadas as redes neurais artificiais, que são técnicas de computação inteligente, e suas arquiteturas, algoritmos de treinamento e técnicas de validação.

- **Capítulo 5:** Mostra o projeto do Sensor Virtual de Temperatura, como ele foi construído para atingir os objetivos do trabalho, a coleta dos dados, filtragem, determinação do modelo utilizado e o projeto de uma possível integração com o parque tecnológico de TI a Automação da Indústria.
- **Capítulo 6:** São mostrados os resultados obtidos, incluindo metodologia de treinamento utilizada, otimização dos resultados e sua validação.
- **Capítulo 7:** É apresentada a conclusão do trabalho e são sugeridos trabalhos futuros.

2. PROCESSO DE FABRICAÇÃO DE ALUMÍNIO PRIMÁRIO

Este capítulo apresenta de forma simplificada o processo de fabricação de alumínio primário e seus subprocessos.

Apesar de ser um dos elementos mais abundantes da natureza, o alumínio puro é extremamente difícil de ser extraído, o que não é possível sem a ocorrência de alguma reação química. O alumínio está sempre ligado a algum outro elemento químico na forma de sais ou óxidos, o que torna necessária uma separação. A figura 2.1 mostra o alumínio na sua forma pura, após ter sido reduzido. A figura 2.2 mostra a bauxita, que é encontrada livremente na natureza e é um composto de alumínio e outros elementos.



Figura 2.1 Alumínio Puro



Figura 2.2 Bauxita

Durante séculos, diversas tentativas de se obter o alumínio puro foram feitas, mas somente em 1825, Hans Christian Oersted conseguiu obter através de aquecimento pequenas pedras de Alumínio [Alcoa, 2006]. Já em 1854, Henri Sainte-Claire Deville foi o primeiro a utilizar eletrólise para separar o Alumínio de outros elementos, porém para isso necessitava-se de uma quantidade muito grande energia para poder aquecer os amálgamas e conseguir realizar a reação. Apesar disso, a produção de alumínio chegou a ser de 10 toneladas por ano na década de 1870 [Alcoa, 2006].

Na década de 1880, com a invenção do dínamo elétrico por Thomas Edison, a energia elétrica se tornou mais abundante e possibilitou que os jovens estudantes Charles Hall e Paul Heroult utilizassem eletrólise para separação do alumínio do oxigênio dos grãos de alumina (Al_2O_3) em sais fundentes como a criolita (Na_3AlF_6). Este novo processo, o qual é detalhado a seguir, possibilitou a produção de alumínio em larga escala, em menos de 5 anos, a produção já ultrapassava 300 toneladas por ano.

2.1. O PROCESSO HALL HÉROULT

Este é o processo pelo qual a maioria das indústrias de alumínio primário executa para se obter o alumínio com até 99,9% de pureza. Basicamente, trata-se da separação da alumina em alumínio e oxigênio, mas o processo também requer a participação de outros elementos como sais fundentes, gases e aditivos químicos para manter a estabilidade do processo, o que torna o processo mais complexo. A equação 2.1 mostra a reação química de redução do Alumínio e a figura 2.3 mostra uma sequência temporal da reação.





Figura 2.3 Sequência de ionização da eletrólise

O processo Hall-Héroult é um processo contínuo no qual a alumina é dissolvida em um banho de criolita derretida a uma temperatura em torno de 960°C sob a passagem de corrente elétrica contínua, na ordem de 180 kA. As unidades de produção do alumínio são chamadas de fornos ou cubas [McFadden, 2001], que normalmente são dispostas em série, assim a corrente elétrica é a mesma em todos os fornos, compondo uma linha de produção. Periodicamente, o metal produzido é retirado dos fornos e encaminhado ao lingotamento, no qual o alumínio líquido é solidificado em formas produzindo lingotes, que logo depois são empilhados e estocados para exportação. A figura 2.4 mostra graficamente a seqüência de todo o processo.




Figura 2.4 Cadeia de Produção do Alumínio

Atualmente, as indústrias de alumínio gastam aproximadamente 14,4 MWh para produzir 1 tonelada de alumínio [Alcoa,2006], e a produção mundial supera os 30 milhões de toneladas. Uma única indústria, com quatro linhas de redução, é capaz de produzir quase 500 mil toneladas por ano, e esse número pode ser maior dependendo das condições em que o processo ocorre. A tabela 2.1 mostra as maiores indústrias redutoras de alumínio no mundo e a tabela 2.2 mostra os países que mais produzem alumínio no mundo. A evolução da produção de alumínio nos últimos 100 anos é mostrada na figura 2.5.

Indústria Redutora	Localização	Acionista Majoritário	Produção (milhares de toneladas)
Bratsk Am Works-Braz	Bratsk-Russia	RUSAL 100%	950
Krasnoyarsk Am Works-Kras	Krasnoyarsk-Russia	RUSAL 100%	937
Alba	Manama-Bahrein	Alba	872
Dubal	Jebel Ali-Emirados Árabes	Dubal	861
Hillside	Richards Bay-South Africa	BHP Billiton	670
Aluminerie Alouette	Sept Îles-Canadá	Rio Tinto Alcan 40%	572
Boyne Smelters Ltd	Boyne Island-Austrália	Rio Tinto Alcan 59%	545
Mozal	Maputo-Moçambique	BHP Billiton	530
Tomago Aluminium Co	Tomago-Austrália	Rio Tinto Alcan 51%	520
Tadzik Am Works-Tadaz	Tursunzade-Tadzikistão	RUSAL 100%	520
Sayamsk Am Works-Saaz	Sayanogorsk-Russia	RUSAL 100%	500
Companhia Brasileira de Alumínio	Sorocaba-Brasil	CBA 100%	475
Albras	Barcarena-Brasil	Vale 51%	460
Irkutsk Am Works-Iraz	Shelekhovo-Russia	RUSAL 100%	456
Alcoa Canada	Baie Comeau-Canadá	Alcoa 100%	438
Alumar	São Luís-Brasil	Alcoa 60%	438
Venalum	Puerto Ordaz-Venezuela	Venalum	436
Rio Tinto Alcan	Alma-Canadá	Rio Tinto Alcan 100%	415
A.B.I	Becancour-Canadá	Alcoa 75%	409
Qingtongxia Al Co	Qingtongxia-China	Rio Tinto Alcan 50%	385

Tabela 2-1 As vinte maiores fábricas de alumínio no mundo [Fonte: World Aluminium, 2007]

<i>País</i>	<i>Produção milhares toneladas)</i>	<i>(em de Número Indústrias</i>	<i>de</i>
China	5896	34	
Rússia	4102	12	
Estados Unidos	3493	17	
Canadá	3117	11	
Austrália	1945	6	
Brasil	1674	7	
Noruega	1384	7	
Índia	1183	6	
Bahrein	872	1	
Emirados Árabes	861	1	

Tabela 2-2 Os 10 maiores países produtores de alumínio no mundo. [Fonte: World Aluminium, 2007]




Figura 2.5 Evolução da produção de alumínio no século XX

2.1.1. Forno Eletrolítico

O forno é o local onde a reação ocorre. É uma construção de aço especialmente preparada para receber os elementos utilizados no processo: banho eletrolítico, alumina, gases, aditivos químicos, corrente elétrica e estruturas de carbono para condução de energia. O corte transversal do forno com seus elementos é exibido nas figuras 2.6 e 2.7.




Figura 2.6 Corte transversal de um forno eletrolítico




Figura 2.7 Elementos Constituintes de um Forno Eletrolítico

A corrente elétrica atravessa o forno dos anodos ao catodo. Normalmente existem de 12 a 20 anodos em cada forno, dependendo de seu tamanho. O banho eletrolítico fica entre os anodos e o catodo, que é o meio onde ocorre a eletrólise. O alumínio produzido é atraído para o pólo negativo, ficando depositado no fundo do forno. Uma crosta sólida se forma ao redor do forno e na sua superfície. Essa crosta é periodicamente rompida para troca de anodos ou para adição de alumina, fluoreto ou outros aditivos químicos. Acima da superfície ficam os gases gerados no processo, que são reaproveitados em uma Planta de Tratamento de Gases, atendendo a uma norma ambiental. A figura 2.8 mostra uma fotografia de uma linha de redução típica.



Figura 2.8 Linha de redução típica

2.1.2. Banho Eletrolítico

O Banho consiste principalmente de criolita fundida, fluoreto de alumínio em excesso de 6 a 10% e alumina que fica em torno de 2 a 5%. Este banho deve permanecer líquido para que a reação ocorra [McFadden et al, 2001], o que naturalmente já acontece com a passagem da corrente elétrica contínua de 180 kA.

2.1.3. Aditivos Químicos utilizados

A temperatura de operação do banho é de 920 a 1000°C, entretanto o ideal é manter a temperatura o mais próximo possível de 960°C. A criolita pura possui um ponto de fusão alto (1009°C), e para reduzi-lo são adicionados alguns aditivos químicos, principalmente o fluoreto de alumínio (AlF_3), o fluoreto de cálcio (CaF_2), a barrilha (Na_2CO_3) e a própria alumina. A finalidade dos aditivos químicos também é manter a composição química do forno estável, conforme mostrado na tabela 2.3.

<i>Elemento</i>	<i>Percentual aceitável de operação</i>
AlF_3 (Fluoreto de Alumínio)	Entre 9 e 11 %
CaF_2 (Fluoreto de Cálcio)	Entre 4 e 5 %
Al_2O_3	Entre 1,5 e 2,5%
Na_2CO_3	Menos de 1 %

Tabela 2-3 Composição química normal desejável dos fornos

2.1.4. Anodo e Catodo

O Anodo e o Catodo são os dois extremos de uma reação química por eletrólise, sendo respectivamente um pólo negativo e outro pólo positivo, conforme mostrado na figura 2.9.




Figura 2.9 Representação esquemática anodo catodo

Em fornos de produção de alumínio, o anodo (figura 2.10) está presente na forma de hastes, já o catodo (figura 2.11) está presente na estrutura do próprio forno, sendo este ligado diretamente ao barramento elétrico. Ambos são feitos a partir de coque e piche.



Figura 2.10 Anodo



Figura 2.11 Bloco Catódico

O Catodo normalmente possui um tempo de vida útil de três a oito anos, ou de 1000 a 3000 dias, dependendo da estabilidade do forno. Já o anodo é consumido continuamente pela natureza do forno e necessita ser trocado a cada 2 ou 3 semanas.

2.2. ESTRATÉGIAS DE CONTROLE

O sucesso do processo produtivo depende de vários fatores ligados ao controle. Conforme já esclarecido, os fornos operam sob uma condição extremamente hostil, a altas temperaturas e sujeito a uma corrente elétrica muito alta. A produção de alumínio depende de quão eficiente está sendo a corrente elétrica, ou seja, para cada kW gerado existe uma


quantidade máxima de alumínio que pode ser produzida. À quantidade de alumínio retirada do forno dividida pela quantidade máxima teórica, dá-se o nome de Eficiência de Corrente.

A quantidade máxima teórica de produção está em função da intensidade de corrente, pois a produção está diretamente relacionada com a quantidade de carga elétrica que passa pelo eletrólito. É estabelecido em [Alcoa, 2006], segundo a constante de Avogrado, que a cada 96.485 Coulombs são liberadas 9 gramas de alumínio, portanto a quantidade máxima teórica é:

$$Kg_{Al} = \left(\frac{I * 86400}{96485} \right) * 0,009 \quad (2.2)$$

onde I é a corrente em Amperes.

Assim, uma linha operando a 180 KA, produz cerca de 1.450 Kg de alumínio por dia. Entretanto, como parte do alumínio ionizado se liga novamente às moléculas de gás carbônico, conforme mostrado na equação 2.3, ocorre uma perda de produção, reduzindo a eficiência de corrente de 100% para em torno de 90%.



Idealmente, para se obter o máximo da produção, é necessário manter o forno estável [McFadden, 2001] em um determinado *setpoint*, conforme tabela 2.4. No entanto, para se manter esse controle, é necessário um mecanismo robusto e tolerante a falhas, pois qualquer alteração em uma das variáveis pode levar o forno a uma situação de instabilidade, comprometendo a sua produção.

Variável	Setpoint
VMR (Tensão de Forno)	4,2 V
RMR (Resistência)	15 $\mu\Omega$
TMP (Temperatura)	960°C
%AlF3 (Percentual Fluoreto)	10%
%Al2O3 (Percentual Alumina)	2%
%CaF2 (Percentual Fluorita)	5%
NME (Nível de Metal)	18 cm

Tabela 2-4 Lista de variáveis com seus respectivos valores ideais de operação

Basicamente, são utilizadas estratégias para controlar:

- Resistência do Forno (RMR)
- Composição química do banho eletrolítico (%AlF3, %CaF2)
- Alimentação de alumina. (QAlr)

Porém, os três sistemas de controle podem compartilhar variáveis, assim, qualquer decisão tomada em um sistema de controle pode propagar seus efeitos nos outros sistemas.

2.2.1. Controle de Resistência dos Fornos

As indústrias organizam seus fornos em série com o barramento elétrico, dentro de salas chamadas de reduções. As figuras 2.12a e 2.12b mostram duas disposições de fornos usadas.




Figura 2.12 Disposição de fornos em uma sala de redução. (a) tecnologia End-to-End (b) tecnologia side-by-side

A resistência comum de um forno está em torno de 15 μOhm , mantendo a tensão em torno de 4,2V. A tensão efetiva, ou seja, aquela que é gerada pela própria reação química e resulta na produção do alumínio corresponde a 1,65V por forno. É fundamental que a resistência se mantenha estável para que a tensão efetiva não se altere, causando uma queda na produtividade. Uma resistência muito alta pode provocar aquecimento no forno, comprometendo o anodo e em casos extremos o catodo [Prasad,1999]. O comprometimento do Catodo provoca o desligamento do forno [Prasad,1999]. Já uma resistência muito baixa provoca uma queda na eficiência de corrente [McFadden et al,2001].




Figura 2.13 Distância anodo-catodo

Para se manter a resistência estável, é necessário controlar a distância anodo-catodo (figura 2.13) a um nível que mantenha a resistência próxima de seu *setpoint*. Os anodos *prebake* [Prasad,1999] são consumidos continuamente pelo eletrólito fazendo com que a distância com o catodo aumente, elevando a resistência do forno. O sistema de controle de resistência (figura 2.14) monitora continuamente as variáveis online do forno (tabela 2-5), assim, ele identifica se haverá necessidade de subir ou descer anodo.

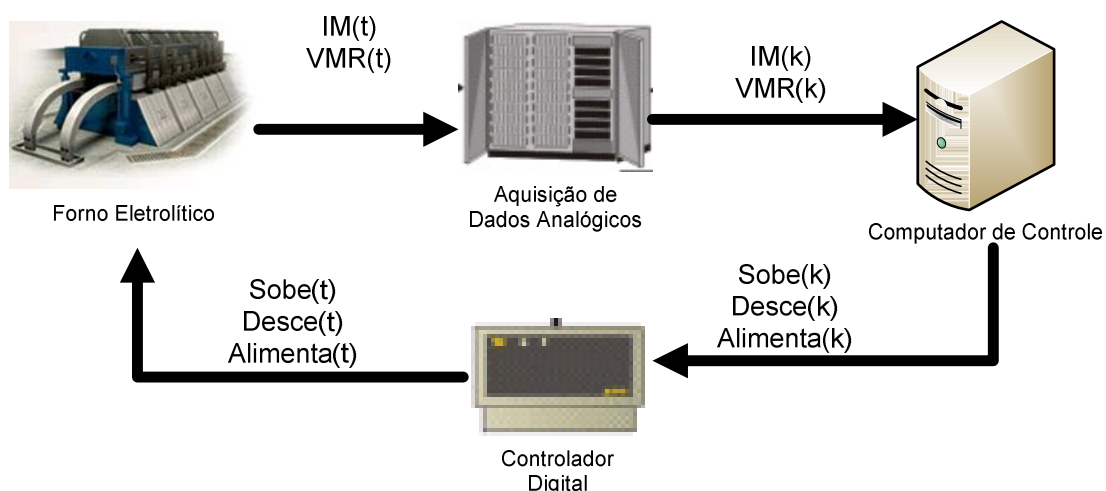


Figura 2.14 Diagrama esquemático do sistema de controle de Resistência

<i>Variável</i>	<i>Descrição</i>
VMR (Tensão de Forno)	Tensão total do forno
RMR (Resistência)	Resistência do forno
IM (Intensidade de Corrente)	Corrente da Linha de Redução
QAIR (Quantidade Alimentada)	Quantidade de alumina alimentada
Alimentação	Tipo de alimentação
%TOV	Percentual do Tempo de alimentação em Over
%TUN	Percentual do Tempo de alimentação em Under

Tabela 2-5 Variáveis no Controle de Resistência do Forno

Os anodos normalmente são trocados de 15 a 20 dias, e os fornos costumam ter entre 12 e 20 anodos, o que resulta numa taxa de uma troca por dia, aproximadamente. As trocas acontecem em intervalos programados. Um anodo novo está com o tamanho completo, o que pode baixar a resistência do forno, provocando a necessidade de uma subida de anodo. O sistema de controle normalmente não movimenta um anodo individualmente mas todos ao mesmo tempo.




Figura 2.15 Anodo Alto




Figura 2.16 Anodo Baixo

2.2.2. Química de Banho

A composição química do eletrólito (ou Banho) possui um papel fundamental no processo produtivo. Visando manter estáveis as suas variáveis, há duas formas de se controlar a química de banho: balanço térmico e balanço de massa. Qualquer alteração no balanço térmico (ou equilíbrio térmico) interfere no balanço de massa (composição química), e vice-versa [Pereira, 2005].

O equilíbrio térmico é obtido através dos aditivos químicos:

- Fluoreto de Alumínio (AlF_3)
- Fluorita de Cálcio (CaF_2)
- Barrilha (Carbonato de Sódio) Na_2CO_3

No banho há também outras substâncias, provenientes da alimentação de alumina: Óxido de Sódio, Óxido de Cálcio, entre outros [Prasad, 1999].

Este tipo de controle normalmente é feito a cada 32 a 120 horas, nos quais são coletadas informações sobre o balanço térmico (Temperatura de Banho, Temperatura de Líquidos, Super Heat) [McFadden, 2001]. Para se obter a informação sobre a composição química atual do banho, uma análise química é feita em laboratório com amostras do banho retirado a cada 64 a 120 horas, entretanto, algumas indústrias já utilizam mecanismos para que esse tempo se torne menor [McFadden, 2001]. Tendo essa informação, o técnico de processo deve tomar a decisão sobre o que deve ser adicionado ao banho para que a composição química e conseqüentemente a temperatura fique estabilizada. A figura 2.17 mostra um diagrama esquemático do processo de controle da química de banho.

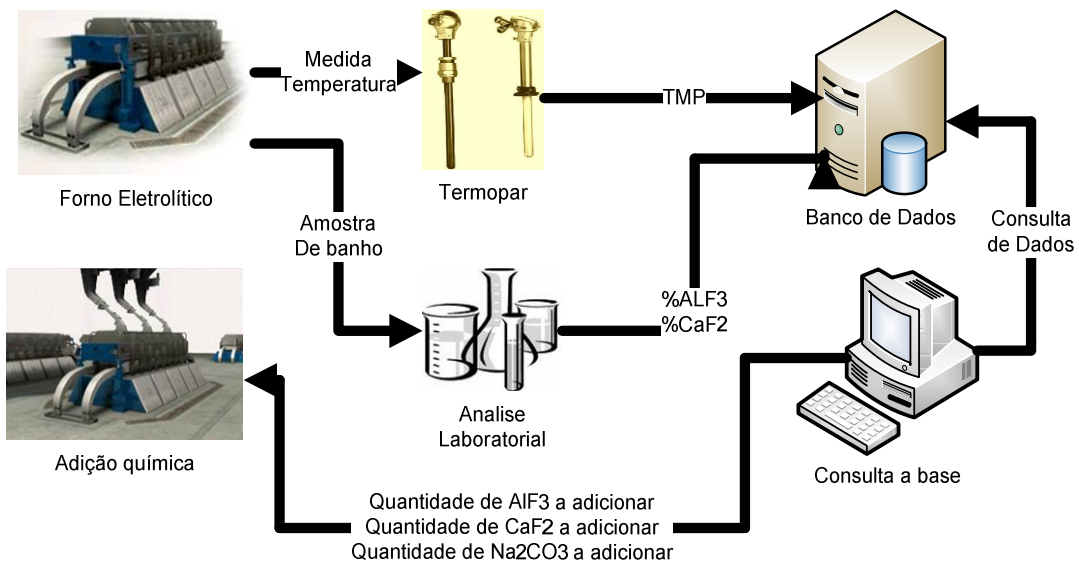


Figura 2.17 Diagrama do processo de química de banho

<i>Variável</i>	<i>Descrição</i>
TMP (Temperatura de Forno)	Temperatura do banho químico
%ALF3 (Fluoreto de Alumínio)	Excesso de Fluoreto no banho
%CaF2 (Fluoreto de Cálcio)	Excesso de Fluorita no banho
AlF3A (Adição de AlF3)	Quantidade de fluoreto adicionada
CaF2A (Adição de CaF2)	Quantidade de fluorita adicionada
Na2CO3A (Adição de Na2CO3)	Quantidade de barrilha adicionada
VIDA (Tempo de funcionamento)	Número de dias de operação do forno

Tabela 2-6 Variáveis envolvidas na química de banho

O principal impacto da química de banho no processo de fabricação de alumínio é a influência direta na Eficiência de Corrente e a formação da Crosta, também conhecida como Lombo. As variáveis de temperatura e fluoreto se tornaram um parâmetro de avaliação importante sobre o desempenho do forno, uma vez que a oscilação delas é muito frequente. Este controle, em muitas indústrias, é feito de forma manual e não contínua, entretanto alguns trabalhos tem sido desenvolvidos para automatizar ou minimizar a interferência humana [Pereira et al, 2005], [De Oliveira et al, 2007].

2.2.3. Controle da Alimentação de Alumina

A presença de alumina no banho é um importante fator de desempenho da produção, pois existe uma quantidade ideal para que o forno não se desestabilize. Normalmente a quantidade ideal é em torno de 2 a 5%. Qualquer quantidade fora desse limite leva a um comportamento inadequado do forno. Como o processo é contínuo, a

alimentação de alumina é feita por pequenas bateladas periodicamente de forma pré-programada. A taxa de alimentação de alumina é em torno de 1,7 Kg / min. O que varia é a frequência de como é alimentada.




Figura 2.18 Consumo teórico de alumina com o passar do tempo e tipo de alimentação

O controle, na verdade, deve identificar qual tipo de alimentação é mais adequado para o forno naquele momento. Essa informação é extraída das mesmas variáveis do controle de resistência. O principal parâmetro para se identificar uma mudança de alimentação é a própria resistência do forno [Prasad,1999].

2.2.4. Instrumentação e Automação

Para fazer funcionar todo esse processo, as indústrias dispõem de tecnologia baseada em automação industrial e computação (TI). Após a década de 1960, com a consolidação das disciplinas de automação e controle, um padrão de automação industrial para esse processo foi estabelecido [Ogata,2007;Stearns,2007]. As reduções dispõem de máquinas para transporte automático de alumina e outros aditivos químicos [McFadden, 2001], além de veículos para transporte e troca dos anodos. Uma máquina para troca de anodos é mostrada na figura 2.19.



Figura 2.19 Máquina Troca Anodo

O metal é retirado periodicamente (sifonamento) de cada 24 a 48 horas por cadinhos, conforme mostrado na figura 2.20. Existe um turno específico somente para retirada de metal dos fornos. Durante este, somente os cadinhos são autorizados a circular na planta, conforme figura 2.21. Em seguida, o metal líquido é encaminhado ao lingotamento por veículos especialmente preparados.



Figura 2.20 Cadinho fazendo sifonamento

O controle do processo contínuo é fortemente baseado em computadores e software. Com a evolução das técnicas de controle e instrumentação, cada forno é equipado com sensores, medidores, motores e outros elementos de automação [McFadden, 2001], para fornecer informações necessárias ao sistema de controle. Todavia, existem painéis de comando local para eventual manobra em casos emergenciais.



Figura 2.21 Fornos de Redução Cadinho retirando metal durante Corrida

O controle do balanço térmico e da composição química, entretanto, ainda sofre muita intervenção humana. Uma equipe de processo monitora a temperatura de cada forno através de termopares (figura 2.22), cujas medições são feitas em turnos definidos. A composição química é analisada em laboratório em um intervalo maior, pois é tempo necessário para se extrair amostras do banho eletrolítico e fazer a análise [McFadden, 2001].



Figura 2.22 Termopares utilizados para medição de Temperatura

Todos os sistemas de controle são automatizados parcialmente, ficando a cargo da equipe de processo a tomada de decisões de acordo com as informações passadas pelo sistema de controle. Com as tecnologias de acesso a dados e interoperabilidade, é possível registrar em bancos de dados todas as informações referentes aos fornos, suas variáveis e seus registros com o passar do tempo. Isso possibilita a realização de pesquisas sobre esses dados de forma que é possível a identificação de certos padrões entre as variáveis. Alguns trabalhos tem sido feitos na busca desses padrões, na esperança de automatizar operações que atualmente sofrem muita interferência humana [Pereira et al,2005; De Oliveira et al,2007;McFadden et al,2001; Soares et al, 2010]. Um diagrama da infraestrutura de TI e automação da uma redução de alumínio é mostrada na figura 2.23.

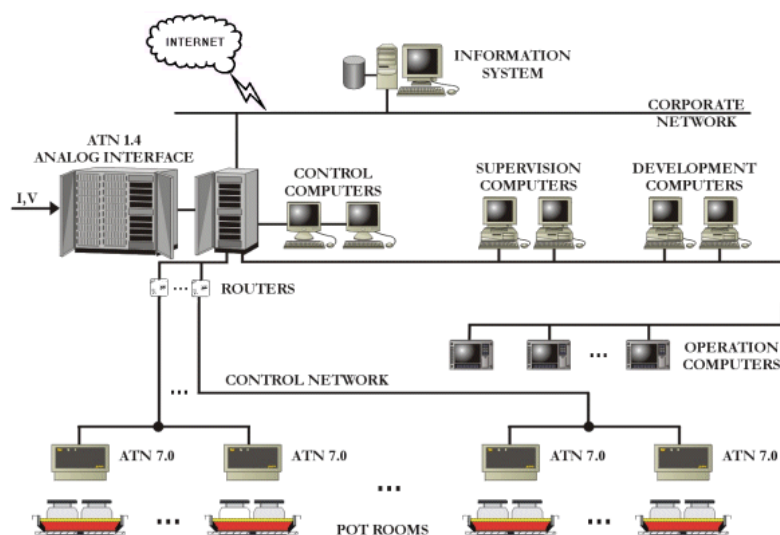


Figura 2.23 Diagrama da infraestrutura de TI e Automação de uma Planta

2.3. PROBLEMAS ENFRENTADOS

Apesar de se encontrar em um patamar já bastante evoluído, o processo enfrenta alguns problemas de natureza operacional ou por limitações dos equipamentos. As alimentações são pré-definidas para cada tipo de situação, porém há situações indesejáveis que acabam ocorrendo e cujas causas ainda são desconhecidas:

- Formação de Pontas nos Anodos
- Efeito Anódico
- Superaquecimento do Forno
- Oscilações fortes na Temperatura e na Composição Química
- Vazamento de Metal
- Expansão do Lombo

A equipe de processo trabalha continuamente em soluções para esses problemas, através de ciclos de qualidade, congressos e pesquisa e desenvolvimento. O processo ainda possui modelagem analítica incompleta [Prasad,1999], e seus equipamentos utilizados para controle sofrem interferência de ruídos e erros [McFadden,2001], assim uma decisão errada ou equivocada certamente prejudica processo [Welch,2000]. Diante desse cenário, diversas tentativas de se evitar problemas foram feitas [Branco,2004;Pereira,2005;De Oliveira et al,2007; Soares et al, 2009].

2.3.1. Variações de Temperatura e Medição

As temperaturas dos fornos costumam apresentar altas oscilações. As causas desse problema ainda são desconhecidas, pois depende de vários fatores. Segundo [Welch, 2000] a temperatura está diretamente relacionada com a composição química, mas alterações nas variáveis elétricas já mostraram influência [Welch, 2002]. A figura 2.24 mostra a oscilação da temperatura (em vermelho) em movimentos opostos à oscilação do fluoreto (em azul).




Figura 2.24 Grafico mostrando a oscilação de temperatura (em vermelho)

A medição da temperatura também é uma dificuldade enfrentada, pois existem variações espaciais dentro do forno, conforme é mostrado na figura 2.25.

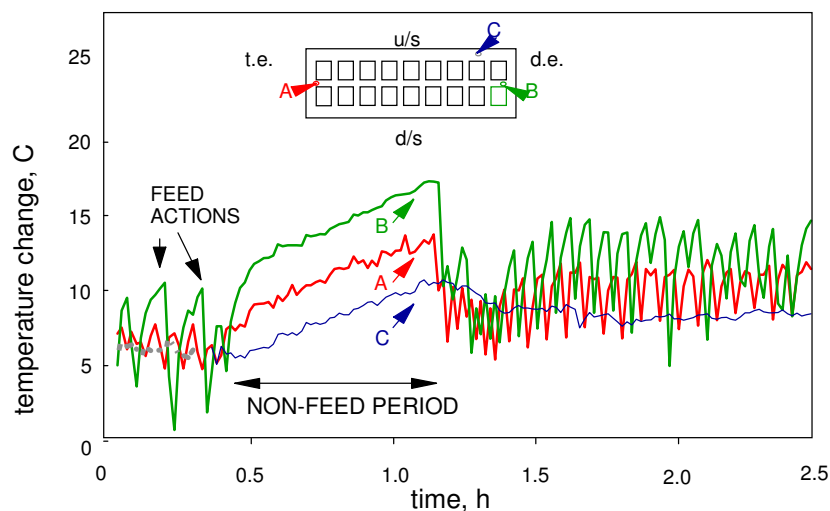


Figura 2.25 Variações espaciais de temperatura em um forno

O uso de termopares digitais também é um problema, pois os mesmos possuem uma vida útil muito curta além de estarem sujeitos a erros de medição, que se propagam no controle deste e de outros sistemas [McFadden,2001]. A natureza corrosiva do eletrólito acaba comprometendo em parte os equipamentos envolvidos no seu controle. Isso faz com que os intervalos de medição de temperatura sejam feitos em um intervalo muito longo, para aproveitar o uso dos termopares por mais tempo. Um termopar típico suporta de 20 a 30 medições, de cerca de dois minutos cada. O custo operacional para este processo é muito alto e seu resultado não é 100%, dados os problemas. Alguns trabalhos tem sido feitos na otimização deste controle [McFadden,2001].

2.4. CONSIDERAÇÕES FINAIS

Este trabalho propõe uma solução para o problema da medição de temperatura com a construção de um sensor virtual para fornecer informações sobre a temperatura do forno em intervalos de tempo menores ou até substituir os termopares em um tempo mais longo. No próximo capítulo, são apresentados os sensores virtuais e suas aplicações na indústria.

3. USO DE SENSORES VIRTUAIS NA INDÚSTRIA

Este capítulo tem a intenção de apresentar os sensores virtuais, o que são, como são projetados e para quê são usados.

São, na verdade, programas de computador (*software*) capazes de estimar o valor de uma determinada variável cuja medição é difícil, custosa ou requer um certo trabalho para ser disponibilizada [Zanata, 2005], conforme ilustrado na figura 3.1. A estimação é feita através da informação que já é conhecida ou disponível online, ou seja, a partir de variáveis em tempo real, os sensores virtuais são capazes de inferir o valor de uma variável.

