

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA QUÍMICA

**ÁREA DE CONCENTRAÇÃO
SISTEMAS DE PROCESSOS QUÍMICOS E INFORMÁTICA**

**REDES NEURAIIS EM PROCESSOS SIDERÚRGICOS:
ANALISADOR VIRTUAL DE PROPRIEDADES METALÚRGICAS DO SÍNTER E
MODELO DE PREDIÇÃO DE QUALIDADE DO AÇO**

Autor: André Pitasse da Cunha

Orientadora: Ana Maria Frattini Fileti

Tese de Doutorado apresentada à Faculdade de Engenharia Química como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Química.

Campinas - São Paulo

Dezembro/2001

**UNICAMP
BIBLIOTECA CENTRAL
SEÇÃO CIRCULANTE**

**UNICAMP
BIBLIOTECA CENTRAL**

Nº CHAMADA UNICAMP
C914r
V EX
TOMBO BCI 49623
PROC 16-83710 2
C DX
PREÇO R\$ 11,00
DATA 14/06/02
Nº CPD _____

CM00169433-0

1B 1D 245752

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

C914r Cunha, André Pitasse da
Redes neurais em processos siderúrgicos: analisador virtual de propriedades metalúrgicas do sinter e modelo de predição de qualidade do aço / André Pitasse da Cunha. -- Campinas, SP: [s.n.], 2001.

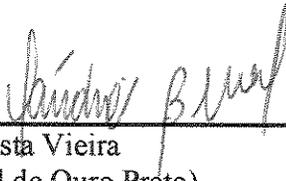
Orientador: Ana Maria Frattini Fileti.
Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Controle. 2. Redes neurais (Computação). 3. Siderurgia. 4. Aço - Indústria. I. Fileti, Ana Maria Frattini. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Tese de Doutorado defendida e aprovada em 14 de dezembro de 2001 pela banca examinadora constituída pelos doutores:



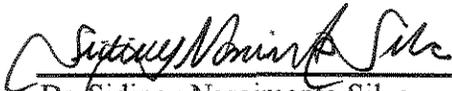
Prof.^a Dr.^a Ana Maria Frattini Fileti
Orientadora



Prof. Dr. Cláudio Batista Vieira
(Universidade Federal de Ouro Preto)



Dr. Ricardo Henriques Leal
(Companhia Siderúrgica Nacional)



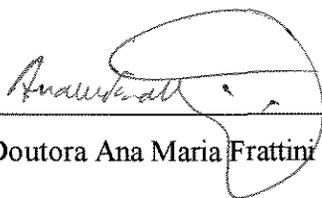
Dr. Sidiney Nascimento Silva
(Companhia Siderúrgica Nacional)



Prof. Dr. João Alexandre Ferreira da Rocha Pereira
(Faculdade de Engenharia Química, UNICAMP)

0059200

Este exemplar corresponde à versão final da Tese de Doutorado em Engenharia Química.

A handwritten signature in black ink, appearing to read "Ana Maria Frattini Fileti", is written over a horizontal line. The signature is stylized and partially overlaps the line.

Professora Doutora Ana Maria Frattini Fileti

AGRADECIMENTOS

À Profa Dra. Ana Maria Frattini Fileti, pela confiança, pela orientação, pelo conhecimento transmitido e pela relação de respeito.

Aos técnicos do Centro de Pesquisa da CSN, Oldair, Alexandre, Wilson, David, Giuliano, Epitácio, Márcio, Rosângela, Muricy e Valdeir pelo apoio nas análises laboratoriais e nas simulações piloto.

Ao supervisor Renato Luiz Martins Pinto, pelo apoio laboratorial e pelas discussões técnicas.

Ao engenheiro Carlos Tadeu Reis pelas discussões técnicas e ao técnico Edival pelo grande trabalho realizado no apoio ao ajuste do banco de dados.

Ao Prof. Dr. Cláudio Batista Vieira, pelas discussões técnicas e orientação no ramo metalúrgico.

Aos operadores dos conversores da CSN, pelo apoio e orientação durante os testes industriais.

Ao engenheiro Luiz Fernandes Messias, pelo apoio desde o início do trabalho.

À Lidia Rocha Micheloni pelo incansável apoio ao desenvolvimento deste trabalho.

Aos meus pais, Carlos Roberto Fajardo da Cunha e Maria Eloíza Pitasse da Cunha pelo apoio integral ao meu desenvolvimento.

RESUMO

O baixo acerto simultâneo de temperatura e de teor de carbono ao final do refino é um típico problema das siderúrgicas e é determinado, principalmente, por oscilações de qualidade das matérias primas e pelas limitações de atuação dos modelos matemáticos.

O consumo de coque e a permeabilidade dos altos-fornos são parcialmente inferidos por informações das propriedades metalúrgicas das matérias primas: o RDI (Índice de Degradação sob Redução) indica a geração de finos dentro dos altos-fornos e o RI (Índice de Redutibilidade) infere a quantidade de coque necessária para a redução dos óxidos de ferro neste reator. Entretanto, estas propriedades são pouco exploradas pelas empresas pois os ensaios são caros e, particularmente o RI, leva um longo tempo de obtenção da resposta. Estas limitações atribuem oscilações de qualidade ao gusa e, portanto, influem no refino.

No processo de refino, o modelo estático define a mistura de matérias primas e a razão de oxigênio necessária ao início do sopro no conversor LD e, após as medidas efetuadas pela sublança, o modelo dinâmico busca acertar a temperatura e a composição do aço objetivadas, através de correções com refrigerantes e oxigênio. Estes modelos são similares em muitas indústrias, mas têm comportamentos diferentes devido as diferenças em níveis de controle.

Para resolver estas duas limitações, não existência de análises de propriedades metalúrgicas e restrições em modelos matemáticos (para agir na aciaria), modelos baseados em redes neurais artificiais foram desenvolvidos para prever RDI e RI de sínter (a partir de análises químicas e mineralógicas) e para prever teor de carbono e de temperatura do aço (a partir de informações do processo de refino). No caso da sinterização, foram estudadas, no Centro de Pesquisa da CSN, as influências das características mineralógicas nas propriedades metalúrgicas do sínter. Em seguida, construiu-se o banco de dados com amostras industriais de sínter analisadas em laboratórios.

Planejamento e Otimização de Experimentos (POE) foi necessário para planejar as sinterizações piloto, para selecionar amostras industriais (para simplificar as análises químicas, mineralógicas, de RDI e de RI) e para ajustar os parâmetros dos modelos neurais. Para o processo de aciaria, foi utilizado o histórico do processo e o POE para ajustar as redes neurais.

A modelagem com diferentes bancos de dados de diferentes tamanhos, possibilitaram, com a organização do POE, obter-se novos resultados no contexto de ajuste dos parâmetros e de arquitetura de rede neural artificial .

O analisador virtual atingiu bons resultados de previsão de RDI (precisão de 4,5% contra o permissível de 2 a 4% da norma ISO 4696-1) e de RI (precisão de 4,5% contra 7 a 11% de tolerância da norma ISO 7215).

No caso da aciaria, os modelos neurais foram superiores aos modelos convencionais da CSN. Entretanto, o resultado significativo foi obtido pelo modelo dinâmico via redes neurais, com um acerto simultâneo de 73,3%, contra 44% do modelo dinâmico convencional. Este excelente resultado motivou testes industriais. Para tanto, combinou-se os modelos estático convencional e dinâmico via redes neurais. Após 30 corridas, o acerto simultâneo foi de 83,3%.

ABSTRACT

The low hitting rate of temperature and carbon content in blow-off is a typical problem in steel companies. There are two main reasons for that: oscillation in raw materials quality and limitation in mathematical models to hit the target.

Coke consumption and permeability in the blast furnace can be partially inferred from information on metallurgical properties of raw materials: the RDI (Reduction Degradation Index) indicates the quantity of fines produced inside blast furnace and RI (Reducibility Index) infers the quantity of coke necessary to reduce iron oxides in this reactor. However, these properties are not assessed in many industries because the analyses are expensive. Besides, in the case of RI analysis, the results take a long time to be concluded. These restrictions make difficult avoiding oscillation in hot metal quality and affect steelmaking process.

In the refining process, the static model defines the raw mix materials and the oxygen flow rate necessary to start blowing in the LD converter and, after in-blow measuring by substance, the dynamic model search to hit the aimed temperature and composition of steel in the blow-off, through corrections with coolants and final volume of oxygen . These models are similar in many industries, but they have different behavior where there are differences in levels of control.

To solve these two limitations, no analyses of metallurgical properties and restrictions in mathematical models (to act in steelmaking process), models based on artificial neural network were developed to predict RDI an RI of sinter (from chemical and mineralogical analyses) and to predict carbon content and temperature of steel (from information of the refining process). In the case of sintering, first of all was studied, in the Research Center of CSN, how mineralogical characteristics define the metallurgical properties in sinter. After that, it was necessary to build the database with industrial samples of sinter analyzed in laboratories.

Design and Optimization Experiment (DOE) was necessary to plan pilot sintering, to select industries samples of sinter (to simplify the chemical, mineralogical, RDI and RI analyses) and to set the parameters of neural networks models. For the steelmaking process, it was used historical database and DOE techniques only to set neural models.

The modeling of artificial neural networks with different database and different size, through DOE, brought new information on optimization of parameters and architecture of these models.

The virtual analyzer reached good results predicting RDI (the accuracy was 4,5% versus 2 to 4% of ISO 4696-1 tolerance) and RI (the accuracy was 4,5% versus 7 to 11% of ISO 7215 tolerance).

Artificial neural networks models performed better than CSN's conventional models in the case of the steelmaking process. But the best result was reached with the neural model acting as dynamic model, with hitting rate equal to 73,3% versus 44% for conventional dynamic model. This excellent result motivated industrial tests. Then, it was combined conventional static and artificial neural network dynamic models. After 30 heats, the hitting rate reached 83,3%.

ÍNDICE

CAPÍTULO 1	INTRODUÇÃO	1
CAPÍTULO 2	DESCRIÇÃO DO PROCESSO E REVISÃO BIBLIOGRÁFICA	5
	2.1 A METALURGIA DA REDUÇÃO E DO AÇO	5
	2.1.1 O SÍNTER PARA ALTOS-FORNOS	7
	2.1.1.1 CONSIDERAÇÕES SOBRE MINERALOGIA, RDI E RI DO SÍNTER	23
	2.1.2 O REFINO E OS MODELOS MATEMÁTICOS	33
	2.1.2.1 INTRODUÇÃO	33
	2.1.2.2 MECANISMO DE DESCARBURAÇÃO	35
	2.1.2.3 O MODELO ESTÁTICO	36
	2.1.2.3.1 O BALANÇO DE MASSA	38
	2.1.2.3.2 O BALANÇO DE ENERGIA	45
	2.1.2.4 O MODELO DINÂMICO	48
	2.1.2.5 O DIRECIONAMENTO DA MODELAGEM MATEMÁTICA	50
	2.2 REDES NEURAIS ARTIFICIAIS	54
	2.2.1 HISTÓRICO	54
	2.2.2 CONCEITOS BÁSICOS EM REDES NEURAIS ARTIFICIAIS	57
	2.2.3 ANALOGIA ENTRE O NEURÔNIO BIOLÓGICO E O ARTIFICIAL E ARQUITETURA DA REDE NEURAL ARTIFICIAL	59
	2.2.4 O ALGORITMO DE TREINAMENTO BACKPROPAGATION	61
	2.2.5 ASPECTOS AVANÇADOS EM REDES NEURAIS ARTIFICIAIS	70
	2.2.6 APLICAÇÕES DE REDES NEURAIS EM SIDERURGIA	85
CAPÍTULO 3	ANÁLISE DO PROBLEMA	91
CAPÍTULO 4	MATERIAIS E MÉTODOS	96
	4.1 DESENVOLVIMENTO DA FERRAMENTA REDES NEURAIS ARTIFICIAIS	96
	4.2 O PLANEJAMENTO DE EXPERIMENTOS FATORIAL	99
	4.3 EXPERIMENTOS PILOTO E CARACTERIZAÇÃO LABORATORIAL	102
	4.4 MODELAGEM DO ANALISADOR VIRTUAL DE RDI E RI DE SÍNTER	105
	4.5 MODELAGEM PARA A PREVISÃO DE QUALIDADE DO AÇO	114

CAPÍTULO 5	RESULTADOS E DISCUSSÃO	117
	5.1 EXPERIMENTOS PILOTO PARA SÍNTER	117
	5.2 SIMULAÇÕES NUMÉRICAS PARA AJUSTE DAS REDES NEURAIS	130
	5.2.1 ANÁLISE DOS PARÂMETROS DE REDE	130
	5.2.2 ANÁLISE DO DESEMPENHO DA RNA EM FUNÇÃO DA ARQUITETURA E DO TAMANHO DO BANCO DE DADOS	137
	5.3 AJUSTES FINAIS DOS PARÂMETROS DE REDES NEURAIS ARTIFICIAIS	148
	5.3.1 RESULTADOS PARA OS ANALISADORES VIRTUAIS	149
	5.3.2 RESULTADOS PARA OS MODELOS DE ACIARIA	155
	5.4 TESTES INDUSTRIAIS	162
CAPÍTULO 6	CONCLUSÕES E SUGESTÕES	171
	6.1 CONCLUSÕES	171
	6.2 SUGESTÕES	176
BIBLIOGRAFIA		178
ANEXO A	FOTOS DA METALURGIA DA REDUÇÃO E DO AÇO DA CSN	188
ANEXO B	MODELAGEM DA REDE NEURAL ARTIFICIAL EM VISUAL C	191
ANEXO C	SISTEMA PILOTO DE SIMULAÇÃO E CARACTERIZAÇÃO DE SÍNTERES	217
ANEXO D	NORMAS ISO DE ENSAIOS DE RDI/RI E PROCEDIMENTO DE ANÁLISE MINERALÓGICA DE SÍNTER	219
ANEXO E	COMPORTAMENTO DAS VARIÁVEIS DE SÍNTER	222
ANEXO F	COMPORTAMENTO DAS VARIÁVEIS DE ACIARIA	225
ANEXO G	ANÁLISE MINERALÓGICA DE SÍNTER	229
ANEXO H	RESULTADOS DAS SIMULAÇÕES NUMÉRICAS PARA OS MODELOS DE ACIARIA	231
ANEXO I	RESULTADOS DAS SIMULAÇÕES NUMÉRICAS PARA OS ANALISADORES VIRTUAIS DE RDI E RI DE SÍNTER	236

CAPÍTULO 1 - INTRODUÇÃO

Processos industriais normalmente são caracterizados por inúmeros fenômenos que, se tratados individualmente, não descrevem com precisão o modelamento como um todo. E a interação de vários fenômenos num mesmo processo leva a um alto nível de complexidade de modelagem. Como se isto não bastasse, os conhecidos problemas de variação dos resultados de qualidade de matérias primas e do produto adicionam ainda maiores dificuldades de validação de modelos matemáticos para um sistema complexo, como a produção do sinter, do gusa ou do aço.

No sistema de produção da metalurgia da redução e do aço, o processo que possui maior controle é justamente a produção de aço e isto se deve principalmente ao fato de que a aciaria recebe em seus conversores matérias primas com maior frequência de amostragem e caracterização, como o gusa, que compõe de 75 a 100% a carga do conversor (dependendo do tipo de aço requisitado). Entretanto, apesar da existência dos modelos matemáticos estáticos e dinâmicos para ajustes de adições e sopro na aciaria, a previsão de qualidade do aço ainda é bastante prejudicada pela falta de informação referente às demais matérias primas e aos gases e fumos gerados pelo processo. Em relação ao controle do sinter e do gusa, estes processos recebem matérias primas sólidas e com baixa frequência de amostragem, o que dificulta a modelagem. No caso específico do sinter, as empresas que possuem o recurso de blendagem das matérias primas ainda conseguem produzir um sinter com maior controle, o que favorece não só a modelagem deste processo, como também dos seguintes. Porém, a complexidade das reações químicas, por exemplo, considerando as reações que ocorrem por contato físico aleatório, dificultam a modelagem matemática convencional.

De um outro segmento de modelagem, observa-se que as áreas que abrangem a engenharia e a medicina nunca tiveram tão perto quanto nos dias atuais. E um produto desta aproximação é a linha híbrida conhecida como engenharia genética. Conhecidos estudos atuais demonstram os avanços desta união e os progressos da busca da medicina em tentar resolver mistérios do corpo humano. Por outro lado, a engenharia tem buscado na

inteligência humana soluções para problemas difíceis de se resolver com as ferramentas convencionais, através de estudos em inteligência artificial, onde alguns conhecidos conceitos do funcionamento do cérebro humano tem sido aplicados como algoritmos matemáticos em problemas de processos industriais.

As redes neurais artificiais são a imitação do funcionamento do sistema neural humano, que possuem como objetivo maior o aprendizado sobre um processo e o desenvolvimento da capacidade de generalização do que foi aprendido. O ser humano aprende a lidar com qualquer situação, uma vez que ele seja treinado para tal finalidade. A rede neural artificial não é diferente; ela necessita de um histórico do que ocorre num processo para seu aprendizado. Condições operacionais, qualidade/quantidade de matérias primas e outros influentes numa variável a ser modelada devem constar num banco de dados previamente filtrado. A rede neural artificial aprende pela apresentação destes padrões, donde surgem erros entre o que foi calculado pelo modelo e o valor real. Este erro é minimizado de forma iterativa até a um valor aceitável. Quando todos os vetores de entrada e saída forem treinados, a rede neural artificial será capaz de generalizar um padrão que não fez parte do treinamento, através de uma característica parecida com a interpolação. Este poder de previsão de variáveis será alcançado pelo modelo após o treinamento da rede neural artificial e esta propriedade será explorada através da “lembrança” da rede.

Por ser uma técnica de aplicação em base de dados (informações disponíveis nas empresas), as redes neurais artificiais se adequam perfeitamente às aplicações industriais, pois as combinações de várias experiências industriais das aleatoriedades citadas possuem uma faixa de atuação que é possível de se rastrear (dentro de limites de especificação). E uma grande vantagem da rede neural é a melhoria contínua do modelo de previsão, mediante o aumento da apresentação de casos reais de processos ao sistema de aprendizado artificial.

Neste trabalho, o problema em questão estudado foi a baixa previsibilidade do teor de carbono e da temperatura do aço pelos modelos matemáticos convencionais de controle estático e dinâmico da CSN. O modelo estático determina as quantidades de agentes

corretivos da composição química do aço e da escória e a quantidade de oxigênio necessária ao refino, em função das características das matérias primas e o modelo dinâmico corrige, conforme equacionamento cinético e/ou ajustes empíricos, durante o final do refino, o direcionamento para acerto da especificação do aço. Os principais problemas relacionados a este efeito indesejável são as limitações de medida das entradas e saídas do conversor, as simplificações dos modelos matemáticos e a grande variação química do gusa.

O baixo acerto simultâneo da composição química e da temperatura do aço após o fim de sopro (em torno de 45% de acerto simultâneo) é fortemente influenciado pela sua principal matéria prima, o gusa. Por sua vez, o gusa é fortemente influenciado por oscilações químicas, granulométricas e mineralógicas do sinter, que determinam as características metalúrgicas desta matéria prima. Sendo assim, deduz-se que a consequência da melhoria da qualidade do gusa poderia ajudar muito os modelos matemáticos estático e dinâmico de produção de aço a atingirem acertos maiores. Mas alguns fatores tornam inviáveis a modelagem, tanto convencional quanto por inteligência artificial dos processos de altos-fornos:

- i. Variação do tempo de residência das matérias primas no interior dos altos-fornos, devido às oscilações operacionais;
- ii. Baixa frequência de caracterização química das matérias primas (se comparada com a frequência de análise química do gusa);
- iii. Inexistência de informações do comportamento metalúrgico do sinter e do minério de ferro, referentes à resistência a degradação a quente e à redutibilidade;
- iv. Inexistência de monitoramento do comportamento das matérias primas e de sua transformação no interior do reator.

Com a necessidade de melhoria do acerto simultâneo de teor de carbono e de temperatura do aço e a impossibilidade de atuação imediata em melhoria da qualidade do gusa, devido principalmente aos problemas de qualidade das matérias primas, optou-se neste trabalho por atuar em dois grandes problemas:

- i. Na falta de informações de propriedades metalúrgicas do sinter, mais especificamente, de RDI (índice de degradação sob redução) e de RI (redutibilidade) do sinter;
- ii. No baixo acerto na previsão da qualidade do aço, estruturando um sistema de auxílio que saiba atuar com as oscilações químicas e térmicas do gusa.

A solução para estes problemas foi o desenvolvimento de modelos de redes neurais com o intuito de melhorar a previsão do teor de carbono e da temperatura do aço líquido, baseados em dados de processo de refino, e viabilizar a previsão de importantes propriedades metalúrgicas do sinter (neste caso a rede neural artificial substituiria a análise laboratorial, atuando como um analisador virtual de RDI e RI). No caso do sinter, seria uma tentativa de se melhorar a qualidade do gusa mediante a melhoria da principal matéria prima que o produz (já que o grande problema da variação química do gusa, fortemente influenciada pelas variações térmicas, é a variação de qualidade do sinter). Já o caso do aço, o modelo foi ajustado para a atuação no sistema de controle de produção do aço.

Para atender ao proposto, foi realizada uma revisão bibliográfica sobre os assuntos sinter, gusa, aço, modelagem matemática nestes processos e inteligência artificial (registrada no capítulo 2 deste trabalho). No capítulo 3 foram caracterizados os problemas a serem solucionados. No capítulo 4, com a técnica de planejamento fatorial e otimização de experimentos e com o desenvolvimento de uma rede neural, foi possível estruturar as soluções para este problema, que passaram pelo ajuste de alternativas de solução baseadas em diferentes redes neurais, tanto para o processo sinter, quanto para o aço. No capítulo 5 estão os resultados dos trabalhos desenvolvidos e no capítulo 6 estão as conclusões.

CAPÍTULO 2 - DESCRIÇÃO DO PROCESSO E REVISÃO BIBLIOGRÁFICA

2.1 A METALURGIA DA REDUÇÃO E DO AÇO

Segundo Assis⁽¹⁾, as rotas possíveis de processo para a produção de aço combinam os seguintes equipamentos:

- i. Forno elétrico de aço: rota não integrada (não há redução dos minério de ferro).
Processos de pequena e média escala (100 a 800 mil de toneladas por ano);
- ii. Altos-fornos e conversores a oxigênio: rota integrada de grande escala (acima de 1 milhão de toneladas por ano, caso da CSN);
- iii. Redução direta e forno elétrico de aço: rota integrada de média escala (300 mil a 1 milhão de toneladas por ano);
- iv. Fusão-redução e conversores a oxigênio - tecnologia emergente: único processo em escala comercial é o Corex com escala de 1 milhão de toneladas por ano.

A produção de aço pela CSN, por conversor a oxigênio, é um processo que envolve o refino (remoção de impurezas) de uma carga composta por sucatas (fontes de ferro diversas, tais como refugos do processo de laminação, lingotamento, escória beneficiada, etc.), aditivos para ajuste da composição química da escória e do aço, tais como cal calcítica, cal dolomítica, minério de ferro, FeSi etc, e a principal matéria prima (cerca de 75 a 100% da carga, dependendo do tipo de aço produzido, ou da forma de atuação da empresa), o gusa, produzido em altos-fornos.

O refino (com sopro de oxigênio realizado de cima para baixo por uma lança controlada por computador) em conversores LD é fortemente influenciado pela composição química e pela temperatura do gusa. Nas indústrias siderúrgicas integradas, os principais sistemas produtivos necessários à produção do aço, desde a chegada das matérias primas (hematita, dolomito, calcário, etc) são: a coqueria, que produz o coque a partir de uma

mistura de carvões, objetivando a aglomeração destes carvões e eliminação de voláteis e impurezas, como o enxofre, sendo o produto coque fabricado com granulometria e propriedades químicas e metalúrgicas adequadas ao consumo para as reações de redução dentro dos altos-fornos; a sinterização, que possui a finalidade de aglomerar e sinterizar finos de minério de ferro, de fundentes e outros aditivos, utilizando de combustíveis de finos de coque (produzidos pela coqueria (beneficiados por peneiramento) e/ou adquiridos no mercado); e o alto-forno, que através do consumo de matérias primas e insumos oriundos de minas de minério de ferro e de fundentes, de sinter produzido pelas sinterizações e de coque e derivados, produzidos pelas coquerias, produz o gusa. Com o produto gusa e com as sucatas e outros aditivos, a aciaria produz o aço. Assim, para se conseguir alguma ação sobre a qualidade do aço é necessário melhoria nas matérias primas, nos procedimentos operacionais e no ajuste dos modelos matemáticos. Para agir nas matérias primas, é necessário a otimização da compra das sucatas, o que compete as áreas comerciais, e a melhoria da qualidade das matérias primas internas e de materiais recirculados. Como os altos-fornos são equipamentos que determinam processos complexos, com um volume muito grande de variáveis e equipamentos para controle, as equipes de manutenção e os especialistas nesta área são os responsáveis pelo ajuste e controle destas variáveis. E apesar das limitações e dos erros produzidos pelos equipamentos, o grande problema de produção do gusa atual é o pouco conhecimento sobre a influência das propriedades metalúrgicas e químicas das matérias primas. Com relação às matérias primas, no caso específico de indústrias brasileiras, as que “escondem” a maior quantidade de informações são as portadoras de ferro, tais como minério de ferro granulado e sinter. Este motivo pode ser atribuído a várias causas, tais como a dificuldade de obtenção das informações em laboratórios, através de ensaios caros e demorados, da falta de ferramenta necessária para a inferência destas mesmas variáveis a partir de outras de fácil obtenção e a da própria cultura da siderurgia brasileira, que antes das privatizações, possuíam o papel de suprir as necessidades brasileiras e não de competir entre si, como é o caso atual. Por último, os níveis de sofisticação das empresas em equipamentos variam de acordo com a estratégia empresarial, o que determina direta influência em como desenvolver e atuar nos processos.

2.1.1 O SÍNTER PARA ALTOS-FORNOS

O alto-forno (foto real no Anexo A) é um equipamento de grandes dimensões e envolve um conjunto complexo de fenômenos, que interagem em determinadas regiões e influenciam outros fenômenos. Do topo para o fundo, o alto-forno pode ser dividido em três zonas principais, com características diferentes.

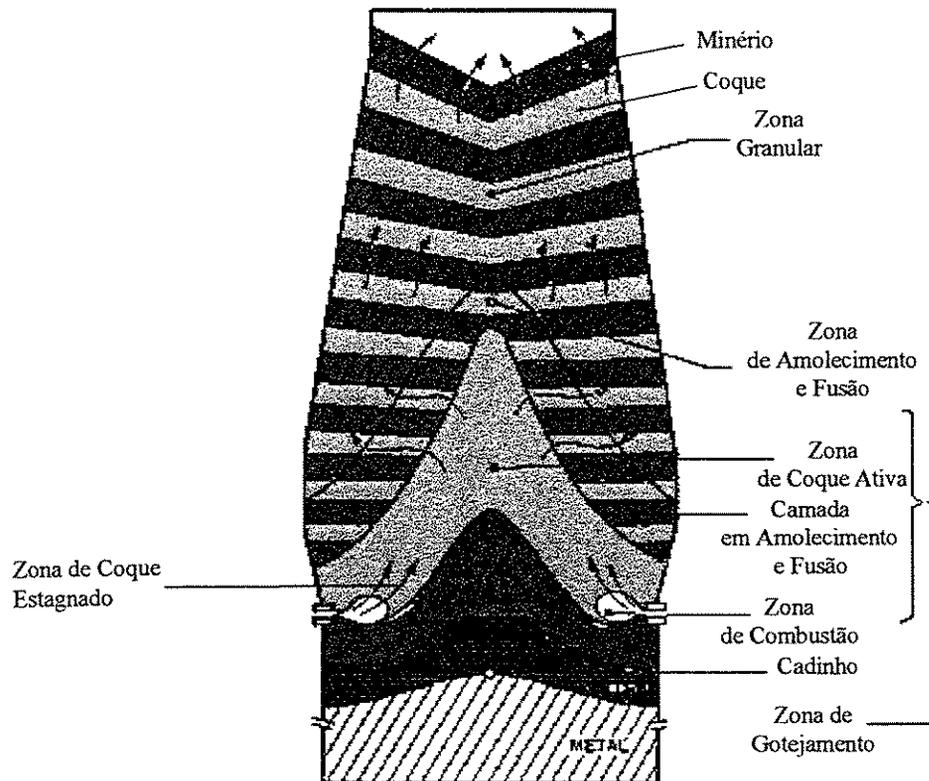


Figura 2.1 - O alto-forno.

Correias transportam as matérias primas (coque, sinter, calcário etc) até o topo do alto-forno e formam a **zona granular**, pela atuação de um sistema de distribuição de carga. A carga que entra no alto-forno da CSN e compõe a zona granular é a seguinte: coque metalúrgico e frações menores de coque (*small coke*), que possuem alto teor de carbono e hidrogênio e teores menores de enxofre e cinzas (sílica, alumina, cal etc.); o sinter (aglomerado de finos de minério e de fundentes) e o minério granulado, ricos em ferro e com impurezas contendo fósforo, zinco, alumina, sílica, cálcia, magnésia, enxofre etc; e os

fundentes, tais como calcário, dolomito, cascalho e quartizito. De todas estas matérias primas a que contribui em maior quantidade para a produção do gusa é o sinter, com cerca de 1,2 tonelada para cada tonelada de gusa produzido. Em seguida vem o minério de ferro (400 kg por tonelada de gusa) e o coque, com cerca de 350 kg por tonelada de gusa. Uma outra importante matéria utilizada por outras empresas é a pelota, composta de finos de minério de ferro e fundentes. Este produto da pelotização possui características interessantes, como baixo volume de escória, alta redutibilidade e baixo RDI, entretanto de custo mais alto que o sinter.

O efeito da temperatura e dos gases (que sobem em contracorrente com a carga sólida que desce), após um determinado tempo de residência, transforma o minério e o sinter num material em processo de amolecimento e o coque permanece sólido, formando a chamada **zona de amolecimento e fusão**, que é caracterizada por um elevado gradiente térmico e uma elevada perda de pressão. O início desta zona forma o processo de amolecimento e o final o processo de fusão.

