ANTONIO LUIZ DOS SANTOS FILHO

**INTELIGÊNCIA COMPUTACIONAL APLICADA À
ADAPTAÇÃO NA MODELAGEM MATEMÁTICA DO
PROCESSO DE LAMINAÇÃO A FRIO DE AÇOS PLANOS**

São Paulo

2009

ANTONIO LUIZ DOS SANTOS FILHO

**INTELIGÊNCIA COMPUTACIONAL APLICADA À
ADAPTAÇÃO NA MODELAGEM MATEMÁTICA DO
PROCESSO DE LAMINAÇÃO A FRIO DE AÇOS PLANOS**

Tese apresentada ao Programa de Pós-Graduação em
Engenharia Elétrica da Escola Politécnica da Universidade de
São Paulo, para a obtenção do título de Doutor em
Engenharia Elétrica

São Paulo

2009

ANTONIO LUIZ DOS SANTOS FILHO

**INTELIGÊNCIA COMPUTACIONAL APLICADA À
ADAPTAÇÃO NA MODELAGEM MATEMÁTICA DO
PROCESSO DE LAMINAÇÃO A FRIO DE AÇOS PLANOS**

Tese apresentada ao Programa de Pós-Graduação em
Engenharia Elétrica da Escola Politécnica da Universidade de
São Paulo, para a obtenção do título de Doutor em
Engenharia Elétrica

Área de Concentração: Sistemas Eletrônicos

Orientador: Professor-Doutor
Francisco Javier Ramirez-Fernandez

São Paulo

2009

**AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES
TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO,
PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.**

**Este exemplar foi revisado e alterado em relação à versão original, sob
responsabilidade única do autor e com a anuência de seu orientador.**

São Paulo, 2 de outubro de 2009.

Assinatura do autor _____

Assinatura do orientador _____

FICHA CATALOGRÁFICA

**Santos Filho, Antonio Luiz dos
Inteligência computacional aplicada à adaptação na modela-
gem matemática do processo de laminação a frio de aços
planos / A.L. dos Santos Filho. -- ed.rev. -- São Paulo, 2009.
179 p.**

**Tese (Doutorado) - Escola Politécnica da Universidade de
São Paulo. Departamento de Engenharia de Sistemas Eletrô-
nicos.**

**1. Automação industrial 2. Laminação 3. Redes neurais 4. In-
teligência artificial I. Universidade de São Paulo. Escola Politéc-
nica. Departamento de Engenharia de Sistemas Eletrônicos II. t.**

SANTOS FILHO, A. L. **Inteligência computacional aplicada à adaptação na modelagem matemática do processo de laminação a frio de aços planos.** Tese apresentada à Escola Politécnica da Universidade de São Paulo para a obtenção do título de Doutor em Engenharia Elétrica.

Aprovada em 25 de setembro de 2009.

Banca Examinadora

Prof. Dr. **Francisco Javier Ramirez-Fernandez** Instituição: **Escola Politécnica da USP**

Julgamento: **Aprovado**

Assinatura: _____

Prof. Dr. **Roberto Moura Sales**

Instituição: **Escola Politécnica da USP**

Julgamento: **Aprovado**

Assinatura: _____

Prof. Dr. **Carlos Thadeu de Avila Pires**

Instituição: **Lyon Engenharia / Usiminas**

Julgamento: **Aprovado**

Assinatura: _____

Prof. Dr. **Paulo Sérgio Licciardi Messeder Barreto**

Instituição: **Escola Politécnica da USP**

Julgamento: **Aprovado**

Assinatura: _____

Prof. Dr. **Hani Camille Yehia**

Instituição: **Escola de Engenharia da UFMG**

Julgamento: **Aprovado**

Assinatura: _____

DEDICATÓRIA

À memória de **Antonio Luiz dos Santos**, meu pai.

AGRADECIMENTOS

Rezam as normas acadêmicas que uma tese de doutorado é uma obra de autoria individual, de modo que um único nome aparece sob a rubrica “autor”. No entanto, tal tarefa dificilmente poderia ser levada a cabo sem o concurso de vários indivíduos e instituições que, em maior ou menor grau, se tornam co-autores efetivos da obra. Em meu caso, reconhecendo em primeiro lugar a possível imperfeição dessa retrospectiva, e desde já me penitenciando por eventuais omissões, gostaria de consignar a minha especial gratidão:

Ao Senhor e Salvador Jesus Cristo, que proveu as forças físicas, mentais e espirituais indispensáveis para a realização deste trabalho.

Ao meu inestimável orientador, o Professor-Doutor Francisco Javier Ramirez-Fernandez, que soube dosar magistralmente firmeza e paciência ao me conduzir ao perfeito equilíbrio entre as demandas, nem sempre harmônicas, do ambiente produtivo e do mundo acadêmico.

À Engenheira Sabrina Rizzo Celante Vieira, com quem tive o privilégio de trabalhar durante os últimos oito anos, e cuja assistência foi de importância fundamental nas fases de coleta de dados e de avaliação do trabalho desenvolvido durante a pesquisa.

Ao IF/SP e à CAPES, pela concessão da Licença-Capacitação que me proporcionou a devida tranquilidade durante a fase crítica dos experimentos necessários para a conclusão do trabalho.

Aos demais colegas da Gerência de Automação das Usinas Siderúrgicas de Minas Gerais (Usiminas), planta de Cubatão (antiga Cosipa), que devido às horas que dediquei a este trabalho foram obrigados a uma redobrada dedicação para manter o padrão de nossa atividade.

Ao Sr. Francisco Roberto Martins de Andrade, Gerente de Automação da Usiminas, planta de Cubatão, que foi um grande incentivador da minha pesquisa e que, depois de deixei a companhia, franqueou-me a entrada na Usina para a complementação do trabalho.

Aos Professores Doutores Roberto Moura Sales, Ronald Lesley Plautt e José Reinaldo Teixeira, que compuseram a Banca de Qualificação deste trabalho e fizeram sugestões que nortearam a estratégia mais adequada para o seu desenvolvimento, bem como aos Professores Doutores Paulo Sérgio Licciardi Messeder Barreto, Hani Camille Yehia e Carlos Thadeu de

Ávila Pires, que se juntaram ao primeiro para compor a Banca Examinadora dessa Tese. Foram simplesmente notáveis as contribuições que a Banca apresentou por ocasião da Defesa Pública, através de relevantes sugestões que efetivamente agregaram valor ao trabalho, justificando plenamente essa Edição Revisada.

Por fim, mas não menos importante, à minha esposa Nilva e aos meus filhos Leonardo e Heloísa, que, apesar de terem sido privados do meu convívio durante a elaboração deste trabalho, não me privaram do suporte emocional indispensável para a sua conclusão.

“O coração do sábio adquire o conhecimento, e o ouvido dos sábios procura o saber.”
(**Livro de Provérbios, capítulo 18, versículo 15**)

RESUMO

SANTOS FILHO, A. L. **Inteligência computacional aplicada à adaptação na modelagem matemática do processo de laminação a frio de aços planos**. 2009. 179 p. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, 2009.

A laminação a frio de aços planos é um processo industrial de grande complexidade, executado num ambiente bastante agressivo e caracterizado por parâmetros incertos, grandes tempos de atraso, múltiplas entradas e múltiplas saídas e por forte interação entre as diversas variáveis (GUO, 2000). As referências necessárias para o controle de tal processo são obtidas por meio de um modelo matemático, responsável pela sua otimização. Dadas as particularidades do processo, o modelo deve ser do tipo adaptativo, ou seja, deve ter seus parâmetros continuamente ajustados com base nos resultados efetivamente obtidos durante a operação. A adaptação do modelo é essencial para a consecução dos requisitos de qualidade do produto e, em consequência, para a viabilidade da planta. Este trabalho primeiramente investiga as estratégias tradicionalmente empregadas no desenvolvimento de modelos adaptativos para o processo de laminação de aços, identificando os pontos fortes e deficiências de tais técnicas. Com o objetivo de minimizar essas deficiências e aperfeiçoar o desempenho do modelo, o trabalho propõe em seguida a utilização de ferramentas de Inteligência Computacional (mais especificamente, Redes Neurais Artificiais) para tornar mais eficiente a adaptação de dois importantes parâmetros: o limite de escoamento do material e o coeficiente de atrito entre a tira e os cilindros de trabalho. O texto apresenta os fundamentos teóricos, a metodologia de desenvolvimento e a implantação da solução, bem como os resultados preliminares obtidos com a aplicação da proposta num laminador real. Finalmente, discutem-se esses resultados, apresentam-se as conclusões, resumizam-se as contribuições da pesquisa e se sugerem futuras linhas de pesquisa para extensão dos resultados.

Palavras-chave: Automação industrial. Laminação. Redes neurais. Inteligência artificial.

ABSTRACT

SANTOS FILHO, A. L. Computational intelligence applied to the adaptation of mathematical modeling in flat steel cold rolling process. 2009. 179 p. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, 2009.

Flat steel cold rolling is a complex industrial process, carried out into a very harsh environment, characterized by uncertain parameters, large delay times, multiple inputs and outputs, and having a strong interaction between the diverse variables (GUO, 2000). The control system of such a process obtains its setpoints from a mathematical model, responsible for process optimization. Given process peculiarity, the mathematical model must have adaptive features, that is, its parameters need to be continuously adjusted, on the basis of actual operational results. Adaptation is an essential characteristic for achieving product quality requirements and, as a consequence, for the plant feasibility itself. First of all, this work surveys the strategies commonly used in the development of cold rolling adaptive models, pointing out their strengths and deficiencies. Following to this, aiming at the minimization of such deficiencies and by this way improving the performance of the model, this work proposes the application of Computational Intelligence techniques (specifically Artificial Neural Networks) in order to bestow greater effectiveness to the adaptation of two important parameters, namely, the material flow stress and the friction coefficient between rolled strip and rolling cylinders. The text presents the theoretical foundations, the methodology and the implementation of the solution, as so the preliminary results after its application in a real steel mill plant. Finally, the text presents the conclusions, sums up the contributions of the research work and suggests further research to improve the results.

Keywords: Industrial automation. Rolling. Neural networks. Artificial intelligence.

LISTA DE FIGURAS

<i>Figura 1-1 – Deformação do material numa cadeira de laminação</i>	<i>30</i>
<i>Figura 1-2 – Principais sensores, atuadores e malhas de controle de um laminador típico</i>	<i>30</i>
<i>Figura 1-3 – Pirâmide de automação segundo o modelo de referência da ISO.....</i>	<i>32</i>
<i>Figura 1-4 – Diagrama da estratégia de controle de um laminador.....</i>	<i>33</i>
<i>Figura 1-5 – Diagrama simplificado da arquitetura de automação do LTF.....</i>	<i>36</i>
<i>Figura 1-6 – Principais malhas de controle e atuadores da planta estudada.....</i>	<i>37</i>
<i>Figura 1-7 – Desempenho típico do controle de espessura</i>	<i>44</i>
<i>Figura 1-8 – Desempenho do controle de espessura no caso de referências inadequadas</i>	<i>45</i>
<i>Figura 2-1- Geometria do arco de contato numa cadeira de laminação</i>	<i>54</i>
<i>Figura 2-2 - Diagrama para determinação do modelo de força</i>	<i>57</i>
<i>Figura 2-3 – Comportamento do aço-carbono sob ensaio de tração</i>	<i>61</i>
<i>Figura 2-4 – Atrito entre uma tira laminada e os cilindros de trabalho</i>	<i>64</i>
<i>Figura 2-5 – Estratégia de filtragem adaptativa do modelo CORUM®</i>	<i>68</i>
<i>Figura 2-6 – Limite de escoamento versus deformação após adaptação de longo prazo</i>	<i>69</i>
<i>Figura 3-1 – AI e CI como campos disjuntos.....</i>	<i>73</i>
<i>Figura 3-2 – Densidade dos conceitos em IC nos anos de 2002 (esquerda) e 2006 (direita)</i>	<i>74</i>
<i>Figura 3-3 – Diagrama de um neurônio artificial</i>	<i>75</i>
<i>Figura 3-4– Fluxograma de um algoritmo supervisionado de treinamento.....</i>	<i>76</i>
<i>Figura 3-5 – Estrutura de uma rede neural do tipo MLP</i>	<i>81</i>
<i>Figura 3-6 - Algumas funções de ativação utilizadas nos neurônios de uma RNA do tipo MLP</i>	<i>81</i>
<i>Figura 3-7 – Fluxograma do algoritmo de retropropagação de erros.....</i>	<i>82</i>
<i>Figura 3-8 – Variações do algoritmo de retropropagação de erros</i>	<i>83</i>
<i>Figura 3-9 – Alguns tipos de função de base radial</i>	<i>84</i>
<i>Figura 3-10 - Arquitetura Moody/Darken de uma RNA do tipo RBF.....</i>	<i>85</i>
<i>Figura 3-11 – Três exemplos de funções de pertinência.....</i>	<i>91</i>
<i>Figura 3-12 – Diagrama em blocos de um sistema de inferência nebulosa</i>	<i>93</i>
<i>Figura 3-13 – Processo de agregação de regras nebulosas.....</i>	<i>94</i>
<i>Figura 3-14 – Valores crisp obtidos através de diferentes métodos de defuzzificação</i>	<i>96</i>

<i>Figura 3-15 – Fluxograma de um algoritmo genético elementar.....</i>	<i>97</i>
<i>Figura 3-16 – Algumas modalidades de cruzamento em algoritmos genéticos.....</i>	<i>100</i>
<i>Figura 3-17 – Operador genético de mutação.....</i>	<i>100</i>
<i>Figura 3-18 – Fusão entre as tecnologias de inteligência computacional</i>	<i>102</i>
<i>Figura 3-19 – Artigos e conferências sobre fusão de tecnologias no final do século XX</i>	<i>103</i>
<i>Figura 3-20 – Evolução do número de artigos sobre RNA no processo de laminação</i>	<i>104</i>
<i>Figura 4-1 – Localização do sistema de adaptação proposto no contexto do sistema atual</i>	<i>106</i>
<i>Figura 4-2 – Visualização da composição química de uma bobina</i>	<i>110</i>
<i>Figura 4-3 – Tela para seleção do tipo de análise</i>	<i>113</i>
<i>Figura 4-4 – Tela para seleção de variáveis de entrada e saída.....</i>	<i>114</i>
<i>Figura 4-5 – Tela para separação dos padrões de treinamento.....</i>	<i>114</i>
<i>Figura 4-6 – Tela para configuração das redes a serem treinadas e retidas.....</i>	<i>115</i>
<i>Figura 4-7 – Tela para seleção das funções de ativação.....</i>	<i>115</i>
<i>Figura 4-8 – Tela da toolbox do Statistica® durante uma sessão de treinamento..</i>	<i>116</i>
<i>Figura 4-9 – Visualização do desempenho das redes para escoamento da cadeira</i>	<i>117</i>
<i>Figura 4-10 – Visualização dos resíduos das redes para o escoamento da cadeira</i>	<i>117</i>
<i>Figura 4-11 – Visualização do desempenho das redes para escoamento da cadeira</i>	<i>2118</i>
<i>Figura 4-12 – Visualização dos resíduos das redes para o escoamento da cadeira</i>	<i>2118</i>
<i>Figura 4-13 – Visualização do desempenho das redes para escoamento da cadeira</i>	<i>3119</i>
<i>Figura 4-14 – Visualização dos resíduos das redes para o escoamento da cadeira</i>	<i>3119</i>
<i>Figura 4-15 – Visualização do desempenho das redes para escoamento da cadeira</i>	<i>4120</i>
<i>Figura 4-16 – Visualização dos resíduos das redes para o escoamento da cadeira</i>	<i>4120</i>
<i>Figura 4-17 – Curva de regressão para o limite de escoamento (execução n)</i>	<i>122</i>
<i>Figura 4-18 – Curva de regressão para o limite de escoamento (execução n+1)...</i>	<i>122</i>
<i>Figura 4-19 – Curva de regressão para o limite de escoamento (execução n+2)...</i>	<i>123</i>
<i>Figura 4-20 – Curva de regressão para o limite de escoamento (execução n+3)...</i>	<i>123</i>
<i>Figura 4-21 – Visualização do desempenho das redes para o atrito da cadeira 1 ..</i>	<i>127</i>
<i>Figura 4-22 – Visualização dos resíduos das redes para o atrito da cadeira 1</i>	<i>127</i>
<i>Figura 4-23 – Visualização do desempenho das redes para o atrito da cadeira 2 .</i>	<i>128</i>
<i>Figura 4-24 – Visualização dos resíduos das redes para o atrito da cadeira 2</i>	<i>128</i>
<i>Figura 4-25 – Visualização do desempenho das redes para o atrito da cadeira 3 .</i>	<i>129</i>
<i>Figura 4-26 – Visualização dos resíduos das redes para o atrito da cadeira 3</i>	<i>129</i>
<i>Figura 4-27 – Visualização do desempenho das redes para o atrito da cadeira 4 .</i>	<i>130</i>

<i>Figura 4-28 – Visualização dos resíduos das redes para o atrito da cadeira 4.....</i>	<i>130</i>
<i>Figura 4-29 – Interface do utilitário Sigma_Mu_Calc</i>	<i>132</i>
<i>Figura 4-30 – Interface do Utilitário NeuraLTF</i>	<i>134</i>
<i>Figura 5-1 – Distribuição dos erros no cálculo da força de laminação da cadeira 1</i>	<i>136</i>
<i>Figura 5-2 – Distribuição dos erros no cálculo da velocidade da cadeira 1</i>	<i>136</i>
<i>Figura 5-3 – Distribuição dos erros no cálculo da força de laminação da cadeira 2</i>	<i>137</i>
<i>Figura 5-4 – Distribuição dos erros no cálculo da velocidade da cadeira 2</i>	<i>137</i>
<i>Figura 5-5 – Distribuição dos erros no cálculo da força de laminação da cadeira 3</i>	<i>138</i>
<i>Figura 5-6 – Distribuição dos erros no cálculo da velocidade da cadeira 3</i>	<i>138</i>
<i>Figura 5-7 – Distribuição dos erros no cálculo da força de laminação da cadeira 4</i>	<i>139</i>
<i>Figura 5-8 – Distribuição dos erros no cálculo da velocidade da cadeira 4</i>	<i>139</i>
<i>Figura 5-9 – Interface do Sigma_Mu_Calc no modo de avaliação.....</i>	<i>140</i>
<i>Figura 5-10 – Histogramas de espessura de entrada das tiras</i>	<i>141</i>
<i>Figura 5-11 – Histogramas de espessura de saída das tiras</i>	<i>142</i>
<i>Figura 5-12 – Histogramas de largura das tiras</i>	<i>142</i>
<i>Figura 5-13 – Histogramas de coroa das tiras</i>	<i>143</i>
<i>Figura 5-14 – Interface da fila de entrada do laminador.....</i>	<i>144</i>
<i>Figura 5-15 – Interface para o cálculo de referências</i>	<i>145</i>
<i>Figura 5-16 – Método para alteração de valores na base de dados</i>	<i>146</i>
<i>Figura 5-17 – Indicação visual de erro no cálculo de referências.....</i>	<i>147</i>
<i>Figura 5-18 – Distribuição dos erros de força de laminação na cadeira 1</i>	<i>148</i>
<i>Figura 5-19 – Distribuição dos erros de velocidade de laminação na cadeira 1 ...</i>	<i>149</i>
<i>Figura 5-20 – Distribuição dos erros de força de laminação na cadeira 2</i>	<i>149</i>
<i>Figura 5-21 – Distribuição dos erros de velocidade de laminação na cadeira 2 ...</i>	<i>150</i>
<i>Figura 5-22 – Distribuição dos erros de força de laminação na cadeira 3</i>	<i>150</i>
<i>Figura 5-23 – Distribuição dos erros de velocidade de laminação na cadeira 3 ...</i>	<i>151</i>
<i>Figura 5-24 – Distribuição dos erros de força de laminação na cadeira 4</i>	<i>151</i>
<i>Figura 5-25 – Distribuição dos erros de velocidade de laminação na cadeira 4 ...</i>	<i>152</i>

LISTA DE TABELAS

<i>Tabela 1-1 – Características principais do laminador estudado.....</i>	<i>46</i>
<i>Tabela 4-1 – Redes para o limite de escoamento da cadeira 1.....</i>	<i>117</i>
<i>Tabela 4-2 – Redes para o limite de escoamento da cadeira 2.....</i>	<i>118</i>
<i>Tabela 4-3 – Redes para o limite de escoamento da cadeira 3.....</i>	<i>119</i>
<i>Tabela 4-4 – Redes para o limite de escoamento da cadeira 4.....</i>	<i>120</i>
<i>Tabela 4-5 – Limites de redução nas cadeiras do laminador.....</i>	<i>121</i>
<i>Tabela 4-6 – Redes para o coeficiente de atrito da cadeira 1</i>	<i>127</i>
<i>Tabela 4-7 – Redes para o coeficiente de atrito da cadeira 2</i>	<i>128</i>
<i>Tabela 4-8 – Redes para o coeficiente de atrito da cadeira 3</i>	<i>129</i>
<i>Tabela 4-9 – Redes para o coeficiente de atrito da cadeira 4</i>	<i>130</i>
<i>Tabela 4-10 – Características e desempenho das redes treinadas</i>	<i>131</i>
<i>Tabela 5-1 – Melhores resultados para a média das grandezas testadas</i>	<i>152</i>
<i>Tabela 5-2 – Melhores resultados para o desvio-padrão das grandezas testadas ..</i>	<i>153</i>

LISTA DE ABREVIATURAS E SIGLAS

ABM –	Associação Brasileira de Metalurgia, Materiais e Mineração
AC –	Alternating Current
AEI –	Associated Electric Industries
AG –	Algoritmo(s) Genético(s)
AGC –	Automatic Gauge Control
AI –	Artificial Intelligence
ANN –	Artificial Neural Network(s)
BFGS –	Broyden-Fletcher-Goldfarb-Shanno (algoritmo de otimização)
BP –	Backpropagation
CAPES –	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CE –	Computação Evolucionária
CI –	Computational Intelligence
CIM –	Computer Integrated Manufacturing
COA –	Center of Area
COSIPA –	Companhia Siderúrgica Paulista
CPU –	Central Processing Unit
DC –	Direct Current
DDC –	Direct Digital Controller
DDE –	Dynamic Data Exchange
FB –	Controle por realimentação (<i>feedback</i>)
FBD –	Function Block Diagram
FFN –	Flat Fuzzy Number
FIFO –	First-In, First-Out
FIS –	Fuzzy Inference System
FL –	Fuzzy Logic
FW –	Controle antecipativo (<i>feedforward</i>)
GA –	Genetic Algorithm
GMNN –	Gated Modular Neural Network
GRNN –	General Regression Neural Network
HGC –	Hydraulic Gauge Control
HP –	Hewlett-Packard

IA –	Inteligência Artificial
IC –	Inteligência Computacional
IF/SP –	Instituto Federal de Educação, Ciência e Tecnologia de São Paulo
IEEE –	Institute of Electrical and Electronic Engineers
IHM –	Interface Homem-Máquina
IPACT –	Integrated Process Automation and Control Technologies
ISO –	International Organization for Standardization
LFN –	Left Fuzzy Number
LMS –	Least Mean Squares
LN –	Lógica Nebulosa
LTF –	Laminador de Tiras a Frio
MAX –	Método do Máximo para Defuzificação
MIMO –	Multiple Inputs, Multiple Outputs
MLP –	Multiple Layer Perceptron
MMI –	Man-Machine Interface
MOM –	Mean of Maxima
NTC –	Normal Tension Control
OOP –	Object-Oriented Programming
PC –	Personal Computer
PDI –	Primary Data Input
PID –	Proporcional, Integral e Derivativo
PLC –	Programmable Logic Controller
PLS –	Partial Least Squares
RAID –	Redundant Array of Independent Drives
RAM –	Random Access Memory
RBF –	Radial Basis Function
RDBMS –	Relational Data Base Management System
RFN –	Right Fuzzy Number
RISC –	Reduced Instruction Set Computer
RLS –	Recursive Least Squares
RNA –	Rede(s) Neural(is) Artificial(is)
SAS –	Serial Attached SCSI
SCADA –	Supervisory Control and Data Acquisition
SCARA –	Selective Compliant Assembly Robot Arm

SCSI – Small Computer System Interface
SFC – Sequential Function Charts
SQL – Structured Query Language
STC – Safety Tension Control
TCP/IP – Transmission Control Protocol / Internet Protocol
USIMINAS – Usinas Siderúrgicas de Minas Gerais
WCCI – World Congress on Computational Intelligence

LISTA DE SÍMBOLOS

V_r	Velocidade periférica dos cilindros de trabalho do laminador
s	Escorregamento ou diferença percentual entre velocidades de superfícies em contato
h_i	Espessura da tira na entrada de uma cadeira de laminação
h_o	Espessura da tira na saída de uma cadeira de laminação
v_s	Velocidade linear da tira durante a laminação
R_{def}	Raio do cilindro, deformado sob a ação da força de laminação
θ	Ângulo de mordida
e_{min}	Espessura mínima da tira no interior do arco de contato
e_{in}	Espessura da tira no início do arco de contato
P	Tensão de laminação, em Ton/mm
R_o	Raio original (não deformado) do cilindro de laminação
Nu	Coefficiente de Poisson
E	Módulo de Young
T_{in}	Tensão longitudinal aplicada à tira na entrada da cadeira de laminação (tensão à ré)
T_o	Tensão longitudinal aplicada à tira na saída da cadeira de laminação (tensão avante)
σ_o	Limite de escoamento do material na saída da cadeira de laminação
σ_{in}	Limite de escoamento do material na entrada da cadeira de laminação
W	Largura da tira
μ	Coefficiente de atrito entre a tira e os cilindros de laminação
f	Pressão normal exercida sobre a tira
e	Deformação convencional (ou de engenharia) sofrida pela tira
Δl	Variação de comprimento experimentada pela tira
l_o	Comprimento inicial da tira
l_f	Comprimento final da tira
ϵ	Deformação verdadeira (ou logarítmica) sofrida pela tira

τ	Força de atrito
Δh	Variação de espessura experimentada pela tira
n	Velocidade periférica de um cilindro de trabalho
D	Diâmetro de um cilindro de trabalho
P	Potência aplicada a uma cadeira de laminação
P_{opt}	Valor ótimo de potência numa cadeira de laminação
P_r	Força de laminação
P_{real}	Valor real da força de laminação
P_{mod}	Valor da força de laminação calculado pelo modelo
c_k	Coefficiente de correção referente ao k-ésimo passe de laminação
$adap_k$	Coefficiente de adaptação referente ao k-ésimo passe de laminação
x_k	Fator de influência referente ao k-ésimo passe de laminação
x	Sinal de entrada de uma unidade processadora numa RNA
y_d	Sinal de saída desejado numa unidade processadora numa RNA
y_r	Sinal de saída efetivo numa unidade processadora numa RNA
ω	Peso da conexão entre duas unidades processadoras numa RNA
E	Erro quadrático entre os valores efetivo e desejado na saída de uma RNA
t	Época no treinamento de uma RNA
η	Taxa de aprendizado do algoritmo de treinamento de uma RNA
α	Taxa de momento do algoritmo de treinamento de uma RNA
c	Centro de uma função de base radial
σ	Raio de uma função de base radial
h	Número de unidades processadoras ocultas numa RNA
i	Número de unidades processadoras na camada de entrada de uma RNA
p	Número de padrões de treinamento de uma RNA
o	Número de unidades processadoras na camada de saída de uma RNA
$\mu_A(x)$	Função de pertinência de um elemento x em relação a um conjunto A
T	Norma triangular (operação conjuntiva entre variáveis nebulosas)

S	Conorma triangular (operação disjuntiva entre variáveis nebulosas)
c	Valor de uma variável categórica (<i>crisp</i>)
H₀	Hipótese nula numa inferência estatística
H₁	Hipótese alternativa numa inferência estatística
α	Nível de significância de um teste de hipóteses
Z_{TAB}	Valor tabelado da estatística de um teste de hipóteses
Z_{CALC}	Valor calculado da estatística de um teste de hipóteses

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	25
1.1 Objetivos	25
1.2 Justificativa	26
1.3 Metodologia	27
1.4 O Processo de Laminação a Frio e Sua Automação	28
1.5 Arquitetura de Automação e Controle do Laminador de Tiras a Frio	35
1.5.1 Funções de Controle de Velocidade	40
1.5.2 Funções de Controle de Espessura	42
1.5.3 Funções de Controle de Tensão	43
1.6 Caracterização do Problema.....	44
1.7 Sumário Estruturado da Tese.....	47
 CAPÍTULO 2 – A MODELAGEM MATEMÁTICA DO PROCESSO SIDERÚRGICO DE LAMINAÇÃO PLANA E SUA ADAPTAÇÃO	 49
2.1 Principais Categorias de Modelos Para a Laminação Plana	50
2.2 Um Modelo Unidimensional Básico	52
2.2.1 Premissas e Equações de um Modelo de Deformação	53
2.3 Adaptação do Modelo Matemático	58
2.3.1 Fatores de Influência sobre o Limite de Escoamento do Material	60
2.3.2 Fatores de Influência Sobre o Coeficiente de Atrito no Arco de Contato	63
2.3.3 Métodos Utilizados Para a Adaptação dos Parâmetros do Modelo	66
 CAPÍTULO 3 TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL E SUA APLICAÇÃO AO PROCESSO DE LAMINAÇÃO	 72
3.1 Definindo Inteligência Computacional	72

3.2 Redes Neurais Artificiais.....	74
3.2.1 Roteiro para o Desenvolvimento de um Sistema Baseado em RNA.....	78
3.2.2 Redes Neurais Artificiais Para Aproximação de Funções.....	80
3.2.3 Comparação Entre as Duas Arquiteturas.....	87
3.3 Lógica Nebulosa.....	88
3.3.1 Sistemas de Inferência Nebulosa.....	92
3.4 Algoritmos Genéticos.....	96
3.4.1 Roteiro Para o Desenvolvimento de um Algoritmo Genético.....	99
3.5 Utilização Conjunta das Ferramentas.....	101
3.6 Aplicação de Inteligência Computacional no Processo de Laminação.....	103
CAPÍTULO 4 – METODOLOGIA DE DESENVOLVIMENTO.....	106
4.1 Estratégia de Abordagem.....	106
4.2 Coleta de Dados.....	107
4.3 Desenvolvimento das Redes Neurais.....	109
4.3.1 Desenvolvimento das RNA para Determinação do Limite de Escoamento ..	109
4.3.2 Desenvolvimento das RNA para Determinação do Coeficiente de Atrito	124
4.4 Análise dos Resultados do Treinamento.....	131
4.5 O Aplicativo <i>Sigma_Mu_Calc</i>.....	132
CAPÍTULO 5 AVALIAÇÃO DO SISTEMA E DISCUSSÃO DOS RESULTADOS.....	135
5.1 Avaliação do Desempenho Original do Modelo.....	135
5.2 Obtenção dos Parâmetros Adaptativos pelo Sistema Proposto.....	140
5.3 Avaliação dos Resultados.....	146
5.4 Verificação Pelo Método Estatístico do Teste de Hipóteses.....	153

5.4.1 Cálculos Para a Força de Laminação.....	154
5.4.2 Cálculos Para a Velocidade de Laminação.....	155
5.5 Recomendações Decorrentes dos Resultados Obtidos.....	156
CAPÍTULO 6 CONCLUSÕES E CONSIDERAÇÕES FINAIS.....	158
6.1 Oportunidades de Melhoria.....	158
6.2 Contribuições da Pesquisa e Consecução dos Objetivos.....	160
6.3 Produção Científica Durante a Pesquisa.....	161
6.4 Considerações Finais.....	161
REFERÊNCIAS.....	163

Capítulo 1 - INTRODUÇÃO

Este trabalho descreve as técnicas tradicionalmente utilizadas na adaptação dos parâmetros do modelo matemático de um laminador a frio de aços planos e propõe a aplicação de métodos não convencionais (mais especificamente, técnicas de Inteligência Computacional) para aperfeiçoar esse processo de adaptação.

Devido às peculiaridades do processo de laminação a frio de aços, que envolve inúmeras variáveis de difícil modelagem e fortemente correlacionadas, as técnicas englobadas no campo de conhecimento denominado Inteligência Computacional parecem ser especialmente apropriadas para esse fim. Esse trabalho comprova tal adequação e propõe a utilização dessas técnicas em conjunto com os métodos convencionais de adaptação de parâmetros. As hipóteses levantadas na pesquisa são testadas com a sua aplicação num laminador real, o Laminador de Tiras a Frio das Usinas Siderúrgicas de Minas Gerais (Usiminas) – Fábrica de Cubatão (SP), a antiga Cosipa.

1.1 Objetivos

A siderurgia é um mercado extremamente competitivo, especialmente nos setores que conferem maior valor agregado ao produto, como a laminação a frio. Hufbauer e Goodrich (2002) reportam a falência de nada menos que 29 siderúrgicas norte-americanas num período de apenas quatro anos. As fusões e aquisições estão cada vez mais na ordem do dia desse setor. Analisando o panorama siderúrgico europeu, Beguin e Carley (2005) concluem que o mesmo “*tem experimentado um longo período de reestruturação, marcado por privatização, internacionalização, e concentração sob um pequeno número de grandes multinacionais*”, o que pode ser igualmente constatado nos demais continentes. A profunda crise econômica que eclodiu no segundo semestre de 2008 agravou sobremaneira esse cenário. Visto que a acirrada concorrência não permite o repasse de custos para o cliente final, a sobrevivência nesse mercado requer uma cultura empresarial de melhoria contínua, em cada fase do processo produtivo.

Nesse contexto, o presente trabalho tem seu foco sobre uma das etapas da estratégia de controle do processo de laminação a frio, a saber: a adaptação dos parâmetros dos modelos matemáticos utilizados no cálculo das referências (“*setpoints*”) para os dispositivos de controle em tempo real de um laminador a frio de aços planos.

A tese que a pesquisa buscou comprovar é a aplicabilidade das técnicas de Inteligência Artificial para o aperfeiçoamento da adaptação dos modelos utilizados no controle de tal processo. Outros propósitos objetivados, além do principal, foram:

- Aprofundar o conhecimento sobre o processo, obtendo-se, em consequência, maior domínio sobre ele;
- Desenvolver um aplicativo a ser incorporado ao sistema de automação e controle de uma planta real, visando aperfeiçoar as características de adaptação do modelo de otimização dessa planta e, com isso,
- Reduzir os erros na geração de referências, proporcionando maior produtividade e qualidade do produto.

1.2 Justificativa

Em condições normais de mercado, um laminador de tiras a frio opera durante 24 horas por dia, 7 dias por semana. A produção anual é da ordem de grandeza de centenas de milhares de toneladas. No caso específico do laminador estudado, a produção gira em torno de 1.100.000 toneladas anuais. Desse modo, incrementos na produtividade ou na qualidade, ainda que da ordem de partes por mil, originam significativos ganhos financeiros.

Nishino *et al.* (2000) são enfáticos ao afirmar que:

Os esforços para a melhoria da acurácia do modelo (do processo de laminação) não têm fim. Um modelo mais acurado é capaz de um controle de qualidade mais preciso, contribuindo para o aumento da produtividade e da qualidade do produto, bem como para a redução de custos.

Visto que o modelo matemático responsável pelo cálculo das referências usadas no controle em tempo real do processo é preponderante para a sua qualidade, qualquer aperfeiçoamento do modelo tende a reduzir as perdas de produção e de produtividade (causadas principalmente pela ruptura de tiras devido a referências mal calculadas), bem como os defeitos no produto. Esse ganho potencial justifica plenamente a iniciativa. Para dar uma idéia, um aumento de apenas 0,1 % na produtividade da planta significa, no caso em questão, uma produção adicional de 1.100 toneladas por ano. Quantificando financeiramente, dado o preço médio de US\$ 661,00 para a tonelada da bobina laminada a frio no ano de 2007 (no qual os índices não foram contaminados pela crise), tal acréscimo implica numa receita anual complementar de US\$ 727.100,00, o que está longe de ser desprezível.

Em anos recentes, foram realizados alguns trabalhos que resultaram na melhoria da operação do modelo matemático utilizado no laminador em questão. Pires (2007) investigou e implantou estratégias para a otimização do cálculo de referências. Santos Filho e Ramirez-Fernandez (2003) propuseram e desenvolveram uma ferramenta alternativa para o cálculo de referências, baseado na aplicação híbrida de redes neurais artificiais e modelagem matemática. O fato de que o Nível 2 de automação da planta estudada, incluindo o seu modelo matemático, foi totalmente reformulado durante o ano de 2008 justifica novas iniciativas no sentido de aperfeiçoá-lo.

1.3 Metodologia

Uma acurada revisão bibliográfica permitiu a compreensão dos problemas envolvidos na modelagem matemática da laminação de aços planos, com enfoque no processo realizado a frio. A partir dessa revisão foi possível identificar os principais parâmetros que, possuindo características simultâneas de alta complexidade, difícil mensuração e relevância no desempenho do modelo de otimização, seriam naturalmente candidatos à abordagem por meio de técnicas de Inteligência Computacional: o limite de escoamento do material e o coeficiente de atrito entre a tira laminada e os cilindros de laminação.

O passo seguinte no desenvolvimento do trabalho foi o levantamento de dados que permitissem a construção do novo mecanismo de adaptação do modelo, bem como a comparação de seu desempenho com o do mecanismo original de adaptação da planta. Esse levantamento foi realizado por meio de consultas SQL à base de dados Oracle existente na planta (banco de dados histórico). A implementação do modelo proposto foi realizada com o auxílio do aplicativo Statística[®] (*toolbox* Automated Neural Networks).

A partir das configurações ótimas das redes neurais, foi desenvolvido um utilitário em linguagem de programação C# para permitir a execução em modo *off-line* do modelo desenvolvido, ou seja, sem atuação efetiva sobre o processo produtivo, limitando-se a produzir resultados que permitissem comparação posterior com aqueles obtidos pelo modelo existente.

A análise dos resultados obtidos originou as recomendações que são apresentadas no Capítulo 5 da tese, que delineia os passos para a incorporação do sistema desenvolvido à estrutura de automação da planta estudada.

1.4 O Processo de Laminação a Frio e Sua Automação

No processo de laminação, a espessura de uma tira é submetida a esforços de compressão axial e de tração longitudinal, com o objetivo de se reduzir a sua espessura. Quando esse processo é realizado abaixo da *temperatura de recristalização* (aquela em que se verificam alterações na microestrutura do material), é denominado como *laminação a frio*. A laminação a frio do aço eleva a sua dureza, sua resistência à tração e o valor de seu limite de escoamento, ao mesmo tempo em que reduz a sua ductilidade.

