

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

MODELAGEM NEURAL DA RESISTÊNCIA ELÉTRICA DOS FORNOS DE  
REDUÇÃO DO ALUMÍNIO

THIAGO NICOLAU MAGALHÃES DE SOUZA CONTE

DM: 35 / 2015

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil  
2015



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

THIAGO NICOLAU MAGALHÃES DE SOUZA CONTE

MODELAGEM NEURAL DA RESISTÊNCIA ELÉTRICA DOS FORNOS DE  
REDUÇÃO DO ALUMÍNIO

DM: 35 / 2015

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil  
2015

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

THIAGO NICOLAU MAGALHÃES DE SOUZA CONTE

MODELAGEM NEURAL DA RESISTÊNCIA ELÉTRICA DOS FORNOS DE  
REDUÇÃO DO ALUMÍNIO

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para a obtenção do Grau de Mestre em Engenharia Elétrica na área de Computação Aplicada.

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil  
2015

Dados Internacionais de Catalogação-na-Publicação (CIP)  
Sistema de Bibliotecas da UFPA

---

Conte, Thiago Nicolau Magalhães de Souza, 1984-  
Modelagem neural da resistência elétrica dos fornos  
de redução do alumínio / Thiago Nicolau Magalhães de  
Souza Conte. - 2015.

Orientador: Roberto Célio Limão de Oliveira.  
Dissertação (Mestrado) - Universidade  
Federal do Pará, Instituto de Tecnologia,  
Programa de Pós-Graduação em Engenharia  
Elétrica, Belém, 2015.

1. Inteligência computacional. 2. Alumínio -  
indústria. 3. Processos de fabricação -  
simulação por computador. 4. Redes neurais  
(computação). I. Título.

CDD 22. ed. 006.32

---

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

MODELAGEM NEURAL DA RESISTÊNCIA ELÉTRICA DOS FORNOS DE  
REDUÇÃO DO ALUMÍNIO

AUTOR: THIAGO NICOLAU MAGALHÃES DE SOUZA CONTE

DISSERTAÇÃO DE MESTRADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA ADEQUADA PARA OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM 16/10/2015

**BANCA EXAMINADORA:**

---

Prof. Dr. **Roberto Celio Limão de Oliveira**  
(Orientador – PPGEE/UFPA)

---

Profª. Dra. **Adriana Rosa Garcez Castro**  
(Avaliadora Interna – PPGEE/UFPA)

---

Prof. Dr. **Orlando Shiguelo Ohashi Junior**  
(Avaliador Externo – UFRA)

VISTO:

---

Prof. Dr. **Evaldo Gonçalves Pelaes**  
(COORDENADOR DO PPGEE/ITEC/UFPA)

## AGRADECIMENTOS

Primeiramente a Deus, pois sem ele, nada seria possível e não estaríamos aqui reunidos, usufruindo, juntos, destes momentos que nos são tão importantes.

Aos meus pais Nicolau Nazaré e Maria do Socorro pelo esforço, dedicação e compreensão, em todos os momentos desta e de outras caminhadas. Agradeço ainda Analu Saraiva e meus irmãos Bruno Nicolau e Hugo Nicolau por me acompanhar e incentivar na busca de meus objetivos e realização dos meus sonhos.

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

Ao colega Diemisom Melo que conheci durante o processo de pós-graduação, onde me apoiou na realização dos meus trabalhos com suporte e ajuda na tomada de decisões.

À Universidade Federal do Pará, pela oportunidade a mim oferecida para obter este grau mestrado, além do apoio dado pelo corpo docente que sempre procurou transmitir o melhor conhecimento para seus alunos.

## SUMÁRIO

AGRADECIMENTOS .....	VI
LISTA DE ILUSTRAÇÕES E TABELAS .....	VIII
RESUMO/ABSTRACT .....	2
1. INTRODUÇÃO.....	4
1.1 APRESENTAÇÃO DO CENÁRIO .....	4
1.2 OBJETIVOS E JUSTIFICATIVAS .....	5
1.3 METODOLOGIA E ESTRUTURA DO TRABALHO .....	6
2. PROCESSO DE FABRICAÇÃO DE ALUMÍNIO PRIMÁRIO.....	9
2.1 ALUMÍNIO .....	9
2.2 A INDÚSTRIA DO ALUMÍNIO NO BRASIL.....	9
2.3 PRINCIPAIS APLICAÇÕES .....	12
2.4 CADEIAS DE PRODUÇÃO DO ALUMÍNIO .....	14
2.5 REDUÇÃO DO ALUMÍNIO .....	14
2.5.1 O processo Hall Héroult .....	14
2.5.2 Forno Eletrolítico.....	15
3. REDES NEURAS ARTIFICIAIS .....	22
3.1 SISTEMA NERVOSO .....	22
3.2 COMPONENTES BÁSICOS DA RNAs .....	23
3.2.1 Arquitetura.....	25
3.2.2 Aprendizado.....	29
3.3 PROJETO DE REDE NEURAL .....	37
4. ABORDAGEM PROPOSTA .....	39
4.1 ANÁLISE DE RESULTADOS .....	40
4.1.1 Pré-processamento.....	40
4.1.2 Implementação dos Modelos .....	41
5. CONCLUSÃO.....	49
5.1 BEBEFÍCIOS ESPERADOS .....	50
5.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	50
REFERÊNCIAS .....	51
APÊNDICE .....	54

## LISTAS DE ILUSTRAÇÕES

Figura 2.1 Alumínio Puro .....	9
Figura 2.2 Bauxita .....	9
Figura 2.3 Cadeia de Produção Do Alumínio.....	14
Figura 2.4 Elementos Constituintes de um Forno Eletrolítico .....	16
Figura 2.5 Distância anodo-catodo.....	19
Figura 2.6 Disposição de Fornos em uma Sala de Redução (a) Lado a Lado (b) Ponta a Ponta .....	20
Figura 2.7 Configuração dos Fornos Eletrolíticos em uma Redução .....	21
Figura 3.1 Neurônio Biológico Simplificado .....	23
Figura 3.2 Neurônio Artificial .....	24
Figura 3.3 Exemplo de RNA Multicamada Típica.....	26
Figura 3.4 Padrões de Conexão em uma RNA Multicamada.....	26
Figura 3.5 Rede Feedforward Monocamada .....	27
Figura 3.6 Rede Feedforward Multicamada .....	28
Figura 3.7 Rede Recorrente Monocamada .....	29
Figura 3.8 Rede Recorrente Multicamada.....	29
Figura 3.9 Representação esquemática de um aprendizado .....	30
Figura 3.10 Aprendizado Supervisionado .....	31
Figura 3.11 Coleção de pontos ajustados pelo algoritmo Levenberg-Marquardt.....	33
Figura 3.12 Retropropagação do Erro .....	34
Figura 3.13 Variação da Medida de Erro, Identificando-se os Mínimos Locais e Globais.....	36
Figura 3.14 Visualização do Efeito dos Mapas Auto-Organizadores Kohonen.....	37
Figura 3.15 Etapas do Projeto de Rede Neural.....	38
Figura 4.1 Estrutura Neural da Resistência Elétrica.....	41
Figura 4.2 Vetores de Entrada da Tensão e Corrente, Respectivamente.....	43
Figura 4.3 Vetores de Entrada de Descida e Subida, Respectivamente .....	44
Figura 4.4 Vetores de Entrada de Consumo de Alumina .....	45
Gráfico 4.1 Resultados da RNMD.....	46
Gráfico 4.2 Resultados da RNR.....	47
Figura 4.5 Saída em Tensão Durante a Validação.....	49
Figura 4.6 Saída em Corrente Durante a Validação .....	49

## LISTAS DE TABELAS

Tabela 1.1 Metodologia do Trabalho .....	7
Tabela 2.1 Dados Sobre Balança Comercial de Bauxita.....	10
Tabela 2.2 Dados Sobre Balança Comercial da Alumina .....	11
Tabela 2.3 Dados Sobre Balança Comercial de Alumínio Primário .....	11
Tabela 2.4 Dados Sobre Produção Mensal.....	12
Tabela 2.5 Composição Química Normal Desejável dos Fornos.....	17
Tabela 3.1 Funções de Ativação Comuns .....	25
Tabela 4.1 Resultados da RNMD .....	46
Tabela 4.2 Resultado da RNR .....	47

## RESUMO

Este trabalho avalia dois tipos de Redes Neurais Artificiais na tarefa de modelar dinamicamente o comportamento da resistência elétrica de um forno de redução de alumínio primário. A proposta é utilizar Redes Neurais Multicamada Diretas (RNMD) e Redes Neurais Recorrentes (RNR) para modelar a resistência elétrica do forno. Para cada uma destas Redes Neurais é explorado a sua capacidade de modelar sistemas dinâmicos, seja variando o número de camadas de neurônios, bem como o número de neurônios em cada camada, variando também os sinais de entrada da rede neural, etc. Os dados a serem utilizados na modelagem são oriundos de uma fábrica brasileira de alumínio primário. Esta modelagem pode ser usada para controlar a distância (subir ou descer) entre os eletrodos anodos e catodos do forno de redução que são constituídos principalmente por materiais carbonáceos. Desta forma o sistema de controle possui a tarefa de manter o valor de resistência dentro de faixas aceitáveis de operação procurando sempre garantir estabilidade térmica e conseqüentemente a produção do alumínio primário, com alto teor de pureza, com base em dados disponíveis online no sistema de controle da fábrica. Através desses eletrodos são injetadas correntes elétricas contínuas que, além da eletrólise em si, provocam o aquecimento do banho eletrolítico, elevando a sua temperatura para uma faixa acima de 960 °C. A motivação para o trabalho está na alta complexibilidade do processo de redução do alumínio primário, cuja natureza é não-linear e o mesmo sofre influência de diversas variáveis diretamente ligadas a dinâmica do processo, muitas vezes imperceptíveis aos engenheiros de processo da fábrica, mas que podem ser percebidas por meio das técnicas de inteligência computacional refletindo aproximadamente as diferentes condições operacionais do sistema real.

**PALAVRAS-CHAVES:** Redução de Alumínio, Indústria, Modelagem Dinâmica, Inteligência Computacional, Redes Neurais Artificiais, Redes Neurais Recorrentes.

## ABSTRACT

The paper evaluates two types of Artificial Neural Networks to model dynamically the behaviour of the electrical resistance of a primary aluminum reduction furnace. The proposal is to use Direct Multilayer neural networks (RNMD) and Recurrent Neural networks (RNR) to model the electrical resistance of the oven. For each of these Neural Networks is explored its ability to model dynamic systems, either by varying the number of layers of neurons, as well as the number of neurons in each layer, varying the neural network input signals, etc. The data to be used in modeling from a Brazilian factory of primary aluminum. This modeling can be used to control the distance (up or down) between the electrodes, anodes and cathodes of the reduction that it consists primarily of carbonaceous materials. In this way the system of control has the task of maintaining the value of resistance within acceptable ranges of operation always attempting to ensure thermal stability and consequently the production of primary aluminum, high-purity, based on data available online in the control system of the plant. Through these electrodes are injected electrical currents keep that, besides the electrolysis itself cause the electrolytic bath, raising its temperature to a range up to 960° C. The motivation for the work is in high complexity of primary aluminum reduction process, whose nature is non-linear and the same suffering directly related variables influence the dynamics of the process, often imperceptible process engineers from the factory, but can be perceived by means of computational intelligence techniques reflecting about the different operating conditions of the real system.

**KEYWORDS:** Aluminum Reduction, Industry, Dynamic Modeling, Computational Intelligence, Artificial Neural Networks, Recurrent Neural Networks

# 1. INTRODUÇÃO

## 1.1. APRESENTAÇÃO DO CENÁRIO

Nas últimas décadas, com a crescente complexidade dos problemas a serem tratados computacionalmente e do volume de dados gerados em diferentes setores da indústria, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, que fossem mais autônomas, reduzindo a necessidade de intervenção humana e dependência de especialistas. Para isso, essas técnicas deveriam ser capazes de criar por si próprio, a partir de experiência passada, uma hipótese, ou função, capaz de resolver o problema que se deseja tratar (Carvalho, 2011).

Uma forte pesquisa desse assunto ocorreu após a metade do século XX, cujos resultados apresentam sucesso na identificação de padrões até então invisíveis ou imperceptíveis numa simples análise (Haykin, 2008). Essas técnicas começaram a ser utilizadas na modelagem de processos não lineares e complexos e bons resultados começaram a aparecer. Mas ainda, o uso destas técnicas se mostrou eficiente na identificação de variáveis correlatas entre si, que mais tarde evoluíram na constituição de um instrumento virtual ou sensor virtual (Fortuna et al, 2007).

O campo de Inteligência Computacional, ou IC, tenta não apenas compreender, mas também, construir entidades ‘ditas’ inteligentes. Atualmente, a IC abrange uma enorme variedade de subcampos, desde áreas de uso geral, como aprendizado e percepção, até tarefas específicas como jogos de xadrez, demonstração de teoremas matemáticos e diagnósticos de doença. A Inteligência Computacional sistematiza e automatiza tarefas intelectuais e, portanto, é potencialmente relevante para qualquer esfera da atividade intelectual humana. Nesse sentido, ela é verdadeiramente um campo universal (Russell, 2004).

As Redes Neurais Artificiais representam uma tecnologia, da inteligência computacional, que tem raízes em muitas disciplinas: neurociência, matemática, física, ciência da computação e engenharia. As redes neurais encontram aplicações em campos tão diversos, como modelagem, análise de séries temporais, reconhecimentos de padrões, processamento de sinais e controle, em virtude de uma importante propriedade: a habilidade de aprender a partir de dados de entrada com ou sem um professor, ou melhor, supervisão (Haykin, 2008).

A indústria de redução de alumínio, através de um processo mundialmente conhecido como processo Hall-Héroult, transforma alumina em alumínio líquido. Neste processo, funcionam três sistemas de controle: um para controlar a resistência elétrica de um forno de

redução de alumínio; um para controlar a adição de fluoreto de Alumínio no banho eletrolítico e um para controlar a adição de alumina. Tais sistemas recebem forte influência da variação de temperatura do forno. Portanto, os mesmos devem manter estável a temperatura do forno eletrolítico, pois o processo físico-químico para fabricar o alumínio exige uma estabilidade térmica de modo a evitar a destruição do forno.

A modificação de qualquer estratégia de controle, assim como alteração de algum parâmetro diretamente ligado à dinâmica do processo poderá causar resultados indesejáveis, por isso raramente são implementadas alterações nesta estratégia. Existe então a necessidade de um modelo dinâmico que reflita aproximadamente as diferentes condições operacionais do sistema, a fim de que possam simular novas estratégias de controle sem comprometer a qualidade do alumínio produzido.

A modelagem da resistência elétrica no forno de redução do alumínio utilizando-se de redes neurais artificiais é o principal assunto deste trabalho. São apresentados alguns casos de utilização destas técnicas de inteligência computacional, sendo mostradas todas as etapas da modelagem neural, desde sua concepção até sua validação, com dados reais de um processo de fabricação de alumínio primário no Brasil.

## 1.2. OBJETIVOS E JUSTIFICATIVAS

O mundo real é muito complicado para descrições precisas serem obtidas, portanto aproximação ou imprecisão devem ser introduzidas a fim de obter um modelo razoável ou ainda rastreável. Logo, à medida que se avança para a era da informação, o conhecimento humano, torna-se cada vez mais importante, e precisa-se de uma teoria para a formulação do conhecimento de uma forma sistemática e aplica-las às diversas áreas de conhecimento, tais como engenharias, medições sensoriais, ciências de computação, matemática, física, economia, finanças e estatística (Wang, 1997).

Na literatura científica os dados indicam que a utilização de técnicas como Redes Neurais Artificiais para modelar e controlar processos não lineares é uma das metodologias mais utilizadas atualmente no âmbito acadêmico, e mais recentemente nas indústrias (Braga et al., 2011; Rosa, 2011; Benuskova e Kasabov, 2010), e estudos demonstram aplicações de Redes Neurais também em neurologia, medicina, psicologia, etc (Silva, 2010; Ponsart, 2010).

As fábricas de alumínio primário necessitam de uma jiga ou computador de testes para fazer alterações na lógica de controle da variação da resistência elétrica do forno de redução, sem a exigência de retirar um forno da produção diária da fábrica. Dentro desta

lógica de ação, existe um problema sério que consiste em ter disponível um modelo da variação da resistência elétrica.