Logo após a zona de amolecimento e fusão surge a **zona de gotejamento**, formada:

- i. Pela zona de coque ativa, onde ocorre a interação entre o coque em processo de queima (queimado na zona de combustão pela injeção de oxigênio) e entre o ferro gusa (no estado líquido). Os gases gerados pela combustão do coque (grande geração de CO na queima de coque e carvão) e o efeito da temperatura reduzem o óxido de ferro do minério para ferro metálico (Fe_2O_3 para Fe_3O_4 para FeO e para Fe^0), gerando o gotejamento do ferro gusa e um “novo” sistema de contracorrente, onde o gás sobe e o metal líquido desce. A injeção de carvão pulverizado ocorre também na zona de combustão. Nesta zona começa a incorporação do enxofre e do silício no gusa;
- ii. Forma-se no próximo estágio, a zona de coque estagnado já sem a presença de gás de combustão. A região é caracterizada pela presença de coque e ferro líquido e é chamada de “homem morto”;

iii. Após passarem pela zona de coque estagnado, a última fase sólida, os materiais fundidos se separam por diferença de densidade no fundo do alto-forno (no cadinho). Neste recipiente, a fase menos densa é chamada de escória e é rica nas impurezas das matérias primas. A fase mais densa é rica em ferro gusa.

A escória, rica em CaO, SiO₂, MgO, MnO e Al₂O₃, possui característica básica e condições favoráveis à retirada do enxofre impregnado no ferro gusa. Para que esta condição seja aproveitada, há a necessidade também de se ter uma atmosfera redutora no metal líquido. Esta reação ocorre durante a passagem do ferro, em processo de gotejamento, pelo volume de escória, através das reações de interface metal/escória e, em menor escala, pelas reações metal/sulfeto.

A escória e a fase mais densa, o gusa, são então vazados pelos furos dos altos-fornos e transportados através de canais de corrida, construídos com revestimento refratário. A separação é feita por um desnível no canal de corrida, onde a escória, menos densa, é desviada para um poço onde é granulada com água a alta pressão e o gusa é vazado para carros torpedos com cerca de 250 t. O material passa por processo de dessulfuração e é então transportado até a aciaria, onde é carregado nos conversores.

O processo de sinterização surgiu da necessidade de aproveitamento de finos gerados nas minerações. Estes finos não podem ser consumidos em altos-fornos pois prejudicam a permeabilidade da carga destes reatores, que exigem granulometria grossa o suficiente para seu perfeito funcionamento (maior que 6,35 mm), considerando a condição de permeabilidade, mas não tão grosso que não possibilite tempo suficiente de reação química de redução (menor que 40 a 50 mm, dependendo do alto-forno). Daí a importância do processo de sinterização, que aglomera estes finos e gera um produto com granulometria adequada, além de permitir a incorporação de importantes componentes químicos em sua formulação, tais como fundentes, manganês, titânio etc.

A produção do sinter é definida pelo seguinte grupo de materiais: os fundentes (calcário, dolomito, serpentinitos, etc), os ligantes (cal e água), os finos de minérios de ferro

(também chamados de “*sinter feed*”), as adições (como os minérios de manganês e de titânio), os combustíveis sólidos (tais como o coque, o carvão vegetal, o coque de petróleo, o antracito, etc) e os resíduos, tais como as lamas grossa e fina de aciaria, a lama e o pó de coletores de altos-fornos e o pó de precipitadores eletrostáticos, além de resíduos gerados por processos de laminação. A definição da proporção de mistura destes materiais é de suma importância para a definição da qualidade do sinter produto.

Os finos de minério de ferro utilizados pela CSN (cerca de 55 a 60% na mistura a sinterizar), oriundos da Mina de Casa de Pedra, situada em Congonhas no Estado de Minas Gerais, apresenta como principais componentes químicos cerca de 63 a 65% de ferro total, 4 a 5,5% de sílica (SiO_2) e cerca de 1% alumina (Al_2O_3), que influenciam diretamente na qualidade do sinter. Algumas impurezas importantes, como o fósforo, influem de forma negativa na qualidade do gusa e outras como ZnO , Na_2O e K_2O , influem na formação de incrustações nas paredes refratárias dos altos-fornos, gerando sérios problemas operacionais.

Alguns estudos, resumidos em Vieira et al.⁽²⁾, salientam a necessidade de adicionar às informações químicas e granulométricas dos minérios, informações texturais, estruturais e mineralógicas para o verdadeiro domínio do processo de sinterização, uma vez que, segundo os autores, são muito variadas as condições de tectonismo, metamorfismo e intemperismo a que foram submetidos os minérios brasileiros ao longo do tempo, gerando variações na qualidade intrínseca destas matérias primas e, portanto, variações mineralógicas, químicas, estruturais etc. Desta forma, é de suma importância conhecer as informações relevantes e criar um mecanismo de monitoramento das informações levantadas.

Este trabalho faz ainda algumas considerações importantes e esclarecedoras. Por exemplo, a granulometria destes finos de minério de ferro é de suma importância para a definição da qualidade do produto final. O minério de ferro possui uma distribuição granulométrica com cerca de 90% abaixo de 6,35mm. A divisão destas partículas em grupos por tamanho, feita por Ishikawa et al.⁽³⁾, define uma forma de controle e formação do

aglomerado a frio e posteriormente a quente. Uma adequada distribuição de partículas entre 1 e 6,35 mm, denominadas nucleantes (que atuarão como núcleo no processo de aglomeração a frio) e entre 0,106 e 0,3 mm, as aderentes (que irão aderir ao núcleo nos processos de mistura e micropelotização com ajuda da cal e da água), além da minimização de partículas acima de 6,35 mm, chamadas aqui de supergrossas, de partículas abaixo de 0,106 mm, chamadas de superfínas e de partículas que não atuam nem como núcleo (pois são finas em relação ao necessário), nem como aderentes (pois são grossas para este fim), ou seja, entre 0,3 e 1 mm, pode ajudar muito a otimização do sistema de produção de sinter.

Outro ponto fundamental citado em Vieira et al.⁽²⁾ para a produção do sinter, é a característica estrutural e de textura das partículas. A partícula que atua como núcleo deve possuir característica granular eqüidimensional, com superfície rugosa e porosa, para facilitar o processo de aderência pelas partículas entre 0,106 e 0,3 mm, que ocorre durante a aglomeração a frio. Uma partícula em formato tabular ou em chapinha em tamanho de núcleo, com superfície lisa e pouco porosa, determina baixo poder de aglomeração, prejudicando em demasia a produção das micropelotas, piorando a permeabilidade da carga e a sinterização. Outras características, como percentagem e tamanho de poros, orientação de cristais de hematita, tipos de partículas mistas e grau de liberação, também devem concluir o estudo de uma forma geral. Estas características definem também as taxas de reações químicas. Uma reação química ocorre preferencialmente nos contornos dos grãos e, portanto, será influenciada pelo tamanho do grão (quanto menor o grão, maior a taxa de reação). Já a porosidade determina uma maior ou menor superfície específica disponível para as reações químicas.

As características mineralógicas definem o mecanismo de reações químicas durante a produção do sinter. Segundo Goldring e Fray⁽⁴⁾, a caracterização de minério de ferro é essencial para a produção de um sinter de boa qualidade e as fases mineralógicas mais importantes do minério de ferro são as hematitas- Fe_2O_3 (especular e compacta), a martita- Fe_2O_3 (oriunda da oxidação da magnetita), a magnetita- Fe_3O_4 , o hidróxido de ferro, goethita- FeOOH e o quartzo- SiO_2 , além das fases presentes em quantidades pequenas, tais como a caolinita- $\text{Al}_4(\text{Si}_4\text{O}_{10})(\text{OH})_8$, a gibsita- $\text{Al}(\text{OH})_3$, a pirita- Fe_2S , a sericita-

$KAl_2(AlSi_3O_{10})(OH)_8$, e variações de óxidos de manganês. Cada fase mineralógica possui características próprias de reatividade, que influenciarão de forma significativa na produção do sinter e em seu comportamento nos altos-fornos. Assim sendo, é importante a empresa ter este conhecimento, independente da nomenclatura utilizada, pois para efeitos de sinterização, o importante é produzir informações referentes às diferentes taxas de reações químicas.

Os fundentes, portadores de CaO e MgO na forma de carbonatos e de silicatos (caso da CSN: calcário + dolomito = cerca de 11% na mistura a sinterizar), devem apresentar granulometria fina para atuação como aderentes, para participar ao máximo das reações de sinterização. O CaO reage com a sílica, formando a escória e com os óxidos de ferro, alumina e sílica, formando os chamados sílico-ferrito de cálcio e alumínio. Estas fases influem diretamente na qualidade do sinter e suas formações durante a sinterização afetam a produtividade. O rendimento de sinter produzido assim como a resistência a frio e a quente são também fortemente influenciadas por estas reações químicas.

O combustível sólido, que participa da mistura a sinterizar em cerca de 3,5 a 4% em peso, é o responsável pela energia necessária para as reações endotérmicas, e deve apresentar o máximo de carbono fixo, mínimo de cinzas e voláteis, além de pouca variação química e granulométrica. Segundo Karabasov et al.⁽⁵⁾, este material deve apresentar um equilíbrio entre a reatividade e a granulometria, para perfeito desencadeamento das reações químicas. A moinha de coque, até então considerada a fonte de combustível que melhor atende a estes pré-requisitos, deve apresentar granulometria variável entre 1 e 3 mm.

Os ligantes, água e cal, possuem funções diferentes; o primeiro, atua através da tensão superficial sobre as partículas finas e mantém as micropelotas na etapa a frio. Após a secagem, a estrutura dos microaglomerados são mantidas pela cimentação da cal. A cal deve ser fina (pulverizada). Como a cal mantém o microaglomerado resistente mesmo a quente, observa-se que quanto maior o seu consumo na micropelotização melhor a permeabilidade que favorece o aumento da produtividade de sinterização e a melhora da resistência a frio do sinter obtido.

O processo de produção de sinter inicia quando matérias primas e insumos são adicionados por silos dotados de balanças dosadoras para formar a mistura a sinterizar (fotos dos equipamentos principais no Anexo A). Estes materiais não devem possuir umidade alta pois do contrário podem entrar no misturador como micropelotas já formadas (micropelotas de aderentes, por exemplo), o que dificulta a homogeneização da mistura e a formação das micropelotas realmente necessárias. Esta mistura é transportada por uma correia e entra num misturador cilíndrico, levemente inclinado, que homogeneiza a mistura da extremidade inicial até ao meio (região esta formada por aletas internas) e daí em diante (região lisa), recebe água até a sua extremidade final e forma as micropelotas.

Após a micropelotização, as micropelotas devem ser acondicionadas na esteira da máquina de sinterização.

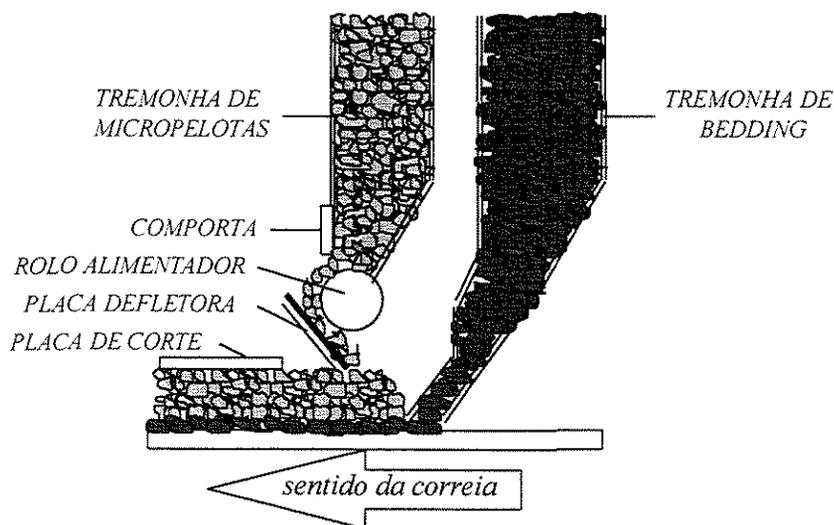


Figura 2.2 - Sistema de acondicionamento de micropelotas na esteira da máquina de sinterização.

Com a ajuda de um sistema formado por uma tremonha de mistura (que recebe as micropelotas do misturador), um rolo alimentador (que retira os microaglomerados da tremonha e controla a vazão pela ajuda de uma comporta e pela velocidade deste rolo), uma placa defletora (que orienta o acondicionamento na esteira através do ângulo e da distância em relação ao rolo alimentador) e de uma placa niveladora (que promove um aperto da

camada de microaglomerados), as micropelotas são transportadas pela esteira até a máquina de sinterização.

Este processamento físico determina a forma de carregamento, a densidade da mistura e a altura da camada que, junto às características dos microaglomerados (que são função das características intrínsecas das matérias primas, da umidade e do regime de mistura) determinam a permeabilidade do leito de sinterização.

Quanto às características intrínsecas das matérias primas, Roller e Firth⁽⁶⁾ estudaram a relação entre a mineralogia, a estrutura (considerando somente a porosidade), a granulometria e a umidade da mistura com relação ao poder de aglomeração e à permeabilidade do leito adquirido. Cinco minérios foram testados: três hematíticos compactos (com diferentes granulometrias), um martítico e outro goethítico. Mantidas a proporção de mistura a sinterizar e as condições de aglomeração, observou-se que o minério martítico, mais poroso e com maior área superficial, necessita de mais água para iniciar a aglomeração, pois antes de iniciar a formação das micropelotas seus poros devem ser preenchidos. Entretanto, após esta etapa, o melhor poder de microaglomeração está associado justamente a este tipo de minério, o que determina também melhor permeabilidade do leito. O segundo melhor comportamento foi observado para o minério goethítico.

Neste trabalho, observou-se também que as partículas superfinais funcionam como auxílio da aglomeração das partículas grosseiras, melhorando a resistência do aglomerado e evitando a perda dos aderentes grossos durante o processo de sucção do ar (o que produziria obstrução do leito, prejudicando a permeabilidade do leito). No caso do minério martítico, este também é um ponto positivo.

Já a densidade de carregamento determina baixa compactação para baixa densidade e alta permeabilidade. Entretanto, o elevado número de vazios determina pouco contato entre os microaglomerados, o que pode ser prejudicial gerando baixo rendimento de produto.

Quanto a calha defletora, esta determina a segregação granulométrica das micropelotas, ou seja, a variação do tamanho dos microaglomerados que cresce de cima para baixo ao longo da camada. Este procedimento gerará maior concentração de partículas grossas e mais densas na base e maior concentração de partículas menores e menos densas no topo, diminuindo o arraste dos finos pelos gases de exaustão, aumentando a permeabilidade do leito já que a parte superior será formada por sinter já produzido com estas partículas finas já aglomeradas e transformadas em partículas grossas e por partículas grossas segregadas na base e deslocando maior quantidade de combustível para o topo da camada, fato este favorável pois a parte superior da camada depende exclusivamente do calor gerado pela combustão, ao contrário da base, que recebe calor pela transferência das camadas superiores e pela combustão, necessitando, teoricamente, de menor quantidade de combustível.

Em relação a altura da camada, um aumento promoverá maior compactação das micropelotas e, por conseqüência, melhor resistência a frio do sinter. Desta forma, ocorrerá uma diminuição da permeabilidade, que por sua vez dificultará a passagem dos gases diminuindo a produtividade. Portanto, deve-se ponderar a relação entre produtividade, qualidade e custo para a definição da altura de camada.

A velocidade de sinterização, definida pela relação entre a altura da camada e o tempo necessário para a frente de combustão atravessar toda a altura da camada (ou para percorrer um comprimento útil da máquina), é considerada o fator mais sensível no sistema de controle da sinterização.

Alterações na permeabilidade da carga afetam diretamente a velocidade de sinterização e, por conseqüência, a velocidade da máquina (relação entre o comprimento útil da máquina e o tempo) e a produção do sinter.

Após a aglomeração a frio da mistura a sinterizar, que forma a zona úmida na máquina de sinterização (Figura 2.3), a produção do sinter passa por várias etapas de processo, que são determinadas pela queima do combustível da superfície do bolo, que

avança para o fundo devido a um sistema de exaustão que succiona os gases e vapores de cima para baixo, promovendo um grande montante de reações químicas.

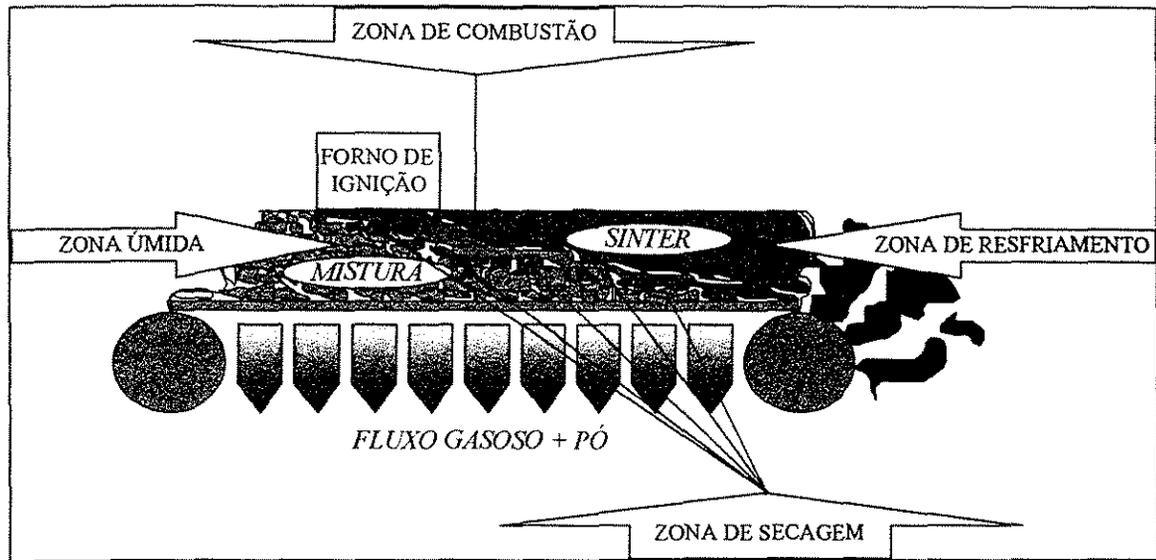


Figura 2.3 - Definição das zonas de produção de sinter.

A permeabilidade do sinter produto é a mais intensa do leito. Na superfície do sinter, entretanto, é comum observar a presença de uma fina camada frágil de sinter. Já a região de menor permeabilidade é a zona de combustão, caracterizada pela fase líquida que envolve as partículas nucleantes (zona similar, no aspecto de menor permeabilidade, à zona de amolecimento e fusão dos altos-fornos). Desta forma, quanto mais larga a zona de combustão, menor a permeabilidade da camada.

Na zona de secagem (entre 100 e 500 °C) ocorre o aquecimento da carga, com vaporização da água (até a temperatura atingir 200 °C) e decomposição de hidróxidos.

Na zona de combustão (ou de sinterização, ou de reação), com ciclo variando temperaturas entre 500 °C até a temperatura máxima de sinterização (cerca de 1250 a 1350 °C) e diminuição até 900 °C, ocorre a queima do combustível, decomposição dos carbonatos, reações no estado sólido ou semilíquido, pela fusão parcial da mistura (deseja-se a fusão dos aderentes e da superfície dos núcleos, para a produção do sinter heterogêneo), formando-se os ferritos de cálcio, os silicatos, redução dos óxidos de ferro.

Após atingir-se a temperatura máxima da formação do magma, inicia-se, sob atmosfera altamente oxidante, a reoxidação parcial da wustita (FeO) e da magnetita (Fe₃O₄), até a temperatura de 900°C.

Após esta temperatura, o que se observa é somente o resfriamento da massa sem reações químicas, formando a zona de resfriamento. A tabela 2.1 ilustra as principais reações químicas.

Em todo este mecanismo de reações endotérmicas, a transferência de calor das camadas superiores para as inferiores (forçadas pela sucção do ar) é determinada pela combustão dos finos de combustível da mistura.

O combustível sólido deve ser controlado para que a propagação da frente de queima (controlada pela reatividade do combustível e pela concentração de oxigênio) coincida com a propagação da frente de calor (controlada pela vazão de ar que atravessa a camada). Dois casos podem gerar um alargamento da zona de combustão, o que prejudicará o rendimento térmico do processo:

- i. Se a reatividade do combustível for muito alta (combustível muito fino), pois ocorrerá mais rápido deslocamento da frente de combustão do que da frente de calor e diminuir-se-á a possibilidade de aglomeração devido ao conseqüente abaixamento da temperatura necessária ao processo de sinterização (ocorrido pela falta do aporte térmico necessário da frente de transferência de calor). Outro problema: haverá prejuízos à permeabilidade da carga;
- ii. Se o combustível apresentar granulometria grossa, menor será a sua reatividade e mais lentamente se deslocará a frente de combustão (além de gerar problemas de segregação e pontos de superaquecimento).

Tabela 2.1 - Mecanismos de reações químicas.

REAÇÕES DURANTE A MICROPELOTIZAÇÃO DA MISTURA - zona úmida	
Hidratação da Cal ($\text{CaO} + \text{H}_2\text{O} = \text{Ca(OH)}_2$)	exotérmica
REAÇÕES DURANTE O AQUECIMENTO DA MISTURA - zona de secagem	
Vaporização da umidade (secagem):	endotérmica
$\text{H}_2\text{O(l)} = \text{H}_2\text{O(v)}$	
Desidratação do hidróxido de cálcio:	endotérmica
$\text{Ca(OH)}_2 = \text{CaO} + \text{H}_2\text{O}$	
Perda de água de cristalização do minério de ferro:	endotérmica
$\text{Fe}_2\text{O}_3 \cdot n\text{H}_2\text{O} = \text{Fe}_2\text{O}_3 + n\text{H}_2\text{O}$	
REAÇÕES DURANTE O AQUECIMENTO DA MISTURA - zona de reação	
Combustão do combustível (coque):	início: 500 a 700 °C (exotérmica - eleva a temperatura local até 1350 °C)
$2\text{C} + \text{O}_2 = 2\text{CO}$ (20%) e $\text{C} + \text{O}_2 = \text{CO}_2$ (80%)	
Decomposição de Calcários ($\text{CaCO}_3 = \text{CaO} + \text{CO}_2$) e Dolomitos ($\text{CaO} \cdot \text{MgO} \cdot \text{CO}_2 = \text{CaO} + \text{MgO} + \text{CO}_2$)	endotérmicas - início: 600 °C (mais intensa entre 870 e 900 °C)
REAÇÕES DURANTE A SINTERIZAÇÃO DA MISTURA - zona de reação	
$\text{CaO} + \text{Fe}_2\text{O}_3 = \text{CaO} \cdot \text{Fe}_2\text{O}_3$	500~700 °C
$\text{CaCO}_3 + \text{Fe}_2\text{O}_3 = \text{CaO} \cdot \text{Fe}_2\text{O}_3 + \text{CO}_2$	500~700 °C
$2\text{CaO} + \text{SiO}_2 = 2\text{CaO} \cdot \text{SiO}_2$	500~700 °C
$\text{CaO} + \text{Al}_2\text{O}_3 \cdot \text{SiO}_2 = \text{Ca} \cdot \text{SiO}_3 + \text{Al}_2\text{O}_3$	530 °C
$\text{CaO} + \text{MgCO}_3 = \text{CaCO}_3 + \text{MgO}$	560 °C
$\text{CaO} + \text{MgSiO}_3 = \text{CaSiO}_3 + \text{MgO}$	560 °C
$\text{CaO} + \text{MnSiO}_3 = \text{CaSiO}_3 + \text{MnO}$	565 °C
$\text{MgO} + \text{Fe}_2\text{O}_3 = \text{MgO} \cdot \text{Fe}_2\text{O}_3$	600 °C
$2\text{MgO} + \text{SiO}_2 = 2\text{MgO} \cdot \text{SiO}_2$	680 °C
$\text{MgO} + \text{FeO} = \text{MgO} \cdot \text{FeO}$	700 °C
$\text{Fe}_3\text{O}_4 + \text{SiO}_2 = 2\text{FeO} \cdot \text{SiO}_2$	900~1057 °C
$\text{MgO} + \text{Al}_2\text{O}_3 = \text{MgO} \cdot \text{Al}_2\text{O}_3$	920~1000 °C
$\text{FeO} + \text{Al}_2\text{O}_3 = \text{FeO} \cdot \text{Al}_2\text{O}_3$	1100 °C
REAÇÕES DURANTE O RESFRIAMENTO E RECRISTALIZAÇÃO - zona de reação	
$2\text{Fe}_3\text{O}_4 + 1/2\text{O}_2 = 3\text{Fe}_2\text{O}_3$	
$2\text{FeO} + 1/2\text{O}_2 = \text{Fe}_2\text{O}_3$	

Se houver superposição das duas frentes com altas velocidades de propagação (o que ocorrerá com um combustível muito reativo e alta permeabilidade da mistura), não haverá tempo suficiente para ocorrerem as reações de sinterização, o que diminuirá o rendimento de produto (haverá estreitamento da zona de combustão).

Quanto a quantidade adicionada de combustível, um grande aporte deste insumo poderá espalhar a escória pelo aglomerado e diminuir a permeabilidade, podendo-se com isso interromper o fluxo gasoso e a sinterização e uma pequena quantidade pode não permitir atingir-se a temperatura necessária de sinterização.

O balanço térmico do processo de sinterização envolve o calor sensível introduzido pelo gás de ignição e pelo calor de combustão (representam aproximadamente 6,5% do total), a quantidade de calor oriunda da mistura, que equivale a 13,5% do total e a quantidade de calor introduzida pela queima do carvão ou coque (75% da transformação de coque em CO e 5% da queima em CO₂). As necessidades se distribuem na quantidade de calor para a aglomeração (cerca de 17%), na quantidade para os finos de retorno (4%), na quantidade necessária à evaporação da água (18%), na necessária à dissociação dos hidratos e carbonatos (11%), nas perdas pelos gases de exaustão (pouco mais de 45%) e em outras perdas (cerca de 4%).

No complexo sistema de reações químicas sólido-sólido do processo de sinterização (sem controle e sem previsão, devido a condições locais ou pontuais), não existe mobilidade dos reagentes e, desta forma, cada partícula só pode reagir no estado sólido com aquelas com as quais se está em contato direto. Há formação de várias fases inorgânicas, cada qual com sua particularidade de obtenção e atribuição de qualidade ao sinter. As reações no estado sólido ocorrem por difusão devido ao contato e não por combinação (comum entre líquidos e gases).

Devido ao fato dos minérios de ferro possuírem ganga ácida (com mais SiO_2 do que Al_2O_3) e dos sínteres serem básicos, sob a ótica da frequência de contatos entre os reagentes, as reações mais favorecidas são as seguintes:

- i. Óxidos de Ferro com CaO , formando-se as cálcio-ferritas, antes mesmo da combustão do coque, ou seja, sob atmosfera ainda oxidante, a partir de 500 a 700 °C, formando $2\text{CaO}\cdot\text{Fe}_2\text{O}_3$, logo após $\text{CaO}\cdot\text{Fe}_2\text{O}_3$ e por fim $\text{CaO}\cdot 2\text{Fe}_2\text{O}_3$. Entre 1250 e 1350 °C, forma-se a sílico-ferrito de cálcio e alumínio acicular (que possui formato de inúmeras agulhas entrelaçadas, com microporos e são mais ricas em cálcio e pobres em alumínio) e acima de 1350 °C forma-se a sílico-ferrito de cálcio e alumínio colunar (que apresenta formas grossas alongadas e apresentam estruturas ricas em alumínio e pobres em cálcio). Sob atmosfera redutora, o CaO estabiliza o Fe_2O_3 , dificultando a formação da fayalita. Estas são as fases mais conhecidas. Porém, já existem estudos diferenciando estas fases, de acordo com o interesse da empresa e ganhos projetados com este conhecimento mais aprofundado;
- ii. Óxidos de Ferro com SiO_2 , formando-se as fayalitas (favorecidas pela introdução da sílica do próprio minério). Ocorrem a temperaturas em torno de 1000 °C e sob atmosfera redutora, através da redução da hematita);
- iii. CaO com SiO_2 , formando-se os silicatos somente em fase líquida com afinidade elevada e grande velocidade (não formam quase nada por contato, devido a falta de contato entre eles).

Na zona de combustão, onde são atingidas as maiores temperaturas e a mistura entra num estado de semifusão, as condições de redução são muito favoráveis. Forma-se uma grande quantidade de magnetita e wustita, que devido às suas maiores quantidades que a sílica, CaO , MgO e alumina, ficam sem reagir. Ultrapassada a zona de combustão, o aquecimento se transforma em resfriamento e o gás pouco redutor se transforma em pouco oxidante. Assim a hematita se torna o único óxido de ferro estável a baixas temperaturas e em ambientes oxidantes.

Após o processo de sinterização e de resfriamento, o sínter passa por um processamento de britagem a quente, peneiramento a quente, resfriamento, peneiramento a frio e britagem a frio, para atingir a granulometria adequada para o consumo em altos-fornos (entre 5 e 50 mm). Os finos gerados do peneiramento a quente e a frio e os finos arrastados pelo sistema de exaustão retornam ao processo de sinterização num total em torno de 25 % da mistura a sinterizar.

Ao ser produzido, o sínter assume uma microestrutura que definirá suas características intrínsecas, que determinarão seu rendimento de produto no peneiramento (após britagem), a quente e a frio, sua resistência a frio, sua resistência à degradação sob a atmosfera redutora dos altos-fornos e sua capacidade de redutibilidade.