Um laminador a frio de aços planos promove uma redução entre 50% e 90% na espessura da tira processada. Para tanto, utiliza-se de uma pilha de quatro (laminadores *quádruplos*) a seis cilindros superpostos, que transmitem ao material processado a pressão exercida por pistões hidráulicos. Cada conjunto formado por pilha de cilindros e pistões é chamado de *cadeira de laminação*. Para atingir os elevados níveis de redução necessários, com a máxima produtividade, os laminadores a frio utilizam em geral várias cadeiras (até sete) – são os chamados laminadores *tandem*. Os intervalos entre as cadeiras são chamados de *vãos* e a região de contato entre os cilindros e a tira é chamada de *arco de contato*.

Durante o processamento de uma tira, várias operações são realizadas. Primeiramente, dadas as espessuras de entrada e saída da tira e a sua largura, calcula-se um padrão (denominado *esquema*) para as espessuras e tensões nos vãos, bem como a máxima velocidade de laminação que proporcione uma distribuição satisfatória da carga de laminação e da potência entre as cadeiras. Em seguida, com base no esquema assim calculado, é possível determinar as referências necessárias para os atuadores do processo. Essa determinação é obtida a partir das equações que regem o comportamento do laminador em estado permanente. Essas referências são conhecidas como *presets* e o processo de cálculo dessas referências é denominado de *setup* do laminador. Finalmente, as referências calculadas do modo acima descrito são transferidas aos equipamentos que farão o controle do processo em tempo real, ou seja, durante a laminação propriamente dita. Nessa fase, a partir das informações sobre os valores efetivos das variáveis de processo, controladores digitais realizam os ajustes necessários para que o objetivo proposto seja alcançado.

O processamento de uma tira pode ser dividido em três fases distintas: o *encaixe*, a *laminação propriamente dita* e o *desencaixe*. Edwards (1978) enumera uma série de fatores que tornam as condições operacionais na fase de encaixe substancialmente diferentes daquelas

vigentes na fase seguinte. Entre elas, destacam-se: a inexistência de tensão longitudinal sobre a tira (embora logo após a mordida se estabeleça uma tensão à ré), a diferença nas características de deformação da tira (devido ao valor do limite de escoamento em baixa temperatura e sob baixa pressão), o aumento no coeficiente de atrito (devido às características da emulsão refrigerante em baixa velocidade) e a baixa espessura do filme de óleo nos mancais dos cilindros de encosto, o que equivale a um aumento da abertura entre os cilindros.

Assim, o principal objetivo do controle, tanto durante o encaixe quanto durante o desencaixe, é manter uma planicidade satisfatória nas partes inicial e final da tira, de forma que a introdução e a saída da tira nas diversas cadeiras sejam livres de problemas, evitando-se danos aos cilindros. Para tanto, durante essas fases o laminador é operado em velocidade bem menor que a utilizada durante a fase de laminação propriamente dita. No caso de materiais de menor espessura, o laminador pode ser ajustado para operar com espessura de saída maior que a objetivada, para evitar danos aos mancais, ao corpo dos cilindros de trabalho e à qualidade do material. Uma vez que a tira é composta pela soldagem de duas ou mais bobinas previamente laminadas a quente, a velocidade de operação também é reduzida nas regiões de solda, visando evitar rupturas.

Além da deformação plástica (permanente) aplicada à tira laminada, o processo de laminação envolve ainda deformações elásticas (transitórias), em especial sobre os cilindros de laminação, mas também sobre o material processado e sobre o próprio laminador. Segundo Helman e Cetlin (1993), a deformação elástica envolve todos componentes do equipamento (estrutura, rolamentos, mancais, cilindros, etc.). Essa característica tem que ser levada em conta no cálculo da abertura necessária entre os cilindros de trabalho para que a tira tenha uma determinada espessura à saída de uma cadeira de laminação. O cálculo preciso requer o conhecimento do *módulo de rigidez* ou *cedagem* do laminador. A partir desse conhecimento, combina-se a curva que relaciona a deformação plástica e a força de laminação com a curva que relaciona a espessura de saída e a força de laminação, obtendo-se o ponto ótimo de operação.

A Figura 1-1 e a Figura 1-2, obtidas do trabalho de Morita e Emi (2002), mostram, respectivamente, o processo de deformação sofrido pelo material numa cadeira de laminação e os principais sensores e atuadores utilizados nos laminadores *tandem* a frio em geral. Com relação à planta especificamente estudada neste trabalho, os detalhes são apresentados na Seção 1.5.

Figura 1-1 – Deformação do material numa cadeia de laminação

Figura 1-2 – Principais sensores, atuadores e malhas de controle de um laminador típico

Como bem observa Aylen (2004), siderurgia e computadores mantêm entre si uma relação de simbiose, com o desenvolvimento da primeira exigindo o aperfeiçoamento dos últimos, ao mesmo tempo em que, conforme esse autor, a indústria siderúrgica foi pioneira na

aplicação de computadores no controle de processos. Para o desenvolvimento de um modelo especificamente relacionado com o processo de laminação, foi estabelecido, em 1966, um consórcio formado pelo Ministério da Tecnologia britânico, pela companhia Associated Electrical Industries (AEI), pelo Imperial College e pela Companhia Siderúrgica do País de Gales, numa iniciativa que foi considerada “*um exercício verdadeiramente notável para a transformação da automação de laminadores, não apenas no Reino Unido, mas em todo o mundo*” (BRYANT, J., 2004, *apud* AYLEN, 2004).

Assim, o aperfeiçoamento dos computadores digitais permitiu um maior grau de sofisticação aos sistemas de controle para os laminadores, cujos modelos passaram a incorporar, além da força de laminação, outras variáveis, entre as quais a espessura e a tensão mecânica, nos modelos desenvolvidos por Courcoulas e Ham (1957) e por Arimura, Kamata e Saito (1971), e o coroamento térmico dos cilindros de laminação, e o perfil transversal da tira, como o desenvolvido por Bryant, Halliday e Spooner (1973).

A forte interação existente entre as diversas variáveis aumenta de forma significativa a complexidade das equações que constituem um modelo para a laminação a frio. A solução de tais equações requer o uso de métodos iterativos, que mesmo em computadores modernos, demandam um razoável tempo de processamento (da ordem de segundos). Visto que os tempos de resposta envolvidos no processo são da ordem de dezenas de milissegundos, torna-se claro que tais modelos não são capazes de controlar a planta em tempo real, tornando-se necessária uma divisão dos níveis de controle, numa arquitetura de automação hierárquica e distribuída, na qual as funções de controle e informação dividem-se em níveis bem definidos – é a chamada *estrutura CIM*, representada na Figura 1-3. Essa estrutura foi definida pelo Grupo de Trabalho N° 1 da ISO e é explicada em detalhes por Williams (1989). Ela é chamada de “pirâmide” porque, em geral, quanto mais baixo o nível hierárquico, maior o número de dispositivos existentes. De acordo com a companhia Integrated Process Automation and Control Technologies (IPACT 2003), “*independente da magnitude do processo de laminação a frio considerado, múltiplos níveis (de automação) são necessários*”. Não existe consenso quanto ao número de níveis presentes, nem mesmo quanto à forma de denominá-los. No caso específico da Usiminas, a pirâmide é dividida em quatro níveis (de baixo para cima: instrumentação e atuação, controle, otimização e corporativo), sendo o inferior denominado “Nível 0”.

Figura 1-3 – Pirâmide de automação segundo o modelo de referência da ISO

Como explanado acima, a hierarquização dos níveis de automação se faz necessária porque, conforme o atestam Reeve, MacAlister e Bilkhu (1999), o escopo do controle cobre um amplo leque de funções, que vai desde malhas de controle de alta velocidade (na ordem de milésimos de segundos) até o manuseio de ordens de produção, que são feitas com horas ou mesmo dias de antecedência. Tais diferenças no escopo e na escala de tempo das funções se refletem nessa estrutura de múltiplos níveis.

Cho, Cho e Yoon (1997) dividem a estratégia de controle de um laminador *tandem* em três fases distintas, às quais denominam de *pré-cálculo* (ou *fase estática*), *controle em tempo real* (ou *fase dinâmica*), e *pós-cálculo*. A Figura 1-4 esquematiza a estratégia de controle tal como concebida por esses autores.

Figura 1-4 – Diagrama da estratégia de controle de um laminador

A fase de pré-cálculo é executada pelos modelos matemáticos. Sua função é calcular, a partir das informações sobre o material de entrada, os valores ótimos para as diversas variáveis (força de laminação, velocidade, tensão mecânica, coroamento dos cilindros, etc.) para que se obtenham as características desejadas para o produto final. Esse cálculo precisa levar em conta os limites mecânicos e elétricos dos equipamentos, dentro dos quais deve

objetivar as máximas qualidade e produtividade. A fase de pré-cálculo consiste basicamente na solução de um problema de otimização com múltiplas restrições.

A fase de controle em tempo real, que se inicia com a laminação propriamente dita, tem como objetivo a manutenção, em face dos distúrbios existentes, da espessura de saída, da forma e do acabamento superficial, sem que ocorra uma sobrecarga da operação das cadeiras intermediárias. Um cuidado especial deve ser tomado em relação à tensão entre as cadeiras, para evitar o afrouxamento ou o rompimento da tira.

Os rápidos tempos de resposta exigidos nessa fase requerem que o processamento seja executado através de controladores especialmente apropriados, conhecidos como Controles Digitais Diretos (DDC), que consistem de dispositivos baseados em microprocessadores, nos quais a lógica de controle é realizada por software. Tais dispositivos representam um aperfeiçoamento dos antigos controladores lógicos programáveis. Em geral, sua interface de programação utiliza uma linguagem de blocos (SFC, FBD, diagramas escada, etc.) e, eventualmente, alguma linguagem de terceira geração. O controle em tempo real, que desse ponto em diante será referido simplesmente como *controle*, é também conhecido como *fase dinâmica* da estratégia de controle e é executado no Nível 1 da pirâmide de automação.

A fase de pós-cálculo consiste na adaptação dos parâmetros do modelo matemático, com base nos valores reais das variáveis, medidos pelos sensores localizados no Nível 0 da pirâmide de automação, durante a fase dinâmica e enviados para o Nível 2. Dessa forma, o pós-cálculo é uma fase intermediária na estratégia de controle, na qual interagem os níveis 0, 1 e 2 da pirâmide de automação. À medida que o processo é executado, os valores efetivos de diversas variáveis são medidos e armazenados na base de dados do sistema. Outras variáveis, cuja medição não é factível, têm seus valores inferidos por meio de modelagem inversa. Esses valores são em seguida comparados com aqueles previamente calculados pelo modelo, que tem então os seus coeficientes ajustados com base nas diferenças encontradas, de forma que as estimativas futuras do modelo sejam mais precisas. Este é o processo de adaptação do modelo.

Diversos métodos são utilizados na fase de adaptação. De acordo com Fechner, Neumerkel e Keller (1994), embora na maior parte dos modelos matemáticos de laminação sejam utilizados algoritmos de mínimas médias quadráticas (LMS), devido à sua simplicidade, os algoritmos de mínimos quadrados recursivos (RLS) apresentam melhor desempenho, tanto em termos de velocidade de convergência quanto em termos de erros

médios. Reeve, MacAlister e Bilkhu (1999) preconizam a utilização de filtros de Kalman para a obtenção dos valores ótimos para os coeficientes adaptativos. Cada um desses algoritmos apresenta diversas variações. Note-se que, embora tais técnicas sejam por vezes utilizadas também para melhorar o desempenho do controle (fase dinâmica), elas são muito mais confortavelmente adequadas à fase do pós-cálculo, devido aos requisitos de tempo menos estritos.

De acordo com Röscheisen, Hoffmann e Tresp (1992), o considerável interesse econômico no aperfeiçoamento nos métodos de adaptação utilizados nos modelos matemáticos de laminação deriva do fato de que a capacidade de produzir com tolerâncias de espessura cada vez menores tem-se tornado indispensável para a sobrevivência das indústrias e, já ao tempo em que foi publicado o trabalho desses pesquisadores, os métodos convencionais vinham-se mostrando insuficientes para atender a tal nível de exigência.

Nessa busca por maior eficiência, certas peculiaridades dos fenômenos envolvidos na laminação e seu sistema de controle (complexidade, informações incompletas e sujeitas a ruídos, abundância de dados históricos, influência da habilidade e experiência humana em certas operações) qualificam a Inteligência Computacional como ferramenta especialmente promissora. Prova dessa adequação é o número sempre crescente de trabalhos reportando a utilização bem sucedida de técnicas de Inteligência Computacional, especialmente Redes Neurais Artificiais (RNA), Lógica Nebulosa (LN) e Algoritmos Genéticos (AG), no aperfeiçoamento de várias das funções relacionadas a esse processo produtivo. Essa tendência é analisada com maior profundidade no Capítulo 3 desse documento.

Face à variedade de aplicações bem sucedidas da Inteligência Computacional como ferramenta de apoio a diversos aspectos da automação do processo siderúrgico de laminação, este trabalho se propõe a investigar sua adequação a um aspecto particular desse processo, a saber: a adaptação de seus modelos matemáticos de otimização.

1.5 Arquitetura de Automação e Controle do Laminador de Tiras a Frio

Visto que as conclusões decorrentes desta tese são aplicadas a um laminador real, a saber, o Laminador de Tiras a Frio da Usiminas, Unidade Fabril de Cubatão (anteriormente denominada como Cosipa), faz-se necessária uma descrição da arquitetura de automação e controle dessa planta.

Santos Filho, Novaes e Assis (1999) dão detalhes a respeito da arquitetura original do sistema, que em julho de 2008 experimentou uma renovação completa das plataformas de hardware e software no Nível 2 de automação (no qual se insere o presente trabalho) e uma renovação parcial nas plataformas de hardware e software de Nível 1. Após essa renovação, o sistema passou a exibir a arquitetura mostrada na Figura 1-5, na qual os itens nomeados em vermelho correspondem ao escopo da renovação.

O coração do Nível 2 é um servidor HP Proliant[®] ML 370 G5, com 2 processadores INTEL Xeon[®] MP, frequência de operação 1,6 GHz, memória cache de 4 MB, memória RAM de 4 GB, 2 pares de discos rígidos SAS de 2,5” de 146,8 GB, com espelhamento RAID 1 e 2 placas de rede Gigabit, utilizando o sistema operacional Windows[®] 2003 Server. Esse servidor abriga uma base de dados de curto prazo (Oracle[®] 10G). A interface homem-máquina é feita por meio de *desktops* Dell Optiflex[®], executando o sistema operacional Windows XP[®]. O software aplicativo foi desenvolvido em .Net Visual Studio C++ e as telas de operação em .Net Visual Studio C#. A comunicação, tanto com o Nível 3 como com o Nível 1, é realizada por meio de *sockets* TCP/IP. Santos Filho *et al.* (2008) apresentam uma descrição detalhada do sistema de automação e controle instalado na planta nessa ocasião.

Figura 1-5 – Diagrama simplificado da arquitetura de automação do LTF

Os dados de planta, de processo e de produto que foram usados no presente estudo são provenientes do banco histórico de dados da planta, uma base de dados Oracle® 10G hospedada num servidor HP Proliant® ML 370 G3, com 2 processadores INTEL Xeon® MP, frequência de operação 3,06 GHz, memória cache de 512 KB, memória RAM de 2 GB, 6 discos rígidos SCSI Wide Ultra 320 de 146,8 GB e 2 placas de rede Gigabit. O sistema operacional utilizado é o Windows® 2003 Advanced Server e a integridade dos dados armazenados é garantida por uma configuração matricial de discos rígidos do tipo RAID 5. Essa base de dados histórica recebe os dados da base de curto prazo, hospedada no servidor de Nível 2, e os armazena por no mínimo dois anos. As funcionalidades e características dessa base histórica são descritas em detalhes por Vieira e Santos Filho (2007).

As principais malhas de controle do Nível 1 e os sensores presentes no Nível 0 de automação da planta, que não aparecem na Figura 1-5, podem ser vistos na Figura 1-6.

Figura 1-6 – Principais malhas de controle e atuadores da planta estudada

Relembrando, as principais variáveis controladas em tempo real são a espessura de saída, o perfil (ou coroa) e a forma da tira (ou planicidade). O controle de coroa é obtido, em malha aberta, através da deflexão dos cilindros de trabalho (*bending*) das três primeiras cadeiras e o controle de planicidade é feito, em malha fechada, por meio de uma ação combinada de deflexão de cilindros de trabalho da última cadeira e da refrigeração localizada, com base nas informações do rolo medidor de planicidade. Na descrição que se segue, a

atenção será focalizada no controle de espessura, de importância tão fundamental que o sistema de controle em tempo real é freqüentemente denominado de AGC (*Automatic Gauge Control*). Os sensores responsáveis por realimentar o AGC do LTF são os medidores Raios-X de espessura, o medidor laser de velocidade, os geradores tacométricos e os tensiômetros.

Caley e Edwards (1973) dividem os distúrbios presentes no processo de laminação em duas categorias: os distúrbios derivados do equipamento (como a excentricidade e o coroamento térmico dos cilindros e a variação na espessura do filme de óleo) e os distúrbios oriundos do material processado (como as variações na espessura de entrada e as variações na dureza). Segundo esses autores, o processo de laminação *tandem* possui uma característica peculiar de permitir que a propagação dos distúrbios da entrada para a saída ocorra sem qualquer filtragem dinâmica.

As variáveis manipuladas para o controle da espessura são a força de laminação, a tensão mecânica sobre a tira e a velocidade de laminação, que são modificadas primeiramente com base nas informações recebidas do medidor de espessura instalado na saída da primeira cadeira. O transporte da tira da saída da cadeira até a posição do medidor introduz um tempo de atraso dependente da velocidade de laminação. A resposta dinâmica do sistema é determinada essencialmente por esse tempo de atraso, especialmente em baixas velocidades. Isso significa que erros de alta freqüência não podem ser eliminados por um sistema de controle baseado apenas em realimentação. Beal (2003) estima que o desempenho de um AGC típico seja da ordem de um quarto do desempenho dos atuadores utilizados. Assim, para cápsulas hidráulicas com tempo de resposta da ordem de 50 ms (resposta em freqüência de 20 Hz), a resposta do AGC será da ordem de 5 Hz, de forma que desvios com freqüência superior a esta não serão adequadamente tratados pela realimentação.

Para suplantar essa deficiência, o sistema deve ser dotado de controle antecipativo, que permite a atenuação dos desvios de espessura da tira de entrada. Para tanto, os desvios de espessura são detectados ainda na entrada do laminador (no caso em questão, através do medidor de espessura na saída da primeira cadeira). Essa informação é armazenada numa memória temporária, com o objetivo de adequar-se ao tempo de transporte entre o ponto de medição e o ponto de utilização, levando também em conta os tempos de atraso dos elementos finais de controle. O controle antecipativo atua sobre a velocidade da Cadeira 1 não apenas em resposta a desvios de espessura, mas também em resposta a variações na velocidade de laminação. Assim, desvios de espessura decorrentes da variação da velocidade (que influi

sobre o coeficiente de atrito, e sobre a espessura do filme de óleo) podem ser substancialmente reduzidos durante a aceleração do sistema.

O sistema de controle de espessura atua sobre o cilindro hidráulico da primeira cadeira, com base nas informações dos medidores de espessura. Atua também sobre a velocidade dos motores de todas as cadeiras, exceto da segunda, que é a *cadeira pivô*, ou seja, aquela cuja velocidade serve de base para o cálculo das velocidades das demais cadeiras. O controle de tensão, por sua vez, atua sobre os cilindros hidráulicos das três primeiras cadeiras e, se necessário, também sobre as velocidades dos motores. O controle de processo em tempo real (fase dinâmica) é norteado pelos seguintes princípios:

- **Controle da espessura de saída da Cadeira 1:** Tem como objetivo manter a espessura na entrada da Cadeira 2 tão constante quanto possível.
- **Controle do fluxo de massa na entrada da Cadeira 2:** Uma malha de controle antecipativo monitora os desvios de espessura registrados pelo medidor da saída da Cadeira 1, rastreia-os até a entrada da Cadeira 2 e então atua sobre a velocidade da Cadeira 1.
- **Manutenção do fluxo de massa até a saída do laminador:** Considerando que o fluxo de massa é mantido constante na entrada da Cadeira 2, a espessura na saída da Cadeira 4 é imposta provendo-se uma relação de velocidades entre as cadeiras 2, 3 e 4 proporcional à redução objetivada para cada uma delas. Em virtude da variação de parâmetros como escorregamento e dureza, a espessura na saída da Cadeira 4 pode variar mesmo com um fluxo de massa constante. Portanto, os desvios de espessura registrados pelo medidor localizado na saída da Cadeira 4 são aplicados a uma malha de realimentação que realiza um ajuste fino de velocidade nas cadeiras 3 e 4.
- **Controle da tensão mecânica nos vãos:** A obtenção de um fluxo de massa constante só pode ser obtida mantendo-se as tensões entre as cadeiras igualmente constantes, sob pena de rompimento da tira ou de seu afrouxamento. A partir das informações dos tensiômetros instalados em cada um dos vãos, o controle de tensão atua sobre os parafusos das cadeiras 2, 3 e 4 e sobre a velocidade da Cadeira 4.

As principais variáveis controladas na fase dinâmica são, portanto, a velocidade linear, a espessura e a tensão mecânica nos vãos. Existe uma forte interação entre essas variáveis. Como explicam King e Sills (1973), a posição dos parafusos (espessura) afeta a tensão e a

velocidade afeta tanto a tensão quanto a espessura. O controle dessas variáveis é realizado pelas seguintes funções:

- Velocidade { Geração de Referências de Velocidade
Cálculo do Escorregamento Avante
- Espessura { Realimentação da Cadeira 1
Controle Antecipativo da Cadeira 2
Ajuste Fino de Espessura da Cadeira 4
- Tensão { Controle de Tensão Normal
Controle de Tensão de Segurança

1.5.1 Funções de Controle de Velocidade

Atuam sobre os acionamentos (conversores AC/DC tiristorizados) dos motores principais, de acordo com o fluxo de massa calculado com base nas informações dos medidores de espessura.

1.5.1.1 Geração de Referências de Velocidade

A lei do fluxo de massa, que assegura que a quantidade de material que sai da cadeira é igual à que entra, pode ser expressa matematicamente pela equação:

$$\mathbf{Vr}_i \times (1 + \mathbf{s}_i) \times \mathbf{hi}_{i+1} = \mathbf{Vr}_{i+1} \times (1 + \mathbf{s}_{i+1}) \times \mathbf{ho}_{i+1} \quad (\text{Equação 1-1}),$$

onde $\mathbf{Vr}$ é velocidade periférica dos cilindros de trabalho, $\mathbf{hi}$ é a espessura de entrada da tira, $\mathbf{s}$ é o escorregamento avante na cadeira, $\mathbf{ho}$ é a espessura de saída da tira e $\mathbf{i}$ é o número da cadeira.

Lembrando que a espessura de saída $\mathbf{ho}$ de uma determinada cadeira corresponde à espessura de entrada $\mathbf{hi}$ da cadeira subsequente e que na planta estudada a Cadeira 2 é a pivô, as referências de velocidade para os cilindros de trabalho das demais cadeiras são geradas em conformidade com a lei de conservação de fluxo de massa (Equação 1-1), dando origem às equações que se seguem:

$$\text{Cadeira 1: } \mathbf{Vr}_1 = \frac{ho_2}{ho_1} \times \frac{1+s_2}{1+s_1} \times \mathbf{Vr}_2 \quad (\text{Equação 1-2});$$

$$\text{Cadeira 3: } \mathbf{Vr}_3 = \frac{ho_2}{ho_3} \times \frac{1+s_2}{1+s_3} \times \mathbf{Vr}_2 \quad (\text{Equação 1-3});$$

$$\text{Cadeira 4: } \mathbf{Vr}_4 = \frac{ho_3}{ho_4} \times \frac{1+s_3}{1+s_4} \times \mathbf{Vr}_3 \quad (\text{Equação 1-4}).$$

A velocidade periférica dos cilindros de trabalho da Cadeira 2 é igual à velocidade calculada pelo modelo estático para a fase de laminação, uma vez que esta é a cadeira pivô do laminador. Assim, durante a fase dinâmica, a velocidade dessa cadeira não é modificada.

A relação $\frac{ho_{i+1}}{ho_i} \times \frac{1+s_{i+1}}{1+s_i}$ é conhecida como *razão de velocidades*. A atuação dos

controles de espessura e tensão se dá sobre essa relação.

1.5.1.2 Cálculo do Escorregamento Avante

Até que a tira seja submetida a tensão (encaixe na cadeira posterior ou, no caso da Cadeira 4, na enroladeira), o sistema utiliza a referência de escorregamento calculada pelo modelo estático para a fase de encaixe. Assim que a tira é tensionada, o controle passa a utilizar a referência de escorregamento calculada pelo modelo estático para a fase de laminação. A partir de então, esse valor passa a ser continuamente calculado através da equação:

$$s_i = \frac{vs_i - vr_i}{vr_i} \quad (\text{Equação 1-5}),$$

sendo vs a velocidade linear da tira (que pode ser obtida pelo medidor de velocidade a laser ou pela velocidade periférica dos rolos dos tensiômetros), vr a velocidade periférica dos cilindros de trabalho (obtida através dos tacômetros instalados nos eixos dos motores desses cilindros) e i o índice referente ao número da cadeira.

Sobre o escorregamento assim calculado, aplica-se uma correção antecipativa baseada em eventuais diferenças de tensão ocorridas nos vãos anterior e posterior à cadeira. Essa função utiliza o escorregamento calculado para determinar a velocidade linear da tira no vão posterior à cadeira.

1.5.2 Funções de Controle de Espessura

O controle de espessura é realizado por uma combinação de malhas de realimentação e de controle antecipativo. A leitura do medidor de espessura localizado no vão 1-2 é utilizada pela realimentação para corrigir a abertura dessa cadeira e pelo controle antecipativo para modificar a razão de velocidades da Cadeira 2. A leitura do medidor de espessura localizado no vão 4-E é utilizada para realizar um ajuste fino na espessura de saída da tira, através da modificação da razão de velocidades na Cadeira 3 ou na Cadeira 4. A combinação de um ajuste grosso e um ajuste fino no controle de espessura é, segundo King e Sills (1973), um princípio de utilização quase universal nos laminadores. Detalham-se a seguir essas funções.

1.5.2.1 Realimentação de Espessura da Cadeira 1

Trata-se de um controle proporcional-integral, que tem como objetivo minimizar os desvios de espessura na saída da Cadeira 1, a partir das informações do medidor localizado no vão 1-2. Para minimizar o efeito do atraso entre a mordida da cadeira e a posição do medidor, o sinal é processado através de um Preditor de Smith, estratégia de controle idealizada por Smith (1957). O tempo de atraso depende da velocidade da tira na Cadeira 1, da distância entre o medidor e a entrada da cadeira, do tempo de resposta do medidor e do tempo de resposta da cápsula hidráulica da cadeira.

A correção enviada ao cilindro hidráulico da Cadeira 1 é calculada como a diferença entre o desvio de espessura instantâneo e a correção já enviada quando a tira, atualmente sob o medidor, se encontrava na abertura da cadeira. A correção leva em conta a dureza do aço e o módulo de elasticidade da cadeira.

Simultaneamente à correção na posição da cápsula hidráulica, um sinal de compensação de inércia é enviado à desenroladeira para minimizar variações de tensão na entrada da Cadeira 1. Essa compensação de inércia depende da velocidade da tira na entrada da cadeira e da espessura de entrada.

1.5.2.2 Controle Antecipativo da Cadeira 2

Controle proporcional do fluxo de massa na entrada da Cadeira 2 com base na informação do medidor de espessura do vão 1-2 e que atua sobre a velocidade da Cadeira 1. O desvio de espessura registrado pelo medidor é rastreado até a mordida da Cadeira 2 e, neste ponto, é usado para corrigir a velocidade da Cadeira 1, de forma a manter o fluxo de massa constante na entrada da cadeira pivô. O tempo de atraso depende da velocidade da tira na

saída da Cadeira 1, da distância entre o medidor e a entrada da Cadeira 2, do tempo de resposta do medidor e do tempo de resposta dos acionadores dos motores da Cadeira 1. Como consequência da correção da velocidade da Cadeira 1, ocorre uma variação de tensão entre as cadeiras 1 e 2. Para minimizar essa variação, faz-se uma correção preventiva sobre a cápsula hidráulica da Cadeira 2.

1.5.2.3 Ajuste Fino de Espessura da Cadeira 4

Controle proporcional-integral que tem como objetivo minimizar as variações de espessura na saída da Cadeira 4, com base na informação do medidor de espessura localizado no vão 4-E. Trata-se de um controle por realimentação e, da mesma forma como ocorre com o controle de espessura da Cadeira 1, utiliza um Preditor de Smith para processar a informação do medidor. A realimentação é aplicada sobre os controladores de velocidade das cadeiras 3 e 4. Além disso, o controle atua sobre a cápsula hidráulica da Cadeira 3, para evitar a variação na tensão entre as cadeiras 2 e 3 como resultado da correção na velocidade.

1.5.3 Funções de Controle de Tensão

Para se obter o controle do fluxo de massa nas cadeiras do laminador, é necessário manter constantes as tensões nos vãos. Visando esse objetivo, o sistema atua sobre as cápsulas hidráulicas dos parafusos das cadeiras 1, 2 e 3. Não há atuação sobre a cápsula hidráulica do parafuso da Cadeira 4 porque, na planta em questão, a força de laminação nessa cadeira é mantida constante, para garantir a homogeneidade do acabamento superficial da tira.

O controle de tensão é dividido em duas funções: controle de tensão normal (NTC – *Normal Tension Control*) e controle de tensão de segurança (STC – *Safety Tension Control*).

1.5.3.1 Controle de Tensão Normal

Esta função atua sobre as cápsulas hidráulicas dos parafusos das cadeiras 2, 3 e 4 e se mantém ativa enquanto a força de laminação da cadeira posterior ao vão se mantiver entre os valores máximo e mínimo permitidos. A informação vinda dos tensiômetros localizados nos vãos é processada por um controlador proporcional-integral, que calcula a correção a ser enviada às cápsulas hidráulicas.

Se a tensão num determinado vão for superior ao valor de referência, o NTC causa um aumento na força (ou seja, uma redução na abertura) da cadeira posterior ao vão, o que leva a uma redução na tensão. Para valores de tensão inferiores ao de referência, o NTC reduz a

força na cadeira posterior ao vão. Caso a força de laminação tenda a se localizar fora da janela permitida, a função atua no sentido de mantê-la dentro dos limites, sendo o controle de tensão assumido pelo STC.

1.5.3.2 Controle de Tensão de Segurança

Tem por função manter a tensão nos vãos dentro dos limites seguros. Atua sobre a relação de velocidades dos motores das cadeiras anterior e posterior ao vão. Caso a tensão num determinado vão ultrapasse o valor máximo, o STC provoca um aumento na velocidade na cadeira anterior e uma diminuição na velocidade da cadeira posterior. No caso de uma tensão inferior ao valor mínimo, ocorre o oposto.

1.6 Caracterização do Problema

Para que os requisitos de qualidade sejam plenamente atingidos e o equipamento seja operado dentro da máxima produtividade, é essencial que as referências (*presets*) sejam corretamente calculadas; em outras palavras, é necessário que o modelo responsável pelo cálculo dessas referências seja acurado. A Figura 1-7 mostra um gráfico de espessura típico de uma tira produzida na planta estudada, ou seja, uma tira em cujo processamento o Nível 1 utilizou referências corretamente calculadas pelo Nível 2. A linha verde representa o desvio percentual da espessura em relação à objetivada, as linhas vermelhas representam os limites aceitáveis para tal desvio e a linha azul representa a velocidade de laminação.

Figura 1-7 – Desempenho típico do controle de espessura

Como se pode observar, a espessura real se afasta da objetivada apenas nas extremidades da tira (nas quais o AGC está fora das condições de regime) e nas regiões nas vizinhanças das soldas, visto que uma tira laminada a frio é composta por duas ou três tiras anteriormente laminadas a quente (as soldas são feitas na planta anterior, a decapagem). Para fins de comparação, a Figura 1-8 mostra o gráfico relativo a uma tira processada com referências inadequadas.

Figura 1-8 – Desempenho do controle de espessura no caso de referências inadequadas

Conforme mostra a figura, as referências erroneamente calculadas praticamente inviabilizaram a operação do controle em tempo real, resultando numa tira fora dos requisitos de qualidade. Uma vez que não é possível reprocessar o material no LTF (o que, por si só, representaria uma perda por retrabalho), e que o processo posterior de laminação (executado no Laminador de Encruamento) é capaz de realizar apenas pequenas variações na espessura do material, o sucateamento da tira é virtualmente inevitável.

Ainda que o erro no cálculo das referências não seja de magnitude suficiente para causar problemas de qualidade, pode influir também sobre a produtividade da planta. A Tabela 1-1 mostra as principais características do laminador estudado, com destaque para as relativas aos motores responsáveis pelo acionamento dos cilindros de trabalho.

Capacidade nominal (Ton/ano)		1.260.000			
Velocidade máxima (m/min)		1.080			
Máxima espessura de entrada (mm)		4,75			
Mínima espessura de entrada (mm)		2,00			
Máxima espessura de saída (mm)		3,00			
Mínima espessura de saída (mm)		0,38			
Máxima largura da tira (mm)		1.575			
Mínima largura da tira (mm)		650			
Motores principais	Cadeira	1	2	3	4
	Potência (KW)	2 × 1.800	2 × 1.800	2 × 1.800	2 × 1.482
	Rotação (rpm)	433 a 1.046	433 a 1.046	433 a 1.046	433 a 1.046
	Tensão (V)	900	900	900	700

Tabela 1-1 – Características principais do laminador estudado

Entre as referências calculadas pelo modelo se encontra a potência desenvolvida em cada cadeira, que obviamente deve respeitar os limites dos seus motores. Quando o modelo verifica que a potência exigida numa determinada cadeira é superior à permitida, sua estratégia consiste em reduzir a velocidade naquela cadeira de modo a garantir o respeito aos limites.

Se, no entanto, a potência em excesso não é real, mas resultante de um erro de cálculo, a redução de velocidade (de fato, desnecessária) significa uma perda de produtividade. Pode ocorrer o erro oposto (cálculo de uma potência inferior à realmente exigida), o que acarreta o cálculo de uma velocidade superior à permitida. Nesse caso, os controladores de Nível 1 garantem os limites seguros de operação.

A principal causa de erros no cálculo das referências é a presença dos chamados *parâmetros incertos*, que são aqueles cujos valores não podem ser diretamente medidos e cuja modelagem apresenta significativa complexidade. O objetivo do emprego de técnicas adaptativas na modelagem matemática do processo é lidar da melhor maneira possível com tais variáveis. Dentre os diversos parâmetros incertos presentes no processo de laminação, os mais importantes são o limite de escoamento do material e o coeficiente de atrito entre a tira e os cilindros de trabalho. Essa tese focaliza sua atenção nessas duas grandezas.

1.7 Sumário Estruturado da Tese

O Capítulo 1 fornece uma visão geral do problema tratado, da motivação para este trabalho e dos resultados esperados com a sua implantação, além introduzir a terminologia específica da área de conhecimento abordada. O capítulo apresenta os fundamentos do processo de laminação a frio de aços planos, descreve genericamente a arquitetura de automação utilizada no controle desse processo e faz uma descrição particularizada para a planta em que foi desenvolvida a pesquisa. Em seguida, procura caracterizar o problema, mostrando suas causas e conseqüências.

O Capítulo 2 apresenta uma revisão bibliográfica sobre os modelos matemáticos utilizados pelos processos siderúrgicos de laminação, com ênfase naqueles específicos para o processamento a frio. O foco principal do capítulo dirige às técnicas empregadas para a adaptação dos parâmetros dos modelos matemáticos descritivos dos processos industriais em geral, e da laminação a frio em particular, ressaltando-se aqueles efetivamente utilizados na planta que é objeto do presente estudo. O capítulo identifica as variáveis de processo mais adequadas à abordagem por meio de técnicas de Inteligência Computacional, focalizando de maneira mais profunda a revisão bibliográfica sobre essas variáveis em particular. O capítulo conclui apresentando de forma sucinta as características do modelo CORUM®, utilizado no Laminador de Tiras a Frio estudado.

O Capítulo 3 introduz o tema da Inteligência Computacional, examinando os principais conceitos e paradigmas relacionados. Delimitando o escopo do trabalho, o destaque principal do capítulo recai sobre as Redes Neurais Artificiais, a Lógica Difusa e os Algoritmos Genéticos, que são as técnicas cuja utilização conjunta foi investigada no decorrer da pesquisa. O capítulo apresenta as justificativas para a preferência pela utilização dessas técnicas, através de uma revisão bibliográfica de relatos de seu uso em aplicações semelhantes àquela que o presente trabalho aborda.

O Capítulo 4 trata da metodologia utilizada no desenvolvimento da solução proposta, começando por uma análise de possíveis soluções para o problema tratado e justificando a opção pela abordagem escolhida (redes neurais artificiais). Isto feito, o capítulo apresenta o procedimento adotado para a solução do problema, descrevendo a seguir o desenvolvimento do sistema propriamente dito, incluindo: a coleta e pré-processamento dos dados, o treinamento das redes e sua validação. Segue-se a análise comparativa de desempenho que

permitiu a escolha, dentre as diversas arquiteturas testadas, daquela que integraria a solução final.

O Capítulo 5 descreve o método de avaliação do sistema proposto, apresenta os resultados obtidos a partir do mesmo, quantificando a diferença entre o desempenho original do modelo de otimização da planta e o desempenho potencial com a implantação do sistema. O capítulo delinea também a estratégia para a futura incorporação da nova estratégia de adaptação à estrutura de automação e controle da planta, proposta com base no resultado do estudo comparativo.

Finalmente, o Capítulo 6 apresenta as conclusões obtidas como fruto da realização do trabalho, ressalta as contribuições que a presente pesquisa oferece ao estado da arte da adaptação de modelos de laminação e avalia os pontos fortes e fracos do sistema proposto, sugerindo futuras linhas de pesquisa que possam aperfeiçoar seus resultados.

Ressalva-se que o texto foi redigido segundo a norma ortográfica brasileira anterior ao Novo Acordo Ortográfico da Língua Portuguesa, vigente a partir de janeiro de 2009. O próprio decreto que instituiu o acordo prevê que a norma antecedente será aceita até dezembro de 2012. Nesse particular o autor está em boa companhia, visto que Pasquale Cipro Neto, preeminente professor de Língua Portuguesa, afirma:

Vou continuar usando a antiga ortografia até o último minuto do dia 31/12/2012, a menos que, por imposição de algum jornal em que colabore, seja obrigado a usar a nova. Mas nos meus escritos particulares e nos meus blogs, esta é a linha que seguirei (SILVA, 2009).