Para superar esta dificuldade, este trabalho propõe a utilização de uma modelagem computacional, isto é, prever o comportamento ou valor futuro da resistência elétrica com base em valores anteriores da variável de interesse e de outras variáveis utilizando-se de redes neurais artificiais aplicados na aquisição e processamento de dados reais dos fornos para encontrar o comportamento dinâmico não-linear da resistência elétrica do forno da indústria de redução de alumínio primário. Esse estudo tem relação com as potencialidades e possibilidades das redes neurais artificiais de atender de maneira satisfatória as diferentes situações apresentadas em problemas do mundo real.

Assim, de forma geral, o objetivo dessa dissertação encontra-se no reconhecimento de que os modelos neurais artificiais que a partir da coleta dos sinais de entrada e saída do processo, podem ser utilizados como ferramentas eficientes e pode aprender o comportamento da variação da resistência elétrica do forno de fabricação de alumínio, para uso em um computador de testes, onde são testadas novas estratégias de controle da resistência do forno, com o modelo neural emulando o funcionamento do forno real.

De forma específica, objetiva-se:

- I. Adquirir conhecimento sobre o problema, para facilitar o entendimento e a especificação da solução neural.
- II. Selecionar e filtrar os dados reais de processo a fim de se encontrar quais informações são relevantes para a construção do modelo neural.
- III. Definir, elaborar e validar computacionalmente uma solução baseada em redes neurais artificiais para o problema proposto e fornecer resultados que reflita estimativas satisfatórias.

### **1.3. METODOLOGIA E ESTRUTURA DO TRABALHO**

Para alcançar os objetivos propostos segue-se uma metodologia específica para elaboração de softwares para a simulação de ambientes reais (Sensores Virtuais). Como a natureza do processo a ser modelado é não-linear e complexa, se requer paralelamente, uma boa pesquisa operacional, que inclui coleta de dados históricos, entrevistas com à equipe do processo, adquirindo um domínio mínimo da experiência que a equipe já possui que deve ser

aproveitada para se determinar ou identificar de forma preliminar quais variáveis têm maior influência sobre a resistência elétrica e uma revisão bibliográfica para se atualizar nos trabalhos já feitos na área e sobre o que a comunidade científica e acadêmica compartilham neste contexto.

Com o conhecimento do processo e a definição das técnicas possíveis a serem utilizadas, o próximo passo é a escolha e filtragem dos dados para análise. A partir de testes e simulações em software, descobre-se quais variáveis possuem maior relevância para o problema em questão e logo submetido à validação, pelos dados coletados do forno real. Logo, novos modelos são produzidos e comparados com os resultados dos dados reais de produção a fim de se obter o melhor desempenho.

A tabela 1.1 mostra as atividades desenvolvidas para atingir cada objetivo elencado:

Tabela 1.1 - Metodologia do trabalho

Objetivo	Método/Atividade
I	Entrevista com a equipe de processo da fábrica de alumínio primário (técnicos de processo, engenheiros de processo, operadores, etc.) Pesquisa de literatura sobre a modelagem da resistência elétrica do forno de redução de alumínio primário.
II	Utilizar técnicas de filtragem de dados Escolher dados mais estáveis e fiéis que representam de forma genérica a natureza do processo
III	Utilizar diversos tipos de redes neurais artificiais para modelar o comportamento dinâmico da resistência elétrica do forno de redução de alumínio. Elaborar uma estrutura de modelo neural com as respectivas variáveis em questão. Simular os dados coletados e realizar ajustes nos parâmetros do modelo neural.
IV	Validar, segundo os dados já coletados, os resultados obtidos, havendo até a possibilidade de se modificar a estrutura do modelo neural.

Esta dissertação está organizada em 5 capítulos da seguinte forma:

**Capítulo 1** – Neste capítulo mostra a motivação que deu origem ao trabalho, os objetivos e a metodologia aplicada, a fundamentação teórica preliminar e estrutura do trabalho.

**Capítulo 2** – Neste capítulo é apresentado o processo de fabricação do alumínio primário de forma sucinta e simplificada.

**Capítulo 3** – São apresentadas as redes neurais artificiais, que são técnicas de computação inteligente, e suas arquiteturas, algoritmos de treinamento e técnicas de validação.

**Capítulo 4** – São apresentados os resultados obtidos com as diversas modelagens neurais, incluindo as etapas do processo de treinamento utilizadas e sua validação.

**Capítulo 5** - São apresentadas as considerações finais do trabalho e sugestões de trabalhos futuros

## 2. PROCESSO DE FABRICAÇÃO DE ALUMÍNIO PRIMÁRIO

### 2.1 ALUMÍNIO

O alumínio é o terceiro elemento de maior quantidade na crosta terrestre e pode ser encontrado em diversos tipos de minerais. Apesar de ser um dos elementos mais abundante da natureza, o alumínio puro é extremamente difícil de ser extraído, o que não é possível sem a ocorrência de alguma reação química. A Figura 2.1 mostra o alumínio na sua forma pura, obtido da alumina através de um processo que acontece em células eletrolíticas, ou melhor, após ter sido reduzido. A Figura 2.2 mostra a bauxita, que é a principal matéria prima da alumina, localizada principalmente numa ampla faixa de terra ao redor da linha do equador, usado para produzir o alumínio primário.



Figura 2.1 - Alumínio Puro  
Fonte: Soares (2009, p. 8)



Figura 2.2 - Bauxita  
Fonte: Soares (2009, p. 8)

### 2.2 A INDÚSTRIA DO ALUMÍNIO NO BRASIL

O Brasil é o oitavo maior produtor de alumínio primário, precedido pela China, Rússia, Canadá, Estados Unidos, Austrália, Emirados Árabes e Índia; quarto produtor de bauxita, atrás da Austrália, China e Indonésia; e terceiro produtor de alumina, atrás de China e Austrália.

As informações estatísticas da indústria brasileira de alumínio são organizadas e divulgadas sob a coordenação da Comissão de Economia e Estatística da ABAL (Associação Brasileira de Alumínio). São dados atualizados sobre produção, consumo e balança comercial de bauxita, alumina, alumínio primário, ligas e produtos transformados, além dos índices de reciclagem realizados no Brasil (ALUMÍNIO, 2014).

Os dados de produção nacional da Bauxita estão apresentados na Tabela 2.1 (Fontes: Informações das empresas do setor e SISCOMEX – Sistemas integrados de Comércio exterior – SECEX/MDIC).

Tabela 2.1. Dados sobre balança comercial de bauxita

Unidade: 1000 toneladas

Composição	2011	2012	2013
<b>Suprimento</b>	<b>33.765,2</b>	<b>35.104,0</b>	<b>33.856,4</b>
<b>Produção</b>	<b>33.624,6</b>	<b>34.987,8</b>	<b>33.848,7</b>
Alcoa Alumínio S.A.	4.965,5	5.315,2	5.506,1
Poços de Caldas (MG)	1.032,5	1.015,2	1.065,4
Juruti (PA)	3.933,0	4.300,0	4.440,7
MRN - Mineração Rio do Norte S.A. - Oriximiná (PA)	16.819,8	17.132,0	17.274,0
Norsk Hydro Brasil Ltda – Mineração Paragominas S.A.	8.150,8	9.221,4	7.567,2
Votorantim Metais - CBA Itamarati, Cataguases e Mirai (MG)	2.722,5	2.399,2	2.905,2
Outros <sup>1</sup>	966,0	920,0	596,2
<b>Importações</b>	<b>140,6</b>	<b>116,2</b>	<b>7,7</b>
<b>Consumo doméstico</b>	<b>25.161,8</b>	<b>24.720,8</b>	<b>23.570,7</b>
Usos metálicos	24.706,5	24.016,7	22.485,3
Outros usos	455,3	704,1	1.085,4
<b>Exportações</b>	<b>6.887,3</b>	<b>6.860,7</b>	<b>8.422,2</b>

Notas:

O item “outros” de produção de bauxita considera dados das empresas que produzem para usos não metálicos.

Já os dados de produção nacional da Alumina estão apresentados na Tabela 2.2 (Fontes: Informações das empresas do setor e SISCOMEX – Sistemas integrados de Comércio exterior – SECEX/MDIC).

Tabela 2.2. Dados sobre balança comercial da Alumina

Unidade: 1000 toneladas

Composição	2011	2012	2013
<b>Suprimento</b>	<b>10.320,1</b>	<b>10.370,9</b>	<b>9.968,0</b>
<b>Produção</b>	<b>10.306,8</b>	<b>10.320,6</b>	<b>9.942,1</b>
Alcan Alumina Ltda - São Luís (MA)	336,7	338,6	344,2
Alcoa Alumínio S.A.	2.125,8	2.145,9	2.186,6
Poços de Caldas - MG	303,3	305,3	327,8
São Luís - MA	1.822,5	1.840,6	1.858,8
BHP Billiton Metais S.A. - São Luís (MA)	1.212,3	1.219,0	1.239,2
Hindalco do Brasil Ind. e Com. Ltda (Ouro Preto, MG)	-	-	3,1
Norsk Hydro Mineração Alunorte – Alumina do Norte do Brasil S.A. (Barcarena, PA)	5.826,6	5.792,2	5.377,1
Votorantim Metais – CBA (Alumínio,SP)	805,4	824,9	791,9
<b>Importações</b>	<b>13,3</b>	<b>50,3</b>	<b>25,9</b>
<b>Consumo doméstico</b>	<b>2.916,0</b>	<b>2.924,9</b>	<b>2.702,9</b>
Usos metálicos	2.782,0	2.778,5	2.515,0
Outros usos	134,0	146,4	187,9
<b>Exportações</b>	<b>7.104,7</b>	<b>7.274,4</b>	<b>7.103,2</b>

A Tabela 2.3 apresenta a produção nacional por usina de alumínio primário (Fonte: Produtores Primários).

Tabela 2.3. Dados sobre balança comercial de Alumínio Primário

Unidade: 1000 toneladas

Produtores	Localização	2011	2012	2013
Albras	Barcarena (PA)	458,1	446,7	452,3
Alcoa	Poços de Caldas (MG)	87,9	85,9	69,4
Alumar (*)	São Luís (MA)	438,3	402,4	339,5
Novelis		47,1	46,5	29,2
	Ouro Preto (MG)	47,1	46,5	29,2
	Aratu (MG)	-	-	-
Votorantim Metais – CBA	Alumínio (SP)	409,0	454,9	413,9
<b>Total</b>		<b>1.440,4</b>	<b>1.436,4</b>	<b>1.304,3</b>

Notas:

(1) A unidade de redução do consórcio Alumar, tem como principais acionistas as empresas Alcoa Alumínio S.A e BHP Billiton Metais S.A

A Tabela 2.4 apresenta a produção nacional mensal de alumínio primário para os anos de 2013 e 2014 (Fonte: Produtores Primários).

Tabela 2.4. Dados sobre Produção mensal

Unidade: 1000 toneladas

Período	2014	2015	2015 / 2014 (%)
JANEIRO	104,8	70,9	-32,3
FEVEREIRO	92,6	63,5	-31,4
MARÇO	101,1	72,2	-28,6
ABRIL	90,5	64,9	-28,3
MAIO	81,3	62,8	-22,8
JUNHO	71,9	61,3	-14,7
JULHO	70,4	63,5	-9,8
AGOSTO	69,6	63,2	-9,2
SETEMBRO	68,6	61,4	-10,5
OUTUBRO	71,0	-	-
NOVEMBRO	69,3	-	-
DEZEMBRO	70,9	-	-
<b>JANEIRO - SETEMBRO</b>	<b>750,8</b>	<b>583,7</b>	<b>-22,3</b>
<b>Total Ano</b>	<b>962,0</b>	-	-

### 2.3 PRINCIPAIS APLICAÇÕES

O alumínio é um dos mais importantes metais não ferrosos, tendo expressivos crescimentos no seu uso pela indústria de modo geral, tal como no setor automotivo e transportes, indústria elétrica, máquinas e equipamentos, bens de consumo e construção Civil.

As variedades de aplicações do alumínio estão relacionadas com suas características físico-químicas, como por exemplo, a resistência à corrosão, alta condutibilidade elétrica e térmica, diversidades de formatos e designs, durabilidade, maleabilidade e soldabilidade,

logo, em função dos inúmeros atributos que este metal incorpora, os produtos que utilizam o alumínio ganham também competitividade quando comparado com outros materiais.

Devido às suas características, o alumínio é um metal que pode ser aplicado em vários segmentos utilizados para os mais diferentes fins. Atualmente são reconhecidas as seguintes aplicações:

- O alumínio na construção civil é sinônimo de beleza, longevidade, modernidade e inteligência construtiva. Produtos como esquadrias de alumínio, painéis de revestimento, fachadas envidraçadas, estruturas de alumínio para coberturas, estruturas de alumínio para fechamentos laterais, divisórias, forros, box, utensílios para a construção, formas de alumínio para paredes de concreto, andaimes, escoras telhas, entre tantas outras soluções são facilmente montados e manuseados nos canteiros de obras e dão um toque de sofisticação, funcionalidade e bom gosto aos empreendimentos (ALUMÍNIO, 2014).
- O alumínio no meio de transporte é sinônimo de segurança, durabilidade, economia, desempenho, sofisticação e leveza. Ele absorve duas vezes mais energia de impacto em uma colisão, oferece o dobro de resistência quando comparado ao aço e, além disso, permite a redução do consumo de combustível e de emissões poluentes (ALUMÍNIO, 2014).
- O alumínio na indústria elétrica é sinônima de redução de custos das redes elétricas com menores investimentos, manuseio e manutenção. O uso de cabos de alumínio para transporte de corrente elétrica reduz o peso nas estruturas de sustentação, maior capacidade de transmissão de energia, resistência a altas temperaturas sem perda de propriedades físicas (ALUMÍNIO, 2014).
- Na indústria química e na medicina, o alumínio é bastante empregado em cilindros para gases, vasos de reação, tubulações e tanques de estocagem e criogênicos. A condutibilidade elétrica aliada à leveza do alumínio favorece sua aplicação na indústria de transformadores, solenóides, relés, capacitores, condutores e outros componentes, em chassis eletrônicos, bases de lâmpadas. No setor gráfico, o metal é ainda largamente utilizado em chapas litográficas para impressão (ALUMÍNIO, 2014).

## 2.4 CADEIAS DE PRODUÇÃO DO ALUMÍNIO

O processo de produção do alumínio envolve diferentes fases. Cada uma destas fases é identificada por uma área dentro do parque industrial, logo, a produção do alumínio inicia com a extração e refinamento do minério chamado bauxita que é a principal matéria prima do óxido de alumínio, ou alumina, em seguida passando pela área de redução onde ocorre a eletrólise, dando origem ao alumínio líquido. O metal produzido é retirado dos fornos e encaminhado ao lingotamento, no qual o alumínio líquido é solidificado em formas produzindo lingotes, que logo depois são empilhados e estocados para exportação. A Figura 2.3 mostra graficamente a sequência de todo o processo.



Figura 2.3 Cadeia De Produção Do Alumínio

Os fornos eletrolíticos localizam-se na área de redução, por isso esta área merece especial atenção. A qualidade do alumínio produzido em um forno esta diretamente a uma operação adequada do forno eletrolítico.

## 2.5 REDUÇÃO DO ALUMÍNIO

### 2.5.1 O PROCESSO HALL HÉROULT

Processo Hall-Héroult é o único método pelo qual o alumínio é industrializado e produzido até os dias de hoje (GRJOTHEIM; KVANDE, 1993; PRASAD, 2000). Assim o processo Hall-Héroult é um processo contínuo no qual a alumina é dissolvida em um banho de criolita derretida a uma temperatura em torno de 960°C sob a passagem de corrente elétrica contínua, na ordem de 180 kA. As unidades de produção do alumínio são chamadas de fornos ou cubas (McFadden, 2001), que normalmente são dispostas em série, assim a corrente elétrica é a mesma em todos os fornos, compondo uma linha de produção.