A estrutura mineralógica do sínter, definida pelas características das matérias primas (granulo-química, mineralógica, textural e estrutural) e pelas condições operacionais de microaglomeração e de sinterização, determina o comportamento deste produto nas solicitações a ele impostas pelo sistema de transporte até os altos-fornos e no processo de redução destes reatores. Portanto, o simples controle granulo-químico do sínter apenas indica um caminho do que irá acontecer (é um processo de inferência), dando informações precisas para a formação química do gusa e da escória, mas não explica o real comportamento durante o transporte e durante a redução em altos-fornos. Por exemplo, um sínter com a mesma quantidade de CaO, Fe₂O₃ e Al₂O₃, pode possuir diferentes quantidades de cálcio-ferritas colunar ou acicular (que são produzidos em função da temperatura do processo), sendo a segunda fase mais interessante para determinar melhor redutibilidade ao sínter e, desta forma, impactar num menor consumo de coque nos altos-fornos.

Segundo Toda et al.⁽⁷⁾, as principais fases mineralógicas do sínter são:

- i. Hematita (Fe₂O₃) - esta fase é formada por partículas que não reagiram no processo de sinterização, ou seja, as que atuaram como núcleo ou por partículas que reagiram, chamadas de hematitas secundárias, e que foram recristalizadas a partir da fase líquida ou ainda formada pela oxidação da magnetita durante o processo de resfriamento;

- ii. Magnetita (Fe_3O_4) - Formada pela redução da hematita ou pela recristalização da fase líquida. Podem ser envolvidas por sílico-ferrito de cálcio e alumínio;
- iii. SFCA (sílico-ferrito de cálcio e alumínio) - tem composição complexa e variável, podendo ocorrer em formas colunares ou massivas (que envolvem a magnetita) ou em formas aciculares (associadas a silicatos);
- iv. Silicatos de Cálcio - é a escória que, devido ao rápido resfriamento do sinter, não cristaliza totalmente, formando escória vítrea.

As características metalúrgicas avaliadas no sinter produto nas indústrias mundiais são:

- i. O índice de degradação sob redução (RDI), que mede a geração de finos dos sínteres em ambientes redutores (atmosfera formada por CO_2 , CO , N_2 e H_2) durante um intervalo de tempo a $500\text{ }^\circ\text{C}$;
- ii. A redutibilidade (RI), que é a capacidade de redução do sinter pela perda de oxigênio sob atmosfera redutora a $900\text{ }^\circ\text{C}$;
- iii. O *Tumbler Test*, que mede a resistência ao tamboramento;
- iv. O *Shatter Test*, que mede a resistência à queda;
- v. O rendimento de sinter produto (retido em peneira de $6,35\text{ mm}$) em relação ao sinter bruto;
- vi. O peneiramento, que indica a geração de finos e o tamanho médio do produto que será consumido pelos altos-fornos.

Destas características metalúrgicas citadas, todos os ensaios, exceto RDI e RI, são fáceis de serem realizados e atribuem baixo custo ao produto final sendo, assim, ensaios adotados ou não pelas indústrias de acordo com a necessidade de avaliação escolhida pela empresa. Já os ensaios de RDI e RI são demasiadamente caros e, principalmente o RI, de longo tempo de duração (cerca de 15 horas de ensaio, considerando em duplicata). Para se ter uma idéia do custo destes ensaios, uma possível implantação destas análises na mesma frequência de análise química do sinter, ou seja, 24 ensaios por dia (a CSN possui três sinterizações que produzem 24 horas) atribuiria um gasto de cerca de US\$ 1,5 milhão/ano.

2.1.1.1 CONSIDERAÇÕES SOBRE MINERALOGIA, RDI E RI DO SÍNTER

O sínter, durante sua permanência nos altos-fornos, produz finos sob a atmosfera redutora ajudada pelos esforços mecânicos, o que produz problemas relacionados à permeabilidade da carga e à distribuição gasosa. Essa degradação pode ser proveniente:

- i. Da degradação oriunda da transformação da estrutura hexagonal da hematita para a estrutura cúbica de faces centradas da magnetita;
- ii. Da degradação devido à impregnação de carbono, por volta de 500 °C;
- iii. E da estrutura mineralógica do sínter, onde cada fase responde positivamente ou negativamente para a degradação sob redução, produzindo diferentes graus de resistência e de propagação de trincas.

Um componente bastante estudado como forte influente na qualidade do sínter é o TiO_2 , principalmente no RDI. Este componente químico é consumido em altos-fornos pela necessidade da formação de uma camada de alta refratariedade nas paredes do cadinho destes reatores para a proteção destas paredes quando estas sofrem desgastes acentuados. Este componente reage, na linha de escória, com CaO e forma titanato de cálcio e nas paredes do cadinho que estão em contato com o gusa, reagem com nitrogênio e carbono, formando carbonitreto de titânio.

O TiO_2 pode ser adicionado na carga do alto-forno de várias formas e uma delas é através de sua incorporação ao sínter. Mas, segundo Bristow e Loo⁽⁸⁾, o óxido de titânio causa sérios problemas à qualidade do sínter, pois ao fundir e se incorporar na escória, difunde-se pela hematita e após a recristalização, forma pontos de tensões na microestrutura do sínter, que por sua vez, atuarão de forma negativa principalmente no que tange ao RDI, pela forte geração de finos. No trabalho realizado pelos autores já citados, encontrou-se, para dois níveis de limonita nos minérios e diferentes teores de areia ilmenítica consumida (menor que 0,3 mm), a mesma direção de comportamento (evidentemente com níveis

diferenciados): acentuada degradação sob redução, baixa perda de rendimento e nenhum problema com produtividade de sínteres produzidos em escala piloto.

Ishikawa et al.⁽⁹⁾, desenvolveram um sínter com alta redutibilidade através da diminuição do consumo de moinha de coque no processo de sinterização (reduzindo o custo do sínter). Por consequência, o aumento da redutibilidade também propiciou ganho em redução de custo nos altos-fornos devido ao menor consumo de “*coke-rate*”. Para atingir estes objetivos sem prejudicar outros itens de qualidade, foi necessário o conhecimento da microestrutura dos minérios e do sínter. Assim, as premissas utilizadas pelos autores para este trabalho foram as seguintes:

- i. Melhora do RI com aumento da quantidade de SFCA (Sílico-ferrito de Cálcio e Alumínio) acicular (não é envolvida com escória e por isto é mais porosa que a SFCA colunar, que é envolvida por escória), aumento da hematita granular de 10 a 100 microns (não fundidas) envolvida em silicato vítreo (melhora o RI pela formação de poros maiores que a SFCA colunar e que a hematita compacta não fusível) e coexistindo com SFCA (caso mais favorável ao alto RI), além de núcleo formado de minério não fundido e poroso;
- ii. Decréscimo de RDI com decréscimo de hematita secundária (romboédrica esquelética), o que é atingido pela diminuição do FeO do sínter em valores abaixo de 9% (acima deste valor, o aumento do FeO é que melhorará o RDI do sínter). O RDI é influenciado também pela resistência a frio do sínter;
- iii. Melhora da resistência a frio devido a diminuição de trincas e da quantidade de poros grandes, o que é conseguido com o aumento da dispersão das hematitas, da magnetita e de SFCA nos silicatos vítreos. Em sínter comercial, o aumento do volume de escória só melhora a resistência a frio do sínter para valores entre 5 e 12 %. Além disto, o aumento da fase SFCA acicular, com poucos e pequenos poros e sem trincas, melhoram muito a resistência a frio.

Segundo os autores, o mecanismo de reações de sinterização pode ser resumido da seguinte forma: o magma é gerado em torno de 1300 °C e consiste basicamente de CaO e Fe₂O₃. Se este material penetra no contorno dos grãos superficiais de hematita nucleante, ocorre fragmentação da superfície e geram-se finos de hematita granular.

Quando o CaO e a Al₂O₃ incorporam o magma e reagem com Fe₂O₃ e SiO₂, ocorre a formação de SFCA acicular como solução sólida. Quando a temperatura ultrapassa 1300 °C, o SFCA acicular dissolve-se e torna-se hematita, magnetita e escória (se a alumina é baixa, a 1250 °C o SFCA pode dissolver). A hematita secundária romboédrica esquelética é formada durante o resfriamento.

Um desejável perfil térmico do processo de fabricação de sinter para atingir bons índices de redutibilidade e de RDI deve seguir a prevenção da formação da magnetita mantendo a temperatura de sinterização no máximo em 1250 °C, assegurando a formação de SFCA acicular e hematita granular. Gera-se um problema: baixa resistência a frio devido à baixa geração de magma, que pode ser solucionado pela concentração de sílica nos aderentes e tempo de sinterização de 3 a 5 minutos com mínimo de 1100 °C.

Em relação ao estudo dos efeitos das propriedades dos minérios e do modelo de aquecimento na formação das fases minerais, Ishikawa et al.⁽⁹⁾ concluíram que a formação de SFCA acicular na camada aderente aumenta com o aumento da basicidade, com a temperatura em torno de 1250 °C e com aumento da relação alumina/sílica. Quanto a assimilação do núcleo pela fase fundida, o SFCA acicular foi formado a 1300 °C e a hematita granular começou a aparecer a 1350 °C com uso de minério de baixa fusibilidade. Com o minério de alta fusibilidade, formou-se microestrutura rica em hematita granular. Quanto a estrutura dos poros, o minério de pouca fusibilidade não tem muitos poros em sua parte assimilada. Já o minério de alta fusibilidade possui um corpo poroso com grandes poros. Assim, é importante evitar a assimilação de núcleos de alta fusibilidade para melhorar a resistência a frio.

Com todas estas informações, os autores decidiram, para o aumento da redutibilidade, obter sinter com minérios não fundidos porosos e com alta quantidade de SFCA acicular e de hematita granular. A atuação foi a seguinte:

- i. Redução do tamanho dos minérios compactos e de baixa fusibilidade;
- ii. Aumento da participação de minério poroso e de alta fusibilidade (altamente assimilativos);
- iii. Diminuição da temperatura de sinterização.

A baixa temperatura de sinterização envolve o problema de baixa resistência. Os autores contornaram este problema pelo aumento do tempo de reação na faixa acima de 1100 °C. Decidiu-se aumentar também a participação do minério de maior fusibilidade no lugar do coque economizado, substituindo o minério pouco fusível com minério de alta fusibilidade. Houve uma diminuição de sílica e alumina. O RDI melhorou devido à diminuição da hematita romboédrica esqueletal. Em termos mineralógicos, houve uma diminuição de magnetita, de silicatos vitrosos e aumento de hematita. Não houve aumento de SFCA, mas aumentou-se o SFCA acicular.

Um recente trabalho publicado por Yang e Davis⁽¹⁰⁾, relatou a experiência obtida através da avaliação do grau de assimilação de minérios nucleantes (hematíticos, pisolíticos e magnetíticos) por aderentes magnetíticos. Sempre correlacionando com a qualidade mineralógica do sinter, as principais conclusões foram as seguintes:

- i. Os minérios pisolíticos (formados de goethita e hematita) são mais fáceis de assimilar os aderentes do que os minérios hematíticos e do que os magnetíticos, já que são mais reativos;
- ii. Os minérios hematíticos geram a maior quantidade de SFCA;
- iii. A substituição de minérios hematíticos por pisolíticos não influi na mineralogia do sinter de forma significativa (considerando todas as fases principais, ou seja, magnetita, hematitas primária e secundária, silicatos e SFCA);

- iv. Os minérios mais porosos e/ou com maior quantidade de ganga são os mais reativos, resultando numa menor quantidade de minério não fundido e mais SFCA ao final da sinterização;
- v. A maior basicidade de mistura produz mais SFCA (favorecendo a reação entre o CaO e o Fe_2O_3);
- vi. O aumento da relação nucleante/aderente proporciona menor quantidade de material não fundido ao final do processo e menor quantidade de SFCA;
- vii. A menor temperatura de sinterização (1250 °C) define as melhores condições para a formação de SFCA e gera menos material fundido ao final do processo de sinterização;
- viii. As características mineralógicas dos minérios de ferro consumidos são influenciadas quantitativamente pelas características da mistura a sinterizar e pelo processo de sinterização. Por exemplo, o aumento da basicidade aumenta a formação de SFCA e diminui a quantidade de minério não fundido ao final do processo de sinterização, tanto para o minério pisolítico quanto para o hematítico. Mas para uma mesma basicidade, o minério pisolítico é sempre mais reativo e gera sempre mais material fundido e menos SFCA que o minério hematítico.

Hida et al.⁽¹¹⁾ estudaram o efeito das propriedades mineralógicas dos minérios de ferro nucleantes na redutibilidade e na produtividade do sinter. Adotando três minérios com diferentes porosidades, mais poroso (mais fusível), porosidade intermediária e menos poroso (menos fusível), os resultados indicaram que:

- i. A redutibilidade aumenta com o aumento da porosidade das partículas nucleantes;
- ii. A redutibilidade aumenta com a diminuição da relação entre nucleante e aderente, pelo aumento de SFCA;
- iii. A produtividade aumenta com a diminuição da fusibilidade do minério.

Hida et al.⁽¹²⁾ investigaram a variação da mineralogia do sinter com a temperatura máxima atingida de sinterização (entre 1250 °C e 1300 °C). Com o aumento da temperatura houve um decréscimo do conteúdo de SFCA e de poros do sinter e em contrapartida

ocorreu um aumento da formação de escória vítrea e de magnetita. Ao avaliarem a redutibilidade do sinter, encontraram que este índice aumentou com o aumento da porosidade e do conteúdo de SFCA do sinter e diminuiu com o aumento da magnetita e da escória vítrea. Desta forma, o aumento da temperatura máxima de sinterização de 1250 para 1300 °C piorou a redutibilidade do sinter.

Okazaki e Hida⁽¹³⁾, constataram que o aumento tanto da basicidade quanto da relação entre calcário e minério de ferro da fração de aderentes da mistura a sinterizar, melhorou sensivelmente o grau de assimilação das partículas nucleantes, sugerindo melhoria da qualidade do sinter com o consumo de material fundente em granulometria mais fina.

Maeda et al.⁽¹⁴⁾, relataram o aumento da redutibilidade com o aumento da basicidade e da porosidade do sinter.

Maeda e Ono⁽¹⁵⁾, buscaram compreender o comportamento na mineralogia do sinter durante a redução deste produto com baixo FeO (cerca de 4%). Encontraram o seguinte:

- i. A hematita foi reduzida mais rapidamente que a magnetita para wustita e posteriormente para ferro metálico;
- ii. A fase SFCA foi reduzida mais facilmente que a wustita para ferro metálico.

Pimenta et al.⁽¹⁶⁾ produziram sínteres piloto com variação da microestrutura através da variação do aporte térmico (variação do consumo de energia) e da variação da basicidade (sem variação do volume de escória dos sínteres). Alterações nos teores de alumina e titânia também foram realizadas. Eles avaliaram a degradação dos produtos durante a redução sob atmosfera redutora a baixas temperaturas. As conclusões dos autores foram as seguintes:

- i. O teor de hematita no sinter diminuiu acentuadamente com a elevação do nível térmico do processo, favorecendo a formação de magnetita e ferritos de cálcio. As hematitas

- primárias passam de residual policristalino, com baixo combustível utilizado, para romboédricas esqueléticas (secundárias) com alta quantidade de combustível consumido;
- ii. A fase matriz (que forma a ligação entre as partículas), nos sínteres de baixa basicidade, é predominantemente formada de silicatos de cálcio vítreo, alterando-se progressivamente para sínteres formados de ferritos de cálcio com a elevação da basicidade;
 - iii. Os ferritos de cálcio acicular fino e acicular comprido foram encontrados em sínteres produzidos com basicidade intermediária e alta e baixos níveis térmicos. Com a elevação do consumo de combustível o maior aporte térmico produz sínteres com maiores quantidades de ferritos dendríticos e colunares;
 - iv. A adição de alumina promove pequeno aumento nos teores de ferritos de cálcio e a adição de titânia promove estabilização da hematita pela difusão do óxido de titânio. O aumento tanto de TiO_2 quanto de Al_2O_3 levou a um aumento considerável do RDI do sínter, função da concentração destes componentes na hematita secundária;
 - v. A desintegração do sínter ocorre devido somente a redução da hematita para a magnetita.

Costa et al.⁽¹⁷⁾ estudaram em escala laboratorial e em planta piloto a formação da escória em camadas aderentes e suas reações com o núcleo de minérios de ferro hematíticos, goethíticos e hematíticos-goethíticos. Os experimentos foram realizados com temperaturas de sinterização de 1250 °C e de 1350 °C. As conclusões dos autores foram as seguintes:

- i. Em todos os casos, a quantidade de hematita primária diminui com o aumento da temperatura. Parte desta fase mineralógica foi transformada em hematita secundária (a 1250 °C) e outra parte em magnetita (a 1350 °C);
- ii. O núcleo do minério hematítico foi menos atacado pela escória. Assim, sínteres produzidos com este minério possuem mais hematitas primárias;
- iii. A fase mineral SFCA foi obtida em maior escala no minério goethítico a 1350 °C (35%), ajudado pela maior quantidade de alumina, pela maior basicidade e pelo maior

volume de escória. Para o minério hematítico, o máximo de SFCA foi de 24%, a 1225 °C. Para o minério hematítico-goethítico, o máximo atingido de SFCA foi de 24% a 1250 °C. O aumento de temperatura transformou SFCA em magnetitas e, em menor escala, em escória vítrea. A grande quantidade de SFCA obtida para minério goethítico foi caracterizada por grande quantidade de SFCA tabular. A SFCA acicular foi maximizada a baixas temperaturas;

- iv. O sínter produzido com minério hematítico necessitou de menos combustível devido a sua natureza compacta e apresentou a maior quantidade de hematita primária (26%). O sínter produzido com minério goethítico apresentou maior quantidade de SFCA e fase vítrea (50% no total). Já o sínter produzido com minério hematítico-goethítico apresentou 34% de magnetita;
- v. Ensaios de tamboramento indicaram os melhores resultados para os sínteres produzidos com minérios hematíticos. O pior resultado foi apresentado pelo sínter feito com minério goethítico (este sínter formou muita escória vítrea e SFCA tabular);
- vi. A principal fonte de fissuras durante a redução do sínter em altos-fornos foi a hematita secundária, que contém poucos poros e mais alumínio que as hematitas primárias. A propagação das fissuras é inversamente proporcional a dureza de cada fase mineral. As fases com menor dureza, ou seja, SFCA massiva e fase vítrea, são as principais responsáveis pela propagação de trincas. Assim, hematita secundária, fase vítrea e SFCA massivo pioram o RDI do sínter. O sínter produzido com minério hematítico apresentou melhor RDI;
- vii. A redutibilidade indica a percentagem de oxigênio removido dos óxidos de ferro durante a exposição do sínter a 900 °C e atmosfera redutora. A melhor redutibilidade do sínter indica menor consumo de coque em altos-fornos, produzindo redução de custos. O sínter feito com material goethítico apresentou a melhor redutibilidade. O pior foi o sínter produzido com material hematítico-goethítico. Estes resultados foram atribuídos à maior porosidade do sínter feito com material goethítico;
- viii. O sínter mais desejado, portanto, deveria possuir o máximo de SFCA acicular e hematitas primárias em sua estrutura, pois esta estrutura produziria melhor resistência a quente e a frio e maior redutibilidade.

Segundo Jeulin⁽¹⁸⁾, a estrutura mineralógica deve ser considerada sob dois pontos de vista: na escala macroscópica, quando deve-se considerar a porosidade do sinter e na escala microscópica, onde se estudam as fases mineralógicas. As fases mineralógicas são analisadas em seções polidas de sinter de acordo com o seu poder reflectivo: a hematita tem alto poder reflectivo, e em seguida, em ordem decrescente de poder de reflectividade, a magnetita, as cálcio ferritas e os silicatos. Esta é a base do desenvolvimento mineralógico em laboratório.

Kama et al.⁽¹⁹⁾ desenvolveram um método de análise mineralógica quantitativa pelo rastreamento do nível de cinza das fases mineralógicas, concordando com Jeulin. O princípio deste método é ainda hoje a base da análise mineralógica de sinter.

Murray⁽²⁰⁾ apresentou, num recente seminário de sinter e pelotas, a produção de sinter com baixa ganga, para aumento da oferta de ferro no sinter. Com nível de sílica mais baixo que o praticado em condições normais pela empresa, foram produzidos sínteres com aumento da basicidade, para manter o rendimento, mesmo com o menor volume de escória. Houve um natural aumento de SFCA e uma diminuição da magnetita no sinter o que proporcionou uma melhoria da resistência a quente do sinter (RDI) e da resistência a frio (medida pelo ensaio de tamboramento).

Ishikawa⁽²¹⁾ estudou os importantes fatores para se trabalhar com sinter de baixo volume de escória e chegou a várias conclusões, dentre elas destacam-se as seguintes:

- i. Reduzir o FeO pela diminuição de combustível e do carregamento de materiais ricos em FeO;
- ii. Trabalhar com fundentes em granulometria fina;
- iii. Aumentar a basicidade do sinter para aumentar as cálcio ferritas;
- iv. Atentar para o teor de MgO do sinter, pois este reage com FeO formando espinélios, melhorando a resistência a frio e a quente, mas diminuindo a redutibilidade;
- v. Buscar baixas temperaturas de sinterização.

Panigrahy et al.⁽²²⁾ estudaram a influência da substituição do CaO por MgO na mistura a sinterizar. Concluíram que esta substituição favorece a formação de espinélios de magnésio, o que determina a melhoria do RDI (pelo decréscimo de hematita) e a piora de RI.

Hsieh et al.⁽²³⁾ investigaram a influência da variação química do sínter e da temperatura de sinterização na composição mineralógica. Observaram que com o aumento da alumina, formou-se mais SFCA e menos hematita secundária. Observou-se um aumento do RDI pelo maior consumo de alumina. Um aumento no teor de MgO do sínter diminuiu a quantidade de SFCA com o uso de dolomito como portador de MgO e aumentou a quantidade de SFCA com o uso de serpentinito. Segundo os autores, foi observado um aumento da quantidade de SFCA pelo aumento da basicidade do sínter, acompanhado de uma diminuição dos silicatos de cálcio e da hematita secundária. Quanto ao aumento da temperatura, foi observado que ocorrem diminuições nos teores de SFCA, na hematita secundária e aumenta-se significativamente o teor de magnetita.

Este relato do que existe de mais importante na literatura, sugere que qualquer modelo que venha a ser criado pelos estudiosos da área de sinterização para a previsão de propriedades metalúrgicas do sínter, considere tanto a composição química, comum nas indústrias siderúrgicas, quanto outras características do sínter, sendo que quanto mais rico for a quantidade de detalhamento incorporada às entradas, mais poderoso será este modelo. Fica claro também que o sínter será sempre produzido em condições de oscilação química, física e mineralógica, o que produzirá também variações das propriedades metalúrgicas deste produto.

2.1.2 O REFINO E OS MODELOS MATEMÁTICOS

2.1.2.1 INTRODUÇÃO

Numa usina siderúrgica, a produção de aço é o resultado do processamento em um reator, chamado de conversor (figura 2.4).

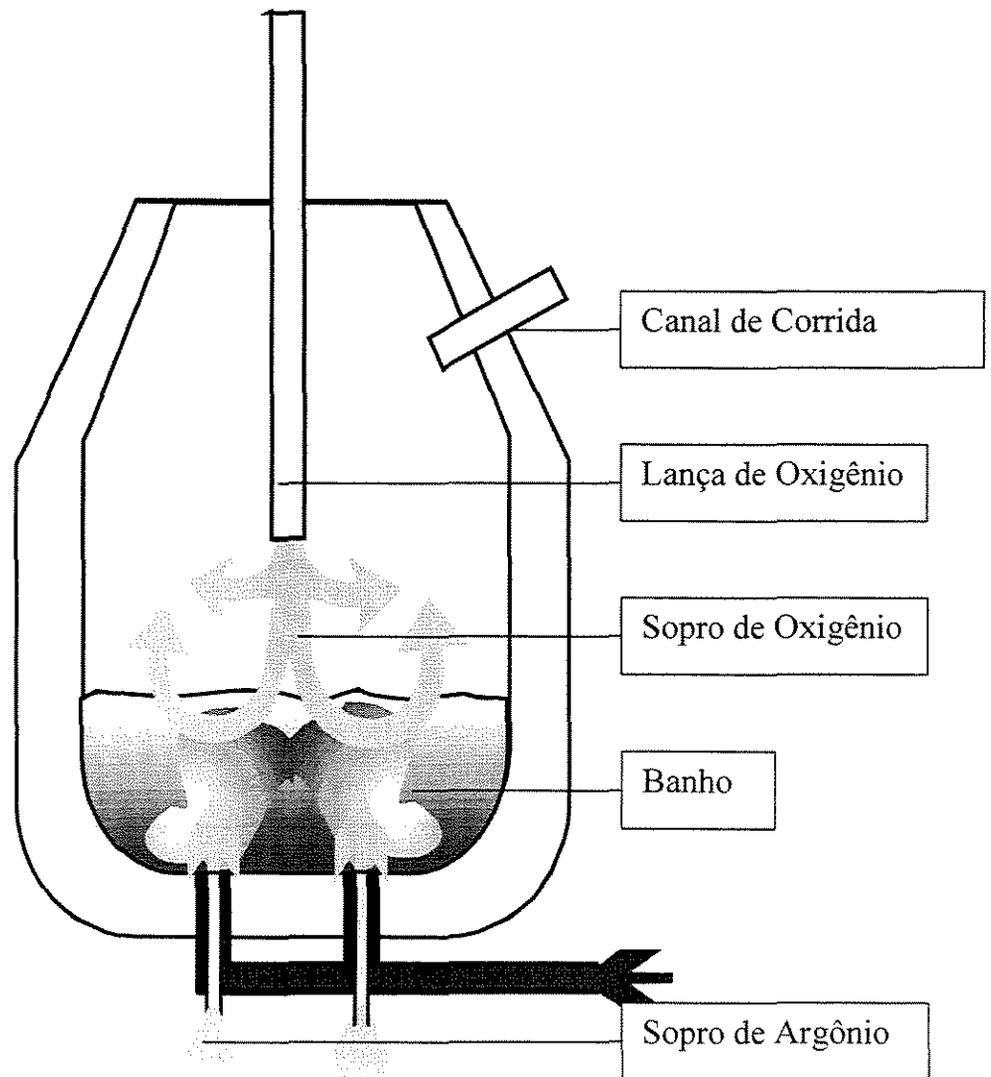


Figura 2.4 - Conversor.

São as seguintes as etapas do processo de refino (observe o Anexo A, para o conhecimento dos equipamentos instalados na CSN):

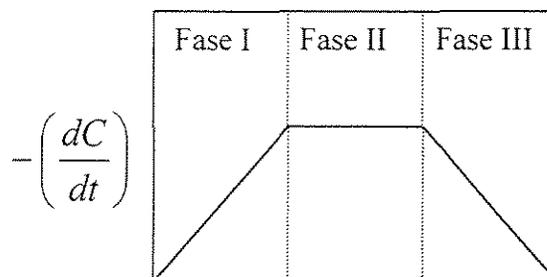
- i. Carregamento das matérias primas: materiais ferrosos reciclados, tais como sucatas de ferro, sucatas mistas (sucatas de ferro sem e com revestimento de zinco e estanho) e sucatas oriundas de escórias de corridas anteriores;
- ii. Carregamento de gusa (ferro líquido produzido em altos-fornos), a principal matéria prima, cerca de 80% em média da carga metálica, que é um ferro líquido com 94,5% de Ferro e 4,3% de carbono. Este produto de altos-fornos possui importantes impurezas, tais como silício, fósforo, manganês e enxofre, que são controlados para a produção do aço;
- iii. Carregamento de fundentes, para ajuste da composição da escória;
- iv. Sopro de oxigênio, realizado no banho através de uma lança, oxidando silício, carbono, manganês e fósforo. Os óxidos de silício, manganês e fósforo, aliados aos óxidos de cálcio e de magnésio oriundos dos fundentes, formam junto ao óxido de ferro, gerado pelo sopro, uma escória altamente básica. A escória tem papel fundamental no processo e sua composição química altamente básica, além de proteger a região refratária dos conversores que tem contato com a sílica e o FeO da escória, funciona estabilizando fósforo e enxofre, evitando que estas impurezas retornem ao aço;
- v. Amostragem do banho e medição de temperatura e de percentual de carbono por inferência da temperatura de solidificação da amostra. Nesta etapa, se a temperatura do banho estiver abaixo do previsto ou o carbono estiver acima do projetado, o modelo dinâmico calcula a quantidade de oxigênio necessária ao ressopro. Mas se a temperatura estiver acima do previsto pelo modelo estático, o modelo dinâmico indica quanto de minério será necessário para o resfriamento para atingir a temperatura desejada;
- vi. Vazamento do aço para processamentos posteriores;
- vii. Vazamento da escória. Esta escória é beneficiada por terceiros, dentro das próprias instalações da CSN, e retorna como sucatas A e B (ricas em ferro metálico).

Para determinação das matérias primas, dos insumos e das condições de operação, são utilizados três tipos de modelo: modelo manual, baseado no ajuste do operador e dois modelos matemáticos: o modelo estático e o modelo dinâmico. O modelo estático é o modelo inicial utilizado para a definição de todos os aditivos, materiais a serem reciclados, sucatas e gusa e da quantidade de minério e de oxigênio necessário ao processo para a composição química e temperatura desejada. Este modelo é baseado em conhecimentos de balanço de massa e de energia, de termodinâmica e de estatística. Já o modelo dinâmico funciona como ajustes finais para a obtenção das características desejadas, onde a coleta de amostras quase ao final do sopro indica qual o nível de carbono (CIB) e de temperatura (TIB) naquele momento. Com o modelo baseado em equações diferenciais de variação da composição química e da temperatura ao longo do tempo, além do conhecimento já mencionado para o modelo estático, calculam-se as necessidades de materiais refrigerantes ou exotérmicos e de oxigênio necessário ao atendimento das características do aço.

2.1.2.2 MECANISMO DE DESCARBURAÇÃO

A descarburização é a principal reação química existente na produção do aço e ocorre através das reações entre o carbono e o oxigênio, ambos dissolvidos no banho e entre o carbono do banho e o FeO, formando em ambas as reações o componente monóxido de carbono. Para que estas reações ocorram é necessário que haja pontos para a nucleação das bolhas de CO a serem formadas. Isto ocorre na superfície dos refratários, nas partículas em suspensão (escória) ou nas superfícies de bolhas formadas em decorrência da emulsão metal-gás-escória, que é função direta da injeção de oxigênio.