Capítulo 2 – A MODELAGEM MATEMÁTICA DO PROCESSO SIDERÚRGICO DE LAMINAÇÃO PLANA E SUA ADAPTAÇÃO

Conforme exposto no capítulo anterior, a diferença entre o tempo requerido para o cômputo das equações que modelam o processo de laminação e o tempo de resposta do controle dinâmico desse processo impõe uma dicotomia entre essas duas funções, que devem necessariamente ser executadas em fases diferentes da estratégia de controle. Desse modo, os modelos matemáticos têm como função o cálculo antecipado (anterior ao processamento) das melhores referências para que o controle dinâmico (durante o processamento) atinja os seus objetivos em conformidade com os requisitos de qualidade e produtividade. Este capítulo enfoca o desenvolvimento dos modelos matemáticos que descrevem o processo siderúrgico de laminação, com ênfase no processamento a frio. Em conformidade com o objetivo do presente trabalho, o capítulo explora os métodos utilizados para conferir características adaptativas a esses modelos.

Atack e Robinson (1996) enfatizam o fato de que a modelagem é um processo de três estágios. Segundo esses pesquisadores, além da formulação do modelo representativo dos aspectos físicos do processo, a estimativa dos parâmetros desconhecidos e sua validação em confronto com os dados medidos não devem ser negligenciadas. Esses dois últimos estágios justificam a necessidade de adaptação dos parâmetros do modelo.

Numa tira de aço plano laminada a frio, a principal característica de qualidade é a espessura uniforme ao longo do material, ou seja, a variação longitudinal de espessura deve ser a menor possível. Logo, a principal tarefa do sistema de controle é atingir esse objetivo. Outros requisitos importantes são a planicidade ou perfil transversal da tira e o acabamento superficial. Para aumentar a produtividade, a velocidade de laminação deve ser a maior possível, as bobinas de entrada devem ser tão longas quanto possível (reduzindo assim as operações de encaixe e desencaixe), e a tensão a que se submete o material processado deve ser mantida em limites que evitem a ruptura do material e as conseqüentes interrupções e perdas na produção.

Quando o laminador é do tipo *tandem* (como o estudado neste trabalho), a redução na espessura do material de h_o (na entrada da primeira cadeira do laminador) para h_n (na saída da enésima cadeira) deve ser distribuída ao longo do total de cadeiras. Dentre as diversas possibilidades para tal distribuição, cabe ao sistema de otimização obter aquela que maximize

os resultados, respeitando as restrições mecânicas e elétricas, tanto do equipamento quanto do material processado. O problema, portanto, é caracterizado por vários graus de liberdade, de forma que, ao invés de uma solução única, ele admite um conjunto de soluções aceitáveis, dentre as quais se procura obter a solução ótima.

2.1 Principais Categorias de Modelos Para a Laminação Plana

Dado que a obtenção de soluções analíticas exatas para equações que descrevam todos os aspectos envolvidos no processo de laminação é virtualmente impossível, cabe aos pesquisadores introduzir simplificações que, ao mesmo tempo em que tornem factível o cômputo das grandezas necessárias, conduzam a resultados compatíveis com a realidade e que permitam uma produção economicamente competitiva.

Lenard (1987) afirma que o sucesso de um modelo matemático é medido pela sua capacidade preditiva, que é estabelecida pela comparação entre um grande número de medições de variáveis experimentais e os resultados dos cálculos do modelo para essas mesmas variáveis. A média das diferenças percentuais entre esses conjuntos de valores (medido e calculado) dá uma idéia da acurácia do modelo e o desvio padrão dessas diferenças indica a consistência (precisão) do modelo. A precisão é de maior importância do que a acurácia, que sempre pode ser corrigida por meio de parâmetros de sintonia. Roberts (1978), por sua vez, ressalta que um modelo, para ser válido, deve ser capaz de elucidar as diversas observações coletadas durante o processo de seu desenvolvimento; não apenas as mais óbvias (como o aumento da força de laminação com o grau de redução), mas também as mais sutis (como a variação da força com a velocidade de laminação).

Na opinião de Reeve, MacAlister e Bilkhu (1999), existem três aspectos principais a afetar a precisão de um modelo matemático para o processo de laminação: as hipóteses simplificadoras feitas para viabilizá-lo, a precisão com que são conhecidas as propriedades do material e a precisão com que são conhecidas as condições de contorno do processo. Obter melhor desempenho ou capacidade preditiva de um modelo requer avanços em um desses três aspectos.

Os modelos utilizados para a otimização do processo de laminação se dividem em categorias. Lenard (2007) os classifica como:

- Modelos empíricos, usados primordialmente para proporcionar uma estimativa simples, rápida e razoavelmente acurada da força de laminação;
- Modelos fenomenológicos unidimensionais, nos quais se considera a coordenada na direção de laminação como a única variável independente;
- Modelos fenomenológicos que utilizam o Teorema do Limite Superior (*“Upper Bound Theorem”*), que permitem uma estimativa conservadora da potência necessária para a laminação;
- Modelos baseados em técnicas de Inteligência Artificial, principalmente Redes Neurais Artificiais.

A essa lista, Shivpuri e Chou (1989) e Reddy e Suryanarayana (2001) acrescentam os modelos baseados no Método dos Elementos Finitos, que, embora sejam potencialmente mais precisos, obtêm seus resultados, no dizer de Reeve, MacAlister e Bilkhu (1999), à custa de descrições muito mais complexas das propriedades do material e das condições de contorno. Obviamente, existem vários exemplos de modelos em cada uma das categorias acima listadas.

Além da divisão em categorias com base nos princípios físicos ou matemáticos utilizados para a sua concepção, os modelos descritivos do processo de laminação podem ser classificados, conforme o seu modo de utilização, em modelos *off-line* e modelos *on-line*. Os modelos *off-line*, que são executados sem maiores restrições de tempo, têm como principal fator de qualidade a precisão. Tais modelos prestam-se a diversas funções, entre as quais se encontram as destacadas por Hodgson, McFarlane e Gibbs (1993):

- Reduzir a necessidade de testes na planta durante o desenvolvimento de novos produtos ou processos;
- Estimar o impacto de diferentes configurações da planta ou de novo hardware;
- Predizer o valor de variáveis que não podem ser facilmente medidas;
- Realizar análise de sensibilidade para determinar que variáveis devem ser medidas ou controladas para que se obtenham as propriedades finais e a qualidade requeridas;
- Auxiliar no projeto do hardware;
- Aprofundar a compreensão do processo.

Os modelos *on-line* são efetivamente utilizados na operação de plantas industriais, tanto na otimização do processo (cálculo de *setups*) como no controle em tempo real. Como

atesta Yuen (2003), é primordial que tais modelos, ainda que em prejuízo da acurácia, sejam caracterizados pela consistência e por uma formulação matemática eficiente, que permita que seus cálculos sejam realizados no exíguo tempo disponível. Além disso, os modelos *on-line* devem ser passíveis de inversão, para que sua adaptação possa ser eficientemente executada.

Uma terceira classificação dos modelos para laminação é dada por Yuen (2003), que os divide de acordo com o fenômeno que eles se destinam a representar. Segundo essa classificação, existem modelos para a deformação da tira na região entre os cilindros de trabalho, modelos para o coroamento térmico dos cilindros, para o perfil transversal da tira, para a lubrificação, etc. A otimização do processo, em geral, compreende a utilização híbrida de vários desses modelos, sendo o modelo de deformação ou de força o elemento-chave.

2.2 Um Modelo Unidimensional Básico

O modelo estudado nesta tese é do tipo híbrido, unidimensional e usado *on-line* para a otimização (cálculo de *presets*) de um laminador tandem a frio. O núcleo desse modelo trata da deformação da tira entre os cilindros de laminação. Como tal, pode-se considerar que ele se situa na transição entre os modelos *off-line* e os modelos *on-line* usados no controle em tempo real. Apesar do crescimento do poder de processamento dos computadores e dos progressos no desenvolvimento de modelos mais sofisticados, como os baseados no Método dos Elementos Finitos, a realidade expressa em trabalhos como os de Schipper *et al.* (1998), Yuen (2003) e Lenard (2007) continua válida até a presente data: a maior parte dos modelos industrialmente utilizados para essa aplicação é do tipo unidimensional, que proporcionam um compromisso adequado entre nível de precisão e tempo de computação.

Apenas para fins de comparação (levando-se em conta a época de publicação do trabalho), Lenard, Malinowski e Pietrzyk (1992) confrontaram o desempenho de um modelo unidimensional com os de dois modelos baseados em elementos finitos. Como esperado, os dois últimos apresentaram maior precisão e foram capazes de calcular um maior número de variáveis. Em contrapartida, os pesquisadores constataram tempos de processamento de 15 minutos para um dos modelos de elementos finitos e de 200 minutos para o outro, demonstrando que eles não poderiam ser utilizados *on-line*. Reforçando essa idéia, Freshwater (1996) faz referência a um modelo elastoplástico de elementos finitos, desenvolvido por Gratacos *et al.* (1991), que demandava entre 4 e 5 horas de processamento.

Dentre as diversas variações de modelos unidimensionais para o processo de laminação plana, encontra-se o chamado método dos blocos (*slab method*), idealizado no início do século XX por von Karman (1925 *apud* SHIVPURI; CHOU, 1989) e aperfeiçoado ao longo do tempo, com diferentes hipóteses simplificadoras, por pesquisadores como Orowan (1943 *apud* SHIVPURI; CHOU, 1989), Ford, Ellis e Bland (1951) e Alexander (1972), entre outros. Visto que o laminador estudado neste trabalho utiliza um modelo dessa categoria, apresentam-se a seguir os seus princípios básicos e equações.

2.2.1 Premissas e Equações de um Modelo de Deformação

Segundo Yuen (2003), para que se obtenham produtos de alta qualidade, com a espessura objetivada e boa planicidade, é essencial uma estimativa precisa da força de laminação. Prover tal estimativa é um dos principais objetivos dos modelos de deformação. Além disso, através desses modelos obtêm-se também o torque necessário, as tensões mecânicas a que a tira fica submetida nos vãos entre as cadeiras, o escorregamento e outros importantes parâmetros do processo.

Para ilustrar as características de tais modelos, descrevem-se a seguir as linhas-mestras do que foi apresentado nos trabalhos de Ford, Ellis e Bland (1951), Ford e Ellis (1952) e Bland e Ford (1952). As premissas básicas desse modelo são:

- A deformação da tira é plana, ou seja, seu alargamento é desprezível;
- O coeficiente de atrito é constante no arco de contato entre os cilindros e a tira;
- A tira obedece ao critério de plasticidade de von Mises (1913, *apud* BOLON, 1996), que descreve o comportamento de materiais isotrópicos sob pressão;
- Os cilindros de trabalho, ainda que deformados pelos esforços de compressão, permanecem com formato circular, com raio modificado de acordo com a

VON KARMAN, T. Beitrag zur Theorie des Walzvorganges. **Zeitschrift für Angewandte, Mathematik und Mechanik**, v. 5, p. 139-141, 1925.

OROWAN, E. The Calculation of Roll Pressure in Hot and Cold Rolling. **Proceedings of the Institute of Mechanical Engineers**, v. 150, n. 4, p. 140-167, 1943.

VON MISES, R. Mechanik der festen korper im plastich deformablen zustand. **Nachr. Ges. Wiss. Gottingen**, p. 582– 592, 1913.

fórmula proposta por Hitchcock (1935, *apud* BOLON, 1996);

- A deformação é homogênea em cada fatia em que se divide o arco de contato.

A tira sofre dois tipos de deformação no arco de contato: a deformação plástica (permanente) e a deformação elástica (transitória). A região de deformação plástica é dividida em zona de entrada e zona de saída. De modo análogo, a região de deformação elástica é composta por uma região de entrada e uma região de saída. A Figura 2-1 mostra a geometria do arco de contato e algumas das variáveis envolvidas.

Figura 2-1- Geometria do arco de contato numa cadeia de laminação

Na figura, a abscissa zero corresponde ao ponto neutro. Depreende-se facilmente que:

$$\mathbf{x} = \mathbf{R}_{def} \times \text{sen}\theta \text{ (Equação 2-1).}$$

Supondo-se $\theta \cong 0$, obtém-se:

$$\mathbf{x} = \mathbf{R}_{def} \times \theta \text{ (Equação 2-2).}$$

Derivando-se a Equação 2-2:

$$d\mathbf{x} = \mathbf{R}_{def} \times d\theta \text{ (Equação 2-3).}$$

Outra equação obtida através das relações geométricas é:

$$\mathbf{h}(\mathbf{x}) = \mathbf{e}_{min} + \mathbf{x} \bullet \text{tg}\theta \cong \mathbf{e}_{min} + \mathbf{x} \bullet \theta \text{ (Equação 2-4).}$$

A partir das equações 2-2 e 2-4, chega-se a:

$$\mathbf{h}(\mathbf{x}) = \mathbf{e}_{min} + \frac{\mathbf{x}^2}{\mathbf{R}_{def}} \text{ (Equação 2-5).}$$

Observando que, na origem, $\mathbf{h}(0) = \mathbf{e}_{min}$ e que $\mathbf{h}(\mathbf{x}_{ent}) = \mathbf{e}_{in}$, então:

$$\mathbf{x}_{ent} = \sqrt{\mathbf{R}_{def} \times (\mathbf{e}_{in} - \mathbf{e}_{min})} \text{ (Equação 2-6).}$$

O raio do cilindro deformado sob o esforço de compressão é calculado pela fórmula proposta por Hitchcock (1935):

$$\mathbf{R}_{def} = \mathbf{R}_o \times \left(1 + \frac{\mathbf{K}_1 \times \mathbf{P}}{\left(\sqrt{\mathbf{e}_{in} - \mathbf{e}_o + \mathbf{K}_2 + \mathbf{K}_3} + \sqrt{\mathbf{K}_2} \right)^2} \right) \text{ (Equação 2-7).}$$

Na equação acima, as constantes **K1**, **K2** e **K3** foram introduzidas para simplificar a notação. Elas equivalem a:

$$\mathbf{K}_1 = 16 \times \frac{1 - \mathbf{N}_u^2}{\pi \times \mathbf{E}}, \mathbf{K}_2 = \frac{\left[(\mathbf{e}_o \times \sigma_o) - \mathbf{T}_o \right] \times (1 - \mathbf{N}_u^2)}{\mathbf{E}} \text{ e } \mathbf{K}_3 = \frac{(\mathbf{T}_o - \mathbf{T}_{in}) \times (1 + \mathbf{N}_u) \times \mathbf{N}_u}{\mathbf{E}}.$$

As variáveis envolvidas nessas equações são:

- **P** → Tensão de laminação, em Ton/mm.
- **Ro** → Raio original (sem deformação) dos cilindros de trabalho, em mm.
- **Nu** → Coeficiente de Poisson, adimensional.

- $E \rightarrow$ Módulo de Young, em Ton/mm².
- $T_{in} \rightarrow$ Tensão longitudinal de entrada, em Ton/mm (tensão à ré).
- $T_o \rightarrow$ Tensão longitudinal de saída, em Ton/mm (tensão avante).
- $\sigma_o \rightarrow$ Limite de escoamento do material na saída da cadeira, em Ton/mm².

O valor da força na zona de compressão elástica de entrada é dado por:

$$F_{ZEE} = \sqrt{\frac{R_{def}}{e_{in} - e_o}} \times \frac{(1 - N_u^2) \times e_{in}}{4 \times E} \times \left(\sigma_{in} - \frac{T_{in}}{e_{in}} \right)^2 \times W \quad (\text{Equação 2-8}).$$

O valor da força na zona de recuperação plástica de saída é dado por:

$$F_{ZPS} = \frac{2}{3} \times \left(\frac{R_{def} \times (1 - N_u^2) \times e_o}{E} \right)^{\frac{1}{2}} \times \left(\sigma_o - \frac{T_o}{e_o} \right)^{\frac{3}{2}} \times W \quad (\text{Equação 2-9}).$$

As grandezas introduzidas nas equações acima são:

- $\sigma_{in} \rightarrow$ Limite de escoamento do material na entrada da cadeira, em Ton / mm².
- $W \rightarrow$ Largura da tira, em mm.

A espessura da tira no ponto final do arco de contato, exatamente antes da zona de recuperação elástica de saída, vale:

$$e_{min} = e_o \times \left[1 - \frac{1 - N_u^2}{E} \times \left(\sigma_o - \frac{T_o}{e_o} \right) \right] \quad (\text{Equação 2-10}).$$

A Figura 2-2 permite determinar o equilíbrio de forças no arco de contato, numa fatia elementar da tira.

Figura 2-2 - Diagrama para determinação do modelo de força

O equilíbrio de forças na direção horizontal para a fatia é dado por:

$$h(x+dx) \times \sigma_{x+dx} - h(x) \times \sigma_x + 2 \times f \times (\theta \pm \mu) dx = 0 \quad (\text{Equação 2-11}).$$

O sinal no interior dos parênteses da última parcela do lado esquerdo da equação será positivo na saída da cadeira e negativo na entrada. μ é o coeficiente de atrito e f é a pressão normal. Dividindo a equação por dx :

$$\frac{d(h\sigma_x)}{dx} + 2f \times (\phi \pm \mu) = 0 \quad (\text{Equação 2-12}).$$

Na direção vertical:

$$\sigma_y dx = (-f \cos \phi \pm \mu f \sin \phi) dx \quad (\text{Equação 2-13}).$$

Assumindo que $\phi \cong 0$, essa equação equivale a: $\sigma_y = -f$.

Lembrando que a tira é comprimida na direção vertical ($\sigma_y < 0$) e tensionada na direção horizontal ($\sigma_x > 0$), que $|\sigma_x - \sigma_y| = \sigma_p$ (segundo o critério de plasticidade de von Mises), que a expressão principal de esforço é $\sigma_x = \frac{T_x}{h(x)}$, e usando as equações 2-2 e 2-5, chega-se ao sistema de equações diferenciais:

$$\begin{cases} \mathbf{f}(\mathbf{x}) = \sigma_p - \frac{\mathbf{T}_x}{\mathbf{h}(\mathbf{x})} \\ \frac{d\mathbf{f}}{d\mathbf{x}} = \frac{d\sigma_p}{d\mathbf{x}} + \frac{2}{\mathbf{h}} \times \left(\frac{\mathbf{x} \times \sigma_p}{\mathbf{R}_{def}} \pm \mu \times \mathbf{f} \right) \end{cases} \quad (\text{Equação 2-14}).$$

Resumindo, constata-se que o raio deformado dos cilindros depende da força aplicada e que, por outro lado, o valor da força depende do raio deformado. Dessa forma, os valores dessas duas grandezas podem ser determinados concorrentemente através de um processo iterativo. Essa é a técnica utilizada pelo modelo.

2.3 Adaptação do Modelo Matemático

Através do modelo de força e dos demais modelos embutidos na estratégia de otimização do laminador, são calculadas as diversas referências de que o sistema de controle em tempo real necessita para comandar o processamento do material em conformidade com os requisitos de qualidade, maximizando a qualidade e respeitando os limites do equipamento.

Na visão de Quinn e Vaculik (2002), a adaptação é uma característica de importância crítica para um modelo matemático industrial, porque ela assegura que seu desempenho seja adequado e consistente ao longo do período de utilização desse modelo, além de reduzir os requisitos de manutenção do sistema.

Reeve, MacAlister e Bilkhu (1999) afirmam que, sem a adaptação, não seria possível que os laminadores atingissem o elevado desempenho que os caracteriza. A adaptação se faz necessária, em primeiro lugar, porque mesmo na improvável hipótese de se desenvolver um modelo fenomenológico capaz de refletir perfeitamente o processo de laminação, tal modelo seria de aplicação prática inexecutável, devido aos recursos computacionais necessários. Além disso, as propriedades do material processado não são totalmente conhecidas e as medições fornecidas pelos sensores, além de não serem completas (nem todas as variáveis requeridas pelo modelo são medidas – algumas são inferidas), estão sujeitas a erros de várias categorias (ruídos, calibração, fundo de escala, etc.). Faz-se necessário, portanto, um ajuste coerente dos parâmetros do modelo, que leve em conta os resultados efetivamente obtidos durante o processamento do material. Essa estratégia de adaptação é dividida em quatro estágios distintos: aquisição de dados, identificação dos parâmetros do produto, identificação dos parâmetros do processo e atuação sobre o modelo.

Atack e Robinson (1996) descrevem o mecanismo de adaptação utilizado num laminador reversível composto por uma única cadeira, que, *mutatis mutandis*, é análogo ao utilizado num laminador *tandem* a frio. Em geral, a adaptação é dividida em duas categorias. A adaptação de curto prazo é usada para modificar as referências utilizadas pelo sistema de controle para o próprio material em processamento na planta, ou para a próxima ocorrência de um material similar (o que é mais comum na laminação a frio, dada a velocidade em que o processo é executado). De acordo com Bolon (1996), a função da adaptação de curto prazo é lidar com os fenômenos envolvidos no processo e que não são abarcados pelas hipóteses simplificadoras adotadas na modelagem. Na adaptação de longo prazo, os valores medidos durante o processamento de um lote considerável de material (uma semana ou um mês de produção, por exemplo) são utilizados para captar as tendências de longo prazo, tanto da planta quanto do material, e a elas amoldar o modelo.

Conquanto algumas das variáveis de processo relevantes para a acurácia do modelo de otimização sejam efetivamente medidas, e outras sejam inferidas, com razoável grau de precisão, por meio de modelos físicos bem estabelecidos, há também aquelas cujos valores são obtidos por meio de equações semi-empíricas e só podem ser determinados com precisão *a posteriori*, por meio de ensaios laboratoriais que, como bem observam Byon, Kim e Lee (2008), são realizados em condições totalmente diversas das existentes durante a operação da planta. Esse é mais um fato que torna essencial a adaptação dos parâmetros do modelo.

Dentre as variáveis cujos valores devem ser adaptados para o bom desempenho do modelo de otimização de um laminador, destacam-se o limite de escoamento do material e o coeficiente de atrito entre os cilindros de trabalho e a tira laminada. A importância dessas variáveis é destacada em diversos trabalhos, entre os quais os de Yuen, Popeliansk e Prouten (1996), Tieu *et al.* (2005), Zhao *et al.* (2005), Pires (2007) e de Byon, Kim e Lee (2008). Tanto o limite de escoamento quanto o coeficiente de atrito são utilizados no mais importante dos modelos requeridos para a otimização do processo, que é o modelo de força, apresentado sucintamente no Capítulo 1. No modelo CORUM®, utilizado na automação do laminador, essas variáveis estão incluídas tanto na adaptação de curto prazo quanto na de longo prazo.

Uma contribuição adicional à complexidade da modelagem do limite de escoamento e do coeficiente de atrito é a dependência mútua que essas variáveis mantêm entre si. O valor da força de laminação depende de ambas, as quais, por sua vez, são também afetadas pelo valor da força.

Visto como os valores dessas variáveis não podem ser efetivamente medidos, os modelos matemáticos geralmente os estimam por meio de cálculos inversos, baseados nos valores de grandezas mensuráveis durante o processamento do material. Byon, Kim e Lee (2008) descrevem pormenorizadamente uma estratégia de modelagem inversa empregada com bons resultados num laminador a frio quádruplo e reversível.

2.3.1 Fatores de Influência sobre o Limite de Escoamento do Material

Ao serem submetidos a esforços de tensão ou compressão, os metais apresentam dois tipos de deformação: a elástica e a plástica. A deformação é dita elástica quando é reversível, ou seja, desaparece quando o esforço que a originou é removido. Na região elástica, a deformação é regida pela chamada lei uniaxial de Hooke, segundo a qual:

$$\sigma = E \times e \quad (\text{Equação 2-15}).$$

Na equação acima, σ representa a tensão a que o metal está submetido (força dividida pela área sobre a qual ela é aplicada), E representa o módulo de elasticidade (ou módulo de Young), que é uma medida da rigidez do material, e e representa a deformação experimentada pelo metal, que é a razão entre a variação de comprimento Δl e o comprimento original l_0 , ou seja:

$$e = \frac{\Delta l}{l_0} \quad (\text{Equação 2-16}).$$

A deformação calculada conforme a equação acima é conhecida como *deformação convencional*. Como observam Helman e Cetlin (1993), ao se considerar a natureza tridimensional do material deformado, esse parâmetro não representa fielmente o processo de deformação. A razão é que a deformação convencional está ligada ao comprimento original da barra sob tensão. Supondo-se que seja aplicada uma nova tensão a uma barra já deformada, sua deformação total seria dada por:

$$\frac{\Delta l}{l_0} + \frac{\Delta l'}{l_0 + \Delta l} \quad (\text{Equação 2-17}).$$

Estendendo-se o raciocínio, o alongamento pode ser enxergado como uma soma de incrementos infinitesimais no comprimento l da barra, que, sob a tensão aplicada, passa de l_0 para l_f . Dessa forma, define-se a chamada *deformação verdadeira* ϵ :

$$\varepsilon = \int_{l_0}^{l_f} \frac{dl}{l} = \ln \frac{l_f}{l_0} \quad (\text{Equação 2-18}).$$

Combinando-se as equações 2.16 e 2.18, obtém-se a relação entre as deformações verdadeira e convencional:

$$\varepsilon = \ln (1 + e) \quad (\text{Equação 2-19}).$$

No estudo do processo de laminação de metais, utiliza-se a deformação verdadeira, que apresenta sobre a convencional a vantagem de permitir obter a deformação total por meio da soma das deformações parciais sofridas pelo corpo, o que não é possível quando se usa o conceito de deformação convencional. É bastante comum que a deformação verdadeira seja expressa na forma de porcentagem.

Caso se aumente o esforço aplicado ao metal, a deformação passa a ser permanente – é o que se chama de *deformação plástica*. Define-se o limite de escoamento do metal como o valor de tensão que marca a transição do regime elástico para o regime plástico. Para alguns metais, entre os quais os aços-carbono, essa transição ocorre de forma abrupta, sendo muito bem definida, conforme a Figura 2-3, que mostra um gráfico típico do comportamento de um corpo de prova de aço-carbono submetido a um ensaio de tração. O limite de escoamento é claramente determinado pelo início do comportamento não-linear da tensão.

Figura 2-3 – Comportamento do aço-carbono sob ensaio de tração

Vários são os fatores que influenciam o limite de escoamento de um aço. Freshwater (1996) , abordando especificamente o processo de laminação a quente, apresenta o limite de escoamento como função da deformação, da taxa de deformação, da temperatura do processo e da microestrutura do material. Kirihata *et al.* (1998) apontam o tipo de recristalização experimentado (estática, dinâmica ou metadinâmica), a composição química e as condições de laminação (deformação e taxa de deformação) como os elementos mais relevantes. Roberts (1978) ressalta a importância da taxa de deformação (velocidade em que a deformação é realizada), especialmente na laminação a frio, processo em que a taxa de deformação tem ordem de grandeza entre 10 s^{-1} e 10^3 s^{-1} . Em tais condições, o limite de escoamento pode ter o dobro do valor observado em condições de teste em laboratório.

Ainda no que se refere à laminação a frio, Brezocnik, Balic e Kampus (2001) incluem a geometria da peça laminada (espessura inicial e final) e o coeficiente de atrito entre a peça e os cilindros como fatores importantes. Na prática da laminação a frio, existem diversas equações empíricas em que o limite de escoamento é obtido a partir da deformação verdadeira sofrida pelo material, por meio de uma função não-linear (polinomial, exponencial, logarítmica, etc.). Alguns exemplos de tais equações são:

$\sigma = \mathbf{A} \cdot \varepsilon^3 + \mathbf{B} \cdot \varepsilon^2 + \mathbf{C} \cdot \varepsilon + \mathbf{D}$ (Equação 2-20), utilizada por Machek (1987, *apud* DUROVSKÝ, ZBORAY E FERKOVÁ, 2008);

$\sigma = \mathbf{A} \cdot \left(\frac{1 + \varepsilon}{\mathbf{B}} \right)^{\mathbf{C}}$ (Equação 2-21), utilizada por Jiang *et al.* (2008);

$\sigma = \mathbf{A} \cdot \varepsilon^{\mathbf{B}}$ (Equação 2-22), utilizada por Li e Lagergren (2000);

$\sigma = \mathbf{A} \cdot (\ln \varepsilon)^{\mathbf{B}}$ (Equação 2-23), utilizada por Pawelski (2003).

Em cada uma dessas equações, as constantes são obtidas empiricamente a partir de resultados reais da planta.

Ginzburg (2004) descreve o relacionamento entre o limite de escoamento e a resistência à deformação do material, grandeza que por sua vez é um dos fatores determinantes da força de laminação e do torque necessários para o processamento da peça. De acordo com este pesquisador, o cálculo da resistência à deformação deve ser efetuado a partir do resultado obtido em testes de laboratório para o limite de escoamento. Dada a

diferença entre as condições de laminação e as condições de teste, melhores resultados são alcançados quando se utilizam laminadores em escala reduzida (laminadores-piloto) para se chegar ao valor do limite de escoamento.

2.3.2 Fatores de Influência Sobre o Coeficiente de Atrito no Arco de Contato

Embora as primeiras considerações sobre a força de atrito remontem ao décimo quinto século da Era Cristã, no *Codex Atlanticus* de Leonardo da Vinci, a primeira descrição matemática do fenômeno se deve a Coulomb (1781, apud OLIVEIRA, 2004). O modelo de Coulomb descrevia o atrito em termos do intertravamento e da deformação das asperezas de superfícies em contato. Ele concluiu que a força de atrito é proporcional à força normal atuante sobre as superfícies em contato, o que pode ser expresso por meio da equação:

$$\tau = \mu \times p \quad (\text{Equação 2-24}).$$

Na equação acima, τ é a força de atrito, μ é o chamado *coeficiente de atrito* e p é a força normal à direção do movimento relativo entre as superfícies. O coeficiente de atrito depende de fatores como a velocidade do movimento e mesmo a temperatura.

De acordo com Batchelor e Stachowiak (1995, apud LENARD, 2002), os três mais importantes mecanismos de interação entre duas superfícies, em ordem crescente de importância no que se refere à deformação de metais, são o arraste viscoso, a adesão e a sulcagem (“*ploughing*”). Jiang *et al.* (2008) declaram enfaticamente que “o atrito é a razão pela qual o processo de laminação efetivamente ocorre” e apontam sua influência sobre a mecânica da laminação, bem como sobre o perfil e a planicidade da tira laminada.

Durovský, Zboray e Ferková (2008) explicam a importância do atrito para o processo de laminação. Se ele for muito reduzido, a velocidade periférica dos cilindros de trabalho será maior que a velocidade da tira e haverá deslizamento entre as duas superfícies. Se, por outro lado, o atrito for excessivo, maior potência será requerida para o processamento do material e uma maior quantidade de calor será gerada.

O valor mínimo para o coeficiente de atrito para que um determinado grau de deformação seja possível pode ser calculado pela equação:

⁷COULOMB, C.A. *Théorie des Machines Simples*. Paris, 1781.

$$\mu_{\min} = \left(1 + \frac{T_{\text{in}} - (1 - \varepsilon) \times T_{\text{out}}}{\varepsilon \times \sigma} \right) \times \sqrt{\frac{h_o \times \varepsilon}{4 \times R_{\text{def}}}} \quad (\text{Equação 2-25}),$$

onde T_{in} é a tensão à ré, T_{out} é a tensão avante, h_o é a espessura de entrada e R_{def} é o raio deformado dos cilindros de trabalho.

Uma hipótese simplificadora usualmente empregada é de que o valor do coeficiente de atrito seja constante em todo o arco de contato entre os cilindros de trabalho e a tira laminada. Como o material flui ao sofrer deformação plástica no arco de contato, Tan *et al.* (2008) concluem que o problema deve ser modelado por uma aplicação conjunta dos princípios de mecânica dos sólidos e de mecânica dos fluidos. A partir de tal raciocínio, esses autores desenvolveram um modelo dinâmico de atrito.

Embora o coeficiente de atrito esteja ligado à microestrutura dos materiais, é possível avaliá-lo indiretamente por meio de elementos macroscópicos. No processo de laminação, os principais elementos que influenciam o coeficiente de atrito são, de acordo com Tieu *et al.* (2005), a rugosidade dos cilindros e da tira, as condições de lubrificação e a velocidade periférica dos cilindros. Yuen, Popeliansk e Prouten (1996) acrescentam a dureza e a temperatura, tanto dos cilindros como da tira. Zhao *et al.* (2005) apresentam também o diâmetro dos cilindros de trabalho, a largura da tira e as tensões avante e à ré como fatores relevantes. Li (1999) inclui a geometria da deformação.

A Figura 2-4 representa o mecanismo de atrito entre a tira e os cilindros de trabalho durante o processo de laminação.

Figura 2-4 – Atrito entre uma tira laminada e os cilindros de trabalho

Lenard (2002) argumenta que a medição direta do coeficiente de atrito durante a laminação não é possível, uma vez que se trata de uma razão entre duas forças. Assim, podem ser usados métodos experimentais em que as forças de cisalhamento e normal sejam medidas simultaneamente e a relação entre elas seja calculada.

Outra abordagem envolve uma análise inversa em que, de acordo com McConnel e Lenard (2000), o coeficiente de atrito é tratado como incógnita e calculado a partir de uma grandeza mensurável (geralmente a força de laminação). Seguem-se três exemplos de equações obtidas por meio de modelagem inversa do coeficiente de atrito, especificamente para o processo de laminação plana a frio. Essas equações são citadas por Lenard (2002):

$$\mu = \frac{\frac{P_r}{\sigma \times \sqrt{R_{\text{def}} \times \Delta h}} - 1,08 + 1,02 \times \left(1 - \frac{h_o}{h_{\text{in}}}\right)}{1,79 \times \left(1 - \frac{h_o}{h_{\text{in}}}\right) \times \sqrt{\frac{R_{\text{def}}}{h_{\text{in}}}}} \quad (\text{Equação 2-26}),$$

conhecida como *fórmula de Hill*;

$$\mu = 2 \times \sqrt{\frac{h_{\text{in}}}{R_{\text{def}} \times \epsilon}} \times \left[\frac{P_r \times (1 - \epsilon)}{\sigma - T_{\text{in}}} \times \sqrt{\frac{1}{R_{\text{def}} \times h_{\text{in}} \times \epsilon}} - 1 + \frac{5 \times \epsilon}{4} \right] \quad (\text{Equação 2-27}),$$

conhecida como *fórmula de Roberts*; e

$$\mu = \frac{\left(\frac{P_r}{\sigma \times \sqrt{R_{\text{def}} \times \Delta h}} - 1 \right) \times (h_{\text{in}} + h_o) + 1,2 \times \Delta h}{1,6 \times \sqrt{R_{\text{def}} \times \Delta h}} \quad (\text{Equação 2-28}),$$

conhecida como *fórmula de Ekelund*.

Nas fórmulas acima, P_r é o valor da força de laminação, h_{in} é a espessura de entrada da tira, Δh é a diferença entre as espessuras de entrada e de saída, T_{in} é a tensão à ré e R_{def} é o raio dos cilindros de trabalho, ao serem deformados pela força de laminação.

Os valores de coeficiente de atrito calculados por meio das três equações foram comparados para dois diferentes regimes de deformação, e constatou-se maior similaridade entre os resultados obtidos em condições de deformação elevada ($\epsilon = 45\%$) do que entre aqueles observados em condições de deformação mediana ($\epsilon = 15\%$).

2.3.3 Métodos Utilizados Para a Adaptação dos Parâmetros do Modelo

Nishino *et al.* (2000) expõem os princípios básicos da abordagem tradicional à questão da adaptação de um modelo (especificamente o modelo de força). Sendo P_{real} e P_{mod} , respectivamente, os valores real e calculado da força de laminação durante o k -ésimo passe de um determinado material, calcula-se um coeficiente de correção c_k , relativo a esse passe:

$$c_k = \frac{P_{\text{mod}}}{P_{\text{real}}} \quad (\text{Equação 2-29}).$$

O coeficiente c_k será usado para modificar o resultado obtido pelo modelo na próxima operação de um material com características similares. Assim, a próxima estimativa para o valor de força é multiplicada pelo coeficiente de predição obtido através da fórmula:

$$P_{\text{mod}}^{K+1} = c_K \times P_{\text{mod}}^K \quad (\text{Equação 2-30})$$

Esse procedimento reduz o erro no valor calculado de força à medida que aumenta a ocorrência de operações com um dado tipo de material.

Luinenburg, Onink e Ritman (1998), descrevem o algoritmo de adaptação usado num modelo de temperatura de bobinamento na laminação de tiras a quente. Nesse modelo, a otimização baseia-se numa função de aprendizagem β , que é uma combinação linear dos m parâmetros adaptativos:

$$\beta = \sum_{k=1}^m (\text{adap}_k \cdot x_k) \quad (\text{Equação 2-31}),$$

sendo adap_k os coeficientes de adaptação, determinados a partir da relação entre os valores calculados e os valores medidos, e x_k os fatores de influência. A otimização é obtida minimizando-se, por meio de um método de mínimos quadrados, a diferença entre os valores calculados c e a última adaptação:

$$\text{mín} \left\{ \frac{1}{m} \sum_{i=1}^m (c - \text{adap}^T \cdot x)^2 \mid \text{adap} \in \mathbb{R}^m \right\} \quad (\text{Equação 2-32}).$$

Atack e Robinson (1996) apontam como um problema das técnicas usuais de mínimos quadrados o fato de que nelas todos os parâmetros são tratados igualmente, não permitindo que se adote uma escala de importância. Ilustrando essa questão, os autores dão como

exemplo uma medida de temperatura que pode ser feita tanto através de um pirômetro de radiação quanto através de um termopar. Visto que o segundo tipo de medidor é muito mais confiável do que o primeiro, tal informação deveria ser incluída e levada em conta pelo algoritmo de adaptação. Além disso, eles argumentam que o algoritmo deveria ser recursivo. Por esses motivos, eles preconizam a utilização do Filtro de Kalman Estendido (KALMAN, 1960 – *apud* ATTACK E ROBINSON, 1996), uma técnica de identificação de sistemas que, além de ser recursiva, pode ser configurada para incluir todas as informações sobre medidas e as incertezas da modelagem. Os pesquisadores utilizaram essa técnica na adaptação dos modelos de força, torque e planicidade de um laminador plano de alumínio.

Outro método freqüentemente utilizado na adaptação de modelos matemáticos são os Mínimos Quadrados Parciais (PLS – *Partial Least Squares*). Quinn e Vaculick (2002), reportando o uso dessa técnica na modelagem da dessulfurização de aço líquido, consideram-na particularmente adequada para a construção de modelos de processos industriais, devido à sua capacidade de lidar com sistemas MIMO, com não-linearidades e com dados incompletos.