O processo Hall-Héroult consiste em transformar a alumina (Al<sub>2</sub>O<sub>3</sub>) que é utilizada como matéria prima (SOARES; OLIVEIRA, 2009) em alumínio líquido e este é processado pela redução da eletrolise da alumina dissolvida em criolita (Na<sub>3</sub>AlF<sub>6</sub>), no banho eletrolítico, passando por altas correntes elétricas (TORMOND; BJARNE, 1998; SOARES; OLIVEIRA, 2009), sendo que a formação deste alumínio metálico se dá através da reação química entre o Al<sub>2</sub>O<sub>3</sub> e o carbono fornecido pelos ânodos, formando CO<sub>2</sub> conforme nos mostra a equação (2.1).



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

### 2.5.2 FORNO ELETROLÍTICO

O forno eletrolítico é o local onde ocorre o processo de obtenção do alumínio, ou seja, é uma construção de aço preparada para ocorrer a eletrolise – dissociação das moléculas de alumina (Al<sub>2</sub>O<sub>3</sub>) em alumínio e gás carbônico (CO<sub>2</sub>) - e receber os elementos utilizados no processo: banho eletrolítico, alumina, gases, aditivos químicos, corrente elétrica e estrutura de carbono para condução de energia.

### 2.5.2.1 Estrutura Física do Forno Eletrolítico

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

O corte transversal do forno com seus elementos de interesse direto, citados nos diversos itens deste estudo, são exibidos na Figura 2.4.

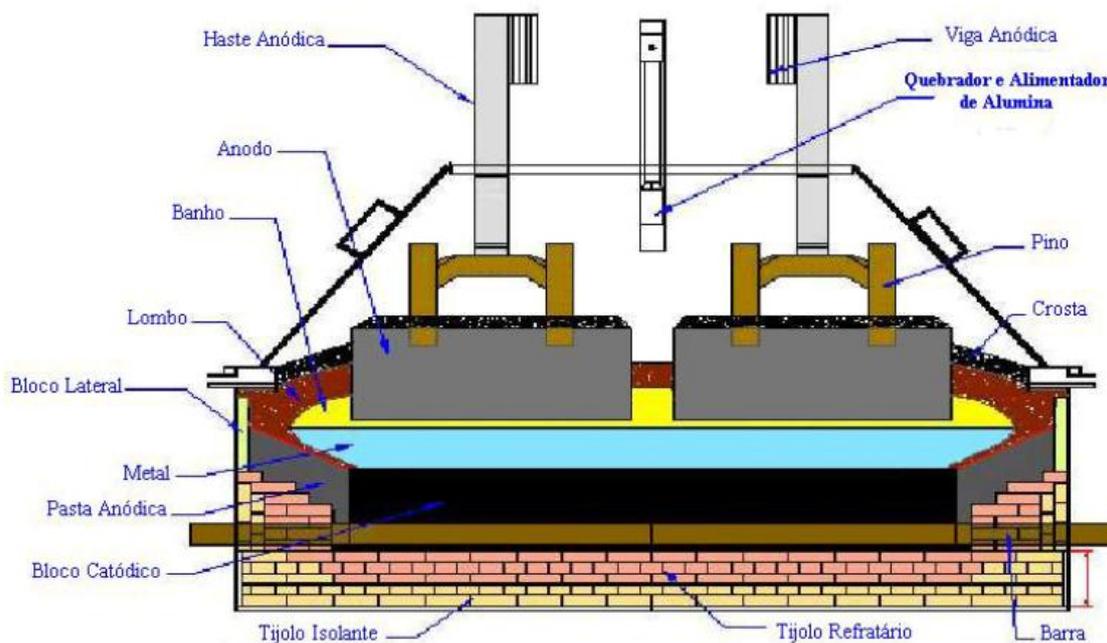


Figura 2.4 Elementos Constituintes de um Forno Eletrolítico

Fonte: Pereira (2005 p. 10).

- Anodo e Catodo: São dois extremos de uma reação química por eletrólise, sendo respectivamente um pólo positivo e outro pólo negativo. Em fornos de redução de alumínio, o anodo está presente na forma de hastes, já o catodo está presente na estrutura

do próprio forno, sendo este ligado diretamente ao barramento elétrico. Ambos são feitos a partir de coque (derivado do petróleo) e piche sólido;

- Viga Anódica: viga metálica pelo qual os anodos de um forno estão presos;
- Crosta: atua como uma capa termo-protetora, localizada ao redor do forno e na sua superfície;
- Quebrador e Alimentador: haste metálica que rompe a crosta, com a finalidade de injetar alumina ao nível correto do banho;
- Metal: é o alumínio obtido pela quebra da molécula de alumina, através da eletrólise;
- Tijolo Isolante, Refratário e Pasta Anódica: São elementos diretamente ligados à proteção térmica externa interior da cuba.

### 2.5.2.2 Banho Eletrolítico

O banho consiste principalmente de criolita fundida, fluoreto de alumínio em excesso de 6 a 10% e alumina que fica em torno de 2 a 5%. Este banho deve permanecer líquido para que a reação ocorra (McFadden et al, 2001).

#### 2.5.2.2.1 Aditivos Químicos

A criolita pura possui um ponto de fusão alto (1009°C), entretanto a temperatura ideal de operação do banho é o mais próximo possível de 960°C, e para reduzi-lo são adicionados alguns aditivos químicos, principalmente o fluoreto de alumínio (AlF<sub>3</sub>), o Fluoreto de cálcio (CaF<sub>2</sub>), a barrilha (Na<sub>2</sub>CF<sub>3</sub>) e a própria alumina. A finalidade dos aditivos químicos também é manter a composição química do forno estável, conforme mostrado na Tabela 2.5.

Tabela 2.5 Composição química normal desejável dos fornos

Elemento	Percentual aceitável de operação
AlF <sub>3</sub> (fluoreto de alumínio)	Entre 9 a 11 %
CaF <sub>2</sub> (Fluoreto de cálcio)	Entre 4 e 5 %
Al <sub>2</sub> O <sub>3</sub> (Alumina)	Entre 1,5 e 2,5 %
Na <sub>2</sub> CO <sub>3</sub> (carbonato de Sódio)	Menos de 1 %

### 2.5.2.3 Controle de Resistência

É fundamental que a resistência de um forno se mantenha estável, pois a oscilação da mesma acaba por ocasionar um aumento extremo na tensão do forno de redução e consequentemente uma elevação na temperatura do banho eletrolítico, com temperaturas altíssimas, resultando em um distúrbio térmico, com possibilidade de ocorrer o derretimento da camada isolante do forno, e as consequências finais são a perda de produção em toda linha haja vista que os fornos de produção estão em uma ligação elétrica em série, mas produzem alumínio de forma independente, vida útil diminuída e o aumento da produção de gases.

A tensão de cada um dos fornos, ligadas em série, varia de 4 a 5 Volts, dos quais apenas 1,6 V são necessários para eletrólise propriamente dita e resultar na produção do metal não ferroso. Esse valor de tensão de 1,6 V se refere à voltagem gerada pela própria reação química (ALCOA,2015).

Alto consumo de energia é outra consequência da variação da resistência, pois com o aumento da resistência há um aumento da energia consumida e mais energia transformada em calor, com isso a temperatura do banho também aumenta, com essa temperatura elevada, há um desgaste maior do forno podendo ocorrer o derretimento da camada sólida e isolante do forno, afetando assim o balanço térmico do forno e sua vida útil.

Esta resistência elétrica é avaliada pela posição do anodo em relação ao catodo do forno de redução. O valor desta resistência é função, não apenas da amperagem e tensão, mas também da temperatura do forno, da quantidade de algumas substâncias existentes no banho químico como, por exemplo: criolita, fluoreto, concentração de alumina, sais fundentes, etc.

Por isso quando precisa ajustar o valor de resistência de um forno, atua-se modificando a distância entre o anodo e o catodo, a baixa concentração de alumina no banho e eliminação do Efeito Anódico (EA) e outros. EA é fenômeno indesejável no processo produtivo do alumínio que está associado a muitas variáveis do processo de redução. No entanto grande parte da sua ocorrência é ocasionada pela variação da resistência, que faz com que o banho fique mais resistivo, assim o EA faz com que haja um aumento rápido de tensão do forno, alcançando valores até 10 vezes maiores que os valores normais. EA é atribuído à formação de uma camada de gás que isola o anodo da superfície do banho e com esse comportamento o banho não pode mais molhar a superfície anódica, até que a barreira de gás isolante seja quebrada.

A Figura 2.5 uma noção de distância entre o anodo e o catodo de um forno de redução de alumínio.

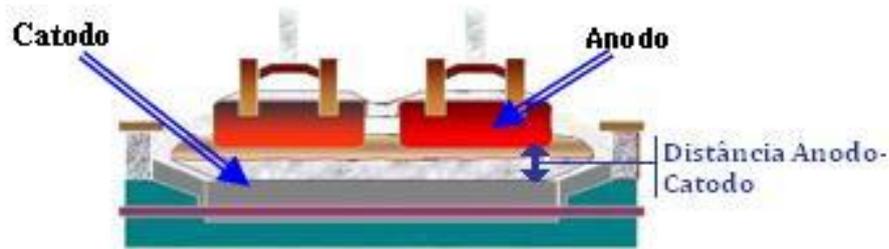


Figura 2.5 Distância anodo-catodo

Uma resistência muito alta pode provocar aquecimento no forno, comprometendo o anodo e em casos extremos o catodo (Prasad, 2000). O comprometimento do catodo provoca o desligamento do forno (Prasad, 2000). Já uma resistência muito baixa provoca uma queda na eficiência de corrente (MacFadden et al, 2001).

Para controlar a distância dos anodos, em relação às substâncias existentes dentro do forno, tendo como base a localização do catodo, as empresas de alumínio primário tem um sistema de controle de resistência elétrica que monitora continuamente as variáveis do forno e determina a posição que os anodos devem permanecer, para que o valor da resistência fique em torno de 15  $\mu\Omega$ s.

As fábricas de alumínio necessitam de uma Jiga de testes ou computador de testes para auxiliar a detectar problemas e simular alterações necessárias no comportamento de controle da variação da resistência elétrica do forno de redução, sem a exigência de retirar um forno da produção diária da fábrica. Dentro destas funcionalidades de ação, existe um problema que consiste em ter disponível um modelo não-linear da variação da resistência elétrica.

Para superar este obstáculo, pensou-se na utilização de uma técnica de inteligência computacional, especificadamente no uso de uma rede neural artificial (RNA) para modelar esta oscilação de resistência elétrica do forno, a partir de registros reais dos fornos.

O controle da resistência faz aquisição basicamente de dois sinais, intensidade da corrente (corrente contínua que alimenta um conjunto de fornos) e tensão do forno, como mostra na Equação 2.2.

$$R_{inst} = \frac{v_{inst} - B_{emf}}{I} \quad (2.2)$$

Onde:

$R_{inst}$  = Resistência do forno (Micro Ohm - $\mu\Omega$ )

$V_{inst}$  = Tensão media para cada forno (Volt - V)

$B_{emf}$  = Queda da tensão química (Volt - V)

$I$  = Corrente (Quilo Amper – KA)

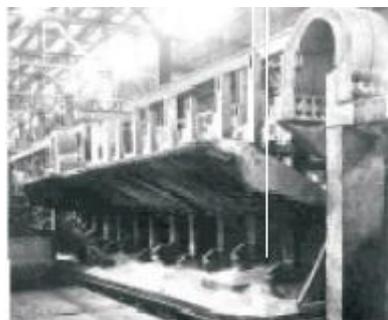
#### 2.5.2.4 Disposição dos Fornos Eletrolíticos nas Reduções

As indústrias organizam seus fornos em série com o barramento elétrico, dentro de salas chamadas de reduções. Esta ligação pode ser feita de duas maneiras:

- a) **Lado a Lado (side-by-side)**: Os fornos ficam dispostos um ao lado do outro, mas sempre conservando um espaço de aproximadamente 2 metros entre um forno e outro.
- b) **Ponta a Ponta (end-to-end)**: Os fornos são interligados de tal maneira que a cabeceira de um forno fique bem próximo à cabeceira do outro forno.

A Figura 2.6 mostra as duas disposições de fornos usados e a Figura 2.7 mostra a disposição lado a lado na Albras dividida em:

- **Seção**: é um conjunto de 30 fornos.
- **Linha**: conjunto de duas Seções.
- **Sala**: conjunto de duas linhas.
- **Redução**: conjunto de duas salas.



(a)



(b)

Figura 2.6 Disposição de fornos em uma sala de redução. (a) Lado a Lado (b) Ponta a Ponta

Fonte: Pereira (2005 p.8).

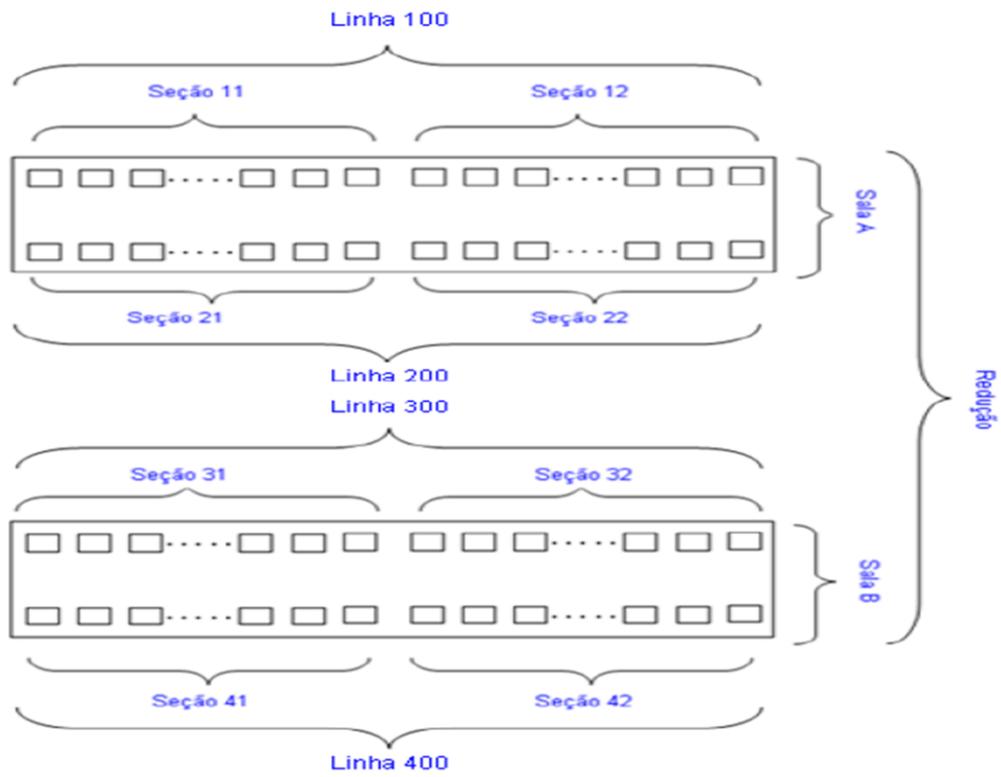


Figura 2.7 Configuração dos fornos eletrolíticos em uma redução  
 Fonte: Albras, 1993.

### 3. REDES NEURAIS ARTIFICIAIS

Na busca pela construção de máquinas inteligentes, ou com comportamento inteligente, um modelo que ocorre naturalmente é o do cérebro humano. Em nosso cotidiano, realizamos diversas tarefas que requerem atenção a diferentes eventos ao mesmo tempo e o processamento de informações variadas, de forma a tomarmos ações convenientes.

Tarefas consideradas simples, como pegar um objeto ou mesmo caminhar, envolvem ação de diversos componentes, tais como memória, aprendizado e coordenação física. A complexidade de tais ações simples para a maioria das pessoas é evidenciada pela dificuldade encontrada em ensinar robôs a realizá-las. A realização aparentemente simples de tarefas como essas e muitas outras é possível graças à nossa complexa estrutura biológica, e o grande responsável pelo citado processamento de diversas informações e geração de respostas a ela é o cérebro humano.

A partir dessas motivações, o desenvolvimento das redes neurais artificiais tomou como inspiração a estrutura e o funcionamento do sistema nervoso, com o objetivo de simular a capacidade de aprendizado do cérebro humano na aquisição de conhecimento (carvalho, 2011).

#### 3.1 SISTEMA NERVOSO

O sistema nervoso, do qual faz parte o cérebro, é um conjunto complexo de células que determinam o funcionamento e o comportamento dos seres vivos. A Figura 3.1 mostra a unidade fundamental do sistema nervoso é a célula nervosa, o neurônio, que se distingue das outras células por apresentar excitabilidade, que lhe permite responder a estímulos externos e internos. Isso possibilita a transmissão de impulsos nervosos a outros neurônios e a células musculares e glandulares.