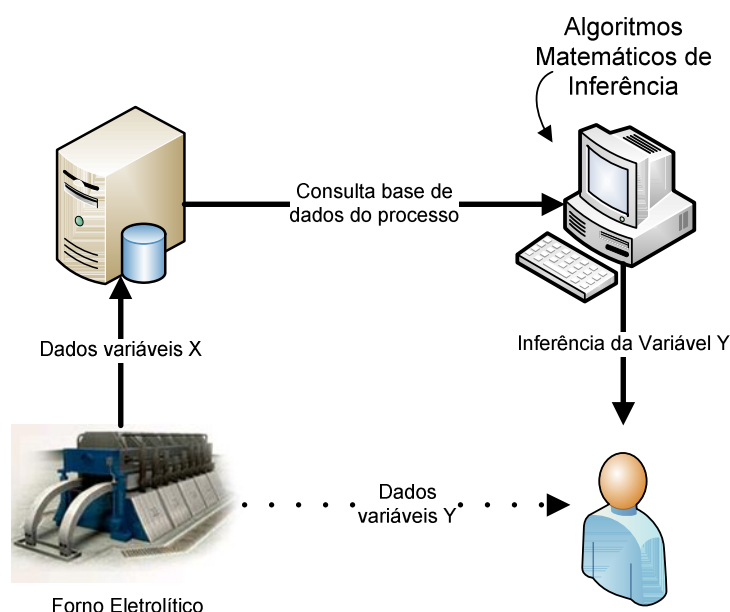


Figura 3.1 Diagrama do princípio do sensor virtual

Segundo [James et al, 2000], um sensor virtual também pode ser definido como:

“algoritmos matemáticos (modelos inferenciais) capazes de estimar, em tempo real, variáveis de interesse não medidas a partir de outras variáveis disponíveis medidas instantaneamente.” (JAMES et al, 2000, p. 13)

Com o aprimoramento das disciplinas de controle e inteligência computacional, a modelagem matemática de processos passou a ser utilizada na predição de propriedades a partir de dados de planta [Haykin,1999;Branco,2004]. Esses estimadores evoluíram para a categoria de sensor virtual ou do inglês “*soft sensor*” cuja origem está relacionada a uma das principais aplicações desta técnica que é o uso de software.

Os sensores virtuais apresentam algumas vantagens para modelagem de plantas:

- ***Substituição de dispositivos de Hardware caros***
 - Os sensores virtuais são totalmente baseados em software, portanto parte do custo operacional pode ser diminuído se considerar a utilização de sensores virtuais;
- ***Fácil implementação em qualquer dispositivo***
 - Como são algoritmos matemáticos, podem ser implementados em microcontroladores, microprocessadores, microcomputadores, controladores programáveis com a mínima capacidade de processamento necessária dependendo da aplicação;
- ***Estimação de dados em tempo real***
 - Dadas as capacidades da planta, o sensor virtual pode fornecer dados do processo sem os atrasos que aconteceriam por sensores baseados em hardware analógicos ou análises demoradas do sinal;
- ***Para o processo funcionam como sensores reais;***
 - O sensor, depois de implantado, é visto como mais um elemento na planta de automação, fornecendo dados importantes para o sistema de controle, porém sem a necessidade de um plano de manutenção e troca, como acontecem com os sensores reais.

3.1. APLICAÇÕES

Tais sensores possuem uma grande área de aplicação, pois podem ser usados para estimar qualquer variável, auxiliando na sua monitoração, controle e otimização de processos [Fortuna et al, 2007]. Ao longo da história, os sensores virtuais têm sido utilizados com sucesso na substituição de sensores físicos ou no trabalho em conjunto com eles, auxiliando no controle do processo. Ocorre que muitas das indústrias já possuem uma base de dados histórica muito grande, o que facilita a modelagem do processo a partir do uso de sensores virtuais [Zanata,2005; Fortuna et al, 2007].

Os sensores virtuais, porém, são indicados para processos cuja complexidade e não linearidade inviabiliza uma modelagem analítica.

3.1.1. Indústria Química

Na indústria química estão os melhores exemplos de utilização destes sensores, pois seus processos são complexos e não lineares. Em Camaçari, na Bahia, uma fábrica de polietileno implementou junto com a Pavillion um sensor virtual para estimação do índice de fusão e da densidade de polietileno [Amos,2005]. A implementação feita recompensou os esforços na redução da variedade do produto em mais de 20%, que para a indústria de polietileno significa que a produção fica mais fácil com menos perdas.

Na produção de alumina, há outro exemplo considerável no uso de sensores virtuais é na estimação da Perda na Ignição (do inglês Loss On Ignition – LOI), que é a medida do total de umidade da alumina ao sair dos calcinadores. Em uma indústria australiana (Worsley Alumina) foi construído um sensor virtual onde ele determinou de forma totalmente empírica a estimação do LOI [Amos, 2005].

Zanata em seu trabalho de mestrado [Zanata, 2005] mostra a modelagem de sensores virtuais para estimação da composição química de produtos de saída em colunas de destilação, cujos analisadores são cromatógrafos gasosos, que apresenta grandes atrasos na medição e são altamente difíceis de manter. Sua estratégia foi inferir a composição do destilado através de outras variáveis.

Em [James et al, 2000] são apresentados sensores virtuais para biorreatores em processos bioquímicos. O trabalho aborda de forma bem geral, uma metodologia para inferência de variáveis do processo e suas técnicas utilizadas.

Na indústria petroquímica [Martin e Gerhard,1997], há vários trabalhos desenvolvidos com estes sensores, a saber:

- Indústria de Polímeros: medição do índice de fluidez
- Papel e Celulose: medição da resistência e porosidade do papelão
- Mineração: Medidas de PH na Neutralização

A automação de processos também é um fator importante e decisivo na construção de sensores virtuais. Muitas das medidas são feitas de forma manual e seria uma economia de trabalho e tempo disponibilizar o mesmo dado de forma automática, sem erros.

3.2. PROJETO DE SENSOR VIRTUAL

Basicamente, há três formas de modelagem dos sensores virtuais:

3.2.1. Modelagem Física (Caixa Branca)

Nesta modelagem, o sistema é determinado a partir de equações matemáticas que descrevem a física do processo. Esta modelagem seria a ideal, porém, para se realizá-la, deve-se entender completamente a natureza do processo e seus fenômenos envolvidos [Aguirre, 2004; Fortuna et al,2007]. O trabalho se concentra, portanto, na determinação das equações que descrevem analiticamente o processo.

3.2.2. Modelagem baseada em Inteligência Artificial (Caixa Preta)

Nesta abordagem, os modelos são constituídos de forma totalmente empírica, a partir de dados de processo disponíveis, levando-se em consideração apenas o comportamento entrada-saída. Não há necessidade de se conhecer a fundo o processo, mas a técnica utilizada pode fornecer bons resultados [Fortuna et al, 2007]. O trabalho se concentra na escolha da técnica computacional a ser utilizada, que pode ser Redes Neurais Artificiais, Lógica Fuzzy ou Algoritmos Genéticos. Cada técnica possui sua finalidade para cada tipo de problema.

3.2.3. Modelagem Híbrida (Caixa Cinza)

Muitas vezes, o conhecimento do processo acaba sendo importante também na modelagem baseada em inteligência artificial, o que pode poupar alguns trabalhos, como a escolha de variáveis de entrada e saída ou parâmetros do sistema. Esta modelagem considera a utilização das duas classes de modelagens anteriores, ou seja, é possível estimar os estados e os parâmetros [Aguirre, 2004; Fortuna et al,2007].

Esta classificação, muitas vezes, permite uma diferença tênue entre uma abordagem e outra. Alguns autores consideraram metodologias típicas utilizadas em uma modelagem podem ser melhoradas por técnicas de outras. [Fortuna et al, 2007] explica detalhadamente os passos para elaboração de um sensor virtual, aqui resumidos na figura 3.2.

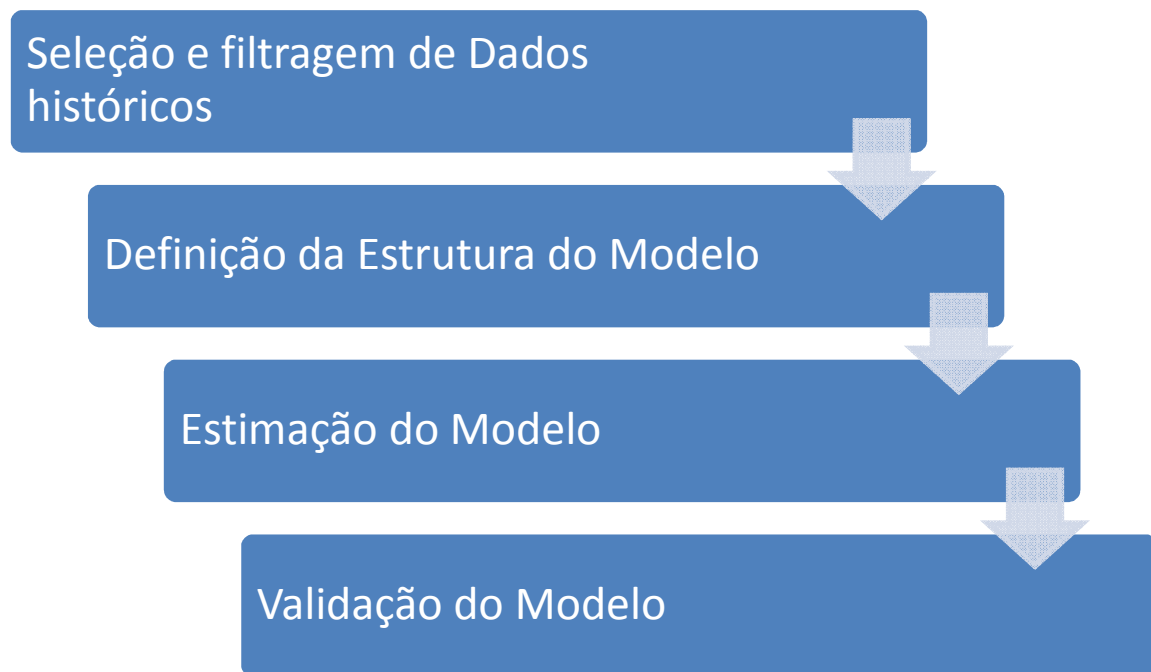


Figura 3.2 Processo de Projeto do sensor virtual

3.2.4. Coleta de Dados de Planta

O banco de dados operacional da planta serve como uma fonte útil de informação, que permitirá a identificação de padrões interessantes no processo, muitas vezes ocultos às análises visuais dos especialistas [Pereira, 2005;Fortuna et al,2007]. O primeiro passo na construção de um modelo é a seleção das variáveis na sua composição. É interessante escolher dados que representem bem a dinâmica do sistema [Branco,2004].

Uma cooperação entre os projetistas do sensor e a equipe de processo é altamente recomendada, pois a experiência da equipe é um importante conhecimento a ser agregado no projeto do sensor. Neste primeiro momento o objetivo é identificar quais variáveis possuem maior relação com a variável que se quer medir. Paralelamente, técnicas de análise dos dados podem ser feitas na busca de padrões entre elas. Tais técnicas podem ser a correlação linear, correlação logarítmica e a análise de componentes principais [Fortuna et al, 2007]. A escolha de dados passados, com atrasos regulares, também é considerada [Branco,2004;Fortuna et al 2007]. A escolha de quantidade de instantes passados para uma variável pode ser determinada da mesma forma, como se o atraso fosse uma variável adicional do modelo [Zanata,2005]. As figuras 3.3 e 3.4 mostram, respectivamente, um gráfico de correlação linear e um gráfico de correlação cruzada.




Figura 3.3 Gráfico de Correlação Linear

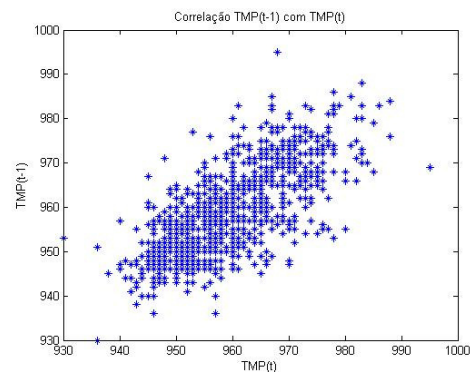


Figura 3.4 Gráfico de Correlação Cruzada

A escolha das variáveis é apenas uma parte da tarefa. Depois de escolher quais tipos de dados serão coletados, a segunda parte é realizar de fato a coleta dos dados. A coleta dos dados requer algum cuidado, pois dados ruidosos, incorretos ou não disponíveis podem propagar falhas durante todo o processo de construção do sensor, afetando sua qualidade [Fortuna et al, 2007].

“A coleta de dados é tarefa fundamental e o projeto do modelo deve considerar dados que representem a dinâmica completa do sistema, quando possível, executando testes na planta. Perturbações de alta frequência também devem ser removidas. Por outro lado, uma investigação cuidadosa dos dados disponíveis é necessária para filtrar dados ruidosos ou defeituosos e dados distantes da faixa de operação devido a falhas na medida ou na transmissão ou a perturbações incomuns. Particularmente, como em qualquer procedimento conduzido por dados, pontos fora de faixa operacional podem ter efeitos indesejados na qualidade do modelo.” (Fortuna et al, 2007 p. 30)

Além disso, os dados disponíveis geralmente são amostras de sinais analógicos, nos quais os especialistas utilizam certos critérios conservativos para corrigir eventuais erros no processo de amostragem [Ogata, 2007; Aguirre, 2004]. As figuras 3.5 e 3.6 mostram, respectivamente um gráfico contendo registros outliers e um gráfico mostrando a distribuição normal dos dados de uma variável.




Figura 3.5 Dados outliers




Figura 3.6 Distribuição normal dos dados

Uma filtragem dos dados é necessária para deixar apenas os dados que representam bem a dinâmica do sistema. O objetivo é eliminar dados que fogem a uma faixa regular de operação (*outlier*), dados incompletos ou ausentes (NaN, NULL, etc.). Algumas regras, dependendo do processo, devem ser definidas na filtragem destes dados.

“Os pontos de fora de faixa operacional podem ser isolados ou aparecer em grupos, até mesmo em intervalos regulares. Pontos isolados são geralmente interpolados, mas a interpolação não faz sentido quando grupos de pontos outliers consecutivos são detectados. Neste caso, eles precisam ser removidos e o conjunto de dados originais deve ser dividido em blocos para se manter a seqüência temporal correta entre eles, que é necessária para identificar corretamente os modelos dinâmicos. Obviamente, este é o caso com modelos estáticos, que requerem apenas as amostras correspondentes para as variáveis restantes a serem removidas.” (Fortuna et al, 2007 p.31)

Em [Fortuna et al,2007], são apresentadas algumas propostas para se filtrar os dados:

3.2.4.1 REGRA 3SIGMA

Nesta regra, são eliminados os dados que fogem a uma janela de até 3 vezes o desvio padrão da média da variável.

$$d_i = \frac{x_i - E[x]}{\sigma_i} \quad (3.1)$$

onde x_i é valor da variável x no tempo i , $E[x]$ é a média da variável, σ_i é o desvio padrão, e d_i é a distância ponderada do ponto x_i à media da variável de acordo com o desvio padrão.

Esta técnica é utilizada para se detectar pontos fora de faixa de operação, pois uma distância maior do que 3, que corresponde a uma probabilidade de 0,27% assumindo-se

uma distribuição normal dos dados, são considerados dados inadequados à construção do modelo [Fortuna et al,2007].

3.2.4.2 ANÁLISE DE COMPONENTES PRINCIPAIS

O objetivo desta técnica é reduzir o conjunto de dados, que pode possuir dados compostos, correlacionados entre si em dados não correlacionados, ordenados por variabilidade decrescente. As variáveis transformadas são combinações lineares das originais e as últimas podem ser removidas com uma perda mínima de informação [Fortuna et al, 2007].

O primeiro passo consiste na centralização e na normalização para escalar os dados, que normalmente podem ser números muito grandes e assim representá-los por números menores [Smith,2002]. É construída uma matriz P, que contem os autovetores da matriz de covariância C:

$$C_X = X^T X \quad (3.2)$$

$$X = T P^T \quad (3.3)$$

onde X é o conjunto de dados original escalado e normalizado e T é o conjunto de dados com as componentes principais.

Detalhamento dessa técnica pode ser consultado em [Fortuna et al 2007] e [Smith, 2002]. O efeito causado por uma Análise de Componentes Principais pode ser visualizado nos gráficos das figuras 3.7 e 3.8.




Figura 3.7 Gráfico de Correlação entre os pontos das variáveis X e Y, reagrupadas nas componentes principais P1 e P2




Figura 3.8 Mesmo gráfico, porém com eixos orientados aos coeficientes de correlação mostrando que a componente principal p2 pode ser representada por p1 que possui melhor qualidade de informação

3.2.4.3 ANÁLISE DE CORRELAÇÃO LINEAR

A correlação Linear consiste em detectar quais variáveis possuem maior influência em outras, de acordo com seu coeficiente de correlação. Quando há um coeficiente de correlação próximo a -1 ou 1, é possível visualizar graficamente que uma variável tem efeito em outra. Caso contrário, nota-se que ambas possuem correlação fraca, sem parecer interferir uma na outra, conforme pode ser visto na figura 3.9.

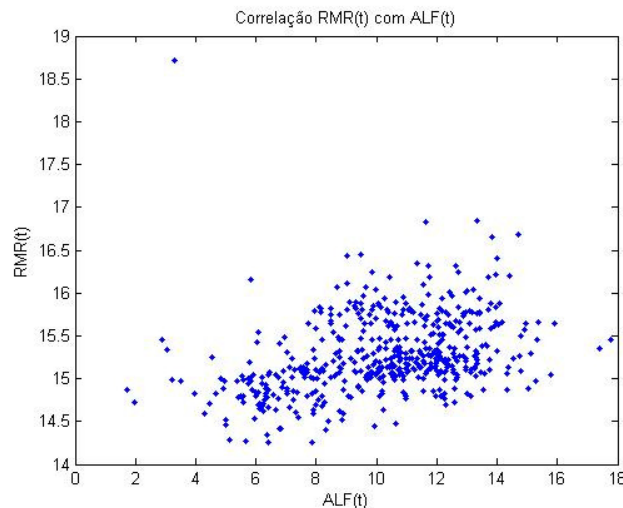


Figura 3.9 Gráfico de Correlação entre duas variáveis. Nota-se a presença de outliers.

Normalmente, se faz um estudo de correlação linear dos dados quando se quer identificar as variáveis que irão compor o modelo. Na identificação de sistemas, as variáveis que apresentarem maior coeficiente de correlação com a variável de saída são preferenciais para serem escolhidas por apresentarem numericamente uma melhor relação com a variável de saída [Aguirre,2004].

3.2.4.4 NORMALIZAÇÃO

Também é necessária uma normalização nos dados, a fim de se diminuir as magnitudes de algumas variáveis. Isto é obtido através da normalização dos dados, que pode ser feita de duas formas [Fortuna et al,2007].

3.2.4.4.1 Normalização min-max

Esta normalização considera uma faixa regular de operação, na qual os dados todos são reescalados entre valores menores, geralmente entre -1 e 1 [Fortuna et al, 2007.: O cálculo é dado pela equação:

$$x' = \frac{x - \min_x}{\max_x - \min_x} (\max_{x'} - \min_{x'}) + \min_{x'} \quad (3.4)$$

onde x' é a variável normalizada, \min_x e \max_x são respectivamente os valores mínimo e máximo da variável x e $\min_{x'}$ e $\max_{x'}$ são os valores mínimo e máximo da variável normalizada.

3.2.4.4.2 Normalização z-score

Esta normalização acontece quando uma quantidade muito grande de pontos fora da faixa é suspeitada, pois ela é baseada na média e no desvio padrão da variável. O cálculo é efetuado pela equação:

$$x' = \frac{x - E[x]}{\sigma_x} \quad (3.5)$$

onde x' é a variável normalizada, $E[x]$ é a média da variável e σ_x é o desvio padrão da variável.

Após a aplicação de vários filtros, os dados finais resultantes podem ser considerados mais fiéis a estruturação do modelo. Porém, uma reaplicação dos filtros as vezes pode ser necessária se for considerada uma nova consulta a base de dados.

3.2.5. Escolha da Estrutura do Modelo

A estrutura genérica do sistema é um bloco contendo conjuntos de variáveis de entrada e saída.




Figura 3.10 Representação do modelo de sistema

Assim como qualquer sistema, o modelo pode ser descrito por meio de equações de diferença ou função de transferência, considerando ou não entradas exógenas [Fortuna et al, 2007]:

$$A(z^{-1})y(t) = z^{-d} \frac{B(z^{-1})}{F(z^{-1})} u(t) + \frac{C(z^{-1})}{D(z^{-1})} e(t) \quad (3.6)$$

$$y(t) = G(z^{-1})u(t) + H(z^{-1})e(t) \quad (3.7)$$

onde A , B , C , D e F são vetores (ou matrizes no caso de sistemas MIMO), z é a variável complexa que atua como operador de atraso, e d é o atraso natural entre a entrada e saída. Na equação 3.7, G e H são funções de transferência.

A determinação de qual estrutura utilizar para se construir o modelo depende de vários fatores, sendo que a mesma pode ser feita empiricamente, ou seja, pela tentativa e erro. Com a utilização de recursos de computação atualmente disponíveis, é possível testar várias estruturas de modelo.

Quando se trata de estruturas lineares, há várias técnicas de identificação disponíveis para utilização: Mínimos Quadrados, Média Móvel entre outras [Aguirre, 2004]. Porém, quando se trata de estruturas não-lineares, existem técnicas para identificação não lineares, mas podem ser usadas técnicas computacionais inteligentes, assunto do próximo capítulo.




Figura 3.11 Representação modelo não linear com atraso

As técnicas comumente utilizadas para esse tipo de modelagem são os modelos NARMAX, redes neurais, fuzzy e neuro-fuzzy. Existem estratégias baseadas em uma modelagem híbrida combinando duas ou mais técnicas [Branco, 2004; Pereira, 2005]. Sobre a modelagem baseada em redes neurais, Zanata menciona:

“Sensores virtuais vem sendo desenvolvidos empregando, em sua maioria, tecnologia baseada em redes neurais artificiais,.... Fato este pode ser explicado devido aos resultados superiores apresentados pelas redes neurais, tanto na maior precisão e acuidade na estimação dos valores, como pela capacidade superior no reconhecimento de padrões em sistemas complexos, não-lineares e com atrasos.” (ZANATA, 2005, p. 17)

Assim que a estrutura do modelo é escolhida, é necessário descobrir os seus parâmetros. Em modelos não lineares baseados em redes neurais, isto é feito através do treinamento do modelo. Os algoritmos de treinamento de Redes Neurais Artificiais serão abordados no capítulo 4.

3.2.6. Validação do Modelo

A parte final da modelagem é a validação do modelo. Uma abordagem comum utilizada para validação é testá-lo com dados diferentes dos que foram usados na sua construção. Se os resultados forem próximos do esperado, significa que o sensor funcionou com sucesso e está pronto para ser utilizado em operação. Caso contrário, alguns ajustes ainda devem ser feitos, seja na estrutura do modelo, ou nos parâmetros do treinamento.

Há casos em que a validação do modelo pode se tornar complexa, a medida que o modelo se torna maior e não linear. A cooperação com o pessoal de processo nesta fase também pode ser muito útil [Fortuna et al,2007]. Problemas comuns que ocorrem na validação podem ser decorrentes da uma construção mal elaborada ou com dados de treinamento mal escolhidos.

Uma estratégia comum consiste em separar os dados em pelo menos três grupos:

- **Dados para construção do modelo:** Cerca de 65 a 75%. Estes dados devem representar bem a dinâmica do sistema e o sistema deve prever tais dados dentro de um possível intervalo. Não é bom que a previsão seja 100% igual ao modelo para não comprometer a capacidade de generalização do sensor.
- **Dados para teste do modelo:** Cerca de 10 a 15%. Tais dados são utilizados para testar o desempenho do modelo durante sua construção. Enquanto houver um erro alto no seu teste, a construção continua.
- **Dados para validação:** Cerca de 15 a 20%. Quando o modelo for finalizado, o mesmo deve ser validado por um conjunto de dados pré-definido. Estes dados, assim como os de construção, devem representar bem a dinâmica do sistema.

Basicamente, duas formas de se validar quão certas estão as previsões do modelo: o erro médio quadrático e a taxa de acerto [Haykin, 1999]. O erro médio quadrático é definido através da função custo, que mostra o erro médio de todas as medidas.

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.8)$$

onde e_j é o erro de cada estimacão do sensor e $\varepsilon(n)$ é o erro global. Um menor valor de $\varepsilon(n)$ significa um sensor virtual com previsões e estimacões mais exatas.

O erro médio quadrático representa a precisão do sensor. Nos casos em que há uma faixa aceitável de erro de medida, é interessante verificar quantas previsões estão dentro

dessa faixa, para isso é melhor exibir o desempenho do modelo através da taxa de acerto. Ela é determinada pelo número de previsões cujo erro é menor do que a margem estabelecida.

3.2.7. Validação do Sensor Virtual

As vezes o modelo pode funcionar bem para determinadas situações, porém nem sempre o erro é eliminado adequadamente. Uma estratégia para minimizá-lo é adicionando redundâncias [Zanata, 2005]. A validação do sensor virtual envolve a disponibilização e outras medidas da mesma variável, assim há uma “avaliação” da inferência do sensor virtual.

3.2.8. Ajustes e Melhoramentos

Se os resultados fornecidos pelo sensor virtual não forem satisfatórios, dependendo de quão inexata for a previsão do sensor, o projeto deve voltar à modelagem do sensor, seja na escolha de variáveis, dados ou o treinamento. Os erros mais comuns são:

3.2.8.1 NÃO GENERALIZAÇÃO

Quando o treinamento for muito forte, cujo erro mínimo aceitável for muito baixo, a previsão do sensor será muito adaptada ao conjunto de treinamento (figura 3.12). É recomendável manter um erro não muito baixo, para que o sensor possa ser generalizado.

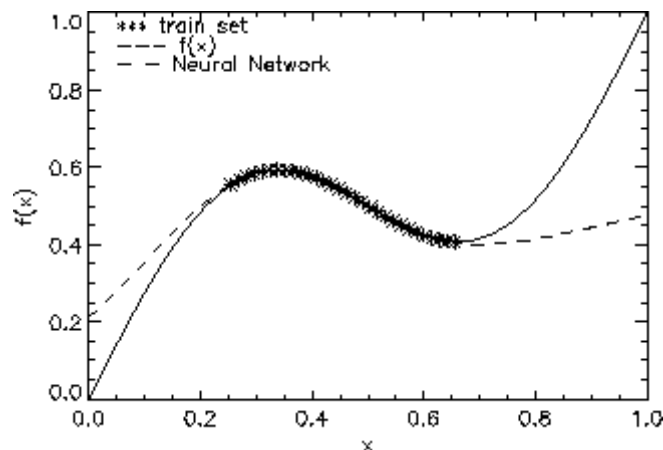


Figura 3.12 Gráfico mostrando a não generalização da Rede para dados que não foram treinados.

3.2.8.2 ERRO ALTO

O sensor está preparado para responder aos dados de treinamento, mas na validação os erros são muito altos (figura 3.13), além da janela de operação recomendável pela equipe de processo. Mudanças na sua estruturação devem ser consideradas, incluindo a quantidade de regressores e até o tipo de técnica a ser utilizado [Fortuna et al, 2007;Zanata,2005].




Figura 3.13 Gráfico mostrando que o erro das medições está alto.

3.2.8.3 PREVISÕES FORA DA FAIXA NORMAL OU ERRO ESPÚRIO (PICOS)

O sensor pode prever com sucesso boa parte dos dados, mas existem alguns picos, que provavelmente foram originados a partir de dados que não foram previstos durante o treinamento (figura 3.14). Uma análise do gráfico pela equipe de processo pode determinar uma mudança no treinamento ou na nova separação dos conjuntos de dados.

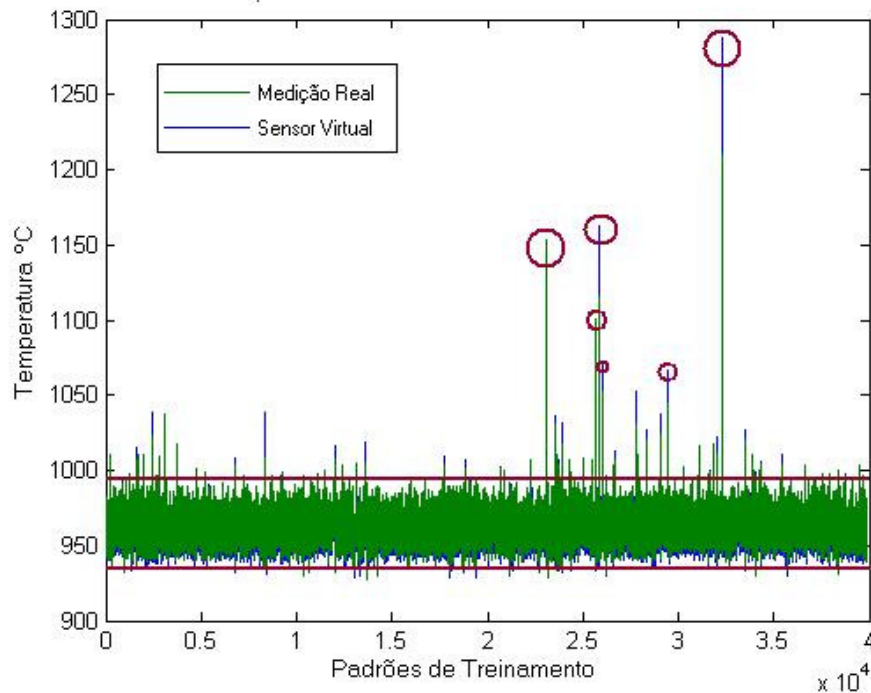


Figura 3.14 Gráfico contendo dados não previstos fora da faixa normal

Há uma classe de erros, porém, que é difícil de ser detectado, que são aqueles que ocorrem na ausência de dados disponíveis. Um exemplo é quando um sensor virtual é utilizado para aferir o valor de uma variável em intervalos de tempo menores, mas cujas medições são feitas em intervalos de tempo maiores. Se uma previsão for errada e não houver medição para comprovar a eficácia do sensor, o erro passará despercebido [Zanata, 2005].

Entretanto, algumas estratégias têm sido utilizadas para se detectar estes tipos de erros [Zanata, 2005]. O sensor virtual pode funcionar com outros em paralelo, treinados com dados diferentes, mas testados com os mesmos dados. Assim, quando um sensor previsse um dado diferente dos demais, a estimativa seria considerada errada.

Periodicamente o sensor virtual é retreinado com dados mais atuais, assim alterações na forma de operação da planta são logo inseridas no modelo novo, ficando este atualizado.

O objetivo dos ajustes é reencontrar uma configuração na qual o sensor opere de modo satisfatório. Há, porém, casos em que isto não é possível [Fortuna et al,2007], normalmente modelos e sistemas não determinísticos ou processos cujo conhecimento ainda é incompleto. Os sensores virtuais podem ser úteis apenas em casos cujas variáveis de processo sejam totalmente identificadas e em sistemas determinísticos [Zanata, 2005].

3.3. IMPLEMENTAÇÃO E INTEGRAÇÃO DE SENSORES VIRTUAIS COM APLICAÇÕES

Ao se testar e validar um sensor virtual, o mesmo está pronto para ser inserido no meio de produção. Sua implementação, embora seja simples, requer algumas exigências:

3.3.1. Memória

O Hardware deve possuir o mínimo de memória necessário para armazenar os parâmetros do sensor. Tais parâmetros são o fator determinante da exatidão das medições do sensor virtual. Qualquer alteração ou mudança não desejável neles comprometerá o desempenho do sensor virtual.

3.3.2. Linguagem de Programação

Dependendo do tipo de abordagem utilizada na construção do sensor virtual, o mesmo só poderá ser implementado em determinados tipos de linguagem de programação. Por exemplo, uma rede neural só pode ser implementada em uma linguagem imperativa

como C++, C# e Java. Se for necessário e houver suporte, é cogitada a possibilidade de utilizar uma máquina virtual para executar o sensor.

3.3.3. Padronizações

Com o surgimento de padrões e protocolos de controle industrial, o sensor virtual deve estar preparado para conversar sob este padrão. Um padrão conhecido de comunicação é o OPC.

3.3.4. Contexto da Aplicação

Há casos em que o sensor virtual é construído para funcionar como um dispositivo de backup ou de substituição eventual de algum sensor físico. O programa no qual ele é implementado deve estar preparado para se comunicar com os demais dispositivos elementos do processo.

3.3.5. Tolerância a falhas

Como todo software está sujeito, o sensor deve estar preparado para responder satisfatoriamente contra falhas no hardware ou no software em nível de sistema operacional.