O mecanismo de descarburização divide-se em três fases:



A primeira fase é caracterizada pela oxidação do silício, do manganês, do fósforo e do ferro, que impedem a total descarburização. Com o passar do tempo, as impurezas vão reduzindo no banho e a taxa de descarburização aumenta pois a vazão de oxigênio fixada para o processamento está mais disponível para a descarburização. O máximo de descarburização é atingido na fase 2, onde preferencialmente reações entre oxigênio e carbono/ferro ocorrem. Esta fase é caracterizada pela constante taxa de descarburização, determinada pela vazão constante de oxigênio. Esta etapa foi comprovada pelos estudos de Ghosh⁽²⁴⁾, que variou o nível da vazão de sopro constante ao longo do refino e obteve vários patamares constantes de descarburização. O carbono crítico é atingido no final da segunda fase e caracteriza o início de um novo fenômeno, que governa a terceira fase: a difusão do carbono no banho até a frente de reação.

A curva de descarburização esquematizada acima pode ser observada nos trabalhos piloto de Li et al.⁽²⁵⁾ e industrial de Kern⁽²⁶⁾.

A elevação de temperatura é característica de todo o refino e no resopro é função da partição do oxigênio entre o carbono e o ferro. Essa partição é fortemente influenciada pela altura da lança, pelo percentual de carbono no banho, entre outros parâmetros. Segundo Nilles e Denis⁽²⁷⁾, com o aumento da altura do lança, ocorre um aumento da combinação do oxigênio com o ferro e de acordo com Kern⁽²⁶⁾, o aumento de temperatura é fortemente influenciado pelo aumento da vazão de oxigênio.

2.1.2.3 O MODELO ESTÁTICO

Todas as matérias primas oscilam quimicamente e termicamente (gusa) e quimicamente e granulometricamente (materiais sólidos). Além disto, limitações de medidas, diferenciação na atuação humana (que varia de influência de acordo com o grau de padronização das operações da empresa), simplificações teóricas dos modelos e procedimentos ainda não equalizados (como tempo entre corridas e de transporte de gusa) limitam muito o acerto na previsão dos modelos estáticos. Estes modelos são baseados em balanços de massa e de energia, além de “melhorias” impostas pela necessidade de se

considerar relações estatísticas e procedimentos operacionais. Entretanto, estas melhorias são normalmente afetadas pelo uso de banco de dados repletos de erros de laboratório, de digitação, de transmissão de dados, entre outros.

As principais variáveis disponíveis na CSN atualmente como forte influentes na previsão da qualidade do aço foram divididas em classes:

1) Influência de equipamento:

1.1- Balança de sucata utilizada para pesagem desta matéria prima (possível influência de erro de medida entre as duas balanças disponíveis);

1.2- Conversor utilizado para produzir o aço (possível erro devido ao fato dos conversores possuírem diferentes perfis de revestimento refratário);

1.3- Estação de dessulfuração de gusa utilizada (por problemas de limitação do conjunto de equipamentos);

1.4- Vida do conversor (por problemas relacionados a variação da capacidade de transferência de calor);

2) Influência de procedimento operacional:

2.1 - Realização ou não de Slag Splash, recobrimento do revestimento refratário com óxidos de cálcio e magnésio antes da corrida (que influi no tempo de conversor parado);

2.2 - Realização ou não de escumagem de escória (que influi na composição química da emulsão);

2.3 - Tempo de transporte do gusa entre a estação de dessulfuração e o conversor (que influi nas perdas térmicas relacionadas à temperatura interna do conversor para recebimento do gusa e nas perdas térmicas do gusa);

2.4 - Tempo de conversor parado e vazio, entre as corridas (que influi nas perdas térmicas relacionadas à temperatura interna do conversor);

3) Influência das matérias primas e insumos:

- 3.1 - Peso de FeSi;
- 3.2 - Peso de Cal Calcítica;
- 3.3 - Peso de Cal Dolomítica;
- 3.4 - Peso de Dolomito Crua;
- 3.5 - Peso de Sucata A;
- 3.6 - Peso de Sucata B;
- 3.7 - Peso de Sucata Mista;
- 3.8 - Peso de Sucata de Ferro;
- 3.9 - Peso de Minério de Ferro;
- 3.10 - Peso de Gusa;
- 3.11 - Temperatura de Gusa;
- 3.12 - Silício do Gusa;
- 3.13 - Enxofre do Gusa;
- 3.14 - Manganês do Gusa;
- 3.15 - Fósforo do Gusa;
- 3.16 - Volume de Oxigênio Consumido.

2.1.2.3.1 O BALANÇO DE MASSA

O balanço de massa conta com as seguintes entradas:

- i. Temperatura e composição química do gusa;
- ii. Composição química da cal calcítica, da cal dolomítica, das sucatas e do minério de ferro;
- iii. Teor de Oxigênio no Sopro;
- iv. Dados Objetivados (de fim de sopro, como carbono, temperatura, oxigênio, distribuição de P, S e Mn entre aço e escória, relação entre FeO e Fe₂O₃ na escória e

basicidade binária (relação entre CaO e SiO₂) e magnésiana (relação entre MgO e SiO₂) da escória;

- v. Dados operacionais, tais como FeO da escória, % Fe transformado em Fe₂O₃ e taxa de combustão do CO em CO₂.

No processo de refino ocorre a fusão das sucatas, cales, dolomito, FeSi, quartzito e outros aditivos pela troca de calor com o gusa líquido. Com o sopro de oxigênio, ocorrem reações de oxidação de Si, P, Mn e Fe do banho, gerando mais calor, o que ajuda a fundir parte da carga ainda em estado sólido. O minério de ferro só é usado no fim do sopro se houver a necessidade de refrigerar o banho. Neste caso ocorrem reações de redução de parte do óxido de ferro do minério, que passa pelo processo de fusão e redução. Já os óxidos que entram no sistema, via sucatas A e B (oriundas do beneficiamento da escória das corridas anteriores), via minério de ferro, via cales ou via dolomito e quartzito, passam pelo processo de aquecimento e fusão e incorporam a escória, formando compostos complexos.

No balanço para os fluxantes, o percentual de CaO e de MgO disponível para fins de ajuste da escória são os que não são necessários para o ajuste do desejado na escória em função da sílica do próprio fundente. Assim:

$$\%CaO \text{ disponível na cal calcítica} = (\%CaO)_{cal} - BB.(\%SiO_2)_{cal} \text{ calcítica} \dots\dots\dots 2.1$$

$$\%MgO \text{ disponível na cal calcítica} = (\%CaO)_{cal} - BM.(\%SiO_2)_{cal} \text{ calcítica} \dots\dots\dots 2.2$$

$$\%CaO \text{ disponível na cal dolomítica} = (\%CaO)_{cal} - BB.(\%SiO_2)_{cal} \text{ dolomítica} \dots\dots\dots 2.3$$

$$\%MgO \text{ disponível na cal dolomítica} = (\%CaO)_{cal} - BM.(\%SiO_2)_{cal} \text{ dolomítica} \dots\dots\dots 2.4$$

Onde BB é a basicidade binária e BM, a basicidade magnésiana.

A quantidade de SiO₂ a ser neutralizada pelos fundentes e a quantidade de cales necessária são calculadas com base na oxidação do Si do gusa: $Si + O_2 \rightarrow SiO_2$:

$$m_{(CaO_nec)} = m_{(SiO2_cales)} \cdot BB \dots\dots\dots 2.5$$

$$m_{(MgO_nec)} = m_{(SiO2_cales)} \cdot BM \dots\dots\dots 2.6$$

Sendo $m_{(X_nec)}$, a massa necessária do componente X para atingir as basicidades binária e magnésiana em função da oxidação do silício do banho e $m_{(X_cales)}$, a massa do componente X nas cales. Assim, a quantidade de CaO e MgO necessária ao sopro (indicada por $m_{(X_sopro)}$, pode ser obtida pela massa de cal calcítica disponível ($m_{(cal_calc_disponível)}$) e pela massa de cal dolomítica disponível ($m_{(cal_dolo_disponível)}$):

$$m_{(CaO_sopro)} = m_{(cal_calc_)} \cdot (\%CaO_{(cal_calc_disponível)}) + m_{(cal_dolo_)} \cdot (\%CaO_{(cal_dolo_disponível)}) \dots\dots\dots 2.7$$

$$m_{(MgO_sopro)} = m_{(cal_calc_)} \cdot (\%MgO_{(cal_calc_disponível)}) + m_{(cal_dolo_)} \cdot (\%MgO_{(cal_dolo_disponível)}) \dots\dots\dots 2.8$$

Com as duas últimas equações (2.7 e 2.8) calcula-se a quantidade de cal calcítica e dolomítica necessária ao sopro.

O balanço de óxidos da escória de refino é o seguinte (sendo $m_{(X_escória)}$, a massa gerada do componente X na escória, sendo $m_{(X_cal_calc)}$, a massa do componente X na cal calcítica, $m_{(X_cal_dolo)}$, a massa do componente X na cal dolomítica, $m_{(X_gusa)}$, a massa do componente X oriundo da oxidação do gusa, $m_{(X_sucatas)}$, a massa do componente X oriundo das sucatas como óxidos ou por oxidação e $m_{(X_minério)}$, a massa do componente X no minério de ferro):

$$m_{(SiO2_escória)} = m_{(SiO2_cal_calc_)} + m_{(SiO2_cal_dolo_)} + m_{(SiO2_gusa)} + m_{(SiO2_sucatas)} + m_{(SiO2_minério)} \dots\dots\dots 2.9$$

$$m_{(CaO_escória)} = m_{(CaO_cal_calc_)} + m_{(CaO_cal_dolo_)} + m_{(CaO_sucatas)} + m_{(CaO_minério)} \dots\dots\dots 2.10$$

$$m_{(MgO_escória)} = m_{(MgO_cal_calc_)} + m_{(MgO_cal_dolo_)} + m_{(MgO_sucatas)} + m_{(MgO_minério)} \dots\dots\dots 2.11$$

$$m_{(Al_2O_3_escória)} = m_{(Al_2O_3_cal_calc.)} + m_{(Al_2O_3_cal_dolo.)} + m_{(Al_2O_3_sucatas)} + m_{(Al_2O_3_minério)} \dots\dots\dots 2.12$$

A quantidade de Mn do gusa e da sucata oxidada pelo sopro ($m_{(Mn_gusa\ ou\ sucata)}$) são determinadas pela partição (ajuste experimental) entre a escória e o metal ($y_X(escória/metal)$, que indica a taxa de incorporação do elemento X no metal ou na escória) , com base na reação: $Mn + \frac{1}{2} O_2 \rightarrow MnO$.

$$m_{(MnO_escória)} = m_{(MnO_oxidação_Mn_gusa)} \cdot y_{Mn(escória/metal)} + m_{(MnO_oxidação_Mn_sucatas)} \cdot y_{Mn(escória/metal)} + m_{(MnO_minério)} + m_{(MnO_sucatas)} \dots\dots\dots 2.13$$

Também a quantidade de P do gusa e da sucata oxidada pelo sopro ($m_{(X_gusa\ ou\ sucata)}$) são função da partição entre a escória e o metal: $2P + \frac{5}{2} O_2 \rightarrow P_2O_5$:

$$m_{(P_2O_5_escória)} = m_{(P_2O_5_oxidação_P_gusa)} \cdot y_{P(escória/metal)} + m_{(P_2O_5_oxidação_P_sucatas)} \cdot y_{P(escória/metal)} + m_{(P_2O_5_minério)} + m_{(P_2O_5_sucatas)} \dots\dots\dots 2.14$$

Já a quantidade de sulfeto de cálcio ($m_{(CaS_escória)}$) formada é função da reação: $2CaO + S_2 \rightarrow 2CaS + O_2$

$$m_{(CaS_escória)} = (m_{(S_gusa)} - m_{(S_aço)}) \cdot mol_{(CaS)} / mol_{(S)} + (m_{(S_sucatas)} - m_{(S_aço)}) \cdot mol_{(CaS)} / mol_{(S)} + m_{(S_minério)} \cdot mol_{(CaS)} / mol_{(S)} + m_{(CaS_sucatas)} \dots\dots\dots 2.15$$

Desta forma, a massa necessária de CaO ($m_{(CaO_nec_CaS)}$) para escorificar o CaS é a seguinte:

$$m_{(CaO_nec_CaS)} = m_{(CaS)} \cdot mol_{(CaO)} / mol_{(CaS)} \dots\dots\dots 2.16$$

E a massa de CaO na escória é descontada da massa que produz o CaS.

As massas $m_{(FeO)}$ e $m_{(Fe_2O_3)}$ são dados de entrada pela partição entre eles.

Com todos componentes restantes calculados conforme mostrado, tem-se o FeO e o Fe_2O_3 pela relação entre eles e a equação:

$$100\% - (\%Fe_2O_3 + \%FeO) = \text{somatório dos demais constituintes} \dots\dots\dots 2.17$$

O balanço de ferro para o aço ($m_{(Fe_aço)}$) considera as massas de ferro oriunda do gusa, das sucatas da redução de Fe_2O_3 , do minério de ferro e saída de ferro do sistema, através da formação de fumos e da oxidação do ferro para escória, em FeO e Fe_2O_3 :

$$m_{(Fe_aço)} = m_{(Fe_gusa)} + m_{(Fe_sucatas)} + m_{(Fe_redução_Fe_2O_3_minério)} - m_{(Fe_fumos)} - m_{(Fe_oxidadaFeO_escória)} - m_{(Fe_oxidadaFe_2O_3_escória)} \dots\dots\dots 2.18$$

Para o balanço de Mn, S, O, C e P ($m_{(Mn, S, O, C \text{ ou } P_aço)}$):

$$m_{(Mn_aço)} = m_{(Mn_gusa)} \cdot y_{Mn(metal/escória)} + m_{(Mn_sucatas)} \cdot y_{Mn(metal/escória)} \dots\dots\dots 2.19$$

$$m_{(P_aço)} = m_{(P_gusa)} \cdot y_{P(metal/escória)} + m_{(P_sucatas)} \cdot y_{P(metal/escória)} \dots\dots\dots 2.20$$

$$m_{(S_aço)} = m_{(S_gusa)} \cdot y_{S(metal/escória)} + m_{(S_sucatas)} \cdot y_{S(metal/escória)} \dots\dots\dots 2.21$$

$$m_{(aço_total)} = \frac{(m_{(Fe)} + m_{(Mn)} + m_{(S)} + m_{(P)})}{100\% - \%C_aço - \%O_aço} \dots\dots\dots 2.22$$

$$m_{(C_aço)} = \%C_aço \cdot m_{(aço_total)} \dots\dots\dots 2.23$$

$$m_{(O_aço)} = \%O_aço \cdot m_{(aço_total)} \dots\dots\dots 2.24$$

O cálculo do volume de oxigênio necessário envolve o seguinte:

$$m_{(C_gusa)} = \%C_gusa \cdot 100 \cdot m_{(gusa)} \dots\dots\dots 2.25$$

$$m_{(C_sucatas)} = \%C_sucatas \cdot 100 \cdot m_{(sucatas)} \dots\dots\dots 2.26$$

$$m_{(C_oxidado)} = m_{(C_gusa)} + m_{(C_sucatas)} - m_{(C_aço)} \dots\dots\dots 2.27$$

$$m_{(CO_oxidaçãoCO)} = m_{(C_oxidado)} \cdot (\%C_oxidado_CO) \cdot \frac{mol_CO}{mol_C} \dots\dots\dots 2.28$$

$$m_{(CO2_oxidaçãoCO)} = m_{(C_oxidado)} \cdot (\%C_oxidado_CO2) \cdot \frac{mol_CO2}{mol_C} \dots\dots\dots 2.29$$

$$m_{(CO)} \text{ formada a partir da redução do } Fe_2O_3 \dots\dots\dots 2.30$$

$$m_{(CO2)} \text{ formada pela combustão do CO gerado pela redução do } Fe_2O_3 \dots\dots\dots 2.31$$

$$m_{(O_formaçãoCO)} = m_{(CO_formado)} \cdot \frac{mol_O}{mol_CO} \dots\dots\dots 2.32$$

$$m_{(O_formaçãoCO2)} = m_{(CO2_formado)} \cdot \frac{mol_O}{mol_CO2} \dots\dots\dots 2.33$$

$$m_{(O_formaçãoFeO_escória)} = m_{(FeO_formado)} \cdot \frac{mol_O}{mol_FeO} \dots\dots\dots 2.34$$

$$m_{(O_formaçãoFe2O3_escória)} = m_{(Fe2O3_formado)} \cdot \frac{mol_O}{mol_Fe2O3} \dots\dots\dots 2.35$$

$$m_{(O_formaçãodoFe_2O_3_fumos)} = m_{(Fe_2O_3_formado)} \cdot \frac{mol_O}{mol_Fe_2O_3} \dots\dots\dots 2.36$$

$$m_{(O_formaçãodoMnO_escória)} = m_{(MnO_formado)} \cdot \frac{mol_O}{mol_MnO} \dots\dots\dots 2.37$$

$$m_{(O_formaçãodoP_2O_5_escória)} = m_{(P_2O_5_formado)} \cdot \frac{mol_O}{mol_P_2O_5} \dots\dots\dots 2.38$$

$$m_{(O_formaçãodoSiO_2_escória)} = m_{(SiO_2_formado)} \cdot \frac{mol_O}{mol_SiO_2} \dots\dots\dots 2.39$$

$$m_{(O_corrigirCaOdoCaS_escória)} = m_{(CaS_formado)} \cdot \frac{mol_O}{mol_CaS} \dots\dots\dots 2.40$$

$$m_{(O_total_necessária)} = m_{(O_formaçãodoCO)} + m_{(O_formaçãodoCO_2)} + m_{(O_formaçãodoFeO_escória)} + m_{(O_formaçãodoFe_2O_3_escória)} + m_{(O_formaçãodoMnO)} + m_{(O_formaçãodoP_2O_5_escória)} + m_{(O_formaçãodoSiO_2_escória)} + m_{(O_formaçãodoFe_2O_3_fumos)} - m_{(O_formaçãoc}$$

..... 2.41

Assim, o volume de oxigênio (puro) pode ser obtido pela densidade deste elemento e o volume bruto pela pureza do oxigênio recebido.

O total de gases é obtido pela soma do volume de CO, CO₂, N₂ e perdas ao fogo da cal calcítica e da cal dolomítica.

2.1.2.3.2 O BALANÇO DE ENERGIA

Considerando a primeira lei da termodinâmica, a conservação de energia, o modelo trabalha com o seguinte balanço:

Entrada de Energia no Conversor LD:

(1) Entalpia do Gusa Líquido

Utiliza-se a equação para todos os elementos do gusa, ou seja, Fe, C, Si, Mn, S e P (todas exotérmicas):

$$\Delta H_i = \int_{298}^{T_{gusa}} C_{p_i} . dT + \Delta H_{transf. fase} \dots\dots\dots 2.42$$

(2) Entalpias de Decomposição de C, Si, P, Mn e S do gusa e resfriamento a temperatura ambiente:

2.1 - Decomposição da liga Fe-C, com:

$$\Delta H = -451,3 - 31 (\%C), \text{ kcal/kg de C} \dots\dots\dots 2.43$$

2.2 - Decomposição de Si dissolvido na liga Fe-C, com :

$$\Delta H = 1246,2 - 80(\%C) - 34(\%Si) \dots\dots\dots 2.44$$

2.3 - Como não existem estudos que identifiquem a relação do C com Mn, S e P, considera-se a entalpia de dissolução para soluções diluídas:

P, transformado em $1/2P_2(g)$, com $\Delta H = 942,7 \text{ kcal/kg P}$;

Mn, transformado em Mn líquido, com $\Delta H = 0 \text{ kcal/kg Mn}$;

S, transformado em $1/2S_{2(g)}$, com $\Delta H = 983 \text{ kcal/kg S}$.

(3) Entalpias de reação de oxidação de C, CO, Fe, Si, Mn e P (todas exotérmicas), utilizando o calor de reação:

(4) Entalpias de dissolução dos óxidos na escória: $2CaO.SiO_2$, $2CaO.Fe_2O_3$ e $4CaO.P_2O_5$, além é claro da transformação do CaO em CaS (todas exotérmicas exceto a formação do sulfeto de cálcio).

Saída de Energia no Conversor LD:

(5) Entalpia de formação do aço líquido, pelo aquecimento dos elementos C, Si, P, Mn, S e O e dissolução destes na matriz de ferro líquido, formando o aço;

(6) Entalpia de aço líquido ($\Delta H=A+BT$);

(7) Entalpia da escória líquida: assumindo mesma temperatura do aço no fim da corrida e calculando-se a dissolução de SiO_2 , CaO, MgO, CaS, P_2O_5 , FeO, Fe_2O_3 , MnO e Al_2O_3 na escória.

(8) Perdas térmicas por radiação através da boca dos conversores:

$$Q_r = A (\text{área da boca}) * (t_h (\text{tempo da corrida}) - t_s (\text{tempo de sopra}))^{0,9} \dots\dots\dots 2.45$$

(9) Entalpia dos fumos, dos gases e da decomposição dos carbonatos: como as temperaturas destes compostos não podem ser medidas com a mesma precisão que os líquidos do processo, assume-se o valor médio entre a temperatura do gusa e do aço produzido. As entalpias são calculadas conforme o mesmo procedimento da escória, pela formação destes vapores e gases através dos fumos de Fe_2O_3 , dos gases N_2 , CO, CO_2 e perda ao fogo de CO_2 e pela decomposição dos carbonatos

(10) Perdas de calor por condução através do Refratário

$Q_c = k.th$ 2.46

(11) Disponibilidade térmica dos conversores:

11.1 - Entalpia para aquecimento das sucatas até a temperatura de fim de sopro, ocorrendo transformação de fases dos elementos e componentes químicos e dissolução no banho ($\Delta H = A + BT$);

11.2 - Elementos químicos das sucatas, como o carbono da sucata de ferro que passa por oxidação a CO e este até CO₂ e Si passando para SiO₂, sofrem processo semelhante ao gusa, ou seja oxidação com ΔH vinculado a cada calor de formação e os óxidos oriundos destas sucatas são transformados em escória. Observa-se o rendimento de incorporação do elemento no aço e a formação dos óxidos da escória. Todas as entalpias são somadas;

11.3 - Adição de minério de ferro para resfriamento do banho proporciona reações endotérmicas: o Fe₂O₃ é aquecido até a temperatura do banho, reduzido até FeO por moléculas de Fe e reduzido até Fe líquido pelo carbono, gerando CO a temperatura de gases. Para os outros componentes químicos, tais como SiO₂, Al₂O₃, entre outros, são considerados somente o aquecimento e incorporação na escória.

Os modelos estáticos normalmente são caracterizados por simplificações matemáticas de programação, além da falta de informações importantes, tais como as citadas no trabalho de Barreto⁽²⁸⁾ :

- i. Consideração da composição do gás de saída constante;
- ii. Temperatura do gás sendo uma média entre temperatura do gusa e da escória;
- iii. Perdas na fumaça;
- iv. Não medida da temperatura da escória;
- v. Perdas térmicas;

- vi. Perdas de oxigênio;
- vii. Falta de informação referente à granulometria e análise química de sucatas, fundentes, entre outros;
- viii. Falta de informação referente à quantidade de escória vinda dos altos-fornos;
- ix. Erros de arredondamento, de análises laboratoriais, de digitação, de equipamentos, entre outros.

Estas e outras possíveis limitações tornam pobre a resposta do modelo estático, justificando a necessidade do uso de modelos dinâmicos e/ou modelos alternativos de inteligência artificial.

2.1.2.4 O MODELO DINÂMICO

O modelo dinâmico utiliza os cálculos do modelo estático e, através das indicações de sensores, possibilita ações corretivas durante o sopro. O ponto fundamental neste controle é o acompanhamento da velocidade de descarburização, avaliada através de análise de gases, métodos audiométricos ou utilização de sublanças. Este tipo de controle requer alto investimento e necessita alto grau de padronização da aciaria.

O controle dinâmico pode ser realizado mediante três tipos de sistema:

- i. Método da Sublança, onde o sensor mede a temperatura do banho e, com a temperatura de solidificação do aço, calcula o percentual de C;
- ii. Método da Análise de Gás de Exaustão, onde mede-se a percentagem de monóxido e dióxido de carbono, tendo-se assim a quantidade de carbono removido do aço;
- iii. “*Bomb-Method*”, onde um sensor é inserido dentro do banho para a medida da temperatura e da temperatura de solidificação do aço.

Takemura et al.⁽²⁹⁾ desenvolveram o modelo de controle dinâmico mais conhecido e difundido: o controle com uso de sublança, que se baseia na tese de que o processo de refino é altamente dinâmico e utiliza sensores que informam as condições operacionais

necessárias para alimentar o modelo dinâmico. Segundo os autores, o refino pode ser dividido em duas partes: a descarburização direta e a indireta.

A descarburização direta envolve o refino do banho em direção ao aço através das reações químicas entre o oxigênio e os principais elementos químicos do banho: C, Si e P. Estas reações são controladas pelas condições iniciais e se estas condições podem ser quantificadas, a precisão de previsão do modelo estático é alta. Entretanto, variações provocadas por erros na avaliação das condições iniciais, tais como temperatura e composição química das matérias primas, calor sensível do conversor, propriedades das sucatas, combustão secundária do CO, perda de calor dos conversores e variação do oxigênio dos refrigerantes.

Na segunda parte do processo, chamada de descarburização indireta, ocorrem reações entre o C e o oxigênio e também entre o Fe e o oxigênio, uma vez que outros elementos químicos já se apresentam em teores bastante reduzidos. Neste caso os fatores que influenciam na distribuição do oxigênio entre o Fe e o C são as condições de escorificação, as reações intrínsecas, as condições de agitação e as reações dos fundentes. As dificuldades destas duas etapas abrem espaço para a inclusão de procedimentos operacionais e correlações empíricas que favorecem a melhoria da qualidade do aço.

O modelo matemático para o controle dinâmico considera as condições abaixo:

- i. Taxa de descarburização, que considera o mecanismo de reações de descarburização direta e indireta, já citado.
- ii. Taxa de aumento da temperatura, que considera o balanço de energia no conversor durante o tempo da medida na sublança até o *blow-off*. Um balanço entre o calor de formação da escória, da combustão secundária do gás de exaustão, da reação entre oxigênio e Fe/C, o calor de fusão da escória, o calor dissipado pelo forno, o calor sensível do gás de exaustão e o calor da evaporação do Fe;

- iii. Avaliação dos refrigerantes considera que o calor de resfriamento está calcado no calor de fusão dos óxidos de ferro e no calor de descarburização do banho pelo oxigênio destes óxidos.

O modelo existente na CSN considera as seguintes variáveis operacionais: capacidade dos conversores, altura da lança para resopro, vazão de oxigênio, pressão de oxigênio, inclinação dos furos e pesos da escória. Algumas variáveis são consideradas constante, como a altura da lança e outras são calculadas, como é caso do peso da escória. Assim estas simplificações geram limitações de acerto do modelo dinâmico. Este modelo é baseado no conhecimento das taxas de descarburização e foi ajustado com correlações estatísticas obtidas do trabalho de Neto⁽³⁰⁾. Este modelo dinâmico trouxe melhorias para o sistema de previsão, entretanto, mesmo associado ao modelo estático e às correlações estatísticas, além do conhecimento dos operadores, ainda possui grande espaço para melhoria.

2.1.2.5 O DIRECIONAMENTO DA MODELAGEM MATEMÁTICA

Na busca de se melhorar os resultados, Kanemoto et al.⁽³¹⁾ desenvolveram um sistema de auxílio aos métodos matemáticos convencionais de controle estático e dinâmico: o sistema especialista. Este sistema cria uma base de conhecimento considerando os procedimentos operacionais desenvolvidos pelos operadores treinados no sistema. Este conhecimento é estocado no computador e o raciocínio então é utilizado pelo sistema para a tomada de decisão. Os modelos convencionais calculam o “necessário” para o atendimento das metas e o sistema especialista decide quais as correções devem ser realizadas para o acerto no fim do sopro. De acordo com os autores, este sistema tem a vantagem de adicionar informações onde o modelo atua de forma limitada, por exemplo: o modelo estático, baseado em suposições do balanço de massa e de energia, define as necessidades para se atingir o alvo do fim do sopro. Normalmente, o operador experiente e capacitado a trabalhar nesta área do processo avalia as informações e, às vezes, “corrige” o que foi calculado pelo modelo. O sistema especialista já faz isto automaticamente, e o que é mais

importante, sempre da mesma forma. Assim, não há diferenciação na atuação humana, ou seja, um operador pouco treinado ou pouco experiente não produzirá um resultado pior que outro mais experiente (o que ocorre com frequência sem o sistema especialista). Os resultados, em escala piloto, indicaram resultados melhores para o sistema auxiliado pelo controle por sistema especialista do que para a modelagem convencional.

Em busca de alta produtividade e alta qualidade de aço, um desenvolvimento na indústria da Kashima Steel, apresentado por Tani et al.⁽³²⁾, considerando sistema especialista e modelos estatísticos, tem sido realizado com o intuito de auxiliar o modelo estático no controle do processo desta empresa. E informações do gás de exaustão tem sido utilizadas para o controle dinâmico.

Sistemas de controle remoto e operações automáticas tem sido introduzidos no lugar de operações manuais, que dependem da experiência do operador e de alto grau de padronização. Em particular, o controle da necessidade de sopro através de medidas da sublança durante o refino reduziram o tempo de sopro e de espera entre as corridas, aumentando a produtividade.