O principal bloco de construção do cérebro é o neurônio. Os principais componentes de um neurônio são:

- **Dendritos:** são prolongamento dos neurônios especializados na recepção de estímulos nervosos proveniente de outros neurônios ou do ambiente;
- **Corpo celular ou Soma:** coleta as informações recebidas dos dendritos, as combina e processa;

- **Axônio:** é um prolongamento dos neurônios, responsável pela condução dos impulsos elétricos produzidos no corpo celular até outro local mais distante (usualmente até outros neurônios).

O sinal no neurônio flui dos dendritos para o corpo celular e em seguida para o axônio. O contato entre a transmissão de um axônio e o dendrito de outro neurônio é denominado sinapse. As sinapses são, portanto, as unidades que medeiam às interações entre os neurônios (Haykin, 2008), e podem ser excitatórias ou inibitórias.

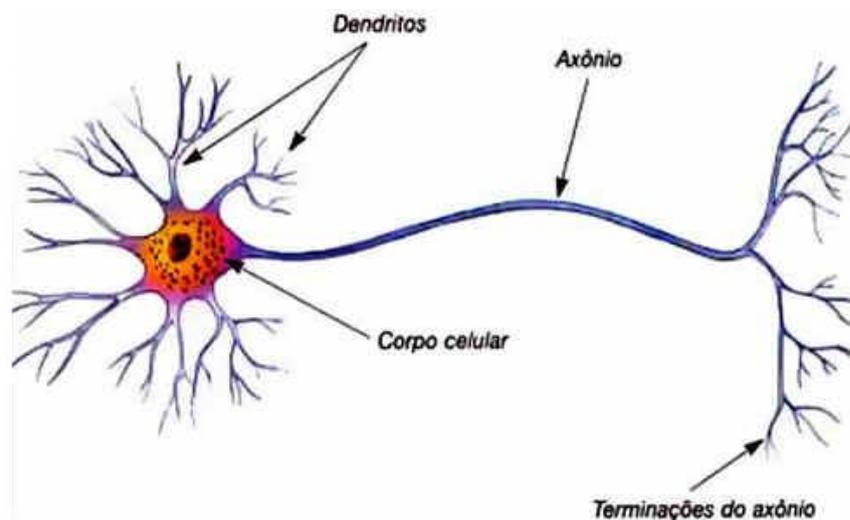


Figura 3.1 Neurônio Biológico Simplificado

Fonte: Carvalho (2011 p. 109 )

### 3.2 COMPONENTES BÁSICOS DAS RNAS

Uma Rede Neural Artificial é constituída basicamente de dois tipos de elementos (Neurônios e Sinapses) e por dois aspectos (arquitetura e aprendizado).

Os Neurônios artificiais são unidades de processamento simples que computam funções matemáticas. Enquanto a arquitetura está relacionada ao tipo e o número de unidades de processamento e a forma como os neurônios estão conectados.

Na maioria das arquiteturas, essas conexões, que simulam as sinapses biológicas, possuem pesos associados que ponderam a entrada recebida por cada neurônio da rede. Os pesos podem assumir valores positivos e negativos, depende do comportamento da conexão ser excitatória ou inibitório respectivamente. O aprendizado diz respeito às regras utilizadas

para o ajuste dos pesos da rede e que informação é utilizada pela regra (Braga, 2011). A figura 3.2 mostra o modelo de um neurônio artificial Segundo (Hernandez 2005), as redes neurais ou redes de neurônios artificiais são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas nos neurônios biológicos e nas características de suas interconexões.

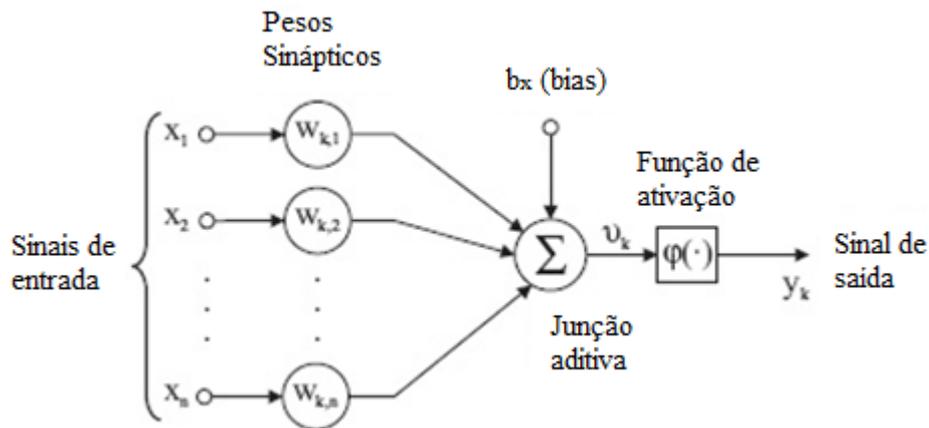


Figura 3.2 Neurônio Artificial

Fonte: Haykin (2008 p. 36)

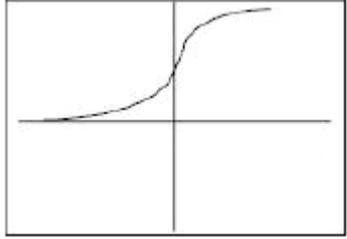
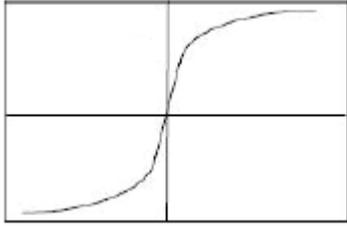
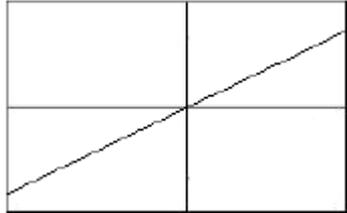
As unidades de processamento desempenham um papel muito simples. Cada terminal de entrada do neurônio, simulando os dendritos, recebe um valor  $x = [x_1, x_2, \dots, x_p]$ . Os valores recebidos são ponderados pelos pesos  $w_{k1}, w_{k2}, \dots, w_{kn}$  e combinados por uma função matemática, equivalente ao processamento realizado pelo soma. A saída de um neurônio é definida por meio da aplicação de uma função de ativação à entrada total recebida pelo neurônio  $u_i$ , podendo ser definida pela equação 3.1:

$$y_j = f(u_j) \quad (3.1)$$

$$u_i = \sum_{j=1}^P x_j w_{ji} \quad (3.2)$$

A presença da função de ativação é importante, pois reproduz um comportamento de não-linearidade inerentes aos modelos que a rede neural busca emular (Haykin, 2008: Aguirre, 2004). Várias funções de ativação têm sido propostas na literatura e algumas estão apresentadas na Tabela 3.1 onde mostra a equação e o formato de três dessas funções.

Tabela 3.1 Funções de Ativação comuns

Função	Fórmula	Gráfico
Sigmoide	$\text{Sigmoide}(x) = \frac{K}{1 + e^{-px}}$	
Tangente Hiperbólica	$\text{Tanh}(x) = K \frac{(1 - e^{-px})}{(1 + e^{-px})}$	
Linear	$\text{Linear}(x) = K \cdot X$	

### 3.2.1 Arquitetura

A topologia de uma rede Neural Artificial é definida pelo número de camadas, o número de neurônios em cada camada, o grau de conectividade e a presença ou não de conexões de retropropagação.

Uma RNA com mais de uma camada de neurônios recebe o nome de rede de multicamadas onde a camada de neurônios que gera valores de saída é chamada de camada de saída e as demais camadas são denominadas camadas intermediárias, escondidas ou ocultas. Esta situação é visualizada na figura 3.3

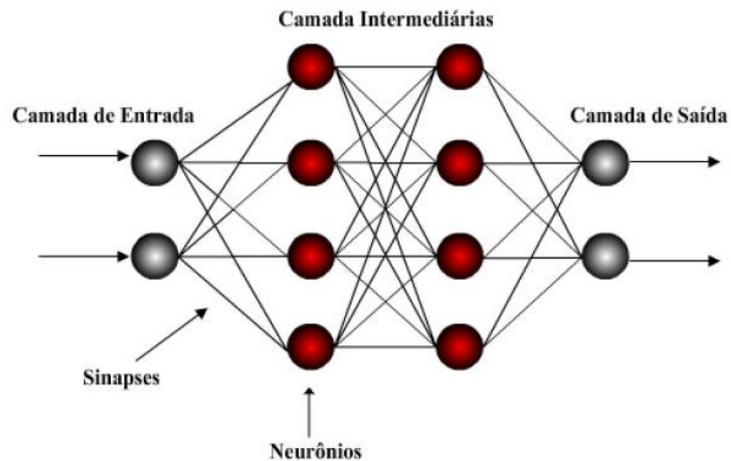


Figura 3.3 Exemplo de RNA multicamadas típica

Fonte: Soares (2009, p. 45)

Em uma rede multicamadas, de acordo com o grau de conectividade, a rede pode ser classificada em: completamente (a), localmente (b) e (c) parcialmente conectada. Ver característica na Figura 3.4.

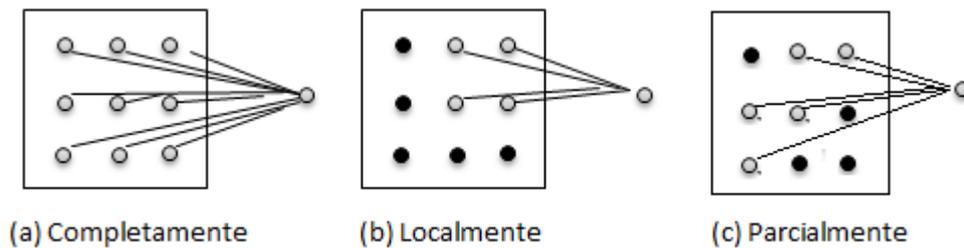


Figura 3.4 Padrões de conexão em uma RNA multicamadas

Fonte: Carvalho (2011 p. 111)

Além do grau de conectividade, as RNAs podem apresentar ou não conexões de retroalimentação (feedback). As redes com retropropagação conhecidas também como redes recorrentes permitem que um neurônio receba em seus terminais de entrada a saída de um neurônio da mesma camada ou de uma camada posterior. O neurônio pode inclusive receber sua própria saída em um de seus terminais de entrada e as redes sem conexões de retropropagação são denominadas RNAs feedforward (Carvalho, 2011).

- Redes Feedforward Monocamada

É uma topologia de rede simples, pois é constituída apenas por uma camada neural, “camada única” se refere à camada de saída de unidades de processamento (neurônios). Esta rede é rigorosamente do tipo alimentada adiante ou acíclica, a Figura 3.5 ilustra uma rede Feedforward monocamada (Haykin, 2008).

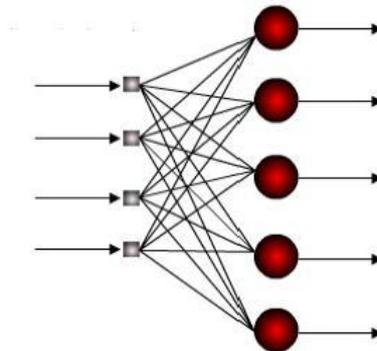


Figura 3.5 Rede Feedforward Monocamada

Fonte: Soares (2009, p. 45)

Para o caso desta topologia temos quatro nós na camada de entrada e cinco na camada de saída. Os sinais são delegados para os nós de entrada, os quais reenviam e este são ajustados pelos pesos, para camada de saída. Algumas arquiteturas que fazem parte desta categoria são as perceptron, ADALINE (acronima do inglês: ADaptive LINEar Element) e a sua generalização multidimensional, o MADALINE (Múltipla Adaline). (Haykin, 2008).

- Redes Feedforward Multicamadas

A segunda classe de rede neural alimentada adiante se diferencia pela presença de uma ou mais camadas intermediárias, cujas unidades de processamento são chamadas de correspondentemente de neurônios intermediários ou camadas intermediárias. A função dos neurônios intermediários é interceder entre a entrada externa e a saída da rede neural de uma forma vantajosa. Na figura 3.6 é possível visualizar as conexões.

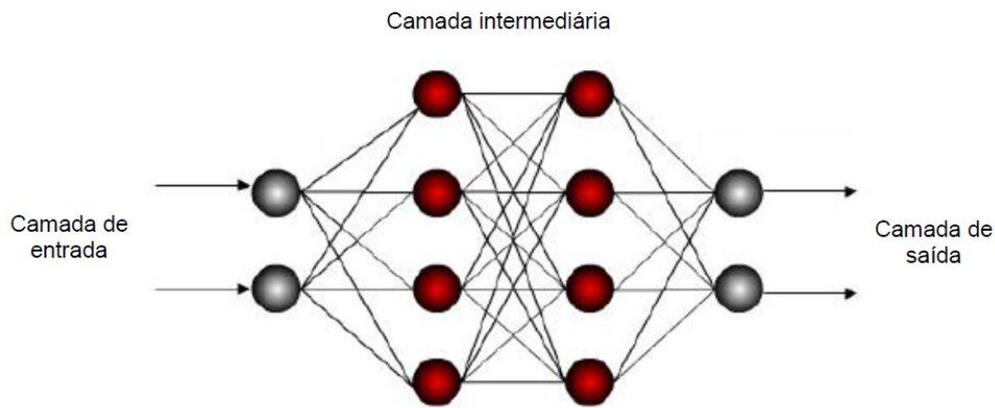


Figura 3.6 Rede Feedforward Multicamada

Fonte: Soares (2009, p. 45)

No caso do esquema acima é uma das arquiteturas com um grande número de qualidade e aplicabilidades. Entre estas citaremos algumas potencialidades que se destacam nesta área.

- Aproximação universal de funções
  - Identificação e controle de processos
  - Otimização de sistemas
  - Previsão de séries temporais
  - Reconhecimentos de padrões
- Redes Neurais Recorrentes

Uma rede neural recorrente se diferencia de uma rede neural com propagação para frente por ter pelo menos um loop de realimentação entre os neurônios. A presença de laços de realimentação nas redes mono ou multicamadas tem um impacto profundo na capacidade de aprendizagem da rede e no seu desempenho.

Uma rede recorrente com apenas uma camada possui uma ligação entre a saída dos neurônios às entradas deles mesmos. As figuras 3.7 e figura 3.8 mostram um esquema de rede neural recorrente multicamadas.

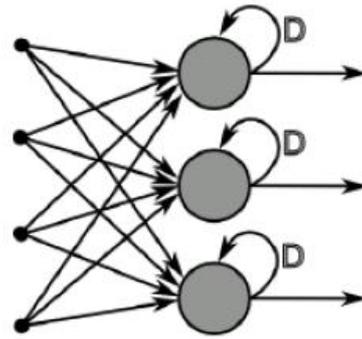


Figura 3.7 Rede Recorrente Monocamada

Fonte: Soares (2009, p. 46)

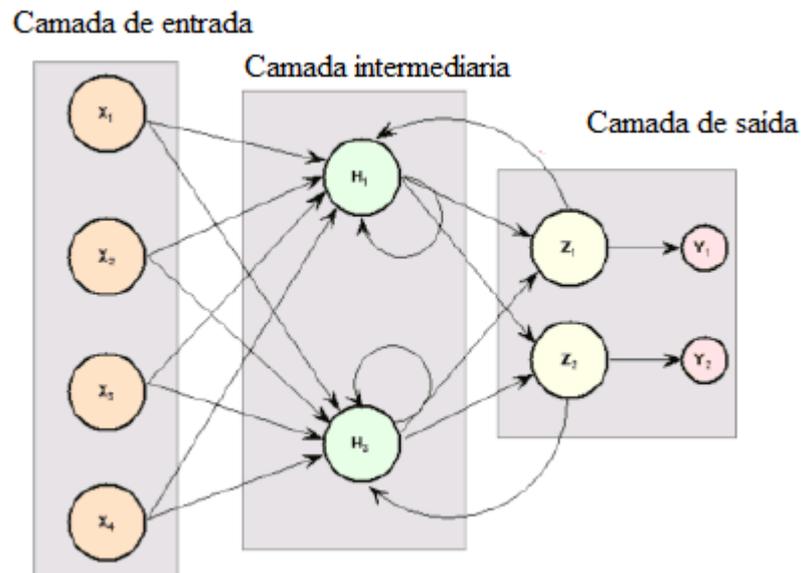


Figura 3.8 Rede Recorrente Multicamada

Fonte: Soares (2009, p. 46)

### 3.2.2 Aprendizado

O aprendizado corresponde à maneira de como a rede neural vai ajustar seus parâmetros, principalmente a definição dos valores dos pesos associados às conexões da rede que fazem com que o modelo obtenha melhores resultados. A Figura 3.9 exemplifica uma configuração de rede neural.