3.4. CONSIDERAÇÕES FINAIS

Concluindo, o projeto de um sensor virtual deve considerar também as limitações do hardware e do sistema no qual ele estará inserido, pois tais exigências podem inviabilizar a sua utilização. No capítulo seguinte, será abordada a técnica de computação inteligente a ser utilizada neste trabalho, explorando suas vantagens e reforçando sua utilização.

4. REDES NEURAIS ARTIFICIAIS

Inspirados pelo cérebro humano, alguns pesquisadores começaram a investigar estruturas que processam informações paralelamente, havendo uma forte interação entre elas. Neste paradigma conexionista, alguns trabalhos foram desenvolvidos, alguns deles mostrando que, assim como o cérebro, estas mini-estruturas denominadas neurônios artificiais podem realizar certos processamentos muito mais rapidamente do que computadores digitais como o reconhecimento de padrões [Haykin,1999].

Este capítulo apresenta as características das redes neurais, suas arquiteturas e algoritmos de treinamento, oferecendo uma visão geral de como é seu funcionamento e quais suas aplicações.

4.1. CARACTERÍSTICAS

Uma Rede Neural Artificial é constituída basicamente de dois tipos de elementos: Neurônios e Sinapses. Os Neurônios são unidades processadoras simples constituídas de um somador, um bias e uma função de ativação. Sua representação esquemática é mostrada na figura 4.1.




Figura 4.1 Neurônio Artificial

Cada neurônio possui apenas uma saída, mas pode ter várias entradas. Estas são processadas pelo neurônio artificial e seu resultado é propagado para demais neurônios na Rede Neural. O *bias* introduz uma variação no sinal do neurônio, independente das entradas. A presença da função de ativação é importante, pois reproduz um comportamento de não-linearidade inerente aos modelos que a Rede Neural busca emular [Haykin,1999;Aguirre,2004]. Algumas funções de ativação utilizadas estão apresentadas na tabela 4-1.

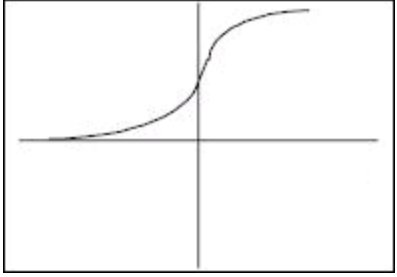
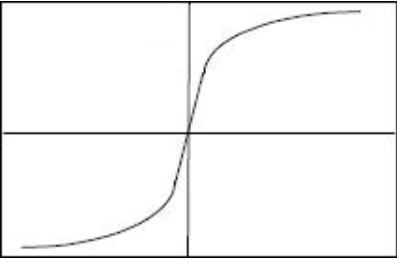
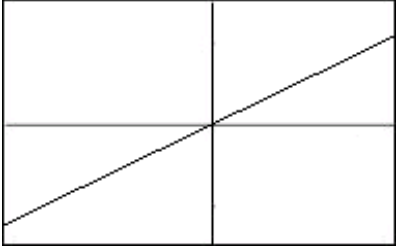
<i>Função</i>	<i>Fórmula</i>	<i>Gráfico</i>
Sigmoide	$\text{Sigmóide}(x) = \frac{K}{(1 + e^{-\rho x})}$	
Tangente Hiperbólica	$\text{Tanh}(x) = K \frac{(1 - e^{-\rho x})}{(1 + e^{-\rho x})}$	
Linear	$\text{Linear}(x) = Kx$	

Tabela 4-1 Funções de Ativação comuns

As ligações entre os neurônios são as Sinapses, também conhecidas como Pesos. Elas atuam de forma amplificadora ou atenuadora do sinal, modificando a saída de um neurônio até a entrada de outro. Tais pesos representam o chamado conhecimento da Rede. Eles são os coeficientes que podem fazer com que as saídas da Rede respondam de modo satisfatório para um certo conjunto de entradas [Haykin,1999; Shlens, 1999].

4.2. ARQUITETURAS

As Redes Neurais podem ter seus elementos (Neurônios e Pesos) dispostos de acordo com o seu propósito. Mais adiante, será visto que o fator determinante na arquitetura de uma rede neural é o seu algoritmo de treinamento [Haykin,1999; Santos, 2008]. De maneira geral, há três classes de arquiteturas de redes neurais:

4.2.1. Redes *Feedforward* Monocamadas

Nesta arquitetura, os neurônios estão organizados paralelamente formando uma camada, tal como pode ser visto na figura 4.2.

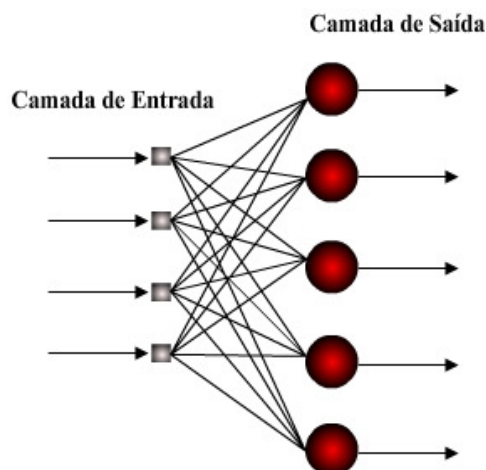


Figura 4.2 Rede monocamada

Os nós de entrada da rede recebem e enviam os sinais de entrada para os neurônios dispostos na camada. Estes por sua vez realizam o processamento destes sinais fornecendo-os à saída da Rede.

Algumas Arquiteturas que fazem parte desta categoria são os Perceptrons, Adaline e os mapas auto organizadores como o Kohonen [Haykin, 1999; Soares, 2006; Moreno, 2008].

4.2.2. Redes *Feedforward* Multicamadas

Nesta categoria, se encontram redes cuja organização de seus neurônios é feita em mais de um nível, em múltiplas camadas. Uma camada corresponde à disposição paralela de vários neurônios recebendo um mesmo conjunto de dados de entrada. Em geral, existem três tipos de camadas nesta topologia.

- **Camada de Entrada:** Recebe os sinais de entrada e envia-os para a próxima camada
- **Camada Escondida:** Recebe sinais da camada anterior, os processa e envia para a próxima camada
- **Camada de Saída:** Fornece os dados de saída da Rede.

É importante ressaltar que esta topologia permite que o fluxo dos sinais seja apenas em um sentido, das camadas de entrada até a camada de saída, daí o nome feedforward.

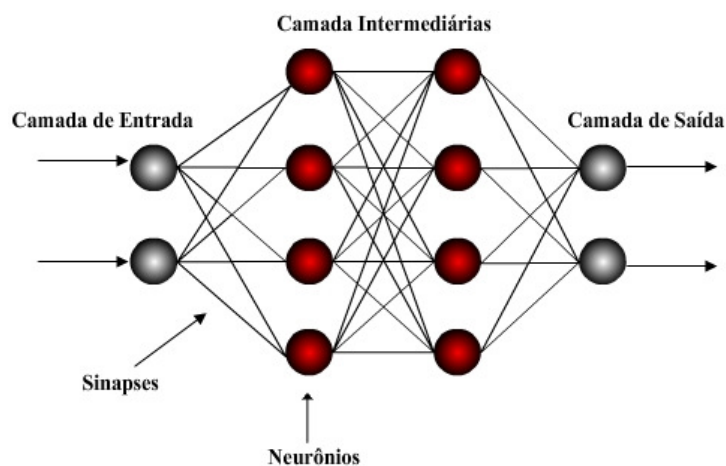


Figura 4.3 Topologia de redes neurais multicamadas

Cada camada possui um conjunto de pesos atribuídos a cada ligação entre os neurônios, sendo que estes são ajustados de acordo com o algoritmo de treinamento. A adição de mais camadas à rede neural traz como benefício a possibilidade de se representar modelos de ordem superior, fato que não é possível com arquiteturas monocamadas [Haykin, 1999]. Também é comprovado que quanto maior o número de neurônios, melhor capacidade de aprendizado uma rede neural vai possuir, contudo o número de ligações tende a aumentar de forma exponencial, dificultando e tornando muito complexo o treinamento.

4.2.3. Redes Recorrentes

Uma rede recorrente é aquela que permite uma realimentação (*feedback*) entre os neurônios. Uma rede recorrente com apenas uma camada possui uma ligação entre a saída dos neurônios às entradas deles mesmos, conforme visualizado nas figura 4.4 e 4.5.




Figura 4.4 Rede Recorrente monocamada




Figura 4.5 Rede Recorrente multicamada

Este tipo de rede possui a capacidade de modificar seu aprendizado de acordo com informações passadas. É útil quando o conjunto de dados a ser utilizado está organizado temporalmente, e assim é possível reconhecer padrões variantes no tempo [Shlens, 1999; Haykin, 1999; Zanata, 2005].

Como exemplos desta arquitetura se destacam as Redes de Elman (figura 4.6) e Hopfield (figura 4.7).

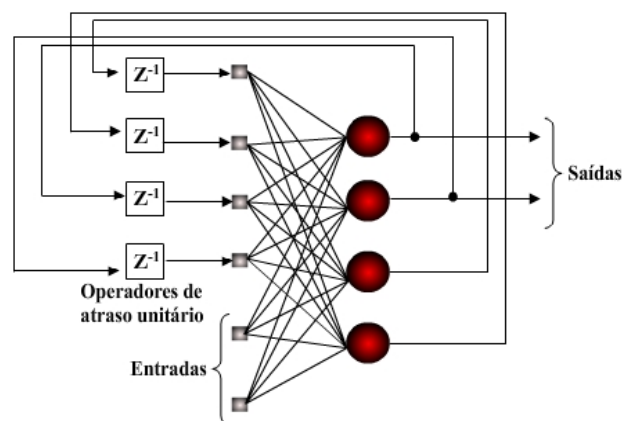


Figura 4.6 Rede de Elman




Figura 4.7 Rede de Hopfield

4.3. APRENDIZADO

Cada arquitetura possui seus prós e contras, cada uma tendo uma utilidade para determinada classe de problema [Haykin,1999;Demuth et al, 2008]. Normalmente as classes de problema que a Rede Neural se propõe a resolver envolvem reconhecimento de padrões, modelagem de sistemas complexos ou emulação e simulação. Para todos os propósitos, a Rede contará com uma experiência já adquirida na forma de dados armazenados. Cada conjunto de dados representa um conhecimento. Como a Rede vai conseguir reproduzir esse conhecimento é o processo chamado de aprendizado.

O aprendizado corresponde à maneira de como a Rede Neural vai adaptar seus coeficientes (pesos) para se conseguir um objetivo, conforme ilustrado na figura 4.8.

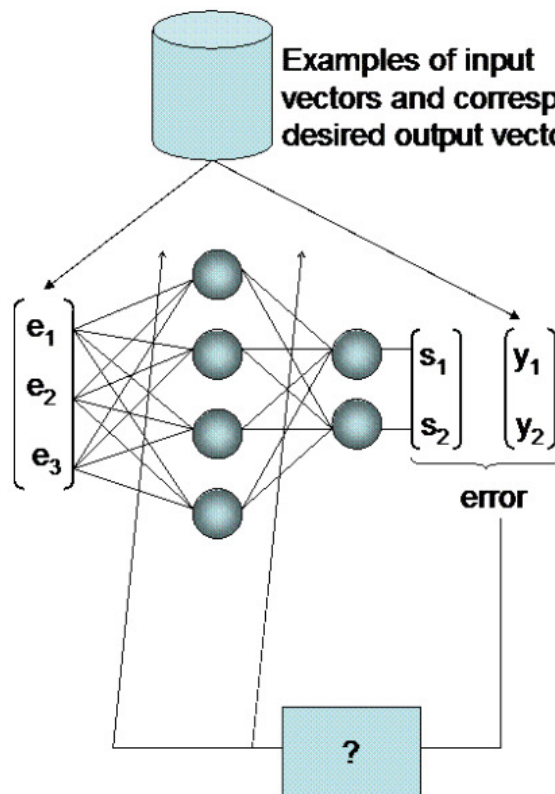


Figura 4.8 Representação Esquemática de um Aprendizado

O conhecimento o qual se deseja que a Rede Neural reproduza são os dados que serão alimentados à sua entrada. A resposta da Rede, que inicialmente será inadequada, vai se alterar ao longo do período de aprendizado, evoluindo para a resposta desejada.

Computacionalmente, o aprendizado é implementado na forma de algoritmos de treinamento [Demuth et al, 2008], que são baseados nas técnicas de otimização. Estes algoritmos compartilham variáveis comuns como:

- Entradas (x_i) e Saídas (y_i) da Rede;
- Pesos (w_{ij}) e *Bias* (b_i) dos Neurônios da Rede;
- Saída desejada (y_i^t), no caso de aprendizado supervisionado.

O algoritmo possui alguns parâmetros de execução que determinam a condição de parada:

- Número máximo de épocas de treinamento (n);
- Erro global mínimo aceitável (ϵ) no caso de aprendizado supervisionado;
- Taxa de aprendizado (η).

Há duas classes de aprendizado, supervisionado e não supervisionado.

4.3.1. Aprendizado Supervisionado

Quando se é conhecida a resposta desejada, o aprendizado é considerado supervisionado, tendo a resposta desejada como um tutor supervisor que vai avaliar o quão próximo do desejável está a Rede Neural.

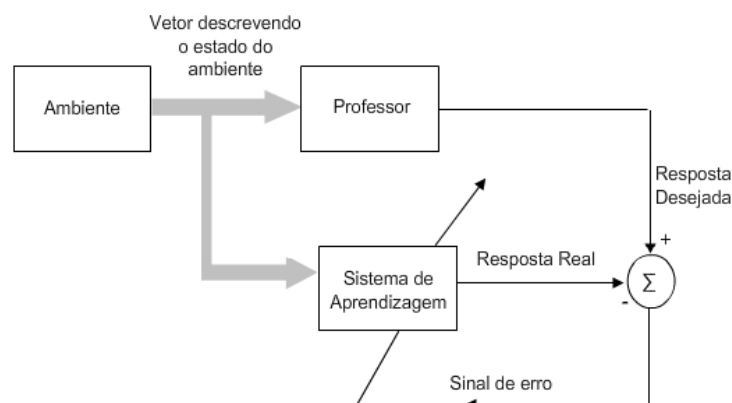


Figura 4.9 Aprendizado supervisionado

Existem atualmente, muitos algoritmos de treinamento implementados nas ferramentas de desenvolvimento, alguns deles são:

- Gradiente Descendente
- Backpropagation
- Levenberg-Marquadt
- Regularização Bayesiana

Entretanto todos eles seguem um mesmo princípio que é otimizar a função custo (eq. 4.2), que representa o quão próximo a Rede está do seu objetivo.

$$e(t) = d(t) - y(t) \quad (4.1)$$

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.2)$$

O que muda de um algoritmo para o outro é a forma como o peso é atualizado. Como a implementação e o propósito de cada algoritmo são parecidos, serão apresentados aqui 2 algoritmos, ficando os outros como leitura recomendada para aprofundamento no assunto.

4.3.1.1 ALGORITMO BACKPROPAGATION

O que motivou o desenvolvimento de novos algoritmos foi o surgimento do algoritmo de retropropagação do erro (Backpropagation) na década de 1980 [Rumelhart,1986].

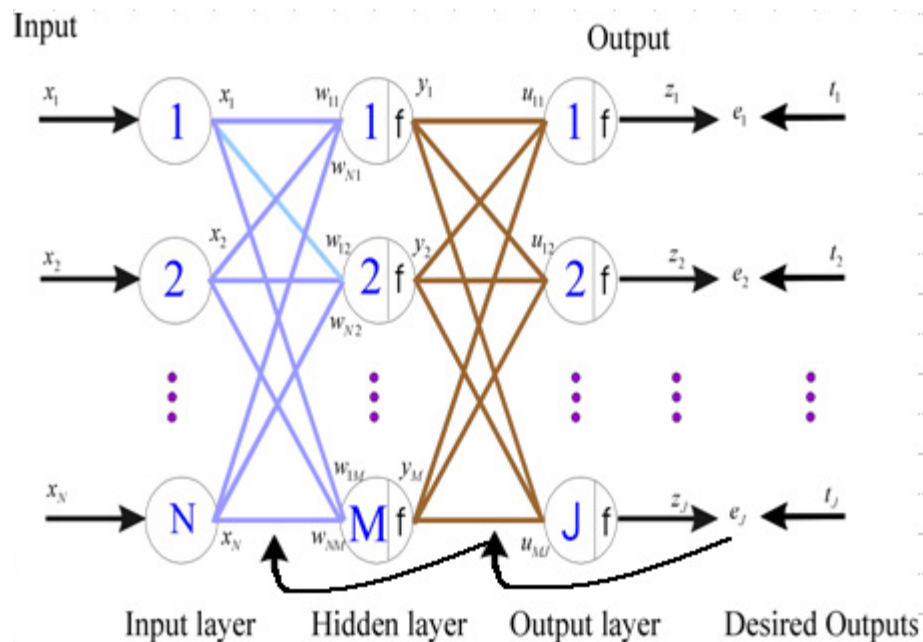


Figura 4.10 Retropropagação do erro

Consiste em duas fases: na primeira, a rede recebe os dados de entrada, processa-os de camada em camada em direção a camada de saída, e na segunda o desempenho da Rede é avaliado e o ajuste dos pesos é feito de forma contrária, ou seja, da camada de saída à camada de entrada. Isto é assim porque a atualização do peso depende de um valor de erro que esteja diretamente relacionado com a saída do neurônio de onde o peso deve ser atualizado.

$$w_{ij}^k(t+1) = w_{ij}^k(t) - \eta \sigma_j^k x_i^k \quad (4.3)$$

onde:

- k é a camada da rede
- w_{ij}^k é o peso que liga a entrada i ao neurônio j da camada k

- x_i^k é a entrada i da camada k
- σ_j^k é o valor da retropropagação do erro no neurônio j da camada k

O valor da retropropagação é dado por:

$$\sigma_i^k = -(y_j - y_j) \cdot \frac{\partial f_i^{k-1}}{\partial net_i^{k-1}} \quad (4.4)$$

para a camada de saída e

$$\sigma_i^k = \sum_{j=1}^M w_{ij}^{k+1} \sigma_j^{k+1} \quad (4.5)$$

para as demais camadas, onde:

- f_i^{k-1} é a função de ativação do neurônio i da camada $k-1$
- net_i^k é definido na equação

$$net_i^k = \sum_{i=1}^m w_{ji}^k x_i \quad (4.6)$$

Um problema que este algoritmo enfrenta é o mínimo local [Soares, 2006]. Durante o seu aprendizado, o desempenho da Rede Neural evolui de forma que seu erro diminui conforme os pesos vão se ajustando. No entanto, há casos em que uma combinação de pesos leva o desempenho da rede a um ponto, cuja direção de otimização é indefinida ou não existe, o chamado mínimo local, mostrado na figura 4.11.

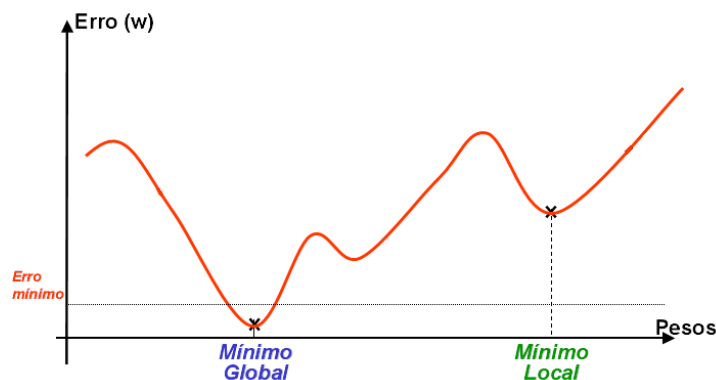


Figura 4.11 Mínimo local

Para se evitar esse problema, um parâmetro é inserido no algoritmo de forma a levar o peso a um ponto mais para fora desta “cavidade”.

$$\mu_i^k = \beta (w_{ij}^k(t) - w_{ij}^k(t-1)) \quad (4.7)$$

onde β é taxa de momento, geralmente entre 0 e 1.

Com o uso do Momentum, a atualização dos pesos muda para a equação:

$$w_{ij}^k(t+1) = w_{ij}^k(t) - \eta \sigma_j^k x_i + \mu_i^k \quad (4.8)$$

O algoritmo *backpropagation* é utilizado somente em redes do tipo *feedforward* multicamadas [Haykin, 1999].

4.3.1.2 ALGORITMO DE LEVENBERG-MARQVARDT

Este é considerado uma evolução do *backpropagation*, uma vez que ele acelera sua execução. Todo algoritmo de treinamento evolui de forma parecida, mas este algoritmo apresenta um desempenho muito bom logo no início de sua execução, conforme visto na figura 4.12.

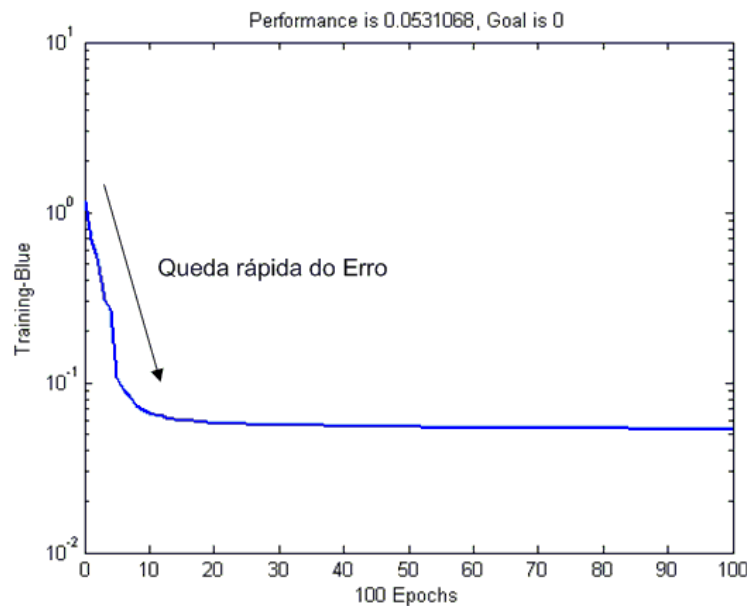


Figura 4.12 Queda rápida do erro

Este se baseia no método de otimização de Newton, que inclui o cálculo da matriz Hessiana:

$$H = J^T J \quad (4.9)$$

e o gradiente pode ser calculado como:

$$g = J^T e \quad (4.10)$$

onde J é a matriz Jacobiana que contém a primeira derivada dos erros da rede com os respectivos pesos e bias e e é o vetor de erros da rede. A matriz Jacobiana é obtida pelo maio do Backpropagation padrão.

O Levenberg-Marquardt usa esta aproximação Quase-Newton para a matriz Hessiana com a seguinte atualização:

$$x_{k+a} = x_k - [J^T . J + \mu I]^{-1} J^T . e \quad (4.11)$$

onde I é a matriz identidade e μ é um fator de estabilização do treinamento, correspondente a taxa de aprendizado.

Quando o fator μ é zero, este é o Método de Newton e usa a aproximação da matriz Hessiana. Por outro lado, quando μ é grande, isto faz com que o gradiente descendente sofra um pequeno incremento a cada passo. Alves em seu trabalho [Alves, 2008] resume:

“Então, de fato, μ serve de fator de estabilização do treinamento, pois ele diminui depois de cada passo bem sucedido, implicando na redução do erro, e só é aumentado quando o erro aumentar. Portanto, o erro sempre é diminuído a cada época de treinamento.” (ALVES, 2008 p. 23)

Apesar de seu desempenho bom, sua execução poderá se tornar lenta ao se utilizar em redes com muitos parâmetros.

4.3.2. Aprendizado Não-Supervisionado

Para problemas de classificação ou de reconhecimento de padrões, onde não há uma resposta bem definida para cada entrada da rede, os algoritmos de treinamento não supervisionados são indicados. Embora não haja uma regra para se definir uma saída desejada para a rede neural, o algoritmo deve levar em conta a distribuição dos dados de entrada em um espaço multidimensional, no qual pontos próximos produzem a mesma saída ou saídas parecidas, que ao longo do tempo são ajustadas de forma a representarem melhor suas zonas de classificação.

O algoritmo de treinamento não supervisionado mais conhecido é o utilizado em redes neurais de mapas auto organizadores Kohonen mostrados na figura 4.13.




Figura 4.13 Visualização do Efeito dos Mapas Auto organizadores Kohonen

Outro tipo de Rede no qual o aprendizado não supervisionado pode ser útil é a Rede de Base Radial, mostrada na figura 4.14.




Figura 4.14 Rede com Funções de Base Radial (Radial Basis Function)

Nesta, a rede é dividida em basicamente duas camadas, as quais são utilizadas para propósitos diferentes. A camada competitiva classifica a entrada de acordo com uma função de base radial (figura 4.15).




Figura 4.15 Função de Base Radial

Na camada seguinte o treinamento é supervisionado, já que para este tipo de rede haverá uma saída desejada. A diferença é que a entrada sofre um tipo de classificação.

Há muitas outras classes de aprendizado e de redes neurais conhecidas [Haykin, 1999], ficando recomendada a leitura das referências para mais informações.

4.4. PROJETO DE REDE NEURAL

Para o projeto de uma Rede Neural, é necessário primeiramente definir qual a classe de problema está sendo lidada. As redes neurais se propõem a resolver os seguintes problemas, entre outros:

- Aproximação de Funções
- Previsão de Séries Temporais
- Classificação e Reconhecimento de Padrões

Para cada classe de problema, existe um tipo de aprendizado e uma arquitetura de rede recomendada [Haykin,1999].

Escolhendo-se a arquitetura, a estrutura da Rede pode ser desenhada. Nesta são definidas quantas camadas a Rede possuirá, quantos neurônios em cada camada haverá e quais as funções de ativação em cada neurônio (ou em cada camada de neurônios).

Tendo escolhida a estrutura da Rede, o próximo passo é escolher a forma de inicialização dos pesos e o algoritmo de treinamento a ser utilizado e seus parâmetros. Deve ser escolhido também, dependendo do conjunto de dados do treinamento qual deve ser a função custo que medirá o desempenho da rede. Pode-se optar por fazer um treinamento do tipo batch ou do tipo online [Haykin,1999]. O projeto da Rede Neural é resumido na figura 4.16.

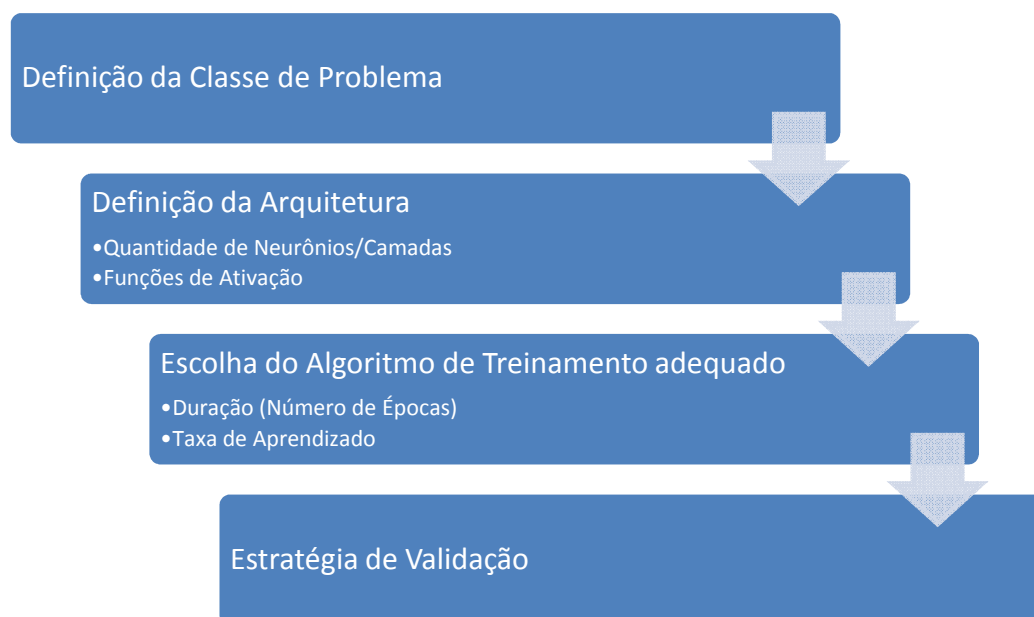


Figura 4.16 Sequencia de passos do projeto de Rede Neural

O projeto da Rede Neural ainda envolve uma validação por parte do treinamento, conforme o seu desempenho. Às vezes, certo treinamento se comporta de forma inadequada para um conjunto de dados, fazendo com que a Rede não consiga convergir para uma solução.

Se for preciso, ajustes podem ser feitos na estrutura da Rede ou nos parâmetros do treinamento. Por exemplo, se um problema não se converge a uma solução, é recomendável aumentar o número de neurônios ou camadas, se for viável computacionalmente. É comum que alguns treinamentos demorem um tempo muito longo para ser concluído, fazendo com que a Rede Neural fique estagnada e o erro mínimo até nunca seja alcançado. Pode se diminuir o tamanho do conjunto de dados, pois muitos dados, mal representados podem causar *overhead* na Rede Neural, fazendo com que ela não aprenda [Haykin,1999].

4.5. CONSIDERAÇÕES FINAIS

Neste capítulo, foram apresentadas as Redes Neurais Artificiais, seus conceitos, finalidades, vantagens em se utilizá-las e quais classes de problemas são adequados.

No capítulo seguinte será visto como foram aplicadas as Redes Neurais no projeto do Sensor Virtual de Temperatura, qual a metodologia empregada, e como foi implementado.

5. PROJETO DO SENSOR VIRTUAL DE TEMPERATURA

Tendo já apresentado nos capítulos anteriores os conhecimentos necessários para o desenvolvimento deste trabalho, este capítulo mostra em si o projeto do Sensor Virtual de Temperatura dos Fornos. É apresentada a estrutura operacional da Empresa, que foi a empresa que subsidiou a construção do sensor, e os processos administrativos que tiveram alguma influência no projeto do Sensor.

5.1. A EMPRESA

A pesquisa foi realizada em uma empresa brasileira de capital fechado, internacionalmente reconhecida pelos padrões de qualidade do metal produzido. Até 2007, data da pesquisa, a empresa possuía certificações internacionais ISO 9001, ISO 14001, OHSAS 18001 e SA 8000 para seus Sistemas de Gestão de Qualidade, Gestão da Saúde Operacional e Segurança no Trabalho e Responsabilidade Social. Atua no mercado há mais de 20 anos e fornece alumínio primário para mais de 40 países, sendo que 97% de sua produção é voltada para exportação. Sua produção em 2008 foi de cerca de 465000 toneladas, figurando-se entre as 20 maiores do mundo em produção e as 4 melhores em qualidade.

5.1.1. Parque Industrial

A produção do alumínio, conforme [Prasad, 1999], requer a presença de um bloco anódico constituído de coque e piche. Este bloco é constituído na própria Empresa. Desta forma, na Empresa há 3 grandes linhas de produção:

- Produção de Anodo
- Redução de Alumínio
- Lingotamento

A produção do Anodo é feita nas fábricas de anodo verde e cozido, sendo que este, ao ser chumbado, é encaminhado às reduções onde farão parte do processo de eletrólise.

Na Empresa, existem quatro linhas de redução e cinco de fundição. Nas reduções se encontram os fornos (ou cubas) eletrolíticos. Cada redução possui um total de 240 fornos. Para efeitos administrativos e de controle, os fornos são divididos em seções, onde nas quais estão sujeitas aos mesmos turnos e rotinas de manutenção programada. Cada redução possui 8 seções, de 30 fornos cada. Seu layout é mostrado na figura 5.1.



Figura 5.1 Representação do Layout de uma Redução da Empresa

O lingotamento é feito por máquinas chamadas lingoteiras, que consistem de uma esteira com moldes onde o alumínio líquido é despejado até se solidificar. Um conjunto de máquinas empilha estes lingotes e os envia para o pátio de estocagem, onde ficam aguardando exportação.

5.1.2. Estrutura Organizacional

A Empresa está organizacionalmente dividida em sete grandes áreas.

Área	Propósito
Administração	Relações públicas, Recursos Humanos, Gestão da Qualidade, Serviços Gerais
Engenharia	Coordenação de Projetos e serviços de Engenharia, manutenção do arquivo técnico
Carbono	Fabricação e Cozimento de Anodos
Redução	Produção de alumínio primário por eletrólise.
Fundição	Análise da Pureza e Lingotamento
Utilidades	Prestação de serviços e suporte para outras áreas, fornecimento de água tratada, ar comprimido e energia elétrica através da subestação
Tecnologia da Informação	Gerência do parque de TI e desenvolvimento de soluções de informática e telecomunicações

Tabela 5-1. Áreas da Empresa

O papel que cada área desempenha é importante para o processo, pois a partir destas, a cadeia é suprida.