Bolon (1996) descreve o mecanismo de filtragem adaptativa utilizado no modelo CORUM[®], do laminador objeto do presente estudo. Dois vetores de 10 elementos são utilizados para cada uma das variáveis cujos valores são adaptados. Um dos vetores contém os valores dos coeficientes adaptativos propriamente ditos, enquanto o outro armazena os instantes em que tais informações são obtidas. Esses vetores são estruturas do tipo FIFO, onde a chegada de um novo valor acarreta o deslocamento dos valores existentes, com a eliminação do mais antigo, conforme ilustrado na Figura 2-5. A idéia subjacente é atribuir maior importância à informação mais recente. Assim, o valor do último coeficiente é obtido através de média ponderada considerando os valores anteriores:

$$\mathbf{A}_0 = \frac{\sum_{i=0}^9 (\mathbf{A}_i \times \mathbf{P}_i)}{\sum_{i=0}^9 \mathbf{P}_i} \quad (\text{Equação 2-33}),$$

onde os pesos $\mathbf{P}_i$ são calculados por meio da equação:

$$\mathbf{P}_i = \frac{1}{\mathbf{T}_0 - \mathbf{T}_i + 1} \quad (\text{Equação 2-34}).$$

Figura 2-5 – Estratégia de filtragem adaptativa do modelo CORUM®

Lacasse, Fromont e Sorin (1989) utilizam dois algoritmos adaptativos: um para a modelagem do arco de contato (modelos de força, torque e escorregamento) e outro para a cedagem (módulo de rigidez) das estruturas das cadeiras de um laminador. Nesses algoritmos, determinam-se três diferentes coeficientes de correção: de curto prazo, de longo prazo e de normalização. O primeiro é usado para ajustar o cálculo das referências para o próximo produto. O segundo é obtido através de uma média ponderada dos coeficientes de curto prazo obtidos para os produtos de uma determinada classe, e serve para levar em conta os diferentes resultados dos modelos diante de diferentes tipos de produto. Por fim, os coeficientes de normalização têm como objetivo melhorar o desempenho dos modelos no caso de produtos “inéditos”.

No desenvolvimento de um modelo adaptativo específico para a resistência à deformação (diretamente relacionada ao limite de escoamento), Wang *et al.* (2005) introduzem diferentes estratégias adaptativas para os regimes de baixa e alta velocidade de laminação, atribuindo maior peso às medições obtidas em velocidades mais elevadas.

2.3.3.1 Estratégia de Adaptação no Laminador

No caso específico do laminador em que os resultados deste trabalho são aplicados, a estratégia contempla as adaptações de curto e de longo prazo. A primeira categoria de adaptações inclui o coeficiente de atrito, o limite de escoamento do material, um coeficiente

para correção do cálculo de torque, um coeficiente para correção da abertura entre os cilindros (levando em conta a cedagem das cadeiras) e um coeficiente relacionado ao coroamento térmico dos cilindros de trabalho. A segunda categoria de adaptações (de longo prazo) inclui apenas o coeficiente de atrito e o limite de escoamento, que são as duas variáveis abordadas neste trabalho.

A adaptação de curto prazo, como já explanado acima, é executada bobina a bobina, e seus resultados ajustam os cálculos do modelo para o próximo produto da mesma categoria. A adaptação de longo prazo é executada periodicamente, com intervalo de execução ajustável (a frequência atual é a cada 12 horas). Cada vez em que a adaptação de longo prazo é executada, a base de dados do sistema é varrida e, através de uma comparação entre os valores calculados e medidos de força, é realizada uma regressão para ajustar os valores do limite de escoamento a uma equação do tipo:

$$\sigma = \frac{2}{\sqrt{3}} \times \sigma_0 \times \left[\mathbf{A} + \mathbf{B} \times \varepsilon \times \left(1 - \mathbf{C} \times e^{-\mathbf{D}} \right) \right] \text{ (Equação 2-35).}$$

A adaptação de longo prazo atualiza os parâmetros σ_0 , $\mathbf{A}$ e $\mathbf{B}$, mantendo-se inalterados os valores dos parâmetros $\mathbf{C}$ e $\mathbf{D}$.

A Figura 2-6 mostra, em vermelho, a curva obtida após uma execução da adaptação de longo prazo para um determinado tipo de material. Os pontos em verde representam os valores “reais” (obtidos por modelagem inversa) de limite de escoamento para cada uma das bobinas constituídas por esse tipo de material.

Figura 2-6 – Limite de escoamento *versus* deformação após adaptação de longo prazo

Como se pode constatar na figura, existe uma razoável discrepância entre a curva ajustada (que representa os valores usados pelo modelo) e os pontos individuais, o que indica uma oportunidade de aperfeiçoamento.

Com relação ao coeficiente de atrito, o modelo compara o último valor por ele calculado com o resultado obtido por meio de modelagem inversa dos valores efetivamente medidos. Com base na diferença, é calculado um fator α de filtragem adaptativa que é utilizado para a determinação do valor μ_{cal} estimado para o coeficiente de atrito, de acordo com a expressão:

$$\mu_{cal}^i = \alpha \times \mu_{med}^{i-1} + (1 - \alpha) \times \mu_{cal}^{i-1} \quad (\text{Equação 2-36}),$$

onde μ_{med} representa o último valor “medido” do coeficiente de atrito (calculado por modelagem inversa) e i representa o número da bobina. Tal esquema constitui a adaptação de curto prazo para o coeficiente de atrito.

A adaptação de longo prazo para essa variável é executada simultaneamente à adaptação de longo prazo para o limite de escoamento (ou seja, aproximadamente a cada 12 horas) e calcula, para cada cadeira, uma parcela μ_{adp} que se soma algebricamente ao coeficiente de atrito calculado pelo modelo.

Mais recentemente, Pires (2007) desenvolveu uma estratégia de adaptação em que, a partir de uma estimativa inicial dos valores do limite de escoamento σ e do coeficiente de atrito μ , calculam-se os valores correspondentes de força e redução para todas as cadeiras do laminador. Os valores calculados para essas variáveis são comparados com os valores reais (medidos) e, com base nessa comparação, ajustam-se os parâmetros através do algoritmo Simplex de Programação Linear (num procedimento semelhante ao usado para o cálculo das referências), empregado para a minimização de uma função-custo. A simulação de tal estratégia de adaptação apresentou resultados significativamente superiores aos produzidos pela estratégia anteriormente em uso no laminador. Esses resultados são apresentados em detalhes por Pires, Ferreira e Sales (2009).

Um ponto fraco da adaptação tradicional é a classificação do material laminado em famílias de aços. É comum que dois aços que não possuem exatamente a mesma composição química sejam classificados como pertencentes à mesma família. Assim, os mesmos

parâmetros serão utilizados no cálculo do limite de escoamento de ambos. Uma vez que o limite de escoamento está relacionado com a composição química, isso é uma fonte potencial de imprecisão, fazendo-se necessária uma estratégia que, além de uma classificação discreta em famílias de materiais, leve em conta a composição química efetiva.

Não se coloca em dúvida, obviamente, que os métodos tradicionais de adaptação proporcionem bons resultados – os níveis de qualidade e produtividade alcançados pelas unidades fabris são prova incontestável desse fato. Não obstante, a própria variedade de técnicas indica que o ideal ainda não foi alcançado, existindo espaço para a pesquisa de novos métodos que conduzam a resultados ainda melhores. É exatamente a isto que se propõe o presente trabalho.

Capítulo 3 TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL E SUA APLICAÇÃO AO PROCESSO DE LAMINAÇÃO

O presente capítulo tem como primeiro objetivo definir o conceito de Inteligência Computacional e expor os princípios básicos referentes às técnicas exploradas nessa tese. O nível de profundidade pretendido é o suficiente para permitir a compreensão da solução proposta para o problema abordado. Um segundo propósito do capítulo é apresentar uma resenha da aplicação dessas técnicas na solução de problemas relacionados à Siderurgia e, mais especificamente, ao processo de laminação a frio de aços planos.

3.1 Definindo Inteligência Computacional

A Inteligência Computacional (IC) pode ser entendida, de um modo simplista, como uma especialização de uma área mais ampla de conhecimento, que é a Inteligência Artificial (IA). Nas palavras de Duch (2008), definições de ramos da Ciência não são forjadas *a priori*, mas desenvolvem-se aos poucos, num processo de compartilhamento e de agrupamento de interesses comuns. Reconhecendo que o termo tem significados diferentes para diferentes pessoas, esse autor formula uma definição ampla para a Inteligência Computacional como sendo “*um ramo da Ciência da Computação que estuda problemas para os quais não existem algoritmos computacionais eficientes*”. Hernandez (2005) enfatiza que:

O objetivo do campo “inteligência computacional” é o desenvolvimento de técnicas que permitam incorporar ao ambiente computacional, mesmo que de forma limitada, algumas das funcionalidades dos sistemas biológicos (humanos ou não) no que se refere aos seus aspectos de inteligência.

Em sua pesquisa sobre publicações científicas que possuem em seu título o termo “Inteligência Computacional”, abrangendo um período de mais de duas décadas (desde 1984 até 2007), Duch (2008) constata que inicialmente o termo era praticamente indistinto de “Inteligência Artificial”, mas, ao longo do tempo, foi tomando contornos mais definidos, passando a englobar principalmente Redes Neurais Artificiais (RNA), a Lógica Nebulosa (LN) e a Computação Evolucionária (CE), em especial os Algoritmos Genéticos (AG). Essa tendência foi igualmente percebida por van Eck *et al.* (2006).

Trabalhos como os de Fukuda e Kubota (2001) e de Wilamowski (2004) reforçam a percepção de que essas técnicas constituem o cerne da IC, uma vez que ambos procuram defini-la em termos da utilização isolada ou conjunta das mesmas. Não obstante, a pesquisa bibliográfica revela que um consenso a esse respeito é algo ainda distante. Embora a maior parte dos textos apresente a IC como um ramo da IA, há publicações em que esses dois campos de conhecimento são considerados disjuntos, como mostra a Figura 3-1, tirada do trabalho de Schmutter (2002), em que se procura caracterizar a IA como estando relacionada às ciências sociais e a IC às ciências naturais, servindo a Lógica Nebulosa como um elo entre ambas.

Figura 3-1 – AI e CI como campos disjuntos

Van Eck *et al.* (2006) empreenderam uma pesquisa sobre a estrutura e a evolução da IC através de mapas conceituais (representações gráficas que têm por objetivo refletir da forma mais acurada possível as associações entre conceitos). Sua pesquisa baseou-se na análise dos resumos de artigos submetidos ao Congresso Mundial IEEE sobre Inteligência Computacional (WCCI), nas edições de 2002 e 2004. Considerando os conceitos presentes em pelo menos sete resumos, foram constatados 134 conceitos em 2002 e 172 conceitos em 2006. Tratando esses conceitos por meio de uma ferramenta matemática, os pesquisadores obtiveram os chamados *mapas de densidade conceitual*, reproduzidos na Figura 3-2, na qual a cor azul clara representa menor densidade e a cor vermelha viva representa maior densidade.

Figura 3-2 – Densidade dos conceitos em IC nos anos de 2002 (esquerda) e 2006 (direita)

A partir desses mapas de densidade, van Eck e seus colaboradores constataram três agrupamentos principais englobando a maior parte dos conceitos: Redes Neurais Artificiais, Sistemas Nebulosos e Computação Evolucionária. Eles concluem que, embora o ramo da Computação Evolucionária mostre uma tendência mais independente em relação aos outros dois, a estrutura da IC mostra uma tendência que indica a maturidade da matéria. Esse trabalho representa uma confirmação da visão disseminada entre os pesquisadores sobre os paradigmas no campo da IC e corrobora a proposta da *IEEE Computational Intelligence Society* (denominação adotada em 2004 para a antiga *IEEE Neural Network Society*), que considera como objetos de estudo da IC justamente esses três campos (IEEE, 2008). Apresentam-se a seguir os fundamentos das duas primeiras técnicas e dos Algoritmos Genéticos, que são um caso particular de Computação Evolucionária.

3.2 Redes Neurais Artificiais

Tratam-se de sistemas computacionais, implementados através de software ou hardware, constituídos por diversas unidades processadoras, em geral distribuídas em camadas, e ligadas entre si através de conexões ponderadas, conhecidas como *sinapses*. Sua organização e modo de operação inspiram-se vagamente no cérebro humano, sendo essa a razão pela qual as unidades processadoras são conhecidas como *neurônios artificiais*.

A saída de uma unidade processadora é obtida pela aplicação de uma *função de*

ativação (em geral não-linear) sobre a sua entrada, que por sua vez é obtida pela soma ponderada das saídas de outras unidades a ela conectadas. A Figura 3-3 mostra esquematicamente a constituição de uma unidade processadora de uma RNA, com seus vetores de entradas e de pesos, sua função de ativação e sua saída.

Figura 3-3 – Diagrama de um neurônio artificial

Uma Rede Neural Artificial é constituída pela interconexão de diversos neurônios artificiais, através das chamadas conexões sinápticas ou sinapses. Existem diversas formas pelas quais as unidades constituintes de uma RNA podem conectar-se entre si. A configuração particular dessa ligação é o que se chama de *arquitetura* da rede.

A principal vantagem de uma RNA reside em sua capacidade de modelar um problema real com base em um número adequado de observações, demandando um mínimo de conhecimento específico sobre o assunto em questão. No caso de sistemas com entradas e saídas multidimensionais, com relacionamentos complexos ou desconhecidos e comportamento não linear, esta é, por vezes, a única abordagem factível. A principal desvantagem é a dificuldade de se interpretar o conhecimento armazenado numa RNA.

De acordo com Uhrig (1995), a utilização de uma RNA envolve dois processos. O primeiro é chamado *aprendizado* ou *treinamento*, e o segundo é conhecido como *operação* (“*recall*”).

Por meio do treinamento, uma RNA “aprende” a dinâmica do sistema por ela modelado, ou seja, o mapeamento entre o vetor de entrada e o vetor de saída. O treinamento consiste no ajuste conveniente dos pesos das conexões sinápticas, a partir de um processo iterativo em que os valores das saídas fornecidas pela rede são comparados com os valores conhecidos ou esperados (*treinamento supervisionado*) ou passam a apresentar um padrão definido (*treinamento não supervisionado*). A regra utilizada para a modificação dos pesos é conhecida como *lei de aprendizado*. Assim como existem diversas arquiteturas de rede, existem vários algoritmos de treinamento, alguns dos quais específicos para uma dada arquitetura. A Figura 3-4 apresenta o fluxograma de um algoritmo de treinamento supervisionado.

Figura 3-4— Fluxograma de um algoritmo supervisionado de treinamento

Existem duas estratégias para a atualização dos pesos das conexões sinápticas: a *atualização por padrão* (“*pattern mode*”) e a *atualização por lote* (“*batch mode*”). Na atualização por padrão, o erro é calculado após a apresentação de cada exemplo de treinamento, sendo o seu valor logo em seguida utilizado para o ajuste dos pesos. Na atualização por lote, o erro vai sendo acumulado até que todo o conjunto de exemplos de treinamento seja apresentado à rede, e só então se ajustam os pesos, com base nesse erro acumulado. Cada ciclo completo de apresentação do conjunto de dados de treinamento é denominado de *época*. Como se verifica em relação a quase todas as questões relativas às RNA, a estratégia ideal depende do problema abordado.

É evidente que a atualização por lote proporciona um treinamento mais rápido do que a atualização por padrão, além de permitir uma estimativa mais acurada da variação mais adequada para os pesos. Em contrapartida, a atualização por padrão é menos propensa a estacionar em mínimos locais da superfície de erro. Rafiq, Bugmann e Easterbrook (2001) recomendam que a rede seja treinada utilizando-se inicialmente a estratégia de atualização por lote. Caso a capacidade de generalização da rede se mostre insatisfatória (erro elevado ao se confrontar com o conjunto de exemplos de teste), deve-se então tentar a estratégia de atualização por padrão. A ferramenta usada neste trabalho utiliza a atualização por lote.

Dependendo do tipo de problema abordado, do número de padrões disponíveis e do algoritmo empregado, o processo de treinamento de uma RNA pode ser extremamente demorado. Num trabalho envolvendo quatro redes utilizadas em conjunto para a obtenção de 110 variáveis de saída, Santos Filho (2003) necessitou de cerca de 120 horas, excluindo-se o tempo empregado na coleta e pré-processamento dos dados.

Uma vez treinada, uma RNA pode passar para o modo de operação, no qual fornece rapidamente as saídas correspondentes aos padrões aplicados às suas entradas, ainda que estes sejam diferentes dos usados durante o seu treinamento. Essas saídas são determinadas com grau de precisão arbitrário, desde que se disponha de um número suficiente de unidades e de padrões de treinamento. Tal característica, altamente desejável numa RNA, é conhecida como *generalização*. Para se incrementar essa capacidade, as boas práticas de desenvolvimento de RNA recomendam que os dados disponíveis sejam divididos em conjuntos distintos para o treinamento, para o teste e para a validação das redes. Outro cuidado importante é que os novos padrões apresentados à rede estejam dentro da faixa de valores usada no treinamento, ou seja, que não se exija da rede capacidade de extrapolação.

3.2.1 Roteiro para o Desenvolvimento de um Sistema Baseado em RNA

O primeiro passo é a coleta e preparação de dados para o treinamento e validação da RNA. Esse é um ponto de fundamental importância, pois a quantidade e a qualidade dos dados disponíveis são primordiais para a viabilidade do projeto. Esses dados são, basicamente, um conjunto de valores para as grandezas de entrada da rede e um conjunto dos respectivos valores para as grandezas de saída.

Além da disponibilidade desses conjuntos de valores, é necessário também um certo grau de conhecimento do problema que se propõe a resolver com o uso da RNA. Esse grau de conhecimento deve ser suficiente para garantir a existência de uma relação de causa e efeito entre as grandezas de entrada e saída, sem a qual a RNA conduzirá a resultados totalmente falsos. Curry e Morgan (1997) apontam como fonte potencial de perigo o fato de que a abundância de pacotes de software especializados para o desenvolvimento de RNA tem possibilitado que elas sejam empregadas sem um rigoroso embasamento teórico. Segundo eles, isso acaba por escamotear aos olhos do pesquisador desavisado as várias “armadilhas” inerentes à técnica, aumentando o risco de erros decorrentes de sua má utilização.

Normalmente, os dados são obtidos de um registro histórico pré-existente. Caso esse registro não exista, é preciso providenciá-lo antes de se dar prosseguimento ao projeto. Obviamente, caso exista um modelo matemático ou equação conhecida regendo o fenômeno, o conjunto de dados para o treinamento da rede pode ser obtido simplesmente através da aplicação das entradas a esse modelo ou equação, obtendo-se as saídas correspondentes aos resultados. Esse, no entanto, não é o caso mais comum quando se adota a abordagem por meio de redes neurais.

Uma vez disponíveis os dados de treinamento, eles devem ser submetidos a um processo de *data mining*, através do qual são removidos os dados inconsistentes e verificada a real relevância de cada uma das entradas sobre o resultado final, o que poderá ensejar uma redução na dimensionalidade da rede. Depois do processo de *data mining*, os dados devem ser normalizados, para evitar que uma variável que tenha valores, por exemplo, entre 1000 e 1500, tenha maior influência do que outra que tenha valores entre 0,2 e 0,8. O processo de normalização garante que todas as variáveis estejam dentro da mesma ordem de grandeza.

O próximo passo é a determinação da arquitetura de RNA a ser utilizada, entre as várias existentes. A resposta a essa questão está intimamente ligada à natureza da tarefa a

que se destina a rede e até mesmo ao tipo e quantidade dos dados disponíveis, e está longe de ser trivial. A pesquisa bibliográfica de aplicações semelhantes à que se pretende desenvolver é a diretriz mais segura para a tomada dessa decisão.

No caso de redes de múltiplas camadas, o passo seguinte é a determinação da topologia da RNA, ou seja, o número de camadas intermediárias e o número de neurônios em cada camada. O número de neurônios nas camadas de entrada e saída é determinado diretamente pelo problema específico ao qual se aplica a rede. Exemplificando, se o objetivo da rede é determinar a cotação do dólar e o risco-país em função das reservas cambiais, do saldo da balança comercial e do montante de investimentos diretos, a rede terá três neurônios na camada de entrada e dois neurônios na camada de saída. Com relação ao número de camadas intermediárias, Cybenko (1988) demonstrou que duas são suficientes para aproximar qualquer tipo de função, não havendo razão teórica para o emprego de um número maior. Svozil, Kvasnicka e Pospíchal (1997) preconizam o emprego de uma única camada intermediária, sendo razoável adicionar uma segunda apenas no caso não se consiga um resultado aceitável. Tal situação costuma acontecer em modelos que apresentem algumas regiões de descontinuidade. Os autores ressaltam, no entanto, que uma segunda camada intermediária tende a aumentar significativamente o tempo necessário para o treinamento da rede.

O número de neurônios na(s) camada(s) intermediária(s) também é um valor empírico, norteado por fatores como a complexidade do problema abordado, a quantidade disponível de dados para o treinamento da rede, a precisão desejada para os resultados, etc. Svozil, Kvasnicka e Pospíchal (1997) denunciam como “*totalmente sem sentido*” várias regras empíricas que buscam determinar a topologia com base no número de entradas e saídas.

Determinada a topologia da rede, atribuem-se valores aleatórios aos pesos das conexões sinápticas (normalmente dentro do intervalo $[-1, +1]$) e se inicia o processo de treinamento da rede. A determinação da topologia e do valor aceitável para o erro da RNA após o seu treinamento deve levar em conta os requisitos contraditórios de precisão e de capacidade de generalização desejados para a RNA. Excesso de neurônios pode levar ao chamado *overfitting*, que ocorre quando a RNA memoriza os padrões usados no treinamento, e se mostra incapaz de classificar corretamente outros padrões, ou seja, não apresenta capacidade de generalização. O *overfitting* é evidenciado quando a RNA apresenta para o conjunto de teste um erro significativamente superior ao apresentado durante o treinamento.

Hines (1997) recomenda três métodos para reduzir a possibilidade do *overfitting*: redução do número de unidades da rede, aumento do tamanho do conjunto de treinamento para que o ruído presente nos dados se anule e a interrupção antecipada (“*early stopping*”) do treinamento. Após o treinamento, a capacidade de generalização da rede pode ser aferida por meio de um conjunto de dados de validação previamente separados para esse fim.

3.2.2 Redes Neurais Artificiais Para Aproximação de Funções

Basheer e Hajmeer (2000) dividem em sete categorias os problemas potencialmente solucionáveis por meio de RNA: reconhecimento de padrões, agrupamento, aproximação de funções, predição de séries temporais, otimização, associação e controle. Para cada uma dessas categorias existe pelo menos um tipo mais apropriado de arquitetura de rede. Esses autores enumeram entre 26 e 50 diferentes tipos de arquiteturas de RNA e apresentam duas delas como particularmente adequadas à tarefa de aproximação de funções: as redes *perceptrons de múltiplas camadas* (*Multilayers Perceptrons* – MLP) e as redes de *função de base radial* (*Radial Basis Function* – RBF).

Ferrari e Stengel (2005) e Lang (2005), entre outros, demonstraram que ambas as arquiteturas são aproximadoras universais de funções, isto é, possuem a propriedade de representar com grau de precisão arbitrário qualquer função multivariável contínua. Visto que o presente trabalho propõe a utilização de RNA para a emulação dos modelos que regem o limite de escoamento e o atrito no processo de laminação de aços planos a frio, esses dois tipos de arquitetura são experimentados na solução do problema. Segue-se uma descrição sucinta sobre elas e, por fim, uma comparação entre suas características.

3.2.2.1 Redes *Perceptrons* de Múltiplas Camadas

Dentre as diversas arquiteturas de RNA, esta é a mais freqüentemente empregada, devido à sua versatilidade. Esse tipo de rede possui três ou mais camadas de unidades processadoras que se ligam exclusivamente às unidades da camada imediatamente seguinte (a chamada protoalimentação ou *feedforward*). As unidades da primeira camada recebem as entradas da rede e as unidades da última camada produzem as saídas. As demais camadas são conhecidas como camadas ocultas ou camadas intermediárias. A Figura 3-5 mostra o diagrama de uma RNA do tipo MLP com uma única camada intermediária.

Figura 3-5 – Estrutura de uma rede neural do tipo MLP

Na maior parte das aplicações práticas, utiliza-se uma unidade processadora adicional, cuja saída é constante e igual a 1 e que se conecta a todas as demais unidades da rede, com exceção das que se encontram na camada de entrada. Essa unidade é conhecida pelo nome de *viés (bias)*. Ela possibilita que a saída de um neurônio seja diferente de zero mesmo que o valor de todas as outras entradas seja nulo, contribuindo para a estabilidade do sistema.

A função de ativação das unidades processadoras é, em geral, não-linear, podendo eventualmente possuir uma região com linearidade. É possível utilizar diferentes funções de ativação em diferentes camadas de uma rede. A Figura 3-6 mostra os tipos mais comuns de funções de ativação utilizadas em RNA MLP.

Figura 3-6 - Algumas funções de ativação utilizadas nos neurônios de uma RNA do tipo MLP

O algoritmo mais frequentemente empregado para o treinamento das redes MLP é o conhecido como retropropagação dos erros (*error backpropagation*), concebido por meio de estudos realizados de forma independente por Werbos (1972), Parker (1982) e por Rumelhart, Hinton e Williams (1986), sendo estes últimos os responsáveis pela ampla disseminação do algoritmo. Sua utilização é tão freqüente que, em alguns textos, as redes MLP são (erroneamente) denominadas como redes BP (*backpropagation*). A Figura 3-7 mostra o fluxograma desse algoritmo de treinamento, para uma rede MLP com duas entradas, três saídas e com duas camadas intermediárias, utilizando a unidade de *bias*.

Figura 3-7 – Fluxograma do algoritmo de retropropagação de erros

Conforme explicam Meireles, Almeida e Simões (2003), o algoritmo de retropropagação de erros é uma variante do algoritmo LMS (*least mean squares*), no qual a função-erro a ser minimizada é definida como diferença média quadrática entre os valores desejado (y_d) e efetivo (y_r) em cada saída k da rede, ou seja, a função erro é definida como:

$$E(k) = \frac{1}{2} \times [y_d(k) - y_r(k)]^2 \quad (\text{Equação 3-1}).$$

O algoritmo calcula então a derivada parcial $\frac{\partial E}{\partial W}$ do vetor de erros E em relação ao vetor de pesos sinápticos W . Para cada época de treinamento t , o vetor de pesos é ajustado de acordo com a equação:

$$\mathbf{W}_t = \mathbf{W}_{t-1} + \eta \times \left(-\frac{\partial \mathbf{E}}{\partial \mathbf{W}} \right) \quad (\text{Equação 3-2}),$$

sendo η a chamada *taxa de aprendizagem*.

Um aperfeiçoamento do algoritmo é a inclusão do chamado *fator de momento* α , que, a exemplo da taxa de aprendizagem, possui valor entre 0 e 1. O fator de momento aumenta a velocidade de convergência e reduz a probabilidade de que o treinamento fique preso a um mínimo local da superfície de erro. Com a adição do fator de momento, a equação de ajuste dos pesos em cada época t do treinamento passa a ser:

$$\mathbf{W}_t = \mathbf{W}_{t-1} + \eta \times \left(-\frac{\partial \mathbf{E}}{\partial \mathbf{W}} \right) + \alpha \times \Delta \mathbf{W}_{t-1} \quad (\text{Equação 3-3}).$$

Diversas variações têm sido desenvolvidas para o algoritmo, visando principalmente reduzir o tempo de convergência e a possibilidade de parada num mínimo local. A Figura 3-8 é reproduzida do trabalho de Vallim (2008), que inclui uma resenha dessas diversas variações. Em geral, os utilitários comerciais para o treinamento de redes neurais oferecem várias dessas modalidades como opções para o treinamento.

Figura 3-8 – Variações do algoritmo de retropropagação de erros

3.2.2.2 Redes de Função de Base Radial

Funções de base radial são aquelas que possuem uma “sintonia”, ou seja, seu valor é significativamente diferente de zero apenas numa região limitada e radialmente simétrica do espaço de sua(s) variável(eis) independente(s). Assim, uma função de base radial pode ser caracterizada por um centro receptivo ou base, que corresponde ao “pico de sintonia” da função e por uma distância ou raio, que dá uma medida da “seletividade” da função. Um exemplo clássico de função de base radial (e largamente utilizada na implementação de RNA com essa arquitetura) é a curva de distribuição estatística normal ou curva de Gauss. Nessa curva, o centro é a média da distribuição e o raio é a sua variância. Dois outros exemplos de funções radiais, usadas com menor frequência, são a multiquadrática (conhecida como função de Hardy) e a multiquadrática inversa. A Figura 3-9 mostra as equações e os gráficos dessas funções.

Figura 3-9 – Alguns tipos de função de base radial

Haykin (1994) assinala que as funções de base radial foram inicialmente utilizadas para a solução de problemas de interpolação real multivariável, com o trabalho de Powell (1985). Broomhead e Lowe (1988) tornaram-se os pioneiros na utilização de funções de base radial no desenvolvimento de RNA, ao que se seguiram os trabalhos de Moody e Darken (1989), de Renals (1989) e de Poggio e Girosi (1990). Embora existam várias topologias possíveis para as RNA do tipo RBF, a mais frequentemente utilizada é a preconizada no trabalho de Moody e Darken, devido à sua simplicidade. A Figura 3-10 apresenta essa topologia.

Figura 3-10 - Arquitetura Moody/Darken de uma RNA do tipo RBF

Segundo a descrição de Hwang e Bang (1997), trata-se de uma RNA não recorrente composta por uma camada de entrada, uma camada oculta e uma camada de saída. Cada unidade processadora da camada de entrada corresponde a um padrão de um vetor de entrada $\mathbf{x}$. A camada oculta, que corresponde aos padrões que a rede classificará, possui n unidades processadoras e, opcionalmente, uma unidade de *bias*. A camada de saída consiste de m unidades que correspondem às possíveis classes do problema.

As unidades de entrada são completamente conectadas às unidades ocultas, com exceção da unidade de *bias*. As unidades de entrada têm como único propósito transmitir os padrões de entrada para a camada oculta, não realizando qualquer ativação nem acrescentando pesos às conexões. As unidades ocultas são completamente conectadas às de saída. A função de ativação das unidades ocultas é:

$$y_i = e^{-\frac{\|\mathbf{x}_i - \mathbf{c}_i\|^2}{2 \times \sigma_i^2}} \quad (\text{Equação 3-4}).$$

Nesta equação, $\mathbf{c}_i$ e σ_i são respectivamente, o centro e o raio da função radial de ativação das unidades ocultas e o operador $\|\cdot\|$ representa a *distância euclidiana*, dada por:

$$\|\mathbf{x} - \mathbf{c}\| = \sqrt{\sum (\mathbf{x}_i - \mathbf{c}_i)^2} \quad (\text{Equação 3-5}).$$

Cada unidade na camada de saída realiza uma soma ponderada dos valores recebidos da camada oculta e possui função de ativação linear, ou seja:

$$\mathbf{y}_j = \sum_{i=0}^n \mathbf{z}_i \times \omega_{ij}, \quad j = 1, 2, \dots, n \quad (\text{Equação 3-6}),$$

onde $\mathbf{y}_j$ é a saída da j-ésima unidade de saída, $\mathbf{z}_i$ é a saída da i-ésima unidade oculta e ω_{ij} é o peso relacionando a i-ésima unidade oculta e a j-ésima unidade de saída.

Existe uma série de questões envolvidas no processo de desenvolvimento de uma RNA RBF. Em primeiro lugar, é necessário determinar o número de unidades ocultas. Segundo Hwang e Bang (1997), o método mais simples e geral para essa determinação é criar uma unidade para cada padrão de treinamento. No entanto, em grande parte das aplicações reais, esse método é impraticável, uma vez que o número de padrões é elevado. Por isso, a prática usual é dividir os padrões de treinamento num número razoável de agrupamentos, utilizando algoritmos, em geral não supervisionados, como o *k-means*, utilizado por Moody e Darken (1989) ou os *mapas auto-organizados*, propostos por Kohonen (1988). Obtida a estrutura da camada intermediária, devem agora ser determinados os parâmetros intrínsecos da rede, ou seja, os valores do centro e do raio das funções de transferência das unidades ocultas e, por fim, os valores dos pesos sinápticos entre essas unidades e as unidades da camada de saída.

Como ressalta Haykin (1994), uma vez que as camadas de uma RNA RBF realizam tarefas diferentes, é razoável separar a otimização dessas camadas em passos distintos e utilizando técnicas distintas, num processo extremamente flexível. Schwenker, Kestler e Palm (2001) classificam os métodos de treinamento desse tipo de rede em monofásicos, bifásicos e trifásicos, de acordo com o número de etapas em que esses métodos são executados. Dentro dessa classificação, esses pesquisadores relacionam um total de nada menos que doze diferentes métodos. Vasconcelos (1995, *apud* SANTOS FILHO, 2003), por sua vez, apresenta as seguintes estratégias de treinamento para cada um dos três parâmetros

que compõem uma rede RBF:

1. Em relação aos raios: estabelecimento de um valor fixo, definição através de um método de descida do gradiente ou determinação através de um processo heurístico (*heurística da máxima proximidade*).
2. Em relação aos centros: escolha aleatória entre os padrões de treinamento ou treinamento baseado em aprendizado competitivo ou algoritmos genéticos.
3. Em relação aos pesos: uso de algoritmos de descida do gradiente (mínima média quadrática, por exemplo) ou por um procedimento de manipulação matricial direta conhecido como *método pseudo-inverso*.

A determinação dos pesos, portanto, é realizada através de um processo supervisionado, semelhante ao utilizado na retropropagação, com a vantagem de que existe um único vetor de pesos a ser calculado. Assim, caso os centros e/ou os raios tenham sido determinados por uma técnica não supervisionada, o treinamento global é chamado de *híbrido*, por ser constituído por uma fase não supervisionada seguida de uma fase supervisionada. Moody e Darken (1989) obtiveram melhores resultados com a modalidade híbrida de treinamento.

3.2.3 Comparação Entre as Duas Arquiteturas

Comparando o desempenho dessas duas arquiteturas de RNA, Hassoun (1995) afirma que as RBF possuem como vantagens um treinamento mais rápido e melhor desempenho em aplicações que requeiram treinamento *on-line*, como no processamento adaptativo de sinais. Em contrapartida, requerem cerca de 10 vezes mais dados para alcançarem a mesma acurácia de uma MLP, necessitando também de um maior número de unidades ocultas.

Num exemplo prático, Moody e Darken (1989) comparam o tempo necessário para o treinamento de uma RNA RBF (no melhor caso, 67 segundos de processamento numa CPU de 90 MFlops) com o tempo despendido no treinamento de uma RNA equivalente, mas com arquitetura MLP, utilizada num trabalho de Lapedes e Farber (1987): no melhor caso, “alguns” minutos de processamento numa CPU de mesmo porte. Assim, eles concluem que, para uma mesma aplicação, o treinamento de uma RNA RBF é de “centenas a milhares de vezes” mais rápido do que o de uma MLP. A razão para tal diferença, segundo concluíram esses pesquisadores, reside no fato de que a representação do conhecimento numa RNA RBF é basicamente local, com poucas unidades ocultas ativas para um determinado padrão de

entrada. Uma RNA MLP, por sua vez, armazena conhecimento de forma distribuída, ativando-se um grande número de unidades ocultas a cada padrão de entrada apresentado. Moody e Darken advertem, no entanto, que a utilização de um método totalmente supervisionado de treinamento anula a característica de representação local das RNA RBF, levando a tempos de treinamento equivalentes ou mesmo superiores aos de uma RNA MLP. Essa é uma das razões pelas quais, como declarado anteriormente, o treinamento híbrido é o preferido.

Venkatesan e Anitha (2006) compararam o desempenho das duas arquiteturas para o diagnóstico de diabetes. Eles constataram que a rede do tipo RBF apresentou maior capacidade preditiva do que a do tipo MLP (cerca de 4 pontos percentuais), mas ressaltam que o desempenho da RBF é sensivelmente prejudicado quando aumenta a dimensionalidade do problema. Essa foi exatamente a constatação de Santos Filho (2003), ao experimentar as duas arquiteturas na abordagem de um problema envolvendo 135 variáveis de entrada e saída, sendo que, no presente trabalho, a utilização da arquitetura RBF se mostrou inviável, como será explanado com mais detalhes no Capítulo 4.

Em resumo, a análise da literatura mostra que a eventual superioridade de uma dessas duas arquiteturas sobre a outra está ligada a aspectos específicos do problema abordado. No caso de não existir um fator determinante favorecendo o uso de uma delas (dimensionalidade, número de vetores de treinamento disponíveis, exigências quanto ao tempo de treinamento, etc.), o procedimento adequado é experimentar ambos os tipos para determinar qual apresenta o melhor desempenho.

3.3 Lógica Nebulosa

O termo Lógica Nebulosa (*Fuzzy Logic*) foi cunhado por Zadeh (1965), num trabalho em que procurou sistematizar um procedimento matemático para lidar com o chamado raciocínio aproximado que, na visão desse autor, caracteriza a maior parte dos problemas com que o ser humano se defronta. Conceitos como “quente”, “baixo” ou “longe” são facilmente compreensíveis para as pessoas, sem que se exijam valores numéricos precisos. Enquanto a lógica clássica é essencialmente binária (uma afirmação é falsa ou verdadeira, um elemento pertence ou não pertence a um determinado conjunto), a Lógica Nebulosa dá espaço à idéia de *grau de pertinência* de um elemento em relação a um dado conjunto.

Zadeh (1973) enunciou o chamado Princípio da Incompatibilidade, segundo o qual:

Na medida em que a complexidade de um sistema aumenta, diminui a nossa capacidade de fazer declarações precisas e ainda assim significativas sobre o seu comportamento, até que se atinge um limite em que precisão e relevância se tornam características mutuamente exclusivas.

Em outras palavras, esse princípio afirma que somente em contextos extremamente simples informações precisas podem ter relevância. Exemplificando, na declaração “*aquele prédio tem 9 andares*”, os atributos de precisão e significado são compatíveis. Aumentando-se o grau de complexidade da declaração, afirmando-se, por exemplo, que “*aquele prédio tem 378 janelas*”, a incompatibilidade entre os dois atributos já começa a se manifestar (o que não ocorreria se a precisão no enunciado fosse substituída por “*deve ter mais de 50 janelas*”). Num extremo de complexidade (“*na construção daquele prédio foram utilizados 12.087,93 sacos de cimento*”), a incompatibilidade aparece em toda a sua força. Assim, a certeza de que uma proposição seja verdadeira diminui com qualquer acréscimo em sua precisão.