Computacionalmente, o aprendizado é implementado na forma de algoritmos de treinamento (Demuth et al, 2008), que são baseados nas técnicas de otimização. Estes algoritmos podem ser divididos em quatro grupos:

- **Correção de Erro:** Geralmente utilizados em aprendizado supervisionado, procuram ajustar os pesos da RNA de forma a reduzir os erros cometidos pela rede.
- **Hebbiano:** Frequentemente usados em aprendizados não-supervisionado, são baseados na regra de Hebb, que diz que, se dois neurônios estão simultaneamente ativos, a conexão entre eles devem ser reforçadas.
- **Competitivo:** Utilizados em aprendizado não supervisionado, promovem uma competição entre neurônios para definir qual ou quais devem ter seus pesos ajustados.
- **Termodinâmico (Boltzmann):** Algoritmos estocásticos baseado em princípios observados na metalurgia.

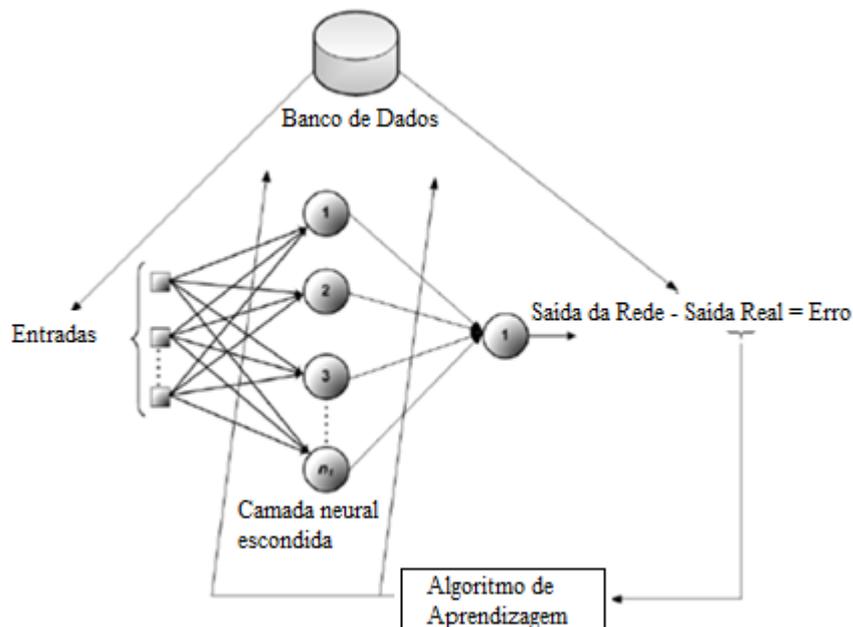


Figura 3.9 Representação esquemática de um aprendizado

Fonte: Soares (2009, p. 47)

O conhecimento o qual se deseja que a Rede Neural reproduza são os dados que serão alimentados à sua entrada. A resposta da rede, que inicialmente será inadequada, vai ser alterada ao longo do período de aprendizado, evoluindo para resposta desejada. Há duas classes de aprendizado, supervisionado e não supervisionado.

### 3.2.2.1. Aprendizado Supervisionado

Quando se é conhecida a resposta desejada, o aprendizado é considerado supervisionado, tendo a resposta desejada com um tutor supervisor que vai avaliar o quão próximo do desejável está a Rede Neural, conforme o esquema apresentado na figura 3.10.

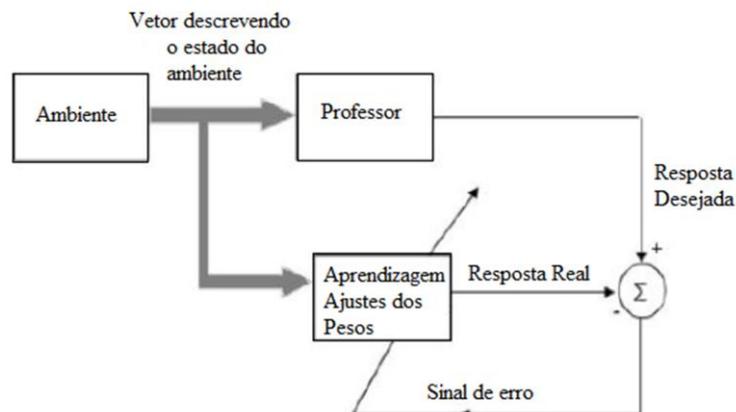


Figura 3.10 Aprendizado Supervisionado

Fonte: Haykin (2008 p. 88)

Vários algoritmos têm sido propostos na literatura para o ajuste dos parâmetros de uma RNA, alguns deles são:

- Gradiente Descendente
- Backpropagation
- Levenberg-Marquadt
- Regularização bayesiana

Entretanto todos eles seguem o mesmo princípio que é otimizar a função custo (eq. 3.4) que representa o quão próximo a Rede está do seu objetivo, por meio da medida de erro da equação (3.3).

$$e(t) = d(t) - y(t) \quad (3.3)$$

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (3.4)$$

O que muda de um algoritmo para o outro é a forma como peso é atualizado. Como a implementação e o propósito de cada algoritmo são parecidos, serão apresentados aqui 2 algoritmos, ficando os outros como leitura recomendada.

- Algoritmo Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt foi elaborado para solucionar de forma interativa problemas de minimização de funções não-lineares pelo método de mínimos quadrados. Problemas de mínimos quadrados têm como objetivo encontrar o melhor ajuste para um conjunto de dados de tal modo que a soma dos quadrados das distâncias (tomadas na vertical) entre o modelo (curva ajustada) e cada um dos pontos dados seja a menor possível. Essas diferenças entre a curva ajustada e cada um dos dados são denominadas resíduos.

Em linguagem matemática podemos escrever o problema de mínimos quadrados da seguinte forma:

Considere  $x = [x_1, x_2, x_3, \dots, x_n]$ . Dada uma função vetorial  $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$  com  $m \geq n$ , queremos minimizar  $\|f(x)\|$ , ou equivalente, para encontrar  $x =$  mínimo local para  $F(x)$  conforme equação 3.5.

Onde:

$$F(x) = \frac{1}{2} \sum_{i=1}^m (f_i(x))^2 = \frac{1}{2} \|f(x)\|^2 = \frac{1}{2} f(x)^t f(x) \quad (3.5)$$

Um motivo para se minimizar a soma dos quadrados dos resíduos ao invés de se minimizar a soma dos resíduos é o fato de que a função módulo não é diferenciável na origem e serão usadas derivadas para resolver os problemas de mínimos quadrados não-lineares.

Como exemplo dessa classe de problemas considere dados a coleção de pontos  $(t_1, y_1), \dots, (t_{m-1}, y_{m-1}), (t_m, y_m)$  obtidos em função de algum experimento e o modelo  $M(x, t) = x_3 e^{x_1 t} + x_4 e^{x_2 t}$  a ser ajustado.

Assume-se que existe um  $x^+$  tal que  $y_i = M(x^+, t_i) + \varepsilon_i$ , onde  $\{\varepsilon_i\}$  são erros de medida. Sendo assim, para qualquer escolha de  $x$  pode-se encontrar os valores dos resíduos da seguinte forma conforme a equação 3.6.

$$f_i(x) = y_i - M(x, t_i) = y_i - x_3 e^{x_1 t} - x_4 e^{x_2 t}, \text{ com } i = 1, \dots, m \quad (3.6)$$

Pode-se perceber que o modelo depende dos parâmetros  $x = [x_1, x_2, x_3, x_4]^T$ . O objetivo do problema seria, então, encontrar  $x^* = [x_1^*, x_2^*, x_3^*, x_4^*]$  onde  $x_1^*, x_2^*, x_3^*, x_4^*$  são os valores que minimizam a soma dos quadrados dos resíduos, o que significa encontrar a melhor curva que se ajusta aos pontos fornecidos. A figura 3.11 mostra exatamente os pontos fornecidos e a curva obtida no ponto  $x^*$ , isto é,  $M(x^*, t)$ .

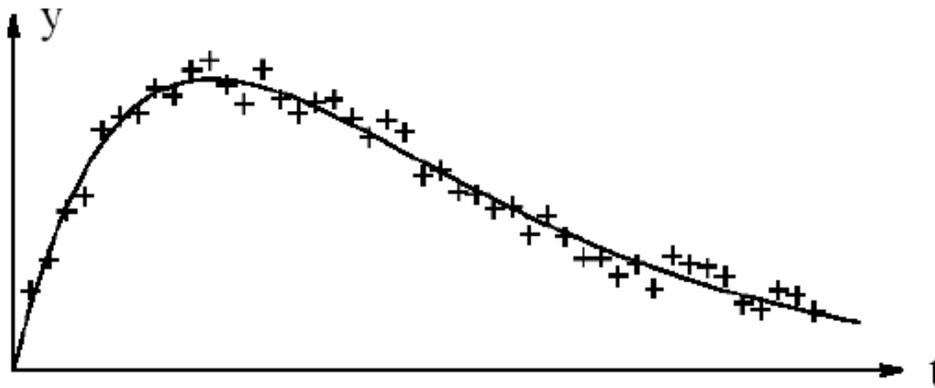


Figura 3.11 Coleção de pontos ajustados pelo algoritmo Levenberg-Marquardt

De modo geral, o algoritmo de Levenberg-Marquardt sugere uma solução de ajuste entre o algoritmo do gradiente descendente e o método iterativo de Gauss-Newton. Sua regra de atualização dos pesos, como proposto por Levenberg é apresentado na equação 3.7.

$$X_{i+1} = X_i - (H + \lambda I)^{-1} \nabla f(X_i) \quad (3.7)$$

onde :

- $X$  representa o vetor de pesos
- $\nabla f$  representa o gradiente do erro médio quadrático
- $H$  representa a matriz Hessiana
- $\lambda$  é um fator de ajuste.

A regra de atualização definida pelo algoritmo considera tanto na inclinação da superfície do erro (método do gradiente descendente) quanto à curvatura desta superfície (método de Gauss-Newton). O fator de ajuste designa qual dos dois métodos será predominante: para fatores de ajuste amplos (erro elevado), o método do gradiente

descendente é dominante e a atualização do parâmetro ocorre intensamente no sentido de inclinação da superfície do erro, do contrário, o método de Gauss-Newton predomina e atualização do peso ocorre mais na direção da curvatura da função, o que faz com que o algoritmo de Levenberg-Marquardt funcione utilizando o que cada um dos algoritmos tem de melhor.

- Algoritmo Backpropagation

O algoritmo backpropagation é utilizado somente em redes do tipo feedforward multicamadas (Haykin, 2008) e constitui-se da interação de duas fases: na primeira, a rede recebe os dados de entrada, processa-os de camada em camada em direção a camada de saída, e na segunda fase é então utilizada a diferença entre os valores de saída produzidos e desejados para cada neurônio da camada de saída, indicando o erro cometido pela rede frente à entrada apresentada, para ajustar seus pesos. O ajuste prossegue da camada de saída até a primeira camada intermediária, conforme ilustrado na Figura 3.12.

Basicamente o algoritmo Backpropagation consiste na seguinte receita:

- Calcular o erro da rede;
- Retropropagar o erro e modificar os parâmetros para minimizar o erro da próxima saída.

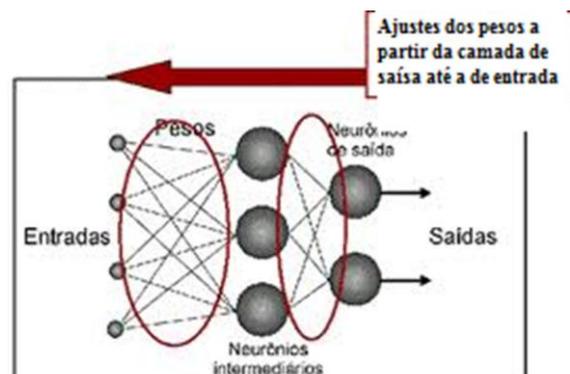


Figura 3.12 Retropropagação do erro

A equação 3.8 ilustra como é feito o ajuste dos pesos de uma rede pelo algoritmo de retropropagação.

$$W_{ij}^k(t+1) = W_{ij}^k(t) - n\sigma_j^k x_i^k \quad (3.8)$$

Onde:

- $K$  é a camada da rede
- $W_{ij}^k$  é o peso que liga a entrada  $i$  ao neurônio  $j$  da camada  $k$
- $x_i^k$  é a entrada  $i$  da camada  $k$
- $\sigma_j^k$  é o valor da retropropagação do erro no neurônio  $j$  da camada  $k$

O valor da retropropagação é dado por:

$$\sigma_i^k = -(yt_j - y_j) \cdot \frac{\partial f_i^{k-1}}{\partial net_i^{k-1}} \quad (3.9)$$

para a camada de saída é

$$\sigma_i^k = \sum_{j=1}^M W_{ij}^{k+1} \sigma_j^{k+1} \quad (3.10)$$

para as demais camadas, onde:

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

$$net_i^k = \sum_{i=1}^m w_{ji}^k x_i \quad (3.11)$$

Apesar do algoritmo de retropropagação ser uma técnica muito difundida, enfrenta problemas na sua implementação como os mínimos locais (Soares, 2009), ver Figura 3.13. O desempenho da Rede Neural evolui de forma que seu erro diminui conforme os pesos vão se ajustando, logo, durante seu aprendizado é necessário que sejam tomados alguns cuidados, pois há casos em que uma combinação de pesos leva o desempenho da rede a um ponto de operação indefinido mascarando o resultado, o chamado mínimo local, fazendo parecer que foi encontrado o desejado mínimo global.

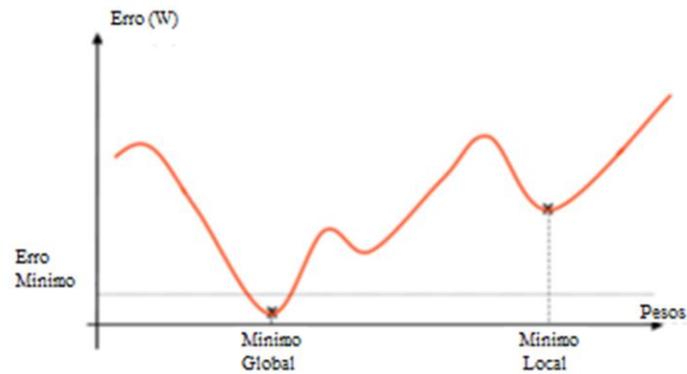


Figura 3.13 Variação da medida de erro, identificando-se os mínimos locais e globais.

Fonte: Soares (2009, p. 50)

Enfatizando a problemática do mínimo local sabe-se que há estratégias com a intenção de evitar a ocorrência dos mesmos. São elas:

- Adição de neurônios na camada escondida
- Adição de ruídos aos dados
- Taxa de aprendizado
- Utilização do termo momentum (adição de mais um parâmetro ajustável no processo de treinamento)

### 3.2.2.2. Aprendizado Não-Supervisionado

Nesta forma de aprendizagem não existe um tutor supervisor que avalia a resposta da rede e a saída desejada, portanto, para problemas de classificação ou de reconhecimento de padrões, onde não há uma saída bem definida para cada entrada da rede, os algoritmos de treinamento não supervisionado são indicados. Apesar de não haver uma regra para se definir uma saída desejada para rede neural, o algoritmo é efetuado com base em observação e descoberta, onde pode ser estimada pela observação da frequência com que esse evento ocorre ou pela aproximação.

Os mais populares algoritmos no aprendizado não supervisionado é o utilizado em redes neurais de mapas auto organizadores Kohonen mostrado na Figura 3.14.

O algoritmo de Kohonen parte, da auto-organização, processo semelhante ao que ocorre com o cérebro. No algoritmo, as saídas estão amplamente conectadas com as entradas

e, depois de muitos fatos terem sido apresentados, os pesos irão especificar grupos ou centros. Que respondem de forma similar.