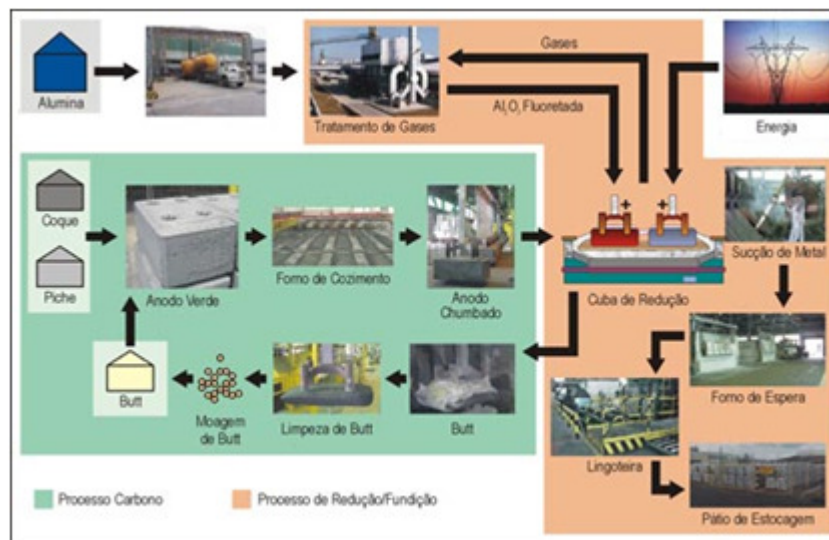


Figura 5.2 Cadeia produtiva de Alumínio interna da Empresa

5.1.3. Turnos e Rotinas Administrativas no Processo de Redução

No processo de redução, as atividades são organizadas em turnos de trabalho de 8 horas, nos quais, em cada seção, uma série de atividades programadas ocorre. As principais rotinas no processo de redução separadas por turnos são:

Turno 1 – Troca de Anodo:

- Troca de anodos dos fornos com mais de 18 dias

Turno 2 – Troca de Anodo II

- Troca de anodos dos fornos com mais de 18 dias e anodos defeituosos por efeitos anódicos

Turno 3 – Miscelânea

- Medida de Temperatura dos fornos
- Coleta de amostras do banho de cada forno
- Adição de Fluoreto (Controle do balanço térmico)

Turno 4 – Corrida

- Retirada de metal dos fornos (Sifonamento)
- Coleta de “lama” (alumina) depositada no fundo dos fornos.

Como cada turno é de 8 horas, as atividades de cada turno se repetem a cada 32 horas. Em casos específicos, uma atividade extra do turno pode ocorrer em outro, em virtude de alguma instabilidade no processo.




Figura 5.3 Turnos de Operação da Empresa

O controle de temperatura dos fornos é feito durante o turno de miscelânea, e de certa forma, sofre as conseqüências da medida das suas variáveis em um intervalo muito longo, o que torna o controle ainda mais difícil e complexo.

Um dos grandes entraves do no turno de miscelânea é o longo tempo gasto na coleta de variáveis dos fornos e na tomada de decisões acerca do que fazer para manter a temperatura e a composição química do forno estável. Enquanto as atividades dos outros turnos são bastante demoradas por envolverem a troca dos anodos e o movimento de cadinhos, o turno de miscelânea concentra atividades manuais que poderiam ser automatizadas com o uso de sensores virtuais.

5.1.3.1 MEDIDA DE TEMPERATURA E CONTROLE DO BALANÇO TÉRMICO

Durante o turno de miscelânea, a temperatura e a composição química dos fornos é medida, sendo que esta última, por demandar uma análise laboratorial, só é realizada a cada 64 horas, ou seja, a cada duas miscelâneas. Essas informações servirão de base para a tomada de decisão sobre quanto fluoreto (de alumínio e de cálcio) adicionar em cada forno. Uma decisão correta é fundamental para se obter um balanço térmico mais estável.

5.1.4. Infraestrutura de Controle e Automação das Reduções

A Empresa possui duas grandes redes, uma corporativa e outra de automação, conforme mostrado na figura 5.4.

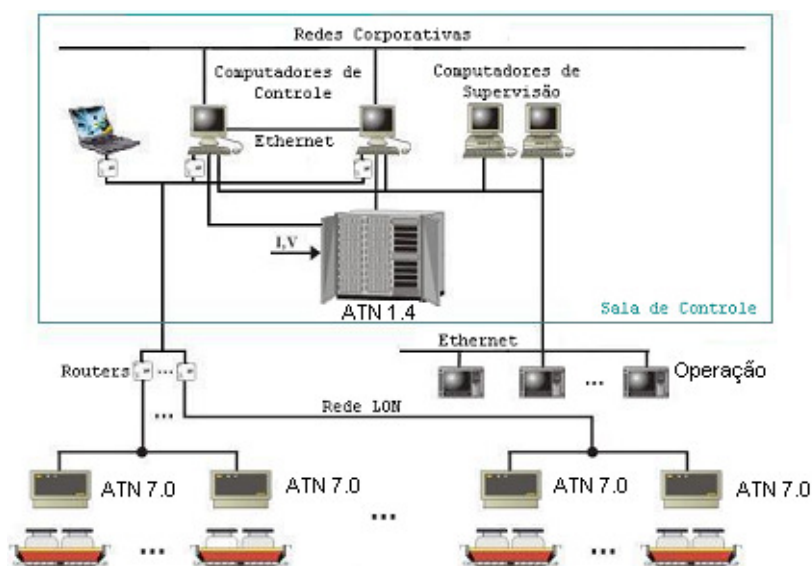


Figura 5.4 Diagrama da Infraestrutura de controle e automação da Empresa

O controle de Redução dos Fornos é feito de forma automática e manual, sendo que opera quase 100% automático, exceto em casos que seja necessária uma intervenção manual nos fornos. O computador de controle dos fornos está interligado nas duas redes, conforme visto na figura. Na rede de Automação (Rede Lon, da Lonworks), estão ligados os nós ATN 7.0 que são circuitos que adquirem e enviam dados digitais em tempo real em cada forno. Os dados são enviados ao computador de controle, e disponibilizados para a rede corporativa. Na rede Lon, também há nós de supervisor, os quais disponibilizam informações do sistema de controle de toda a redução, sendo possível monitorar eventos que estão ocorrendo em cada canto da fábrica.

A instrumentação de automação da Empresa envolve controladores programáveis (CLP's) e instrumentos OPC (Ole for Process Control), desta forma havendo uma rede de informações de planta, que fica disponível para a rede corporativa através dos servidores OPC de cada área.

A rede corporativa é basicamente Ethernet, organizada em domínio e grupos de trabalho. Nesta rede ficam os aplicativos ERP entre outras ferramentas necessárias para controle em um nível mais alto.

5.1.4.1 SISTEMAS DE CONTROLE

Para a redução do Alumínio em específico, a Empresa faz uso basicamente de dois grandes sistemas de controle, o Score e o Sisred.

O controle de reduções é feito pelo software Score, da empresa Atan. O Score consiste em um software que roda no sistema operacional QNX, uma variante do Unix. Este

sistema coleta dados dos fornos em tempo real e gera dados das seguintes variáveis, necessários para fazer o controle de resistência e de alimentação dos fornos.

<i>Variável</i>	<i>Descrição</i>	<i>Freqüência</i>
VMR (Tensão de Forno)	Tensão total do forno	0,5 segundo
RMR (Resistência)	Resistência do forno	0,5 segundo
IM (Intensidade de Corrente)	Corrente da Linha de Redução	0,5 segundo
QAIR (Quantidade Alimentada)	Quantidade de alumina alimentada	100 segundos
A%1 (Alimentação)	Percentual de Alimentação comparado ao teórico	0,5 segundo
EAN (Efeito Anódico)	Efeito Anódico Não programado	Diária
SWT (Oscilação)	Oscilação da Resistência	0,5 segundo
TEA (Tempo de Efeito Anódico)	Tempo em minutos de duração do efeito	Diária
TUN (Tempo de Under)	Tempo de alimentação Under	Diária
TOV (Tempo de Over)	Tempo de alimentação Over	Diária
DeltaR (Variação de Resistência)	Coefficiente de Variação de Resistência	0,5 segundo
IncTM	Incremento de Resistência causado por variação na Temperatura	Diária
IncOs	Incremento de Resistência causado por variação na Oscilação	Diária
IncTr	Incremento de Resistência causado por Troca de Anodo	Diária

Tabela 5-2 Variáveis do Sistema Score

O controle do balanço térmico é feito de forma colaborativa por um software, também desenvolvido pela Atan, o Sisred. Este sistema consiste em um aplicativo Windows que mantém uma base de dados histórica de todos os fornos, contendo dados de todas as variáveis, incluindo as variáveis geradas pelo Score. Assim, é possível se fazer consultas sobre a situação real dos fornos. O Sisred executa tarefas em um nível mais administrativo, podendo nele, inclusive, ser feita a reprogramação de turnos, a configuração de variáveis na base de dados e a geração de relatórios sobre a produção diária.

O módulo de Química de banho, existente no Sisred, realiza as tarefas de programação de adição de fluoreto e outros aditivos químicos no banho. Ele realiza a programação utilizando algoritmos analíticos e sistemas especialistas baseados em lógica

Fuzzy, todos consultando dados históricos e atuais dos fornos. Neste mesmo módulo são cadastrados por outro operador os dados das análises químicas das amostras de cada forno e as temperaturas medidas. As variáveis mantidas somente pelo Sisred estão mostradas na tabela 5-3.

<i>Variável</i>	<i>Descrição</i>	<i>Frequência</i>
TMP (Temperatura)	Temperatura de banho dos fornos	32 horas (miscelânea)
NME (Nível de Metal)	Espessura da camada de metal no forno	32 horas (miscelânea)
NBA (Nível de Banho)	Espessura da camada de banho no forno	32 horas (miscelânea)
ALF3A (Adição de AlF3)	Quantidade de AlF3 a adicionar	32 horas (miscelânea)
ALF (Fluoreto de Alumínio)	% de AlF3 em excesso no banho	64 horas (laboratório)
CAF (Fluoreto de Cálcio)	% de CaF em excesso no banho	64 horas (laboratório)
NA2CO3A (Adição de Na2CO3)	Quantidade de Barrilha a adicionar no banho	64 horas (miscelânea)
CAF2A (Adição de CaF2)	Quantidade de CaF2 a adicionar no banho	64 horas (miscelânea)
TMPLiq (Temperatura de Líquidos)	Ponto de Fusão do Banho	64 horas (laboratório)
%Pur	Pureza do Metal	8 dias (laboratório)
DeltaT (Delta de Temperatura)	Diferença da Temperatura de Líquidos para a Temperatura de Banho	64 horas (miscelânea)
ECO (Eficiência de Corrente)	Produção Real em relação a Produção Teórica	32 horas (corrida)
VIDA (Tempo de Vida)	Tempo de operação de cada forno	Diária
Prod (Produção)	Quantidade de Metal retirada de cada forno	32 horas (corrida)

Tabela 5-3 Algumas das variáveis mantidas pelo sistema Sisred

O banco de dados do Sisred, porém, compreende também as variáveis do Score. Entretanto, como o score realiza um controle online, e o sisred realiza o controle por turnos ou diariamente, a importação dos dados do Score é feita através da média de cada variável ao final de cada dia. Assim, os valores de tensão de forno (VMR) são exportados para o Score apenas como a tensão média do dia para o forno específico.

5.2. LEVANTAMENTO DE REQUISITOS PARA O SENSOR VIRTUAL

Na primeira etapa do projeto, houve uma interação com a equipe de processo, onde foram esclarecidas algumas atividades e necessidades por parte deles. No caso da manutenção do equilíbrio térmico dos fornos, foi esclarecido que as medidas são feitas num intervalo médio de 32 em 32 horas, durante o turno de miscelânea, e seu equilíbrio é extremamente difícil. Conforme [Welch, 2000; Prasad, 1999], a única forma de se realizar este equilíbrio é através da adição de fluoreto e outros sais fundentes. Estes, por sua vez, representam uma decisão importante a ser tomada no processo, pois uma decisão errada pode comprometer o equilíbrio térmico.

A temperatura é medida através dos termopares, cuja precisão é de até 1°C. As variações espaciais da temperatura do forno representam um problema para a equipe, pois uma medida em um local errado pode dar uma informação errada sobre o real balanço térmico do forno. Portanto, a confirmação da temperatura medida com os dados usados na sua inferência oferece uma segurança maior para o controle do processo. Além disso, com o sensor, será possível disponibilizar dados de temperatura dos fornos em tempos menores, a fim de se ter uma noção mais precisa do quanto a temperatura do forno responde às decisões. A proposta é encontrar dentre os dados online uma estimativa do valor de temperatura com variação de até 5°C, conforme ilustrado na figura 5.5.

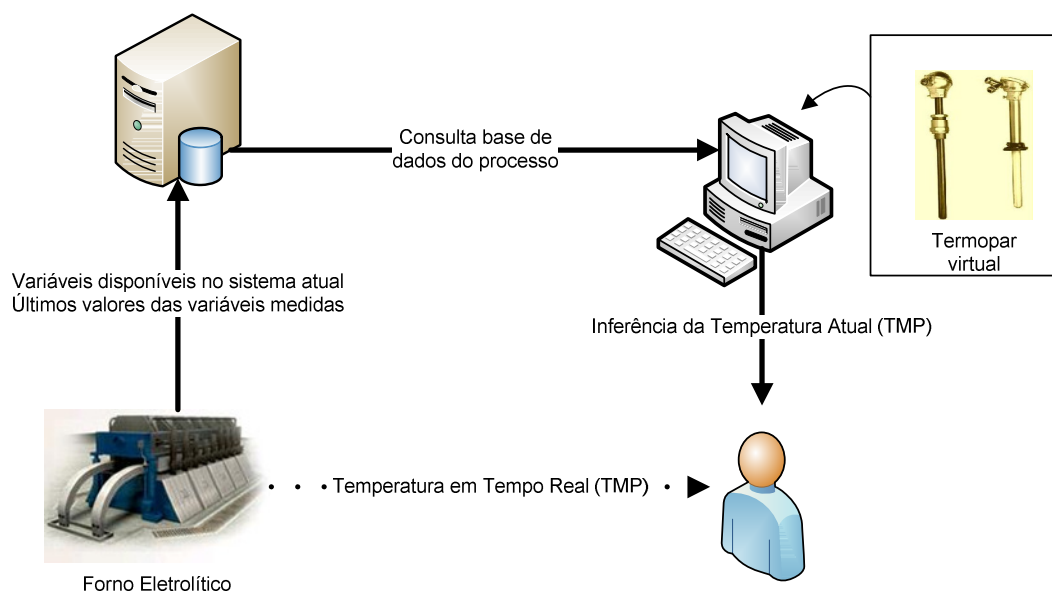


Figura 5.5 Representação Esquemática da Inferência de Temperatura atual através de dados atuais disponíveis no sistema de controle e dados passados (últimas medidas de temperatura e outras variáveis que não estão disponíveis online).

A informação dada pelo sensor virtual também poderia ser utilizada na previsão do próximo valor de temperatura, no caso, haveria a possibilidade de simular os efeitos de uma decisão da química de banho. Um dos grandes desafios existentes na química de banho é a determinação do quanto de fluoreto deve ser adicionado no banho [McFadden, 2001; Pereira, 2005]. Se fosse possível simular uma adição química, como na figura 5.6, prevendo o quanto a temperatura do forno irá subir ou descer, a tarefa ficaria bem mais fácil, ficando o trabalho manual apenas para casos excepcionais.

Desta forma, seriam extraídas informações importantes das variáveis dos fornos que possuem alguma influência no balanço térmico, e estas seriam inseridas em um algoritmo de inferência para o próximo valor de temperatura. Como o valor de temperatura estará dependente da decisão a ser tomada, este estimador funcionará como um simulador do controle de química de banho.

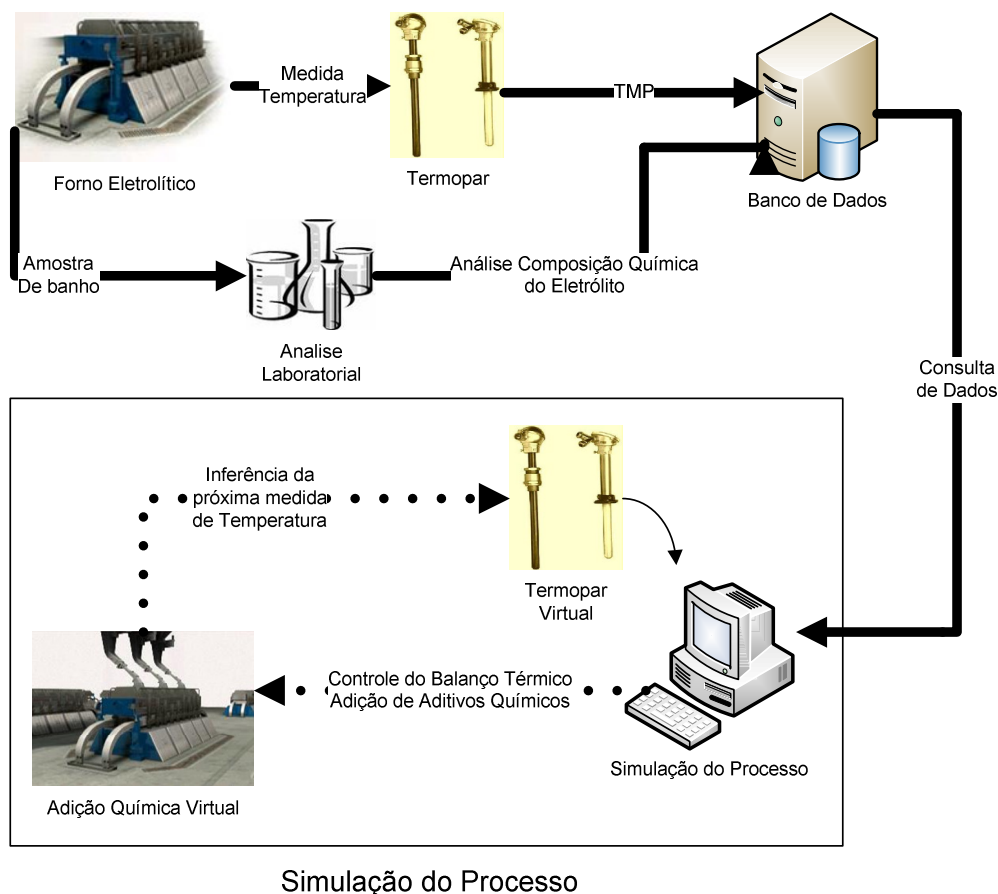


Figura 5.6 Representação esquemática da simulação da química de banho através do sensor virtual. Com base em dados atuais e passados, o algoritmo simula o próximo valor de temperatura de acordo com a decisão de quanto adicionar no forno.

5.2.1.1 MODELAGEM DOS SENSORES

Desta forma, seriam desenvolvidos dois sensores:

- **Sensor Virtual de Temperatura:** Estimação do valor de temperatura através dos dados atuais disponíveis sem a necessidade de se medir.
- **Simulador de Balanço Térmico:** Previsão dos próximos valores de temperatura através dos dados atuais disponíveis.

A figura 5.7 mostra a estrutura externa de cada um dos sensores:

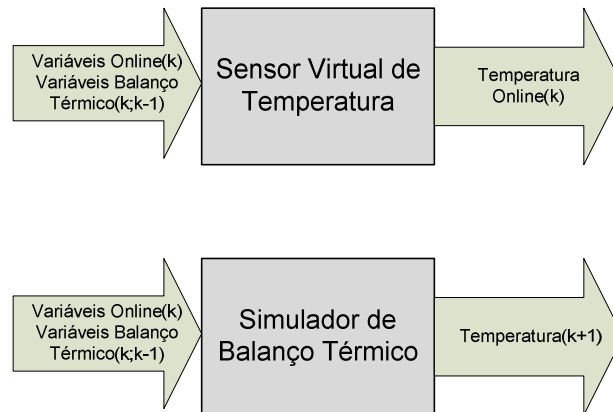


Figura 5.7 Estrutura externa dos dois sensores a serem desenvolvidos

Como os sistemas fazem uso da informação de temperatura na entrada, o sistema pode ser remodelado em malha fechada, neste caso, quando o mesmo estiver funcionando sem a medida de temperatura. A figura 5.8 mostra a estrutura dos sensores considerando-se a realimentação.

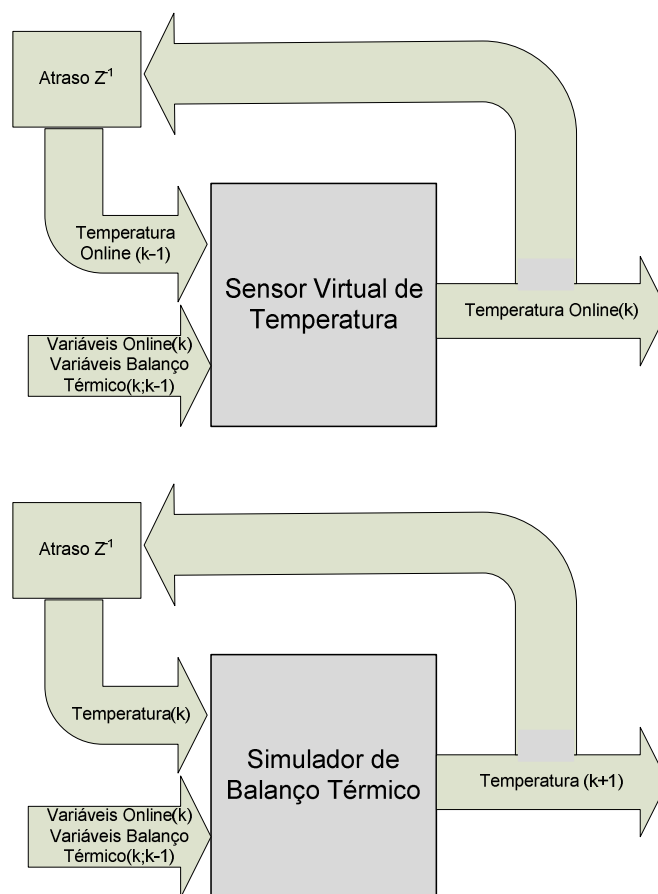


Figura 5.8 Estrutura externa dos sistemas em malha fechada

5.3. COLETA E ANÁLISE DE DADOS

Com apoio da equipe e baseado em alguns artigos, foram determinadas algumas variáveis que, segundo eles, teriam maior influência sobre a temperatura:

<i>Variável</i>	<i>Descrição</i>
%ALF3 (Fluoreto de Alumínio)	Excesso de Fluoreto no banho
%CaF2 (Fluoreto de Cálcio)	Excesso de Fluorita no banho
AIF3A (Adição de AIF3)	Quantidade de fluoreto adicionada
CaF2A (Adição de CaF2)	Quantidade de fluorita adicionada
RMR (Resistência)	Resistência Real de Forno
QALr (Quantidade Alimentada)	Quantidade de Alumina alimentada
A%1	Alimentação de Alumina atual
TMP(Temperaturas passadas)	Valores passados de Temperatura
SWT (Oscilação)	Oscilação do Alumínio no Forno
TEA (Tempo de Efeito Anódico)	Tempo que o Forno ficou com efeito anódico

Tabela 5-4 Variáveis, que, segundo a equipe de processo, possuem alguma influência no balanço térmico

Como as informações sobre o processo estão distribuídos em dois bancos de dados, um do Score (online) e um do Sisred (médias dos valores diários), cada um deles foi utilizado de formas diferentes:

- **Dados do Score:** Base para construção do Sensor Virtual de Temperatura
- **Dados do Sisred:** Base para construção do Simulador de Química de Banho

Como os dados do Score (online) são incorporados ao Sisred (batch), estes podem ser utilizados no estudo de correlação linear com a temperatura, que é sempre batch.

5.3.1. Pré-processamento dos Dados

As variáveis do Sisred relacionadas com a química de banho são inseridas a cada 4 turnos operacionais, ou seja, 32 horas. Já os dados do Score são instantâneos e disponibilizados para o Sisred como médias dos valores a cada 24 horas. Outra diferença está no fato das variáveis mantidas pela química de banho serem pontuais enquanto que as variáveis do Score são médias diárias.

Neste cenário, um pré-processamento de tais dados se fez necessário para se coletar dados que possam trazer informações válidas sobre os seus relacionamentos. Tal pré-processamento consiste em ajustar os dados para transformá-los em registros operacionais para cada ponto no tempo. As tabelas 5-5 e 5-6 mostram a frequência com que os dados do Score e do Sisred, respectivamente estão armazenados na base de dados do Sisred:

<i>Data/Hora</i>	<i>Tensão de Forno(VMR)</i>
25/01/2008 00:00:00	4,29 (média de 24/01/2008)
26/01/2008 00:00:00	4,34 (média de 25/01/2008)
27/01/2008 00:00:00	4,31 (média de 26/01/2008)
28/01/2008 00:00:00	4,49 (média de 27/01/2008)
29/01/2008 00:00:00	4,38 (média de 28/01/2008)
30/01/2008 00:00:00	4,35 (média de 29/01/2008)
31/01/2008 00:00:00	4,25 (média de 30/01/2008)

Tabela 5-5 Médias diárias dos dados do Score armazenados na base de dados do Sisred

<i>Data/Hora</i>	<i>Nível de Metal(NME)</i>
25/01/2008 00:32:00	17
26/01/2008 07:55:00	21
27/01/2008 17:42:00	22
29/01/2008 00:10:00	22

30/01/2008 08:09:00	22
31/01/2008 15:50:00	21
02/02/2008 01:14:00	20

Tabela 5-6 Dados do Sisred cadastrados em pontos temporais específicos

Do jeito que os dados se encontram, uma correlação entre eles é difícil de ser identificada, por causa da enorme variação temporal. A saída encontrada, de acordo com [Fortuna et al, 2007] foi recalculando as médias das variáveis do Score exatamente para os horários que as variáveis do Sisred foram inseridas. Para facilitar a tarefa, a dimensão do tempo foi dividida em turnos, ao invés de dias. As médias diárias dos valores do Score foram recalculadas para se fechar 24 horas exatamente no turno em que foi medida a variável do Sisred. O banco de Dados comum dos dois tipos de variável ficou da seguinte maneira:

<i>Data/Hora</i>	<i>Nível de Metal(NME)</i>	<i>Tensão de Forno(VMR)</i>
25/01/2008 03:30:00	17	4,3 (média desde 24/01/2008 03:30)
26/01/2008 11:30:00	21	4,33 (média desde 25/01/2008 11:30)
27/01/2008 19:30:00	22	4,4 (média desde 26/01/2008 19:30)
29/01/2008 03:30:00	22	4,42 (média desde 28/01/2008 03:30)
30/01/2008 11:30:00	22	4,45 (média desde 29/01/2008 11:30)
31/01/2008 19:30:00	21	4,37 (média desde 30/01/2008 19:30)
02/02/2008 03:30:00	20	4,32 (média desde 01/02/2008 03:30)

Tabela 5-7 Ajuste feito nas variáveis do Score para compor uma base única

5.3.2. Escolha das Variáveis

Além da conversa com a equipe de processo, uma pesquisa bibliográfica sobre controle de química de banho foi feita a fim de se verificar junto a trabalhos já realizados quais variáveis possuem maior grau de influência na temperatura dos fornos. Segundo [McFadden et al, 2001], a temperatura está fortemente relacionada com a composição química do eletrólito, que envolve as variáveis de Fluoreto de Alumínio (ALF), Fluoreto de Cálcio (CAF) e Alumina (Al₂O₃). Haupin e Kvande em seu trabalho sobre balanço térmico [Haupin et al, 2001], identificaram que o tempo de funcionamento (VIDA) e a alumina fluoretada pelas plantas de tratamento de gases possuem alguma relação direta com o consumo de fluoreto em excesso no banho, que impacta diretamente na temperatura dos fornos. Frost e Karri desenvolveram um trabalho de estimação da quantidade de fluoreto em excesso nos fornos utilizando Redes Neurais Artificiais [Frost et al, 1999], na qual faz uso da

Resistência de Forno (RMR), da Tensão efetiva (EMF) e do nível de metal (NME) na inferência do valor de fluoreto (ALF), que possui forte correlação com a Temperatura.

Em todos os trabalhos pesquisados, constatou-se uma grande variedade de dados que pode ter alguma influência direta ou indireta com a temperatura de fornos. No entanto, uma pesquisa na base de dados se faz necessária para se identificar o grau de correlação estas variáveis possuem entre si. Assim, poderá ser feita uma estrutura do modelo inicial para o sensor virtual de temperatura e o simulador de fluoreto.

5.3.2.1 CORRELAÇÃO DAS VARIÁVEIS

Em pesquisa rápida realizada nos fornos 140 ao 149, da seção 12 da redução II no período de 03/06/2006 a 29/09/2007, totalizando 3056 registros, foi feito um estudo de correlação linear entre as variáveis com a de temperatura. Neste estudo, foram consideradas 42 das 156 variáveis disponíveis na base de dados, após a pesquisa bibliográfica e as conversas com a equipe de processo. As variáveis restantes não foram consideradas adequadas para participarem da correlação por possuírem dados de outros tipos (binário ou booleano, textos, altos intervalos de medição, atrasos muito grandes na coleta, etc.) e por algumas serem compostas por outras variáveis como é o caso da Corrente (IM), que é fruto da Resistência e da Tensão dos Fornos.

Por conveniência as variáveis foram separadas em quatro grupos:

- Variáveis do Controle de Resistência Elétrica
- Variáveis do turno de Miscelânea do Sisred
- Variáveis do Controle de Alimentação
- Outras

Os gráficos das figuras 5.9, 5.10, 5.11 e 5.12 mostram as correlações cruzadas de cada variável com a temperatura, considerando-se até sete atrasos. Ademais, para formação do sensor virtual de temperatura, será considerada a variável que possuir correlação maior até o atraso 0, enquanto que para formação do simulador de química de banho, a variável que possuir correlação até o atraso -1 será considerada. Isto se deve ao fato de numa simulação para prever um valor futuro, considera-se que o atraso -1 é na verdade o instante atual, não havendo, portanto o valor no atraso 0 disponível para se inserir no sistema.




Figura 5.9 Gráfico de Correlação Cruzada das variáveis do controle de resistência com a Temperatura dos Fornos

O gráfico da figura 5.9 mostra uma correlação negativa moderada das variáveis Incremento de Resistência por Temperatura (IncTM), Tensão de Forno (VMR) e Resistência Real de Forno (RMR), e uma correlação razoável da variável Incremento por Troca de Anodo (IncTr), enquanto que as demais variáveis apresentam correlação fraca, quase irrelevante. Para a modelagem do Simulador do Balanço Térmico, somente a variável de Incremento por Temperatura se mostra interessante por apresentar um valor de correlação ainda moderado (-0,669) no atraso -1, enquanto que a tensão e a resistência já apresentam valores bem mais baixos (-0,37). No entanto, para a construção do sensor virtual online de temperatura, a tensão e a resistência podem ser escolhidas por apresentarem uma correlação de módulo maior (-0,476 e -0,526), uma vez também que o Incremento por Temperatura demora a ser calculado, pois dependerá do valor da temperatura a ser medida no dia.




Figura 5.10 Gráfico de Correlação Cruzada das Variáveis do Controle de Alimentação de Alumina com a Temperatura de Banho dos Fornos

Na figura 5.10, as variáveis de alimentação apresentaram uma relação mais próxima a Temperatura, sendo que a Quantidade Alimentada Real (QALr), Percentual de Alimentação Teórico (A%1) e a porcentagem do Tempo de Over (%TOV) possuem correlação negativa moderada e o Tempo de Under (TUN) e a porcentagem do Tempo de Under (%TUN) possuem correlação positiva moderada, no entanto com módulo ligeiramente menor do que a Quantidade Alimentada Real. Nota-se que tais variáveis mantem próximo o coeficiente de correlação ao se aproximar do instante da medida de temperatura, o que as torna ideais para modelagem tanto do sensor virtual quanto do simulador de balanço térmico, uma vez que essas variáveis ficam disponíveis no sistema de controle online.