No modelo de controle estático, a equação fundamental do balanço de energia tem sido mudada com a base nos conteúdos de carbono para a base do conteúdo de oxigênio. Os autores consideraram que a variação das quantidades de carbono do gusa e do carbono objetivado para o aço tem menor influência na definição da quantidade de oxigênio que as variações de temperatura. Considerou também que a quantidade de fluxantes e de oxigênio destes fluxantes deveriam ser consideradas na equação. Assim, a equação da quantidade de oxigênio necessário passou a considerar a soma da quantidade de oxigênio necessário à descarbonização, termos de ajustes estatísticos oriundos de experimentos operacionais, termo de ajuste baseado em conhecimento do operador (sistema especialista) e termo de ajuste do *feedback* do processo (que considera erros de quantidades de calores calculadas e reais de corridas passadas). A diferença de temperatura entre o fim de sopro e a temperatura do gusa é calculada pela equação que considera ajustes estatísticos de processo, a quantidade de

calor calculada em função do balanço de oxigênio citado, das considerações programadas em sistema especialista e da lógica de retroalimentação com sistema especialista.

Também no modelo de controle dinâmico, que consiste de equações estatísticas, calcula-se a quantidade de refrigerante e de oxigênio necessário ao fim de sopro, em função das informações oriundas da sublança durante o sopro. Este modelo também estima o carbono e a temperatura de fim de sopro em tempo real. As melhorias impostas a este modelo são as mesmas do controle estático e as equações fundamentais são baseadas agora em condições extraídas da sublança e não de matérias primas.

Mas o modelo dinâmico não segue as mudanças das condições operacionais, como a mudança da altura da lança após a medida da sublança. Por este motivo, as informações referentes ao gás de exaustão (medidas por um espectrômetro de massa instalado no topo do sistema de exaustão do gás de combustão) tem sido de grande importância para a melhoria do controle dinâmico em ordem para seguir a condição operacional após a medida da sublança. A eficiência de descarburização é calculada durante o sopro.

Estas melhorias trouxeram um aumento do acerto simultâneo de carbono (com erro permissível de mais ou menos 0,02%) e de temperatura (com erro permissível de mais ou menos 12 °C) de 80% para 91%. Esta melhoria também resultou numa diminuição do tempo de parada entre as corridas.

A Voest-Alpine (VAI), em Linz, Áustria, é uma das mais importantes empresas mundiais e apresentou, em 1993, através dos autores Kostersitz et al.⁽³³⁾, um sistema integrado de automação e controle composto de três níveis: o nível de controle da qualidade e da produção, o nível de computador de processo e o nível de controle de processo. A VAI conseguiu diminuir o tempo entre as corridas otimizando a operação com sublança pela correção do balanço de calor durante o refino, auxiliado pela análise do gás de exaustão. Anunciou-se também uma melhoria do acerto simultâneo, entretanto sem valores.

A NKK (Fukuyama) desenvolveu, através dos autores Inoue et al.⁽³⁴⁾, um sistema de controle baseado em sistema especialista vinculado a modelos matemáticos convencionais, combinado a um alto padrão de sopro. A NKK usa o modelo estático para calcular as quantidades de fluxantes, refrigerantes e oxigênio. Ao modelo estático, adicionaram um modelo de predição de estágios de reações dentro do refino, ou seja, estágio de dessiliciação, de descarburização e de baixo carbono. E neste modelo determina-se a temperatura e se há a necessidade de adição de refrigerantes. Para auxiliar o modelo estático no balanço de energia foi implantado um modelo que julga se o valor calculado de quantidade de calor está condizente ou não com experiências anteriores, ajudando a refinar os resultados. O sistema especialista expressa o conhecimento dos operadores para melhorar o controle do processo e é atuado pelos modelos estático, dinâmico, de gás de exaustão e os grupos de regras são divididos de acordo com o modelo de interface. O módulo de sistema especialista que atua com o modelo estático prevê a formação da escória e a possibilidade de projeção de material durante o refino.

A fundação para pesquisa metalúrgica, em Lulea, Suécia, vem desenvolvendo um pacote para cálculo contínuo de temperatura e composição química do aço durante o sopro, baseado em balanço de massa e de energia. O autor do projeto, Hahlin⁽³⁵⁾, com planta piloto de 6 t e conversor industrial de 185 t para testes, concentrou os estudos na melhoria das entradas do conversor, o que possibilitaria uma melhor resposta. Foram obtidos altos acertos simultâneos de C e T. Não foram estudados processos com utilização de sublança, o que, segundo os autores, melhorariam ainda mais as respostas dos modelos de previsão.

Observa-se que o direcionamento que vem sendo dado às melhorias em modelagem matemática trazem como novidade a integração da inteligência artificial em modelos convencionais de controle de processo de aciaria, sendo a área explorada a de sistema especialista. Este tipo de modelagem envolve a necessidade de boa padronização de atividades, o que pode trazer resultados expressivos ou não, dependendo do nível de padronização das operações da empresa. Não foi encontrado registro de utilização de redes neurais artificiais nas principais revistas da área de aciaria.

2.2 REDES NEURAIS ARTIFICIAIS

2.2.1 HISTÓRICO

Talvez inspirado por resultados de Alan Turing e John von Neumann sobre a natureza “booleana” da inteligência e, possivelmente, da atividade neuronal, McCulloch⁽³⁶⁾ desenvolveu, em 1943, um modelo matemático simplificado de um neurônio: o neurônio possuía apenas uma saída, que era uma função degrau (“*threshold*”) da soma de suas diversas entradas. Surgiu o primeiro artigo em redes neurais artificiais.

Em 1947, McCulloch e Pitts⁽³⁶⁾ criaram redes interligando os neurônios de McCulloch e demonstraram que estes eram capazes de executar ações complexas. Se analisado como um discriminador linear, as funções “booleanas” E e OU são linearmente separáveis, ou seja, é possível encontrar retas que separam os vetores de entrada em regiões tal que a saída determine corretamente o resultado das funções “booleanas”, que são então implementáveis com o neurônio de McCulloch. Das 16 funções “booleanas” de duas variáveis, somente duas (o XOR e o seu complemento) não são linearmente separáveis.

Em 1949, surgia indícios do treinamento das RNA’s: Hebb⁽³⁷⁾ sugere que a alteração da eficiência “sináptica” é a base do aprendizado, através do seguinte postulado: “Quando uma célula A está suficientemente próxima para excitar uma célula B e repetida ou persistentemente toma parte no disparo desta, algum processo de crescimento ou mudança metabólica ocorre em uma ou ambas as células de modo que a eficiência de A em excitar B é aumentada.”. Então, segundo Hebb, uma determinada conexão somente é reforçada se tanto as células “pré-sinápticas” quanto as “pós-sinápticas” estiverem excitadas.

Em 1958, Roseblatt⁽³⁸⁾ criou o modelo dos *Perceptrons*. Nele, os neurônios estão organizados em duas camadas (uma para entrada e outra para saída) totalmente conectadas entre si, sendo estas conexões direcionadas da camada de entrada para a de saída. A saída dos neurônios desta rede neural produzia zero ou um, conforme a classificação dada ao

valor calculado (saída da RNA maior ou igual a zero classificada como saída igual a um e saída calculada pela RNA menor que zero classificada como zero). Baseado no treinamento de Hebb, Roseblatt conseguiu criar um algoritmo que alterava os pesos entre os neurônios de modo a realizar a computação desejada, que foi denominado algoritmo de aprendizado.

Na mesma época que Roseblatt trabalhava na *Perceptron*, em 1962, Widrow⁽³⁹⁾ criou o *Adaline* (*Adaptive linear neuron*), um elemento processador linear cuja saída é a soma ponderada das entradas pelos seus respectivos pesos. Mais tarde criou o *Madaline* (*Multilayer adaline*), uma arquitetura com duas camadas de neurônios. O modelo *Adaline* é similar ao *Perceptron*. Os elementos processadores também são binários, porém, variam em $\{-1,1\}$.

Mas a contribuição importante de Widrow⁽³⁹⁾ foi a invenção da “Regra Delta” ou “Método do Gradiente”, para treinamento das redes com processadores *adaline*, que se baseava num processo de iteração local para obtenção de um ponto mínimo, utilizando um exemplo do conjunto de treinamento por vez.

Em 1969, Minsky⁽⁴⁰⁾ publica o agora clássico texto "*Perceptrons*", argumentando as limitações dos *Perceptrons*. Cada unidade de saída (um elemento processador *Perceptron*) só poderia classificar entradas linearmente separáveis e não conseguiria, nem mesmo, aprender a resolver problemas simples não separáveis linearmente, como a função XOR (ou-exclusivo). Rosenblatt não conseguiu estender para as RNA's a lei de aprendizado do *Perceptron*. A publicação deste livro introduziu desinteresse pela técnica de RNA's.

Somente em 1982, a partir da publicação dos trabalhos de Hopfield⁽⁴¹⁾, que aplicava RNA's em otimização, o interesse na área tornou a crescer. Ele apresentou um novo modelo de RNA no qual todos os elementos processadores estavam totalmente interconectados entre si. O modelo desenvolvido por Hopfield era essencialmente distinto dos anteriores. Este tipo de topologia tornava a rede recursiva, pois a saída de cada elemento servia como entrada para todas as demais unidades. Era necessário, então, garantir

que a RNA chegasse a um estado estável na ausência de entradas externas. Para tanto, Hopfield associou o estado da rede a uma função de energia. A rede de Hopfield funciona de modo a minimizar esta função de energia, até alcançar um estado onde ela seja mínima (estável). Isto é possível, desde que o procedimento de atualização somente reduza (ou mantenha) o valor desta função. Este, no entanto, não garante achar o mínimo global de energia, pois, avançar em direção a um estado de menor energia que o anterior pode levar a um mínimo local da mesma.

Em 1986, Rumelhart e McClelland⁽⁴²⁾ e o "PDP Research Group" redescobrem as RNA's e publicam dois volumes do mais utilizado livro no assunto: "*Parallel Distributed Processing*". Neste trabalho, foi apresentado um modelo desenvolvido por Werbos em 1974 e reinventado por Parker em 1982, denominado *Backpropagation*. Parecido com seu antecessor, o *Perceptron*, difere deste por permitir a utilização de mais de duas camadas de neurônios sendo, por isso, conhecido também como *Perceptron* multicamadas. Neste modelo, o padrão apresentado à camada de entrada é propagado até a camada de saída (*forward-propagation*), onde é calculado o erro entre a saída real e a saída desejada de cada neurônio da camada de saída. Este erro é propagado de volta (*backward*) através dos respectivos pesos das conexões. Este algoritmo, denominado *Backward-Error-Propagation*, permitiu treinar RNA's com camadas intermediárias, resolvendo a principal limitação dos *Perceptrons*. Criava-se o paradigma de RNA's mais utilizado em todo o mundo.

Atualmente, encontram-se muitos estudos sobre redes neurais artificiais na literatura e o crescente número de artigos publicados confirmam o sucesso deste modelo. Além das muitas aplicações existentes, muitos esforços buscam a melhoria desta técnica através de modificações que levam a um ponto ótimo entre o tempo de treinamento e a uma eficiente generalização.

2.2.2 CONCEITOS BÁSICOS EM REDES NEURAIIS ARTIFICIAIS

A inteligência artificial busca solucionar problemas através da reprodução de características inteligentes, buscando “imitar” o funcionamento do cérebro humano e fazer com que a máquina realize tarefas que hoje são melhor realizadas pelo homem, através do estudo de técnicas como:

- i. Os Algoritmos Genéticos, onde possíveis soluções de um problema são combinadas e alteradas. Normalmente através de mecanismos inspirados na seleção natural (de Darwin), no *Crossing-Over* e na mutação genética. Tem como principais características a obtenção de um conjunto de soluções ao invés de uma única solução;
- ii. Os Sistemas Especialistas, inspirados na lógica do raciocínio humano. O conhecimento a cerca de um determinado assunto é expresso em regras e o sistema se encarrega de avaliar, encadear e quando este conhecimento deve ser utilizado;
- iii. As Redes Neurais, inspiradas nos princípios do processamento neurofisiológico. Se baseiam no processamento paralelo e distribuído das informações. Tem como principais características o aprendizado através de exemplos e a capacidade de generalização;
- iv. E os Sistemas Híbridos, que combinam uma ou mais técnicas de Inteligência Artificial.

A idéia de imitação do sistema neural humano atribui características interessantes às RNA's, tais como:

- i. O aprendizado por experiência;
- ii. Não seguir programação;
- iii. Reconhecimento de padrão e generalização da resposta (mesmo diante de entradas muito distorcidas);
- iv. Vasta aplicação, pois poderá ser usada para problemas que não podemos estruturar, ou seja, problemas que se conhece a solução, mas não se conhece o algoritmo;

- v. Robustez pois, enquanto o homem perde neurônios da ordem de 10^3 ao dia, a máquina não perde nada.

Por não buscar estabelecer relações de conhecimentos, a Rede Neural Artificial (RNA) pode se tornar uma caixa preta! Assim, é importante conhecer o processo que se está modelando e utilizá-lo como fonte de informações para tomada de decisão.

Em relação à aplicação, as RNA's são especialmente úteis para classificação aproximação/mapeamento de funções que são tolerantes de alguma imprecisão, que tem dados disponíveis para treinamento, mas para que regras rápidas e robustas (tais como aquelas que podem ser usadas em sistemas espertos) não possam facilmente serem aplicadas. As redes *feedforward* tipo *Perceptrons*, com uma simples camada oculta usando *threshold* ou funções de ativação sigmóidais, são muito aplicadas.

Mas observa-se também algumas dificuldades: a consistência dos resultados depende do treinamento efetuado pela minimização do erro que vai arbitrariamente atingir um mínimo global. E não existem métodos para treinamento que possam criar informações que não estejam contidas no banco de dados do treinamento.

2.2.3 ANALOGIA ENTRE O NEURÔNIO BIOLÓGICO E O ARTIFICIAL E ARQUITETURA DA REDE NEURAL ARTIFICIAL

As referências adotadas como base neste estudo foram os trabalhos feitos por Wasserman⁽⁴³⁾ e Kovács⁽⁴⁴⁾.

No cérebro humano, cada neurônio possui um corpo celular, ou soma, dentro do qual encontram-se a maioria dos seus orgânulos. Cada neurônio possui dendritos e, normalmente, um axônio. Através dos dendritos, o neurônio recebe impulsos elétricos, processa-os no soma e transmite novo impulso através de seu axônio para os dendritos de outros neurônios.

A estrutura de uma rede neural artificial está calcada na organização dos neurônios (processadores matemáticos) em camadas e na conexão entre um axônio de um neurônio e um dendrito de outro neurônio por uma sinapse, responsável pela comunicação entre estes neurônios. **Portanto, a informação está na sinapse e não nos neurônios. Logo, quanto maior o número de interconexões, maior a capacidade de armazenar informações da RNA.**

A forma pela qual os neurônios estão interligados é denominada topologia da rede. Pelo estudo da topologia das RNA's produz-se a arquitetura através da organização das camadas de neurônios e de suas interconexões. Os neurônios podem estar organizados em conexões intracamadas, onde as saídas dos neurônios de uma camada se tornam entradas de neurônios da mesma camada, em conexões intercamadas, onde as saídas dos neurônios de uma camada se tornam entradas de neurônios de uma outra camada e em conexões recursivas, onde as saídas de um neurônio de tornam entradas dele mesmo. As redes com conexões intercamadas e alimentação direta denominam-se "*Backpropagation*".

Se a topologia da RNA não varia, a RNA é dita rígida. Mas a RNA pode ser flexível ou plástica, podendo ser aumentada ou cortada conforme a necessidade. As redes rígidas são as mais utilizadas. As redes flexíveis são úteis para problemas que variam com o tempo.

Outra particularidade da RNA: pode ser estática (o peso das conexões entre os neurônios não variam) ou dinâmica (com variação dos pesos). As redes estáticas são utilizadas na resolução de problemas conhecidos e equacionados. As redes dinâmicas possuem mecanismos de aprendizado, que possibilitam a modificação dos pesos de suas conexões de modo a codificar o seu desempenho criando ou removendo novos pesos. E no momento em que se alterar o valor de um peso de zero para qualquer outro valor cria-se um novo peso, e zerá-lo equívale a eliminá-lo. Isto acarretará num acréscimo ou decréscimo no tempo de processamento.

2.2.4 O ALGORITMO DE TREINAMENTO BACKPROPAGATION

Uma importante etapa para se construir uma rede neural artificial é o treinamento. Para treinar-se uma RNA, existem dois tipos básicos de treinamento:

A) Autônomo, auto-organizado ou não supervisionado:

Não necessita de um “professor”, não requer nenhum vetor projetado de saída. A rede se auto-organiza para produzir as mudanças. O algoritmo de treinamento necessita apenas vetores de entrada, modificando os pesos para produzir vetores de saída consistentes. O processo de treinamento extrai propriedades estatísticas do conjunto treinado e grupo de vetores similares entre classes.

B) Aprendizado por correção do erro, supervisionado ou associativo:

O treinamento supervisionado requer um “professor” externo que avalie o comportamento do sistema e providencie as modificações subseqüentes. Requer formar pares de cada vetor de entrada com um vetor alvo de saída. Juntos são chamados “par treinando”. Nesta metodologia, um vetor de entrada é aplicado, a saída da rede é calculada e comparada ao vetor alvo, o erro adquirido é retropropagado através da rede e os pesos são mudados conforme o algoritmo de treinamento escolhido que tende a minimizar o erro. Os vetores do treinamento são aplicados seqüencialmente, os erros são calculados para cada par treinado e os pesos ajustados para cada vetor até que o erro de toda rede atinja um valor aceitável.

O **Aprendizado por Gradiente Descendente** é o mais utilizado para agilizar o período de treinamento e o algoritmo denominado “Regra de Delta Generalizada”, *Generalized Delta-Rule* (GDR), o método iterativo por gradiente descendente que minimiza o quadrado do erro e se utiliza de um peso extra atribuído aos pesos a serem ajustados. A

GDR calcula o erro de saída e gera os novos valores para os pesos, propagando de volta para as camadas anteriores.

A GDR utiliza a função *bias*, ao invés dos valores internos residuais de ativação (*Threshold*). Eles são adicionados (e não subtraídos, como nos valores *Threshold*) ao somatório do neurônio e não devem ser atualizados no treinamento. Na GDR, devem assumir valores iguais **zero**, na primeira camada, e iguais a **um** nas seguintes.

A Rede Neural Artificial tipo *Backpropagation* é um dos algoritmos de treinamento mais conhecidos e utilizados para RNA's. Pode ser aplicado a redes com qualquer número de camadas (multicamadas) em conexões *feedforward* ou *feedback*. É uma generalização do GDR.

No funcionamento da rede multicamada *feedforward*, o neurônio artificial tem como função calcular o somatório dos produtos $x_i w_i$, produzindo o valor "NET". Como pode ser visto na figura 2.5, o modelo de processamento do neurônio possui n entradas e uma única saída e seu processamento consiste em transferir, através de uma função de transferência específica (logística, linear, etc.) a saída "OUT". O neurônio artificial (tanto *Perceptron* quanto *Adaline*) foi projetado para imitar características de primeira ordem dos neurônios biológicos. Cada entrada de um neurônio equivale à saída de outro.

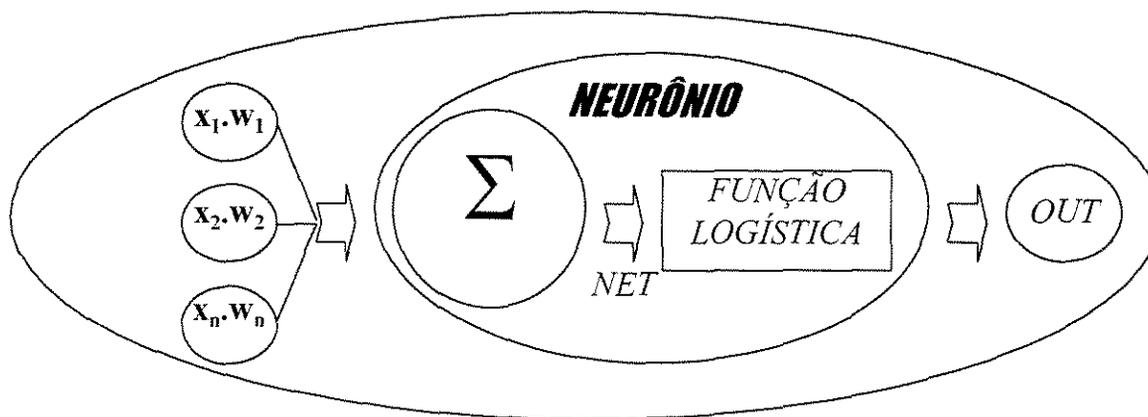


Figura 2.5 - O neurônio artificial com função de ativação.

Para calcularmos a saída NET utilizamos a fórmula:

$$NET = x_1w_1 + x_2w_2 + \dots + x_nw_n \dots\dots\dots 2.47$$

Onde,

x_i - são as entradas dos neurônios;

w_i - são os fatores ponderadores ou pesos.

Esta saída NET poderá ser parte da entrada de outros neurônios, ao serem ponderadas com os pesos determinados pelo treinamento. De forma similar, o cálculo das saídas de uma camada com n neurônios pode ser realizado via uma multiplicação de matrizes:

$$NET = XW \dots\dots\dots 2.48$$

Onde, NET - Vetor linha de saídas;

X - Vetor linha de entradas;

W - Matriz com pesos.

Normalmente, a função de ativação utilizada para as RNA's com *backpropagation* é a função sigmoideal e tem como objetivo produzir a não linearidade para as redes multicamadas serem utilizadas no lugar das redes de camadas simples. As equações 2.50 e 2.51 mostram a função sigmoideal e a sua derivada, respectivamente.

$$OUT = f(NET) \dots\dots\dots 2.49$$

$$OUT = \frac{1}{1 + e^{-NET}} \dots\dots\dots 2.50$$

$$f'(NET) = \frac{\partial OUT}{\partial NET} = OUT(1 - OUT) \dots\dots\dots 2.51$$

A partir da organização dos neurônios artificiais em camadas, constrói-se então uma rede de neurônios, a Rede Neural Artificial. A figura 2.6 mostra a organização de uma RNA tipo *Perceptron*, com a **camada de entrada** das variáveis, que não efetuará cálculos, ou seja, apenas distribuirá as entradas, **a(s) camada(s) intermediária(s)**, também chamada(s) de **camada(s) oculta(s)**, que manipulam os dados de forma “escondida” e a **camada de saída**, responsável pelas variáveis a serem previstas. As conexões entre os neurônios são representadas por pesos (w_{ij} - conexão entre os neurônios i , de uma camada e j , da camada seguinte).

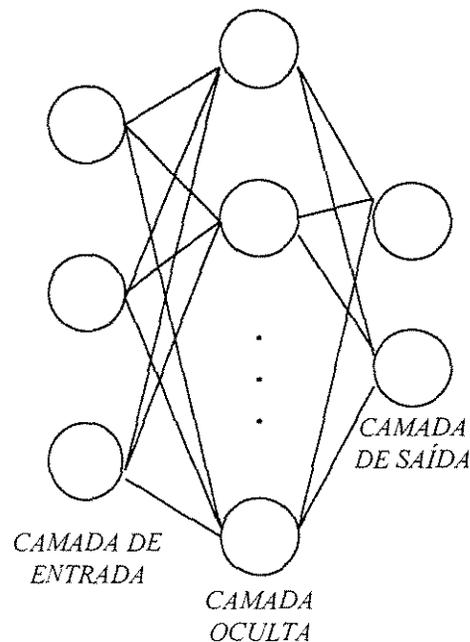


Figura 2.6 - Desenho esquemático de uma rede neural organizada em camadas.

Estes pesos podem ser positivos ou negativos, ou seja, podem atuar como excitadores ou inibidores. O processamento numa RNA é realizado de forma distribuída entre os neurônios, onde ocorrem processamentos matemáticos paralelos. Por este motivo, as RNA's são também conhecidas como sistemas de processamento distribuído e paralelo (PDP).

Com a arquitetura da RNA definida, os passos necessários à aplicação das RNA's a um problema qualquer são:

- i. Coleta de dados e separação em conjuntos de treinamento e testes (os dados devem cobrir amplamente o problema);
- ii. O treinamento, onde a rede aprende a resolver um conjunto de padrões de saída associados a padrões de entrada;
- iii. O teste, onde são apresentados padrões de entrada à rede que não foram utilizados pelo treinamento, e as saídas obtidas são comparadas às saídas desejadas;
- iv. E a implementação, onde deverá ser explorada a memória da RNA, através da lembrança do que foi aprendido.

O treinamento assume a formação de pares de vetores: vetores de entrada com vetores de saída projetadas. Antes do início do treinamento, todos os pesos devem ser inicializados para pequenos números aleatórios. Isto assegura que a rede não sature no início. A seguir será apresentado a modelagem matemática para o algoritmo de treinamento *Backpropagation*.

O modelamento matemático necessário para o equacionamento de uma rede neural artificial, baseado nas referências Wasserman⁽⁴³⁾, Kovács⁽⁴⁴⁾, Fileti⁽⁴⁵⁾ e Haykin⁽⁴⁶⁾ está descrito a seguir e está baseado na estrutura montada na figura 2.7.

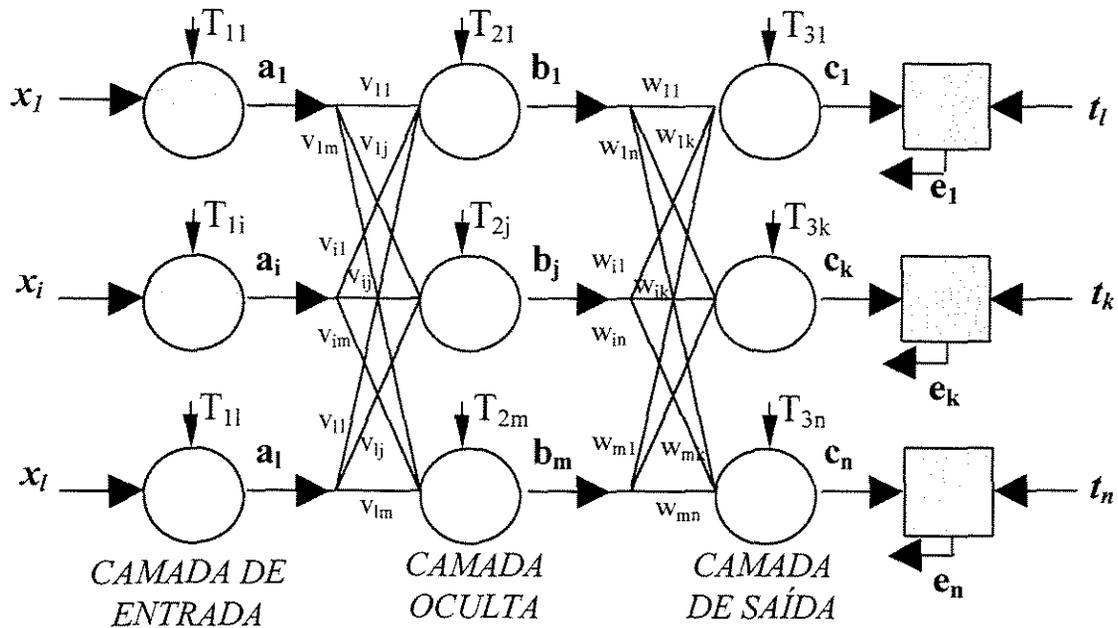


Figura 2.7 - Desenho esquemático de uma RNA *Perceptron* com 3 camadas.

Passos de modelagem e funcionamento do modelo:

1º Passo: Para iniciar o treinamento, deve-se atribuir valores aleatórios para os pesos v_{ij} e w_{jk} e, para os valores residuais internos, 0 para a camada de entrada ($T_{1i} = 0$) e 1 para as camadas ocultas e de saída ($T_{2j} = T_{3k} = 1$), que consideraria a Regra de Delta Generalizada (a GDR), ou variações de valores destas bias, de acordo com o direcionamento dado pelo responsável pelas simulações numéricas. Deve-se também definir-se os limites da função logística empregada no modelo.

2º Passo: Apresentar a matriz de entrada x_i à camada de entrada “A” da RNA, sendo esta apresentação realizada em forma de vetores, ou seja, vetores linha ou coluna, dependendo da configuração do arquivo. Calcular a saída, a_i , parametrizada entre os valores máximo e mínimo da função logística:

$$a_i = x_i + T_{1i} \dots \dots \dots 2.52$$

3º Passo: Calcular a saída da camada oculta “B”, b_j , utilizando a função logística f e a função *bias* $T_{2j} = 1$, ou valor definido. Se for utilizada uma RNA com mais de uma camada oculta, o cálculo abaixo se repete:

$$b_j = f \left(\sum_{i=1}^l (a_i v_{ij}) + T_{2j} \right) \dots\dots\dots 2.53$$

4º Passo: Calcular a saída da camada de saída “C”, c_k , utilizando a função logística f e a função *bias* $T_{3k} = 1$, ou valor ajustado:

$$c_k = f \left(\sum_{j=1}^m (b_j w_{jk}) + T_{3k} \right) \dots\dots\dots 2.54$$

5º Passo: Repetir os passos 1 até 4 para p números de pares de vetores de entrada-saída. Calcular o erro quadrático total e , para n número de neurônios da camada de saída, utilizando o valor desejado, t_k^p , da saída do k -ésimo neurônio do p -ésimo par entrada/saída e o valor de saída do k -ésimo neurônio do p -ésimo par treinando calculado pela RNA, c_k^p :

$$e = \sum_{p=1}^p \sum_{k=1}^n (t_k^p - c_k^p)^2 \dots\dots\dots 2.55$$

6º Passo: Se o valor do erro não for o desejado, iniciar o treinamento. Calcular o termo de declínio do gradiente, δ_{3k}^p , do k -ésimo neurônio do p -ésimo par treinando da RNA:

$$\delta_{3k}^p = (t_k^p - c_k^p) \frac{\partial f}{\partial x_{3k}} \dots\dots\dots 2.56$$

onde f é a função logística e sua derivada parcial em relação a x_{3k} é:

$$\frac{\partial f}{\partial x_{3k}} = \frac{e^{-x_{3k}}}{(1 + e^{-x_{3k}})^2} \dots\dots\dots 2.57$$

e x_{3k} é a soma das entradas ponderadas do k -ésimo neurônio da camada de saída para a p -ésima sessão de treinamento:

$$x_{3k}^p = \sum_j w_{jk}^p b_j^p + T_{3k}^p \dots\dots\dots 2.58$$

7º Passo: Calcular o termo de declínio do gradiente, δ_{2j}^p , do j -ésimo neurônio da camada escondida:

$$\delta_{2j}^p = \left(\sum_k \delta_{3k}^p w_{jk}^p \right) \frac{\partial f}{\partial x_{2j}} \dots\dots\dots 2.59$$

onde k é o neurônio da camada de saída; x_{2j} é definido por:

$$x_{2j}^p = \sum_i v_{ij}^p a_i^p + T_{2j}^p \dots\dots\dots 2.60$$

e a derivada parcial da função logística em relação a x_{2j} é dada por:

$$\frac{\partial f}{\partial x_{2j}} = \frac{e^{-x_{2j}}}{(1 + e^{-x_{2j}})^2} \dots\dots\dots 2.61$$

8º Passo: Com o declínio do gradiente, δ_{2j}^p , da camada escondida, e o declínio do gradiente, δ_{3k}^p , da camada de saída, calcular as variações dos fatores ponderais (pesos) usando:

$$\Delta v_{ij}^p = \eta \delta_{2j}^p a_i^p + \alpha \Delta v_{ij}^{p-1} \dots\dots\dots 2.62$$

$$\Delta w_{jk}^p = \eta \delta_{jk}^p b_j^p + \alpha \Delta w_{jk}^{p-1} \dots\dots\dots 2.63$$

onde η é a taxa de aprendizado e α é o coeficiente de *momentum*, um peso extra para agilizar o treinamento, variando entre 0 e 1.