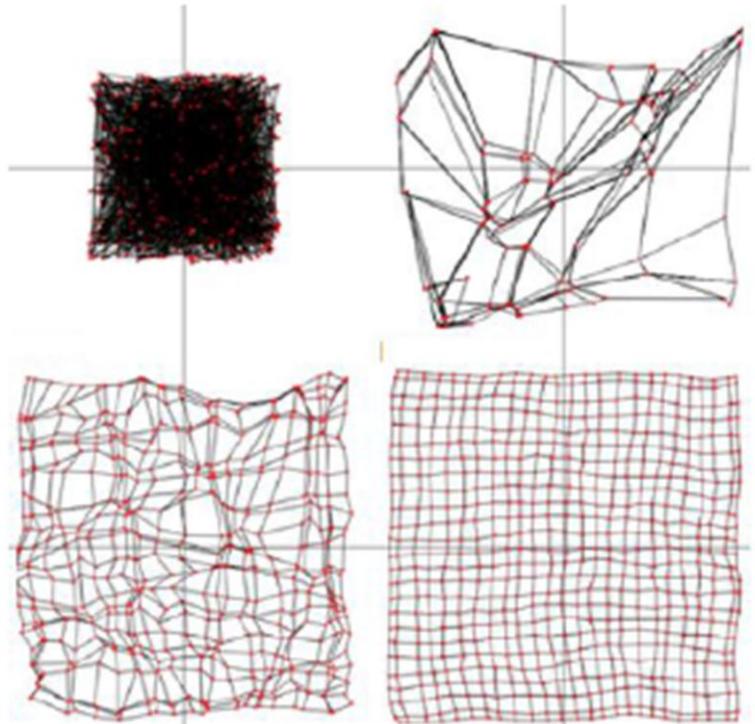


Figura 3.14 Visualização do Efeito dos Mapas Auto-organizadores Kohonen  
Fonte: Kohonen (1982).

### 3.3 PROJETO DE REDE NEURAL

Os primeiros passos para que as Redes Neurais Artificiais possam induzir um modelo para um conjunto de dados são: definir qual a classe de problema está sendo lidada (aproximação de funções, previsão de séries temporais, classificação e reconhecimento de padrões); definir a sua arquitetura, que envolve a escolha das funções de ativação e da topologia da Rede Neural que é caracterizada pelo número de camadas e o número de neurônios em cada camada; por ultimo, para Redes de multicamadas, qual o padrão de conexões e se existem conexões de retropropagação conforme explicado anteriormente.

Definindo-se a classe de problema e a Arquitetura da Rede Neural, o próximo passo é escolher o aprendizado ou algoritmo de treinamento que define as regras utilizadas para os ajustes de parâmetros como a inicialização dos pesos da Rede e que informação é utilizada pela regra. O projeto da Rede Neural é resumido na Figura 3.15.

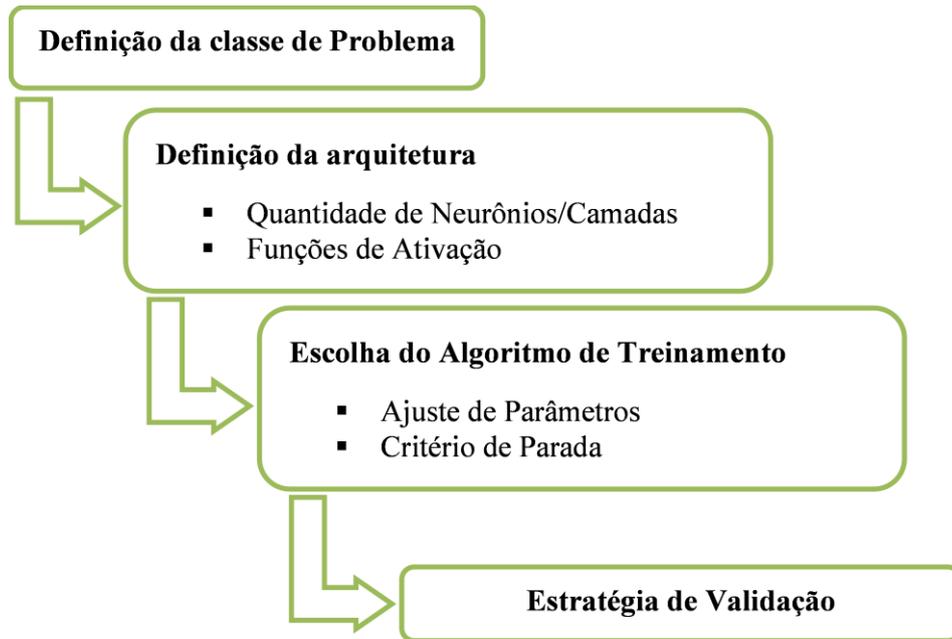


Figura 3.15 Etapas do Projeto de Rede Neural

Fonte: Elaborada pelo autor

O projeto da Rede Neural ainda envolve uma validação por parte do treinamento, conforme o seu desempenho. Normalmente, os dados coletados são separados em duas categorias: dados de treinamento, que serão utilizados para os ajustes dos pesos sinápticos da rede e dados de teste, que serão utilizados para verificar sua performance sob condições reais de utilização. Além dessa divisão, pode-se usar também uma subdivisão do conjunto de treinamento, criando um conjunto de validação, utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento, e podendo ser empregado como critério de parada do treinamento (Haykin, 2008).

## 4. ABORDAGEM PROPOSTA

A utilização das Redes Neurais Artificiais no meio industrial é uma realidade que vem ganhando bastante espaço e aceitação. As características dos processos industriais com relação a sua complexidade fenomenológica viabilizam o uso desta técnica que é realizada em função da coleta dos dados de entrada e saída de um determinado processo.

Este capítulo apresenta as fases de implementação do modelo neural. Por fim serão apresentados e discutidos os resultados obtidos com a implantação do modelo.

A base de dados utilizada foi obtida de uma empresa brasileira, internacionalmente reconhecida pelos padrões de qualidade do metal produzido. Foram coletados dados reais de: corrente, tensão, subida e descida do anodo e frequência de alimentação da alumina, pois esta resistência elétrica é avaliada pela distância entre o anodo e catodo do forno de redução e o valor desta resistência é função, não apenas da corrente e tensão medidas, mas também da temperatura do forno, da quantidade de algumas substâncias existentes no líquido do forno. Estas variáveis são capazes de representar, com um grau de aproximação satisfatório, o comportamento de um forno de redução de alumínio. Porém, alguns fenômenos inerentes ao processo não podem ser reproduzidos pelo modelo apenas com o status destas variáveis.

As seleções dos parâmetros estão fundamentadas em inúmeras pesquisas que determine a configuração ideal de uma rede neural para um dado problema apoiadas em experiências vividas e com base na observação em tentativas e erros durante o processo de aprendizagem.

Para simular estes modelos foram utilizado um conjunto de 47604 amostras, obtidos através da coleta de varias horas de informação, dividido em treinamento (28562 - 60%), validação (9520 - 20%) e testes (9520 - 20%), seguindo a metodologia Cross Validation.

Os parâmetros do RNMD e RNR foram os mesmos utilizados para a modelagem. Os parâmetros são: número de épocas iguais a 60; objetivo a ser alcançado igual a 0.00001; algoritmo de treinamento Levenberg-Marquardt, para solução de mínimos quadrados não-lineares que consiste na interação em um aperfeiçoamento do método de Gauss-Newton com o Gradiente Descendente, utilizando-se as funções de ativação, em todos os casos, Sigmóide nas camadas escondidas e Linear na Camada de Saída.

Com os dados possíveis de serem coletados e mais relevantes e, foram realizadas simulações, variando as topologias dos dois tipos de redes neurais, buscando-se encontrar a melhor topologia para cada tipo de rede, comparando os melhores resultados.

## 4.1 ANÁLISE DE RESULTADOS

Para a modelagem neural de resistência elétrica de um forno eletrolítico utilizou-se o software MATLAB R2012b. Esta ferramenta contém um toolbox de Redes Neurais (nnet), onde encontra-se disponíveis as arquiteturas de RNAs aqui utilizadas e várias regras de aprendizado, destacando-se o algoritmo de aprendizado supervisionado que indica a rede a resposta desejada para o padrão de entrada possibilitando implementações de vários tipos da modelagem proposta. Os passos que seguem descrevem a metodologia utilizada:

### 4.1.1 Pré-processamento

Os sinais utilizados no treinamento da RNA foram normalizados dentro de um intervalo de 0 a 1, conforme apresentado na equação 4.1. Porém devido o total de dados envolverem uma grande quantidade de registros ainda receberam tratamentos, as técnicas de filtragem, que consiste em ajustar os dados para transformá-los em registros operacionais para cada ponto no tempo.

$$V_n = \frac{(V - V_{\min})}{(V_{\max} - V_{\min})} \quad (4.1)$$

Onde:

$V_n$  = Valor normalizado

$V$  = Valor não normalizado

$V_{\min}$  = Valor mínimo apresentado pela variável

$V_{\max}$  = Valor máximo apresentado pela variável

#### 4.1.1.1 Movimentação Anódica

Os vetores relacionados a movimentação anódica, são os vetores de subida e descida de anodo coletados a partir do tempo de acionamento do motor macaco que movimenta o anodo. Podendo variar desde frações de segundo até movimentações de alguns segundos, de acordo com a necessidade observada pelo sistema SCORE ou simplesmente Jiga de Teste.

#### 4.1.1.2 Frequência de Alimentação

Este vetor indica a frequência com que o alimentador está sendo acionado. Fisicamente o sinal coletado é o sinal de retorno de um circuito elétrico utilizado para confirmação do acionamento, sendo ligado ao sistema de controle através de um bit de confirmação, porém, na obtenção deste modelo utilizou-se apenas a sequência de pulsos digitais que acionam o alimentador, dessa forma, qualquer tipo de alimentador pode ser percebido através de sua respectiva sequência de acionamento.

A partir da coleta do bit de confirmação, durante cada incursão do alimentador, foi montada uma estratégia que fosse capaz de reproduzir aproximadamente o consumo de alumina em um forno, ou seja, a quantidade instantânea de alumina, presente no banho, durante o processo de eletrólise. A estratégia baseia-se em um valor teórico que informa que a cada minuto são consumidos em média 1600g de  $Al_2O_3$ .

#### 4.1.2 Implementação dos Modelos

Após o pré-processamento, os dados foram organizados em 3 conjuntos: treinamento (utilizados para atualizar os pesos), validação (utilizados para evitar o sobre treinamento-overfitting) e teste (objetivo de examinar o grau de generalização da rede).

O treinamento, teste e validação da RNA foram realizados com os dados de entrada: subida e descida de anodo ( $S_t$  e  $D_t$ ) respectivamente, intensidade da corrente ( $I_t$ ), frequência de alimentação ( $C_t$ ) e tensão instantânea do forno ( $V_t$ ). Sendo que os vetores de entrada, relacionadas a tensão e corrente instantânea, dão origem a dois outros vetores atrasados de 1 valor temporal ( $V_{t-1}$  e  $I_{t-1}$ ). Este tipo de configuração permite que RNA relacione a proposta futura ( $t+1$ ) com os valores atuais ( $t$ ) e com estados passados ( $t-1$ ) conforme mostra na Figura 4.1.

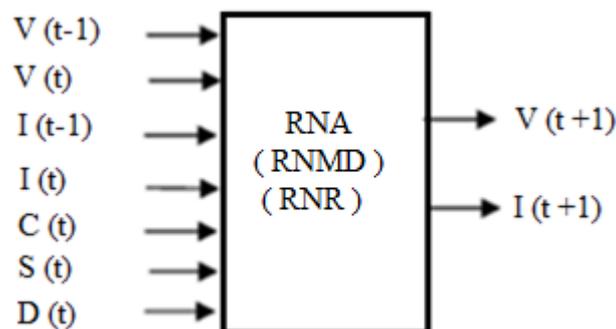


Figura 4.1 Estrutura Neural da Resistência Elétrica

Para simular este modelo foi utilizado um conjunto de 47604 amostras (conforme pode ser visualizado pela figura 4.2, 4.3 e 4.4), de onde foram selecionados os momentos mais ricos, pois em muitos casos o forno não executa movimentação alguma, caracterizando este conjunto de dados como um conjunto “pobre” no que se refere a informação de movimentação anódica e divididos em treinamento da rede 28562 (60%) pontos de coleta, para validação 9520 (20%) e para testes 9520 (20%), seguindo a metodologia Cross Validation.

Em relação aos dados de amostras, a inclusão de uma parada de forno durante a coleta. Uma parada de forno representa o momento em que a corrente que energiza o barramento do forno é desligado para que os operadores possam executar algum tipo de manutenção. Após essa ocorrência a corrente é gradativamente elevada, até atingir seu valor normal de operação. Durante este evento o controle automático de resistência torna-se inoperante.

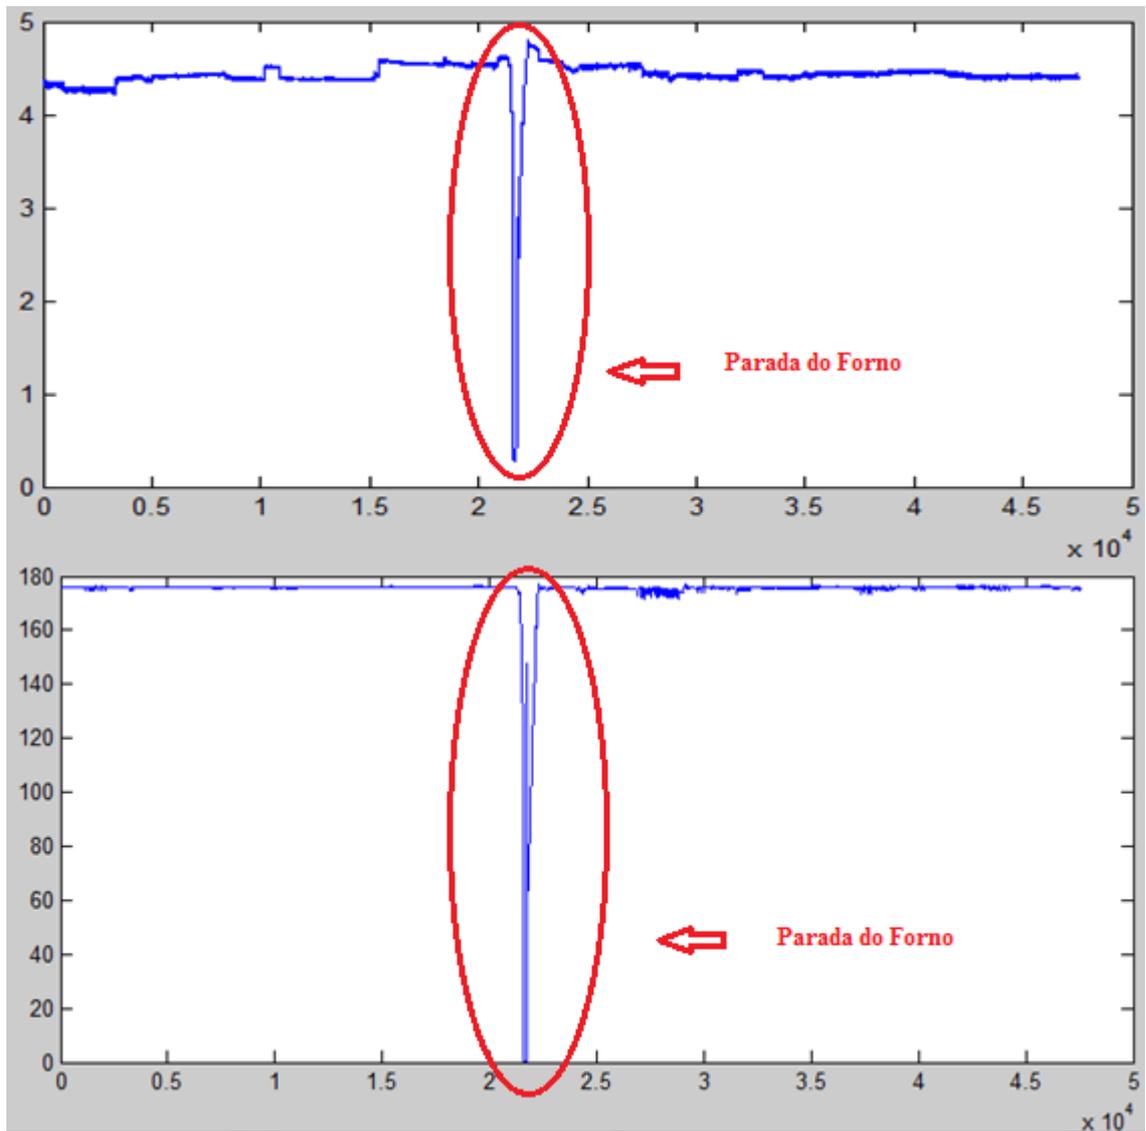


Figura 4.2. Vetores de entrada da Tensão e Corrente, respectivamente.