Figura 5.11 Gráfico de Correlação Cruzada das Variáveis de Miscelânea com Temperatura

No gráfico da figura 5.11, quatro variáveis se destacam por possuírem maior módulo de correlação, entre elas a própria temperatura, que no atraso -1 apresenta coeficiente de correlação superior a 0,8. As outras variáveis que apresentam coeficiente de correlação positivo são a quantidade de fluoreto adicionada (ALF3A) e a temperatura de Líquidos (TMPLiq), ficando somente a variável percentual de fluoreto em excesso (ALF) com coeficiente de correlação negativo (-0,823) no mesmo instante da medida de temperatura. Nota-se que algumas variáveis da química de banho como Fluoreto de Cálcio (CAF) apresentaram pouca correlação, muito embora ela e outras variáveis que também ficaram com pouca correlação sejam utilizadas para cálculo da temperatura de líquidos (TMPLiq), que apresentou correlação elevada. No entanto, esta variável só é disponibilizada a cada análise química do banho, que ocorre de 64 em 64 horas, o que a torna inviável utilizar no sensor virtual e na simulação do balanço térmico. Já as variáveis de Temperatura e Fluoreto Adicionado possuem bom grau de correlação e podem ser utilizados no sensor e no simulador. O Percentual de Fluoreto em Excesso é um caso particular pois a variável é extraída também a cada 64 horas, o que gera um valor de correlação no instante -1 bem menor do que no instante 0. No entanto, esta não poderá ser utilizada no sensor, por não tê-la disponível em um intervalo de tempo pequeno o suficiente para aferir a temperatura, mas poderá ser utilizada no simulador. Será utilizado, para fornecer dados de fluoreto em excesso no banho nas medidas de temperatura que não possuem amostragem de fluoreto, um sistema desenvolvido por Frost e Kerri em [Frost et al, 1999].

Correlação Cruzada das demais variáveis com a Temperatura




Figura 5.12 Gráfico de Correlação das Demais Variáveis com a Temperatura de Banho

Ainda há algumas variáveis que foram pesquisadas, como as variáveis da análise de alumina, retirada de banho, perda catódica, entre outras. Na figura 5.12, a variável que se destacou nesse grupo foi a perda catódica no atraso 0, porém nos atrasos anteriores

nenhuma superou os limites de -0,1 a 0,1, o que as elimina parcialmente da construção do simulador. A informação da perda catódica seria interessante utilizar na construção do sensor virtual, se não fosse armazenada de forma tão escassa no banco de dados, que é aproximadamente uma vez por mês.

Portanto, nota-se nos gráficos de correlação que as variáveis que mais possuem correlação com a temperatura são quase as mesmas previstas pela equipe de processo e nos trabalhos já realizados, a exceção de algumas como nível de metal, fluoreto de cálcio, barrilha. A tabela 5-8 mostra os valores de correlação para cada variável candidata a construção do sensor virtual de temperatura e do simulador de balanço térmico.

<i>Variável</i>	<i>Coefficiente de Correlação</i>	<i>Sensor Virtual</i>	<i>Simulador de Balanço Térmico</i>
VMR[k]	-0,47637	✓	
RMR[k]	-0,52615	✓	
IncTM[k-1]	-0,66956	✓	✓
TUN[k]	0,489652	✓	
TUN[k-1]	0,540991	✓	✓
TUN[k-2]	0,519948		✓
%TUN[k]	0,51626	✓	
%TUN[k-1]	0,575287	✓	✓
%TUN[k-2]	0,551015		✓
%TOV[k-1]	-0,45055	✓	✓
QALr[k]	-0,55777	✓	
QALr[k-1]	-0,63539	✓	✓
QALRr[k-2]	-0,60342		✓
A%1[k]	-0,48318	✓	
A%1[k-1]	-0,55098	✓	✓
TMP[k-1]	0,779249	✓	✓
TMP[k-2]	0,610616		✓
ALF[k-1]	-0,58566		✓
ALF3A[k-1]	0,613902	✓	✓
ALF3A[k-2]	0,464856		✓
TMPLiq[k-1]	0,537638		✓

Tabela 5-8 Tabela das variáveis com seus respectivos coeficientes de correlação

Uma comparação entre a variação destes coeficientes segundo cada forno também foi feita para verificar o grau de exatidão que cada um deles representa na prática. Os gráficos dessa comparação são exibidos nas figuras 5.13, 5.14, 5.15, 5.16, 5.17 e 5.18.




Figura 5.13 Correlação das variáveis VMR e RMR com TMP




Figura 5.14 Correlação de A%1 e TUN com TMP




Figura 5.15 Correlação de ALF e TMP com TMP




Figura 5.16 Correlação ALF3A e TMPLiq com TMP




Figura 5.17 Correlação QALr e IncTM com TMP




Figura 5.18 Correlação de %TUN e %TOV com TMP

A partir dos gráficos das figuras 5.13 a 5.18, nota-se uma imprecisão alta nas variáveis %TOV, A%1, VMR e RMR. As variáveis que denotam melhor qualidade de correlação são as variáveis de balanço térmico TMP, ALF3A e ALF, e também a IncTM, que possui relação direta com a temperatura dos fornos. A tabela 5-9 mostra o desvio padrão das correlações das variáveis escolhidas como candidatas.

<i>Variável</i>	<i>Coefficiente de Correlação</i>	<i>Desvio Padrão</i>	<i>Precisão</i>
VMR[k]	-0,47637	0,113687	Baixa
RMR[k]	-0,52615	0,076016	Baixa
IncTM[k-1]	-0,66956	0,03169	Alta
TUN[k]	0,489652	0,045044	Média
TUN[k-1]	0,540991	0,034361	Alta
TUN[k-2]	0,519948	0,050894	Média
%TUN[k]	0,51626	0,05352	Média
%TUN[k-1]	0,575287	0,049165	Média
%TUN[k-2]	0,551015	0,088236	Baixa
%TOV[k-1]	-0,45055	0,089517	Baixa
QALr[k]	-0,55777	0,056417	Média
QALr[k-1]	-0,63539	0,059142	Média

QALr[k-2]	-0,60342	0,090054	Baixa
A%1[k]	-0,48318	0,042166	Média
A%1[k-1]	-0,55098	0,060889	Média
TMP[k-1]	0,779249	0,020812	Alta
TMP[k-2]	0,610616	0,025128	Alta
ALF[k-1]	-0,58566	0,045428	Média
ALF3A[k-1]	0,613902	0,032665	Alta
ALF3A[k-2]	0,464856	0,063864	Média
TMPLiq[k-1]	0,537638	0,055691	Média

Tabela 5-9 Tabela de desvio padrão das Correlações

As variáveis que apresentam baixa precisão não necessariamente podem ser descartadas [Fortuna et al, 2007], mas devem compor, a princípio um vetor de dados que será filtrado pelas técnicas apresentadas no capítulo 3. Além disso, é da natureza do processo que tais variáveis se comportem de forma imprecisa, variando segundo as condições de operação do forno, layout do barramento e tamanho [Welch, 2000].

5.3.2.2 VALIDAÇÃO DAS VARIÁVEIS CANDIDATAS

A primeira proposta incluiu 24 variáveis para composição do modelo, sendo 15 delas para o simulador de balanço térmico e 12 para o sensor virtual. A equipe de processo achou interessante a inclusão das variáveis de alimentação e resistência, no entanto as variáveis TUN e %TUN são linearmente dependentes, conforme pode ser visualizado na figura 5.19.




Figura 5.19 Gráfico mostrando a relação que existe entre TUN e %TUN

Igualmente, a equipe observou que as variáveis alimentação instantânea (A%1) e quantidade alimentada (QALr) são correlatas, conforme mostrado na figura 5.20 inclusive, conforme pode ser visto no gráfico a seguir, com um grau muito maior. Entretanto, a equipe

sugeriu que fosse utilizada a variável A%1 para o sensor virtual, já que ela possui dados online e a variável QALr para simular o balanço térmico, por incluir um somatório histórico.




Figura 5.20 Gráfico indicando a forte relação que a QALr possui com a alimentação

Visando simplificar o modelo, apenas um atraso poderia servir para as variáveis Tempo de Under(TUN), Percentual de tempo em Under(%TUN) e Quantidade Alimentada(QALr), segundo considerações feitas por especialistas. Para as variáveis de Temperatura (TMP), fluoreto (ALF) e fluoreto adicionado (ALF3A), é importante ter informações das últimas 64 horas (dois atrasos) pois elas trazem a tendência do balanço de massa [McFadden, 2001]. Por fim, a variável Temperatura de Líquidos (TMPLiq) teve de ser descartada por estar indisponível em intervalos de tempo inferiores a 64 horas, tempo em que a composição química e o balanço térmico dos fornos altera consideravelmente.

Apesar da variável Percentual do Tempo em Over (%TOV) ter obtido uma correlação pequena, a equipe ratificou a permanência desta por ela carregar a informação sobre a alimentação, que é um dos fatores que mais possuem influência na temperatura. Segundo a equipe, é importante ter uma idéia do como o consumo de alumina no forno está evoluindo de forma histórica, e esse consumo é retratado pelo tempo de Over (%TOV) e tempo de Under (%TUN).

Conforme conversa com engenheiros do processo, para o sensor virtual, é importante ter os dados online do mesmo dia e hora, ficando os atrasos apenas para as variáveis do balanço térmico. Os dados passados online servirão para construção do simulador, já que sua função será prever o dado presente.

Basicamente, os dois sistemas serão compostos com as mesmas variáveis, a exceção da tensão (VMR) e resistência de forno (RMR), que só ficarão disponíveis para o sensor virtual. Assim, ficam escolhidas para compor o sistema as seguintes variáveis:

<i>Variável</i>	<i>Sensor Virtual</i>	<i>Simulador de Balanço Térmico</i>
VMR[k]	✓	
RMR[k]	✓	
IncTM[k-1]		✓
%TUN[k]	✓	
%TUN[k-1]		✓
%TOV[k-1]		✓
QALr[k-1]		✓
A%1[k]	✓	
TMP[k-1]	✓	✓
TMP[k-2]		✓
ALF[k-1]*		✓
ALF[k-2]		✓
ALF3A[k-1]	✓	✓
ALF3A[k-2]		✓

Tabela 5-10 Variáveis de Entrada do modelo. A variável ALF[k-1] utilizada é produzida por um sistema de inferência de fluoreto desenvolvido por Frost e Karri.

5.3.3. Pesquisa dos Dados

O próximo passo foi a pesquisa dos dados em dois períodos.

- **Período I:** de 06/2007 a 09/2007
- **Período II:** de 10/2007 a 01/2008

Os fornos pesquisados foram das reduções II e IV. Todos foram utilizados na pesquisa, exceto os fornos mais novos inaugurados em 2001 durante Expansão da fábrica. A Expansão foi iniciada em 2001, alocando-se 8 fornos a mais em cada redução. Estes têm características peculiares que os diferenciam dos demais fornos, além de apresentarem muitas instabilidades, por isso foram excluídos da pesquisa. Assim, foram envolvidos registros de 408 fornos. A tabela 5-11 mostra a quantidade de registros obtidos:

<i>Período</i>	<i>Redução II</i>	<i>Redução IV</i>	<i>Total</i>
Período I	18.153	17.963	36.116
Período II	13.243	13.298	26.541
Total	31.390	31.261	62.657

Tabela 5-11 Quantidade de Registros Pesquisada

No apêndice B, estão detalhados os registros pesquisados por seção e por forno.

5.3.4. Tratamento dos Dados

Após a coleta de dados, foram aplicadas as técnicas de filtragem. Em conversa com a equipe, foi estabelecido que os fornos devam operar dentro de uma faixa, e quaisquer valores fora dessa faixa significam que os fornos estão com uma condição particular que requerem interferência manual no processo. A faixa operacional de cada variável é exibida na tabela 5-12.

<i>Variável</i>	<i>Limite Mínimo</i>	<i>Limite Máximo</i>
VMR	4,05 V	4,55 V
RMR	13,7 $\mu\Omega$	17,9 $\mu\Omega$
IncTM	-0,2 $\mu\Omega$	0,8 $\mu\Omega$
%TUN	0%	80%
%TOV	0%	80%
QALr	2000 Kg	3000 Kg
A%1	70%	120%
TMP	940°C	990°C
ALF	5%	17%
ALF3A	0 Kg	120 Kg

Tabela 5-12 Limites Operacionais das Variáveis

Fortuna em seu livro [Fortuna et al, 2007], estabelece que para fazer a construção do modelo, devem ser escolhidos dados que representem bem a dinâmica do processo e dados que fujam da zona operacional podem conter ruídos e não são ideais para fazer a construção do modelo. No entanto, Aguirre em seu livro [Aguirre, 2004] defende que o modelo deve ser hábil para prever situações mais variadas possíveis, mas para critérios de filtragem, alguns dados fora de faixa podem ser retirados.

Analisando-se a média, valores mínimos e máximos das variáveis nos períodos pesquisados, tem-se uma visão sobre quão dentro da faixa operacional os registros se encontram, assim pode-se escolher qual critério será usado para filtrar estes dados.

<i>Variável</i>	<i>Valor Mínimo</i>	<i>Valor Máximo</i>	<i>Valor Médio</i>	<i>Desvio Padrão</i>
VMR	0,34 V	5,7 V	4,3238 V	0,344 V
RMR	4,23 $\mu\Omega$	22,03 $\mu\Omega$	15,1221 $\mu\Omega$	0,45 $\mu\Omega$
IncTM	-0,4 $\mu\Omega$	0,6 $\mu\Omega$	-0,0015 $\mu\Omega$	0,14 $\mu\Omega$
%TUN	0%	84,463%	40,102%	8,4124%
%TOV	0%	73,187%	47,9221%	9,881%
QALr	2,45 Kg	3285,5 Kg	2514,225 Kg	168,252 Kg

A%1	10,218%	142,355%	103,438 %	6,472 %
TMP	922°C	1097°C	963,61°C	11,404°C
ALF	0%	23,41%	10,206%	2,47%
ALF3A	0 Kg	123,6 Kg	32,03 Kg	22,92 Kg

Tabela 5-13 Valores Mínimos, Máximos, Médios e Desvios Padrão das Variáveis

5.3.4.1 ANÁLISE DOS HISTOGRAMAS

Analisando-se o histograma de cada variável, percebe-se que cerca de 90% dos dados encontram-se dentro da faixa operacional. O restante se localiza fora dela, por motivos particulares. A variável de tensão de forno, normalmente quando o forno está sendo desligado ou iniciado, o forno é desconectado do barramento, e o sistema de controle acaba medindo uma tensão residual na faixa de 1 V. Isto explica uma certa concentração de registros na faixa de 0,6V, conforme pode ser visualizado no histograma da variável Tensão de Forno na figura 5.21. Por outro lado, há uma forte concentração de registros na faixa de 4 a 4,6V, que é justamente a faixa operacional que contempla 98,6% das situações. Os registros que se concentram fora dessa faixa são considerados excepcionais, e não devem ser considerados na construção do modelo.




Figura 5.21 Histograma VMR

A variável de Resistência de Forno (RMR) também apresenta uma alta concentração dos registros na sua faixa operacional, de 14 a 17 uOhm, com 99,1% dos registros (figura 5.22). O restante poderá ser filtrado.




Figura 5.22 Histograma da Variável de Resistência

As variáveis Incremento de Resistência por Temperatura (IncTM / figura 5.23), Percentuais de Tempo em alimentação Under (%TUN / figura 5.24) e Over (%TOV / figura 5.25) seguem a mesma distribuição normal. No entanto, a quantidade de registros que excede a faixa operacional é bem pequena na variável IncTM (0,5%), praticamente nula para %TUN(0,08%) e para %TOV.




Figura 5.23 Histograma IncTM




Figura 5.24 Histograma %TUN




Figura 5.25 Histograma %TOV

O histograma para a variável quantidade alimentada (figura 5.26) mostra situações excepcionais em que há pouca ou nenhuma alimentação ao forno. Sabe-se pela teoria [Prasad,1999], que o forno deve receber pelo menos 1800 Kg de alumina por dia para funcionar, abaixo disso, cria-se condições de instabilidade. Os registros se concentram na faixa de 2000 a 3000 Kg, ficando os demais, apenas 0,3%, considerados ruidosos. Para a alimentação instantânea (figura 5.27), a faixa operacional concentra 99,7% dos registros, portanto, seguindo o mesmo padrão da Quantidade Alimentada.




Figura 5.26 Histograma QALr




Figura 5.27 Histograma da variável Alimentação Instantânea (A%1)

Para a temperatura (figura 5.28) e o fluoreto (figura 5.290, a seleção é um pouco mais complicada. Os fornos da Empresa sofrem superaquecimentos e as vezes podem atingir temperaturas de até 1300°C, o que elimina completamente o fluoreto dos fornos. Apesar disso, o histograma mostra que 98,3% dos registros se encontram na faixa operacional, portanto, os registros que as excedem podem ser filtrados. Todavia, em se tratando da variável a ser modelada, é interessante incluir alguns dados fora da faixa, porém com alguma marcação ou normalização especial [Fortuna et al, 2007].




Figura 5.28 Histograma da variável de Temperatura (TMP)




Figura 5.29 Histograma da variável Percentual de Fluoreto (ALF)

Por último, o histograma da variável de Fluoreto adicionado (figura 5.30) não apresenta muitos registros fora da faixa, mas para efeitos de simplificação do modelo, pode sofrer algum filtro por parte da normalização.




Figura 5.30 Histograma Adição de Fluoreto

5.3.4.2 FILTRAGEM DE REGISTROS

Conforme identificado através dos histogramas, alguns dados podem ser eliminados a fim de se ter uma construção do modelo com dados mais qualitativos. Tais dados são eliminados através da filtragem 3 sigma, conforme definida em [Fortuna et al, 2007]. Aplicando-se essa filtragem, serão estabelecidos os novos limites para as variáveis, conforme pode ser visto na tabela 5-14.

Variável	Valor Mínimo	Valor Máximo	Percentual de Registros Originais nesta faixa
VMR	3,2918 V	5,3558 V	99,86%
RMR	13,77 $\mu\Omega$	16,47 $\mu\Omega$	99,03%
IncTM	-0,42 $\mu\Omega$	0,41 $\mu\Omega$	99,91%
%TUN	14,872%	60,332%	97,2 %
%TOV	18,28%	77,562%	99,2 %
QALr	2009,47 Kg	3018,97 Kg	99,67 %
A%1	84,18%	122,855%	99,37 %
TMP	929,41 $^{\circ}$ C	997,81 $^{\circ}$ C	99,94 %
ALF	2,796%	17,616%	99,94 %
ALF3A	0 Kg	100,79 Kg	99,97 %

Tabela 5-14 Tabela novos limites para as variáveis, após filtragem 3 sigma

Exceto para a variável Percentual de Tempo em Under (%TUN), o filtro mantém mais de 99 % dos dados originais. Para esta variável, os dados serão filtrados por um intervalo de tempo maior, porém na normalização os dados serão reescalados no mesmo intervalo, indicando ao sensor que se o dado for muito baixo ou muito alto, é porque ele não está na faixa normal de operação. O mesmo caso pode ser levado em conta para a variável

de Temperatura e Fluoreto, para permitir valores até 1000°C e 20%. Assim, a tabela com os novos limites ajustados para as três variáveis é exibida na tabela 5-15.

<i>Variável</i>	<i>Valor Mínimo ajustado</i>	<i>Valor Máximo ajustado</i>	<i>Percentual de Registros Originais nesta faixa</i>
%TUN	12,722%	66,128%	99,1 %
TMP	929,41°C	1000°C	99,99 %
ALF	2,796%	20%	99,99 %

Tabela 5-15 Ajuste feito nos limites das variáveis %TUN, TMP e ALF

A filtragem foi aplicada em todos os registros de forma intercessora, ou seja, para permanecer no conjunto de dados, os registros tiveram que conter todas as variáveis dentro dos novos limites. Assim, a quantidade de registros após o filtro ficou segundo está exibido na tabela 5-16.

<i>Período</i>	<i>Redução II</i>	<i>Redução IV</i>	<i>Total</i>
Período I	17.317	17.425	34.742
Período II	12.807	12.642	25.449
Total	30.124	30.067	60.191

Tabela 5-16 Quantidade de Registros por Redução e período

A filtragem eliminou cerca de 4% dos registros. O conjunto de dados ainda precisa de outro ajuste para a construção do sistema. Os registros eliminados causam lacunas (gaps) nos registros temporais de cada forno, conforme explicado por Fortuna em seu livro e artigo [Fortuna et al, 2007; Fortuna, 2007]. A figura 5.31 mostra graficamente essa lacuna:




Figura 5.31 Gráfico mostrando a Lacuna causada pela filtragem dos pontos fora da faixa.

Welch em seu estudo sobre o equilíbrio térmico dos fornos [Welch,2000] conclui que alguns fornos podem apresentar condições de instabilidade intrinsecamente atrelada a sua formação, e muitas vezes isso pode ser indetectável durante sua operação normal, somente percebido após alguma instabilidade. Tais fornos não costumam durar muito tempo e são desligados. Baseado nesse estudo pode-se concluir que para a construção de um modelo não é interessante utilizar dados de fornos instáveis, que apresentaram dados fora da faixa normal.

Visto também que o número de registros é muito grande, o que pode dificultar e demorar a construção do sistema, tais fornos que apresentaram registros fora da faixa poderiam ser excluídos do conjunto de dados. Portanto, para a construção do modelo, somente foram considerados registros de fornos que no período operaram sem pontos fora da faixa. A tabela 5.17 mostra quantos fornos, em cada período e cada redução, apresentaram pontos fora da faixa e quantos não apresentaram.

Período	Fornos com registros 100% dentro da faixa		Fornos com pelo menos 1 registro fora da Faixa	
	Redução II	Redução IV	Redução II	Redução IV
Período I	79	85	127	122

Período II	104	26	104	182
------------	-----	----	-----	-----

Tabela 5-17 Quantidade fornos cujos registros estão totalmente dentro da faixa operacional

As figuras 5.33, 5.34, 5.35 e 5.36 mostram quais foram os fornos escolhidos (marcados ●) para compor o conjunto de dados, de cada redução e de cada período.




Figura 5.32 Layout da Planta da Redução II, com Fornos Seleccionados no Período I marcados com pontos verdes




Figura 5.33 Layout da Planta da Redução IV com fornos seleccionados no período I marcados com pontos verdes



Figura 5.34 Layout da Planta da Redução II com fornos selecionados no período II marcados com pontos verdes



Figura 5.35 Layout da Redução IV com fornos selecionados no período II marcados com pontos verdes

Com a filtragem de fornos, novamente, a quantidade de registros sofre redução no seu número. Cada forno tem cerca de 3 registros a cada 4 dias, assim, no período I, correspondente a 116 dias, cada forno tem uma média de 87 registros, e no período II, correspondente a 88 dias, cada forno tem uma média de 66 registros. A tabela 5-18 mostra a quantidade de registros que restaram, por período e por redução.

<i>Período</i>	<i>Redução II</i>	<i>Redução IV</i>	<i>Total</i>
----------------	-------------------	-------------------	--------------

Período I	6.852	7.335	14.187
Período II	6.660	1.613	8.273
Total	13.512	8.948	22.460

Tabela 5-18 Quantidade de registros por redução e período após a filtragem de fornos

5.3.5. Separação dos Dados para Treinamento, Testes e Validação

Seguindo a regra recomendada em [Fortuna et al, 2007; Haykin, 1999], os dados devem ser organizados em 3 conjuntos:

- Conjunto de Dados de Treinamento: 65% (14600 registros)
- Conjunto de Dados de Testes: 15% (3370 registros)
- Conjunto de Dados de Validação: 20% (4490 registros)

A distribuição destes registros entre os fornos e os períodos não se deu forma proporcional, pois há fornos com mais registros do que outros e os períodos são de diferentes durações. A recomendação é usar um mesmo conjunto de fornos para treinamento e outro conjunto para validação. Como o período I já apresenta uma boa quantidade de registros (63,16%), este período todo foi utilizado para o treinamento. Para completar os 65%, foram escolhidos aleatoriamente mais sete fornos do período II (fornos 131, 201, 251, 344, 413 da redução II e 148, 222 da redução IV), completando 14633 registros (65,15%). Para testes e validação foram utilizados os registros do período II, divididos de forma aleatória. A tabela 5-19 mostra quantos fornos foram utilizados para testes e validação no período II:

<i>Conjunto</i>	<i>Redução II</i>	<i>Redução IV</i>	<i>Total de Registros</i>
Testes	42	10	3.393 (15,1%)
Validação	55	13	4.434 (19,74%)
Total	97	23	7.827 (34,84%)

Tabela 5-19 Distribuição dos Registros e Fornos utilizados para Testes e Validação

Uma listagem completa de quais fornos foram utilizados para treinamento, testes e validação nos dois períodos encontra-se no apêndice B.

5.4. DEFINIÇÃO DA ESTRUTURA DO MODELO

As estruturas do sensor virtual e do simulador de balanço térmico ficam definidas nas figuras 5.36 e 5.37:

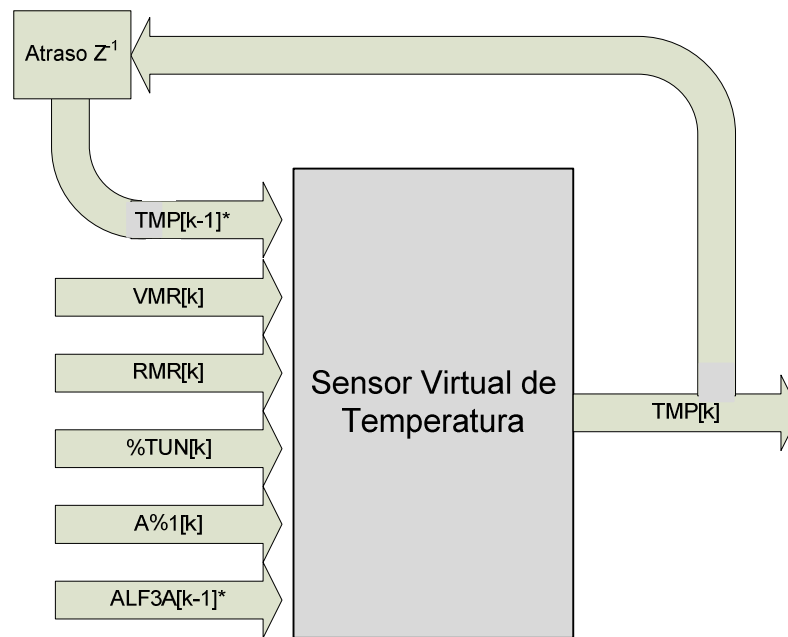


Figura 5.36 Estrutura do Sensor Virtual de Temperatura com as Variáveis de entrada definidas.

A variável ALF3A é usada com seu último valor disponível, e a Temperatura, quando seu último valor disponível é antigo, é usada a realimentação da saída, fechando a malha.

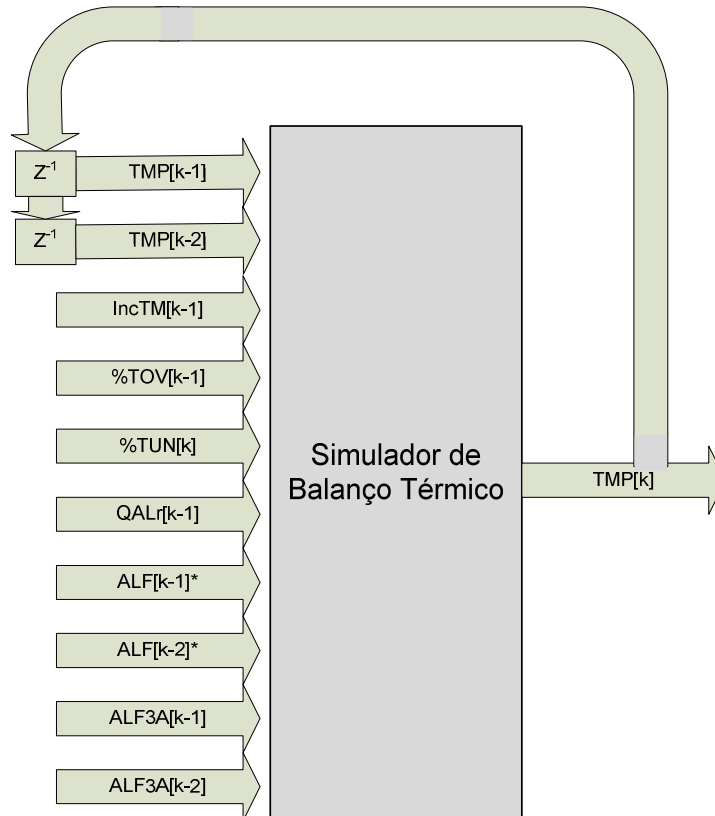


Figura 5.37 Estrutura do Simulador do Balanço Térmico

Em ambos os modelos, há realimentação, por causa da natureza de 2ª ordem da temperatura. Entretanto, essa realimentação só ocorre quando não houver medida disponível. No caso do simulador do balanço térmico, enquanto medidas estiverem sendo feitas, o simulador poderá considerar somente essas medidas.

5.4.1. Escolha da Arquitetura da Rede Neural

Com relação à técnica computacional inteligente a ser utilizada, optou-se por utilizar as redes neurais artificiais por suas vantagens oferecidas, conforme descrito no capítulo 4.

A Rede Neural utilizada neste modelo é do tipo Perceptron Multicamadas (MLP), devido sua maior capacidade de generalização [Zanata,2005; Haykin,1999; Santos, 2008]. Embora, o problema se trate de séries temporais, as redes recorrentes também poderiam ser utilizadas, contudo, à época deste trabalho, não houve tempo hábil para realização de testes com esta arquitetura. Um trabalho já feito na mesma área [Branco, 2004], utilizou esta redes recorrentes sem sucesso, e baseado neste fato, decidiu-se por utilizar as redes MLP como modelo inicial.

5.4.2. Escolha do Algoritmo de Treinamento

Como no conjunto de treinamento há dados na entrada e na saída, o algoritmo de treinamento será supervisionado. Para as redes MLP, o algoritmo que tem melhor desempenho é o de Levenberg-Markvardt, conforme descrito no capítulo 4, seção 4.3. Como há uma quantidade muito grande de dados, a utilização deste algoritmo diminuirá bastante o tempo de treinamento para poucas iterações, pois sua busca encontra pesos bons logo nas primeiras épocas.

5.4.3. Configuração de Parâmetros da Rede Neural

5.4.3.1 QUANTIDADE DE NEURÔNIOS E CAMADAS

Devido o total de dados envolver uma grande quantidade de registros, uma rede neural com bastantes pesos é necessária para poder representar melhor e de forma mais acurada o conhecimento do processo. Porém, para obter-se um primeiro resultado, optou-se por começar com redes neurais simples, com duas camadas e poucos neurônios. Conforme o seu desempenho evolui, decide-se adicionar mais neurônios ou camadas à rede. As funções de ativação utilizadas são as mais comuns: Sigmóide, tangente hiperbólica e linear, sendo que as duas primeiras são usadas nas camadas escondidas e a linear na camada de saída.

5.4.3.2 PARÂMETROS DE TREINAMENTO E INICIALIZAÇÃO DOS PESOS

Outra configuração importante foi a escolha dos parâmetros de treinamento e a inicialização dos pesos. Tal inicialização pode ser muito importante e diminuir bastante o tempo de treinamento. Optou-se por realizar uma inicialização aleatória com distribuição uniforme entre -2 e 2. Os demais parâmetros de treinamento são mostrados na tabela 5-20:

Parâmetro	Valor
Quantidade Máxima de Épocas	100 a 1000
Mi (μ)	0,001
Erro mínimo global	0,001
Incremento de Mi	10
Gradiente Mínimo	1e-24
Tipo de Treinamento	Batch

Tabela 5-20 Parâmetros de Treinamento utilizados para as Redes Neurais do Modelo

5.4.3.3 NORMALIZAÇÃO DOS DADOS

A normalização é uma etapa importante para se facilitar o treinamento. Os dados de escalas diferentes, quando normalizados, possuem valores menores e escaláveis no mesmo nível em todas as variáveis de entrada. Assim, a Rede Neural, ao invés de receber valores muito altos e diferentes na entrada, o que pode dificultar o processo de aprendizado da rede por misturar valores muito altos com muito baixos [Haykin, 1999], recebe valores todos no mesmo nível.