A importância da Lógica Nebulosa consiste em permitir a quantificação de conceitos ou propriedades que o homem manipula semanticamente – isto é o que Zadeh (1996) chama de “computação com palavras”. Dessa forma, torna-se possível instruir um computador a executar um algoritmo do tipo “se o nível do tanque estiver muito baixo, feche a válvula V1; se estiver um pouco alto, abra a válvula V2”. Tal algoritmo, trivial para um operador humano, apresenta notável complexidade para a computação convencional. A Lógica Nebulosa permite a um processador interpretar o significado de “muito baixo” ou “um pouco alto”, questões que o cérebro humano trata com facilidade.

Um conjunto clássico (*crisp*) pode ser definido pela enumeração dos seus elementos, como por exemplo: $A = \{ x, y, z \}$. Dado um conjunto clássico A , a pertinência $\mu_A(x)$ de elemento x a esse conjunto é dada pela equação:

$$\mu_A(x) = 1, \text{ se } x \in A \mid \mu_A(x) = 0, \text{ se } x \notin A \quad (\text{Equação 3-7}).$$

Segundo Lee (1990), um conjunto nebuloso pode ser entendido como uma generalização de um conjunto clássico. Dada uma coleção de objetos U , constituída de *etiquetas lingüísticas* (como “baixo”, “médio”, “alto”, etc.) e denominada de *universo de discurso*, caracteriza-se um conjunto nebuloso A dentro desse universo de discurso por meio

de uma *função de pertinência* μ_A com valores no intervalo $[0, 1]$. O conjunto nebuloso pode ser representado como um conjunto de pares ordenados, cada um deles consistindo de um elemento genérico x e sua respectiva função de pertinência, na forma: $A = \{(x, \mu_A(x)) \mid x \in U\}$.

Outros conceitos importantes na teoria de conjuntos nebulosos são *suporte*, *ponto de cruzamento* e *singleton*. O suporte é o conjunto de todos os pontos do universo de discurso para os quais a função de pertinência possui valor maior que zero. O ponto de cruzamento é o nome dado ao elemento que, dentro do universo de discurso, possui função de pertinência com valor igual a 0,5. Um *singleton*, por sua vez, é um conjunto nebuloso cujo suporte é formado por um único ponto, com função de pertinência igual a 1.

Um conjunto nebuloso é classificado como *normal* se ele inclui pelo menos um ponto com função de pertinência igual a 1, e classificado como *convexo* se a função de pertinência decresce monotonicamente do seu valor máximo para o seu valor mínimo. Um conjunto nebuloso que satisfaça simultaneamente as condições de normalidade e convexidade é o que chamamos de *número nebuloso* ou *variável nebulosa*.

Em geral, as funções de pertinência são expressas na forma de números nebulosos, que podem tomar diversas formas, como, por exemplo:

- Triangular $\rightarrow$ Pertinência igual a 1 num único ponto, decrescendo linearmente à esquerda e à direita;
- Trapezoidal $\rightarrow$ Pode ter pertinência igual a 1 num intervalo desde o início do universo de discurso até um determinado ponto, decrescendo linearmente à sua direita (*left fuzzy number* – LFN); ou pertinência igual a 1 num intervalo a partir de um ponto até o final do universo de discurso, decrescendo linearmente à esquerda (*right fuzzy number* – RFN); ou pertinência igual a 1 num intervalo entre dois pontos, decrescendo linearmente à esquerda e à direita (*flat fuzzy number* – FFN).

Uma variável nebulosa triangular depende, assim, de três parâmetros (a , b e c) e sua função de pertinência tem a forma:

$$f(x; a, b, c) = \begin{cases} 0 & \text{se } x < a \\ \frac{x-a}{b-a} & \text{se } a \leq x < b \\ \frac{c-x}{c-b} & \text{se } b \leq x \leq c \\ 0 & \text{se } x > c \end{cases} \quad (\text{Equação 3-8}).$$

Uma variável nebulosa trapezoidal do tipo FFN depende de cinco parâmetros. Sua função de pertinência tem a forma:

$$f(x; a, b, c, d) = \begin{cases} 0 & \text{se } x < a \\ \frac{x-a}{b-a} & \text{se } a \leq x < b \\ 1 & \text{se } b \leq x < c \\ \frac{d-x}{d-c} & \text{se } c \leq x < d \\ 0 & \text{se } d \leq x \end{cases} \quad (\text{Equação 3-9}).$$

Outra categoria de variável nebulosa frequentemente utilizada é conhecida como gaussiana. Sua função de pertinência tem a forma:

$$f(x; \sigma, c) = \exp\left[\frac{-(x-c)^2}{2\sigma^2}\right] \quad (\text{Equação 3-10}).$$

A Figura 3-11 mostra o aspecto dessas três tipos de variáveis nebulosas, sendo que cada gráfico inclui três variáveis dentro do universo de discurso considerado, representadas nas cores vermelha, azul e verde.

Figura 3-11 – Três exemplos de funções de pertinência

Supondo que os gráficos acima representem a temperatura no interior de uma estufa, com seu universo de discurso compreendido entre os valores 40 °C e 90 °C, a temperatura pode ser entendida como uma *variável lingüística*, definida por meio de três etiquetas (“*baixa*”, “*média*” e “*alta*”, por exemplo), cada uma representada por uma variável nebulosa.

Da mesma forma como na Lógica Clássica, definem-se operações entre conjuntos em Lógica Nebulosa. As operações básicas entre conjuntos clássicos são a união, a interseção e o complemento, que correspondem, respectivamente, aos operadores lógicos **OU**, **E** e **NÃO**.

Existem duas famílias de operadores entre conjuntos nebulosos. A primeira dessas famílias é utilizada para realizar operações conjuntivas entre variáveis nebulosas, e são conhecidas como *normas T* (de triangular). O elemento neutro das normas T é o **0**, e elas devem satisfazer aos seguintes requisitos:

- Delimitação: $T(0,0) = 0, T(a,1) = T(1,a) = a$;
- Monotonicidade: $T(a,b) \leq T(c,d)$, se $a \leq c$ e $b \leq d$;
- Comutatividade: $T(a,b) = T(b,a)$; e
- Associatividade: $T(a, T(b,c)) = T(T(a,b), c)$.

As principais normas T são a *interseção*, o *produto algébrico*, o *produto delimitado* e o *produto drástico*. Destas, a mais utilizada é a interseção, definida como:

$$\mu_{A \cap B}(u) = \text{mín} \{ \mu_A(u), \mu_B(u) \} \quad (\text{Equação 3-11}),$$

em que **A** e **B** são conjuntos nebulosos dentro de um universo de discurso **U**, sendo μ_A e μ_B suas respectivas funções de pertinência. A interseção entre dois conjuntos nebulosos **A** e **B** pode ser interpretada como o maior conjunto nebuloso **C** que seja simultaneamente subconjunto de **A** e **B**.

A segunda família de operadores nebulosos é usada para realizar operações disjuntivas entre conjuntos nebulosos, e são conhecidas como *normas S*, ou *conormas T*. As normas S têm o **1** como elemento neutro e devem satisfazer os mesmos requisitos aplicáveis às normas T. As principais normas S são a *união*, a *soma algébrica*, a *soma delimitada* e a *soma drástica*. A união entre dois conjuntos nebulosos **A** e **B** dentro de um universo de discurso **U** é definida como:

$$\mu_{A \cup B}(u) = \text{máx} \{ \mu_A(u), \mu_B(u) \} \quad (\text{Equação 3-12}).$$

A união entre dois conjuntos nebulosos **A** e **B** pode ser interpretada como o menor conjunto nebuloso **C** que tenha simultaneamente **A** e **B** como subconjuntos.

3.3.1 Sistemas de Inferência Nebulosa

A utilização de Lógica Nebulosa permite que se projetem controladores cujo funcionamento se baseie em regras semânticas, ao invés de em algoritmos puramente

numéricos. Isso dá ensejo à concepção de programas semelhantes aos sistemas especialistas, que, ao invés de se limitarem simplesmente a dar sugestões que, a critério de um operador, poderão ou não ser seguidas, possuem a vantagem de tomarem decisões de forma semelhante à que faria um ser humano. Tais programas são conhecidos como Sistemas de Inferência Nebulosa (*Fuzzy Inference Systems – FIS*), e se baseiam em regras do tipo “SE... ENTÃO...”, que definem o relacionamento entre os conjuntos nebulosos de entrada e saída.

Supondo que U e V sejam dois universos de discurso, uma *relação nebulosa* $R(U,V)$ é um conjunto no espaço $U \times V$ caracterizado por uma função de pertinência $\mu_R(\mathbf{x}, \mathbf{y})$, onde $\mathbf{x} \in U$ e $\mathbf{y} \in V$. Uma *regra de inferência nebulosa* tem a forma “se $\mathbf{x}$ é A , então $\mathbf{y}$ é B ”, em que a primeira parte (“se $\mathbf{x}$ é A ”) é chamada de *premissa* ou *antecedente* e a segunda parte (“então $\mathbf{y}$ é B ”), é conhecida como *conclusão* ou *consequente*. Tanto as premissas quanto as conclusões podem ser compostas, ou seja, envolver mais de uma variável nebulosa. A Figura 3-12 representa o diagrama em blocos de um Sistema de Inferência Nebulosa.

Figura 3-12 – Diagrama em blocos de um sistema de inferência nebulosa

Lee (1990) enumera os passos para a implantação de um sistema de inferência nebulosa. O primeiro é o desenvolvimento da interface de *fuzzificação*, que é responsável pelo mapeamento entre os valores *crisp* na entrada do sistema e as variáveis nebulosas correspondentes que serão processadas pela máquina de inferência. Isso envolve a medição dos valores das variáveis de entrada, seu mapeamento dentro do universo de discurso correspondente e a determinação da função que converte esses valores de entrada em etiquetas lingüísticas apropriadas.

Em seguida, é necessário montar a base de conhecimento, que é composta por uma base de dados e uma base de *regras de controle nebuloso*. A base de dados provê as definições que permitirão a discretização do universo de discurso, que definirá a granularidade da estratégia de controle; a partição dos espaços de entrada e de saída; e a determinação das funções de pertinência. A base de regras de controle, que compreende o conhecimento do domínio da aplicação e os objetivos da estratégia de controle, é obtida por meio da experiência de um ou mais especialistas ou por meio da análise das ações de controle realizadas pelos operadores. A base de regras deve ser tal que proporcione ao sistema as características de *completeza* (que significa sua capacidade de inferir uma ação de controle apropriada para qualquer estado do processo controlado) e de *consistência* (se os antecedentes de duas regras forem similares, seus conseqüentes também o serão).

O próximo passo é o projeto da *máquina* ou *motor de inferência*, que constitui o núcleo do sistema. Esse módulo é responsável pela determinação do grau com que o antecedente de cada regra é satisfeito, de forma que precedente possa ser computado. A forma como o conseqüente é obtido chama-se *mecanismo de implicação nebulosa*. Como é possível que duas ou mais regras sejam ativadas em paralelo (bastando que a função de pertinência associada ao seu antecedente tenha valor superior a 0), é necessário um que a máquina de inferência proveja um *mecanismo de agregação* que combine as saídas das regras ativadas numa única variável nebulosa. A Figura 3-13 mostra o resultado da agregação de três regras ativadas simultaneamente, com diferentes graus de confiança (valores de função de pertinência) em relação a uma variável **Z**. A área resultante é uma *distribuição de funções de possibilidade*.

Figura 3-13 – Processo de agregação de regras nebulosas

Dentre os motores de inferência existentes, dois se destacam. Um deles é o proposto por Mamdani (1975, *apud* LEE, 1990), que consiste na utilização do operador mínimo como mecanismo de implicação nebulosa e do operador máximo dos mínimos como mecanismo de agregação. O outro é o proposto por Larsen (1980, *apud* LEE, 1990), que usa o produto na implicação e o produto dos máximos na agregação.

Por fim, deve-se definir a estratégia de *defuzzificação*, que é responsável pelo mapeamento entre as variáveis nebulosas produzidas pela máquina de inferência e as variáveis *crisp* a serem apresentadas na saída do sistema. Dentre as técnicas mais utilizadas para a *defuzzificação*, Gomide e Gudwin (1994) destacam:

- Método do Centróide → Também conhecido como COA (*center of area*), é o mais freqüentemente utilizado. O valor *crisp* é calculado como o “centro de gravidade” (centróide) da área determinada pela função de distribuição de possibilidades. Para

uma área descontínua, o valor *crisp* c é dado por:
$$c = \frac{\sum_{i=1}^n y_i \mu_B(y)}{\sum_{i=1}^n \mu_B(y)} \quad (\text{Equação 3-13}),$$

sendo i o número de elementos no universo de discurso e $\mu_B(y)$ a função de pertinência.

- Método da Média dos Máximos → Em existindo mais de um máximo na função de distribuição de possibilidades, esse método de *defuzzificação*, também conhecido como MOM (*mean of maxima*) obtém o valor *crisp* através da média desses máximos, ou seja:

$$c = \sum_{i=1}^n \frac{y_i}{n} \quad (\text{Equação 3-14}).$$

- Critério do Máximo → O valor *crisp* devolvido por esse método é o primeiro ponto em que função de distribuição de possibilidades atinge o seu máximo absoluto. Esse método é também conhecido como MAX.

MANDANI, E. H. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. **International Journal of Man-Machine Studies**, v. 7, n. 1, p. 1-13, 1975.

LARSEN, P.M. Industrial Applications of Fuzzy Logic Control. **International Journal of Man-Machine Studies**, v. 12, n. 1, p. 3-10, 1980.

A Figura 3-14, reproduzida do trabalho de Gomide e Gudwin (1994), mostra os valores *crisp* obtidos com o uso dos três métodos supracitados, para uma dada função de distribuição de possibilidades.

Figura 3-14 – Valores *crisp* obtidos através de diferentes métodos de *defuzzificação*

Gomide e Gudwin (1994) enumeram diversos parâmetros que devem ser definidos no projeto de sistemas de inferência nebulosos, categorizando-os como parâmetros estruturais, que têm valores fixos, e parâmetros de sintonia, cujos valores são variáveis. Segundo esses autores, os parâmetros estruturais compreendem o número de variáveis de entrada e saída, o tipo de operação nebulosa a ser aplicada às variáveis de entrada, as variáveis lingüísticas, o número de partições nebulosas, e a estrutura da base de regras. Os parâmetros de sintonia são o universo de discurso das variáveis, os suportes das funções de pertinência e os ganhos e *offsets* das entradas e saídas.

3.4 Algoritmos Genéticos

Os Algoritmos Genéticos (AG) são métodos adaptativos de busca e otimização cuja operação é baseada nos processos de seleção natural. Os seres vivos eventualmente experimentam alterações genéticas e, quando estas acarretam uma descendência com maiores condições de sobrevivência, acabam por se tornar dominantes entre a população. Caso contrário, a seleção natural se encarregará de extinguir esse código genético. Esse mecanismo

serviu de inspiração para Holland (1975, *apud* KONAK, COIT E SMITH, 2006) no desenvolvimento dos AG. Seu objetivo era investigar os mecanismos de naturais de adaptação e desenvolver métodos para utilizá-los em sistemas computacionais.

Mitchell (1999) afirma que, embora não exista uma definição universalmente aceita pelos pesquisadores da área para diferenciar os AG de outros métodos de Computação Evolucionária, existem alguns elementos comuns a todos os algoritmos denominados “genéticos”: populações de cromossomos, seleção de acordo com a aptidão, cruzamento para produzir novas gerações e mutação aleatória. A Figura 3-15, reproduzida do trabalho de Townsend (2003), representa a estrutura básica de um Algoritmo Genético. Nela podem ser vistos os elementos acima citados.

Figura 3-15 – Fluxograma de um algoritmo gentico elementar

A terminologia empregada em AG , compreensivelmente, bastante similar utilizada em Gentica. Cada uma das possveis solues para um problema conhecida como um *indivduo* ou *cromossomo*, e a cada indivduo atribudo uma pontuao de acordo com a sua *aptido*, ou seja, seu grau de correo ou qualidade como soluo do problema. O conjunto de indivduos conhecido como *populao*. Aos indivduos com maior aptido so dadas melhores condies para a *reproduo*, ou seja, a interao com outros indivduos para a

combinação de seu *código genético*, dando origem a um *descendente* cujas características são uma combinação daquelas apresentadas por seus *pais*. Cada símbolo no código genético (que pode ser uma sequência de bits binários, de números inteiros ou de números em ponto flutuante) é conhecido como um *gene*. Os indivíduos com menor aptidão terão menor probabilidade de se reproduzir e, ao longo de algumas *gerações*, seu código genético acaba sendo extinto. Assim, cada nova geração tende a preservar as melhores características das gerações anteriores, de modo que, se o AG tiver sido corretamente especificado, ele convergirá para uma solução aceitável para o problema em questão.

Goldberg (1989) apresenta diversas peculiaridades que diferenciam os AG de outras técnicas de busca, entre as quais: o fato de usarem regras de transição probabilísticas, ao invés de determinísticas; serem inerentemente paralelos, residindo aí sua principal vantagem; necessitarem apenas das informações sobre a função objetivo e o valor correspondente de aptidão para decidirem a direção na busca da solução; e serem, em geral, de aplicação mais direta do que outros métodos.

No que se refere à aplicabilidade da ferramenta, Townsend (2003) relaciona algumas características dos problemas para os quais os AG são especialmente recomendados:

- Uma técnica de busca robusta é necessária;
- Uma solução quase-ótima é aceitável;
- O espaço de soluções é muito grande para ser percorrido por outros métodos;
- Suas soluções potenciais são facilmente representáveis;
- A avaliação de cada solução potencial é factível;
- É possível definir uma função de aptidão para as soluções potenciais;
- Essa função de aptidão é sujeita a ruídos;
- É possível utilizar processamento paralelo na busca da solução.

Mitchell (1999) argumenta que ainda que o problema não tenha essas características, isso não permite afirmar que um AG seja menos eficiente que outras técnicas na busca de sua solução. Segundo ela, a eficiência de um AG está diretamente relacionada com a forma como ele é desenvolvido, e a pesquisa teórica baseada meramente nas características do problema abordado ainda não foi capaz de produzir prognósticos acurados quanto ao desempenho da ferramenta.

3.4.1 Roteiro Para o Desenvolvimento de um Algoritmo Genético

Para que um problema possa ser atacado por meio de AG, é necessário desenvolver uma codificação de suas possíveis soluções. De acordo com Mitchell (1999), esse é o principal fator determinante para o desempenho de um AG. Segundo ela, determinar o melhor esquema de codificação pode ser quase tão trabalhoso quanto a própria solução do problema. Holland (1975) e seus colaboradores utilizaram originalmente a codificação binária, ou seja, os cromossomos eram constituídos por seqüências de “0” e “1”, de tamanho fixo. Mitchell (1999) argumenta que, a despeito de sua simplicidade (ou exatamente por essa razão), a codificação binária é inadequada para vários problemas. Por isso, outros paradigmas de codificação foram desenvolvidos, entre os quais a codificação com múltiplos caracteres, com números inteiros, com números em ponto flutuante e com árvores binárias.

Uma vez decidida a forma de codificação das soluções, o passo seguinte é a determinação do método de seleção, isto é, a escolha dos cromossomos que participarão do processo de reprodução. A idéia é escolher os indivíduos com maior aptidão, esperando-se que seus descendentes sejam ainda mais aptos. Existem diversos métodos de seleção, entre os quais o método da roleta (*roulette wheel*), o método da fileira (*rank*) e o método do torneio (*tournament*). Em adição aos métodos de seleção, utiliza-se por vezes a chamada técnica elitista (*elitism*), através da qual se retêm alguns dos melhores cromossomos da população, evitando que seus genes se percam caso não sejam selecionados para a reprodução. Pesquisadores como Laumanns, Zitzler e Thiele (2001) e Ahn e Ramakrishna (2003) têm constatado que essa técnica aumenta consideravelmente o desempenho de um AG.

Selecionados os indivíduos para a reprodução, faz-se necessário determinar a maneira como essa se efetivará, ou seja, o tipo de recombinação que dará origem à descendência. Isso se faz através dos chamados *operadores genéticos*. Eles garantem a diversidade dos indivíduos, o que equivale a explorar de forma mais completa o espaço de soluções.

O principal operador genético é o *cruzamento* (*crossover*). Existem diversas modalidades de cruzamento. Na mais comum, escolhe-se aleatoriamente um determinado número de posições na cadeia de codificação dos indivíduos que se reproduzem e as partes das cadeias que ficam entre essas posições são intercambiadas entre os indivíduos. Pesquisadores como Eshelman, Caruana e Schaffer (1989) afirmam que a escolha de um único ponto de cruzamento tende a reduzir o desempenho do AG, preconizando a escolha de

pelo menos dois pontos. Noutra modalidade, chamada de cruzamento uniforme, a troca de genes entre os indivíduos é determinada através de uma máscara de bits aleatórios, de comprimento igual ao dos cromossomos. Se o bit numa posição dessa máscara tiver valor “0”, um dos indivíduos descendentes recebe nessa posição o gene de um dos indivíduos pai; se tiver valor “1”, recebe o gene do outro indivíduo pai. Com relação ao outro indivíduo descendente, ocorre exatamente o oposto. Esses esquemas de cruzamento estão representados na Figura 3-16, na qual **X1** e **X2** são os indivíduos-pai e **Y1** e **Y2** são os descendentes.

Figura 3-16 – Algumas modalidades de cruzamento em algoritmos genéticos

Outro importante operador genético, e que não implica em interações de indivíduos, é a *mutação*. Por meio dela, um ou mais genes de um indivíduo são alterados, gerando dessa forma novos cromossomos. A Figura 3-17 mostra o princípio do operador de mutação.

Figura 3-17 – Operador genético de mutação

A mutação reduz a possibilidade de convergência prematura do AG, o que pode indicar uma solução sub-ótima, além de assegurar probabilidade não-nula para a busca de todos os pontos do espaço de soluções. Em geral, a mutação é aplicada à população após o cruzamento.

Relativamente ao cruzamento e à mutação, não há consenso sobre a preeminência de um desses operadores. Embora boa parte dos pesquisadores atribua maior importância ao cruzamento, outros métodos de Computação Evolucionária utilizam apenas (ou principalmente) a mutação. Na visão de Mitchell (1999):

Não é uma escolha entre cruzamento ou mutação, mas é antes o equilíbrio entre cruzamento, mutação e seleção o que importa. O equilíbrio correto também depende de detalhes sobre a função de aptidão e a codificação. Além disso, cruzamento e mutação variam em utilidade relativa durante a execução (de um AG). Precisamente como tudo isso ocorre ainda precisa ser elucidado. Em minha opinião, a perspectiva mais promissora para produzir o equilíbrio correto ao longo de uma execução é encontrar formas pelas quais o AG adapte suas próprias taxas de mutação e cruzamento durante uma busca.

A última etapa no desenvolvimento de um AG é a escolha dos vários parâmetros que governam a execução do algoritmo, entre os quais o tamanho da população inicial, o tipo e a taxa de cruzamento e a taxa de mutação. Sendo que esses parâmetros influenciam uns aos outros de modo não-linear, não é possível modificá-los simultaneamente. Sendo que não existem estudos conclusivos sobre a melhor forma de estabelecer ou adaptar esses parâmetros, o curso de ação mais indicado é seguir procedimento semelhante ao adotado em casos bem sucedidos reportados na literatura.

3.5 Utilização Conjunta das Ferramentas

A complementaridade entre as técnicas de IC tem sido demonstrada por diversos pesquisadores. Segundo Shapiro (2002), devido às suas limitações inerentes, a utilização isolada de Redes Neurais Artificiais, de Lógica Nebulosa ou de Algoritmos Genéticos alcança de forma incompleta os princípios de tolerância à imprecisão, à incerteza e à verdade apenas parcial, na busca de soluções tratáveis, robustas e de baixo custo. Dessa forma, a fusão dessas técnicas de forma sinérgica permite reforçar seus pontos positivos e compensar seus pontos negativos.

Descrevendo o processo que levou a tal integração, Bonissone (1997) afirma que inicialmente cada técnica era bem rotulada e identificada com comunidades científicas específicas. À medida que o conhecimento sobre as virtudes e deficiências de cada ferramenta se aprofundava, começaram a ser desenvolvidos algoritmos híbridos, com resultados superiores aos obtidos com seus componentes individuais. A Figura 3-18, reproduzida do trabalho desse autor, mostra as diversas formas de fusão entre as tecnologias.

Figura 3-18 – Fusão entre as tecnologias de inteligência computacional

No editorial de um número da revista *Expert Systems*, especialmente dedicado a apresentar o potencial dos sistemas híbridos de Inteligência Computacional, Xu (1999) justifica essa hibridização com base nas dificuldades com que os pesquisadores se defrontam ao tentarem modelar a complexidade dos problemas do “mundo real” utilizando uma única técnica. Segundo esse autor, a abordagem híbrida já havia alcançado, à época da publicação, o ponto em que sistemas práticos já estavam em operação bem sucedida, trazendo economia e lucros para a indústria e os negócios em geral.

Traçando um histórico do desenvolvimento de aplicações híbridas, Takagi (2000) data de 1974 o primeiro artigo com os termos “*redes neurais*” e “*conjuntos nebulosos*” constando simultaneamente da lista de palavras-chave. A pesquisa sobre a fusão dessas duas tecnologias tomou impulso no final da década de 1980, experimentando grande crescimento desde então. Tal movimento, segundo o autor, começou no Japão, que já possuía um histórico de aplicações comerciais bem sucedidas de Lógica Nebulosa, espalhando-se daí para os Estados Unidos e a Europa. Pouco tempo depois, os Algoritmos Genéticos foram incorporados nesse processo de fusão de tecnologias. A Figura 3-19, reproduzida do trabalho de Takagi (2000), mostra a evolução no número de artigos e conferências relacionados à hibridização de tecnologias de IC (especificamente RNA e LN) durante as três últimas décadas do século XX. A escala do lado esquerdo refere-se aos artigos e a do lado direito, às conferências.

Figura 3-19 – Artigos e conferências sobre fusão de tecnologias no final do século XX

3.6 Aplicação de Inteligência Computacional no Processo de Laminação

A complexidade do processo de laminação, o relacionamento não-linear entre suas variáveis, o conhecimento incompleto dos fenômenos que o regem, a abundância de dados e a experiência acumulada ao longo dos anos, são características que tornam as ferramentas de Inteligência Computacional especialmente apropriadas à sua abordagem. Essa adequação tem sido confirmada pelo crescente número de aplicações nessa área. Para se ter uma idéia magnitude desse crescimento, enquanto Iida, Urakami e Iwamura (1993), numa pesquisa minuciosa reportam uma aplicação (de Lógica Nebulosa) na área de laminação, Gorni (1998), num artigo escrito apenas cinco anos após, reporta nada menos do que onze aplicações, somente de RNA e somente na laminação a quente.

As aplicações baseadas em RNA são, de longe, as mais comuns e as que abrangem o maior leque de aspectos específicos da laminação. Trabalhos como os de Larkiola *et al.* (1996), de Cho, Cho e Yoon (1997), de Singh *et al.* (1998) e de Schlang *et al.* (2001) relatam o uso de RNA em conjunto com modelos matemáticos (ou seja, na otimização) para aperfeiçoar a capacidade de previsão dos valores de uma ou mais variáveis importantes. Nos trabalhos reportados por Hattori, Nakajima e Katayama (1992), por Sbarbaro-Hofer, Neumerkel e Hunt (1993) e por Rossomando, Ferreira e Denti Filho (2005) as RNA são utilizadas no controle em tempo real. Essas são apenas algumas das muitas referências.

Larkiola *et al.* (1998) datam de 1991 a publicação do primeiro artigo versando sobre a aplicação de RNA no processo de laminação. A partir de então, esses pesquisadores traçaram a evolução do número de aplicações publicadas durante os cinco anos seguintes, chegando ao gráfico que é reproduzido na Figura 3-20.

Figura 3-20 – Evolução do número de artigos sobre RNA no processo de laminação

Em segundo lugar entre as mais numerosas vêm as aplicações baseadas em Lógica Nebulosa. Jung, Im e Lee-Kwang (1995) realizaram a modelagem e o controle de forma para tiras laminadas a frio através de um sistema de inferência nebulosa. Sharma e Parfitt (1998) usam essa ferramenta em conjunto com o controle convencional, para melhorar a performance de espessura de um laminador a frio durante as transições na velocidade de laminação. Zhu *et al.* (2003) obtiveram melhoria de desempenho no controle de planicidade de um laminador de tiras a quente ao associarem um controlador nebuloso ao controle PID convencional. Janabi-Sharif e Fan (2000), Yingjie *et al.* (2001) e Ferreira (2005) a empregam para o controle. Mais recentemente, Xie *et al.* (2007) reportaram a utilização da Lógica Nebulosa no controle do resfriamento laminar num laminador de tiras a quente.

Existem também diversos registros de aplicações de algoritmos genéticos no processo de laminação. Denti Filho, Fardim e Silva (2000) utilizaram esta técnica para o controle de espessura num laminador de tiras a frio, com um mínimo de comprometimento da planicidade. Brezocnik, Balic e Kampus (2001) relatam o uso dessa ferramenta para a estimativa do limite de escoamento de materiais metálicos. Chung *et al.* (2002) abordaram o problema de quebra de bordas num laminador de tiras a frio. Wang, Tieu e D'Alessio (2005) propõem algoritmos genéticos para a obtenção do esquema ótimo para um laminador de tiras a frio. Nandan *et al.* (2005) otimizaram o controle de coroamento e planicidade de tiras

laminadas a quente. Chakraborti *et al.* (2006) aplicam algoritmos genéticos na modelagem da coroa de esboços laminados a quente.

Além dos vários trabalhos registrando a utilização isolada de uma dessas ferramentas, existem vários outros em que elas são aplicadas de forma conjunta, em todas as combinações possíveis: sistemas *neurofuzzy* (DIXIT E CHANDRA, 2003) (MENDEZ *ET AL.*, 2005), sistemas *neuroevolutivos* (SON *ET AL.*, 2004), sistemas *fuzzyevolutivos* (JANABI-SHARIF E LIU, 2002) e sistemas *neurofuzzyevolutivos* (JANABI-SHARIF E LIU, 2005). Já em meados da década de 90 foram publicados artigos versando sobre o processo de laminação com o relato de aplicação combinada de técnicas de Inteligência Computacional, como, por exemplo, o trabalho de Xiaoguang *et al.* (1996).

A presente pesquisa foi estimulada pela aplicação bem sucedida dessas técnicas em aplicações semelhantes àquela de que trata esta tese.

Capítulo 4 – METODOLOGIA DE DESENVOLVIMENTO

Descrevem-se neste capítulo os materiais e métodos utilizados na busca da solução para o problema proposto. Na abordagem inicial, após a coleta de dados, foram desenvolvidos dois conjuntos de redes neurais, um para a estimativa do limite de escoamento e outro para a estimativa do coeficiente de atrito, para cada uma das cadeiras do laminador. Os resultados obtidos por meio desses conjuntos de redes neurais substituíram os valores originalmente utilizados pelo modelo de força e as referências assim calculadas foram comparadas com as referências originais. Nessa fase do trabalho, a utilização das RNA é feita *off-line*, ou seja, sem interação com o processo produtivo.

4.1 Estratégia de Abordagem

Delimitando a abrangência deste trabalho, o objetivo é aperfeiçoar a capacidade preditiva do sub-modelo de força, o principal dentre os diversos incluídos no modelo de otimização do processo, por meio da utilização de redes neurais para a adaptação do limite de escoamento e do coeficiente de atrito, variáveis que possuem grande influência sobre esse sub-modelo. A Figura 4-1 representa a configuração final projetada para o sistema.

Figura 4-1 – Localização do sistema de adaptação proposto no contexto do sistema atual

Como se pode depreender da figura, não se cogita a substituição definitiva do sistema convencional de adaptação utilizado na planta, mas proporcionar um sistema alternativo que possa ser utilizado nas condições em que apresentar resultados comprovadamente superiores.

4.2 Coleta de Dados

Dados são essenciais para o desenvolvimento de sistemas baseados em RNA. De acordo com Zhang, Patuwo e Hu (1998), RNA são adequadas para problemas que envolvam conhecimento de explicitação complexa, mas para os quais existam suficientes dados ou observações. A quantidade e a qualidade desses dados são determinantes na viabilidade da abordagem de um problema através desse instrumento, bem como na escolha da topologia da RNA a ser empregada.

Os dados necessários para o desenvolvimento se dividem nas seguintes categorias:

- Dados primários → Tratam-se de informações conhecidas *a priori* pelo nível corporativo. Estão relacionados com as dimensões e composição química da matéria-prima e com as dimensões e características de qualidade objetivadas para o produto. As espessuras de entrada e saída, o tipo de aplainamento e o código de estampagem são exemplos de dados primários.
- Dados de operação → Tratam-se de diretivas para o processamento do material, que o operador informa ao sistema de automação imediatamente antes da produção efetiva. O nível corporativo não tem conhecimento prévio acerca desse tipo de dados. A força de laminação imposta na última cadeira é um exemplo de dado de operação.
- Dados de equipamento → Tratam-se de parâmetros próprios da planta, relativos a dimensões, limites aceitáveis para certas grandezas, etc. Entre os dados de equipamento incluem-se informações sobre os cilindros de laminação (diâmetro, coroa, dureza, etc.). Tais dados são conhecidos antes do processamento do material.
- Dados de modelo → Tratam-se basicamente dos *presets*, ou seja, os valores calculados pelo modelo matemático, levando em conta os dados primários, os dados de operação e as características estáticas e dinâmicas da planta. Entre os dados de modelo incluem-se a força de laminação nas diversas cadeiras e a velocidade linear da tira nos diversos vãos.

- Dados de processo → Tratam-se dos valores efetivos das diversas variáveis relevantes para o desenvolvimento das diversas redes neurais. Em geral, tais valores são obtidos pelos sensores do Nível 0 de automação, e, através do Nível 1, chegam ao Nível 2, onde são armazenados. Alguns desses dados, ao invés de medidos, são calculados.

Conforme exposto no Capítulo 1, a arquitetura de automação da planta inclui uma base relacional de dados históricos, que armazena as informações por um prazo mínimo de dois anos de produção. Essa base de dados é formada por 58 tabelas. As bases utilizadas neste trabalho foram:

- LTF_ROLO_PDI → Contém os dados primários das bobinas a serem laminadas, com exceção da composição química.
- LTF_ROLO_COMP_QUIMICA → Contém os elementos presentes na composição química das bobinas, especificando a concentração de cada um deles.
- LTF_ROLO_PRESET_CADEIRA → Armazena, para cada bobina laminada, os valores de referências calculadas para as cadeiras.
- LTF_ROLO_PRESET_ZONA → Armazena, para cada bobina laminada, os valores de referências calculadas para os vãos.
- LTF_ROLO_PROCESSO → Entre outros valores, armazena as informações sobre os cilindros de laminação (quilometragem laminada, peso laminado e coroa).
- LTF_ROLO_MEDICAO_CADEIRA → Para cada bobina laminada, armazena os valores reais (medidos, calculados ou obtidos através de modelos inversos) das variáveis relevantes nas quatro cadeiras.
- LTF_ROLO_MEDICAO_ZONA → Para cada bobina laminada, armazena os valores reais (medidos, calculados ou obtidos através de modelos inversos) das variáveis relevantes nos quatro vãos.
- LTF_ROLO_SIGMA → Contém os valores dos coeficientes adaptativos utilizados pelo modelo para estimar o limite de escoamento.
- LTF_WEB_CILINDRO → Armazena as informações atuais sobre os cilindros instalados no laminador.

A utilização de um RDBMS, como o Oracle®, facilita sobremaneira o pré-tratamento dos dados. Por meio da formulação adequada do comando SQL de consulta à base, a exclusão de eventuais registros com valores incoerentes ou fora da faixa permitida é feita automaticamente. Além disso, os comandos SQL permitem a classificação dos dados, sua ordenação e a obtenção de informações secundárias provenientes de operações entre duas ou mais informações primárias. Torna-se desnecessário, portanto, o emprego de pacotes especializados de pré-processamento, como o DataSculptor®, utilizado por Santos Filho e Ramirez-Fernandez (2003).

4.3 Desenvolvimento das Redes Neurais

Primeiramente foi desenvolvido um conjunto de redes neurais (uma para cada cadeira) para a obtenção do limite de escoamento e em seguida outro conjunto para a determinação do coeficiente de atrito. O desenvolvimento das redes teve que ser feito nessa ordem, visto que o limite de escoamento serve como uma das entradas das redes que determinam o coeficiente de atrito. Tanto o limite de escoamento como o coeficiente de atrito são dados de processo que não podem ser medidos diretamente. Desse modo, os valores considerados como objetivos para as variáveis de saída das duas redes são os calculados de modo inverso pelo modelo de otimização, e que são armazenados na tabela LTF_ROLO_MEDICAO_CADEIRA.

4.3.1 Desenvolvimento das RNA para Determinação do Limite de Escoamento

De acordo com a revisão bibliográfica, os fatores de maior influência sobre o limite de escoamento dos aços laminados a frio são a deformação experimentada pelo material, a taxa em que essa deformação ocorre e a composição química. Embora a temperatura também tenha influência sobre essa grandeza, no caso específico da laminação a frio ocorre pouca variação de temperatura de uma bobina para outra, de forma que essa grandeza não é especialmente relevante numa modelagem por meio de redes neurais.

No caso do laminador estudado, até 40 elementos podem estar presentes na composição química das bobinas de entrada, e a utilização de todos eles aumentaria a dimensionalidade da rede de forma inaceitável. Por essa razão, apenas os elementos de maior influência foram levados em conta. Ozerdem e Kolukisa (2008), num trabalho semelhante, utilizaram o carbono, o silício e o manganês. A estes três elementos, Vallim (2008) acrescentou o cromo e o cobre. Bèle *et al.* (2004) acrescentam fósforo, enxofre, alumínio,

molibdênio, estanho, nióbio, vanádio, boro e titânio. A Figura 4-2 apresenta a tela de operação que possibilita a visualização da composição química da bobina.

Figura 4-2 – Visualização da composição química de uma bobina

A experiência dos analistas de processo da planta aponta, no caso específico do laminador de tiras a frio, o carbono, o manganês, o silício, o titânio, o alumínio e o molibdênio como os elementos mais relevantes na determinação do limite de escoamento. Tal informação está em conformidade com a obtida pela revisão bibliográfica. Assim sendo, apenas estes seis elementos foram incluídos no conjunto de entradas das redes.

Os experimentos mostraram a necessidade de incluir no conjunto de entradas não apenas a deformação verdadeira (ϵ), mas também os valores absolutos das espessuras de entrada e de saída da tira. A informação sobre taxa de deformação é levada em conta de forma indireta, através da inclusão da velocidade de laminação e do diâmetro dos cilindros de trabalho no conjunto de entradas da rede. Esse procedimento está em conformidade com o preconizado por Miranda, Barbosa e Cunha (1993), que propõem a seguinte equação para o cálculo da taxa de deformação:

$$\dot{\epsilon} = \frac{\epsilon \times v}{\sqrt{\frac{D \times \Delta h}{2}}} \quad (\text{Equação 4-1}).$$

Na equação acima, v é a velocidade periférica dos cilindros de trabalho, D é o seu diâmetro e Δh é a variação de espessura.