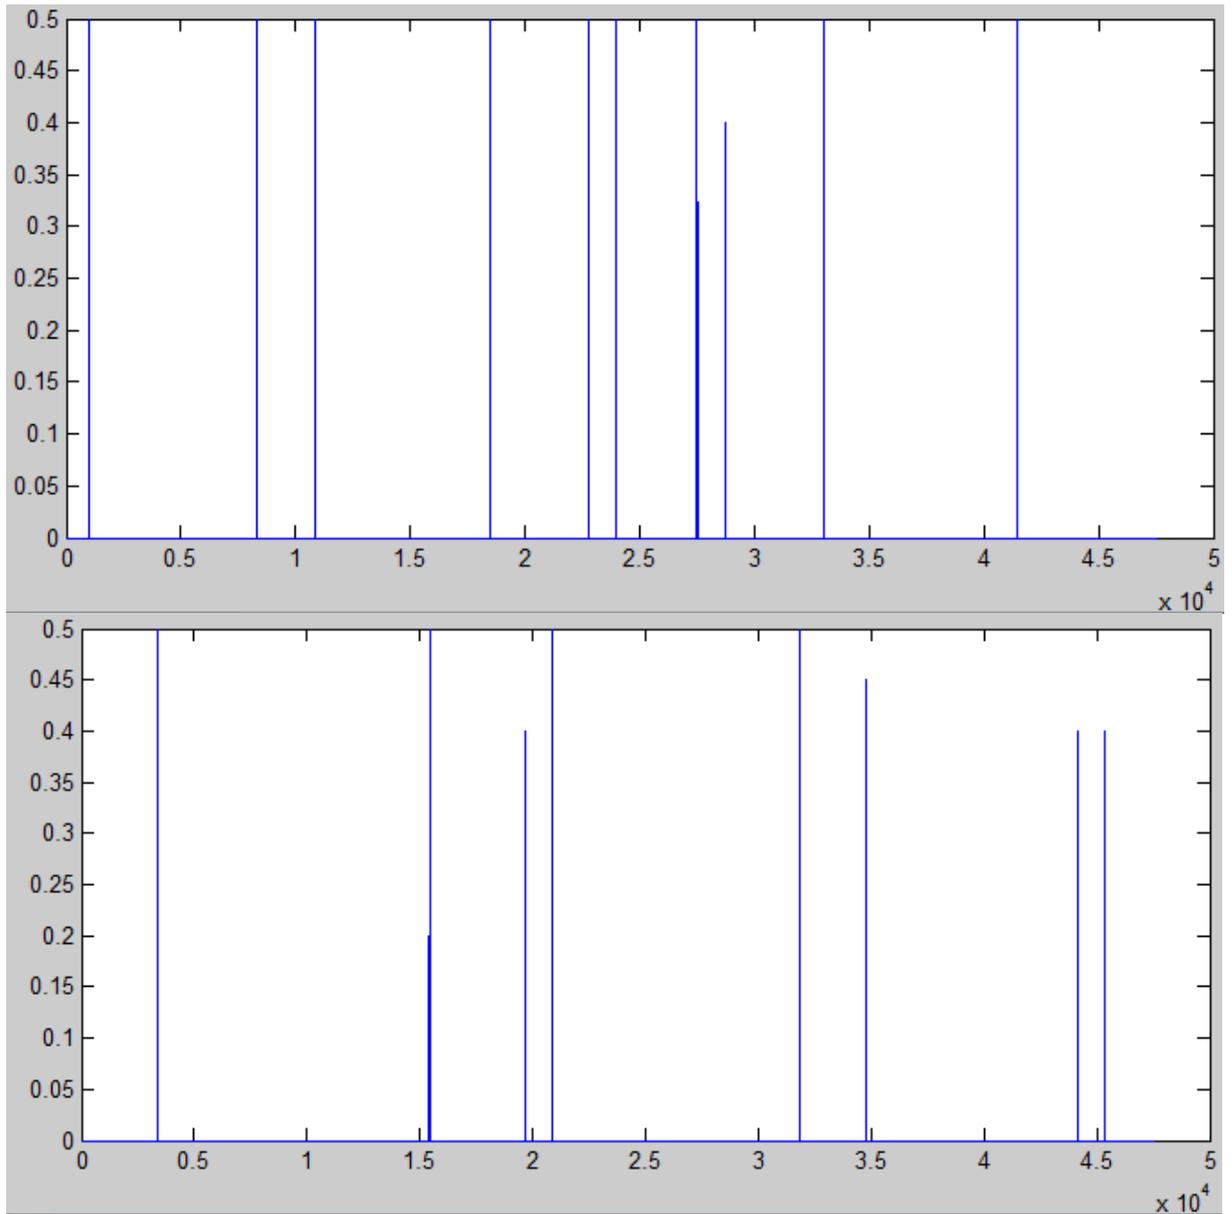


Figura 4.3. Vetores de entrada de descida e subida, respectivamente.

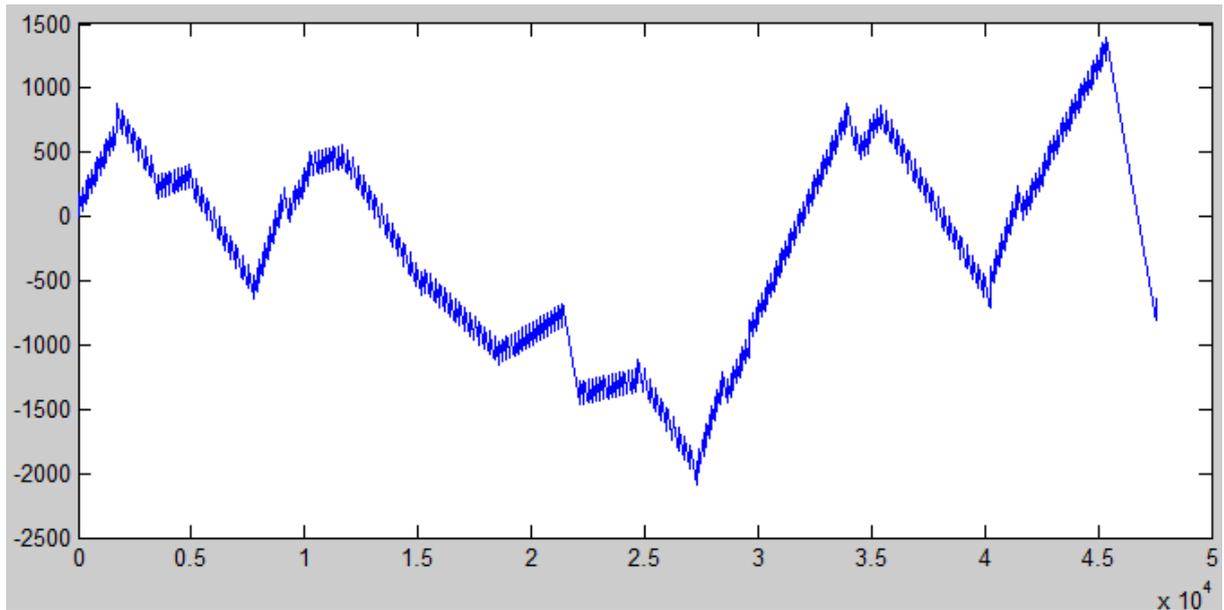


Figura 4.4: Vetor de entrada de Consumo de Alumina

Para topologia RNMD as simulações foram realizadas considerando as seguintes topologias:

- Uma camada escondida com variação da quantidade neurônios de 3 a 30 desta camada.
- Duas camadas escondidas com variação da quantidade neurônios de 3 a 15 e 2 a 20 respectivamente destas camadas.
- Três camadas escondidas com variação da quantidade neurônios de 3 a 15, 2 a 20 e 2 a 20 respectivamente destas camadas.

Para topologia RNR as simulações foram realizadas considerando as seguintes topologias:

- Uma camada escondida variando a quantidade de neurônios (3 a 15), utilizando como retroalimentação a saída da camada oculta e levando-se em consideração os atrasos definidos, ou melhor, acrescentando com os dados de entrada vetores atrasados de 1 valor temporal (tensão  $V_{t-1}$  e corrente  $I_{t-1}$  para o modelo ) e não definidos gerados pela própria rede.

As tabelas 4.1 e 4.2 e seus respectivos gráficos 4.1 e 4.2 apresentam os melhores resultados encontrados para as topologias RNMD e RNR. Observa-se que as topologias

utilizadas apresentaram significativa contribuição para previsão da resistência elétrica, sendo que a RNA do tipo feedforward com três camadas intermediárias, que utiliza momentos atuais e passados das entradas proporcionou melhores resultados, onde se considerou como medida de avaliação o erro de validação diante de padrões não utilizados no treinamento.

. O número de neurônios, assim como o número de camadas que compõe o modelo foram obtidos partindo-se sempre das configurações mais simples com menor número de neurônios e camadas até chegar-se a um número ótimo.

Tabela 4.1 Resultados da RNMD

Quantidade de Neurônios	Erro Treinamento	Erro Validação	Erro Teste
1 Camada Oculta com 5 Neurônios	1.7942e-05	9.1168e-06	6.8037e-06
2 Camadas Ocultas com 5 e 18 Neurônios	1.7037e-05	8.0248e-06	1.1942e-05
3 Camadas Ocultas com 3, 2 e 19 Neurônios	1.8451e-05	4.7689e-06	9.1408e-05

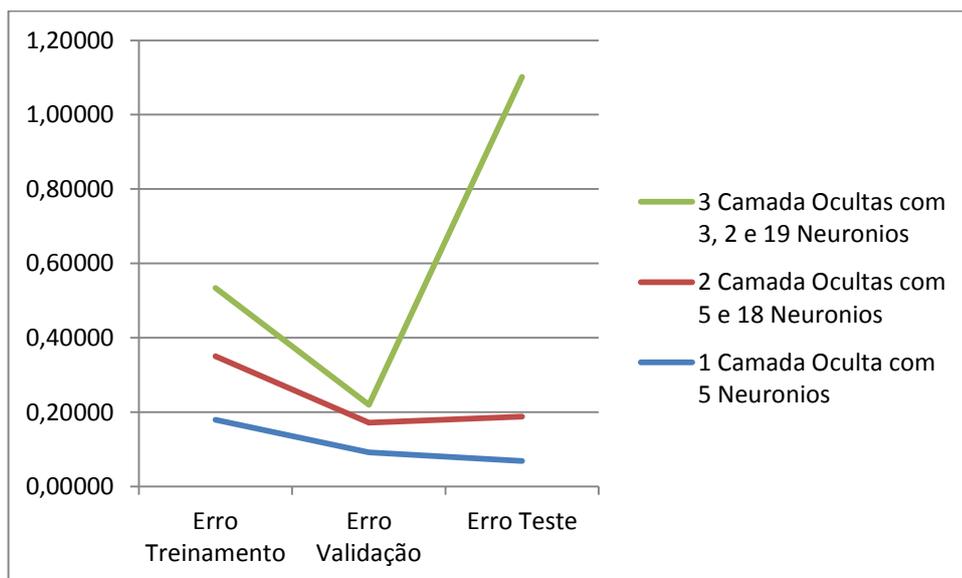


Gráfico 4.1 Resultados da RNMD

Tabela 4.2 Resultados da RNR

Arquitetura	Quantidade Neurônios na camada Oculta 1	Erro Treinamento	Erro Validação	Erro Teste
Com atraso definido	6	1.7113e-05	8.7193e-06	1.8548e-05
Sem atraso definido	14	1.9102e-05	1.0880e-05	2.2581e-06

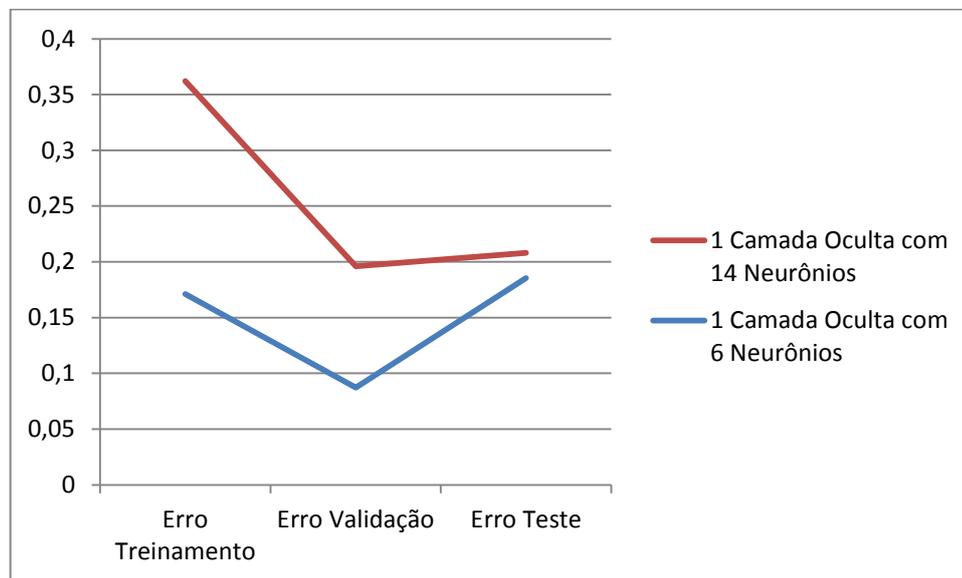


Gráfico 4.2 Resultados da RNR

A rede recorrente sem atraso definido foi a que obteve o menor erro de teste, portanto maior generalização. De fato, a experiência prática diz que mais de duas camadas não resulta em melhora de desempenho e como é possível perceber a RNA conseguiu mapear satisfatoriamente os valores de tensão instantânea e intensidade da corrente.

Nas figuras 4.5 e 4.6 a seguir são apresentados os valores reais e os melhores resultados, obtidos pela RNMD com 3 camadas para os vetores de tensão ( $V_{t+1}$ ) e corrente ( $I_{t+1}$ ), respectivamente. Devem ser levados em consideração alguns aspectos. O primeiro nas figuras a tensão e corrente desejada são representados pela linha azul e tensão e corrente obtida da rede é o traçado circular em vermelho. Segundo, diz respeito à inclusão de uma

parada do forno durante a coleta. Este evento pode ser encarado como uma forte perturbação e que mesmo assim o modelo reagiu adequadamente.