Neste trabalho, a normalização foi feita utilizando-se a escala min-max, conforme mostrada na figura 5-38:




Figura 5.38 Representação gráfica da normalização min-max em uma variável

Neste trabalho, a faixa das variáveis normalizadas foi entre -2 e 2. Nesta normalização, o sistema irá dispor de dados que podem causar três efeitos:

- Amplificador ($|X| > 1$)
- Neutralizador ($|X| = 0$)
- Atenuador ($|X| < -1$)

Uma rede com pesos na entrada muito próximos de 1 ou -1 poderá sentir diferença com valores muito altos ou muito baixos. É interessante deixar o intervalo de normalização um pouco maior para que esses efeitos possam reproduzir mais aproximada a dinâmica do processo.

5.4.4. Backup do sensor virtual

Para o sensor virtual, serão usadas três redes adicionais com propósito de backup [Fortuna et al, 2007]. A finalidade é obter o mesmo modelo com uma configuração de pesos diferente, de modo que a estimação do sensor possa ser “validada” através dos sensores backup.

Cada termopar virtual de backup fornece valores para as mesmas entradas. O termopar principal irá fornecer como valor principal, a média aritmética de todos os valores, incluindo o do próprio termopar principal.

$$TMP_v = TMP_{vp} + a \left(\frac{\sum_{i=1}^N TMP_{vbi}}{3} - TMP_{vp} \right) \quad (5.1)$$

onde TMP_{vp} é o valor de temperatura inferido pelo termopar virtual principal, TMP_{vbi} é o valor inferido pelo termopar virtual de backup i , N é a quantidade de termopares backup e a é um fator de ponderação. Neste trabalho, foi utilizado um fator de ponderação de 0,3.

Contudo, quando o desvio padrão dos valores dos backups for muito alto, o sistema deve informar que tal previsão pode estar errada. Portanto, o esquema do sistema, incluindo os backups é mostrado na figura 5.39.

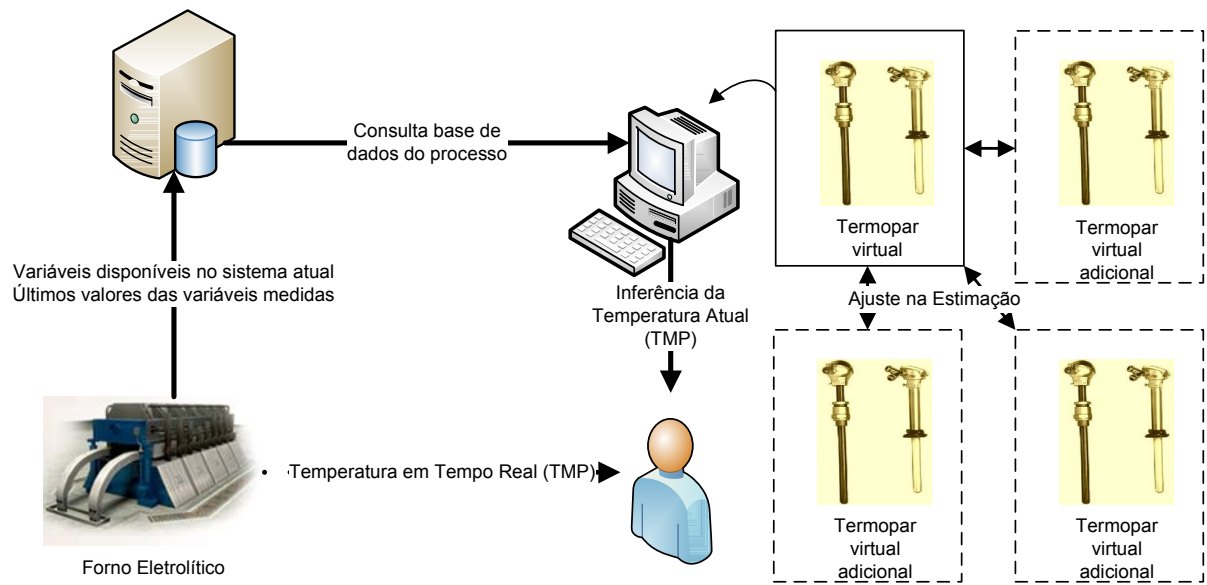


Figura 5.39 Estrutura de Backup do Sensor Virtual

5.4.5. Estrutura final do sistema

A modelagem da estrutura do sensor virtual e do simulador de balanço térmico é mostrada nas figuras 5.40 e 5.41.




Figura 5.40 Estrutura do Sensor Virtual com a Rede Neural Artificial integrada

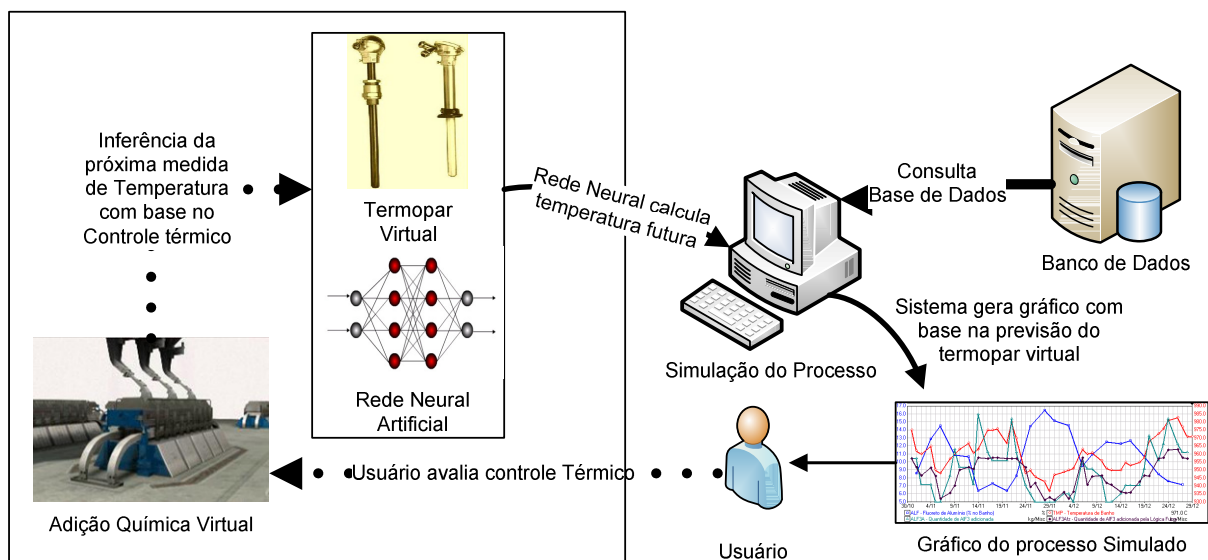


Figura 5.41 Representação esquemática completa do simulador de balanço térmico

5.5. IMPLEMENTAÇÃO DOS SENSORES EM SOFTWARE

A próxima etapa da construção do sensor virtual é a sua programação, e normalmente ocorre em duas subetapas:

- **Programação do Sensor:** Treinamento e validação das Redes Neurais
- **Implementação do Sensor:** Disponibilização das Redes Neurais para plataformas de software corporativas.

À época de construção deste sensor, não houve tempo hábil para implementação do sensor, contudo a partir da modelagem esquematizada na figura 5.41, a implementação do software pode ser feita em qualquer linguagem de programação que atende aos requisitos do sensor.

Na primeira parte da implantação, os modelos foram trabalhados e simulados em ambiente computacional preparado para tais testes: o Matlab. Após uma configuração de rede neural ser homologada, a mesma deve ser implementada em um ambiente de produção.

5.5.1. Requisitos não funcionais

Como espera-se que a rede neural seja suficientemente grande e extensa, com uma boa quantidade de neurônios, o sensor virtual vai demandar uma boa quantidade de memória. O desempenho não é uma questão problemática, uma vez que o tempo de resposta para uma simulação ou previsão precisa ser muito rápido, mas não deve demorar

mais do que 40 segundos. A segurança no processamento, no entanto, precisa ser bem robusta e tolerante a falhas.

Portanto, o sensor deve ser instalado em um hardware programável, com no mínimo 4MB de memória disponível para a aplicação. A ferramenta deve estar integrável às demais ferramentas de gestão e software existentes que fazem parte da infraestrutura de TI da Empresa:

<i>Tipo</i>	<i>Recursos</i>
Sistema Operacional	Windows XP/2000
Bancos de Dados	SQL Server 2000 SP4
ERP	Oracle Visa
Servidores OPC	RSLinx, ATAN
Protocolo de Rede	Ethernet

Tabela 5-21 Infraestrutura de TI da Empresa

5.5.2. Matlab

O Matlab é uma ferramenta disponível nos meios universitários e possui grande aplicação científica [Demuth et al, 2008], dadas as suas implementações de algoritmos de controle, inteligência artificial entre outros [Demuth et al, 2008]. Possui um bom desempenho, porém, não é viável utilizar o Matlab para controlar um ambiente de produção, já que ele não foi projetado para tal função, mas os seus algoritmos de controle podem ser implementados em qualquer arquitetura de software ou hardware.

Esta ferramenta contém um framework de Redes Neurais, onde já se possui as implementações dos elementos que constituem uma Rede Neural, que são neurônios, camadas, pesos e algoritmos de treinamento.

Os dados foram importados para o Matlab através de arquivos texto, na forma de matrizes. O Matlab possui uma capacidade que o torna diferente das demais ferramentas de programação, que é a facilidade de lidar com matrizes. Conforme apresentado em [Demuth et al, 2008], os elementos de dados uma rede neural podem ser tratados como matrizes, assim como seus conjuntos de dados de teste e treinamento.

967	956	9.739	11.50281	38.04	28.53	2359.39	51.532	40.763	-0.052	972
972	967	8.363602	9.739	47.55	38.04	2337.7	51.512	43.621	-0.1	969
969	972	8.487	8.363602	47.55	47.55	2484.7	45.947	41.781	-0.1	972
972	969	8.363602	8.487	57.06	47.55	2581.1	39.694	52.031	-0.047	965
965	972	10.195	8.363602	38.04	57.06	2583.51	41.319	50.273	0	962
962	965	10.32559	10.195	38.04	38.04	2593.15	34.814	55.427	0	955
955	962	11.734	10.32559	28.53	38.04	2701.6	35.969	61.597	0.081	948
948	955	13.07239	11.734	19.02	28.53	2650.99	43.539	39.48	0.227	946
946	948	14.234	13.07239	0	19.02	2681.52	38.148	44.328	0.39	939
939	946	14.8382	14.234	9.51	0	2622.96	39.408	48.208	0.189	962
962	939	11.164	14.8382	57.06	9.51	2298.45	52.161	40.59	-0.031	970
970	962	8.755997	11.164	66.57	57.06	2454.61	43.319	50	-0.1	972
972	970	7.758	8.755997	47.55	66.57	2588.8	38.628	54.959	-0.1	974
974	972	7.971191	7.758	57.06	47.55	2505.85	46.872	45.296	-0.1	970
970	974	8.145	7.971191	47.55	57.06	2361.89	50.947	38.913	-0.015	967
967	970	9.344604	8.145	38.04	47.55	2605.88	34.977	48.865	0	967
967	967	10.732	9.344604	38.04	38.04	2749.84	34.827	55.579	0	965
965	967	9.737	10.732	38.04	38.04	2525.36	49.177	38.549	0	962
962	965	10.536	9.737	38.04	38.04	2664.44	35.555	57.22	0	956
956	962	11.50281	10.536	28.53	38.04	2718.12	37.645	49.425	0	955
955	956	12.791	11.50281	28.53	28.53	2622.96	33.041	56.18	0	954
954	955	11.8952	12.791	19.02	28.53	2703.48	32.53	59.785	0.05	952
952	954	12.734	11.8952	19.02	19.02	2744.96	34.364	57.922	0.093	955
955	952	11.69899	12.734	28.53	19.02	2713.24	33.117	60.403	0.156	950
950	955	12.104	11.69899	28.53	28.53	2547.32	38.581	44.981	0.095	956
956	950	11.50281	12.104	28.53	28.53	2723	31.799	65.395	0	958
958	956	12.446	11.50281	9.82	28.53	2727.88	33.638	58.27	0	956

Figura 5.42 Representação de dados manipulados pelo Matlab, na forma de arquivos texto

Em uma máquina especialmente preparada para executar o treinamento, o mesmo ficou executando por um determinado tempo, variando de horas até dias, dependendo da capacidade de aprendizado da Rede. Ao final do treinamento, os pesos são salvos em arquivos, onde estes serão implementados no ambiente de produção. No apêndice D, são mostrados os programas utilizados para fazer o treinamento.

5.6. INTEGRAÇÃO COM FERRAMENTAS DE GESTÃO

O projeto do Sensor foi desenvolvido com objetivo de permitir integração com outras arquiteturas na forma de serviço, como demonstrado na figura 5.43.

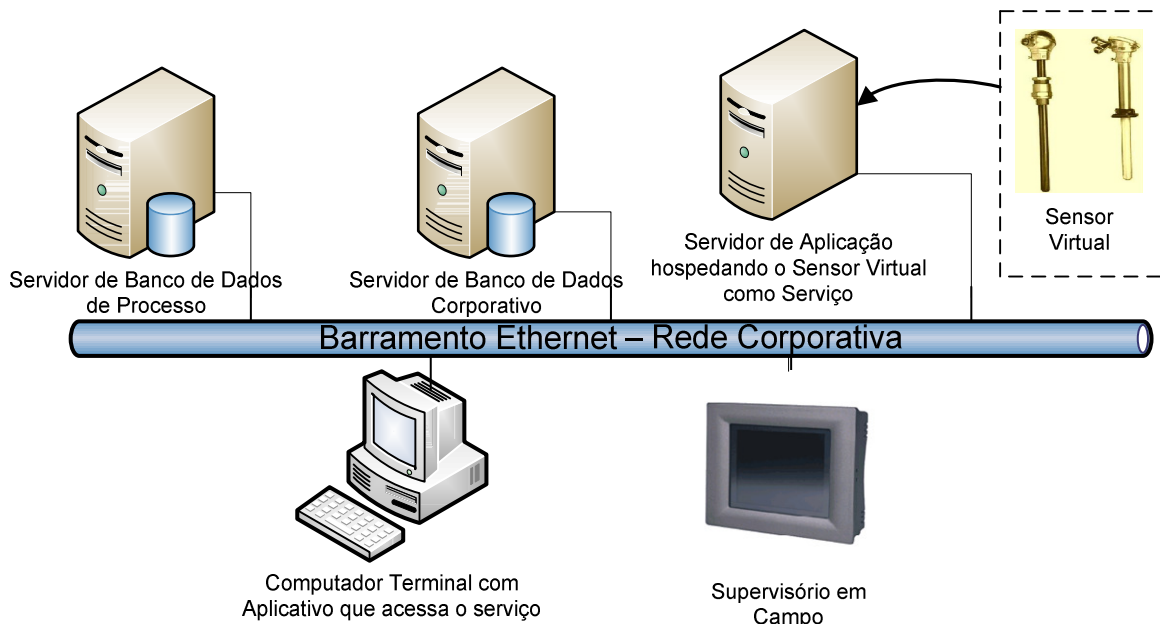


Figura 5.43 Diagrama Interligação do Sensor virtual com a Rede Corporativa como provedor de serviços

Nesta, o Sistema se comporta como um fornecedor de dados, de acordo com os seus parâmetros. Como o Sensor possui acesso às bases de dados de produção, basta

informar qual o forno e uma data para consultar o valor atual de temperatura e qual sua tendência.

Desta forma, o sensor e o simulador agora podem ser implementados e colocados em ambiente de produção, com o mínimo de ajuste possível nas ferramentas de gestão do processo já existentes. Como boa parte do processo ainda é dependente de interfaces humanas, esta arquitetura se mostra bem viável, uma vez que seria adicionada uma ferramenta a mais no parque tecnológico, garantindo mais uma fonte de dados para avaliação dos técnicos de processo.

5.7. CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados os procedimentos realizados para compor a proposta de estimação da temperatura em tempo real e sua previsão. O próximo passo agora é validar as soluções propostas, através de simulações. No capítulo seguinte, são apresentados os resultados das simulações.

6. RESULTADOS

Este capítulo mostra os resultados obtidos com o projeto do sensor virtual de temperatura e do Simulador de Balanço Térmico. Foram definidas redes candidatas em três níveis A, B e C. As redes A são as redes mais simples, com apenas duas camadas, uma escondida e uma de saída. As redes B são redes mais trabalhadas com três camadas, e as redes C são redes com quatro camadas. Cada rede candidata de nível A será denominada rede A1, A2, A3, ..., AN, o mesmo vale para as outras classes.

As redes neurais do sensor virtual de nível A foram definidas inicialmente com quatro neurônios na camada escondida e um na camada de saída. À medida que os treinamentos foram evoluindo, a quantidade de neurônios foi aumentando, até que o poder computacional ficasse sobrecarregado havendo excessiva demora no treinamento.

As redes neurais de nível B e C seguem o mesmo princípio, mas com dois layouts diferentes:

- **Layout Losangular:** Rede Neural com poucos neurônios nas primeiras camadas, muitos na camada escondida e um na saída (figura 6.1).
- **Layout Triangular:** Muitos neurônios nas primeiras camadas, menos neurônios na camada escondida e um na saída (figura 6.2).

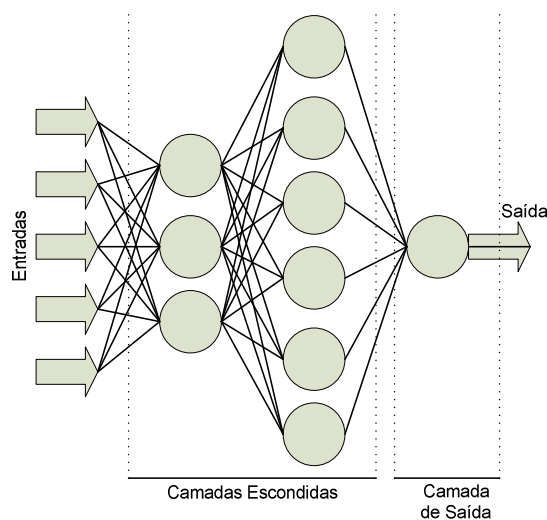


Figura 6.1 Layout Losangular

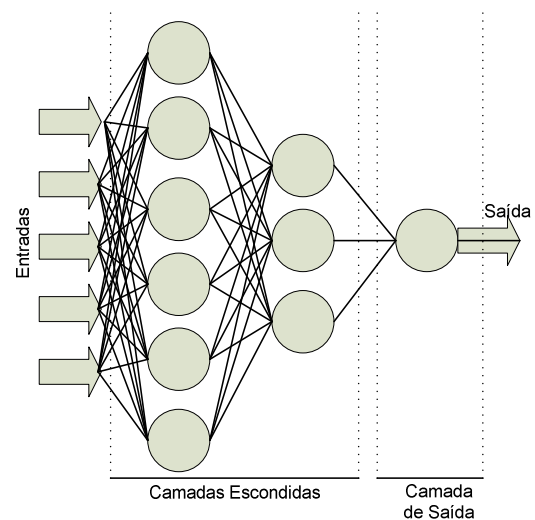


Figura 6.2 Layout Triangular

À medida que a rede demanda mais capacidade de generalização, quantidade de neurônios vai aumentar de acordo com o layout da rede.

6.1. TREINAMENTO

Os dados coletados para treinamento foram separados em 9 grupos, cada um com registros de 19 fornos. A proposta é treinar a rede neural com uma quantidade menor de dados, e gradualmente incluir demais dados para acrescentar conhecimento de outras áreas do processo. Esta metodologia de treinamento foi utilizada por Zanata em sua dissertação de mestrado [Zanata,2005], na qual denominou-se treinamento parcial.

O treinamento parcial é útil na construção de sensores virtuais por permitir a avaliar o desempenho da rede com dados já conhecidos e ao mesmo tempo avaliar a capacidade de evolução da mesma, ao se acrescentar novos dados para treinamento, o que ocorre com freqüência quando os sensores estão em operação.

Os grupos foram nomeados de T1 a T9, e sua escolha foi feita de forma aleatória. No apêndice B, estão detalhes de quais fornos participam de cada grupo. A cada treinamento parcial, o desempenho da rede será avaliado com o conjunto de testes. O treinamento parcial foi feito em 3 etapas, cada uma, levando-se em consideração apenas 3 conjuntos. Serão escolhidas três redes neurais a partir destas para representarem as redes de backup do sensor virtual. O treinamento parcial completo será feito na rede neural principal.

Para formar o simulador de balanço térmico, o treinamento parcial foi feito em uma etapa só, completo para todas as redes. Neste foi determinada apenas uma rede neural principal, sem backups.

Nesta seção são apresentados os procedimentos e os resultados obtidos com o treinamento parcial para construção das redes neurais do Sensor Virtual e do Simulador de Balanço Térmico. A validação ocorrerá, após treinamento completo com todo o conjunto de dados.

6.1.1. Sensor Virtual

6.1.1.1 TREINAMENTO PARCIAL – ETAPA I

Nesta etapa, houve o treinamento parcial das redes neurais considerando-se os conjuntos T1, T2 e T3, inicialmente.

As redes que apresentaram melhor resultado foram as mostradas na tabela 6-1:

Rede	Camada	Neurônios	Função de Ativação
B7b1	Primeira	16	Tangente Hiperbólica
	Segunda	32	Tangente Hiperbólica
B8b1	Primeira	64	Tangente Hiperbólica

	Segunda	24	Tangente Hiperbólica
C3b1	Primeira	8	Sigmóide
	Segunda	16	Tangente Hiperbólica
	Terceira	4	Tangente Hiperbólica
C4b1	Primeira	36	Tangente Hiperbólica
	Segunda	18	Sigmóide
	Terceira	6	Tangente Hiperbólica

Tabela 6-1 Configurações das Redes utilizadas com melhor desempenho

A tabela 6-2 mostra os erros mínimos quadrados alcançados por essas redes

Treinamento Parcial	Erro MSE das Redes			
	B7b1	B8b1	C3b1	C4b1
T1 (1653 reg.)	1,65e-2	1,25e-2	1,62e-2	1,95e-2
T2 (3310 reg.)	2,72e-2	2,28e-2	2,12e-2	2,44e-2
T3 (4964 reg.)	6,77e-2	6,28e-2	4,16e-2	5,36e-2

Tabela 6-2 Erros MSE das Redes após treinamento parcial

Embora o erro mínimo não tenha sido alcançado, obteve-se um resultado satisfatório conforme pode ser visualizado nos gráficos de treinamento e testes da rede C3b1 (figuras 6.3 a 6.8) e nos gráficos de dispersão (figuras 6.9 e 6.10).

Treinamento Sensor Virtual Backup I - Forno 126 Red. II




Figura 6.3 Gráfico de Treinamento do Sensor Virtual Backup I no Forno 126 (Red. II) após Treinamento Parcial T1, T2 e T3

Treinamento Sensor Virtual Backup I - Forno 132 Red. II




Figura 6.4 Gráfico de Treinamento do Sensor Virtual de Backup I no Forno 132 (red. II) após treinamento parcial T1,T2 e T3

Treinamento Sensor Virtual Backup I - Forno 248 Red. II




Figura 6.5 Gráfico do Treinamento do Sensor Virtual de Backup I Forno 248 (red. II) após treinamento parcial T1, T2 e T3

Testes Sensor Virtual Backup I - Forno 131 Red. II




Figura 6.6 Gráfico Testes do Sensor Virtual de Backup I no Forno 131 (red. II) após Treinamento T1, T2 e T3.

Testes Sensor Virtual Backup I - Forno 338 Red. II




Figura 6.7 Gráfico de Testes do Sensor Virtual de Backup I no forno 338 (Red. II) após Treinamento parcial T1, T2 e T3

Testes Sensor Virtual Backup I - Forno 148 Red. IV




Figura 6.8 Gráfico de Testes do Sensor Virtual de Backup I no forno 148 (Red. IV) após treinamento parcial T1,T2 e T3

Dispersão dos Pontos de Treinamento

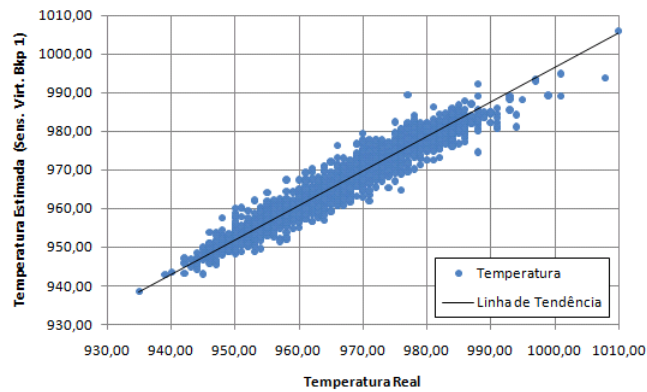


Figura 6.9 Gráfico de Dispersão dos Registros de Treinamento

Dispersão dos Pontos de Testes




Figura 6.10 Gráfico de Dispersão dos Registros de Testes Sensor Virtual de Backup 1

6.1.1.2 TREINAMENTO PARCIAL – ETAPA II

Na etapa II, foram usados os conjuntos de treinamento T4, T5 e T6. A tabela 6-3 mostra as redes que foram utilizadas neste procedimento.

Rede	Camada	Neurônios	Função de Ativação
B9b2	Primeira	36	Tangente Hiperbólica
	Segunda	18	Tangente Hiperbólica
B10b2	Primeira	20	Tangente Hiperbólica
	Segunda	40	Tangente Hiperbólica
C5b2	Primeira	22	Sigmóide
	Segunda	36	Tangente Hiperbólica
	Terceira	10	Tangente Hiperbólica

Tabela 6-3 Configuração das Redes usadas como backup II

Os Erros MSE foram os mostrados na tabela 6-4:

Treinamento Parcial	Erro MSE das Redes		
	B9b2	B10b2	C5b2
T4 (1660 reg.)	7,65e-3	1,05e-2	9,25e-3
T5 (3310 reg.)	9,72e-3	1,28e-2	1,34e-2
T6 (4963 reg.)	1,47e-2	3,28e-2	2,36e-2

Tabela 6-4 Erros MS das redes após treinamento parcial

Os gráficos das figuras 6.11 a 6.16 mostram o resultado da rede B9b2 após o treinamento parcial:




Figura 6.11 Resultado do Treinamento do Sensor Virtual Backup II para forno 201 (Red.II) após treinamento parcial

Treinamento Sensor Virtual Backup II - Forno 242 Red. IV




Figura 6.12 Resultado do Treinamento do Sensor Virtual Backup II para forno 242 (Red. IV) após treinamento parcial

Testes Sensor Virtual Backup II - Forno 226 Red. II




Figura 6.13 Resultado dos Testes do Sensor Virtual Backup II para o forno 226 (Red. II)

Testes Sensor Virtual Backup II - Forno 339 Red. II




Figura 6.14 Resultado dos Testes do Sensor Virtual de Backup II para forno 339 (Red. II)

Dispersão dos Pontos de Treinamento




Figura 6.15 Dispersão dos Registros de Treinamento Sens. Virt. Backup II




Figura 6.16 Dispersão dos Registros de Testes do Sens. Virt. Backup II

6.1.1.3 TREINAMENTO PARCIAL – ETAPA III

Os conjuntos utilizados nesta etapa foram o T7, T8 e o T9. As mesmas configurações apresentaram desempenho melhor:

<i>Rede</i>	<i>Camada</i>	<i>Neurônios</i>	<i>Função de Ativação</i>
B9b3	Primeira	36	Tangente Hiperbólica
	Segunda	18	Tangente Hiperbólica
B10b3	Primeira	20	Tangente Hiperbólica
	Segunda	40	Tangente Hiperbólica
C5b3	Primeira	22	Sigmóide
	Segunda	36	Tangente Hiperbólica
	Terceira	10	Tangente Hiperbólica

Tabela 6-5 Configuração das Redes Neurais usadas para Sens. Virtual Backup III

A tabela 6-6 mostra os resultados dos treinamentos:

<i>Treinamento Parcial</i>	<i>Erro MSE das Redes</i>		
	<i>B9b3</i>	<i>B10b3</i>	<i>C5b3</i>
T7 (1654 reg.)	9,65e-3	9,25e-2	5,25e-3
T8 (3307 reg.)	1,72e-2	9,28e-2	6,34e-3
T9 (4706 reg.)	3,77e-2	9,28e-2	8,36e-3

Tabela 6-6 Erro MSE das Redes após treinamento parcial

Os gráficos das figuras 6.17 a 6.22 mostram o desempenho da rede C5b3:

Treinamento Sensor Virtual Backup III - Forno 331 Red. II




Figura 6.17 Resultados do Treinamento Parcial do Sensor Virtual de Backup III para o Forno 331 (Red.II)

Treinamento Sensor Virtual Backup III - Forno 445 Red. IV




Figura 6.18 Resultados do Treinamento parcial do Sensor Virtual de Backup III para forno 445 (Red.IV)

Testes Sensor Virtual Backup III - Forno 315 Red. II




Figura 6.19 Resultados dos Testes do Sensor Virtual de Backup III para forno 315 (Red. II)

Testes Sensor Virtual Backup III - Forno 349 Red. II




Figura 6.20 Resultados dos Testes do Sensor Virtual de Backup III para forno 349 (Red. II)




Figura 6.21 Dispersão dos registros de treinamento parcial




Figura 6.22 Dispersão dos registros de testes do sensor virtual backup III.

As três redes backup serão usadas com a Rede Principal.

6.1.1.4 TREINAMENTO DA REDE PRINCIPAL

A rede principal foi escolhida a partir de arquiteturas já testadas na construção das redes de backup, havendo a inclusão de mais neurônios conforme demanda para melhores resultados.

Rede	Camada	Neurônios	Função de Ativação
C5p	Primeira	22	Tangente Hiperbólica
	Segunda	44	Sigmóide

	Terceira	12	Tangente Hiperbólica
C6p	Primeira	36	Tangente Hiperbólica
	Segunda	36	Sigmóide
	Terceira	12	Tangente Hiperbólica
C7p	Primeira	48	Tangente Hiperbólica
	Segunda	36	Tangente Hiperbólica
	Terceira	16	Tangente Hiperbólica

Tabela 6-7 Configurações das Redes Neurais Utilizadas para o Sensor Principal

Nestas, o treinamento foi total, envolvendo os 14633 registros, conforme definido em [Zanata, 2005]. Foi feito um teste com todas as redes. O desempenho da rede, embora não tenha sido muito bom, foi considerado satisfatório, conforme pode ser visualizado na tabela 6-8 e nos gráficos das figuras 6.23 a 6.28:

<i>Rede</i>	<i>Número de Épocas</i>	<i>Erro MSE</i>
C5p	126	0,042
C6p	451	0,038
C7p	776	0,035

Tabela 6-8 Erro MSE e número de épocas de treinamento em cada uma das redes.

Treinamento Sensor Virtual Principal - Forno 132 Red. II




Figura 6.23 Resultado do Treinamento Redes Neurais Sensor Virtual Principal Forno 132 (Red.II)

Treinamento Sensor Virtual Principal - Forno 133 Red. II




Figura 6.24 Resultados Treinamento Sensor Virtual Principal Forno 133 (Red.II)

Teste Sensor Virtual Principal - Forno 132 Red. II




Figura 6.25 Resultado dos Testes Sensor Virtual Principal para Forno 132 (Red.II)

Teste Sensor Virtual Principal - Forno 133 Red. II




Figura 6.26 Resultados dos Testes do Sensor Virtual Principal para Forno 133 (Red.II)




Figura 6.27 Dispersão dos Registros de Treinamento do Sensor Virtual Principal




Figura 6.28 Dispersão dos Pontos de Testes do Sensor Virtual Principal

No entanto, operando em paralelo com as redes de backup o desempenho da rede melhor bastante, conforme mostrado na tabela 6-9.