Por fim, para levar em conta as condições de laminação a quente do material, que têm grande influência na microestrutura da tira, foi incluída a informação sobre temperatura de bobinamento. A temperatura de acabamento durante a laminação a quente, que seria igualmente relevante, não foi incluída no conjunto de entradas pelo fato de não estar armazenada na base de dados da planta. Dessa forma, cada rede utiliza um total de doze entradas, a saber: as espessuras de entrada e saída, a deformação real, a temperatura de bobinamento, a velocidade de laminação, o diâmetro dos cilindros de trabalho e os teores de carbono, manganês, alumínio, silício, titânio e molibdênio. Dessas variáveis, apenas a velocidade de laminação, a espessura de entrada (para as cadeiras 2, 3 e 4) e a espessura de saída (para as cadeiras 1, 2 e 3) são dados de processo – todas as demais são dados primários.

Os experimentos foram conduzidos durante os meses de maio e junho de 2009, ou seja, entre nove e dez meses de operação da planta desde a reforma, de modo que a pesquisa da base de dados foi limitada a um intervalo de 180 dias, abrangendo dessa forma materiais processados pelo menos três meses após a reforma, período em que a curva de aprendizagem do novo modelo já teria um acerto adequado. Na eventualidade de registros que contivessem exatamente os mesmos valores para as doze entradas e valores diferentes para a saída (o que caracterizaria a presença de padrões conflitantes para o treinamento da rede), adotou-se o critério de se utilizar o registro relativo à bobina mais recente, para o qual as previsões do modelo podem ser consideradas mais acertadas, devido às suas características adaptativas. As consultas foram executadas através do utilitário SQL Explorer®. A formulação dos comandos SQL utilizados (particularizando as cláusulas para a cadeira específica) para obter os dados relevantes para o treinamento das redes foi:

```
SELECT      tab1.dt_evento DATA, pdi.cd_comp_quimica COD, tab1.nr_rol_1tf ID,
            zon.ep_entrada_lam_c1 EP_ENT, zon.ep_saida_lam_c1 EP_SAI,
            pdi.tm_bobinamento BOB, zon.vl_vel_cilindro_lam_c1 VEL,
            tab1.vl_elemento C, tab2.vl_elemento Mn, tab3.vl_elemento Al,
            tab4.vl_elemento Si, tab5.vl_elemento Ti, tab6.vl_elemento Mo,
            0.5 * (tab_cil_sup.dm_cilindro + tab_cil_inf.dm_cilindro) DIAM,
            sig.vl_a_atual A, sig.vl_b_atual B, sig.vl_sigma0 SIGMA0

FROM        (SELECT * from ltf_rol_comp_quimica WHERE nm_elemento = 'C ') tab1,
```

```

(SELECT * from ltf_rolcomp_quimica WHERE nm_elemento = 'Mn') tab2,
(SELECT * from ltf_rolcomp_quimica WHERE nm_elemento = 'Al') tab3,
(SELECT * from ltf_rolcomp_quimica WHERE nm_elemento = 'Si') tab4,
(SELECT * from ltf_rolcomp_quimica WHERE nm_elemento = 'Ti') tab5,
(SELECT * from ltf_rolcomp_quimica WHERE nm_elemento = 'Mo') tab6,
ltf_rolpdi pdi, ltf_rolsigma sig, ltf_rolmedicao_cadeira zon,

(SELECT      nr_rol_ltf, dt_evento, nr_cilindro, dm_cilindro,
             vl_coroa, vl_rugosidade, vl_dureza
FROM          ltf_rolpdi, ltf_troca_cilindro

WHERE         dt_evento between dt_montagem AND dt_troca
              AND dt_evento between sysdate - 180 AND sysdate
              AND cd_cadeira = 1 AND cd_posicao = 'TS') tab_cil_sup,

(SELECT      nr_rol_ltf, dt_evento, nr_cilindro, dm_cilindro,
             vl_coroa, vl_rugosidade, vl_dureza
FROM          ltf_rolpdi, ltf_troca_cilindro

WHERE         dt_evento BETWEEN dt_montagem AND dt_troca
              AND dt_evento BETWEEN sysdate - 180 AND sysdate
              AND cd_cadeira = 1 AND cd_posicao = 'TI') tab_cil_inf

WHERE         tab1.nr_rol_ltf = tab2.nr_rol_ltf
AND           tab1.nr_rol_ltf = tab3.nr_rol_ltf
AND           tab1.nr_rol_ltf = tab4.nr_rol_ltf
AND           tab1.nr_rol_ltf = tab5.nr_rol_ltf
AND           tab1.nr_rol_ltf = pdi.nr_rol_ltf
AND           tab1.nr_rol_ltf = sig.nr_rol_ltf
AND           tab1.nr_rol_ltf = zon.nr_rol_ltf
AND           tab1.nr_rol_ltf = zon.nr_rol_ltf
AND           tab1.dt_evento = tab_cil_sup.dt_evento(+)
AND           tab1.dt_evento = tab_cil_inf.dt_evento(+)
AND           tab1.dt_evento = tab2.dt_evento
AND           tab1.dt_evento = tab3.dt_evento
AND           tab1.dt_evento = tab4.dt_evento
AND           tab1.dt_evento = tab5.dt_evento
AND           tab1.dt_evento = tab6.dt_evento
AND           tab1.dt_evento = pdi.dt_evento
AND           tab1.dt_evento = sig.dt_evento
AND           tab1.dt_evento = zon.dt_evento
AND           tab1.dt_evento > sysdate - 180
AND           zon.ep_entrada_lam_c1 > zon.ep_saida_lam_c1
AND           zon.ep_entrada_lam_c1 > 0
AND           pdi.tm_bobinamento > 500
AND           tab_cil_sup.dm_cilindro > 300
AND           tab_cil_inf.dm_cilindro > 300

ORDER BY      tab1.dt_evento, pdi.cd_comp_quimica, pdi.tm_bobinamento,
              zon.ep_entrada_lam_c1, zon.ep_saida_lam_c1,
              zon.vl_vel_cilindro_lam_c1, tab1.vl_elemento, tab2.vl_elemento,
              tab3.vl_elemento, tab4.vl_elemento, tab5.vl_elemento,
              tab6.vl_elemento, sig.vl_a_atual, sig.vl_b_atual, sig.vl_sigma0

```

Note-se que a cláusula WHERE do comando permite delimitar com precisão quais são os valores considerados corretos e coerentes para o objetivo em questão, de modo que registros contendo dados defeituosos são automaticamente rejeitados. Essa técnica eliminou a necessidade de exame posterior da massa de dados para remoção de registros inconsistentes, reduzindo o tempo dos experimentos. Foram obtidos 12479 registros válidos para primeira cadeira, 12342 para a segunda cadeira, 12363 para a terceira e 12315 para a quarta cadeira.

Os dados foram exportados para planilhas Excel® e em seguida utilizados para o treinamento das redes através da *toolbox* Automated Neural Networks do utilitário Statistica®. Embora a *toolbox* de redes neurais do utilitário Matlab® também estivesse

disponível, optou-se pelo Statistica® como ferramenta para o treinamento das redes em virtude de suas características autônomas de operação. Uma vez informado sobre o tipo de problema a ser abordado com a RNA (regressão, classificação ou série temporal), sobre o tipo de rede a ser experimentado (MLP e/ou RBF) e sobre os limites desejados para o número de unidades ocultas, esse utilitário treina automaticamente um número arbitrário de redes-candidatas, salvando aquelas que apresentarem os melhores resultados. Dessa forma, o processo de tentativa e erro que caracteriza o desenvolvimento de aplicações envolvendo redes neurais é consideravelmente simplificado.

Outras características positivas deste utilitário são a geração de um código C de grande portabilidade, a disponibilidade de ferramentas para a realização de uma minuciosa análise estatística das variáveis, pré-processamento das variáveis de entrada e pós-processamento das variáveis de saída de forma transparente ao usuário. Como desvantagem em relação à *toolbox* correspondente do Matlab®, ele não oferece flexibilidade em relação ao número de camadas ocultas (admite apenas uma), nem em relação a algoritmos de treinamento (utiliza apenas a retropropagação de erros em conjunto com o algoritmo de otimização BFGS). As figuras seguintes mostram algumas das telas de configuração do utilitário.

Figura 4-3 – Tela para seleção do tipo de análise

Figura 4-4 – Tela para seleção de variáveis de entrada e saída

Figura 4-5 – Tela para separação dos padrões de treinamento

Figura 4-6 – Tela para configuração das redes a serem treinadas e retidas

Figura 4-7 – Tela para seleção das funções de ativação

A Figura 4-8 mostra a tela do aplicativo durante uma sessão de treinamento.

Figura 4-8 – Tela da *toolbox* do Statistica® durante uma sessão de treinamento

O utilitário foi configurado para treinar, para cada uma das quatro cadeiras, 20 redes com a arquitetura MLP, com um mínimo de 10 e um máximo de 30 unidades na camada oculta, retraindo as 5 melhores redes. Como funções de ativação das unidades em cada camada foram pré-selecionadas as funções logística, tangente hiperbólica e identidade. Foi descartada a opção de redes RBF, devido ao número elevado de centros propostos pelo utilitário de treinamento. Os dados disponíveis foram divididos nos conjuntos de treinamento (78% dos dados), de teste (17% dos dados) e de validação (5% dos dados).

As tabelas seguintes apresentam as características (topologia, correlação entre os resultados e os valores objetivados e erro) das cinco melhores soluções obtidas para cada uma das cadeiras. Imediatamente após cada uma das tabelas, o coeficiente de correlação e o resíduo (desvio percentual entre os valores calculados e objetivados do limite de escoamento, em MPa) das redes são apresentados em forma gráfica. A não ser nos casos em que uma das redes apresentou resultado nitidamente superior ao das outras quatro, a base de escolha foi a simplicidade da arquitetura (menor número de unidades na camada oculta).

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	37	0,9619	0,9540	0,0007	0,0008	BFGS/174	logística	logística
2	45	0,9608	0,9547	0,0007	0,0008	BFGS/188	tanh	tanh
3	27	0,9599	0,9545	0,0007	0,0008	BFGS/205	logística	tanh
4	45	0,9599	0,9536	0,0007	0,0008	BFGS/176	logística	tanh
5	26	0,9636	0,9560	0,0006	0,0007	BFGS/361	logística	identidade

Tabela 4-1 – Redes para o limite de escoamento da cadeira 1

Figura 4-9 – Visualização do desempenho das redes para escoamento da cadeira 1

Figura 4-10 – Visualização dos resíduos das redes para o escoamento da cadeira 1

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	25	0,9398	0,9300	0,0012	0,0012	BFGS/37	logística	logística
2	30	0,9397	0,9312	0,0012	0,0012	BFGS/31	logística	logística
3	35	0,9407	0,9283	0,0012	0,0012	BFGS/39	logística	logística
4	33	0,9391	0,9292	0,0012	0,0012	BFGS/23	logística	tanh
5	19	0,9400	0,9285	0,0012	0,0012	BFGS/34	logística	tanh

Tabela 4-2 – Redes para o limite de escoamento da cadeira 2

Figura 4-11 – Visualização do desempenho das redes para escoamento da cadeira 2

Figura 4-12 – Visualização dos resíduos das redes para o escoamento da cadeira 2

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	38	0,9583	0,9575	0,0005	0,0005	BFGS/361	logística	tanh
2	28	0,9590	0,9583	0,0005	0,0005	BFGS/372	tanh	identidade
3	35	0,9604	0,9587	0,0005	0,0005	BFGS/362	tanh	logística
4	23	0,9551	0,9549	0,0005	0,0006	BFGS/311	tanh	tanh
5	38	0,9569	0,9567	0,0005	0,0005	BFGS/270	tanh	logística

Tabela 4-3 – Redes para o limite de escoamento da cadeira 3

Figura 4-13 – Visualização do desempenho das redes para escoamento da cadeira 3

Figura 4-14 – Visualização dos resíduos das redes para o escoamento da cadeira 3

R e d e	Unidades na camada oculta	Desempenho do conjunto de treinamento	Desempenho do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	16	0,9047	0,8780	0,0009	0,0012	BFGS/180	tanh	logística
2	30	0,8963	0,8758	0,0010	0,0012	BFGS/170	tanh	logística
3	30	0,9010	0,8780	0,0010	0,0012	BFGS/263	tanh	identidade
4	19	0,9025	0,8767	0,0009	0,0012	BFGS/170	tanh	logística
5	23	0,8999	0,8766	0,0010	0,0012	BFGS/212	logística	logística

Tabela 4-4 – Redes para o limite de escoamento da cadeira 4

Figura 4-15 – Visualização do desempenho das redes para escoamento da cadeira 4

Figura 4-16 – Visualização dos resíduos das redes para o escoamento da cadeira 4

A maior vantagem da abordagem adotada em relação à estratégia existente de adaptação é o fato de levar em conta não apenas o tipo do aço, mas a sua composição química específica. O sistema de adaptação existente particulariza suas fórmulas de regressão apenas em função do tipo do aço, que é uma classificação que agrupa materiais de composição química correlata, mas não necessariamente idêntica. Desse modo, é possível que aços com diferentes teores de elementos de liga sejam modelados como possuindo o mesmo limite de escoamento, bastando para isso que eles tenham sido classificados sob o mesmo código de tipo de aço.

Outra vantagem da adaptação do limite de escoamento através de RNA é a aplicação imediata de seus resultados às novas tiras a serem produzidas, independentemente do tipo de material. Como exposto no Capítulo 2, a rotina de adaptação no esquema atual, que obtém os novos valores dos parâmetros de regressão utilizados para a estimativa do limite de escoamento, é executada aproximadamente a cada 12 horas. Por isso, o aperfeiçoamento do modelo (nesse aspecto específico) se dá em intervalos discretos, ao invés de ser contínuo.

As figuras das páginas seguintes mostram a evolução da estimativa do limite de escoamento sob o esquema existente de adaptação num período de dois dias (quatro execuções da rotina de adaptação), para o aço codificado como “**181080**”. Note-se nas figuras o incremento no número de pontos (informação “*Nb Points*”), que corresponde ao número de tiras constituídas por esse tipo de material, laminadas até o momento de execução da rotina. Outra informação digna de nota é o erro médio dos pontos em relação à curva (em vermelho) adotada como referência (informação “*EcartType*”).

Como mostram os gráficos, os valores de deformação real se situam na faixa entre 0,1 e 1,9. Para fins de comparação, a Tabela 4-5 mostra os valores máximos e mínimos de deformação real (ϵ) por cadeira, segundo consulta à base histórica de dados da planta, no período de agosto a outubro de 2008 (primeiros três meses do comissionamento do novo sistema de automação e controle), compreendendo cerca de 13000 bobinas.

Cadeira	Mínima deformação real	Máxima deformação real
1	0,2000	0,7160
2	0,0734	0,6579
3	0,0503	0,5845
4	0,0001	0,2287

Tabela 4-5 – Limites de redução nas cadeiras do laminador

Figura 4-17 – Curva de regressão para o limite de escoamento (execução n)

Figura 4-18 – Curva de regressão para o limite de escoamento (execução n+1)

Figura 4-19 – Curva de regressão para o limite de escoamento (execução n+2)

Figura 4-20 – Curva de regressão para o limite de escoamento (execução n+3)

A faixa de valores de deformação real para a Cadeira 4 ocupa justamente a região da curva de regressão que possui a não-linearidade mais acentuada.

4.3.2 Desenvolvimento das RNA para Determinação do Coeficiente de Atrito

Da mesma forma como para a determinação do limite de escoamento, para a estimativa do coeficiente de atrito foi desenvolvida uma rede neural específica para cada uma das quatro cadeiras do laminador. De acordo com a estratégia adotada, uma das variáveis de entrada para essas redes foi o limite de escoamento. O valor para essa grandeza foi aquele calculado pelo modelo por meio de modelagem inversa.

No caso da modelagem do coeficiente de atrito por meio de redes neurais, os experimentos mostraram a necessidade de incluir um número de dados de processo maior do que no caso das redes para a estimativa do limite de escoamento. Além dos dados de processo já utilizados no caso anterior (as espessuras de entrada e saída e a velocidade de laminação), foi necessário incluir no conjunto de entradas das redes a força de laminação e as tensões avante e à ré. As tentativas de modelagem excluindo essas variáveis apresentaram correlação muito baixa, que inviabilizaria a consecução dos resultados objetivados nesta pesquisa. A forma como essa particularidade é tratada na operação do sistema proposto será explanada adiante.

Constatou-se também que, para que se alcançassem resultados aceitáveis, as redes para a determinação do coeficiente de atrito requereram uma massa de dados mais substancial. Para atender a essa necessidade, a pesquisa na base de dados abrangeu os sete últimos meses anteriores à data dos experimentos.

Além do limite de escoamento, as demais variáveis de entrada são: o diâmetro, a rugosidade, a coroa e a dureza dos cilindros de trabalho, a tonelagem laminada pelos cilindros de trabalho desde a última troca (para embutir a informação sobre o desgaste dos cilindros), a largura da tira, as espessuras de entrada e de saída da tira, o valor da deformação real, a força de laminação, as tensões avante e à ré e a velocidade de laminação, num total de 14 variáveis.

O valor “real” do coeficiente de atrito, adotado como valor esperado na saída das redes, foi o valor calculado pelo modelo, o qual, por sua vez, é obtido por meio de modelagem inversa, a partir da fórmula de Ekelund (Equação 2.25), utilizando-se o valor de força calculado pelo mesmo modelo, antes da laminação da tira. A fórmula de Ekelund requer o conhecimento do raio deformado dos cilindros, que por sua vez é obtido pela Equação 2.7, desprezando-se o efeito da recuperação elástica na saída do arco de contato, de forma que a equação fica reduzida a:

$$\mathbf{R}_{\text{def}} = \mathbf{R} \times \left[1 + \frac{16 \times \mathbf{P}_R \times (1 - \nu_R^2)}{\pi \times \mathbf{E}_R \times \mathbf{l} \times (\mathbf{h}_{\text{in}} - \mathbf{h}_o)} \right] \quad (\text{Equação 4-2}),$$

sendo $\mathbf{R}$ o raio dos cilindros, $\mathbf{P}_R$ a força de laminação, $\mathbf{l}$ a largura da tira, $\mathbf{E}_R$ o módulo de Young do material dos cilindros e ν_R o coeficiente de Poisson. Os valores dessas duas últimas grandezas são considerados como constantes e iguais, respectivamente, a 210 GPa e a 0,3 (adimensional). Tais valores estão em conformidade com os utilizados em trabalhos como os de Malik e Grandhi (2008), de Yu, Liu e Li (2008) e de Bolon (1996), este último especificamente relacionado com a planta pesquisada. Considerando estes valores para as constantes, que a força de laminação é dada em toneladas-força e que tanto a largura como as espessuras da tira são dadas em milímetros, a fórmula para o cálculo do raio deformado fica:

$$\mathbf{R}_{\text{def}} = \mathbf{R} \times \left[1 + \frac{0,2165 \times \mathbf{P}_R}{\mathbf{l} \times (\mathbf{h}_{\text{in}} - \mathbf{h}_o)} \right] \quad (\text{Equação 4-3}).$$

Pesquisada a base de dados, constatou-se que, para as três primeiras cadeiras, o valor da coroa dos cilindros era constante, de forma que essa variável só pôde ser nas entradas da rede neural para a obtenção do coeficiente de atrito da quarta cadeira. Por isso, para as demais cadeiras, o número de variáveis de entrada ficou reduzido a treze.

Para a recuperação dos dados, foi utilizado o comando SQL abaixo (caso da quarta cadeira), seguindo o princípio já exposto acima para o caso do limite de escoamento, de incluir na cláusula “WHERE” o pré-processamento dos dados.

```
SELECT pdi.dt_evento DATA, pdi.nr_rolotf ID, tab_cil_sup.nr_cilindro ID_SUP,
       tab_cil_inf.nr_cilindro ID_INF, sig.vl_sigma0 SIGMA0, sig.vl_a_atual A,
       sig.vl_b_atual B, prs.ep_entrada_lam_c4 EP_ENT, prs.ep_saida_lam_c4 EP_SAI,
       prs.vl_forca_lam_c4 FORCA, pdi.lr_rolotf LARG, pdi.vl_coroa_lam COROA_TIRA,
       pro.cm_cil_trab_4 KM_CAD, prz.vl_tensao_lam_z3 TENS_RE,
       prz.vl_tensao_lam_z4 TENS_AV,

       0.5 * (tab_cil_sup.dm_cilindro + tab_cil_inf.dm_cilindro) DIAM,
       0.5 * (tab_cil_sup.vl_coroa + tab_cil_inf.vl_coroa) COROA_ROLL,
       0.5 * (tab_cil_sup.vl_rugosidade + tab_cil_inf.vl_rugosidade) RUG,
       0.5 * (tab_cil_sup.vl_dureza + tab_cil_inf.vl_dureza) DUR,

       prs.vl_cof_atrito_lam_c4 ATRITO_CAD4

FROM   ltf_rolotf pdi, ltf_rolotf_preset_cadeira prs, ltf_rolotf_preset_zona prz,
       ltf_rolotf_processo pro, ltf_rolotf_sigma sig,

       (SELECT      nr_rolotf, dt_evento, nr_cilindro, dm_cilindro, vl_coroa,
                   vl_rugosidade, vl_dureza
FROM   ltf_rolotf_pdi, ltf_troca_cilindro
WHERE  dt_evento BETWEEN dt_montagem and dt_troca
AND    dt_evento BETWEEN sysdate - 210 and sysdate
```

```

AND          cd_cadeira = 4 AND cd_posicao = 'TS') tab_cil_sup,

(SELECT      nr_rolo_ltf, dt_evento, nr_cilindro, dm_cilindro, vl_coroa,
            vl_rugosidade, vl_dureza
FROM         ltf_rolo_pdi, ltf_troca_cilindro
WHERE        dt_evento BETWEEN dt_montagem AND dt_troca
AND          dt_evento BETWEEN sysdate - 210 AND sysdate
AND          cd_cadeira = 4 AND cd_posicao = 'TI') tab_cil_inf

WHERE pdi.nr_rolo_ltf = pro.nr_rolo_ltf
AND   pdi.nr_rolo_ltf = prs.nr_rolo_ltf
AND   pdi.nr_rolo_ltf = prz.nr_rolo_ltf
AND   pdi.nr_rolo_ltf = sig.nr_rolo_ltf
AND   pdi.dt_evento = pro.dt_fim
AND   pdi.dt_evento = prs.dt_evento
AND   pdi.dt_evento = prz.dt_evento
AND   pdi.dt_evento = sig.dt_evento
AND   pdi.dt_evento = tab_cil_sup.dt_evento(+)
AND   pdi.dt_evento = tab_cil_inf.dt_evento(+)
AND   pdi.dt_evento between sysdate - 210 AND sysdate
AND   pro.cm_cil_trab_4 > 0
AND   prs.ep_entrada_lam_c4 > prs.ep_saida_lam_c4
AND   prs.ep_saida_lam_c4 > 0
AND   prs.vl_forca_lam_c4 > 0
AND   prs.vl_vel_per_cil_lam_c4 > 0
AND   prz.vl_tensao_lam_z3 > 0
AND   prz.vl_tensao_lam_z4 > 0
AND   sig.vl_sigma0 > 0
AND   sig.vl_a_atual > 0
AND   sig.vl_b_atual > 0
AND   tab_cil_sup.dm_cilindro > 300
AND   tab_cil_inf.dm_cilindro > 300
AND   tab_cil_sup.vl_coroa > 0
AND   tab_cil_inf.vl_coroa > 0
AND   tab_cil_sup.vl_rugosidade > 0
AND   tab_cil_inf.vl_rugosidade > 0
AND   tab_cil_sup.vl_dureza > 0
AND   tab_cil_inf.vl_dureza > 0

ORDER BY pdi.dt_evento

```

Foram obtidos 15235 registros válidos para primeira cadeira, 15137 para a segunda cadeira, 14965 para a terceira cadeira e 15027 para a quarta cadeira. O procedimento para o treinamento das redes foi análogo ao adotado para o limite de escoamento. As tabelas e figuras mostradas nas páginas que se seguem apresentam, tanto em forma numérica como em forma gráfica, o desempenho das cinco melhores redes obtidas para cada uma das quatro cadeiras.

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	40	0,9561	0,9532	0,0006	0,0007	BFGS/233	logística	identidade
2	50	0,9547	0,9536	0,0007	0,0007	BFGS/233	logística	tanh
3	46	0,9531	0,9528	0,0007	0,0007	BFGS/172	tanh	identidade
4	20	0,9578	0,9548	0,0006	0,0007	BFGS/292	logística	tanh
5	46	0,9612	0,9564	0,0006	0,0006	BFGS/276	tanh	tanh

Tabela 4-6 – Redes para o coeficiente de atrito da cadeira 1

Figura 4-21– Visualização do desempenho das redes para o atrito da cadeira 1

Figura 4-22 – Visualização dos resíduos das redes para o atrito da cadeira 1

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	39	0,9538	0,9486	0,0006	0,0007	BFGS/235	logística	identidade
2	38	0,9542	0,9491	0,0006	0,0007	BFGS/350	logística	tanh
3	21	0,9545	0,9492	0,0006	0,0007	BFGS/314	logística	identidade
4	28	0,9581	0,9537	0,0006	0,0007	BFGS/317	tanh	tanh
5	40	0,9400	0,9479	0,0006	0,0007	BFGS/216	logística	tanh

Tabela 4-7 – Redes para o coeficiente de atrito da cadeira 2

Figura 4-23 – Visualização do desempenho das redes para o atrito da cadeira 2

Figura 4-24 – Visualização dos resíduos das redes para o atrito da cadeira 2

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	43	0,8846	0,8646	0,0011	0,0012	BFGS/107	tanh	logística
2	34	0,8853	0,8664	0,0011	0,0012	BFGS/188	tanh	tanh
3	29	0,8969	0,8658	0,0010	0,0012	BFGS/194	logística	logística
4	50	0,8817	0,8631	0,0011	0,0013	BFGS/217	logística	identidade
5	50	0,8892	0,8678	0,0010	0,0012	BFGS/273	tanh	identidade

Tabela 4-8 – Redes para o coeficiente de atrito da cadeira 3

Figura 4-25 – Visualização do desempenho das redes para o atrito da cadeira 3

Figura 4-26 – Visualização dos resíduos das redes para o atrito da cadeira 3

R e d e	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
1	55	0,9598	0,9455	0,0020	0,0027	BFGS/264	tanh	tanh
2	54	0,9575	0,9458	0,0021	0,0026	BFGS/240	tanh	identidade
3	45	0,9610	0,9488	0,0019	0,0025	BFGS/306	tanh	tanh
4	38	0,9561	0,9437	0,0021	0,0027	BFGS/244	tanh	tanh
5	38	0,9630	0,9455	0,0018	0,0027	BFGS/257	logística	logística

Tabela 4-9 – Redes para o coeficiente de atrito da cadeira 4

Figura 4-27 – Visualização do desempenho das redes para o atrito da cadeira 4

Figura 4-28 – Visualização dos resíduos das redes para o atrito da cadeira 4

A Tabela 4-10 resume as características das 8 redes (4 para limite de escoamento e 4 para coeficiente de atrito) selecionadas após a fase de treinamento. As redes denominadas como “E” referem-se ao limite de escoamento e as chamadas “A” referem-se ao coeficiente de atrito. Os números após as letras referem-se ao número da cadeira modelada pela rede. De acordo com o exposto anteriormente, as redes de limite para o limite de escoamento possuem 12 entradas, enquanto as redes para o coeficiente de atrito possuem 14 entradas. Em todos os casos, as redes possuem uma única saída.

R E D E	Unidades na camada oculta	Correlação do conjunto de treinamento	Correlação do conjunto de teste	Erro do conjunto de treinamento	Erro do conjunto de teste	Algoritmo de treinamento e nº de épocas	Função de ativação na camada oculta	Função de ativação na camada de saída
E1	26	0,9636	0,9560	0,0006	0,0007	BFGS/361	logística	identidade
E2	19	0,9400	0,9285	0,0012	0,0012	BFGS/34	logística	tanh
E3	35	0,9604	0,9587	0,0005	0,0005	BFGS/362	tanh	logística
E4	16	0,9047	0,8780	0,0009	0,0012	BFGS/180	tanh	logística
A1	46	0,9612	0,9564	0,0006	0,0006	BFGS/276	tanh	tanh
A2	28	0,9581	0,9537	0,0006	0,0007	BFGS/317	tanh	tanh
A3	29	0,8969	0,8658	0,0010	0,0012	BFGS/194	logística	logística
A4	38	0,9630	0,9455	0,0018	0,0027	BFGS/257	logística	logística

Tabela 4-10 – Características e desempenho das redes treinadas

4.4 Análise dos Resultados do Treinamento

A análise dos resultados mostra que, no caso das redes para modelagem do limite de escoamento, a correlação entre os valores esperados e os valores calculados foi inferior no caso da quarta cadeira. Tal efeito pode ser explicado com base nas condições peculiares de espessura nessa cadeira. De acordo com Sutcliffe e Rayner (1998), para menores espessuras de tira a deformação elástica dos cilindros de laminação cresce significativamente, e a hipótese simplificadora de que o seu perfil permanece circular se torna mais imprecisa. Antes desses pesquisadores, Grimble, Fuller e Bryant (1978) já haviam observado que a consideração de forma circular para o arco de contato, “*embora válida para uma grande faixa de condições práticas de laminação, é definitivamente suspeita para a última cadeira de um laminador*”. Visto que o modelo utiliza as mesmas hipóteses para todas as cadeiras, é de se esperar que a discrepância em relação ao modelo empírico representado pelas redes neurais seja maior justamente na quarta cadeira.

No que tange ao coeficiente de atrito, constatou-se uma menor correlação para a rede neural que modelou a terceira cadeira. Não foi possível encontrar qualquer base teórica para

tal resultado, visto não haver qualquer peculiaridade que distinga aquela cadeira das demais. Diante desse fato, foi apresentada aos analistas de automação e de processo da planta a recomendação de uma verificação na integridade dos dados de processo da Cadeira 3 relacionados de alguma forma ao cálculo do coeficiente de atrito.

4.5 O Aplicativo *Sigma_Mu_Calc*

Obtidas as configurações ótimas para as oito redes neurais, o passo seguinte foi a sua implementação na forma de um programa que pudesse ser facilmente incorporado ao sistema de automação do laminador. Assim, foi criado um utilitário em linguagem C#, por meio da ferramenta de desenvolvimento Microsoft® .Net Visual Studio®, a mesma usada no Nível 2 da automação da planta. O aplicativo foi denominado como *Sigma_Mu_Calc*.

O programa foi desenvolvido de modo a interagir de modo *off-line* com o processo, ou seja, seus resultados são usados pelo modelo apenas em condições de teste (que serão descritas no próximo capítulo), e não durante a operação efetiva. Desse modo, ele foi dotado de uma interface própria (independente das telas normais de operação), utilizada unicamente pelo analista de processo, e não pelos operadores. A Figura 4-29 mostra essa interface.

Dados Relevantes das Bobinas Disponíveis Para Produção

Número do Programa	Número da Bobina	Seqüência	Espessura de Entrada (mm)	Espessura de Saída (mm)	Largura (mm)	Coroa (mm)	Código do Aço	Dureza	Decapagem	Cliente
5482	185360000	12	2,65	0,74	1207	0,0550	338160	BR	1	CUBATA
5482	185370000	13	2,65	0,74	1207	0,05	338150	BR	1	CUBATA
5482	185380000	14	2,65	0,74	121207	0,05	338160	BR	1	CUBATA
5482	181830000	15	2,02	0,46	1206	0,05	367090	BR	2	ZAMPRO
5489	187070000	1	3,01	1,02	1525	0,06	106070	BR	1	STEMCO
5489	187080000	2	3,01	1,02	1523	0,06	106060	BR	1	STEMCO
5489	187090000	3	3,01	1,02	1523	0,0450	106080	BR	1	STEMCO
5489	187100000	4	3,02	1,02	1523	0,05	106080	BR	1	STEMCO

Dados Relevantes dos Cilindros de Trabalho

Cadeira	Diâmetro (mm)	Coroa (mm)	Rugosidade	Dureza
1	517,37	0,12	1,05	86
1	518,19	0,12	0,96	86
2	542,97	0,07	0,48	88
2	543,68	0,07	0,52	88
3	574,38	0,07	0,54	89
3	574,95	0,07	0,52	88
4	555,29	0,08	4,95	88
4	555,52	0,08	4,95	88

Valores de Processo (estimados)

	Espessura (mm)	Deformação Real (-)	Velocidade (m/min)	Força (Ton)	Tensão (Ton)
Cad#1	3,0100	0,4008	247,94	1530,2	0,50
Cad#2	2,0161	0,3365	347,13	1324,3	40,90
Cad#3	1,4400	0,2913	464,50	1256,6	34,25
Cad#4	1,0762	0,0536	490,08	1220	29,55
	1,0200				5,26

Valores dos Parâmetros (obtidos pelas RNA)

	Cadeira 1	Cadeira 2	Cadeira 3	Cadeira 4
Sigma (MPa)	651,46	649,33	625,20	473,06
Coeficiente de Atrito	0,0250	0,0151	0,0086	0,0452

Modo: OPERAÇÃO
 Seleção de Força Imposta (Ton/mm): 800
 Calcular Parâmetros

Figura 4-29 – Interface do utilitário *Sigma_Mu_Calc*

A figura mostra o aplicativo no chamado “*Modo de Operação*”, que se aproxima da forma como ele será utilizado após sua incorporação ao Nível 2 da estrutura de automação da planta, e que deve ser selecionado quando se desejam calcular parâmetros para bobinas ainda por produzir. Há outro modo de utilização, que é denominado “*Modo de Avaliação*”, usado para obter parâmetros para bobinas já produzidas e que será mostrado e discutido no próximo capítulo.

Na parte superior da interface (grupo “*Dados Relevantes das Bobinas Disponíveis Para Produção*”) são visualizados os dados primários das bobinas prontas para o processamento na planta. Esses dados são obtidos por meio de uma “*view*” (tabela virtual gerada a partir de uma instrução SELECT) da base de dados de produção.

Logo abaixo, no lado esquerdo (grupo “*Dados Relevantes dos Cilindros de Trabalho*”), visualizam-se os dados de equipamento necessários para as entradas das redes, todos eles relacionados com os cilindros de trabalho. Esses dados são obtidos por meio de um comando SELECT aplicado à tabela LTF_WEB_CILINDROS, na base histórica de dados da planta.

À direita se encontra o grupo “*Valores de Processo*”, que reúne as estimativas sobre os valores de modelo utilizados como entradas para as redes neurais, que, como explanado anteriormente, só são determinados *depois* que o modelo matemático realiza os seus cálculos. Uma vez, porém, que os valores de limite de escoamento e de coeficiente de atrito determinados pelo aplicativo Sigma_Mu_Calc devem ser utilizados pelo modelo, eles precisam estar disponíveis *antes* que este seja executado. Faz-se necessária, portanto, uma estimativa confiável dos valores de processo para viabilizar a operação do sistema proposto.

A solução adotada foi incorporar o aplicativo *NeuraLTF*, desenvolvido por Santos Filho e Ramirez-Fernandez (2009). Esse aplicativo foi concebido originalmente como uma alternativa ao modelo matemático (na ocorrência de falhas no servidor de Nível 2 que impossibilitem a sua operação) e utiliza redes neurais para obter a totalidade das referências calculadas pelo modelo, utilizando como entradas exclusivamente dados primários e um único dado de operação, a saber, a força imposta. A Figura 4-30 mostra a interface do *NeuraLTF*.

Os resultados obtidos por meio desse utilitário apresentam desvio inferior a 10% em relação aos valores calculados pelo modelo matemático (SANTOS FILHO E RAMIREZ-FERNANDES, 2009), constituindo, portanto, uma estimativa adequada para os valores de

processo requeridos pelo *Sigma_Mu_Calc*. Das quatro redes neurais que o *NeuraLTF* utiliza, apenas a que calcula os valores de referência para a fase de laminação propriamente dita foi incorporada ao *Sigma_Mu_Calc* para conseguir as variáveis importantes para sua operação (força e velocidade nas cadeiras, espessura e tensão nos vãos).

The screenshot displays the NeuraLTF software interface. At the top, there's a title bar and a menu bar. Below the menu bar, there's a section for 'Mostrar Presets Para:' with radio buttons for 'Encaixe', 'Desencaixe', 'Laminação', and 'Ganhos do AGC'. The 'Laminação' option is selected. To the right, there's a 'Status da Comunicação' section with 'AGC ==>' and 'Banco de Dados ==>' both showing 'OK'. A 'System Messages' window is open on the right, displaying a message: '10:39:32 >> Calculados os presets para a bobina 131.100.119.120'. Below this, there's a table titled 'Programas de Laminação' with columns: Programa, Sequência, Bobina, Peso, Diâmetro, Espessura Entrada, Espessura Saída, Largura, Tipo de Aço, Dureza, Coroa, and Decapagem. The table contains several rows of data. Below the table, there's a section titled 'Entrada Manual de Dados' with input fields for various parameters: Número da Bobina (0215820000), Número do Programa (5606), Peso (Kg) (19240), Espessura de Entrada (mm) (2,42), Espessura de Saída (mm) (0,69), Largura (mm) (1005), Tipo de Aço (181080), Liga (BR), Coroa (mm) (0,075), Número da Decapagem (2), Código de Estampagem (EM), and Força Imposta (Ton/m) (900). Below this, there's a section titled 'Presets Obtidos' with a table showing values for four chairs (Cadeira 1, Cadeira 2, Cadeira 3, Cadeira 4) and five gaps (Vão 0, Vão 1, Vão 2, Vão 3, Vão 4). The table includes rows for Force of Lamination (Ton), Reduction (%), Force of Bending (Ton), Current of Motors (A), Slip Forward (%), Linear Velocity (mpm), Thickness (mm), Tension (Kg/mm), Specific Tension (Kg/mm²), and Velocity (mpm).