9º Passo: Atualizar os pesos de acordo com:

$$v_{ij}^p = v_{ij}^{p-1} + \Delta v_{ij}^p \dots\dots\dots 2.64$$

$$w_{jk}^p = w_{jk}^{p-1} + \Delta w_{jk}^{p-1} \dots\dots\dots 2.65$$

onde v_{ij}^p é o fator ponderal da conexão entre o i -ésimo elemento da camada escondida e w_{jk}^p é o peso da conexão entre o j -ésimo elemento da camada escondida e o k -ésimo elemento da camada de saída, ambos na iteração p .

10º Passo: Repetir os passos 2 até 9 para todos os pares de vetores de entrada-saída até o erro quadrático atingir um valor aceitavelmente baixo e a propriedade principal da rede, ou seja, a generalização, apresentar a melhor resposta.

Uma vez treinada, a RNA estará propícia ao processo de generalização, isto é, apta às previsões das variáveis de saída de acordo com o que a ela for apresentado como entrada. Isto será conseguido mediante a utilização dos passos 2, 3 e 4, além do emprego dos parâmetros tais como os valores residuais internos e os pesos otimizados pelo treinamento.

2.2.5 ASPECTOS AVANÇADOS EM REDES NEURAIAS ARTIFICIAIS

Dificuldades durante o processo de treinamento, tais como, mínimos locais, paralisia da rede ou instabilidade temporal levaram muitos pesquisadores a investigarem as propriedades das Redes Neurais Artificiais e buscarem modificações no algoritmo de treinamento para redes *Backpropagation*.

Segundo Abelem et al.⁽⁴⁷⁾, os fatores que determinam o desempenho das redes neurais artificiais são: a convergência, a generalização e a escalabilidade entre os dois primeiros.

A convergência é função do aprendizado das redes neurais e indica quando o procedimento de treinamento é capaz de aprender a classificação dos vetores de entrada-saída apresentados à RNA, quais condições são necessárias na rede e quais condições computacionais são exigidas. Alguns critérios são adotados para se avaliar o processo de treinamento: número de iterações, erro mínimo aceitável de toda a rede ou por padrão treinado ou ainda tempo de treinamento.

A generalização é a habilidade da RNA de reconhecer os padrões fora do conjunto treinado e é a principal propriedade que deve ser exigida numa RNA.

A escalabilidade é a propriedade de se ajustar os parâmetros do sistema neural projetado para se obter boa convergência e se extrair a generalização desejável. É o ponto ótimo entre uma grande rede que aprenda com facilidade e uma pequena rede que generalize com sucesso.

Esses fatores são determinados pela definição dos parâmetros da RNA:

- i. Função de ativação: as mais usadas são as funções sigmoideal e tangente hiperbólica, com contra-domínios entre 0 e 1 e entre -1 e 1, respectivamente. A utilização destas funções tem a ver com o fato de saturarem nos extremos no contra-domínio;
- ii. Função erro: informa o grau de convergência das RNA's e o quanto a rede está assimilando os padrões em treinamento;
- iii. Parâmetros de controle do gradiente descendente e do tempo de treinamento:
 - *Momentum*: utilizado para diminuir o tempo de treinamento e o risco de mínimos locais, sem adicionar oscilação ao processo de treinamento;
 - Razão de Aprendizado: influencia a intensidade da mudança dos pesos. Valores pequenos podem conduzir a um treinamento lento e a um mínimo local. Valores muito altos podem introduzir oscilações ou saturação ao treinamento.
- iv. Condições de inicialização do treinamento;
- v. Arquitetura da rede: o tamanho e a configuração de uma RNA influencia a escalabilidade da RNA, pois pode-se aumentar ou diminuir a capacidade de treinamento e generalização pela variação do número de camadas ocultas, de neurônios ocultos, etc.

Baseando-se nestas informações, foi realizado um levantamento bibliográfico objetivando a aquisição de dados sobre as particularidades do treinamento de redes tipo *Backpropagation*, para identificar as dificuldades na modelagem de redes neurais artificiais e sugestões da literatura especializada na melhoria dos algoritmos. Experiências sobre a lógica de treinamento, sobre a influência da arquitetura da rede no treinamento/generalização, sobre a influência da inicialização do treinamento, sobre a influência dos dados no treinamento, sobre os parâmetros de controle do gradiente descendente e do tempo de treinamento e sobre as dificuldades com os problemas relacionados ao treinamento e à capacidade de generalização, tais como mínimos locais, velocidade de treinamento, *overtrainig*, entre outros, serão apresentados a seguir.

LÓGICA DE TREINAMENTO

Sob o aspecto da lógica de treinamento, Barnard e Holm⁽⁴⁸⁾ estudaram técnicas de otimização do algoritmo *Backpropagation*. A escolha do método de otimização tem influência direta no número de iterações necessárias para o treinamento da rede, na probabilidade do procedimento de treinamento terminar num mínimo local e na generalização da rede. As principais técnicas de otimização são:

- i. *Batch – Mode*, onde o ajuste dos pesos só são realizados após a apresentação e o treinamento de cada padrão e o cálculo do somatório do erro total da RNA. A função objetivo é a minimização do somatório do erro quadrático total dividido pelo total do número de padrões treinados;
- ii. *Sequencial – Mode*, onde cada vetor entrada-saída é treinado e somente após os pesos se adequarem a todos os padrões apresentados até um determinado momento do treinamento passa-se para o treinamento do padrão seguinte. Este método é sugerido quando não há um conjunto de treinamento fixo, ou seja, quando as entradas são oriundas de um ambiente não estacionário, ou quando o conjunto de treinamento é fixo, finito e grande.

Simulações numéricas realizadas em torno desta teoria investigaram as principais propriedades das RNA's: o tempo de treinamento e a qualidade de generalização para um pequeno conjunto de treinamento (N=96) e um grande conjunto de treinamento (N=1635). Os resultados mostraram que o treinamento tipo *Batch – Mode* são mais rápidos tanto para o N pequeno quanto para N grande e este treinamento atribui à RNA melhor generalização para N pequeno. Já o treinamento *Seqüencial – Mode* produz características de melhor generalização para N grande.

INFLUÊNCIA DA ARQUITETURA

O estudo do número de camadas ocultas em redes neurais artificiais é um ponto importante a ser definido e foi estudado por Villiers e Barnard⁽⁴⁹⁾. Baseado na idéia do número de pesos ser um indicador aproximado da complexidade da RNA, os autores compararam as redes com três e quatro camadas com o mesmo número de pesos, para dimensões de entradas de RNA variando de pequenas ($D=2$) a grandes ($D=21$). As redes com quatro camadas que apresentaram melhores desempenhos na qualidade de generalização foram as ajustadas com o mesmo número de neurônios das duas camadas ocultas. Resultados experimentais indicaram que as redes neurais com quatro camadas são mais propensas a caírem num mínimo local e que por isto, as redes com três camadas apresentaram um desempenho melhor tanto no treinamento quanto na generalização. Entretanto, não foi encontrada diferença entre o desempenho ótimo (melhor rede ajustada) entre redes com três e quatro camadas. Outra observação importante: não verificou-se influência no desempenho das redes de acordo com a mudança do número de entradas.

Na mesma linha do tratamento anterior, um artigo bem recente publicado por Tamura e Tateishi⁽⁵⁰⁾ deu ênfase à comparação entre a capacidade de redes neurais artificiais de três e quatro camadas com um número finito de unidades ocultas. Os autores concluem neste trabalho que a RNA *feedforward* de três camadas com $(N-1)$ neurônios ocultos podem dar qualquer relação exata entre N relações entradas-saída(s) e que a RNA com quatro camadas dará a mesma relação entre N relações entradas-saída(s) usando somente $(N/2)+3$ unidades ocultas. Desta forma, a RNA com quatro camadas é superior em termos de número de parâmetros necessários para o treinamento dos dados e ainda atinge erros menores durante o treinamento.

Ainda sobre a definição da arquitetura da RNA, outro ponto importante é a definição do número de neurônios da(s) camada(s) oculta(s). Hecht-Nielsen⁽⁵¹⁾ concluiu que uma rede neural com três camadas (uma oculta) pode modelar qualquer função matemática contínua através de uma rede com $2n+1$ neurônios ocultos, sendo n o número de neurônios da camada de entrada. Maren⁽⁵²⁾, por sua vez, concluiu que redes com quatro camadas (duas

ocultas) apresentam melhor desempenho quando são treinadas com uma proporção de 3:1 entre o número de neurônios da primeira camada oculta e o número de neurônios da segunda camada oculta. Já Lippmann⁽⁵³⁾ concluiu que para redes com quatro camadas, a segunda camada oculta deverá conter o dobro do número de neurônios da camada de saída e que para rede com três camadas, a camada oculta deverá conter $s.(n+1)$ neurônios, onde s é o número de neurônios da camada de saída e n o número de neurônios da camada de entrada.

Mirchandani e Cao⁽⁵⁴⁾ estudaram a determinação do número ótimo de neurônios ocultos em RNA's de três camadas, considerando um conjunto de vetores de entrada num espaço Euclidiano R^d . Um neurônio oculto age como um hiperplano de dimensão $(d-1)$ que forma duas regiões de decisão. Foi definido que o espaço de entrada de dimensão d é linearmente separável em M regiões, se elas existem em M regiões distintas limitadas compondo porções do hiperplano. E a associação das regiões com classes é a tarefa dos neurônios de saída conectados aos neurônios ocultos. O número de regiões separáveis identifica o número mínimo de padrões de entrada, T , necessários para o treinamento da *Perceptron*. A situação ideal seria fazer $T=M$, ou seja, o emprego de cada padrão de treinamento gerando uma região separável para assegurar a separação do espaço de entrada em M regiões necessárias. Na prática, $T>M$, pois o algoritmo *Backpropagation* não assegura a convergência a um mínimo global.

Os autores criaram na ocasião um teorema: “No espaço de dimensão d , o número máximo de regiões linearmente separáveis, M , usando H neurônios ocultos seria dado por:

$$M(H, d) = \sum_{k=0}^d \binom{H}{k} \dots\dots\dots 2.66$$

Sendo que para $d=1$, $M = H+1$ e para $H \leq d$, $M=2^H$.

Por conseqüência, tendo-se dois de M , H e d , pode-se determinar um mínimo de padrões de treinamento necessários para o sucesso da RNA.

Hagiwara⁽⁵⁵⁾ publicou um artigo sobre a seleção/redução do tempo de treinamento e eliminação de unidades ocultas. Sabe-se que redes que usam *Backpropagation* possuem preocupações de:

- i. Encurtar o tempo de treinamento, através do uso de uma função erro íngreme, da mudança da forma de apresentação dos padrões, do emprego do erro total durante o treinamento e da variação dos parâmetros α e η ;
- ii. Reduzir o número de neurônios ocultos, pois isto resultaria num aumento na capacidade de generalização, numa interpretação facilitada da RNA e na redução dos custos computacionais.

O que o autor propôs foi introduzir a capacidade de seleção para as unidades ocultas, para a redução do tempo de treinamento e das “piores” unidades ocultas:

- i. Priorizar a convergência, pelo reajuste dos pesos conectados aos neurônios selecionados como “piores” para pequenos valores randômicos, acelerando o treinamento e escapando do mínimo local;
- ii. Quando a convergência é atingida, pela eliminação dos piores neurônios selecionados, ocorre uma redução no número de unidades ocultas.

Para a camada oculta $k-1$, com neurônios i e camada de saída k , com neurônios j , indicou-se o fator *badness* (má qualidade) como BAD, para representar a má qualidade dos neurônios ocultos selecionados, em função do erro e do neurônio oculto i , para o padrão p :

$$BAD_i^{k-1} = \sum_p (e_i^{k-1,p})^2 = \sum_p \left(\sum_j w_{ij}^{k-1,p} \delta_j^k \right)^2 \dots\dots\dots 2.67$$

Assim, se o fator BAD é pequeno, a correção para aquela unidade de processamento também é pequena. Logo, BAD indica a condição de convergência dos pesos conectados a cada neurônio da camada oculta. Desta forma, o neurônio oculto com o maior BAD é considerado o pior, pois está longe de convergir.

Baseado na seleção dos neurônios pelo fator BAD, o autor desenvolveu um método para escapar do mínimo local e reduzir o tempo de aprendizado. Ao cair-se num mínimo local, é necessário inserir algum tipo de distúrbio:

- i. Monitorar o erro total na camada de saída;
- ii. Quando a mudança no erro total na camada de saída tornar-se muito pequena, selecionar as unidades piores;
- iii. Reajustar os pesos das unidades selecionadas para pequenos pesos randômicos, perturbando a RNA;
- iv. Se a RNA não convergir após um certo número de iterações, aumentar o número de camadas ocultas.

Para os casos em que a RNA atinge a convergência, pode-se reduzir o número de unidades ocultas:

- i. Garantir que a convergência tenha sido obtida;
- ii. Selecionar as piores unidades;
- iii. Deletar as unidades selecionadas;
- iv. Repetir os passos 1 à 3, usando o algoritmo 1 para restaurar a convergência.

Segundo o autor, as simulações utilizando estes algoritmos proporcionaram uma diminuição no número de unidades ocultas resultando na diminuição do tempo de treinamento e melhor generalização.

INFLUÊNCIA DA INICIALIZAÇÃO DO TREINAMENTO

No campo da influência das condições iniciais sobre o treinamento e a generalização, Atiya e Ji⁽⁵⁶⁾ deram sua contribuição no estudo das condições que afetam o desempenho da generalização em redes grandes. Como é sabido, a generalização depende de três fatores:

- i. Graus de liberdade da RNA (relacionado ao número de pesos);
- ii. Quantidade de ruído no conjunto de treinamento;
- iii. Tamanho do conjunto de treinamento.

Observação: a quantidade de ruído e o tamanho do conjunto de treinamento depende do problema a ser implementado.

Embora muitos pesquisadores têm concentrado esforços no estudo do efeito do tamanho da RNA na generalização, os autores optaram pela investigação da distribuição inicial dos pesos. Quando um algoritmo de gradiente descendente é usado, ele tende a convergir para o mínimo local das funções objetivos encerradas para as condições iniciais. No caso de uma rede sobreparametrizada, o mínimo da função corresponde não a um ponto, mas a uma superfície de solução (como quando o erro tende a zero). O algoritmo de treinamento geralmente aterrá os pesos num ponto da superfície de solução fechada às condições iniciais. Se os pesos iniciais são pequenos, então a tendência é que os pesos finais alcançados sejam pequenos. Isto pode resultar em muita suavidade a ser justificada pela complexidade do problema dado ou pela quantidade de ruído.

Os estudos empíricos dos autores resultaram no seguinte:

- i. Existe uma faixa ótima inicial de pesos que conduzem a uma melhor generalização. Isto contradiz a crença de que pesos iniciais pequenos geram uma melhor generalização;
- ii. O efeito na generalização é mais forte, mas não é limitado à RNA sobreparametrizada;

- iii. Visto que a condição inicial seja somente um dos fatores que afetam os algoritmos de treinamento de gradiente descendente, é natural esperar que ela somente afete o desempenho da generalização de certas redes, mas não de todas.

Três simulações com distribuição de pesos iniciais entre -0,05 e 0,05, -0,5 e 0,5 e -10,0 e 10,0, mostraram que os pesos iniciais menores geraram a pior generalização e o melhor caso ocorreu com pesos iniciais entre -0,5 e 0,5.

Finalmente foi realizado um estudo onde relacionou-se uma medida da complexidade da rede (que é a capacidade da rede de implementar muitas funções diferentes) em função do número de neurônios ocultos, da faixa de valores de entrada e da faixa de pesos iniciais utilizada.

CRITÉRIO DE PARADA DO TREINAMENTO

Schmidt et al.⁽⁵⁷⁾ provaram, através de muitas simulações computacionais de treinamento usando diferentes pesos iniciais, que a “regra” de se selecionar uma rede dita “ótima” através do conceito de menor erro quadrático atingido pelo treinamento não é válida. A primeira observação importante nas simulações foi o fato de que, ao aumentar-se o número de iterações que regem o processo de treinamento, o erro quadrático torna-se cada vez menor. Isto porém não significa que o ótimo foi encontrado, pois durante o processo de treinamento, algumas regiões com erros pequenos apresentaram dois ou mais mínimos locais.

Outras 1000 simulações foram realizadas considerando números fixos de iterações e mesmo banco de dados, diferindo somente nos pesos iniciais. Na seleção das melhores redes, a que apresentou o menor erro quadrático durante o treinamento não resultou na melhor generalização. O maior percentual de acerto na generalização (principal propriedade da RNA) concordou com um resultado de erro quadrático um pouco maior. Desta forma, na hora da escolha da rede ótima o que define é a obtenção da melhor generalização.

Outra informação importante retirada deste trabalho foi uma orientação para o momento de quando se deve parar o treinamento para a obtenção da rede ótima. Neste caminho, um número pequeno e insuficiente de iterações de treinamento levará a uma generalização ruim, pois a modelagem matemática terá sido insuficiente. Por outro lado, um treinamento da RNA com um excessivo número de iterações levará o processo de treinamento ao fenômeno de *overtraining*, que confere uma generalização também ruim, apesar do erro quadrático da rede evoluir para valores pequenos. A sugestão bem plausível feita pelos autores é a seguinte: ao correlacionar-se a capacidade de generalização com o erro quadrático obtido pelo treinamento da rede, uma correlação positiva indicará que a seleção da rede ótima está indo no caminho certo e um comportamento inverso, com correlação negativa, indicará que o treinamento “passou do ponto” e trará como consequência o fenômeno de *overtraining*.

INFLUÊNCIA DOS DADOS

Dentro do contexto de influenciadores da capacidade de generalização de uma rede (arquitetura, algoritmo de treinamento e o conjunto de dados para o treinamento), Hernandez et al.⁽⁵⁸⁾ investigaram o efeito da distribuição dos dados para o treinamento de RNA's. A comparação da distribuição real com uma distribuição em classes iguais mostrou que a primeira produz melhores resultados. No mesmo assunto, Wann et al.⁽⁵⁹⁾ estudaram meios para selecionar o conjunto de dados para maximizar a capacidade de generalização de uma RNA. Segundo os autores, pode-se escolher padrões típicos de cada classe como um conjunto de treinamento, mas na prática isto é extremamente difícil de se realizar. Outra tentativa é escolher os padrões que estão próximos no espaço de entrada e pertencentes à classes diferentes. Neste caso, a dificuldade está no encontro do fim de uma classe e início da próxima. Assim sendo, não existe motivo para se trabalhar com, por exemplo, dois bancos de dados transformando-os em apenas um, se estes bancos de dados representam funções diferentes dentro de um mesmo problema a ser equacionado (exemplo: duas curvas de um diagrama de fase).

As simulações de uma rede com arquitetura 5x3x1, baseadas em subconjuntos de treinamento com padrões limites, padrões intermediários e padrões combinados com valores intermediários e limites, com treinamento de um conjunto de dados e testes com seu complemento, informaram que:

- i. A utilização de um grande conjunto de treinamento nem sempre resulta numa boa generalização;
- ii. A rede só atingirá uma perfeita generalização se for treinada com padrões limites e críticos.

Simulações computacionais de uma rede com configuração 2x2x1, utilizando quatro padrões para o treinamento do clássico problema do “XOR”, foram utilizadas por Lehmen et al.⁽⁶⁰⁾ para checar o desempenho de uma rede em que ruídos são introduzidos nos pesos (analógicos ou discretos). O valor máximo do peso é restringido a um determinado nível e os pesos iniciais são variados. Nas simulações não foi empregado o termo *momentum* com o intuito de se reduzir a memória necessária e a complexidade de cada iteração. No caso dos pesos analógicos com ruídos, encontrou-se uma probabilidade de 100% de aprendizado com sucesso sobre uma grande amplitude de ruído. A explicação dos autores está no fato de que o ruído estimula o sistema a explorar o espaço dos pesos restritos e reduz a chance de mínimo local. No caso dos pesos discretizados, na ausência de ruído a probabilidade de aprendizado ficou em 60~70%; com a adição de ruído, aumentou-se para 80%. Nas simulações para treinamento, são gerados ruídos randomicamente entre valores máximos e mínimos para cada peso em toda iteração, mantendo-se a amplitude dos ruídos constante.

INFLUÊNCIA DOS PARÂMETROS DE CONTROLE DO GRADIENTE DESCENDENTE
E DO TEMPO DE TREINAMENTO

Qiu et al.⁽⁶¹⁾ estudaram a aceleração do treinamento *Backpropagation* pelo uso do termo de *momentum* (α) através da seleção dinâmica deste termo. A equação do algoritmo *Backpropagation* é:

$$w_{ij}(n+1) = w_{ij}(n) - \eta \frac{\partial E}{\partial w_{ij}} + \alpha[w_{ij}(n) - w_{ij}(n-1)] \dots\dots\dots 2.68$$

Existem duas limitações para a inclusão do termo *momentum* no algoritmo de treinamento *Backpropagation*:

- i. Um limite superior no tamanho do ajuste do termo *momentum* que pode ser feito para um peso;
- ii. O termo *momentum* pode levar o peso a ser ajustado acima da inclinação da superfície do erro ao invés de abaixo da inclinação como projetado.

A eficiência do termo *momentum* é também afetada pela razão de treinamento (η): se η é pequeno, um grande valor de α pode aumentar o desempenho, mas se α for demasiadamente grande, poderá ocorrer divergência. Pode-se tentar solucionar esta questão através do emprego da razão de *momentum* adaptativa, em função da razão de treinamento, utilizando as equações:

$$w_{ij}(n+1) = w_{ij} - \eta \frac{\partial E}{\partial w_{ij}} \dots\dots\dots 2.69$$

$$w_{ij}(n+2) = w_{ij}(n+1) + \alpha[w_{ij}(n+1) - w_{ij}(n-1)] \dots\dots\dots 2.70$$

Devido ao termo que contém o *momentum* ser similar ao da equação original do algoritmo *backpropagation*, chamou-se este termo de passo de *momentum*. Antes de

implementar a equação 2.70, calcula-se um novo α pelo uso da minimização unidimensional, definida por:

$$\min_{\alpha} E[w(n+1) + \alpha r] \dots\dots\dots 2.71$$

Onde, $r = w(n+1) - w(n-1) \dots\dots\dots 2.72$

A minimização unidimensional usada é baseada num método de interpolação quadrática. Inicialmente, faz-se a primeira derivada de E em função de α :

$$\frac{dE}{d\alpha} = \left[r_1 \frac{\partial E}{\partial w_1} + r_2 \frac{\partial E}{\partial w_2} + \dots + r_m \frac{\partial E}{\partial w_m} \right]_{w=w(n+1)+\alpha r} \dots\dots\dots 2.73$$

Onde m é o número de pesos. Determina-se um α inicial usando:

$$\alpha_0 = -k \text{sign} \left(\frac{dE}{d\alpha} \Big|_{\alpha=0} \right) \dots\dots\dots 2.74$$

Onde k é uma constante positiva.

O próximo passo é aproximar E por uma parábola que corresponda aos valores $\alpha=0$ e $\alpha=\alpha_0$, e corresponda ao seu gradiente para $\alpha=0$. Faz-se então $\alpha=\alpha_1$ como o mínimo da parábola que corresponda ao E quando $\alpha=0$ e $\alpha=\alpha_1$, e corresponda ao E quando $\alpha=0$. Esse processo iterativo encontra uma nova razão de *momentum*. Os resultados publicados mostraram uma aceleração do treinamento.

Leonard e Kramer⁽⁶²⁾ propuseram uma combinação do método Gradiente Descendente com a lógica de treinamento *Batch-Mode* do algoritmo *Backpropagation* com a busca de um Gradiente Conjugado, onde α e η são ajustados dinamicamente. Segundo os autores, melhor que tomar os passos baseados nas direções indicadas pelo simples exemplo

de treinamento (m_p), deve-se utilizar um gradiente de uma rede representando a direção do passo descendente direcionado sobre o conjunto completo de treinamento (M_p). Sendo:

$$m_p = \delta_{j, k+1} \cdot z_{ik} \dots\dots\dots 2.75$$

$$M_p = \sum m_p \dots\dots\dots 2.76$$

Logo, o gradiente necessário é simplesmente a soma dos gradientes gerados pela GDR para exemplos de treinamento individuais, M_p :

O fator de *momentum* α é determinado numa base passo a passo, segundo os autores, de forma melhor que o usado como constante. Usando α como dado na equação abaixo resulta numa busca ao longo das direções conjugadas, que compõem métodos melhores que os com gradiente descendente:

$$\alpha = \frac{\|M_p\|^2}{\|M_{p-1}\|^2} \dots\dots\dots 2.77$$

O tamanho do passo, melhor que o fixo, é ajustado a cada passo numa linha de busca conforme a equação abaixo. Este procedimento evita o direcionamento cíclico e lento para a função objetivo:

$$w_{q+1} = w_q + \eta M'_p \dots\dots\dots 2.78$$

sendo $M'_p = M_p + \alpha M'_{p-1} \dots\dots\dots 2.79$

As simulações indicaram uma melhoria na estabilidade da convergência e na velocidade de treinamento.

Eaton e Olivier⁽⁶³⁾ estudaram a dependência da razão de treinamento com o tamanho do conjunto de treinamento. Com o aumento do tamanho do conjunto de

treinamento o erro do gradiente tende a aumentar e, se a razão de treinamento não for diminuída com o aumento do número de padrões apresentados à rede, ocorrerá um processo de treinamento lento ou, o que é pior, não será atingida a convergência. Os autores definiram uma regra para cálculo da razão de treinamento, η , em função da variação do número de cada tipo de padrões de entrada de treinamento, N_i :

$$\eta = \frac{1,5}{\sqrt{N_1^2 + N_2^2 + \dots + N_m^2}} \dots\dots\dots 2.80$$

Qualquer grupo de padrões de entrada similares que mapeam saídas idênticas são um tipo de padrão.

Esta regra foi acoplada a um coeficiente de *momentum* igual a 0,9. Simulações com poucos padrões de treinamento (N=16) e muitos padrões (N=192) utilizando esta regra confirmaram um aumento da velocidade de treinamento. Entretanto, é muito difícil conseguir sucesso na separação dos padrões em tipos idênticos, quando se trabalha com processos complexos.

Tang e Kwan⁽⁶⁴⁾ estenderam a idéia do ajuste dos pesos para a inclinação da função de ativação (equação 2.81) e para as bias (equação 2.82):

$$\theta_j^{(h)}(t+1) = \theta_j^{(h)}(t) + \varepsilon_b \sum_{k=1}^k \delta_{ik}^{(h)} \dots\dots\dots 2.81$$

$$\alpha_j^{(h)}(t+1) = \alpha_j^{(h)}(t) + \varepsilon_a \sum_{k=1}^k \delta_{jk}^{(h)} \alpha_j^{(h)} + \mu_a [\alpha_j^{(h)}(t) - \alpha_j^{(h)}(t-1)] \dots\dots\dots 2.82$$

Sendo $\theta_j^{(h)}$ a bias do neurônio j da camada h, ε_b o tamanho do passo para a bias, $\delta_{jk}^{(h)}$ a variação do erro do padrão k em relação à saída da função de ativação, $\alpha_j^{(h)}$ a inclinação, ε_a , o tamanho do passo para a inclinação e μ_a o *momentum*).

Para efeitos de cálculos, a inicialização deve ser feita com valores randômicos para os pesos (entre -0,1 e 0,1), para as bias (entre -0,1 e 0,1) e para os α 's (iguais a 1). Após o cálculo da(s) saída(s) da rede, calcula-se o(s) erro(s). Se o somatório dos erros for maior que o nível predeterminado, ajusta-se as bias, os pesos e as inclinações. Com $\varepsilon_b = 0,1$, $\mu_\alpha = 0,05$ e $\varepsilon_\alpha = 0,15$, produziu-se simulações que mostraram melhorias na velocidade do treinamento e na generalização.

2.2.6 APLICAÇÕES DE REDES NEURAIS EM SIDERURGIA

Segundo vários relatos em aplicações de inteligência artificial, dentre eles o de Argyropoulos⁽⁶⁵⁾, grandes aplicações podem ser idealizadas e implementadas, gerando redução de custos, aumento de produtividade e outros benefícios, através do uso da rede para otimização e controle de processos, aproveitando sua característica adaptativa. Modelos de previsão de qualidade de produtos ou de desgaste de equipamentos podem ser implementados em inúmeros processos, bastando-se levantar um histórico das condições operacionais, qualidade de matérias primas e outros influenciadores da qualidade do produto final ou do desgaste do equipamento e adequar o artifício computacional à necessidade.