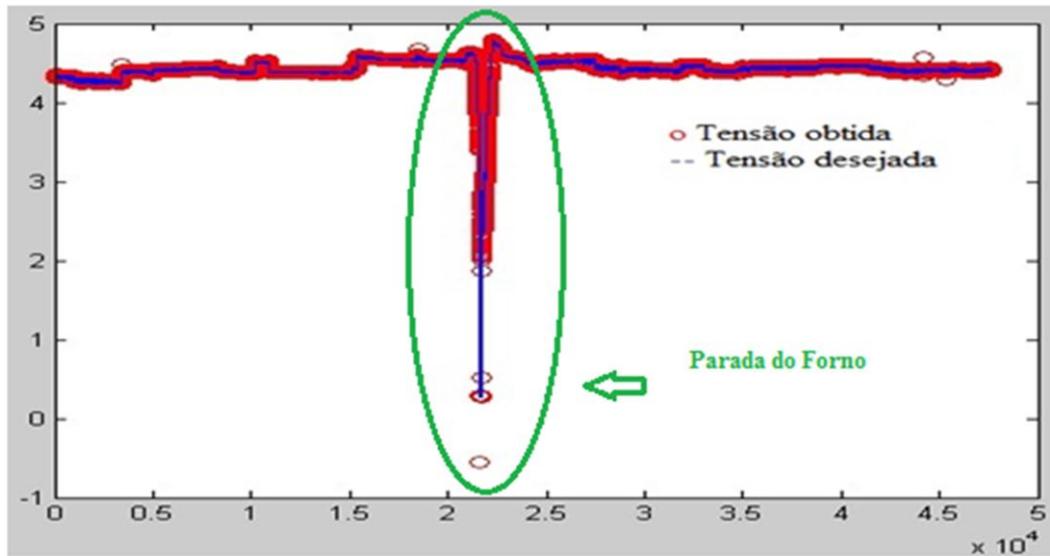


Figura 4.5: Saída em Tensão durante a validação

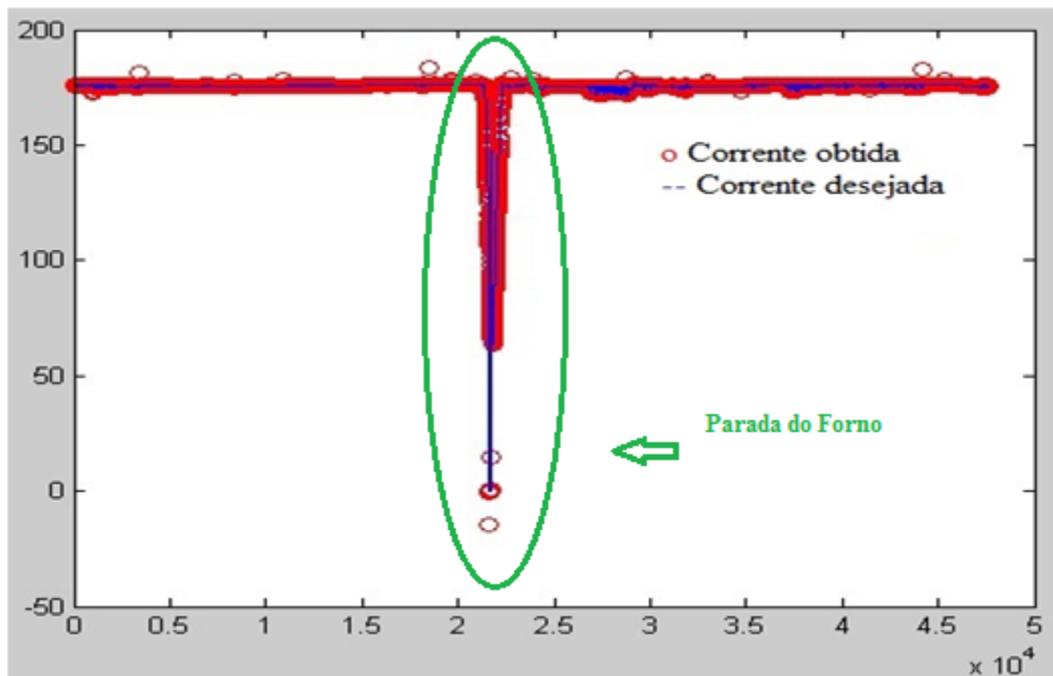


Figura 4.6: Saída em Corrente durante a validação

## 5. CONCLUSÃO

A indústria do alumínio tem investido intensamente na otimização de seu processo. A modificação de qualquer rotina em um sistema de controle pode gerar inúmeros problemas, Assim, qualquer alternativa que minimize tais interferências, são muito bem recebidas.

A tecnologia de automação está definitivamente integrada ao processo de produção industrial. Hoje, a necessidade de alta produtividade em conjunto com a “excelência” da qualidade, somente pode ser atendida, através do adequado equacionamento entre o tipo de tecnologia e a estratégia a ser empregada.

Este trabalho teve como objetivo demonstrar à aplicabilidade do modelo neural em problemas industriais, através da modelagem do comportamento da resistência elétrica de um forno de redução de alumínio.

A rede neural foi utilizada para emular o comportamento dinâmico da variação de resistência elétrica do forno de redução de alumínio. Desta forma é possível se fazer testes, sem utilização de um forno real, de uso de novas topologias para modelagem de resistência elétrica do forno.

A implantação do modelo neural Recorrente no forno de redução apresenta uma nova contribuição com relação às propostas de apoio aos ajustes e desenvolvimento de novas estratégias de controle que visam o aperfeiçoamento da técnica atualmente utilizada pela empresa. Com o entendimento e o controle efetivo da resistência, será possível desenvolver um sistema que resultará em ganhos de produtividade e redução do custo operacional.

A Rede Neural se mostrou uma importante técnica de inteligência computacional e viável na elaboração de modelos para problemas de difícil modelagem e complexos. A operação da área de redução das empresas produtoras do metal não ferroso através de seus fornos eletrolíticas representa um grande desafio para o corpo técnico da empresa. Por isso existe a necessidade de um sistema de controle que atenda de maneira satisfatória as diferentes situações apresentadas pelo processo.

### 5.1 BENEFÍCIOS ESPERADOS

Constatou-se que, em função da sua grande capacidade de aprendizagem e de generalização do conhecimento adquirido, uma RNA pode se constituir em um meio rápido e

preciso de interpretação dos resultados de problemas complexos. Quando bem treinadas e com uma configuração adequada, as mesmas podem atingir níveis de erro muito reduzido.

## 5.2 SUGESTÕES PARA TRABALHOS FUTUROS

Este trabalho finaliza com a apresentação de algumas sugestões de desenvolvimento futuro no que diz respeito à modelagem da resistência dos fornos de redução de alumínio.

- Incluir alguma outra técnica computacional para efetuar comparação com o modelo neural.
- Testar outras arquiteturas de redes para o sistema proposto
- Ampliar a abrangência deste trabalho para as demais variáveis como por exemplo o percentual de fluoreto no banho eletrolítico , afim de se possa reproduzir fenômenos ainda não contemplados pelo modelo neural artificial.
- Incluir análise de outros atrasos nas variáveis de entrada da modelagem neural como descida e subida (t-1) e ( t-2) ou alimentação da alumina (t-1) e (t-2)
- Utilizar o modelo que apresentou melhor resultado para desenvolver um controle na distância do anodo e catodo

## REFERÊNCIAS

AGUIRRE, L.A. Introdução à identificação de sistemas: técnicas Lineares e não-lineares aplicadas a sistemas reais. Belo Horizonte: Ed. UFMG, 2004.

ALUMÍNIO, Associação Brasileira do. ABAL. Disponível em: <<http://www.abal.org.br/>>. Acesso em: 05 nov. 2014.

BRAGA, ANTÔNIO DE PÁDUA; CARVALHO, ANDRÉ PONCE DE LEON F DE; LUDERMIR, TERESA BERNARDA. Redes Neurais Artificiais: Teoria e Aplicações. 2. ed. Rio de Janeiro: Ltc, 2011.

BENUSKOVA, L., KASABOV, N. Computational Neuro Genetic Modeling, 1 ed. Springer 2010.

CARVALHO, ANDRÉ C.P.L.F. Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina. Rio de Janeiro: LTC, 2011.

DEMUTH, H., BEALE, M. HAGAN, M. Neural Network Toolbox 6 User Guide, Mathworks, 10th ed., 2008.

FORTUNA, LUIGI. Soft Sensors for Monitoring and Control of Industrial Processes. Springer, 1ª ed. 2007.

FORTUNA, L., GIANNONE,P.,GRAZIANI,S., XIBILIA, M.G., Virtual Instruments Based on Stacked Neural Networks to Improve Product Quality Monitoring in a Refinery, IEEE Instrumentation & Measurement Magazine, vol. 56, no.1 pp.95-101, Feb. 2007.

GRJOTHEIM, K.; KVANDE, H. Introduction to aluminium eletrolysis.undertanding the Hall-Hèroult Process. 2nd Edition, Aluminium-Verlag Dusseldorf, 1993.

HAYKIN, SIMON. Neural Networks and Learning Machines. 3. ed. Prentice Hall Publisher, 2008

HERNANDEZ, E.D.L. Inteligência computacional e redes neurais em engenharia elétrica. São Paulo: PSI-EPUSP, 2005.

McFADDEN, F.J.S., WELCH, B.J., WHITFIELD, D., KAZACOS, M.S. Control of Temperature in Aluminium Reduction Cells – Challenges in Measurements and Variability TMS Light Metals 2001 – Proceedings of the Technical Sessions, 130rd Technical TMS Annual Meeting, February 11-15, New Orleans.

PEREIRA, V.G. et al. Adição de AlF<sub>3</sub> em Cubas de Alumínio Utilizando Lógica Fuzzy, paper in (CD-Rom) VII Simpósio de Automação Inteligente - São Luís - Brasil, 2005.

ROSA, JOÃO LUIS GARCIA. Fundamentos da Inteligência Artificial. Rio de Janeiro: Ltc, 2011.

RUSSELL, STUART; NORVIG, PETER. Inteligência Artificial. 2. ed. Rio de Janeiro: Campus, 2004.

RASAD, S. Studies on the Hall-Heroult Aluminium electrowinning Process, Journal of Brazilian Chemistry Society, May/June 2000, vol. 11, no.3, p.245-251, ISSN 0103-5053.

SILVA, I.N.; SPATTI, D.H. FLAUZINO, R.A. Rede Neurais Artificiais: para engenharia e ciências aplicadas, Artliber, São Paulo, 2010.

SCHMID, ALBRECHT. A Modular Neural Network Architecture with Additional Generalization Abilities for High Dimensional Input Vectors. Dissertação de mestrado, Manchester Metropolitan University, 1996.

SOARES, F.M., Desenvolvimento de Modelos Neuro-Adaptados para Propagação de Ondas em Florestas, Trabalho de Conclusão de Curso para obtenção do diploma de Engenheiro de computação, Universidade Federal do Pará, 2006.

SOARES,F.M., OLIVEIRA, R.C.L, Inferência de Temperatura de Fornos de Redução de Alumínio Primário através de Sensores Virtuais IX Congresso Brasileiro de Redes Neurais,Ouro Preto-MG 25-28 de Outubro de 2009.

TORMOND, D.; DAG, L.; BJARNE, A. On the ALF3 and Temperature Control of an Aluminum Electrolysis cell. IEEE Transactinos on Control Systems Technology, Vol 6, n. 2, March 1998.

WANG, Li-xin. A course in fuzzy: systems and control. Hong Kong: Prentice-hall International,inc, 1997.

## APÊNDICE A: FONTE DO PROGRAMA DO MATLAB PARA CONSTRUIR A REDE NEURAL MULTICAMADA DIRETA (RNMD)

### A.1 CASO 1

```

load dados.mat
%=====
TAMANHO=47604;
epocas=60;
objetivo=0.000001;
%=====
erroValMelhor=inf;
saidamelhor=zeros(1,TAMANHO);
erVal=ones(1,30);
erTes=ones(1,30);
erTre=ones(1,30);
qtdNeurMelhor=0;

for neuronios=3:30 %permite executar N vezes pra quantidade de neurônio
    net=newff(P,S,neuronios,{'logsig','purelin'},'trainlm');
    net.trainParam.goal=objetivo;
    net.trainParam.epochs=epocas;

    net.divideFcn='divideind';
    net.divideParam.trainInd=indTreino;
    net.divideParam.valInd=indVal;
    net.divideParam.testInd=indTeste;

    net.trainParam.showWindow=false;
    [net tr]=train(net,P,S);%TREINO VALIDAÇÃO e TESTE

    if(tr.best_vperf < erroValMelhor)
        qtdNeurMelhor=neuronios
        saidamelhor=sim(net,P);
    end

    %Salvando os Erros a Cada Quantidade de neurônios
    erVal(neuronios)=tr.best_vperf;
    erTes(neuronios)=tr.best_tperf;
    erTre(neuronios)=tr.best_perf;

    neuronios
end

```

## A.2 CASO 2

```
load dados.mat
```

```
%=====
TAMANHO=47604;
epocas=60;
objetivo=0.000001;
%=====
erroValMelhor=inf;
saidamelhor=zeros(1,TAMANHO);
erVal=ones(15,20);
erTes=ones(15,20);
erTre=ones(15,20);
qtdNeurMelhor=[0 0];

for neuronios1cam=3:15 %permite executar n vezes pra quantidade de neurônio
    for neuronios2cam=2:20 %permite executar n vezes pra quantidade de neurônio

        net=newff(P,S,[neuronios1cam neuronios2cam],{'logsig','logsig','purelin'},'trainlm');
        net.trainParam.goal=objetivo;
        net.trainParam.epochs=epocas;

        net.divideFcn='divideind';
        net.divideParam.trainInd=indTreino;
        net.divideParam.valInd=indVal;
        net.divideParam.testInd=indTeste;

        net.trainParam.showWindow=false;
        [net tr]=train(net,P,S);%TREINO VALIDAÇÃO e TESTE

        if(tr.best_vperf < erroValMelhor)
            qtdNeurMelhor=[neuronios1cam neuronios2cam]
            saidamelhor=sim(net,P);
        end
        %Salvando os Erros a Cada Quantidade de neurônios
        erVal(neuronios1cam,neuronios2cam)=tr.best_vperf;
        erTes(neuronios1cam,neuronios2cam)=tr.best_tperf;
        erTre(neuronios1cam,neuronios2cam)=tr.best_perf;

        neuronios1cam
        neuronios2cam
    end
end
```

### A.3 CASO 3

```

load dados.mat
%=====
TAMANHO=47604;
epocas=60;
objetivo=0.000001;
%=====
erroValMelhor=inf;
saidamelhor=zeros(1,TAMANHO);
erVal=ones(15,20,20);
erTes=ones(15,20,20);
erTre=ones(15,20,20);
qtdNeurMelhor=[0 0 0];

for neuronios1cam=3:15 %permite executar N vezes pra quantidade de neurônio
    for neuronios2cam=2:20
        for neuronios3cam=2:20 %Neuronios da 3a camada escondida
            net=newff(P,S,[neuronios1cam neuronios2cam
neuronios3cam],{'logsig','logsig','logsig','purelin'},'trainlm');
            net.trainParam.goal=objetivo;
            net.trainParam.epochs=epocas;

            net.divideFcn='divideind';
            net.divideParam.trainInd=indTreino;
            net.divideParam.valInd=indVal;
            net.divideParam.testInd=indTeste;

            net.trainParam.showWindow=false;
            [net tr]=train(net,P,S);%TREINO VALIDAÇÃO e TESTE

            if(tr.best_vperf < erroValMelhor)
                qtdNeurMelhor=[neuronios1cam neuronios2cam neuronios3cam]
                saidamelhor=sim(net,P);
            end
            %Salvando os Erros a Cada Quantidade de neurônios
            erVal(neuronios1cam,neuronios2cam,neuronios3cam)=tr.best_vperf;
            erTes(neuronios1cam,neuronios2cam,neuronios3cam)=tr.best_tperf;
            erTre(neuronios1cam,neuronios2cam,neuronios3cam)=tr.best_perf;

            neuronios1cam
            neuronios2cam
            neuronios3cam
        end
    end
end
end

```

## APÊNDICE B: FONTE DO PROGRAMA DO MATLAB PARA CONSTRUIR A REDE NEURAL RECORRENTE (RNR)

### B.1 COM SINAL de ATRASO DEFINIDO

```

load dados.mat
TAMANHO=47604;

erroValMelhor=inf;
saidamelhor=zeros(1,TAMANHO);
erVal=ones(1,15);
erTes=ones(1,15);
erTre=ones(1,150);
qtdNeurMelhor=0;

for neuronios1cam=3:15
    net=layrecnet(1,neuronios1cam);
    net.trainFcn = 'trainlm';
    net.trainParam.showWindow=false;

    net.divideFcn='divideind';
    net.divideParam.trainInd=indTreino;
    net.divideParam.valInd=indVal;
    net.divideParam.testInd=indTeste;

    net.trainParam.goal=0.00001;
    net.trainParam.epochs=40;

    [net tr]=train(net,P,S);
    if(tr.best_vperf < erroValMelhor)
        qtdNeurMelhor=neuronios1cam
        saidamelhor=sim(net,P);
    end

    % Salvando os Erros a Cada Quantidade de neurônios
    erVal(neuronios1cam)=tr.best_vperf;
    erTes(neuronios1cam)=tr.best_tperf;
    erTre(neuronios1cam)=tr.best_perf;

    neuronios1cam
end

```