Programa	Sequência	Bobina	Peso	Diâmetro	Espessura Entrada	Espessura Saída	Largura	Tipo de Aço	Dureza	Coroa	Decapagem
5606	47	21572	8730	1335	2,40	0,69	1005	181080	BR	0,05	2
5606	48	21576	19180	1882	2,42	0,69	1005	181080	BR	0,06	2
5606	50	21582	19240	1885	2,42	0,69	1005	181080	BR	0,0750	2
5606	51	21583	19170	1882	2,42	0,69	1005	181080	BR	0,0850	2
5606	52	21584	19210	1883	2,43	0,69	1005	181090	BR	0,0350	2
5606	53	21587	9610	1387	2,41	0,69	1005	181080	BR	0,08	2
5606	54	21590	19170	1882	2,42	0,69	1005	181080	BR	0,0850	2

	Cadeira 1	Cadeira 2	Cadeira 3	Cadeira 4
Força de Laminação (Ton)	914	836	770	905
Redução (%)	35,6	31,4	30,4	7,2
Força de Bending (Ton)	85	73	69	-36
Corrente dos Motores (A)	0,406	0,560	0,613	0,558
Escoamento Avante (%)	0,4	0,2	0,1	0,5
Velocidade Linear (mpm)	444,6	650,1	934,9	1003,6

	Vão 0	Vão 1	Vão 2	Vão 3	Vão 4
Espessura (mm)	2,420	1,558	1,069	0,744	0,690
Tensão (Kg/mm)	8,4	19,3	17,7	15,0	2,4
Tensão Específica (Kg/mm²)	3,5	7,9	11,5	14,4	3,5
Velocidade (mpm)	287,6	446,6	651,1	935,8	1008,6

Figura 4-30 – Interface do Utilitário *NeuraLTF*

Obtidos os dados primários, os dados dos cilindros e os valores de processo, resta apenas a seleção da força de laminação imposta na quarta cadeira e executar o cálculo dos parâmetros limite de escoamento e coeficiente de atrito para as quatro cadeiras do laminador (grupo “Valores de Parâmetros Obtidos pelas RNA”, na parte inferior da interface). Digno de nota é o fato de que toda a entrada de dados se faz sem a necessidade de digitação, sendo integralmente realizada através do dispositivo apontador, reduzindo significativamente a probabilidade de erros.

Os valores calculados pelo *Sigma_Mu_Calc* devem então substituir os valores correspondentes utilizados pelo modelo matemático, avaliando-se em seguida o efeito dessa substituição sobre as referências calculadas pelo modelo. Tal avaliação é apresentada no capítulo seguinte.

Capítulo 5 AVALIAÇÃO DO SISTEMA E DISCUSSÃO DOS RESULTADOS

Descrevem-se nesse capítulo os procedimentos experimentais e estatísticos adotados para verificar a hipótese apresentada na pesquisa, ou seja, de que a aplicação de Inteligência Computacional é capaz de proporcionar maior eficácia à adaptação do modelo matemático.

5.1 Avaliação do Desempenho Original do Modelo

Para permitir uma correta estimativa da influência do sistema proposto sobre o modelo, foi realizada inicialmente uma avaliação do desempenho original do modelo usando o método convencional de adaptação. Para tanto, foram recuperadas na base de dados da planta as informações referentes a todas as bobinas produzidas entre os meses de fevereiro e abril de 2009 (cerca de 8000 bobinas), com o objetivo de calcular o erro percentual entre os valores das referências calculadas pelo modelo e os valores efetivamente medidos para as mesmas variáveis.

O modelo matemático calcula um total de 125 valores de referências, de forma que o exame exaustivo de cada um desses valores seria inexequível. Assim, foram escolhidas duas grandezas como base de comparação: a força e a velocidade linear de laminação. A força de laminação foi escolhida pela sua grande influência sobre a qualidade do produto. Cho, Cho e Yoon (1997) ressaltam que “a acurada predição da força de laminação é essencial para a qualidade do produto”, no que são secundados por Lee e Choi (2004) e por Jia, Shan e Niu (2008). A escolha da velocidade de laminação deve-se ao fato de ela estar ligada à produtividade da planta. Como exposto no Capítulo 1 desta Tese, incrementos em qualquer uma dessas características (qualidade e produtividade), ainda que da ordem de partes por mil, proporcionam consideráveis ganhos financeiros.

As figuras 5-1 a 5-8, que se seguem, mostram, para cada uma das cadeiras, as distribuições dos erros percentuais entre os valores calculados e medidos para a força e para a velocidade, dentro do universo das 8000 bobinas no período considerado. Como os gráficos permitem facilmente observar, o acerto do modelo é bem maior nos casos de cálculo da força de laminação do que nos cálculos de velocidade.

Figura 5-1 – Distribuição dos erros no cálculo da força de laminação da cadeira 1

Figura 5-2 – Distribuição dos erros no cálculo da velocidade da cadeira 1

Figura 5-3 – Distribuição dos erros no cálculo da força de laminação da cadeira 2

Figura 5-4 – Distribuição dos erros no cálculo da velocidade da cadeira 2

Figura 5-5 – Distribuição dos erros no cálculo da força de laminação da cadeira 3

Figura 5-6 – Distribuição dos erros no cálculo da velocidade da cadeira 3

Figura 5-7 – Distribuição dos erros no cálculo da força de laminação da cadeira 4

Figura 5-8 – Distribuição dos erros no cálculo da velocidade da cadeira 4

5.2 Obtenção dos Parâmetros Adaptativos pelo Sistema Proposto

Conforme exposto anteriormente, os testes do sistema foram realizados sem atuação direta sobre o processo. Além do risco óbvio para a operação representado por uma alteração ainda não testada, ainda vigorava o período de garantia referente à modernização do laminador, no qual modificações no sistema eram contratualmente proibidas, sob pena de perda de garantia. Por essas razões, a estratégia adotada foi realizar as intervenções no modelo matemático a partir do servidor reserva de Nível 2.

Foram selecionadas 84 bobinas, correspondentes a três programas de produção e armazenados os valores das referências calculadas pelo modelo convencional para estas bobinas. O passo seguinte consistiu no cálculo dos parâmetros adaptados (limite de escoamento e coeficiente de atrito) para essas mesmas bobinas por meio do *Sigma_Mu_Calc*. Para tanto, foi necessário utilizar o aplicativo no chamado modo de avaliação, no qual a interface tem o aspecto mostrado na Figura 5-9. Nessa modalidade de utilização, que é apropriada para bobinas previamente produzidas, o aplicativo recupera na base histórica de dados as informações sobre os cilindros de laminação no momento em que tais bobinas foram laminadas, ao invés de recuperar as informações presentes, como ocorre no modo de operação. Da mesma forma, o valor da força imposta é recuperado da base de dados.

Sigma_Mu_Calc: Aplicativo Baseado em Redes Neurais Artificiais para a Determinação Off-line do Limite de Escoamento e do Coeficiente de Atrito - 25/6/2009 15:05:41

Dados Relevantes das Bobinas Disponíveis Para Produção

Número do Programa	Número da Bobina	Seqüência	Espessura de Entrada (mm)	Espessura de Saída (mm)	Largura (mm)	Coroa (mm)	Código do Aço	Dureza	Decapagem	Cliente
5482	190730000	10	3,15	0,92	1205	0,06	365080	BR	2	SONAEX
5482	185350000	11	2,65	0,74	1207	0,04	338180	MR	1	CUBATA
5482	185360000	12	2,65	0,74	1207	0,0550	338160	BR	1	CUBATA
5482	185370000	13	2,65	0,74	1207	0,06	338160	BR	1	CUBATA
5482	185380000	14	2,65	0,74	1207	0,05	338160	BR	1	CUBATA
5482	181830000	15	2,02	0,46	1206	0,05	367090	BR	2	ZAMPRO
5489	187070000	1	3,01	1,02	1525	0,06	106070	BR	1	STEMCO
5489	187080000	2	3,01	1,02	1523	0,06	106060	BR	1	STEMCO

Dados Relevantes dos Cilindros de Trabalho

QUILOMETRAGEM

Número da Bobina	Força Imposta	Cilindro Cadeira 1 (Km)	Cilindro Cadeira 2 (Km)	Cilindro Cadeira 3 (Km)
185380000		12,0356102590	114,56983481...	154,778950

OUTROS

MR_ROLO_LTF	VL_FORÇA_IMPA	DM_CILINDRO	VL_COROA	VL_RUGOSI
185380000	800	520,22	0,12	1,04
185380000	800	519,75	0,12	1,05
185380000	800	545,05	0,07	0,53

Valores de Processo (estimados)

	Espessura (mm)	Deformação Real (-)	Velocidade (m/min)	Força (Ton)	Tensão (Ton)
Cad#1	2,6500	0,4599	341,34	1272,9	0,50
Cad#2	1,6730	0,3998	509,13	1060,8	32,78
Cad#3	1,1217	0,3484	721,36	1036,6	26,22
Cad#4	0,7917	0,0675	771,73	965,6	21,83
Cad#4	0,7400				3,36

Valores dos Parâmetros (obtidos pelas RNA)

Modo: AVALIAÇÃO

Seleção de Força Imposta (Ton/mm): 800

Calcular Parâmetros

Sigma (MPa): Cadeira 1: 733,37; Cadeira 2: 745,18; Cadeira 3: 723,21; Cadeira 4: 562,92

Coeficiente de Atrito: Cadeira 1: 0,0190; Cadeira 2: 0,0158; Cadeira 3: 0,0129; Cadeira 4: 0,0308

Figura 5-9 – Interface do *Sigma_Mu_Calc* no modo de avaliação

Os valores dos parâmetros calculados pelo *Sigma_Mu_Calc* para todas as bobinas eram automaticamente transferidos para uma planilha Excel®, para posterior utilização no cálculo das referências.

Visto que as RNA, em geral, não possuem capacidade de extrapolação, é importante garantir que os dados de entrada estejam dentro do intervalo abrangido pelos dados utilizados na fase de treinamento. As figuras seguintes permitem comparar as distribuições dos valores das principais grandezas dimensionais das bobinas utilizadas na avaliação. As figuras referem-se, respectivamente, à espessura de entrada, à espessura de saída, à largura e à coroa das bobinas. Os histogramas em vermelho correspondem às bobinas usadas na avaliação do sistema, enquanto os histogramas em azul correspondem às bobinas usadas no desenvolvimento do sistema. Como se pode observar, as dimensões das bobinas de avaliação estão compreendidas dentro do intervalo de valores das bobinas usadas no treinamento das redes.

Figura 5-10 – Histogramas de espessura de entrada das tiras

Figura 5-11 – Histogramas de espessura de saída das tiras

Figura 5-12 – Histogramas de largura das tiras

Figura 5-13 – Histogramas de coroa das tiras

Em seguida, os dados primários, os dados de equipamento e os dados de operação correspondentes foram transferidos para a base de dados do servidor reserva. Lembrando que esse servidor fica desconectado da rede de automação da planta, tal transferência foi realizada manualmente.

De posse dessas informações, é possível simular a inclusão das bobinas de avaliação na fila de entrada do laminador. Para qualquer bobina localizada nessa fila o modelo executado no servidor de Nível 2 (seja ele o operacional ou o reserva) pode calcular as referências que serão usadas em tempo real pelos controladores do Nível 1. Visto que o *Sigma_Mu_Calc* não está incorporado ao Nível 2, são necessárias operações manuais para que os valores dos parâmetros utilizados pelo modelo matemático convencional sejam substituídos pelos obtidos através do aplicativo. o passo seguinte foi recalculer as referências, modificando previamente os valores de limite de escoamento e de coeficiente de atrito por aqueles fornecidos pelo *Sigma_Mu_Calc*.

A Figura 5-14 apresenta a interface para inclusão de bobinas na entrada do laminador, operação que permite que as referências sejam calculadas.

Figura 5-14 – Interface da fila de entrada do laminador

Uma vez uma bobina tenha sido incluída na fila de entrada do laminador, o modelo executado no servidor de Nível 2 (seja ele o operacional ou o reserva) pode calcular as referências que serão usadas em tempo real pelos controladores do Nível 1. Visto que o *Sigma_Mu_Calc* não está incorporado ao Nível 2, são necessárias operações manuais para que os valores dos parâmetros utilizados pelo modelo matemático convencional sejam substituídos pelos obtidos através do aplicativo.

Foram realizadas três baterias de testes: a primeira utilizando tanto os valores de limite de escoamento como os valores de coeficiente de atrito calculados pelo *Sigma_Mu_Calc*, a segunda utilizando apenas os valores de limite de escoamento e a última usando exclusivamente os valores de coeficiente de atrito. A Figura 5-15 mostra a interface de Nível 2 para o cálculo de referências. Selecionando-se qualquer das bobinas presentes na fila de entrada, o cálculo das referências é automaticamente executado, sendo permitido ao operador modificar os dados primários ou de operação e solicitar o recálculo sempre que julgar conveniente.

Figura 5-15 – Interface para o cálculo de referências

No caso dos testes aqui descritos, uma vez que os valores alterados foram de parâmetros internos do modelo, e não de dados primários das bobinas utilizadas para os testes ou de dados de processo, as modificações foram efetuadas através de comandos REPLACE diretamente na base de dados local do servidor, e não por meio da interface. Essa operação, necessariamente manual, se constituiu na parte mais trabalhosa da fase de avaliação, especialmente ao se considerar que três baterias de testes foram efetuadas com cada uma das 84 bobinas. Nas três baterias, os valores de todos os parâmetros referentes às quatro cadeiras do laminador tiveram que ser digitados para cada uma das 84 bobinas utilizadas na avaliação. A Figura 5-16 ilustra o método de intervenção na base de dados.

Ao final de cada bateria de testes os valores de referências obtidos após a modificação do(s) parâmetro(s) foram recuperados da base de dados e transferidos para uma planilha eletrônica para posterior comparação.

Figura 5-16 – Método para alteração de valores na base de dados

5.3 Avaliação dos Resultados

A primeira estratégia adotada foi uma análise qualitativa geral, que foi realizada pelo simples exame da interface de cálculo de referências, a qual, em caso de resultados fora dos limites aceitáveis pela planta, produz indicações visuais de alarme e, em caso de processamento real, impede que as referências sejam carregadas nos controladores de Nível 1. Uma vez que tivessem sido introduzidos os valores corretos dos parâmetros obtidos pelo *Sigma_Mu_Calc* e o valor correspondente de força imposta na quarta cadeira, nenhuma das 84 bobinas apresentou problemas de limite nos valores das referências calculadas, demonstrando que o sistema desenvolvido não introduziu incongruências no modelo matemático.

A Figura 5-17 mostra o aspecto da indicação visual de referências fora dos limites (valor ressaltado em cor vermelha).

Figura 5-17 – Indicação visual de erro no cálculo de referências

Em seguida a essa análise qualitativa procedeu-se a uma análise quantitativa das grandezas escolhidas para a avaliação: a força de laminação e a velocidade de laminação. Os valores medidos para essas grandezas durante o processamento efetivo das bobinas de teste foram adotados como alvos e com eles foram comparados: os valores calculados pelo modelo convencional, os valores calculados com alteração simultânea de limite de escoamento e coeficiente de atrito, os valores calculados com alteração apenas de limite de escoamento e os valores calculados com alteração apenas de coeficiente de atrito. Essa comparação foi feita para as 84 bobinas selecionadas para os testes.

Uma vez que os testes tiveram que ser realizados em modo *off-line*, ou seja, sem intervenção efetiva sobre o processo, foi adotado o seguinte procedimento: após a produção efetiva das 84 bobinas, os valores de referências obtidas pelo modelo matemático convencional da planta foram salvos. Depois os dados referentes àquelas bobinas foram carregados no servidor reserva de Nível 2, que em condições normais opera em modo *cold stand-by*, ficando desconectado da rede de automação da planta.

Em seguida, solicitou-se o cálculo das referências para as bobinas nas três condições explanadas acima: modificando-se tanto o limite de escoamento como o coeficiente de atrito, modificando-se apenas o limite de escoamento e, por fim, modificando-se apenas o coeficiente de atrito. Os resultados obtidos em cada uma dessas situações foram salvos para posterior comparação com os calculados em condições normais.

As figuras 5-18 a 5-25 mostram a distribuição dos erros percentuais das duas grandezas avaliadas (força de laminação e velocidade) para cada uma das cadeiras, sempre tomando como base o valor efetivamente medido. Em cada conjunto, o histograma em azul refere-se aos resultados do modelo com adaptação convencional, o histograma em vermelho refere-se à utilização conjunta das adaptações neurais de limite de escoamento e de coeficiente de atrito, o histograma em verde refere-se à utilização isolada da adaptação neural do limite de escoamento e, por fim, o histograma em violeta refere-se à utilização isolada da adaptação neural do coeficiente de atrito. Além do histograma, cada figura contém ainda os valores da média e do desvio-padrão dos erros percentuais, valores que permitem estimar, respectivamente, a precisão (acurácia) e a consistência dos modelos, conforme comentado no Capítulo 2. O valor 1 nas médias corresponde a erro nulo (100% de acerto).

Figura 5-18 – Distribuição dos erros de força de laminação na cadeira 1

Figura 5-19 – Distribuição dos erros de velocidade de laminação na cadeira 1

Figura 5-20 – Distribuição dos erros de força de laminação na cadeira 2

Figura 5-21 – Distribuição dos erros de velocidade de laminação na cadeia 2

Figura 5-22 – Distribuição dos erros de força de laminação na cadeia 3

Figura 5-23 – Distribuição dos erros de velocidade de laminação na cadeira 3

Figura 5-24 – Distribuição dos erros de força de laminação na cadeira 4

Figura 5-25 – Distribuição dos erros de velocidade de laminação na cadeira 4

As tabelas 5-1 e 5-2 resumem os resultados apresentados. Como se pode notar, para os 16 itens comparados (média e desvio-padrão das duas variáveis para as quatro cadeiras), 5 melhores resultados foram obtidos com a adaptação neural exclusiva para o limite de escoamento, 5 com a adaptação neural conjunta do limite de escoamento e do coeficiente de atrito, 3 com a adaptação neural exclusiva do coeficiente de atrito e 3 com a adaptação convencional.

	Força de Laminação	Velocidade de Laminação
Cadeira 1	1,0042 (Adaptação Convencional)	1,0155 (Adaptação Neural do Atrito)
Cadeira 2	1,0076 (Adaptação Convencional)	1,0011 (Adaptação Neural do Atrito)
Cadeira 3	1,0099 (Adaptação Neural do Atrito)	1,0166 (Adaptação Neural do Escoamento)
Cadeira 4	1,0007 (Adaptação Neural do Escoamento + Atrito)	0,9930 (Adaptação Neural do Escoamento)

Tabela 5-1 – Melhores resultados para a média das grandezas testadas

	Força de Laminação	Velocidade de Laminação
Cadeira 1	0,0278 (Adaptação Neural do Escoamento)	0,1085 (Adaptação Neural do Escoamento + Atrito)
Cadeira 2	0,0274 (Adaptação Neural do Escoamento)	0,1068 (Adaptação Neural do Escoamento + Atrito)
Cadeira 3	0,0321 (Adaptação Neural do Escoamento)	0,1100 (Adaptação Neural do Escoamento + Atrito)
Cadeira 4	0,0347 (Adaptação Convencional)	0,1019 (Adaptação Neural do Escoamento + Atrito)

Tabela 5-2 – Melhores resultados para o desvio-padrão das grandezas testadas

Uma observação relevante é que, com exceção da quarta cadeira, os melhores resultados são obtidos quando se utiliza a adaptação neural apenas para o limite de escoamento. Em outras palavras, a modelagem do coeficiente de atrito por meio de redes neurais ainda precisa de aperfeiçoamentos para trazer ganhos efetivos à adaptação do modelo.

5.4 Verificação Pelo Método Estatístico do Teste de Hipóteses

O método estatístico do Teste de Hipóteses (FONSECA E MARTINS, 1996) permite avaliar o grau de confiança em que uma *hipótese inicial* ou *hipótese de nulidade* H_0 pode ser preterida ou preferida em relação a uma *hipótese alternativa* H_1 . Tal teste pode ser *bilateral* (quando se quer verificar se a média suposta por H_1 é diferente da média suposta por H_0), *unilateral à esquerda* (quando se quer verificar se a média suposta por H_1 é menor que a média suposta por H_0), ou *unilateral à direita* (quando se quer verificar se a média suposta por H_1 é maior que a média suposta por H_0).

O tamanho da amostra e o conhecimento de sua variância são fatores fundamentais para a determinação da *estatística* a ser adotada, que por sua vez estabelece a chamada *região crítica*, que marca a fronteira entre a aceitação e a rejeição da hipótese inicial. Se a amostra for grande (ou seja, com pelo menos 30 elementos) ou se a sua variância populacional for conhecida, utiliza-se a chamada *Tabela de Distribuição Normal*. Caso nenhuma das duas condições seja satisfeita, utiliza-se a chamada *Distribuição t-Student*, também conhecida como *Distribuição de Pequenas Amostras*. O outro parâmetro relevante é o *nível de significância* do teste, que é a probabilidade de se cometer um erro ao se rejeitar a hipótese inicial.

No caso específico aqui abordado, tendo sido observadas 84 amostras ($n > 30$), utilizando-se a tabela de distribuição normal e o valor tabelado da estatística para um teste unilateral à direita com um nível de significância α igual a 1%, o valor tabelado da estatística é: $Z_{TAB} \cong 2,33$. O valor calculado para a estatística das amostras é dado por:

$$Z_{CALC} = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \quad (\text{Equação 5-1}).$$

Na equação acima, $\bar{X}$ representa a média considerada na hipótese alternativa, μ representa a média considerada na hipótese nula, σ é o desvio-padrão e n é o tamanho da amostra. Caso $Z_{CALC} > Z_{TAB}$, a hipótese alternativa deve ser preferida em detrimento da hipótese nula, com grau de confiança igual a $1 - \alpha$ (nesse caso específico, 99%).

5.4.1 Cálculos Para a Força de Laminação

Dois dos melhores resultados obtidos com a adaptação convencional referem-se à média de acerto no cálculo das forças de laminação nas cadeiras 1 e 2. Conforme exposto acima, o acerto no cálculo dessa grandeza tem influência determinante sobre a qualidade do produto. Aplicando-se o teste de hipóteses tal como preconizado acima, temos, para a Cadeira 1, a seguinte comparação entre a adaptação convencional e o segundo melhor resultado obtido (adaptação neural exclusiva para o coeficiente de atrito), tomando como hipótese alternativa que o erro médio aumentou . Ressalta-se que, nesses dois casos, o aumento do erro médio significa que ele se tornou mais distante de 1, o que se constitui numa situação indesejável. Logo, o que se deseja é rejeitar a hipótese alternativa.

$$Z_{CALC} = \frac{1,0288 - 1,0042}{\frac{0,0428}{\sqrt{84}}} \cong 5,28, \text{ comprovando-se assim a hipótese alternativa com grau de}$$

confiança superior a 99%. Repetindo-se o raciocínio para o caso da Cadeira 2:

$$Z_{CALC} = \frac{1,0148 - 1,0076}{\frac{0,0342}{\sqrt{84}}} \cong 1,93, \text{ e, neste caso, o grau de confiança para a aceitação da}$$

hipótese alternativa cai para 94,6%, ainda um valor elevado.

Por esse motivo, no presente estágio do desenvolvimento, a adaptação convencional deve ser mantida nas duas primeiras cadeiras, não obstante o fato de a diferença de

desempenho em relação à adaptação neural ser relativamente pequena.

Nas duas últimas cadeiras, a adaptação neural apresentou médias maiores e mais próximas de 1 do que a adaptação convencional, tendendo, portanto, a proporcionar qualidade superior ao produto. Calcula-se a seguir o grau de confiança em que a hipótese alternativa (adaptação neural) deve ser aceita, tendo-se em mente que nesses dois casos essa hipótese é desejável.

Para a Cadeira 3:

$$Z_{\text{CALC}} = \frac{1,0261 - 1,0099}{\frac{0,0376}{\sqrt{84}}} \cong 3,95, \text{ sendo a hipótese alternativa aceita com grau de confiança}$$

superior a 99%.

Para a cadeira 4:

$$Z_{\text{CALC}} = \frac{1,0007 - 0,9981}{\frac{0,0347}{\sqrt{84}}} \cong 0,69, \text{ sendo a hipótese alternativa aceita com grau de confiança}$$

de 51%, o que significa, na prática, incerteza quase total quanto à aceitação ou rejeição da hipótese.

A análise desses resultados conduz à constatação de que, no estágio atual de desenvolvimento, o sistema proposto provoca, em geral, um leve aumento no desempenho no cálculo da força de laminação na cadeira 3, acarretando, contudo, de uma pequena degradação no desempenho da determinação de força para as cadeiras 1 e 2. Com relação à determinação da força de laminação da Cadeira 4, a adaptação neural apresenta desempenho similar ao da estratégia convencional de adaptação.

5.4.2 Cálculos Para a Velocidade de Laminação

Quanto ao desempenho da determinação das velocidades de laminação, constata-se que a adaptação baseada em redes neurais proporciona sensível evolução para todas as cadeiras, com o significativo detalhe de que as velocidades calculadas pelo sistema proposto tendem a ser maiores do que as calculadas pelo método convencional de adaptação, o que se reflete num ganho de produtividade, altamente desejável. Seguem-se os testes de hipótese para essa grandeza em todas as cadeiras, sendo que em cada caso a hipótese nula é o desempenho da adaptação convencional e a hipótese alternativa é o melhor resultado obtido

com a adaptação neural.

- Cadeira 1: $Z_{\text{CALC}} = \frac{1,0155 - 0,9434}{\frac{0,1185}{\sqrt{84}}} \cong 5,58.$
- Cadeira 2: $Z_{\text{CALC}} = \frac{1,0011 - 0,9252}{\frac{0,1175}{\sqrt{84}}} \cong 5,92.$
- Cadeira 3: $Z_{\text{CALC}} = \frac{1,0166 - 0,9417}{\frac{0,1206}{\sqrt{84}}} \cong 5,69.$
- Cadeira 4: $Z_{\text{CALC}} = \frac{0,9930 - 0,9205}{\frac{0,1139}{\sqrt{84}}} \cong 5,83.$

Em todos os casos, o grau de confiança de 99% para a aceitação da hipótese alternativa foi alcançado.

Considerando-se que a consistência de um modelo (representada pelo desvio-padrão) é mais importância do que a sua acurácia (representada pela média), conclui-se que a adaptação neural apresenta potencial de melhoria para todas as cadeiras

5.5 Recomendações Decorrentes dos Resultados Obtidos

Considerando:

- Que um menor desempenho no cálculo de forças degrada a qualidade de produto (o que não é aceitável);
- Que o sistema permite a seleção independente dos parâmetros (limite de escoamento e/ou coeficiente de atrito) em cuja adaptação será empregada a modelagem neural;
- Que o sistema permite a seleção individual das cadeiras sobre as quais se dará tal atuação,

recomenda-se, em face aos resultados obtidos nesta pesquisa, que se utilize a unicamente a modelagem neural do limite de escoamento, aplicada sobre as cadeiras 3 e 4. Dessa forma,

será proporcionada uma pequena melhoria no cálculo de força, que se traduzirá em maior precisão no controle de espessura (qualidade do produto); além de uma significativa melhoria do cálculo de velocidades, com valores maiores e mais próximos aos efetivamente medidos, o que significa maior produtividade da planta.

Para tornar o sistema efetivo, o código-fonte do utilitário *Sigma_Mu_Calc* deve ser incorporado ao código do modelo matemático da planta e a interface do utilitário deve ser integrada à IHM do Nível 2 da arquitetura de automação, de forma a permitir que o operador lance mão do sistema proposto. Sendo que tanto o *Sigma_Mu_Calc* quanto o modelo matemático foram desenvolvidos em Visual Studio®, sob a plataforma .NET®, tal integração é grandemente facilitada, e poderá ser feita tão logo expire o período de garantia relativo à atualização tecnológica da planta.

Essas recomendações se aplicam ao atual estágio de desenvolvimento do sistema proposto. Esse fato não exclui, obviamente, esforços adicionais no sentido de aperfeiçoar o sistema, segundo as linhas futuras de pesquisa sugeridas no capítulo que se segue.

Capítulo 6 CONCLUSÕES E CONSIDERAÇÕES FINAIS

Esse capítulo final é uma reflexão a respeito da pesquisa como um todo, dos resultados obtidos ao seu final, além de ensejar uma avaliação das oportunidades de melhoria e dos pontos fortes da pesquisa. A análise das oportunidades de melhoria indica linhas futuras de pesquisa que permitirão o aprimoramento dos resultados, enquanto a análise dos pontos fortes permite avaliar a consecução dos objetivos inicialmente propostos.

6.1 Oportunidades de Melhoria

A principal lacuna da pesquisa foi não ter obtido um progresso efetivo do esquema de adaptação por meio da modelagem neural do coeficiente de atrito. Desse modo, a primeira linha adicional de pesquisa a ser perseguida num futuro próximo é aperfeiçoar essa modelagem. Fatores que certamente levarão a tal aperfeiçoamento são:

- O levantamento e solução dos problemas de medição de variáveis relacionadas com o coeficiente de atrito da terceira cadeira (fato constatado durante a fase de desenvolvimento e relatado no Capítulo 4 desta tese).
- A inclusão na base de dados históricos do sistema de informações referentes à lubrificação utilizada na quarta cadeira, com a posterior inclusão dessas informações nas entradas das redes neurais para modelagem do coeficiente de atrito.

Com relação à modelagem neural do limite de escoamento, progressos poderão ser obtidos por meio de providências como:

- Inclusão na base de dados do sistema das informações sobre temperatura de acabamento a quente das tiras laminadas. Tais informações já se encontram disponíveis na base de dados do Laminador de Tiras a Quente, sendo necessário apenas providenciar sua inclusão na base de dados do LTF.
- Inclusão de uma estimativa do limite de escoamento a quente das tiras laminadas. Vallim (2008) desenvolveu um utilitário baseado em RNA para realizar tal estimativa para alguns tipos de aços. A extensão desse trabalho e a incorporação dos seus resultados à base de dados do LTF é uma linha bastante promissora.

Outra deficiência existente no estágio atual do desenvolvimento é a necessidade de realizar periodicamente novos treinamentos das redes neurais que constituem o sistema, para incorporar o aprendizado obtido pelo modelo à medida em aumenta que o número de tiras produzidas. Para superar essa deficiência, a pesquisa futura deve objetivar a atualização contínua dos pesos das redes neurais – o chamado *treinamento on-line*. Embora autores como Lee e Choi (2004) tenham reportado bons resultados aplicando essa técnica a redes do tipo MLP (como as utilizadas no presente trabalho), a revisão bibliográfica indica que ela é mais eficiente quando se usa uma arquitetura recorrente como a preconizada por Elman (1990, *apud* KOSKELA ET AL., 1996). Este tipo de arquitetura possui a característica de atribuir maior peso às informações mais recentes, o que é adequado no que se refere à adaptação.

A utilização sinérgica de outras técnicas de Inteligência Computacional é, conforme o preconizado no Capítulo 3 desta Tese, outra promissora linha de investigação. Tal combinação é recomendada por Höhfeld e Schürmann (1993) e por Tsoukalas e Uhrig (1997), entre outros pesquisadores. No caso específico da presente pesquisa, Algoritmos Genéticos podem ser usados tanto para otimizar a estrutura das redes neurais, como nos trabalhos de Miller, Todd e Hedge (1989) e de Yao e Liu (1998); bem como no treinamento on-line das redes, de um modo semelhante ao reportado por Montana e Davis (1989) e por Angeline, Saunders e Pollack (1994).

Visto que as bobinas usadas na avaliação do sistema desenvolvido cobrem apenas parcialmente a faixa de valores permissíveis para os dados primários das bobinas de entrada, faz-se necessário continuar os testes até que se obtenha uma massa de dados representativa de todo o *mix* de produção da planta. Nesta condição, é bastante provável que se constate que o sistema proposto seja mais eficiente para determinados tipos de materiais do que para outros. Diante de tal constatação, pode ser desenvolvido um sistema de inferência nebulosa que decida pela utilização do mecanismo neural de adaptação com base no material que estiver sendo processado na planta.

Por fim, como a pesquisa se ateve apenas ao limite de escoamento e ao coeficiente de atrito, estudos futuros podem objetivar estender a estratégia neural de adaptação a outros parâmetros incertos que são adaptados de modo convencional, tais como o coroamento térmico dos cilindros de laminação e a cedagem (módulo de elasticidade) do laminador.

6.2 Contribuições da Pesquisa e Consecução dos Objetivos

A principal contribuição da pesquisa é a demonstração da viabilidade da aplicação de Inteligência Computacional como mecanismo principal na adaptação da modelagem matemática do processo de laminação. Tal abordagem é, tanto quanto o autor pôde apurar, inédita. Embora pesquisadores como Schlang, Pöppe e Gramchow (1996) e Schlang *et al.* (2001), todos da Siemens AG, reportem a utilização de redes neurais como ferramenta na adaptação, essa técnica é empregada “*apenas quando não há dados disponíveis* (em relação a um determinado tipo de material – observação nossa) *ou quando o hardware da planta muda subitamente*”, ou seja, apenas em situações excepcionais.

Os autores reportam outra modalidade de utilização dessa técnica: em forma complementar, na qual as redes neurais fornecem um coeficiente de correção que é combinado com o coeficiente adaptativo obtido pela técnica convencional de adaptação. Não há nenhum caso relatado em que a adaptação de um parâmetro incerto seja realizada exclusivamente por meio de redes neurais artificiais.

Bengtsson (2007), da empresa sueca First Control Systems AB, reporta de forma vaga o uso de uma “forma” de rede neural na adaptação do controle de abertura de parafusos num laminador de tiras a frio, mas não dá qualquer detalhe preciso quanto à forma em que a técnica é empregada. Esse artigo possui características técnico-comerciais, mais do que propriamente científicas.

Uma contribuição adicional da pesquisa foi a constatação da importância dos valores absolutos das espessuras de entrada e saída da tira na modelagem neural tanto do limite de escoamento quanto do coeficiente de atrito. Vários trabalhos correlatos, como os de Yang e Linkens (1999), de Phaniraj e Lahiri (2003) e de Ozerdem e Kolukisa (2008) utilizam os valores de deformação e/ou de redução real (*draft*), sem levar em conta os valores efetivos das espessuras.

Além do objetivo principal proposto no item 1.1 desta Tese (a investigação da aplicabilidade da Inteligência Computacional como ferramenta principal na adaptação), podem ser considerados como atingidos os objetivos secundários relatados no mesmo item: maior domínio do processo, desenvolvimento de um aplicativo para aperfeiçoar a adaptação (o *Sigma_Mu_Calc*). Maiores níveis de qualidade e produtividade na planta serão consequência da implantação do sistema desenvolvido, mesmo em seu estágio atual.

6.3 Produção Científica Durante a Pesquisa

No período de realização da pesquisa que resultou na presente Tese, foram produzidos os seguintes trabalhos a ela relacionados:

- Vieira, S.R.C e Santos Filho, A.L. **Acessibilidade das Informações do Sistema Legado de Automação do LTF da Cosipa Utilizando as Tecnologias de Banco de Dados Relacional e Web**. Apresentado no XI Seminário de Automação de Processos da ABM, realizado em Porto Alegre, RS, Brasil, entre 3 e 5 de outubro de 2007, e incluído nos anais do Seminário (1 CD-ROM).
- Santos Filho, A.L. *et al.* **Renovação do Sistema de Automação e Controle do Laminador de Tiras a Frio da Cosipa**. Apresentado no XII Seminário de Automação de Processos da ABM, realizado em Vitória, ES, Brasil, entre 1 e 3 de outubro de 2008, e incluído nos anais do Seminário (1 CD-ROM).
- Santos Filho, A. L. e Ramirez-Fernandez, F.J. **Preset Generation for a Steel Tandem Cold Mill by Means of a Neural Network Tool**. Apresentado no IEEE Symposium Series on Computational Intelligence, realizado em Nashville, Tennessee, USA, entre 30 de março e 2 de abril de 2009, e incluído nos anais do Simpósio (1 CD-ROM).
- Santos Filho, A. L. e Ramirez-Fernandez, F.J. **Inteligência Computacional Aplicada à Adaptação na Modelagem Matemática do Processo de Laminação a Frio de Aços Planos**. Apresentado no XIII Congresso Internacional e Exposição de Automação, Sistemas e Instrumentação (Brazil Automation), realizado em São Paulo, SP, Brasil entre 10 e 12 de novembro de 2009.
- Santos Filho, A. L. e Ramirez-Fernandez, F.J. **A Neural Network-Based Preset Generation Tool for a Steel Tandem Cold Mill**. Aceito para publicação no periódico Engineering Applications of Artificial Intelligence, da Elsevier.

6.4 Considerações Finais

A quantidade de linhas complementares de pesquisa sugeridas acima fala por si só sobre as possibilidades de aprimoramento do sistema desenvolvido. No entanto, os resultados

obtidos permitem avaliar que, já no presente estágio de desenvolvimento, os objetivos originalmente propostos foram plenamente atingidos.

Como efeito adicional, a pesquisa gerou a necessidade de um aprofundamento no estudo sobre os princípios e características do modelo matemático de otimização do processo, o que proporcionou aos engenheiros de processo e automação uma compreensão mais ampla sobre esse modelo. Além disso, levou à descoberta de problemas até então não percebidos, como os constatados na medição das variáveis relacionadas ao coeficiente de atrito da terceira cadeira. Desse modo, os resultados obtidos na pesquisa e relatados na presente Tese vêm ao encontro da filosofia de melhoria contínua que caracteriza a Política de Qualidade da Usiminas.

A pesquisa confirma o extraordinário potencial de aplicação das Redes Neurais Artificiais como abordagem alternativa a problemas complexos de Engenharia, ao mesmo tempo em que, confirmando a tese de Curry e Morgan (1997) e de Morris e Martin (1998), desmistifica a idéia de que essa ferramenta seja uma panacéia universal que resolva qualquer tipo de problema com base apenas na abundância de dados. Em resumo, a disponibilidade de dados não pode, em absoluto, substituir ou prescindir de um sólido conhecimento a respeito do problema abordado.