<i>Rede com backup</i>	<i>Erro MSE</i>
C5p	2,24e-2
C6p	3,25e-2
C7p	1,38e-2

Tabela 6-9 Erro MSE das Redes simuladas com Backup

Os gráficos das figuras 6.29 a 6.31 mostram apenas a comparação dos resultados entre o sensor virtual com e sem backup:

Teste Sensor Virtual Principal com Backup - Forno 132 Red. II




Figura 6.29 Testes do Sensor Virtual com Backup no Forno 132 (Red.II)

Teste Sensor Virtual Principal com Backup - Forno 133 Red. II




Figura 6.30 Testes do Sensor Virtual com Backup no Forno 133 (Red.II)




Figura 6.31 Dispersão dos Registros de Testes com Backup

6.1.2. Simulador de Balanço Térmico

Para as redes do simulador de balanço térmico, houve também o treinamento parcial, mas sem a necessidade de backup, foram testadas redes dos três níveis para verificar uma arquitetura mais adequada. Porém, as redes que tiveram melhor desempenho foram as redes C, que foram configuradas de acordo com as tabelas 6-10 e 6-11. As figuras 6.32 a 6.37 mostram os resultados do simulador de Balanço Térmico.

Rede	Camada	Neurônios	Função de Ativação
C1	Primeira	10	Tangente Hiperbólica
	Segunda	12	Sigmóide
	Terceira	6	Tangente Hiperbólica
C2	Primeira	10	Tangente Hiperbólica
	Segunda	24	Sigmóide
	Terceira	12	Tangente Hiperbólica
C3	Primeira	12	Tangente Hiperbólica
	Segunda	144	Tangente Hiperbólica
	Terceira	12	Tangente Hiperbólica

Tabela 6-10 Configuração das Redes Neurais usadas para o simulador de Balanço Térmico

Treinamento Parcial	Erro MSE das Redes		
	C1	C2	C3

T1 (1653 reg.)	5,632e-2	4,3248e-2	2,5791e-2
T2 (3310 reg.)	5,872e-2	4,8412e-2	3,22632e-2
T3 (4964 reg.)	6,287e-2	5,2981e-2	3,3487e-2
T4 (6624 reg.)	6,397e-2	5,6213e-2	3,4898e-2
T5 (8274 reg.)	6,5534e-2	5,9923e-2	3,8572e-2
T6 (9927 reg.)	6,5432e-2	6,0017e-2	4,0274e-2
T7 (11581 reg.)	6,5834e-2	6,0872e-2	4,0471e-2
T8 (13234 reg.)	6,5238e-2	6,0832e-2	4,03289e-2
T9 (14633 reg.)	6,5287e-2	6,0815e-2	4,0534e-2

Tabela 6-11 Erro MSE das Redes Neurais do Simulador de Balanço Térmico

Treinamento Simulador Térmico - Forno 136 (Red.II)




Figura 6.32 Resultado do Treinamento do Simulador Térmico Forno 136 (Red.II)

Treinamento Simulador Térmico - Forno 213 (Red.II)




Figura 6.33 Resultado do Treinamento do Simulador de Balanço Térmico – forno 213 (Red.II)

Teste Simulador Térmico - Forno 351 (Red.IV)




Figura 6.34 Teste Simulador de Balanço Térmico – Forno 351 (Red. IV)

Teste Simulador Térmico - Forno 352 (Red.IV)




Figura 6.35 Teste Simulador Térmico Forno 352 Red.IV

Dispersão Registros de Treinamento




Figura 6.36 Gráfico de Dispersão dos Registros de Treinamento

Dispersão Registros de Testes

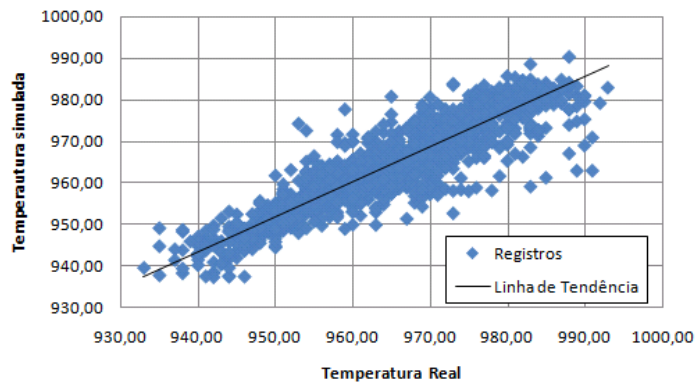


Figura 6.37 Gráfico de Dispersão dos Registros de Testes

Notavelmente, mostra-se a superioridade no desempenho das redes com quatro camadas. Isto talvez se deva no fato de ao acrescentar-se uma camada a mais à rede, há um aumento na capacidade de generalização, por inserir mais um nível de abstração dos dados de treinamento. Isto, aliado a um bom algoritmo de treinamento resulta um bom desempenho.

É importante ressaltar que o simulador de balanço térmico não precisa ser muito exato, pois sua finalidade é fazer uma inferência sobre a tendência da temperatura de acordo com o que está sendo adicionado no forno.

6.2. VALIDAÇÃO

Para validação foram avaliados os desempenhos do sensor virtual e do simulador com dados reais do conjunto de validação V. São apresentados nesta seção casos que houve boa estimativa, juntamente com os erros ocorridos.

6.2.1. Sensor Virtual sem o Backup

Os gráficos das figuras 6.38 a 6.41 mostram a simulação do sensor virtual para dados reais dos fornos de validação da redução II.




Figura 6.38 Validação do Sensor Virtual no Forno 204 (Red.II). Erro MSE 14,91. Caso Comum.




Figura 6.39 Validação do Sensor Virtual no Forno 201 (Red. II). Erro MSE 8,24. Caso ótimo.




Figura 6.40 Validação Sensor Virtual no Forno 252 (Red.II), Erro MSE: 22,45. Caso ruim.

Dispersão dos Pontos de Validação - Sensor Virtual




Figura 6.41 Gráfico de Dispersão dos registros de validação do sensor virtual

Nota-se a presença de erros espúrios no sensor virtual, onde o erro máximo pode chegar até $\pm 30^{\circ}\text{C}$. No entanto, como em 87% dos casos o erro foi inferior a $\pm 5^{\circ}\text{C}$, o desempenho foi considerado satisfatório pela equipe. Eventuais ajustes no modelo podem ser corrigidos com a utilização de backups.

Este teste, entretanto, foi feito não havendo a realimentação na rede. Utilizando-se a realimentação da saída na entrada, o resultado não foi satisfatório, havendo a presença de erros sistêmicos, conforme mostrado nas figuras 6.42 a 6.44.

Validação Sensor Virtual com realimentação - Forno 208 Red.II




Figura 6.42 Resultados do Sensor Virtual com realimentação – Forno 208 (Red.II). Erro MSE: 28,36.




Figura 6.43 Resultados do Sensor Virtual com realimentação – Forno 134 (Red.II). Erro MSE: 33,15.




Figura 6.44 Dispersão dos Registros de Validação com realimentação

Este seria o caso se não houvesse mais a medida de temperatura. Contudo, como parte do processo, a medida de temperatura pode continuar, e o sensor virtual teria aplicação para estimar temperaturas em horários sem a medida. Para estes casos, é indicada a realimentação.

6.2.2. Sensor Virtual com Backup

A utilização de backups consiste em fornecer três valores adicionais à previsão da rede, e se houver uma diferença grande entre elas, o backup pode sinalizar que a previsão poderá estar errada, e não confiável. O ajuste, porém, pode ser feito através da média das medidas. Na saída do sensor são disponibilizados valores máximos e mínimos da previsão. Como a natureza do processo é complexa, é possível que a temperatura real do forno seja inexata, flutuante em uma faixa de até 5°C.

Os gráficos das figuras 6.45 a 6.48 mostram os três casos de desempenho do sensor com backup.




Figura 6.45 Validação Sensor Virtual com Backup Forno 231 (Red. IV). Erro MSE: 5,45.




Figura 6.46 Validação Sensor Virtual com Backup Forno 136 (Red.II). Erro MSE: 3,28.




Figura 6.47 Resultado de Validação do Sensor Virtual para Forno 252 (Red.IV). Erro MSE: 6,29.




Figura 6.48 Dispersão dos Registros de Validação do Sensor Virtual com Backup

O caso com maior erro apresentou erro máximo de $\pm 12^{\circ}\text{C}$, havendo, portanto melhora significativa na previsão.

Utilizando-se a realimentação da saída (figura 6.49), porém, até 2 passos sem a medida de temperatura, nota-se uma ligeira queda no desempenho, portanto, sendo recomendado manter as medidas para nova “calibração do modelo”, isto é, permitir que o modelo seja retreinado para um caso específico.




Figura 6.49 Validação do Sensor Virtual com Realimentação Forno 134 (Red.II). Erro: 21,77.

6.2.3. Simulador de Balanço Térmico

A validação do simulador de balanço térmico foi feita com e sem a realimentação, conforme exposto nos gráficos das figuras 6.50 a 6.53:

Validação Simulador Térmico - Forno 113 (Red.IV)




Figura 6.50 Validação do Simulador Térmico Forno 113 (Red.IV). Erro MSE: 12,25 (sem realimentação), 26,87 (com realimentação)

Validação Simulador Térmico - Forno 441 (Red.II)




Figura 6.51 Validação do Simulador de Balanço Térmico Forno 441 (Red.II). Erro MSE: 15,43 (sem realimentação); 45,88 (com realimentação)




Figura 6.52 Dispersão dos Registros de validação do Simulador de Balanço Térmico sem realimentação




Figura 6.53 Dispersão dos Registros de Validação do Simulador de Balanço Térmico com realimentação

Os erros máximos obtidos no simulador sem realimentação foram na ordem de +/- 15°C, sendo que em 92% dos casos a diferença do estimado para o real foi inferior a +/-5°C, desta forma considerando-se o simulador satisfatório, sem a realimentação.

Com a realimentação, a evolução foi um pouco diferente. Como o erro da estimação é menor, ao longo do tempo sem as medidas de temperatura, o desempenho piora, ocasionando erros sistêmicos como o do forno 441 (Red. II). Para se ter um bom desempenho sem a necessidade de fazer as medidas de temperatura, foram simuladas duas situações, uma com medidas a cada 64 horas e outra com medidas a cada 96 horas. Os resultados estão exibidos nas figuras 6.54 e 6.55.

Validação Simulador Térmico - Forno 113 (Red.IV)




Figura 6.54 Validação do Simulador Térmico com realimentações e medidas a cada 64 e 96 horas, forno 113 (Red.IV). Erro MSE: 14,52 (Realim. 64h), 14,59 (Realim. 96h).

Validação Simulador Térmico - Forno 441 (Red.II)




Figura 6.55 Validação do Simulador Térmico com realimentações e medidas a cada 64 e 96 horas, forno 441 (Red.II). Erro MSE: 11,8 (Realim. 64h), 12,99 (Realim. 96h).

O erro máximo foi de +/- 16,5°C, portanto, mantido para essas estimativas utilizando-se a realimentação. Portanto, o simulador de balanço térmico se mostra capaz de operar independente das medidas de temperatura em até 96 horas. Tal economia resultará em um aumento da vida útil de cada termopar em 200%.

6.3. AJUSTES E MELHORAMENTOS

Com os resultados obtidos, o novo desafio é ajustar e melhorar os modelos. Uma análise dos resultados em que houve um erro alto da estimação foi feita.

Quando não há realimentação, ou seja, as medidas continuam sendo feitas normalmente, houve um desempenho satisfatório. Com realimentação, o desempenho é satisfatório no início, mas as estimações erradas se propagam para registros em datas futuras. Um ajuste pode ser feito na realimentação em até 3 passos, como ocorreu na simulação do balanço térmico, economizando o trabalho de medida de temperatura em 200%. Uma alternativa interessante é utilizar o sensor apenas como um preditor futuro da variável, mantendo-se as medidas, e utilizar o sensor virtual apenas para fazer estimações da temperatura em horários extras. Neste cenário, os erros a serem tratados se resumem aos fornos 244, 252 e 304 da redução II e 254 da redução IV. No simulador de balanço térmico, os erros ocorridos nos fornos 441 da redução II e 113, 351 e 352 da redução IV, a princípio, podem ter sido causados por dados não previstos na entrada.

Forno (Redução)	Data	VMR	RMR	A%1	%TUN	ALF3A_1	TMP_1	TMP real	TMP sensor sem backup	TMP sensor com backup
244(Red.II)	04/01/2008	4,35	14,99	107,25	31,312	28,8	962	972	959,53	965,09
304(Red.II)	03/01/2008	4,35	15,02	108,09	35,034	19,6	954	952	948,03	970,84
252(Red.II)	03/12/2007	4,45	15,55	97,35	51,88	40,24	966	962	970,92	969,12
254(Red.IV)	27/12/2007	4,36	15,03	100,62	42,71	38,40	972	980	963,18	970,25

Tabela 6-12 Alguns registros do Sensor virtual com estimaco errada

Forno (Reduo)	Data	QALr_1	ALF_1	%TOV_1	%TUN_1	ALF3A_1	TMP_1	TMP real	TMP sensor sem realim.	TMP sensor com realim.
113(Red.IV)	09/11/2007	2558,25	7,51	53,27	38,22	67,8	983	978	980,21	957,23
113(Red.IV)	03/12/2007	2683,34	11,85	61,29	33,396	22,6	950	973	956,94	956,09
113(Red.IV)	14/12/2007	2345,84	6,64	33,332	45,928	66	981	988	968,77	980,58
113(Red.IV)	28/12/2007	2629,06	10,32	53,431	31,415	44	962	965	958,03	958,09
351(Red.IV)	24/12/2007	2264,29	9,14	30,706	55,486	33	968	954	972,43	963,21
351(Red.IV)	03/01/2008	2542,44	12,68	32,53	39,55	11	950	973	965,48	957,96
352(Red.IV)	25/11/2007	2567,69	13,26	42,95	33,33	11,3	947	969	954,15	961,57
352(Red.IV)	27/11/2007	2329,32	9,64	33,33	50,435	33,9	969	980	969,61	973,86
352(Red.IV)	28/11/2007	2437,89	6,79	44,91	49,999	67,8	980	969	978,06	973,53
352(Red.IV)	05/12/2007	2702,22	8,53	57,568	30,009	55	968	963	949,77	956,38
352(Red.IV)	11/12/2007	2610,17	13,07	43,798	37,134	0	948	935	949,01	941,99
441(Red.II)	20/11/2007	2577,37	8,23	50	42,577	39,28	967	975	969,83	961

441(Red.II)	07/12/2007	2366,68	7,97	40,42	52,939	40,24	974	971	972,91	978,24
441(Red.II)	21/12/2007	2494,07	14,25	38,861	40,33	0	942	950	955,58	942
441(Red.II)	25/12/2007	2550,42	10,78	46,58	43,73	60,36	954	967	959,5	959,5
441(Red.II)	26/12/2007	2545,52	9,34	44,45	43,112	50,3	967	954	963,62	957
441(Red.II)	08/01/2008	2555,32	12,68	51,05	42,975	0	950	954	953,23	969

Tabela 6-13 Alguns Registos do Simulador Balanço Térmico com estimação errada. Em destaque os registos em que a estimação errada foi dada sem realimentação.

Nesta análise, porém, constatou-se que o sensor virtual procura seguir a tendência de temperatura conforme as manobras operacionais. Tais tendências até são consideradas corretas pelos especialistas no processo, mas na prática funcionam de modo diferente por razões ainda desconhecidas. Por exemplo, o erro de estimação ocorrido no forno 254 da redução IV, no qual era esperada a temperatura 980 graus e foi estimada em 972 (com backup), pode ter causado por alguma manobra inesperada ocorrida. Em pesquisa a base, constatou-se que outras medidas de temperatura para valores na entrada semelhantes variaram de 959 a 988, com média de 972,75, justamente o valor dado pelo sensor virtual com backup.

Dada a dificuldade de se analisar e detectar tais erros, esta análise ficou restrita apenas aos casos de validação envolvendo medidas reais. Os ajustes que podem ser feitos incluem o retreinamento para outros pontos não incluídos. Uma outra estratégia pode ser utilizar o treinamento parcial por uma determinada seção ou redução, já que cada uma compartilha certos parâmetros, ao invés de se utilizar um treinamento total com muitos registros.

6.4. TRATAMENTO DOS ERROS

Nesta seção são apresentados alguns ajustes feitos para reduzir os erros das estimativas.

6.4.1. Retreinamento das Redes Neurais

Com objetivo de aperfeiçoar a capacidade de generalização das redes neurais, são apresentados a elas dados adicionais provenientes dos fornos os quais se está operado. Tal estratégia pode resultar numa redução do erro em casos específicos, porém pode aumentar em outros casos, já que haverá alteração nos pesos da rede. Então, uma alternativa pode ser a utilização desses dados locais como backups para a rede principal.

Nesta etapa, foi feito o retreino da rede neural do sensor virtual para os fornos 244, 252 da redução II, e do simulador de balanço térmico, foi feito um retreino nos fornos 351 e 352. Com um conjunto de dados menor, o erro máximo é diminuído.

Sistema	Rede	Camada	Neurônios	Função de Ativação
Sensor Virtual	C7mt	Primeira	48	Tangente Hiperbólica
		Segunda	36	Tangente Hiperbólica
		Escondida	16	Tangente Hiperbólica
Simulador De Balanço Térmico	C3t	Primeira	12	Tangente Hiperbólica
		Segunda	144	Tangente Hiperbólica
		Escondida	12	Tangente Hiperbólica

Tabela 6-14 Configuração das Redes Neurais utilizadas para retreino

Rede	Número de Épocas	Erro MSE
C7m	76	9,971e-4
C3t	126	8,25e-4

Tabela 6-15 Resultado do retreinamento das redes apresentadas

Forno (Redução)	Data	TMP real	TMP sensor com backup	TMP estimada após treino	TMP sensor com backup após treino	Erro sensor com backup	Erro sensor com treino
244(Red.II)	01/08/2007	953	955,09	952,37	951	2,09	-2
244(Red.II)	02/08/2007	954	957,84	954,87	950,22	3,84	-3,78
244(Red.II)	03/08/2007	961	963,12	959,44	958,97	2,12	-2,03
244(Red.II)	05/08/2007	961	955,25	961,4	964,35	-5,75	3,35
244(Red.II)	06/08/2007	953	960,18	950,25	957,33	7,18	4,33
244(Red.II)	07/08/2007	959	957,33	961,8	960,83	-1,67	1,83
244(Red.II)	09/08/2007	958	958,93	958,58	957,87	0,93	-0,13
252(Red.II)	07/06/2007	981	975,44	979,86	979,36	-5,44	-1,64
252(Red.II)	08/06/2007	978	980,26	978,87	979,35	2,26	1,35
252(Red.II)	10/06/2007	973	975,4	971,97	973,04	2,4	0,04
252(Red.II)	11/06/2007	979	978,2	978,66	978,38	-0,8	-0,62
252(Red.II)	12/06/2007	978	976,54	979,53	978,31	-1,46	0,31
252(Red.II)	14/06/2007	981	980,23	980,01	980,14	-0,77	-0,86
252(Red.II)	15/06/2007	978	973,59	979,83	977,52	-4,41	-0,48

Tabela 6-16 Alguns registros de testes nos fornos treinados

Os testes mostram que os erros ocorridos nos fornos diminuíram. Porém, ao se testar para outros valores não incluídos no treinamento, o erro aumentou, como mostrado na tabela 6-17.

Forno (Redução)	Data	TMP real	TMP sensor com backup	TMP estimada após retreino	TMP sensor com backup após retreino	Erro sensor com backup	Erro sensor com retreino
249(Red.II)	04/07/2007	951	950,87	953,31	952,52	-0,13	1,52
249(Red.II)	05/07/2007	953	954,54	950,83	951,78	1,54	-1,22
249(Red.II)	06/07/2007	958	959,75	963,4	962,71	1,75	4,71
249(Red.II)	08/07/2007	955	956,22	965,05	962,85	1,22	7,85
250(Red.II)	20/06/2007	980	979,34	979,67	979,56	-0,68	-0,44
250(Red.II)	22/06/2007	983	981,77	973,89	978,15	-1,23	-4,85
250(Red.II)	23/06/2007	977	975,06	972,97	974,46	-1,94	-3,54
250(Red.II)	24/06/2007	979	974,61	968,13	973,15	-4,39	-5,85
250(Red.II)	26/06/2007	975	975,87	970,53	971,99	0,87	-3,01

Tabela 6-17 Resultado dos testes para outros fornos

Outra possibilidade é que tal erro pode ser proveniente de elementos externos ao modelo, que não são contemplados pelo sistema. Uma análise detalhada dos erros é necessária para saber qual melhor estratégia usar neste caso.

6.4.2. Análise detalhada dos tipos de Erros

Os erros mais comuns são os erros espúrios e os sistêmicos. A causa e a razão de cada um deles são distintas.

6.4.2.1 ERROS ESPÚRIOS

Esta classe de erros é causada por uma brusca variação da estimação causada por algum padrão de dado não previsto na entrada, ou confundido com outro padrão que fornecesse saída diferente.

Validação Simulador Térmico - Forno 113 (Red.IV)




Figura 6.56 Erro espúrio ocorrido na simulação do Balanço Térmico

Validação Sensor Virtual com realimentação - Forno 208 Red.II




Figura 6.57 Principais erros espúrios ocorridos no Sensor virtual

A detecção deste tipo de erro é fácil, mas a razão de sua causa pode ser difícil saber. Foram comparadas entradas similares que produziram erros espúrios, e constatou-se que a diferença entre elas foi pouquíssima, incluindo o fato de uma estimativa estar bem próxima do real.

Forno (Redução)	Data	VMR	RMR	A%1	IncTM	ALF3A_1	TMP_1 realim.	TMP real	TMP estimada
208(Red.II)	22/11/2007	4,39	15,37	114,69	-0,048	48,75	971,36	973	953,12
208(Red.II)	01/12/2007	4,33	15,27	110,712	0	48	967,31	960	980,4
208(Red.II)	04/01/2008	4,28	14,61	110,034	-0,012	48	968,62	967	980,71

Tabela 6-18 Alguns registros de erros espúrios com entradas similares

<i>Variável</i>	<i>Faixa</i>
VMR	[4,27 4,40]
RMR	[14,5 15,5]
A%1	[110 115]
IncTM	[-0.05 0]
TUN	[35 40]
ALF3A_1	[43 51]
TMP_1	[966 972]

Tabela 6-19 Faixa de variáveis escolhida para consultar comportamento da temperatura

<i>Faixa de TMP</i>	<i>Registros cujos valores de entrada são similares aos dos erros espúrios</i>
(940 945]	1
(945 950]	0
(950 955]	3
(955 960]	4
(960 965]	7
(965 970]	12
(970 975]	5
(975 980]	2
(980 985]	1

Tabela 6-20 Frequência de ocorrência de erros espúrios para as entradas similares

Nota-se nas tabelas 6-19 e 6-20 que um mesmo grupo de entradas fornece dados de temperatura dispersos, o que não necessariamente caracteriza erros espúrios, mas por erros de medições ou eventos ocorridos no processo, podem causar variações na temperatura. A utilização de backups reduz a amplitude dos erros, sendo portanto recomendada para estes casos.

No forno 132 da redução II, a estimação da temperatura se manteve estável, mas a temperatura real sofreu alta variação, não descaracterizando tal situação como sendo um erro espúrio, mostrado na figura 6.58.




Figura 6.58 Variações muito bruscas na temperatura real do forno 132 (Red.II)

Esses casos são de difícil correção, e para estes fornos com esse tipo de variação de origem desconhecida não é recomendável o uso de sensores virtuais, até que se tenha um estudo detalhado sobre a dinâmica do balanço térmico.

6.4.2.2 ERROS SISTÊMICOS

Esta classe de erros ocorre principalmente quando há realimentação. A presença de dados ruidosos pode desencadear uma seqüência de erros nas estimativas, chamados erros sistêmicos. Tais erros são mais comuns sem a presença de backups. Com os sensores de backup, estes são diminuídos. Alguns deste tipo de erro foram detectados no simulador de balanço térmico com realimentação até 96 horas, mostrados na figura 6.59.

Validação Simulador Térmico - Forno 347 (Red.II)




Figura 6.59 Erro sistêmico ocorrido no simulador de balanço térmico para forno 347 (Red.II)

Nesse caso, a estimativa sem realimentação apresenta um bom desempenho, mas quando há realimentação, o erro da estimativa, por menor que seja se propaga para as previsões futuras, havendo a necessidade de se manter as medidas. Este caso pode ser resolvido melhorando-se o desempenho do simulador para garantir resultados mais fiéis ao real. Tal estratégia pode ser implementada com o retreino do simulador para dados locais, estes utilizados como backup do simulador.

6.5. IMPLEMENTAÇÃO DE AJUSTES E VALIDAÇÃO

Os ajustes implementados foram o retreinamento da rede para conjuntos de dados menores separados por seção e a utilização de uma rede adicional de backup no simulador, contendo dados do próprio forno.

6.5.1. Sensor Virtual

Os resultados das validações do sensor virtual são apresentados nos gráficos das figuras 6.60 a 6.63, juntamente com os gráficos comparativos dos erros. O desempenho geral é mostrado na tabela 6-21.




Figura 6.60 Testes de Validação do Sensor Virtual com retreino forno 244 (Red.II)




Figura 6.61 Validação Sensor Virtual após retreino – forno 252 (Red.II)

Validação Sensor Virtual após retreino - Forno 252 Red. IV




Figura 6.62 Validação do Sensor Virtual após retreino forno 252 (Red.IV)

Dispersão de Registros Sensor Virtual após retreino




Figura 6.63 Dispersão de Registros do Sensor Virtual após retreino

Redução	Seção	Erro MSE		
		SV sem backup	SV com backup	SV com retreino
Red.II	11	14,25	8,33	4,95
Red.II	12	13,37	7,34	3,35
Red.II	21	14,85	7,89	3,38

Red.II	22	16,46	8,98	4,05
Red.II	31	13,11	6,35	4,21
Red.II	32	13,89	6,71	4,8
Red.II	41	15,32	7,31	4,56
Red.II	42	14,28	7,41	4,89
Média Red.II		14,44	7,54	4,2737
Red.IV	11	14,37	6,92	3,17
Red.IV	12	13,97	7,03	3,08
Red.IV	21	15,39	8,54	3,95
Red.IV	22	16,23	8,1	3,57
Red.IV	31	15,34	6,22	4,28
Red.IV	32	14,8	5,86	3,75
Red.IV	41	14,38	6,34	4,17
Red.IV	42	14,27	6,22	4,45
Média Red.IV		14,84	6,903	3,8025
Média Geral		14,64	7,221	4,03

Tabela 6-21 Erro MSE geral do sensor virtual por seção.

6.5.2. Simulador de Balanço Térmico

O simulador de Balanço Térmico, após os ajustes funcionou de forma bem satisfatória, mantendo o erro MSE em torno dos 6,876 °C, conforme mostrado nas figuras 6.64 a 6.66.




Figura 6.64 Validação do Simulador Térmico após retreino por seção - Forno 351 (Red.IV)

Validação Simulador Térmico - Forno 441 (Red.II)




Figura 6.65 Validação do Simulador Térmico após Retreino – Forno 441 (Red.II)

Dispersão dos Registros Simulador Térmico com retreino

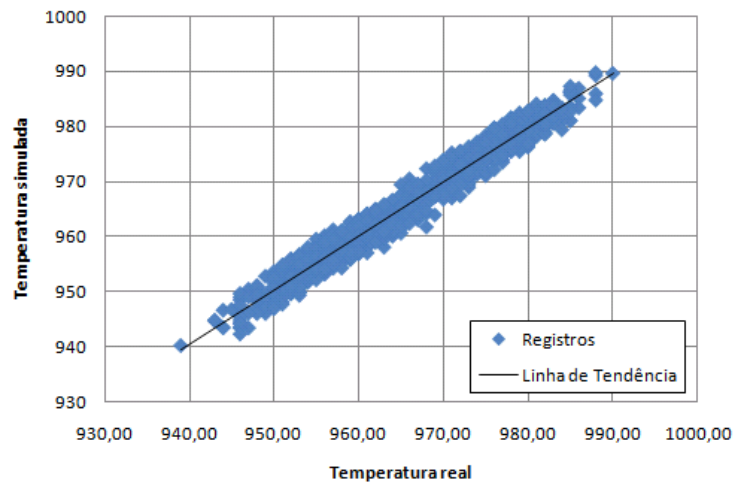


Figura 6.66 Dispersão dos Registros do Simulador Térmico com retreino.

Havendo realimentação até 96 horas, o desempenho foi igualmente semelhante e satisfatório para a equipe. Os resultados estão mostrados nas figuras 6.67 a 6.69, e o desempenho geral é mostrado na tabela 6-22.




Figura 6.67 Validação do Simulador Térmico após retreino com realimentação 96h Forno 352 (red.IV)




Figura 6.68 Validação do Simulador Térmico após Retreino com realimentação 96h Forno 441 (red.II)




Figura 6.69 Dispersão dos Registros do Simulador Térmico com realimentação 96h e retreino

<i>Redução</i>	<i>Seção</i>	<i>Erro MSE</i>			
		<i>ST</i>	<i>ST com realim.</i>	<i>ST com retreino</i>	<i>ST com retreino e realim.</i>
Red.II	11	15,65	15,98	6,712	6,612
Red.II	12	15,87	16,25	6,983	6,872
Red.II	21	15,33	17,45	6,821	6,961
Red.II	22	15,21	17,23	6,651	6,519
Red.II	31	14,77	17,02	7,124	7,013
Red.II	32	16,23	16,91	7,214	7,034
Red.II	41	15,11	16,21	6,584	6,471
Red.II	42	14,76	17,99	6,856	7,128
Média Red.II		15,35	16,88	6,868	6,826
Red.IV	11	18,39	19,61	8,124	7,793
Red.IV	12	16,76	19,87	6,545	7,231
Red.IV	21	17,61	19,41	6,78	7,075
Red.IV	22	14,65	18,37	7,026	7,017
Red.IV	31	16,37	18,95	6,923	6,892
Red.IV	32	18,22	19,27	6,758	6,946
Red.IV	41	14,32	18,36	6,326	6,335
Red.IV	42	15,37	18,34	6,356	6,939
Média Red.IV		16,46	19,0225	6,854	7,0026
Média Geral		15,905	17,951	6,861	6,9143

Tabela 6-22 Erro MSE dos Simuladores Térmicos.

6.6. CONSIDERAÇÕES FINAIS

Após diversas tentativas de se obter um modelo neural robusto baseado em MLP, chega-se a uma configuração satisfatória. Tal estrutura permitirá a simulação de adições químicas nos fornos, e até o estudo de possíveis comportamentos resultantes nos fornos por variações grandes na sua operação.

As estratégias utilizadas para ajustar o desempenho das redes foram eficazes atendendo a maioria dos casos com previsões e erros menores do que $\pm 5^{\circ}\text{C}$. O treinamento parcial se mostrou eficiente por permitir que um número muito grande de registros fosse aprendido pelas redes neurais de maneira gradual, assim seu desempenho foi bastante melhorado.

Por fim, a possibilidade de se implementar tais estruturas computacionalmente em linguagens de alto nível é outra vantagem comprovada no trabalho. Assim, aplicações de controle ou corporativas poderão incorporar esse modelo programaticamente.

7. CONCLUSÃO

Este trabalho foi motivado a partir de uma dificuldade encontrada na indústria, cuja solução teria grande impacto no seu processo. As variações de temperatura em fornos eletrolíticos são um grande desafio para especialistas e pesquisadores do mundo todo, que trabalham por uma solução mais eficiente para controle do balanço térmico.

A grande contribuição deste trabalho é a modelagem térmica de fornos eletrolíticos através de sensores virtuais, seguindo uma tendência de se utilizar algoritmos e técnicas de inteligência computacional, indicada para problemas de difícil modelagem e complexos. Sua função principal é fornecer dados sobre a temperatura dos fornos através de dados já disponíveis pelo processo em sua enorme base de dados.

Após um trabalho exaustivo, acrescentaram-se várias contribuições, realizadas em outros trabalhos similares, para se obter no fim um resultado satisfatório para a equipe de processo.

7.1. LIMITAÇÕES E DIFICULDADES

Uma das grandes limitações encaradas no trabalho foi a pouca literatura sobre o assunto disponível para consulta, por se tratar de uma área de aplicação restrita. Tais estudos poderiam ter sido mais decisivos no início do problema, em se aplicando uma técnica já utilizada em trabalho similar, no caso a previsão da temperatura.

A falta de tempo disponível para comparação dos resultados com outras arquiteturas também foi uma dificuldade enfrentada. O enorme tempo gasto nos treinamentos das redes foi um entrave enfrentado, uma vez que as simulações demoravam várias horas, consumindo todo o recurso computacional existente.