Outra importante aplicação envolve a utilização da RNA para manipular dados de entrada de qualidade de matérias primas com o intuito de gerar um analisador virtual *on-line*, que poderia atuar de forma mais rápida na ajuda de um modelo corretivo no processo e muito mais econômica. Aliás o termo *on-line* é muito bem vindo nas redes neurais artificiais, dados os muitos recursos disponíveis para driblar o problema da atuação em tempo real. Para completar este comentário, basta colocarmos neste contexto uma das áreas mais exploradas atualmente no campo da inteligência artificial: o reconhecimento de padrões, outro vasto campo de aplicação.

Assim, neste curto comentário pode-se imaginar o quão grande é a área de aplicação das redes neurais artificiais. Por isto, alguns ramos da engenharia química hoje se orientam nesta direção, devido a necessidade de se trabalhar com uma extensa gama de fenômenos que não se consegue estruturar.

A seguir são citadas algumas aplicações de RNA nas siderúrgicas, em processos de laminação, sinterização, aciaria, mostrando indícios da aplicação deste importante artifício computacional de inteligência artificial nestas usinas.

Caporalli et al.⁽⁶⁶⁾, apresentaram o estágio de desenvolvimento do programa da Companhia Vale do Rio Doce junto à UFMG da aplicação das RNA's para a descrição quantitativa da relação entre microestrutura-propriedades-desempenho de minérios em processos de aglomeração e redução.

O processo de sinterização em esteira ou em panela poderia ser escrito em relações matemáticas referentes a fenômenos de transferência de calor e massa, secagem e condensação da água, fusão e solidificação de minerais individuais e em misturas e variação na granulação e na fração de vazios do leito. Reações químicas de liberação de água quimicamente ligadas, combustão do coque, decomposição de calcário, redução do CO₂, redução e oxidação da hematita e magnetita envolvendo CO, CO₂ e O₂, formação de ferritos de cálcio e assimilação dos minerais da ganga e sílica do líquido. Assim, pode-se classificar a sinterização de minérios de ferro como um processo complexo que envolve numerosos fenômenos físicos e químicos. Por este motivo, o modelamento matemático deste processo pode demandar um grande nível de esforço.

Ferramentas alternativas, como as RNA's, que buscam menores custos e prazos de modelagem matemáticas, são muito atrativas neste caso. As RNA's foram utilizadas para se prever, com um nível adequado de precisão, o desempenho de misturas de minérios numa dada prática de sinterização e a qualidade do sinter produzido, em função das características dos minérios. Um total de 26 variáveis de entrada foram selecionadas para a confecção do modelo, o qual deverá gerar 7 variáveis de saída. Cada variável de saída foi calculada

através de uma rede especificamente configurada e treinada para ela. Utilizou-se 43 exemplos (cada exemplo representando uma sinterização) sendo 38 exemplos utilizados para treinamento e 5 para validação da rede. Todas as redes construídas apresentaram uma diferença, em relação aos resultados experimentais, inferior ao grau de discriminação de cada variável de saída.

Prevost et al.⁽⁶⁷⁾, utilizaram uma RNA para o estudo de curvas de transformação dos aços. Alguns problemas ocorreram como a não-linearidade do fenômeno, incertezas de medidas, variáveis interdependentes. Soluções para estes problemas são sucessivamente apresentadas, conduzindo para uma RNA fracionada capaz de aprender equações diferenciais, informação qualitativa e tratar medidas experimentais com ruídos.

A simulação da curva de transformação isotérmica envolve algumas dificuldades como a complexidade dos efeitos e suas ligações (não existe modelo satisfatório de tratamento de calor dos aços); a baixa disponibilidade de curvas experimentais; a imprecisão de medidas experimentais e o fato de que alguns parâmetros não são definidos em cada exemplo.

O diagrama resultante da transformação de austenitização do aço depende dos parâmetros químicos do aço, das temperaturas e do tempo dispendido na austenitização. Os parâmetros de entrada da RNA multicamada foram constituídos da composição química de 5 elementos no aço ($C < 0,8\%$; $Mn < 1,5\%$; $Ni < 4\%$; $Cr < 3\%$; $Mo < 1,5\%$); da temperatura de austenitização ($850^{\circ}C < TA < 1000^{\circ}C$) e da temperatura de transformação após austenitização ($550^{\circ}C < TA < 850^{\circ}C$). Os parâmetros de saída foram o tempo inicial de transformação e o tempo final de transformação.

A rede usada neste trabalho foi uma rede neural fracionada. Nesta RNA, todo o peso de uma camada é multiplicado por valores de entrada da rede e o valor da saída da camada anterior.

Levén et al.⁽⁶⁸⁾, aplicaram RNA's em laminação. O programa usa algoritmo de aprendizado do tipo *backpropagation*. Para a previsão da força de laminação de encruamento utilizou-se como entrada a redução de encruamento, a espessura de entrada, a tensão da tira e o raio do cilindro de trabalho. Uma rede *feedforward* com 4 neurônios de entrada, 3 na camada oculta e um na saída, foi treinada com banco de dados gerados por um modelo de elementos finitos (MEF). O ajuste entre a RNA e o MEF atingiu um erro quadrático da ordem de 2~3%. Outras aplicações: previsão da força de laminação de tiras a quente, onde utilizou-se uma RNA com 5 entradas: velocidade da tira, temperatura da tira, fator de dureza do material, redução e a espessura de entrada, 3 neurônios na camada oculta e 1 saída. O erro quadrático ficou em torno de 5% e previsão da força de laminação de tiras a frio com uma RNA com 7 entradas: largura da tira, deslocamento do cilindro intermediário, força de laminação, ajuste do cilindro de encosto, redução, espessura no centro da tira e a espessura de entrada, 3 neurônios na camada oculta e 1 saída. O erro quadrático ficou em torno de 5%.

Kominami et al.⁽⁶⁹⁾, desenvolveram um sistema de RNA's *backpropagation* para a área de lingotamento contínuo. Em processos de lingotamento contínuo de aços, busca-se moldar o aço líquido oriundo de um distribuidor, com o objetivo de produzir placas. Durante o lingotamento do aço, pode ocorrer um problema de controle de temperatura que gera um fenômeno denominado *breakout*, que é o rompimento da camada externa em processo de solidificação na placa em lingotamento ocasionando vazamento de aço e, conseqüentemente, a perda do produto.

Um sistema de predição foi desenvolvido através da aplicação das RNA's. Quando implementadas em sistemas *on-line*, a predição de *breakout* pelas RNA's atingiu quase 100% de acerto, ajudando na previsão do problema e na tomada de atitudes corretivas. Foi utilizada uma RNA com 10 entradas (perfil térmico no molde de lingotamento), 8 neurônios na camada oculta e 1 saída (a indicação ou não do *breakout* - 0 ou 1).

Singh et al.⁽⁷⁰⁾ publicaram uma aplicação de redes neurais artificiais para predição de silício no gusa. O silício é uma das variáveis mais complicadas de serem previstas no

ferro líquido pois a sua concentração está associada às características oscilatórias das matérias primas, a um difícil equacionamento do tempo de residência destas matérias no equipamento, às condições de sopro do comburente e condições de topo do equipamento. Além disto, os fenômenos de transferência de massa que ocorrem na interface escória/gusa são forte influenciadores da partição do silício entre a escória e o gusa. Adicionadas a estas variáveis, as condições dos canais de corrida que recebem o gusa dos altos-fornos, também influem consideravelmente no teor final de silício no gusa. Assim, condições imprescindíveis a uma boa precisão do silício no gusa, envolvem variáveis em espaços de tempo diferentes, o que torna muito difícil a modelagem matemática, mesmo com redes neurais artificiais. Os autores conseguiram modelar o sistema e obtiveram um coeficiente de correlação igual 0,86, o que a nível industrial é um bom resultado. Para tal modelagem trabalharam com uma arquitetura neural de 18x3x1.

Antes da escolha da RNA como uma opção de solução de problemas de processo, é imprescindível a análise do banco de dados gerados neste processo para assegurar que este conjunto de dados seja confiável e significativo para caracterizar o processo. Além disto é importante salientar que a rede neural artificial não gera relações de conhecimento e, por este motivo, é de suma importância a análise dos resultados obtidos pelo ajuste do modelo matemático através do conhecimento técnico do processo.

Existem muitas configurações de RNA's que poderiam ser exploradas em estudos específicos, mas atualmente observa-se que a rede mais explorada é a do tipo *backpropagation*, devido à sua eficiência comprovada em várias aplicações e a facilidade de implementação.

Como foi visto anteriormente, já há evidência do interesse das indústrias siderúrgicas. Devido ao fato destas indústrias trabalharem com um volume muito grande de materiais em processos de redução, refino e laminação, conseqüentemente, um grande montante de dinheiro está envolvido nestes processos. E qualquer melhoria gera um grande benefício para a empresa.

Assim, existe uma boa expectativa de implementação de RNA's para a solução de problemas na indústria siderúrgica, pois nestas usinas são gerados um grande número de informações em aquisições de dados de processos e o retorno econômico, certamente, viabiliza o investimento técnico, um estímulo aos engenheiros que atuam em modelagem e simulação de processos. Para reforçar o otimismo, deve-se lembrar que existem processos complexos e que exigem respostas rápidas e as redes neurais artificiais se encaixam bem nesta necessidade.

CAPÍTULO 3 - ANÁLISE DO PROBLEMA

O problema a ser estudado é o baixo acerto de composição química e de temperatura do aço ao final do processo produtivo, que no caso da CSN está em torno de 44% de acerto simultâneo e é fortemente influenciado pela sua principal matéria prima, o gusa. Por sua vez, o gusa é fortemente influenciado por oscilações químicas, granulométricas e mineralógicas do sinter, que determinam as características metalúrgicas desta matéria prima

A solução para este problema poderia ser a diminuição da oscilação química do gusa e a melhoria dos ajustes dos modelos matemáticos (estático e dinâmico) ao processo. Entretanto, uma análise de processo indicou uma grande dificuldade de se modelar matematicamente o processo de redução que ocorre em altos-fornos e equipamentos periféricos. Alguns fatores que tornam inviáveis a modelagem, tanto convencional quanto por inteligência artificial podem ser citados abaixo:

- i. Variação do tempo de residência das matérias primas no interior dos altos-fornos, devido às oscilações operacionais;
- ii. Baixa frequência de caracterização química das matérias primas (se comparada com a frequência de análise química do gusa);
- iii. Inexistência de informações importantes do comportamento metalúrgico do sinter e do minério de ferro, referentes à resistência à degradação a quente e à redutibilidade;
- iv. Inexistência de monitoramento do comportamento das matérias primas e de sua transformação no interior do reator.

A figura 3.1 ilustra um diagrama de árvore considerando o campo de máquinas, método, mão-de-obra, meio ambiente, medida e matéria prima, que organiza os principais problemas em altos-fornos e aciaria, que influem no problema do baixo acerto de teor de carbono e da temperatura do aço. Dentre os vários motivos que determinam diminuição de controle do processo de refino, os relacionados a erros de medida/calibração de equipamentos e a erros de procedimento são problemas de menor contribuição no efeito

indesejável, pois as empresas atuam de forma contínua nestes segmentos. Sobram assim, os problemas crônicos relacionados às matérias primas, que se estendem por vários anos nas empresas siderúrgicas por motivos que combinam paradigmas, desconhecimento de alternativas de solução de problemas e de uma certa forma, a convivência com o problema, através da possibilidade de se contornar o problema com outras soluções que não as que realmente atingem o objetivo. As simplificações de modelagem matemática são outro ponto de pouca atuação, apesar da tentativa de melhoria dos modelos convencionais.

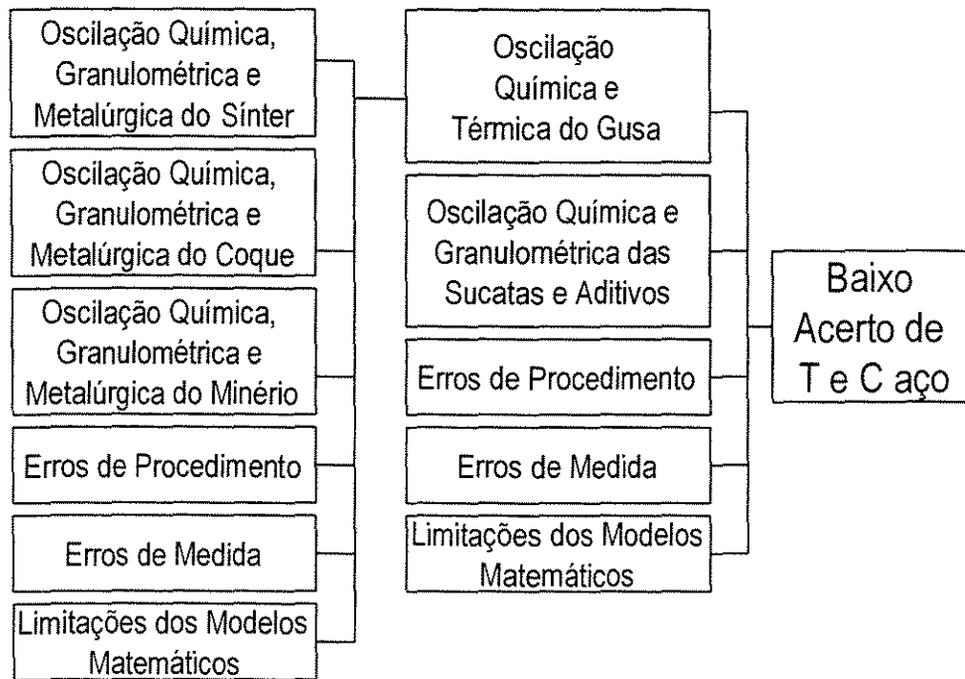


Figura 3.1 – Diagrama de Árvore para a avaliação do problema em estudo.

Os problemas de matérias primas, tanto para altos-fornos quanto para aciaria, estão relacionados às oscilações de características químicas, granulométricas e térmicas e à falta de informação de propriedades metalúrgicas de algumas matérias primas.

Observando-se os gráficos da figura 3.2, numa análise simplificada (com o conceito de análise de pareto), é fácil identificar que destas matérias primas as que merecem maior atenção são as que contribuem mais para o efeito indesejável, ou seja, o gusa, proveniente dos altos-fornos e o sínter, que influem mais na qualidade do gusa.

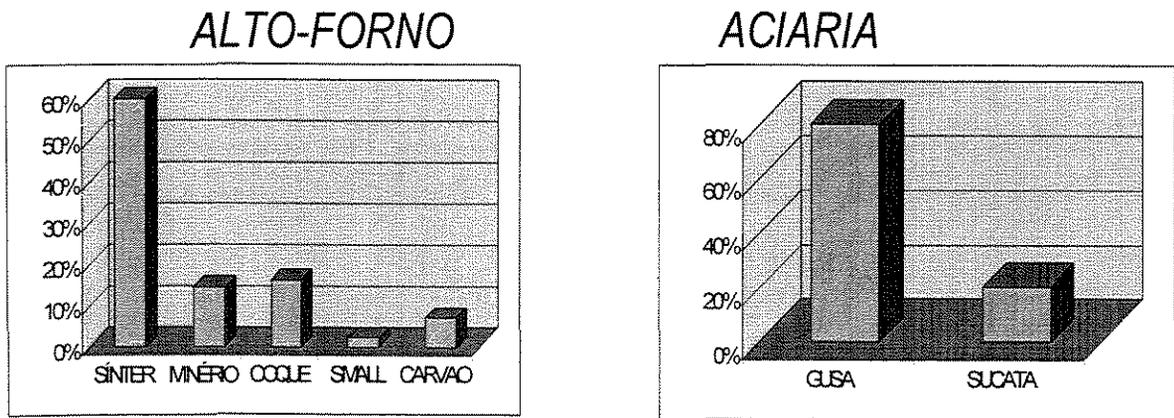


Figura 3.2 - Contribuição das matérias primas na produção do gusa e do aço na CSN.

Assim, numa reorganização do diagrama de árvore para priorização dos temas a serem estudados, chega-se ao diagrama da figura 3.3, onde se define que a atuação deve se concentrar na diminuição da oscilação do gusa e melhoria de previsibilidade pelos modelos estático e dinâmico da aciaria.

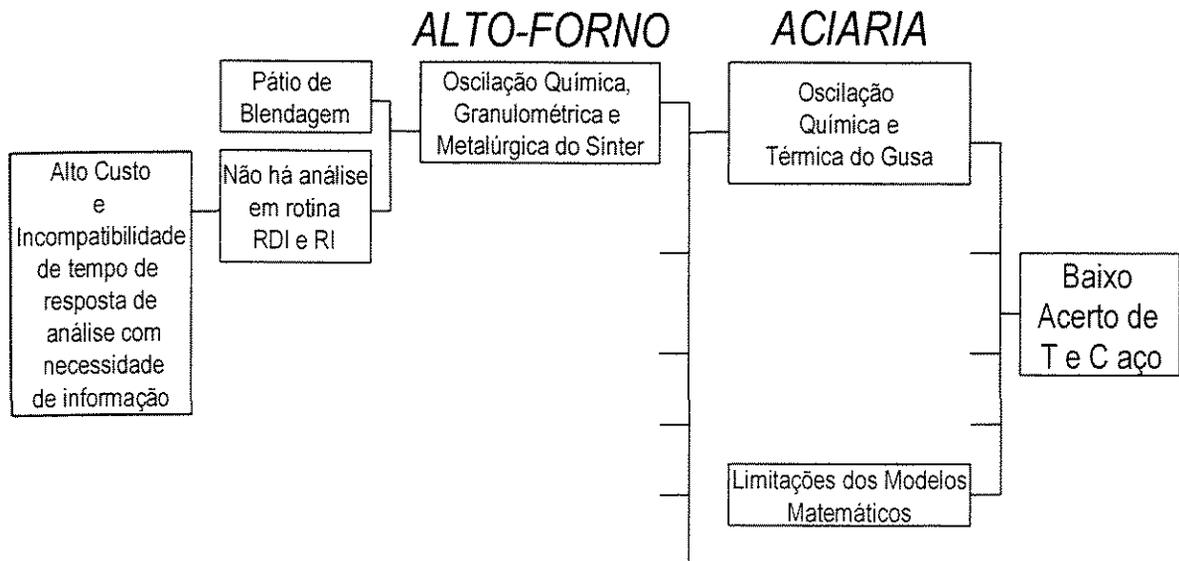


Figura 3.3 – Diagrama de Árvore priorizado para a avaliação do problema em estudo.

Com a necessidade de melhoria do acerto simultâneo de teor de carbono e de temperatura do aço e a impossibilidade de atuação imediata em melhoria da qualidade do

gusa, devido principalmente aos problemas de qualidade das matérias primas, optou-se neste trabalho atuar-se em dois grandes problemas:

- i. A falta de informações de propriedades metalúrgicas do sinter, mais especificamente, de RDI e RI do sinter, que contribuem fortemente para as oscilações operacionais na produção do gusa pelos altos-fornos, pois influenciam na geração de finos (e na permeabilidade dos altos-fornos) e na variação da redutibilidade do sinter, gerando oscilações térmicas no processo de produção do gusa e conseqüentemente, oscilações nas propriedades deste produto, como pode ser verificado por uma análise realizada entre outubro de 2000 e abril de 2001 (figura 3.4);
- ii. O fraco acerto na previsão da qualidade do aço, estruturando um sistema de auxílio que saiba atuar com as oscilações químicas e térmicas do gusa.

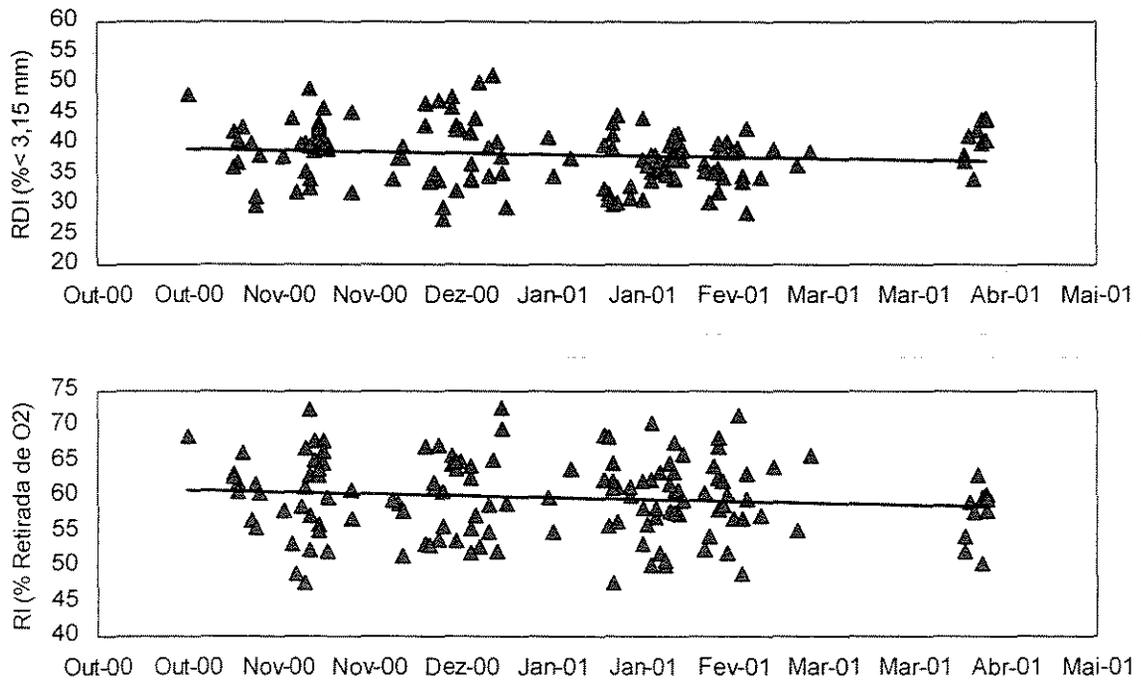


Figura 3.4 - Resultados do acompanhamento da variação de RDI e RI do sinter.

Assim, está sendo idealizado um desenvolvimento primário para o problema que ainda não se conseguiu resolver (a oscilação da qualidade do gusa) pela melhoria do modelo de previsão da qualidade do aço, pela utilização de uma rede neural artificial que aprenda a lidar com as oscilações do gusa e, para não deixar a causa do problema sem solução (a oscilação da qualidade do gusa), começou-se a caminhar em busca da otimização das matérias primas, atuando na principal matéria prima dos altos-fornos. Esta ação possibilitará, junto à outras ações, na melhoria da qualidade do gusa e, portanto, na melhoria ainda maior da qualidade do aço (por esta melhoria do sínter e, conseqüentemente, do gusa e pela melhoria do aço pelo ajuste fino com modelo de redes neurais).

De acordo com a figura 3.5, os problemas definidos como objetos de estudo, utilizarão a mesma ferramenta, as redes neurais artificiais, com finalidades diferentes que ajudarão, inclusive, a entender as simulações numéricas realizadas em dois problemas distintos. Este estudo será ainda mais rico pois as simulações e aplicações passarão por três âmbitos: a simulação numérica, o estudo laboratorial (processo piloto e caracterização) e a aplicação industrial.

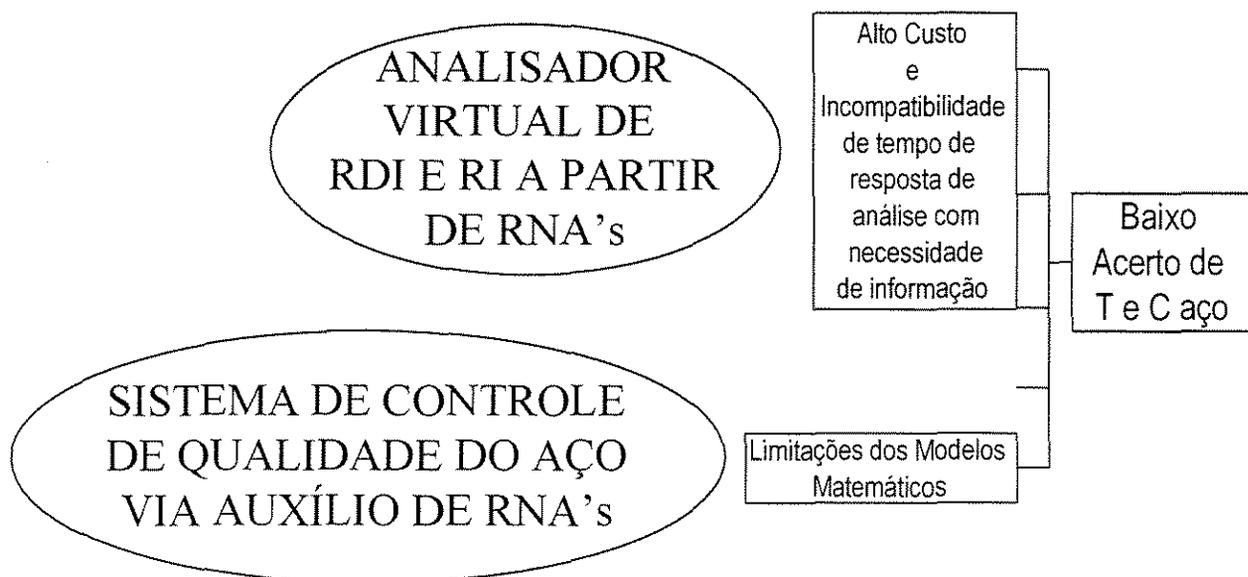


Figura 3.5 – Definição dos problemas e proposta de solução.

CAPÍTULO 4 - MATERIAIS E MÉTODOS

4.1 DESENVOLVIMENTO DA FERRAMENTA REDES NEURAIS ARTIFICIAIS

Para se possibilitar a execução do que foi planejado, foi desenvolvida uma rede neural artificial, baseada nas referências Wasserman⁽⁴³⁾, Kovács⁽⁴⁴⁾, Fileti⁽⁴⁵⁾ e Haykin⁽⁴⁶⁾. O modelo desenvolvido está descrito no Anexo B.

A modelagem matemática do algoritmo de treinamento *Backpropagation* foi desenvolvida em Visual C ++, em versão 7.0 e possui as seguintes características:

- i. Modelo de cálculo em “*batch-mode*” (figura 4.1), lógica de treinamento sugerida por Barnard-Holm⁽⁴⁸⁾ ;
- ii. Visualização Gráfica da Generalização e Erro de cada valor de cada neurônio de saída, a cada iteração, possibilitando parada da RNA no momento oportuno, ou seja, quando houver máxima generalização (concordando com a sugestão de Schmidt et al.⁽⁵⁷⁾);
- iii. Possibilidade de se trabalhar com uma ou duas camadas ocultas, flexibilizando não só a escolha do número de neurônios ocultos como também do número de camadas ocultas;
- iv. Possibilidade de se escolher a função de ativação (sigmoideal ou tangente hiperbólica), assim como os limites inferiores e superiores destas funções;
- v. Possibilidade de se escolher os erros relativos entre a variável calculada e a real apresentada à RNA, de acordo com o desejável para cada processo;
- vi. Possibilidade de variação dos parâmetros de velocidade de convergência e desempenho, conforme desejo do simulador, ou seja, pesos iniciais , tamanho do banco de dados de treinamento e de verificação e parâmetros de aprendizagem e de *momentum*;
- vii. O arquivo de entrada utilizado deverá ser configurado com uma matriz onde cada linha corresponda a uma corrida (ou experiência do processo para a produção de uma

saída (ou várias)). As primeiras colunas receberão as variáveis de entrada e as últimas colunas indicarão as saídas;

- viii. Os arquivos gerados pelo programa são três: um arquivo de saídas reais e calculadas pela rede, para o banco de dados utilizado no momento da verificação, um arquivo com o comportamento da generalização ao longo do processamento e um arquivo de pesos, que deverá ser utilizado pelos programas para atuação no processo.