REFERÊNCIAS

- AHN, C.W.; RAMAKRISHNA, R.S. Elitism-based Compact Genetic Algorithms. **IEEE Transactions on Evolutionary Computing**, v. 7, n. 4, p. 367-385, 2003.
- ALEXANDER, J. M. On the Theory of Rolling. **Proceedings of the Royal Society**, v. A326, p. 535-555, 1972.
- ANGELINE, P.J.; SAUNDERS, G.M.; POLLACK, J.B. An Evolutionary Algorithm That Constructs Recurrent Neural Networks. **IEEE Transactions on Neural Networks**, v. 5, n. 1, p. 111-122, 1994.
- ARIMURA, T.; KAMATA, M.; SAITO M. An Analysis Into the Dynamic Behavior of Tandem Cold Mills By a Digital Computer and Its Application. **Transactions of the Iron and Steel International Journal**, v. 11, p. 777-781, 1971.
- ATACK, P.A.; ROBINSON, I. Adaptation of Hot Mill Process Models. **Journal of Materials Processing Technology**, v.60, p. 535-542, 1996.
- AYLEN, J. Megabytes for Metals: Development of Computer Applications in the Iron and Steel Industry. **Ironmaking and Steelmaking**, v. 31, n. 6, p. 465-478, 2004.
- BASHEER, I.A.; HAJMEER, M. Artificial Neural Networks: Fundamentals, Computing, Design and Application. **Journal of Microbiological Methods**. v.43, p. 3-31, 2000.
- BEAL, B. Rolling Mills Gauge Control Components (A White Paper). **Homepage de referência técnica da companhia Pfeiffer Engineering**. Disponível em: <<http://www.pfeiffereng.com/Gauge%20Control%20Components.PDF>>. Acesso em 1 de mar. 2009.
- BEGUIN, J.-M.; CARLEY, M. **Industrial Relations in the Steel Industry**. European Foundation for the Improvement of Living and Working Conditions, Dublin, 2005. Disponível em: <<http://www.eurofound.eu.int/publications/files/EF0581EN.pdf>>. Acesso em 16 mai. 2006.
- BÈLE, B. *ET AL.* Adaptive Prediction of Steel Hardness on Hot Strip Mill Using Neural Networks and K-Means Classifier. In: IFAC SYMPOSIUM ON AUTOMATION ON MINING, MINERAL AND METAL, 11, Nancy, France, 2004. **Proceedings...** London:

Elsevier, 2004.

BENGTSSON, G. Improved AGC Control in Cold Rolling Using Learning Technology. **Homepage de divulgação da companhia First Control Systems AB.** Disponível em: <http://www.firstcontrol.se/INFO_Improved_AGC_Control.pdf>. Acesso em 12 set. 2007.

BLAND, D.R.; FORD, H. Cold Rolling With Strip Tension, Part III: An Approximate Treatment of the Elastic Compression of the Strip in Rolling Mills. **Journal of the Iron and Steel Institute**, v.172, p. 245-249, 1952.

BOLON, P.-L. **CORUM Tandem Cold Mill Setup Model: COSIPA Implementation.** Cergy Le-Haut: Davy-Clecim, 1996. (Documento Interno K10671 da Usiminas).

BONISSONE, P.P. Soft Computing: The Convergence of Emerging Reasoning Technologies. **Soft Computing**, v. 1, p. 6-18, 1997.

BREZOCNIK, M.; BALIC, J.; KAMPUS, Z. Modeling of Forming Efficiency Using Genetic Programming. **Journal of Materials Processing Technology**, v.109, p.20-29, 2001.

BROOMHEAD, D.S.; LOWE, D. Multivariable Functional Interpolation and Adaptive Networks. **Complex Systems**, v.2, p. 321-355, 1988.

BRYANT, G.F.; HALLIDAY, J.M.; SPOONER, P. D. Optimal Scheduling of a Tandem Cold Rolling Mill. In: Bryant, G.F. (Ed.) **Automation of Tandem Mills.** London: The Iron and Steel Institute, 1973. p. 107-118.

BYON, S.M; KIM, S.I.; LEE, Y. A Numerical Approach to Determine Flow Stress-Strain Curve of Strip and Friction Coefficient in Actual Cold Rolling Mill. **Journal of Material Processing Technology**, v. 201, p. 106-111, 2008.

CALEY; J.M.; EDWARDS, W.J. Cold-rolling-mill Control-system Design Part 4: Design of a Feedforward Control System. In: Bryant, G.F. (Ed.) **Automation of Tandem Mills.** London: The Iron and Steel Institute, 1973. p. 61-80.

CHAKRABORTI, N. *ET AL.* Optimizing Surface Profiles During Hot Rolling: a Genetic Algorithms Based Multi-objective Optimization. **Computational Materials Science**, v. 37, n. 1-2, p. 159-165, 2006.

CHO, S.; CHO, Y.; YOON, S. Reliable Roll Force Prediction in Cold Mill Using Multiple Neural Networks. **IEEE Transactions on Neural Networks**, v. 8, n.4, p.874-882, 1997.

CHUNG, J.S. *ET AL.* Process Optimal Design in Tandem Cold Rolling By Genetic Algorithm. In: ISS MECHANICAL WORKING AND STEEL PROCESSING CONFERENCE, 44, Orlando, USA, 2002. **Proceedings...** Warrendale: Iron and Steel Society, v. 40, p. 3-13, 2002.

COURCOULAS, J.H.; HAM, J.M. Incremental Control Equation for Tandem Rolling Mills. **AIEE Transactions**, v. 75, pt II, p. 363-374, 1957.

CURRY, B.; MORGAN, P. Neural Networks: A Need for Caution. **Omega International Journal of Management Science**, v.25, p.123-133, 1997.

CYBENKO, G. **Continuous Valued Neural Networks With Two Hidden Layers Are Sufficient.** Medford, Massachusetts: Department of Computer Science, Tufts University, 1988. (Technical Report).

DENTI FILHO, J.; FARDIM, J.F.; SILVA, S. Uma Aplicação de Algoritmos Genéticos no Estabelecimento e Controle do Processo de Laminação de Tiras. In: CONGRESSO ANUAL DA ABM, 55, Rio de Janeiro, Brasil, 2000. **Anais...** São Paulo, ABM, p. 2554-2563, 2000. 1 CD-ROM.

DIXIT, U.S.; CHANDRA, S.A. Neural Network Based Methodology for the Prediction of Roll Force and Roll Torque in Fuzzy Form for Cold Flat Rolling Process. **The International Journal of Advanced Manufacturing Technology**, v. 22, n.11-12, p. 883-889, 2003.

DUCH, W. What Is Computational Intelligence and What Could It Become? In: DUCH, W; MANDZIUK, J. (Eds.) **Challenges for Computational Intelligence.** Springer, 2007. Disponível em: <cogprints.org/5358/01/06-CIdef.pdf>. Acesso em 21 mai. 2008.

DUROVSKÝ, F.; ZBORAY, L.; FERKOVÁ, Z. Computation of Rolling Stand Parameters by Genetic Algorithm. **Acta Polytechnica Hungarica**, v. 5, n. 2, p. 59-70, 2008.

EDWARDS, J. K. Automation of Cold Tandem Mills. In: INTERNATIONAL CONFERENCE ON FLAT ROLLING, Cardiff, United Kingdom, 1978. **Proceedings...** p.112-130, 1978.

ESHELMAN, L.J.; CARUANA, R.A.; SCHAFFER, J.D. Biases in the Landscape. In: INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS, 3, Fairfax, USA, 1989. **Proceedings...** San Mateo: Morgan Kaufman Publishers, 1989.

FECHNER, T.; NEUMERKEL, D.; Keller, I. Adaptive Neural Network Filter for Steel Rolling. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE, 4, Orlando, USA, 1994. **Proceedings...** Aachen: ELITE Foundation, 1996, p. 3915-3920.

FERRARI, S.; STENGEL, R.F. Smooth Function Approximation Using Neural Networks. **IEEE Transactions on Neural Networks**, v. 16, n. 1, p. 24-38, 2005.

FERREIRA, A.B.S. **Adaptive Fuzzy Logic Steering Controller for a Steckel Mill**. Johannesburg, South Africa, 2005. 204 p. Dissertação (Mestrado) – Faculty of Engineering, University of Johannesburg. Disponível em: etd.uj.ac.za/theses/available/etd-10022006-113838/restricted/909220186.pdf. Acesso em 15 jan. 2007.

FONSECA, J.S.; MARTINS, G.A. **Curso de Estatística**. São Paulo: Editora Atlas, 1996. 320 p.

FORD, H.; ELLIS, F.; BLAND, D.R. Cold Rolling With Strip Tension, Part I: A New Approximate Method and a Comparison With Other Methods. **Journal of the Iron and Steel Institute**, v.168, n.1, p.57-72, 1951.

FORD, H.; ELLIS, F. Cold Rolling With Strip Tension, Part II: Comparison of Calculated and Experimental Results. **Journal of the Iron and Steel Institute**, v.171, p.239-245, 1952.

FRESHWATER, I.J. Simplified Theories of Flat Rolling – I. The Calculation of Roll Pressure, Roll Force and Roll Torque. **International Journal of Mechanical Science**, v. 38, n. 6, p. 633-648, 1996.

FUKUDA, T.; KUBOTA, N. Computational Intelligence – Fuzzy, Neural and Evolutionary Computing. In: JOINT IFSA WORLD CONGRESS AND NAFIPS INTERNATIONAL CONFERENCE, Vancouver, Canada, 2001. **Proceedings...** p.2084-2089, 2001.

GINZBURG, V.B. **Metallurgical Design of Flat Rolled Steels**. New York: Marcel Dekker,

2004. 744 p.

GOLDBERG, D.E. **Genetic Algorithms in Optimization, Search and Machine Learning**. Boston: Addison-Wesley Longman Publishing Company, 1989. 410 p.

GOMIDE, F.A.C.; GUDWIN, R.R. Modelagem, Controle, Sistemas e Lógica Fuzzy. **SBA Controle e Automação**, v.4, n. 3, p. 98-115, 2004.

GORNI, A.A. **The Modeling of Hot Rolling Processes Using Neural Networks: A Bibliographical Review**. 1998. Disponível em: <www.gorni.eng.br/e/neural_1998.html>. Acesso em: 30 out. 2008.

GRIMBLE, M.J.; FULLER, M.A.; BRYANT, G.F. A Non-Circular Arc Roll Force Model for Cold Rolling. **International Journal for Numerical Methods in Engineering**, v. 12, n. 4, p. 643-663, 1978.

GUO, R.-M. Analysis of Dynamic Behaviors of Tandem Cold Mills Using Generalized Dynamics and Control Equations. **IEEE Transactions on Industry Applications**, v.36, n.3, p.842-853, 2000.

HASSOUN, M.H. **Fundamentals of Artificial Neural Networks**. Cambridge: MIT Press, 1995. 512 p.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. London: MacMillan, 1994. 700 p.

HE, L. *ET AL*. The Combination and Prospects of Neural Networks, Fuzzy Logic and Genetic Algorithms. In: IEEE MIDNIGHT-SUN WORKSHOP ON SOFT COMPUTING METHODS IN INDUSTRIAL APPLICATIONS, Kuusamo, Finland, 1999. **Proceedings...** IEEE Press, p. 52-57, 1999.

HELMAN, H.; CETLIN, P.R. **Fundamentos da Conformação Mecânica dos Metais**. Belo Horizonte: Fundação Christiano Ottoni, 1993. 170 p.

HERNANDEZ, E.D.M. **Inteligência Computacional e Redes Neurais Artificiais em Engenharia Elétrica**. São Paulo, Universidade de São Paulo, ago. 2005. Seminário 2 de PSI-2222 Práticas de Eletricidade e Eletrônica II. Disponível em: <<http://www.lps.usp.br/lps/arquivos/conteudo/grad/dwnld/RedesNeurais.pdf>>. Acesso em 15

out. 2008.

HESSENBERG, W.C.F.; JENKINS, W.N. Effects of Screw and Speed Setting Changes on Gauge, Speed and Tension in Tandem Mills. **Proceedings of the Institute of Mechanical Engineers**, v.169, p.1051-1058, 1957.

HINES, J. W. **Matlab Supplement to Fuzzy and Neural Approaches in Engineering**. New York: Wiley-Interscience, 1997. 212 p.

HODGSON, P.D.; MCFARLANE, D.; GIBBS, R.K. The Mathematical Modelling of Hot Rolling: Accuracy vs. Utility. In: INTERNATIONAL CONFERENCE ON MODELING METAL ROLLING PROCESS, 1, London, United Kingdom, 1993. **Proceedings...** p. 2-15, 1993.

HÖHFELD, M.; SCHÜRMANN, B. The Roles of Neural Networks and Fuzzy Logic in Process Optimization. **Siemens Review** (R&D Special), pp. 9-13, 1993.

HUFBAUER, G.C.; GOODRICH, B.K. **Time for a Grand Bargain in Steel?** Policy Brief PB-02-01. Institute for International Economics. Washington DC. January, 2002. Disponível em: <<http://www.ciaonet.org/pbei/ie/hug02/>>. Acesso em 15 mai. 2006.

HWANG, Y.; BANG, S. An Efficient Method to Construct a Radial Basis Function Neural Network Classifier. **Neural Networks**, v.10, n.8, p.1495-1503, 1997.

IEEE COMPUTATIONAL INTELLIGENCE SOCIETY. Apresenta os princípios e áreas de interesse da Sociedade. Disponível em: <http://ieee-cis.org/about_cis/>. Acesso em 16 out. 2008.

IIDA, O.; URAKAMI, M.; IWAMURA, T. Applications and Evaluation of AI Technology in the Steel Industry. In: IEEE INTERNATIONAL WORKSHOP ON EMERGING TECHNOLOGIES AND FACTORY AUTOMATION, 2, Sidney, Australia, 1993. **Proceedings...** IEEE Press, v. 1, p. 165-163, 1994.

INTEGRATED PROCESS AUTOMATION AND CONTROL TECHNOLOGIES. Cold Processing. **Homepage da Companhia Integradora**. Disponível em: <<http://www.ipact.com/coldprocessing.htm>>. Acesso em 25 de abr. 2003.

JANABI-SHARIF, F.; FAN, J. Self-Tuning Fuzzy Loop Control for Rolling Mills. In: IEEE

CONFERENCE ON DECISION AND CONTROL, 39, Sydney, Australia, 2000. **Proceedings...** IEEE Press, v. 1, p. 376-381, 2000. Disponível em:

<<http://citeseer.ist.psu.edu/421283.html>>. Acesso em 15 dez. 2006.

JANABI-SHARIF, F.; LIU, J. Genetic Fuzzy Tension Controller for Tandem Rolling. In: IEEE INTERNATIONAL SYMPOSIUM ON INTELLIGENT CONTROL, 17, Vancouver, Canada, 2002. **Proceedings...** IEEE Press, v. 1, p. 315-320, 2002.

JANABI-SHARIF, F.; LIU, J. Design of a Self-Adaptive Fuzzy Tension Controller for Tandem Rolling. **IEEE Transactions on Industrial Electronics**, v. 52, n. 5, p. 1428-1438, 2005.

JIA, C.-Y.; SHAN, X.-Y.; NIU, Z.-P. High Precision Prediction of Rolling Force Based on Fuzzy and Nerve Method for Cold Tandem Mill. **International Journal of Iron and Steel Research**, v. 15, n. 2, p. 23-27, 2008.

JIANG, Z.Y. *ET AL.* Modelling of the Effect of Friction on Cold Strip Rolling. **Journal of Materials Processing Technology**, v. 201, p. 85-90, 2008.

JUNG, J.-Y.; IM, Y.-T; LEE-KWANG, H. Development of Fuzzy Control Algorithm for Shape Control in Cold Rolling. **Journal of Materials Processing Technology**, v. 48, p. 187-195, 1995.

KIRIHATA, A. *ET AL.* Mathematical Modelling of Mean Flow Stress During the Hot Strip Rolling of Multiply-alloyed Medium Carbon Steels. **ISIJ International**, v. 38, n. 2, p. 187-195, 1998.

KOHONEN, T. **Self-Organization and Associative Memory**. New York: Springer-Verlang, 1988. 312 p.

KONAK, A.; COIT, D.W.; SMITH, A.E. Multi-objective Optimization Using Genetic Algorithms: a Tutorial. **Reliability Engineering & System Safety**, v. 91, p. 992-1007, 2006.

KOSKELA, T. *ET AL.* Time Series Prediction With Multilayer Perceptron, FIR and Elman Neural Networks. In: WORLD CONGRESS ON NEURAL NETWORKS, San Diego, USA, 1996. **Proceedings...** International Neural Networks Society, p. 491-495, 1996.

LACASSE, R.; FROMONT, J.; SORIN, F. Control Model For a Tandem Cold Mill. **Steel**

Technology International, p.275-279, 1989.

LANG, B. Monotonic Multi-layer Perceptron Networks as Universal Approximators. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORKS, Warsaw, Poland, 2005. **Proceedings...** Springer-Berlin / Heidelberg, p. 31-37, 2005.

LAPEDES, A.S.; FARBER, R. **Nonlinear Signal Processing Using Neural Networks: Prediction and System Modeling**. New Mexico: Los Alamos National Laboratory, 1987. (Technical Report LA-UR-87-2662).

LARKIOLA, J. *ET AL*. Prediction of Rolling Force in Cold Rolling by Using Physical Models and Neural Computing. **Journal of Materials Processing Technology**, v.60, p.381-386, 1996.

LARKIOLA, J. *ET AL*. The Role of Neural Networks in the Optimisation of Rolling Processes. **Journal of Materials Processing Technology**, v.80-81, p.16-23, 1998.

LAUMANN, M.; ZITZLER, E.; THIELE, L. On the Effects of Archiving, Elitism and Density Based Selection in Evolutionary Multi-objective Optimization. In: CONFERENCE ON EVOLUTIONARY MULTI-CRITERION OPTIMIZATION, 1, Zurich, Switzerland, 2001. **Proceedings...** Berlin: Springer-Verlag, p. 181-196, 2001.

LEE, C.C. Fuzzy Logic in Control Systems: Fuzzy Logic Controller – Part I. **IEEE Transaction on Systems, Man and Cybernetics**, v. 20, n. 2, p. 404-418, 1990.

LEE, D.M.; CHOI, S.G. Application of On-line Adaptable Neural Network for the Rolling Force Set-up of a Plate Mill. **Engineering Applications of Artificial Intelligence**, v. 17, p. 557-565, 2004.

LENARD, J.G. Study of the Predictive Capabilities of Mathematical Models of Flat Rolling. In: INTERNATIONAL STEEL ROLLING CONFERENCE, 4, Deauville, France, 1987. **Proceedings...** Maizières-les-Metz: IRSID, v. 1, p. B4-1 – B4-10, 1987.

LENARD, J.G. An Examination of the Coefficient of Friction. In: LENARD, J. G. (ed.) **Metal Forming Science and Practice**. London: Elsevier, 2002. p. 85-114.

LENARD, J.G. **Primer on Flat Rolling**. London: Elsevier, 2007. 368 p.

LENARD, J.G.; MALINOWSKI, Z.; PIETRZYK, M. Comparison of the Predictive Capabilities of Mathematical Models of the Flat Rolling Process. **Journal of Materials Processing Technology**, v.34, p.85-92, 1992.

LI, G-Y. Analytical Equations for On-line Modelling of Friction in Cold Rolling. In: INTERNATIONAL CONFERENCE ON MODELLING OF METAL ROLLING PROCESSES, 3, London, United Kingdom, 1999. **Proceedings...** London: The Institute of Metals, p. 370-379, 1999.

LI, G.-Y.; LAGERGREN, J. Evaluation on Some Important Force Models for Cold Strip Rolling. **Steel Research**, v. 71, n. 11, p. 449-459, 2000.

LUINENBERG, A.W.; ONINK, O.; RITMAN, V.A. New Physical On-line Model for Coiling Temperature Control. In: INTERNATIONAL CONFERENCE ON STEEL ROLLING, 7, Chiba, Japan, 1998. **Proceedings...** The Iron and Steel Institute of Japan, Tokyo, p. 87-92, 1998.

MALIK, A.S.; GRANDHI, R.V. A Computational Method to Predict Strip Profile in Rolling Mills. **Journal of Materials Processing Technology**, v. 206, n. 1-3, p. 263, 274, 2008.

MCCONNELL, C.; LENARD, J.G. Friction in Cold Rolling of a Low Carbon Steel With Lubricants. **Journal of Materials Processing Technology**, v. 99, p. 86-93, 2000.

MEIRELES, M.R.G; ALMEIDA, P.E.M.; SIMÕES, M.G. A Comprehensive Review for Industrial Applicability of Artificial Neural Networks. **IEEE Transactions on Industrial Electronics**, v.50, n.3, p. 585-601, 2003.

MENDEZ, G.M. *ET AL.* Temperature Prediction in Hot Strip Mill Bars Using a Hybrid Type-2 Fuzzy Algorithm. **International Journal of Simulation**, v. 6, n. 9, p. 33-43, 2005.

MILLER, G.F.; TODD, P.M.; HEDGE, S.U. Designing Neural Networks Using Genetic Algorithms. In: INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS, 3, Fairfax, USA, 1989, **Proceedings...** San Francisco: Morgan Kaufmann Publishers, p. 379-384, 1989.

MIRANDA, A.M.; BARBOSA, R.A.N.M.; CUNHA, M.A. Modelamento Matemático de Cargas na Fabricação de Tiras a Quente no Laminador Steckel. In: SEMANA DA

CONFORMAÇÃO, 1, Joinville, Brasil, 1993, **Anais...** São Paulo: Associação Brasileira de Metalurgia e Materiais, p. 307-318, 1993.

MITCHELL, M. **An Introduction to Genetic Algorithms**. Cambridge, Massachusetts: The MIT Press, 1999. 226 p.

MONTANA, D.J.; DAVIS, L.D. Training Feedforward Networks Using Genetic Algorithms. In: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 11, Detroit, USA, 1989, **Proceedings...** New Jersey: Lawrence Erlbaum Associates, v. 1, p. 762-767, 1996.

MOODY, J.; DARKEN, C.J. Fast Learning in Networks of Locally Tuned Processing Units. **Neural Computation**, v.1, p.281-294, 1989.

MORITA, Z.-I.; EMI, T. **An Introduction to Iron and Steel Processing**. Kawasaki Steel 21st Century Foundation, Tokyo, 2002. Disponível em:
<http://www.jfe-21st-cf.or.jp/chapter_3/3b_2.html>. Acesso em 21 jan. 2007.

MORRIS, A.J.; MARTIN, E.B. Neural Networks: Panacea or Pragmatic Solution? In: APPLICATIONS OF ARTIFICIAL NEURAL NETWORK SYSTEMS IN THE STEEL INDUSTRY, Brussels, Belgium, 1998. **Proceedings...** Luxembourg: European Communities, 1998. p. 9-42, 1998.

NANDAN, R. *ET AL*. Regulating Crown and Flatness During Hot Rolling: A Multiobjective Optimization Study Using Genetic Algorithms. **Materials and Manufacturing Processes**, v. 20, p. 459-478, 2005.

NISHINO, S. *ET AL*. An Adaptive Approach to Improve the Accuracy of a Rolling Load Prediction Model for a Plate Rolling Process. **ISIJ International**, v. 40, n. 12, p. 1216-1222, 2000.

OLIVEIRA, A.R.E. The Contribution of Coulomb to Applied Mechanics. In: INTERNATIONAL SYMPOSIUM ON HISTORY OF MACHINES E MECHANISMS, Cassino, Italy, 2004, **Proceedings...** The Netherlands: Kluwer Academic Publishers, p. 217-226, 2004.

OSMAN, N.Y. **The Development of a Predictive Damage Condition Model of Light**

Structures on Expansive Soils Using Hybrid Artificial Intelligence Techniques. 2007. 205 p. Tese (Doutorado) – Swinburne University of Technology, Melbourne, Australia, 2007.

Disponível em:

<http://adt.lib.swin.edu.au/uploads/approved/adt-SWT20071002.131831/public/02whole.pdf>>. Acesso em 20 nov. 2008.

OZERDEM M.S.; KOLUKISA, S. Artificial Neural Network Approach to Predict Mechanical Properties of Hot Rolled, Nonresulfurized, AISI 10xx Series Carbon Steel Bars. **Journal of Materials Processing Technology**, v. 199, p. 437-439, 2008.

PARKER, D. B. **Learning Logic**. Stanford: Office of Technology Licensing, University of Stanford, 1982. (Invention Report S81-64, File 1).

PAWELSKI, H. An Analytical Model for Dependence of Force and Forward Slip on Speed in Cold Rolling. **Steel Research**, v. 74, n. 5, p. 293-299, 2003.

PETTY, D.M. Application of Process Modelling – An Industrial View. **Journal of Materials Processing Technology**, v.60, p. 421-426, 1996.

PHANIRAJ, M.P.; LAHIRI, A.K. The Applicability of Neural Network Model to Predict Flow Stress for Carbon Steels. **Journal of Materials Processing Technology**, v. 141, p. 219-227, 2003.

PIRES, C.T.A. **Sistema de Otimização e Adaptação Para a Geração de Referências em um Laminador de Tiras a Frio**. 2007. 97 p. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2007.

PIRES, C.T.A.; FERREIRA, H.C.; SALES, R.M. Adaptation for Tandem Cold Mill Models. **Journal of Materials Processing Technology**, v. 209, n. 7, p. 3592-3596, 2009.

POGGIO, T.; GIROSI, F. A Theory of Network for Approximation and Learning. **Proceedings of the IEEE**, v.78, p.1481-1497, 1990.

POWELL, M.J.D. Radial Basis Functions for Multivariable Interpolation: A Review. In: IMA CONFERENCE ON ALGORITHMS FOR THE APPROXIMATION OF FUNCTIONS AND DATA, Shrivenham, United Kingdom, 1985. **Proceedings...** Shrivenham: Royal Military College of Science, p.143-167, 1985.

QUINN, S.L.; VACULIK, V. Improving the Desulfurization Process Using Multivariate Statistical Modeling. **AISE Steel Technology**, v. 79, n. 7-12, p. 37-41, October, 2002.

RAFIQ, M.Y.; BUGMANN, G.; EASTERBROOK, D.J. Neural Network Design for Engineering Applications. **Computers and Structures**, v. 79, p. 1541-1552, 2001.

RANDALL, A. *ET AL.* Adaptive Finishing Mill Setup Model and Gage Control for LTF Steel Cleveland Works' 80-in Hot Strip Mill. **Iron and Steel Engineer**, p.31-40, August, 1997.

REDDY, N.V; SURYANARAYANA, G. A Set-Up Model for Tandem Cold Rolling Mills. **Journal of Materials Processing Technology**, v. 173, p. 269-277, 2001.

REEVE, P. J.; MACALISTER, A. F.; BILKHU, T. S. Control, Automation and the Hot Rolling of Steel. **Philosophical Transactions of the Royal Society A**, v. 357, p. 1549-1571, 1999.

RENALS, S. Radial Basis Function Network for Speech Pattern Classification. **Electronic Letters**, v. 25, p.461-467, 1989.

ROBERTS, W.L. **Cold Rolling of Steel**. New York: Marcel Dekker, 1978. 800 p.

RÖSCHEISEN, M.; HOFMANN, R.; TRESP, V. Neural Control for Rolling Mills: Incorporating Domain Theories To Overcome Data Deficiency. In: ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS CONFERENCE, 5, Denver, USA, 1992. **Proceedings...** Morgan Kaufman, p. 659-666, 1993.

ROSSOMANDO, F.G.; FERREIRA, E.P.; DENTI FILHO, J. Controle Neural Adaptativo de um Trem de Laminação a Quente. In: LARRETEGUY, A. (Ed.) **Mecânica Computacional**, v. 24. Buenos Aires, Argentina, p. 995-1008, 2005.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS R.J. Learning Representations by Back Propagating Errors. **Nature**, v. 323, p.533-536, 1986.

SANTOS FILHO, A.L.; NOVAES, G.O; ASSIS, C.F. A Automação na Reforma do Laminador de Tiras a Frio da COSIPA. In: SEMINÁRIO DE AUTOMAÇÃO DE PROCESSOS DA ABM, 3., 1999, São Paulo. São Paulo: ABM, 1999. **Anais...** 1 CD-ROM.

SANTOS FILHO, A.L. **Geração de Referências para os Controladores de um Laminador**

a Frio de Aços Planos: Uma Abordagem Conexcionista. 2003. 142p. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2003.

SANTOS FILHO, A.L.; RAMIREZ-FERNANDEZ, F.J. Controle do Processo de Laminação a Frio com Referências de Segurança Definidas por Meio de Redes Neurais Artificiais. **InTech Brasil**, n. 58, p. 24-38, 2003.

SANTOS FILHO, A.L. *ET AL.* Renovação do Sistema de Automação e Controle do Laminador de Tiras a Frio da COSIPA. In: SEMINÁRIO DE AUTOMAÇÃO DE PROCESSOS DA ABM, 12., 2008, Vitória. São Paulo: ABM, 2008. **Anais...** 1 CD-ROM.

SANTOS FILHO, A.L.; RAMIREZ-FERNANDEZ, F.J. Preset Generation for a Steel Tandem Cold Mill By Means of a Neural Network Tool. In: IEEE SYMPOSIUM SERIES ON COMPUTATIONAL INTELLIGENCE, Nashville, USA, 2009. **Proceedings...** 1 CD-ROM.

SBARBARO-HOFER, D.; NEUMERKEL, D.; HUNT, K. Neural Control of a Steel Rolling Mill. **IEEE Control Systems Magazine**, p.69-75, June, 1993.

SCHLANG, M.; PÖPPE, T.; GRAMCHOW, O. Neural Networks for Steel Manufacturing. **IEEE Expert**, p. 8-9, August, 1996.

SCHLANG, M. *ET AL.* Current and Future Development in Neural Computation in Steel Processing. **Control Engineering Practice**, v. 9, p. 975-986, 2001.

SCHIPPER, G.H. *ET AL.* A Preset Model for a Modernised Cold Strip Rolling Mill for Packaging Steel. In: INTERNATIONAL CONFERENCE ON STEEL ROLLING, 7, Chiba, Japan, 1998. **Proceedings...** The Iron and Steel Institute of Japan, Chiba, 1998, p. 134-138.

SCHMITZ, A.; HERMAN, J.C. Modelisation du Laminage a Froid des Aciers: Étude des Aspects Métallurgiques, Analyse par la Méthode des Tranches. Disponível em: <http://www.crm-eur.com/F-PUBLICATIONS/media/fpms95.pdf>. Acesso em 21 fev. 2007.

SCHMUTTER, P. **Object-Oriented Ontogenic Programming: Breeding Computer Programs That Work Like Multicellular Creatures.** Dortmund, 2002. 100 p. Tese (Doutorado) – Universität Dortmund. Disponível em: <http://www.evodi.org/publications/ooop-thesis.pdf>. Acesso em: 16 out. 2008.

SCHWENKER, F.; KESTLER, H.A.; PALM, G. Three Learning Phases for Radial-Basis-Function Networks. **Neural Networks**, v.14, p.439-458, 2001.

SELLARS, C.M. Modelling: An Interdisciplinary Activity. In: INTERNATIONAL SYMPOSIUM ON MATHEMATICAL MODELLING OF HOT ROLLING OF STEEL, Hamilton, Canada, 1990. **Proceedings...** Canadian Institute of Mining and Metallurgy, p. 1-18, 1990.

SINGH, S.B. *ET AL.* Neural Network Analysis of Steel Plate Processing. **Ironmaking and Steelmaking**, v. 25, n. 5, p. 355-365, 1998.

SHAPIRO, A.F. The Merging of Neural Networks, Fuzzy Logic, and Genetic Algorithms. **Insurance Mathematics & Economics**, v. 31, p. 115-131, 2002.

SHARMA, U.; PARFITT, G.I. Fuzzy Logic Application in Cold Rolling. In: PROCESS TECHNOLOGY CONFERENCE, 8, Dearborn, USA, 1998. **Proceedings...** The Iron and Steel Society, p. 703-708, 1998.

SHIVPURI, R.; CHOU, P.C. A Comparative Study of Slab, Upper Bound and Finite Element Methods for Predicting Force and Torque in Cold Rolling. **International Journal of Machine Tools and Manufacture**, v. 29, n. 3, p. 305-322, 1989.

SILVA, D. Acordo Ortográfico: Tem um VOLP no Meio do Caminho. **Observatório da Imprensa**, edição de 26 mai. 2009. Disponível em:
<<http://observatorio.ig.com.br/artigos.asp?cod=539FDS001>>. Acesso em 26 jul. 2009.

SON, J.S. *ET AL.* A Study on Genetic Algorithm to Select the Architecture of a Optimal Neural Network in the Hot Rolling Process. **Journal of Materials Processing Technology**, v.153-154, p. 643-648, 2004.

SUTCLIFFE, M.P.F; RAYNER, P.J. Experimental Measurements of Load and Strip Profile in Thin Strip Rolling. **International Journal of Mechanical Sciences**, v. 40, n. 9, p. 887-899, 1998.

SVOZIL, D.; KVASNICKA, V.; POSPÍČHAL, J. Introduction to Multi-layer Feed-forward Neural Networks. **Chemometrics and Intelligent Laboratory Systems**, v. 39, p. 43-62, 1997.

TAKAGI, H. Fusion Technology of Neural Networks and Fuzzy Logic: A Chronicled Progression from the Laboratory to Our Day Lives. **International Journal of Applied Mathematics and Computer Science**, v. 10, n. 4, p. 647-673, 2000.

TAN, X. *ET AL.* Dynamic Friction Model and Its Application in Flat Rolling. **Journal of Materials Processing Technology**, v. 207, p. 222-234, 2008.

TIEU, A.K. *ET AL.* Material Resistance and Friction in Cold Rolling. In: WORLD CONGRESS OF STRUCTURAL AND MULTIDISCIPLINARY OPTIMIZATION, 6, Rio de Janeiro, Brazil, 2005. **Proceedings...** Disponível em:

<www.wcsmo6.org/papers/261.pdf>. Acesso em: 15 mai. 2007.

TOWNSEND, A.A.R. **Genetic Algorithms – a Tutorial**. 2003. Disponível em:

<www-course.cs.york.ac.uk/evo/SupportingDocs/TutorialGAs.pdf>. Acesso em: 5 fev. 2008.

TSOUKALAS, L.H.; UHRIG, R.E. **Fuzzy and Neural Approaches in Engineering**. New York: Wiley-Interscience, 1997. 587 p.

UHRIG, R.E. Introduction to Neural Networks. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL ELECTRONICS, CONTROL AND INSTRUMENTATION, 21, Orlando, USA, 1995. **Proceedings...** Disponível em:

<http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=483329>. Acesso em: 26 jun. 2009.

VALLIM, P.S.S. **Aplicação de Rede Neural ao Cálculo da Tensão de Escoamento e da Força Específica de Laminação de Aços C-Mn Processados em um Laminador de Tiras a Quente**. São Paulo, 2008, 194 p. Monografia (MBA). Escola Politécnica, Universidade de São Paulo.

VAN ECK, N.J. *ET AL.* Visualizing the Computational Intelligence Field. **IEEE Computational Intelligence Magazine**, p. 6-10, nov. 2006.

VENKATESAN, P.; ANITHA, S. Application of Radial Basis Function Neural Network for Diagnosis of *Diabetes Mellitus*. **Current Science**, v. 91, n. 9, p. 1195-1199, 2006.

VIEIRA, S.R.C.; SANTOS FILHO, A.L. Acessibilidade das Informações do Sistema Legado de Automação do LTF da Cosipa Utilizando as Tecnologias de Bancos de Dados Relacional e Web. In: SEMINÁRIO DE AUTOMAÇÃO DE PROCESSOS DA ABM, 11, 2007, Porto

Alegre. São Paulo: ABM, 2007. **Anais...** 1 CD-ROM.

WANG, D.D.; TIEU, A.K.; D'ALESSIO, G. Computational Intelligence-Based Process Optimization for Tandem Cold Rolling. **Materials and Manufacturing Processes**, v. 20, p. 479-496, 2005.

WANG, J.S. *ET AL.* Adaptive Calculation of Deformation Resistance Model of Online Process Control in Tandem Cold Mill. **Journal of Materials Processing Technology**, v. 162-163, p. 585-590, 2005.

WERBOS, P.J. **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences**. 1974. Tese (Doutorado). Applied Mathematics Department, Harvard University, Cambridge, Massachusetts, 1974.

WILAMOWSKI, B.M. Methods of Computational Intelligence. In: IEEE INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY, Hammamet, Tunisia, 2004. **Proceedings...** IEEE Press, p. 1-8, 2004.

XIAO GUANG, S. *ET AL.* Application of Synergetic Artificial Intelligence to the Scheduling in the Finishing Train of Hot Strip Mills. **Journal of Materials Processing Technology**, v. 60, p. 405-408, 1996.

XIE, H.B. *ET AL.* Application of Fuzzy Control of Laminar Cooling for Hot Rolled Strip. **Journal of Materials Processing Technology**, v. 187-188, p. 715-719, 2007.

XU, L.D. Editorial. **Expert Systems**, v. 16, n. 4, p. 231-232, 1999.

YANG, Y.Y.; LINKENS, D.A. Modelling the Flow Stress Using BP Network. In: INTERNATIONAL CONFERENCE ON INTELLIGENT PROCESSING AND MANUFACTURING OF MATERIALS, 2, Honolulu, USA, 1999. **Proceedings...** IEEE Press, v. 2, p. 755-761, 1999.

YAO, X.; LIU, Y. Towards Designing Artificial Neural Networks By Evolution. **Applied Mathematics and Computation**, v. 91, n. 1, p. 83-90, 1998.

YINGJIE, G. *ET AL.* Fuzzy Model in Predictive Control for Hydraulic Pressure System. In: INTERNATIONAL CONFERENCE ON FLUID POWER TRANSMISSION AND CONTROL, 5, Hangzhou, China, 2001. **Proceedings...** Disponível em:

<http://fluid.power.net/techbriefs/hanghzau/2_19.pdf>. Acesso em 28 jan. 2007.

YU, H.L.; LIU, X.H.; LI, X.W. FE Analysis of Inclusion Deformation and Crack Generation During Cold Rolling With a Transition Layer. **Materials Letters**, v. 62, p. 1595-1598, 2008.

YUEN, W.Y.D.; POPELIANSKI, Y.; PROUTEN, M. Variations of Friction in the Roll Bite and Their Effects on Cold Strip Rolling. In: MECHANICAL WORKING AND STEEL PROCESSING CONFERENCE, 37, Pittsburgh, USA, 1996. **Proceedings...** ISS, v. 33, p. 47-54, 1996.

YUEN, W.Y.D. On-line and Off-line Models for the Rolling Process. **Scandinavian Journal of Metallurgy**, v. 32, p. 86-93, 2003.

ZADEH, L.A. Fuzzy Sets. **Information and Control**, v. 8, p. 338-353, 1965.

ZADEH, L.A. Outline of a New Approach to the Analysis of Complex Systems and Decision Processes. **IEEE Transactions on Systems, Man and Cybernetics**, v. 3, p. 28-44, 1973.

ZADEH, L.A. Fuzzy Logic = Computing With Words. **IEEE Transactions On Fuzzy Systems**, v. 4, p. 103-111, 1996.

ZHANG, G.; PATUWO, B.E.; HU, M.Y. Forecasting With Artificial Neural Networks: The State of the Art. **International Journal of Forecasting**, v.14, p.35-62, 1998.

ZHAO, Q.-L. *ET AL.* Neural Network Friction Model for Cold Strip Rolling. **International Journal of Iron and Steel Research**, v. 12, n. 4, p. 35-39, 2005.

ZHU, H.T. *ET AL.* A Fuzzy Algorithm for Flatness Control in Hot Strip Mill. **Journal of Materials Processing Technology**, v.140, p. 123-128, 2003.