7.2. BENEFÍCIOS ESPERADOS

Os sensores virtuais aplicados a processos químicos tem se tornado grande sucesso nas indústrias e suas utilizações vem crescendo a cada dia. Com eles, é possível a redução de custos operacionais, substituindo hardware físico por software, que pode ser implementado em qualquer linguagem de programação, em uma arquitetura orientada a serviços, facilmente integrável com outras plataformas.

Para o sensor virtual, possibilitou-se a estimação da temperatura online, sem a necessidade de medição direta nos fornos. Outro benefício do uso do sensor virtual é a identificação de tendências inesperadas na temperatura, podendo se fazer adições extras

de fluoreto nos fornos. Com um controle mais frequente, espera-se que as altas variações na temperatura dos fornos sejam diminuídas.

Com o simulador do balanço térmico, é possível simular a tendência de temperatura ao se adicionar virtualmente fluoreto nos fornos. Tal informação pode facilitar a decisão do técnico de processo, que muitas vezes age baseado na sua própria experiência no trabalho.

7.3. TRABALHOS FUTUROS

São inúmeros os trabalhos que podem ser implementados a partir deste, dentre os quais podem ser classificados em:

- Sensores Virtuais para outras variáveis no processo
- Utilização de Técnicas Avançadas de Redes Neurais
- Implementação de Sistema de Estimação Integrado à outras arquiteturas

7.3.1. Projeto de Sensores Virtuais para outras variáveis

Usando a mesma metodologia, este modelo pode ser replicado para inferir outras variáveis críticas no processo, como concentração de fluoreto em excesso no banho, concentração de alumina e produção real por forno.

7.3.2. Construção de Sensores Virtuais com outras técnicas de Redes Neurais

Existe uma grande variedade de arquiteturas e técnicas de otimização aplicadas à construção de sensores virtuais. Uma delas é o Pruning, que é a eliminação de neurônios com pouca participação nos resultados das redes neurais. Outra técnica é o Cascade Correlation Algorithm, que vai construindo uma melhor configuração dos neurônios de acordo com o resultado. O uso de Memória Recursiva para Séries Temporais também é uma possibilidade a ser explorada.

Para problemas de séries temporais, que é o caso deste trabalho, uma alternativa é utilizar redes recorrentes. Uma implementação deste sensor com este tipo de rede seria interessante.

7.3.3. Sistema Integrado de Estimação de Temperatura

Os sensores virtuais implementados em software podem ser utilizados em uma arquitetura maior de automação. Um trabalho futuro seria a integração destes sensores com os outros sistemas de controle em nível de chão de fábrica. Tal informação teria o mesmo efeito de uma medição real, porém, com um controle mais robusto e preciso..

REFERÊNCIAS

- AGUIRRE, L.A. **Introdução à identificação de sistemas : técnicas Lineares e não-lineares aplicadas a sistemas reais**. Belo Horizonte : Ed. UFMG, 2004.
- ALCOA. **The Smelting Paper** ,
www.alcoa.com/global/en/about_alcoa/pdf/Smeltingpaper.pdf, acessado em 24/07/2008.
- ALVES, M.C.M. da S., **Uso da Entropia para Treinamento em Redes Neurais Artificiais**, Trabalho de Conclusão de Curso para obtenção do diploma de Engenheiro de Computação, Universidade Federal do Pará, 2008.
- AMOS, C.K., **Soft Sensors win Hard Jobs**,
www.chemicalprocessing.com/articles/2005/606.html acessado em 01/06/2008.
- ASSIS, A.J., Filho, R.M., **Soft Sensor development for online bioreactor state estimation**, *Comput. Chemistry Engineering*, vol.24, no 2-7 pp.1099-1103 2000.
- BRANCO, M.V.B.M., OLIVEIRA, R.C.L., PEREIRA, V.G., CASTRO.M.,
DOURADO,N. **Model of Electric Resistance in Reduction Cells of Aluminum to be Applied on the Process Control** TMS Light Metals 2006 – Proceedings of the Technical Sessions, 135rd Technical TMS Annual Meeting, March 9-13, San Antonio, TX. USA.
- CASTRO, M.C.F. **Predição Não-Linear de Séries Temporais usando Redes Neurais RBF por Decomposição em Componentes Principais**, Tese de Doutorado em Engenharia Elétrica, Universidade Estadual de Campinas UNICAMP, 2001.
- DE OLIVEIRA, R.C., SOARES, F.M., **Uso de Técnicas de Inteligência Computacional na Fabricação de Alumínio Primário**, Simpósio Brasileiro Inteligência Articial, 2007.
- DEMUTH, H., BEALE, M. HAGAN, M. **Neural Network Toolbox 6 User Guide**, Mathworks, 10th ed., 2008.

- DUNN, Willian C. **Fundamentals of Industrial Instrumentation and Process Control**. McGraw Hill Companies, e-Book: 0-07-146693, 2005.
- FORTUNA, Luigi et al. **Soft Sensors for Monitoring and Control of Industrial Processes**. Springer, 1^a ed, 2007.
- FORTUNA, L., GIANNONE, P., GRAZIANI, S., XIBILIA, M.G., **Virtual Instruments Based on Stacked Neural Networks to Improve Product Quality Monitoring in a Refinery**, IEEE Instrumentation & Measurement Magazine, vol. 56, no.1 pp.95-101, Feb. 2007.
- FROST, F., KARRI, V., **Performance Comparison of BP and GRNN Models of Neural Networks Paradigm Using a Pratical Industrial Application**, IEEE Transactions Jun/1999 pp. 1069-1074.
- GOLATOWSKI, F., BLUMENTAL, J., HANDY, M., HAASE, M., BURCHARDT, H., TIMMERMANN, D., **Service Oriented Architechure for Sensor Networks**, Computer Communication Proceedings Vol. 30, Issue 13, p.2627-2648, ISSN :0140-3664, 2007.
- HAYKIN, Simon **Neural Networks, A Comprehensive Foundation**. Prentice Hall, 2^a ed, 1999.
- HAUPIN, W., KVANDE, H., **Mathematical Model of fluoride evolution from Hall Heroult Cells**, TMS Light Metals, pp. 257-263, 1993.
- JAMES, S.C. ; LEGGE, R.L., BUDMAN, H. **On-line estimation in bioreactors : A Review**. Reviews in Chemical Engineering, v.16, n.4, p311-240, 2000.
- KARNIN, E.D., **A simple procedure for pruning back-propagation trained neural networks**, IEEE Transacions Jun/1990 pp.239-242.
- MALAVIYA, A.V., **Intelligent Controler for Aluminium Smelters**, IEEE Transactions Jun/2001, pp. 792-805.
- McFADDEN, F.S., BEARNE, G.P., AUSTIN, P.C., WELCH, B. J. **Application of advanced Process Control to Aluminium Reduction Cells – A Review**, *TMS Light Metals, Light Metals 2001 – Proceedings of the Technical Sessions, 130rd Technical TMS Annual Meeting, February 11-15, New Orleans, LA, USA, pp.1233-1242.*
- McFADDEN, F.J.S., WELCH, B.J., WHITFIELD, D., KAZACOS, M.S. **Control of Temperature in Aluminium Redution Cells – Challenges in Measurements and Variability** TMS Light Metals 2001 – Proceedings of

- the Technical Sessions, 130rd Technical TMS Annual Meeting, February 11-15, New Orleans.
- NOCEDAL, J., WRIGHT, S.J., **Numerical Optimization**, 2ed. Springer Ed. ISBN-10 : 0-387-30303-0.
- OGATA, Katsuhiko **Modern Control Engineering**. Prentice Hall, 4^a ed, 2007.
- PEREIRA, V.G., OLIVEIRA, R.C.L., BRANCO, M.V.B.M., CASTRO.M.A.G., SOARES,F.M. **Adição de Fluoreto em Cubas de Redução de Alumínio Utilizando Lógica Fuzzy** Revista C&I. Controle e Instrumentação, v.116, pp.17-25, Jun. 2006.
- PRASAD, S. **Studies on the Hall-Heroult Aluminium electrowinning Process**, *Journal of Brazilian Chemistry Society*, May/June 2000, vol. 11, no.3, p.245-251, ISSN 0103-5053.
- SANTOS, G.S.M. **Aplicação de Redes Neurais para Diagnóstico de poluição em Isoladores de Alta Tensão**, Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal de Pernambuco, 2008.
- SHLENS, J. **Time Series Prediction with Artificial Neural Networks**, Computer Science Program, 1999.
- SOARES, F.M., **Desenvolvimento de Modelos Neuro-Adaptados para Propagação de Ondas em Florestas**, Trabalho de Conclusão de Curso para obtenção do diploma de Engenheiro de computação, Universidade Federal do Pará, 2006.
- SOARES,F.M., OLIVEIRA, R.C.L., **Inferência de Temperatura de Fornos de Redução de Alumínio Primário através de Sensores Virtuais IX** *Congresso Brasileiro de Redes Neurais,Ouro Preto-MG 25-28 de Outubro de 2009*
- SOARES, F.M., OLIVEIRA, R.C.L., CASTRO.M.A.G. **Bath Temperature Inference Through Soft Sensors using Neural Networks** *TMS Light Metals, Light Metals 2010 – Proceedings of the Technical Sessions, 139rd Technical TMS Annual Meeting, February 14-18, Seattle, WA, USA, pp.467-472.*
- STEARNS, Peter N. **The Industrial Revolution in world history**. Westview Press, ISBN-13: 978-0-8133-4360-0, 2007.

WELCH, B.J. **Aluminium Fluoride Consumption and Control in Smelting Cells** in Proceedings 6th International Conference on Molten Slags, Fluxes and Salts (ISS), Stockholm, June 2002.

ZANATA, D.R.P. **Desenvolvimento de Sensor Virtual Empregando Redes Neurais para Medição da Composição em uma Coluna de Destilação**, Dissertação de Mestrado Escola Politécnica da USP, 2005.

APÊNDICES

APÊNDICE A DESCRIÇÃO DO PROCEDIMENTO DE MEDIDA DE TEMPERATURA

A.1 PROCEDIMENTO

No turno de Miscelânea, a seção inteira é medida com os termopares. A equipe tem a tarefa de fazer a medição em um horário dentro do turno, que são 8 horas. A medição deve ser feita em todos os 30 fornos. Em média, leva-se de 5 a 10 minutos para medir a temperatura em um forno. Os dados são registrados em uma prancheta e posteriormente inseridos no Score. Mais tarde os técnicos de processo fazem a importação dos dados do Score para o Sisred, incluindo não apenas as medidas de temperatura como também os resultados das amostras dos fornos.




Figura A 1 Resumo do Procedimento de medição de Temperatura

O procedimento consiste em inserir o termopar entre os anodos 4 e 5, 5 e 6, 13 e 14 ou 14 e 15 a uma profundidade de 20 cm. Para tal, será necessário um rompimento da crosta através de britadeiras.




Figura A 2 Layout dos Anodos na cuba

O termopar começa a medição e dura cerca de 5 minutos para se estabilizar. O Valor é anotado e o termopar é retirado. Espera-se mais um tempo até que o termopar se

estabilize para evitar o choques térmicos. Em seguida a medição continua nos demais fornos.

Os termopares são trocados a cada 20 medições, devido a condições hostis do eletrólito, o que pode causar muito ruído nas medições. Os conversores A/D e D/A usados são mantidos, porém são calibrados seguindo uma agenda regular.

APÊNDICE B

Separação dos Conjuntos de Treinamento, Testes e Validação

Os conjuntos foram separados por fornos, assim um forno em um período pode fazer parte de um conjunto e no outro período, fazer parte de um conjunto diferente.

Período 1

<i>Redução</i>	<i>Forno</i>	<i>Quantidade de Registros</i>	<i>Tipo de Conjunto</i>	<i>Subconjunto</i>
2	126	89	Treinamento	T1
2	132	89	Treinamento	T1
2	133	89	Treinamento	T1
2	134	89	Treinamento	T2
2	135	89	Treinamento	T2
2	136	89	Treinamento	T2
2	138	89	Treinamento	T3
2	139	89	Treinamento	T3
2	142	89	Treinamento	T3
2	143	89	Treinamento	T1
2	144	89	Treinamento	T1
2	147	89	Treinamento	T1
2	148	89	Treinamento	T2
2	152	89	Treinamento	T2
2	201	90	Treinamento	T4
2	203	90	Treinamento	T4
2	210	90	Treinamento	T5
2	213	90	Treinamento	T5
2	215	90	Treinamento	T3
2	221	90	Treinamento	T1
2	226	90	Treinamento	T1
2	229	90	Treinamento	T1
2	241	90	Treinamento	T6
2	243	90	Treinamento	T6
2	244	90	Treinamento	T3
2	248	90	Treinamento	T3
2	301	89	Treinamento	T2
2	302	89	Treinamento	T2
2	303	89	Treinamento	T2

2	304	89	Treinamento	T1
2	305	89	Treinamento	T1
2	307	89	Treinamento	T1
2	308	89	Treinamento	T2
2	309	89	Treinamento	T2
2	310	89	Treinamento	T2
2	313	89	Treinamento	T8
2	315	89	Treinamento	T1
2	316	89	Treinamento	T1
2	318	89	Treinamento	T1
2	321	89	Treinamento	T8
2	322	89	Treinamento	T8
2	326	89	Treinamento	T8
2	327	89	Treinamento	T1
2	330	89	Treinamento	T3
2	331	89	Treinamento	T7
2	333	89	Treinamento	T7
2	334	89	Treinamento	T3
2	336	89	Treinamento	T3
2	338	89	Treinamento	T3
2	339	89	Treinamento	T1
2	341	89	Treinamento	T5
2	342	89	Treinamento	T4
2	344	89	Treinamento	T1
2	345	89	Treinamento	T7
2	347	89	Treinamento	T7
2	350	89	Treinamento	T9
2	351	89	Treinamento	T9
2	352	89	Treinamento	T2
2	406	89	Treinamento	T2
2	409	89	Treinamento	T2
2	412	89	Treinamento	T8
2	425	89	Treinamento	T8
2	426	89	Treinamento	T9
2	427	89	Treinamento	T9
2	429	89	Treinamento	T4
2	430	89	Treinamento	T4
2	431	89	Treinamento	T4
2	433	89	Treinamento	T2

2	436	89	Treinamento	T2
2	437	89	Treinamento	T2
2	438	89	Treinamento	T4
2	439	89	Treinamento	T4
2	440	89	Treinamento	T4
2	441	89	Treinamento	T5
2	444	89	Treinamento	T5
2	445	89	Treinamento	T6
2	447	89	Treinamento	T6
2	448	89	Treinamento	T6
2	452	89	Treinamento	T6
4	103	89	Treinamento	T2
4	104	89	Treinamento	T5
4	106	89	Treinamento	T5
4	107	89	Treinamento	T3
4	108	89	Treinamento	T3
4	109	89	Treinamento	T3
4	114	89	Treinamento	T3
4	115	89	Treinamento	T8
4	116	89	Treinamento	T8
4	118	89	Treinamento	T7
4	120	89	Treinamento	T7
4	121	89	Treinamento	T8
4	122	89	Treinamento	T3
4	124	89	Treinamento	T3
4	125	89	Treinamento	T9
4	128	89	Treinamento	T8
4	129	89	Treinamento	T8
4	130	89	Treinamento	T3
4	132	89	Treinamento	T3
4	133	89	Treinamento	T7
4	134	89	Treinamento	T9
4	135	89	Treinamento	T8
4	136	89	Treinamento	T6
4	139	89	Treinamento	T6
4	141	89	Treinamento	T8
4	144	89	Treinamento	T8
4	145	89	Treinamento	T8
4	152	89	Treinamento	T6

4	203	89	Treinamento	T8
4	216	89	Treinamento	T8
4	219	89	Treinamento	T5
4	220	89	Treinamento	T5
4	226	89	Treinamento	T6
4	228	89	Treinamento	T3
4	233	89	Treinamento	T3
4	234	89	Treinamento	T3
4	242	89	Treinamento	T4
4	243	89	Treinamento	T4
4	245	89	Treinamento	T4
4	301	88	Treinamento	T9
4	302	88	Treinamento	T7
4	305	88	Treinamento	T5
4	306	88	Treinamento	T4
4	307	88	Treinamento	T4
4	308	88	Treinamento	T7
4	309	88	Treinamento	T5
4	310	88	Treinamento	T5
4	312	88	Treinamento	T7
4	314	88	Treinamento	T6
4	315	88	Treinamento	T5
4	317	88	Treinamento	T7
4	319	88	Treinamento	T7
4	320	88	Treinamento	T8
4	321	88	Treinamento	T6
4	322	88	Treinamento	T5
4	323	88	Treinamento	T6
4	324	88	Treinamento	T6
4	327	88	Treinamento	T5
4	333	88	Treinamento	T6
4	334	88	Treinamento	T9
4	335	88	Treinamento	T9
4	336	88	Treinamento	T7
4	337	88	Treinamento	T4
4	338	88	Treinamento	T4
4	339	88	Treinamento	T4
4	342	88	Treinamento	T6
4	348	88	Treinamento	T6

4	352	88	Treinamento	T9
4	404	88	Treinamento	T9
4	406	88	Treinamento	T9
4	408	88	Treinamento	T5
4	412	88	Treinamento	T7
4	414	88	Treinamento	T7
4	416	88	Treinamento	T7
4	417	88	Treinamento	T5
4	418	88	Treinamento	T9
4	420	88	Treinamento	T5
4	422	88	Treinamento	T9
4	424	88	Treinamento	T5
4	429	88	Treinamento	T5
4	430	88	Treinamento	T9
4	431	88	Treinamento	T9
4	433	88	Treinamento	T4
4	438	88	Treinamento	T4
4	444	88	Treinamento	T4
4	445	88	Treinamento	T7

Período II

<i>Redução</i>	<i>Forno</i>	<i>Quantidade de Registros</i>	<i>Tipo de Conjunto</i>	
2	131	70	Testes	T1
2	132	70	Testes	T1
2	133	70	Testes	T1
2	134	70	Validação	-
2	136	70	Validação	-
2	140	70	Validação	-
2	142	70	Validação	-
2	147	70	Treinamento	T9
2	148	70	Testes	T1
2	151	70	Testes	T1
2	201	70	Validação	-
2	202	70	Testes	T1
2	204	70	Validação	-
2	205	70	Validação	-
2	208	70	Validação	-
2	209	70	Testes	T2

2	211	70	Testes	T2
2	213	70	Testes	T2
2	214	70	Validação	-
2	215	70	Validação	-
2	216	70	Validação	-
2	217	70	Treinamento	T9
2	219	70	Testes	T2
2	220	70	Validação	-
2	224	70	Testes	T4
2	226	70	Testes	T4
2	227	70	Validação	-
2	229	70	Testes	T3
2	230	70	Treinamento	T9
2	242	70	Validação	-
2	245	70	Testes	T3
2	249	70	Validação	-
2	250	70	Validação	-
2	251	70	Validação	-
2	252	70	Validação	-
2	302	70	Testes	T2
2	304	70	Testes	T2
2	305	70	Validação	-
2	306	70	Validação	-
2	307	70	Validação	-
2	308	70	Validação	-
2	309	70	Validação	-
2	310	70	Testes	T3
2	312	70	Treinamento	T9
2	315	70	Testes	T7
2	321	70	Validação	-
2	322	70	Validação	-
2	323	70	Validação	-
2	324	70	Treinamento	T9
2	325	70	Testes	T7
2	326	70	Validação	-
2	328	70	Validação	-
2	329	70	Testes	T3
2	330	70	Validação	-
2	332	70	Validação	-

2	333	70	Validação	-
2	334	70	Validação	-
2	335	70	Validação	-
2	338	70	Testes	T4
2	339	70	Testes	T4
2	340	70	Validação	-
2	341	70	Testes	T4
2	343	70	Testes	T4
2	344	70	Validação	-
2	346	70	Testes	T5
2	347	70	Validação	-
2	349	70	Testes	T7
2	350	70	Testes	T5
2	351	70	Validação	-
2	401	69	Validação	-
2	402	69	Testes	T5
2	403	69	Validação	-
2	405	69	Testes	T3
2	406	69	Testes	T3
2	407	69	Validação	-
2	408	69	Validação	-
2	409	69	Validação	-
2	410	69	Testes	T6
2	413	69	Validação	-
2	415	69	Testes	T6
2	418	69	Testes	T6
2	419	69	Validação	-
2	420	69	Validação	-
2	425	69	Validação	-
2	427	69	Testes	T6
2	428	69	Validação	-
2	429	69	Testes	T6
2	430	69	Testes	T6
2	431	69	Validação	-
2	432	69	Testes	T7
2	433	69	Validação	-
2	436	69	Validação	-
2	437	69	Testes	T5
2	438	69	Validação	-

2	440	69	Testes	T5
2	441	69	Validação	-
2	442	69	Testes	T7
2	443	69	Validação	-
2	444	69	Testes	T7
2	445	69	Validação	-
2	446	69	Testes	T8
2	448	69	Validação	-
2	450	69	Validação	-
4	111	70	Testes	T8
4	113	70	Validação	-
4	127	70	Testes	T5
4	148	70	Validação	-
4	222	70	Validação	-
4	227	70	Validação	-
4	231	70	Validação	-
4	252	70	Validação	-
4	307	70	Testes	T8
4	308	70	Validação	-
4	313	70	Validação	-
4	324	70	Validação	-
4	326	70	Validação	-
4	327	70	Validação	-
4	331	70	Testes	T8
4	339	70	Testes	T8
4	340	70	Validação	-
4	344	70	Testes	T8
4	350	70	Validação	-
4	351	70	Testes	T9
4	352	70	Testes	T9
4	401	69	Validação	-
4	416	69	Treinamento	T9
4	439	69	Testes	T9
4	445	69	Testes	T9
4	448	69	Testes	T9

APÊNDICE C

Programas em Matlab

Seguem as listagens dos códigos fonte em matlab utilizados nesta dissertação.

Normalização de Dados:

```
% dados_norm
% Função utilizada para normalizar dados para treinamento
%
% A matriz dados contem os dados usados para treinamento, sendo
% que as colunas representam as variaveis e as linhas sao os
% registros
% A matriz limites_dados contem os valores mínimos e máximos de cada
% coluna
% A matriz limites_norm contem os valores mínimos e máximos
% normalizados
% de cada coluna
function dados_norm = normaliza(dados,limites_dados,limites_norm)
rkdados = size(dados)
rklimites = size(limites_dados)
rknorm = size(limites_norm)
if(rkdados(2)<>rklimites(2) | rkdados(2) <> rknorm(2))
    error('O numero de colunas deve ser igual em todas as matrizes')
for i=1:rklimites(2)
    dados_norm(:,i)=limites_norm(1,i)+(limites_norm(2,i)-
limites_norm(1,i))*(dados(:,1)-limites_dados(1,i) / (limites_dados(2,i)-
limites_dados(1,i)));
end

end
```

Desnormalização:

```
% desnormaliza
% Função utilizada para normalizar dados para treinamento
%
% A matriz dados_norm contem os dados normalizados, sendo que as
% colunas representam as variaveis e as linhas sao os registros
% A matriz limites_dados contem os valores mínimos e máximos de cada
% coluna
% A matriz limites_norm contem os valores mínimos e máximos
% normalizados
% de cada coluna
% A matriz dados contem os dados desnormalizados
function dados = desnormaliza(dados_norm,limites_dados,limites_norm)
rkdados = size(dados_norm)
rklimites = size(limites_dados)
rknorm = size(limites_norm)
if(rkdados(2)<>rklimites(2) | rkdados(2) <> rknorm(2))
    error('O numero de colunas deve ser igual em todas as matrizes')
for i=1:rklimites(2)
    dados(:,i)=limites_norm(1,i)+(limites_dados(2,i)-
limites_dados(1,i))*(dados_norm(:,1)-limites_norm(1,i) / (limites_norm(2,i)-
limites_norm(1,i)));
end

end
```

Definição das Redes Neurais:

```
% As redes neurais são definidas de acordo com o numero de camadas
```

```

% Redes A - 2 camadas
% Redes B - 3 camadas
% Redes C - 4 camadas
% As redes foram numeradas de 1 a 12, com configurações variadas de
% neurônios e funções de ativação
% Com relação a finalidade da rede, a nomenclatura delas receberam sufixos
% b1 - backup 1 do sensor virtual
% b2 - backup 2 do sensor virtual
% b3 - backup 3 do sensor virtual
% p - sensor virtual principal
% m - sensor virtual em intervalos de tempo menores
% t - rede retreinada
%
% Quando a rede não possui sufixos, é porque ela é usada no simulador de
% balanço térmico
function red = confpadraotreinamento(rede)
    red = rede;
    red.trainParam.epochs = 200;
    red.trainParam.goal = 0.01;
    red.trainParam.min_grad = 10e-24;
    red.trainParam.mu_max = 10e24;
    red.trainParam.mu = 0.001;
end
limites_norm = [-1 1;-1 1;-1 1;-1 1;-1 1;-1 1;-1 1;-1 1;-1 1;-1 1]

%redes A - backup 1
A1b1 = newff(limites_norm,[4 1],{'logsig' 'purelin'});
A1b1 = confpadraotreinamento(A1b1);
A2b1 = newff(limites_norm,[12 1],{'logsig' 'purelin'});
A2b1 = confpadraotreinamento(A2b1);
%redes A - backup 2
A3b2 = newff(limites_norm,[24 1],{'logsig' 'purelin'});
A3b2 = confpadraotreinamento(A3b2);
A4b2 = newff(limites_norm,[32 1],{'tansig' 'purelin'});
A4b2 = confpadraotreinamento(A4b2);
%redes B - backup 1
B1b1 = newff(limites_norm,[10 6 1],{'logsig' 'tansig' 'purelin'});
B1b1 = confpadraotreinamento(B1b1);
B2b1 = newff(limites_norm,[10 6 1],{'logsig' 'tansig' 'purelin'});
B2b1 = confpadraotreinamento(B2b1);
B3b1 = newff(limites_norm,[16 8 1],{'tansig' 'tansig' 'purelin'});
B3b1 = confpadraotreinamento(B3b1);
B4b1 = newff(limites_norm,[12 20 1],{'tansig' 'tansig' 'purelin'});
B4b1 = confpadraotreinamento(B4b1);
B5b1 = newff(limites_norm,[16 32 1],{'logsig' 'logsig' 'purelin'});
B5b1 = confpadraotreinamento(B5b1);
B6b1 = newff(limites_norm,[38 16 1],{'logsig' 'tansig' 'purelin'});
B6b1 = confpadraotreinamento(B6b1);
B7b1 = newff(limites_norm,[16 32 1],{'tansig' 'tansig' 'purelin'});
B7b1 = confpadraotreinamento(B7b1);
B8b1 = newff(limites_norm,[64 24 1],{'tansig','tansig' 'purelin'});
B8b1 = confpadraotreinamento(B8b1);
% redes B - backup 2
B9b2 = newff(limites_norm,[36 18 1],{'tansig' 'tansig' 'purelin'});
B9b2 = confpadraotreinamento(B9b2);
B10b2 = newff(limites_norm,[20 40 1],{'tansig','tansig' 'purelin'});
B10b2 = confpadraotreinamento(B10b2);
% redes B - backup 3
B9b3 = newff(limites_norm,[36 18 1],{'tansig' 'tansig' 'purelin'});
B9b3 = confpadraotreinamento(B9b3);
B10b3 = newff(limites_norm,[20 40 1],{'tansig','tansig' 'purelin'});
B10b3 = confpadraotreinamento(B10b3);
%redes C
C1b1 = newff(limites_norm,[4 6 6 1],{'logsig' 'tansig' 'tansig' 'purelin'});
C1b1 = confpadraotreinamento(C1b1);
C2b1 = newff(limites_norm,[6 10 8 1],{'logsig' 'logsig' 'tansig' 'purelin'});
C2b1 = confpadraotreinamento(C1b1);

```

```

C3b1 = newff(limites_norm,[8 16 4 1],{'logsig' 'tansig','tansig' 'purelin'});
C3b1 = confpadraotreinamento(C3b1);
C4b1 = newff(limites_norm,[36 18 6 1],{'logsig' 'tansig','tansig' 'purelin'});
C4b1 = confpadraotreinamento(C4b1);
C5b2 = newff(limites_norm,[22 36 10 1],{'logsig' 'tansig','tansig' 'purelin'});
C5b2 = confpadraotreinamento(C5b2);
C5b3 = newff(limites_norm,[22 36 10 1],{'logsig' 'tansig','tansig' 'purelin'});
C5b3 = confpadraotreinamento(C5b3);
%redec C - sensor principal
C5p = newff(limites_norm,[22 44 12 1],{'tansig' 'logsig' 'tansig' 'purelin'});
C5p = confpadraotreinamento(C5p);
C6p = newff(limites_norm,[36 36 12 1],{'tansig' 'logsig' 'tansig' 'purelin'});
C6p = confpadraotreinamento(C6p);
C7p = newff(limites_norm,[48 36 16 1],{'tansig' 'tansig' 'tansig' 'purelin'});
C7p = confpadraotreinamento(C7p);

%redes C - simulador de Balanço Térmico
C1 = newff(limites_norm,[10 12 6 1],{'tansig' 'logsig' 'tansig' 'purelin'});
C1 = confpadraotreinamento(C1);
C2 = newff(limites_norm,[10 24 12 1],{'tansig' 'logsig' 'tansig' 'purelin'});
C2 = confpadraotreinamento(C2);
C3 = newff(limites_norm,[12 144 12 1],{'tansig' 'tansig' 'tansig' 'purelin'});
C3 = confpadraotreinamento(C3);

% melhoramentos
% retreino fornos 244 e 252
C7mt = newff(limites_norm,[48 36 16 1],{'tansig' 'tansig' 'tansig' 'purelin'});
C7mt = confpadraotreinamento(C7mt);
C3t = newff(limites_norm,[12 144 12 1],{'tansig' 'tansig' 'tansig' 'purelin'});
C3t = confpadraotreinamento(C3t);

```

Treinamento:

```

% treinamento
% Função usada nos treinamentos parciais e totais
%
% rede contem o objeto rede neural criado anteriormente
% dados_treinamento contem os dados de entrada do treinaemnto
% alvo contem os valores objetivos da rede para cada entrada
% testes contem os dados de testes
function dados_sim=treinamento(rede,dados_treinamento,alvo,testes)
rede=train(rede,dados_treinamento',alvo',[],[],[],testes);
dados_sim=sim(rede,dados_treinamento');
end

% treinamento parcial
% script que mostra o treinamento parcial feito por etapas para uma rede
% rede é a rede neural usada
% Tn é o conjunto de treinamento parcial 1.
% No trabalho foram usadas 11
% variaveis, sendo 10 de entrada e 1 de saida
% erro_tp
function erro_tp = treinamento_parcial(rede,T1,T2,T3, t1,t2,t3)
    dados_sim = treinamento(rede,[T1(:,1:10)],[T1(:,11)],[t1(:,1:10)],[t1(:,11)]);
    erro_tp = [1 mse(T1(:,11)-dados_sim)];
    dados_sim = treinamento(rede,[T1(:,1:10) ; T2(:,1:10)],[T1(:,11) ; T2(:,11)],
[t1(:,1:10);t2(:,1:10)], [t1(:,11);t2(:,11)]);
    erro_tp = [erro_tp ; 2 mse([T1(:,11);T2(:,11)]-dados_sim)];
    dados_sim = treinamento(rede,[T1(:,1:10) ; T2(:,1:10) ; T3(:,1:10)],[T1(:,11) ;
T2(:,11) ;
T3(:,1:10)],[t1(:,1:10);t2(:,1:10);t3(:,1:10)],[t1(:,11);t2(:,11);t3(:,11)]);
    erro_tp = [erro_tp ; 3 mse([T1(:,11);T2(:,11);T3(:,11)]-dados_sim)];
end

```

ANEXO I

Sistema de Predição da Variável de Fluoreto por Frost e Karri

Entradas do Sistema:

EMF: Força eletromotiva (tensão de forno efetiva, usada na produção de alumínio)

TMP: Temperatura de Banho

RMR: Resistência do Forno

NBA: Nível de Banho

NME: Nível de Metal

Saída do Sistema:

ALF: Percentual de Alumínio no Banho

Rede Neural Utilizada:




Figura I. Rede Neural do Sistema de Predição de Fluoreto proposto por Frost e Karri