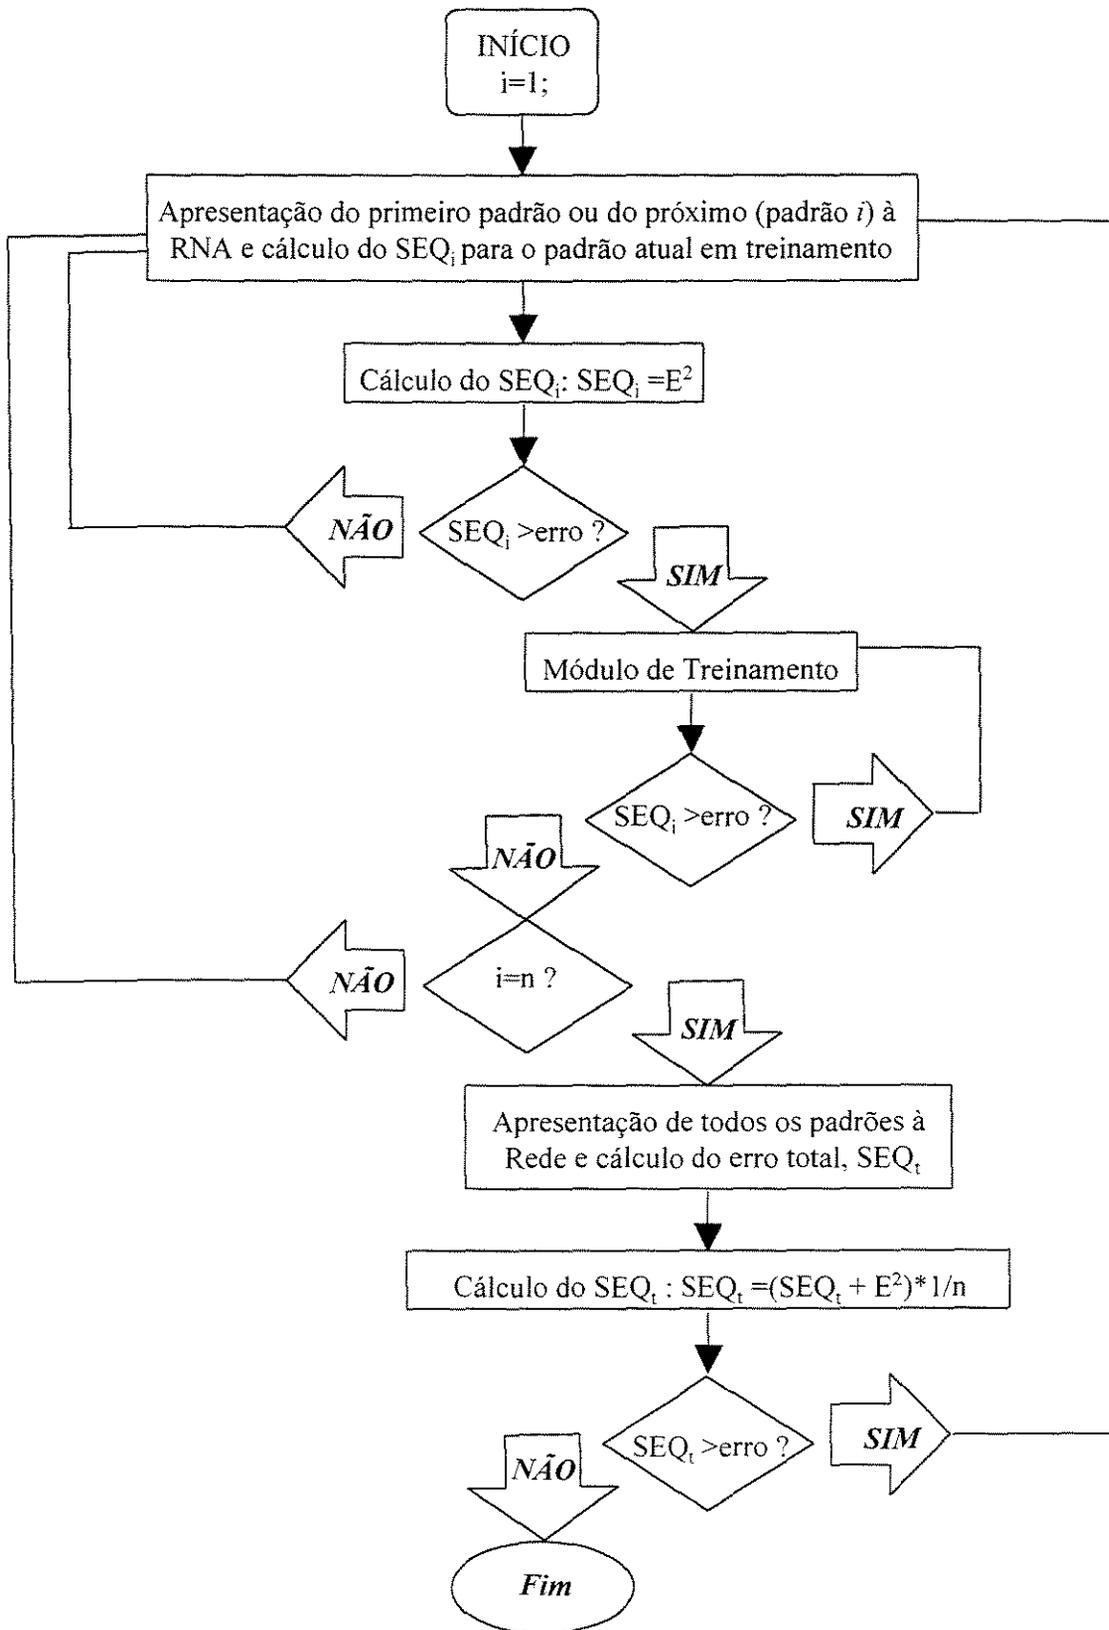


Figura 4.1 – Fluxograma da lógica de treinamento *BATCH-MODE*.

4.2 O PLANEJAMENTO DE EXPERIMENTOS FATORIAL

A outra importante ferramenta necessária neste trabalho, utilizada tanto para planejamento e organização de experimentos quanto para análise dos resultados foi o planejamento de experimentos. A técnica de planejamento de experimentos fatorial Neto et al.⁽⁷¹⁾ deve ser empregada quando há a necessidade de se variar vários parâmetros ao mesmo tempo. Esta técnica é bastante eficiente, seja nos planejamentos completos (onde se realizam todos os experimentos, geralmente em duplicatas) ou nos planejamentos incompletos (fracionados ou saturados, onde se reduzem a quantidade de ensaios pelo emprego de técnicas específicas).

O planejamento de experimentos é muito útil na determinação de quais variáveis são as mais influentes na resposta desejada e quais interações também tem forte efeito nestas respostas (pois é comum num estudo de muitas variáveis encontrar-se interações com efeitos mais fortes nas respostas do que efeitos principais, que são as variáveis do processo).

A técnica de planejamento de experimentos fatorial é executada da seguinte maneira:

- i. Escolha das variáveis controladas pelo experimentador (fatores) do processo que se deseja avaliar;
- ii. Escolha das variáveis de saída (respostas de interesse) que serão avaliadas de acordo com o processo;
- iii. Escolha dos níveis (mínimo, máximo e intermediários) de cada fator que será variado;
- iv. Atribuição de sinais à tabela de planejamento, como no exemplo abaixo, que ilustra o planejamento de experimentos de dois fatores em dois níveis (máximo, com o valor “+” e mínimo, com o valor “-“), caracterizando um planejamento fatorial 2^2 :

Tabela 4.1 - Planejamento Fatorial 2².

Ensaio	Média	Fator 1	Fator 2	Interação entre os dois Fatores	Resposta
1	+	-	-	+	R1
2	+	+	-	-	R2
3	+	-	+	-	R3
4	+	+	+	+	R4

A formação da tabela segue o seguinte:

- i. Atribuição de valores positivos à coluna das médias das respostas (+);
- ii. Atribuição de valores positivos e negativos na coluna do primeiro fator, alternando os valores positivos e negativos, linha a linha, da primeira coluna;
- iii. Atribuição de valores positivos ou negativos nas duas primeiras linhas e negativos (se escolhidos positivos para as duas primeiras linhas) ou positivos (se vice-versa) nas duas últimas linhas na coluna do segundo fator;
- iv. Cálculo dos sinais para a interação entre os dois fatores, pela multiplicação dos sinais das duas colunas.

Desta forma, passa-se ao cálculo de matrizes para obtenção dos efeitos principais e de interação e da média das respostas (obtida pela primeira coluna). Neste exemplo, gera-se uma matriz 4 x 4, que inclui as médias, os fatores e a interação:

+	-	-	+
+	+	-	-
+	-	+	-
+	+	+	+

O vetor coluna organiza os dados das respostas:

$$\begin{pmatrix} R1 \\ R2 \\ R3 \\ R4 \end{pmatrix}$$

Cada efeito principal é o resultado da média do fator que está sendo analisado em função da variação dos outros fatores. E o cálculo dos efeitos são operações que envolvem a multiplicação da matriz de planejamento com o vetor coluna de respostas (ou matrizes, para o caso de mais de um tipo de resposta avaliada). Assim, neste exemplo, as médias são obtidas pelo somatório da multiplicação dos elementos da coluna das “médias” com os elementos do vetor coluna “respostas” e pela divisão do valor obtido pelo número de ensaios e os cálculos dos efeitos e da interação entre eles segue o mesmo procedimento, só que dividindo o valor obtido para cada efeito ou para a interação pelo número de ensaios e por 2 (relativos ao número de níveis escolhidos para análise).

A técnica de planejamento de experimentos foi empregada nas seguintes necessidades: ajustes dos experimentos para sinterização piloto, ajuste do banco de dados para compor as necessidades mínimas de amplitude de cada componente químico do sinter e para os ajustes de todas as redes neurais estudadas.

4.3 EXPERIMENTOS PILOTO E CARACTERIZAÇÃO LABORATORIAL

Para o estudo específico do processo de sinterização, foram realizadas experiências em sinterizações piloto com o objetivo de se conhecer a influência da variação da composição química da mistura a sinterizar na formação mineralógica do sinter, já que a composição mineralógica não é rastreada pelo sistema de controle de qualidade da empresa.

A planta piloto de produção de sinter da CSN possui os seguintes equipamentos (observe Anexo C):

- i. Balanças para pesagem das matérias primas;
- ii. Misturador e micropelotizador, onde as matérias primas são homogeneizadas e, posteriormente, com a adição de água, ocorre a formação das micropelotas;
- iii. Ponte Rolante, para abastecimento da caixa de recebimento de matérias primas;
- iv. Caixa de Sinterização, com capacidade de 110 kg de mistura a sinterizar;
- v. Equipamento de ignição;
- vi. Sistema de Sucção dos Gases;
- vii. Equipamento de tamboramento;
- viii. Sistema de Peneiramento;
- ix. Sistema de controle do perfil térmico e do tempo de sinterização controlado por computador.

Nestes equipamentos, a seqüência de atividades é a seguinte:

- i. Homogeneização das matérias primas, para minimizar efeitos de dispersão química, granulométrica e mineralógica e assegurar a mesma qualidade de matéria prima para todos os ensaios;
- ii. Quarteamento das matérias primas e preparação de amostras para análise química;

- iii. Análise Química de CaO, SiO₂, MgO, Al₂O₃, P, Mn e Fe total de todas as matérias primas. Análise imediata de combustíveis sólidos (matéria volátil, cinzas e carbono fixo);
- iv. Definição da proporção de mistura pelo balanço de massa e energia;
- v. Pesagem das matérias primas, para compor o leito de sinterização;
- vi. Mistura das matérias primas;
- vii. Micropelotização, com a adição de água;
- viii. Transporte das micropelotas até a caixa de sinterização;
- ix. Ignição da superfície da mistura;
- x. Sucção dos gases, forçando o deslocamento da frente de queima com a combustão do coque de cima para baixo dentro da caixa de sinterização;
- xi. Resfriamento do Sínter;
- xii. Estabilização do Sínter em sistema de tamboramento;
- xiii. Peneiramento do Sínter Bruto em Peneira de 5mm, para a produção de sínter produto (com granulometria superior a 5 mm) e finos de retorno (com granulometria abaixo de 5 mm).

Para desenvolver os testes piloto, seguiu-se a técnica de planejamento de experimentos fatorial, não com o objetivo de se avaliar os efeitos das variáveis, mas para se variar a composição em peso do leito de sinterização, objetivando o conhecimento da variação mineralógica.

Tabela 4.2 – Níveis de componentes na mistura segundo planejamento de experimentos fatorial.

	% C na mistura	% SiO ₂	% CaO
Nível Máximo	4,2	5,2	10,0
Nível Intermediário	3,4	-	-
Nível Mínimo	2,5	4,2	8,2

Assim, de acordo com a tabela 4.2, foram realizados 12 ensaios em duplicatas

objetivando a produção de sínteres para a avaliação do RDI e do RI. Estas simulações visam a simular as condições de maior peso nos processos de sinterização da CSN, ou seja, variação de aporte térmico, de basicidade e de volume de escória, uma vez que a variação dos outros componentes químicos não influenciam de forma tão significativa quanto os simulados neste trabalho.

As proporções de mistura para estes testes variaram da seguinte forma:

Tabela 4.3 – Proporções de mistura para as sinterizações.

Sinter Feed	Finos de Retorno	Calcário	Dolomito	Finos de Coque	Cal Calcítica
55 a 60%	23 a 26%	8,5 a 11,5%	2 a 3,2%	3 a 5%	1,5%

A umidade de mistura foi mantida em 5,7%.

Os ensaios de RDI e RI e de análise mineralógica foram realizados de acordo com os procedimentos descritos no Anexo D.

De acordo com a literatura citada neste trabalho, observa-se que a qualidade do sínter é influenciada por diversos fatores, determinados a partir da escolha da qualidade e tipo de matérias primas que irão compor o leito de sinterização, do uso adequado dos balanços mássicos e térmicos e da definição das condições operacionais. O produto fabricado a partir destas condições preestabelecidas irão atribuir ao sínter características mineralógicas que definirão importantes propriedades ditas metalúrgicas a este produto, tais como resistência à frio, resistência dentro dos altos-fornos (em atmosfera quente e redutora) e capacidade de redução dentro destes mesmos reatores.

Observa-se também na literatura que o assunto sínter é bastante complexo, principalmente pelo fato das usinas siderúrgicas mundiais praticarem diferentes processamentos, de acordo com as necessidades econômicas e de ofertas de diferentes

matérias primas para a produção do sinter. Entretanto, muitas informações quantitativas e, principalmente, qualitativas, podem ser aproveitadas para aplicação nos processos da CSN. E para realizar um trabalho que indique o caminho a ser tomado pela CSN, em função das características do processo de fabricação do sinter desta empresa, foi realizado nas dependências do centro de pesquisas da CSN, sinterizações piloto com o objetivo de se avaliar um mecanismo de formação das fases mineralógicas que governam atualmente o processo de sinterização da CSN.

Sínteres foram produzidos para a avaliação do RDI e do RI buscando-se correlacionar a influência da variação química normal do sinter e cobrir as possíveis variações mineralógicas e metalúrgicas do produto, para indicar à próxima fase do trabalho os caminhos para a modelagem com redes neurais artificiais.

4.4 MODELAGEM DO ANALISADOR VIRTUAL DE RDI E RI DE SÍntER

O problema em questão trata-se da inviabilidade técnica e econômica de se produzir resultados de análise de RDI e RI na mesma frequência da análise química, através dos ensaios convencionais. Na CSN, são coletadas cerca de 8 amostras por sinterização por dia, o que equivale a 24 resultados de análise química diariamente. Nesta frequência, ensaios de RDI e RI gerariam algo em torno de US\$ 1,5 milhões de custos por ano para a área de redução, o que provocaria um grande aumento no custo do gusa (e a CSN é altamente competitiva no mercado mundial justamente por produzir o gusa com o menor custo do mundo).

Os ensaios de RDI são possíveis de serem realizados nesta frequência, pois o tempo de ensaio é similar, cerca de uma hora a mais que o necessário para análise química, o que pode ser compensado pelo tempo de residência do sinter desde a produção até o consumo em altos-fornos (cerca de 15 a 18 horas). Mas os ensaios de RI, necessários em duplicata tanto como o RDI, necessitariam de cerca de 15 a 18 horas, contando o tempo desde a amostragem, a preparação de amostra para os ensaios de RI e os ensaios

propriamente dito. Ou seja, um tempo às vezes igual e outras vezes maior que o tempo de produção e transporte do sinter para o consumo em altos-fornos.

Assim sendo, observa-se que os resultados de RDI são possíveis, tecnicamente, de serem implantados em linha, mas os de RI não. Além disto, haveria a necessidade de um grande investimento em fornos para estes ensaios, pois para dar vazão aos resultados, vários fornos deveriam ser instalados em paralelo. Profissionais (pelo menos quatro) deveriam ser contratados e treinados para realizar os testes.

Para resolver este problema técnico-econômico, que se estende pelas indústrias brasileiras e mundiais, que querem ter os resultados e não os conseguem devido aos problemas já citados, propõe-se neste trabalho um modelo de previsão de RDI e RI baseado em redes neurais artificiais, que objetiva prever essas propriedades através de análises químicas (já existentes) e/ou de análises mineralógicas, a serem desenvolvidas. A estes inferenciadores baseados em redes neurais artificiais deu-se o nome de Analisadores Virtuais.

Numa rápida análise, de acordo com o que foi comentado na literatura sobre sinterizações, está claro que os resultados de análise química são somente uma forma de inferir a mineralogia do sinter, pois é o arranjo dos componentes e elementos químicos que formam as fases mineralógicas. Assim, é de se esperar que os resultados com as análises mineralógicas sejam superiores aos obtidos por análises químicas, ou seja, os erros obtidos entre a previsão de RDI e RI sejam menores. Entretanto, é necessário avaliar se os erros obtidos pelo modelo com análises químicas são ou não aceitáveis, uma vez que já existem em linha. Se não são suficientes, aí sim a empresa deverá optar pelo uso das análises mineralógicas, que podem ser realizadas, desde a preparação da amostra (britagem abaixo de 3,15 mm, embutimento, lixamento e polimento) até o resultado final (obtido via microscópio ótico ou analisador de imagens) em cerca de duas horas e o custo de ensaio é desprezível se comparado aos ensaios de RDI e RI. Estes poderiam ser realizados pelos técnicos já existentes, devidamente treinados, pois envolvem poucas atividades.

A verdade é que, mais cedo ou mais tarde, em busca da excelência do produto sinter, as empresas deverão adotar os resultados mineralógicos como fonte de informações para a tomada de decisão, pois são a forma mais avançada existente de se entender o que acontece com o produto quando este é submetido ao consumo em altos-fornos ou aos testes de resistência a frio, como quedas, abrasão, peneiramento, entre outros.

A modelagem envolveu duas propostas de redes neurais:

- i. Uma rede neural completa, considerando todas as variáveis necessárias, cabendo ao simulador a escolha das principais variáveis. Esta opção envolveria a necessidade de treinamento do laboratório para a implantação em rotina de análise mineralógica. Atribuiu-se o nome de analisador virtual completo a este modelo;
- ii. E uma rede neural composta somente de componentes químicos no modelo de previsão, o que possibilitaria a implantação do modelo sem qualquer mudança no que já existe, pois a análise química já é uma rotina. Atribuiu-se o nome de analisador virtual simplificado a este modelo.

Para chegar à modelagem por redes neurais artificiais, um longo caminho teve de ser percorrido, com o envolvimento de um grande grupo de pessoas que prepararam os dados para os devidos fins. A figura 4.2 resume o grupo de atividades realizadas.

A modelagem da previsão de RDI e RI por redes neurais envolveu cerca de 30 pessoas, distribuídas pelos setores de produção do sinter, área de informações técnicas da metalurgia da redução, grupo de pessoas que reforçaram os ensaios laboratoriais (oriundos da coqueria e dos altos-fornos), pessoas do centro de pesquisas e do laboratório interno da redução e da aciaria.

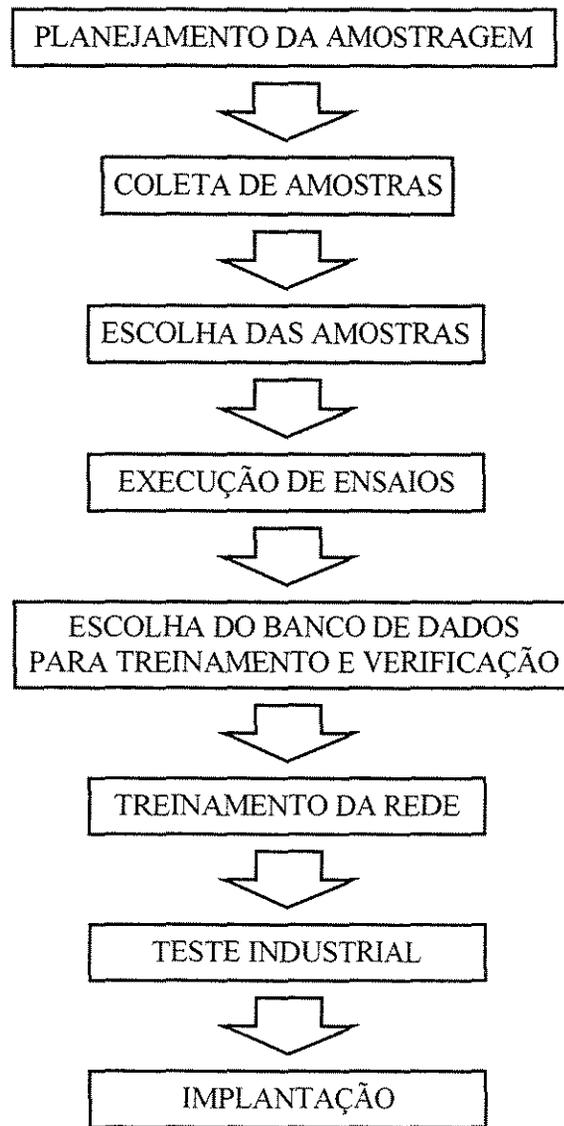


Figura 4.2 - Atividades para se desenvolver um modelo de RNA's em processo de sinterização.

Um dos grandes obstáculos ao desenvolvimento de qualquer modelagem é, justamente, este grande volume de atividades, pois envolve a necessidade de um grande volume de dinheiro para se viabilizar desde a amostragem até a execução do produto, neste caso, o modelo de previsão.

As atividades foram iniciadas com a coleta de amostras, que durou seis meses. Cerca de 800 amostras foram coletadas das três sinterizações da CSN, com o intuito de se conseguir rastrear as dispersões químicas características de cada processo. Destas, 128

foram escolhidas mantendo-se a amplitude química dos componentes/elementos principais, tais como CaO, FeO, MgO, SiO₂, Al₂O₃, Mn e P. Nesta etapa do trabalho, foram realizadas eliminações de amostras por similaridade química. Por último, utilizando a técnica de planejamento de experimentos fatorial, foram escolhidas amostras para caracterizações metalúrgicas e mineralógicas, observando os níveis máximo, intermediário e mínimo dos fatores principais CaO, FeO e SiO₂ e os níveis máximo e mínimo de Al₂O₃ e MgO, componentes químicos minoritários. De acordo com a técnica de planejamento de experimentos, para atender estes níveis para cada fator, ou seja para cada componente químico do sinter, seriam necessários 108 amostras de sínteres (3³ x 2² amostras de sinter). As outras 14 amostras foram utilizadas para a verificação da rede treinada. Uma análise estatística foi realizada com estas 122 amostras, com o intuito de se garantir a distribuição normal das variáveis químicas e mineralógicas (Anexo E).

Tabela 4.4 - Níveis das variáveis escolhidas para o desenvolvimento.

	Nível Mínimo	Nível Intermediário	Nível Máximo
% CaO	Entre 8,8 e 9,4	Entre 10,3 e 10,5	Entre 11,0 e 11,4
% SiO ₂	Entre 4,1 e 4,4	Entre 4,7 e 4,8	Entre 5,2 e 5,6
% FeO	Entre 4,6 e 4,8	Entre 6,0 e 6,2	Entre 7,4 e 8
% Al ₂ O ₃	Entre 0,69 e 0,77	Não foi considerado	Entre 1,03 e 1,14
% MgO	Entre 0,73 e 0,85	Não foi considerado	Entre 1,2 e 1,3

Assim, para as 128 amostras, foram executados ensaios em duplicata de RDI, RI e análise mineralógica.

Para o primeiro modelo estudado, o de previsão de RDI e RI em função de análise química do sinter, simulações preliminares ao estudo com planejamento de experimentos indicaram que o arranjo ideal para os componentes químicos foi o conseguido segundo a figura 4.3.

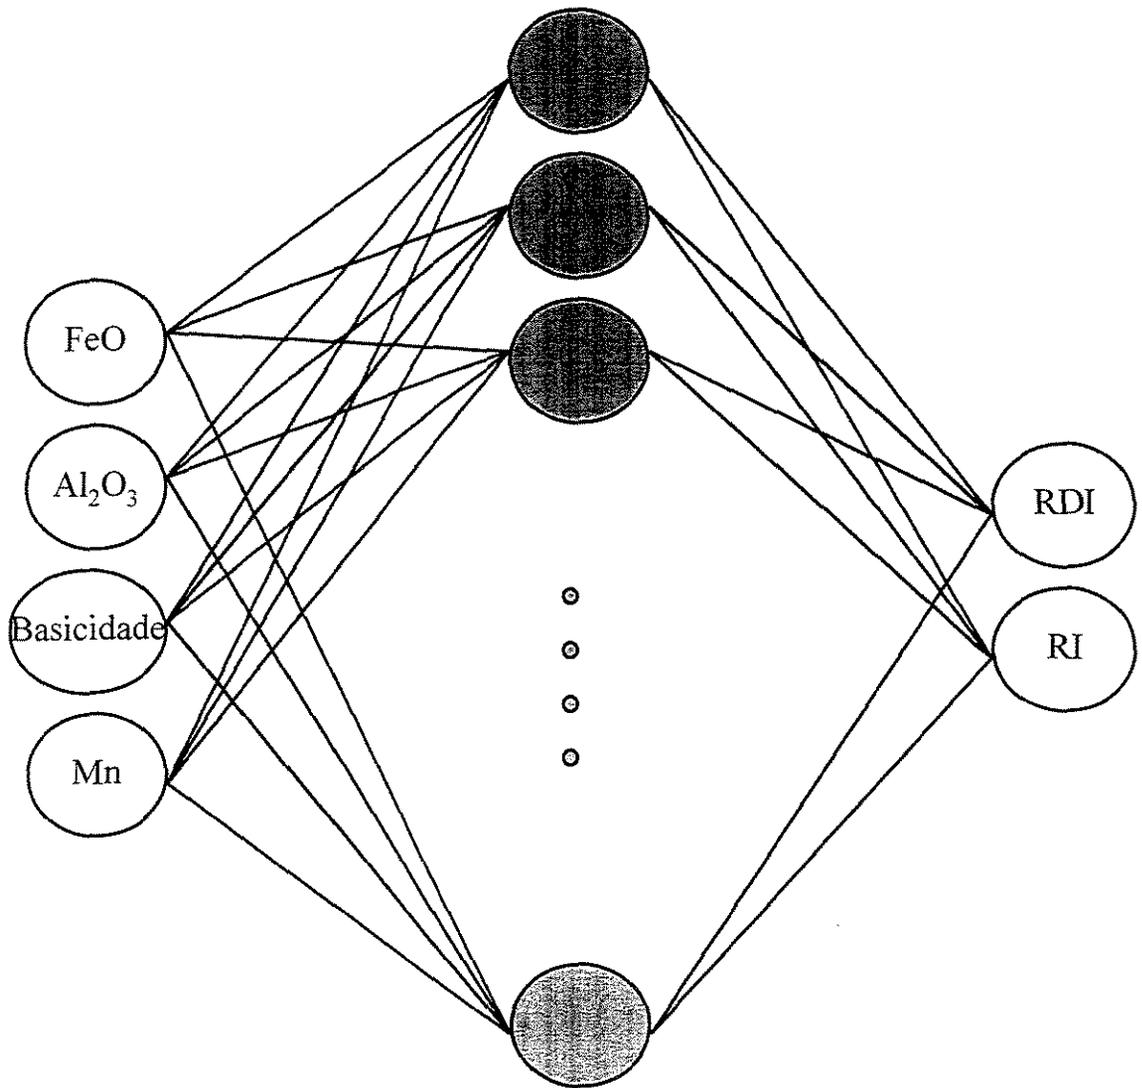


Figura 4.3 – Analisador Virtual Simplificado: Estrutura Neural de Previsão de RDI e RI a partir de análises químicas.

Para tanto foram simulados vários arranjos, com volume de escória, percentuais de CaO, MgO, SiO₂ e os componentes indicados na figura 4.3. Após a definição das variáveis principais necessárias às simulações, foram estudadas as variações e as combinações dos parâmetros das redes neurais, em busca dos melhores resultados.

Para o ajuste dos parâmetros da rede neural artificial foi empregada a técnica de planejamento de experimentos. Para se planejar as simulações numéricas é necessário determinar quais são os fatores, ou seja, quais são as variáveis controladas pelo simulador

(ou experimentador) e quais são os níveis destes fatores que devem ser simulados. Com os fatores (parâmetros de ajuste das RNA's) e os níveis destes fatores, buscou-se avaliar qual a combinação que produz a melhor generalização.

O programa desenvolvido neste trabalho possui o artifício de se acompanhar “on-line” o comportamento gráfico da generalização de acordo com a evolução do treinamento. Assim, a generalização máxima obtida numa determinada simulação foi o critério de comparação entre todo o planejamento de experimentos.

Os fatores escolhidos neste trabalho para o ajuste das redes neurais e os respectivos níveis de cada fator resultaram num planejamento fatorial completo 2⁶. A tabela 4.5 registra os fatores, assim como seus níveis estudados.

Tabela 4.5 - Fatores e Respectivos Níveis dos Parâmetros da RNA.

Fatores	Nível Mínimo	Nível Máximo
Coeficiente de Aprendizado	0,1	0,7
Coeficiente de Momentum	0,1	0,7
Tipo de Função de Ativação	Sigmoidal	Tangente Hiperbólica
Bias Residuais da Primeira Camada	0	1
Bias Residuais das Demais Camadas	0	1
Pesos Iniciais	Entre -1 e +1	Entre -0,1 e 0,1

Este planejamento fatorial foi realizado para cada arquitetura de rede previamente escolhida de acordo com a literatura. Algumas arquiteturas de rede foram simuladas, como as sugeridas na literatura (tabela 4.6).

Tabela 4.6 - Arquiteturas de Rede Sugeridas na Literatura.

Autores da Formulação de Arquitetura	Formulação de Arquitetura
Hecht-Nielsen ⁽⁵¹⁾	RNA com 3 camadas: $2n+1$
Lippmann ⁽⁵³⁾	RNA com 3 camadas: $s.(n+1)$
Villiers e Barnard ⁽⁴⁹⁾	RNA com 4 camadas: $Xn1 = Xn2$
Maren ⁽⁵²⁾	$3Xn1:Xn2$
Lippmann ⁽⁵³⁾	$Xn2 = 2s$

Os erros máximos permitidos para as duas variáveis, RDI e RI, durante o treinamento foram 10%.

A comparação das redes de três e de quatro camadas foi realizada buscando-se o mesmo número de neurônios ocultos e/ou o mesmo número de conexões (sinápses) entre as duas estruturas, conforme sugerido por Villiers e Barnard⁽⁴⁹⁾.

A organização das simulações através do planejamento de experimentos fatorial é interessante também para a avaliação da interação das variáveis controladas, que, às vezes, pode ter um efeito maior que uma variável considerada principal. Para este trabalho, optou-se por considerar nos cálculos dos efeitos de cada variável e das interações, interações com até três variáveis principais. Esta simplificação é comum na aplicação desta técnica pois, interações com três variáveis, na grande maioria dos casos, geram efeitos fracos, sem grande importância no contexto global. Assim, optou-se aqui por desprezar os efeitos da interação entre quatro fatores e acima e avaliar-se o efeito em até três interações.

Antes do estudo com planejamento de experimentos para mineralogia, foram estudadas quais as variáveis seriam necessárias à obtenção dos melhores resultados, de forma similar ao estudo com o modelo de previsão a partir de análise química. Foram consideradas todas as variáveis químicas e mineralógicas inicialmente. Mas o melhor resultado obtido foi com a arquitetura sugerida na figura 4.4.

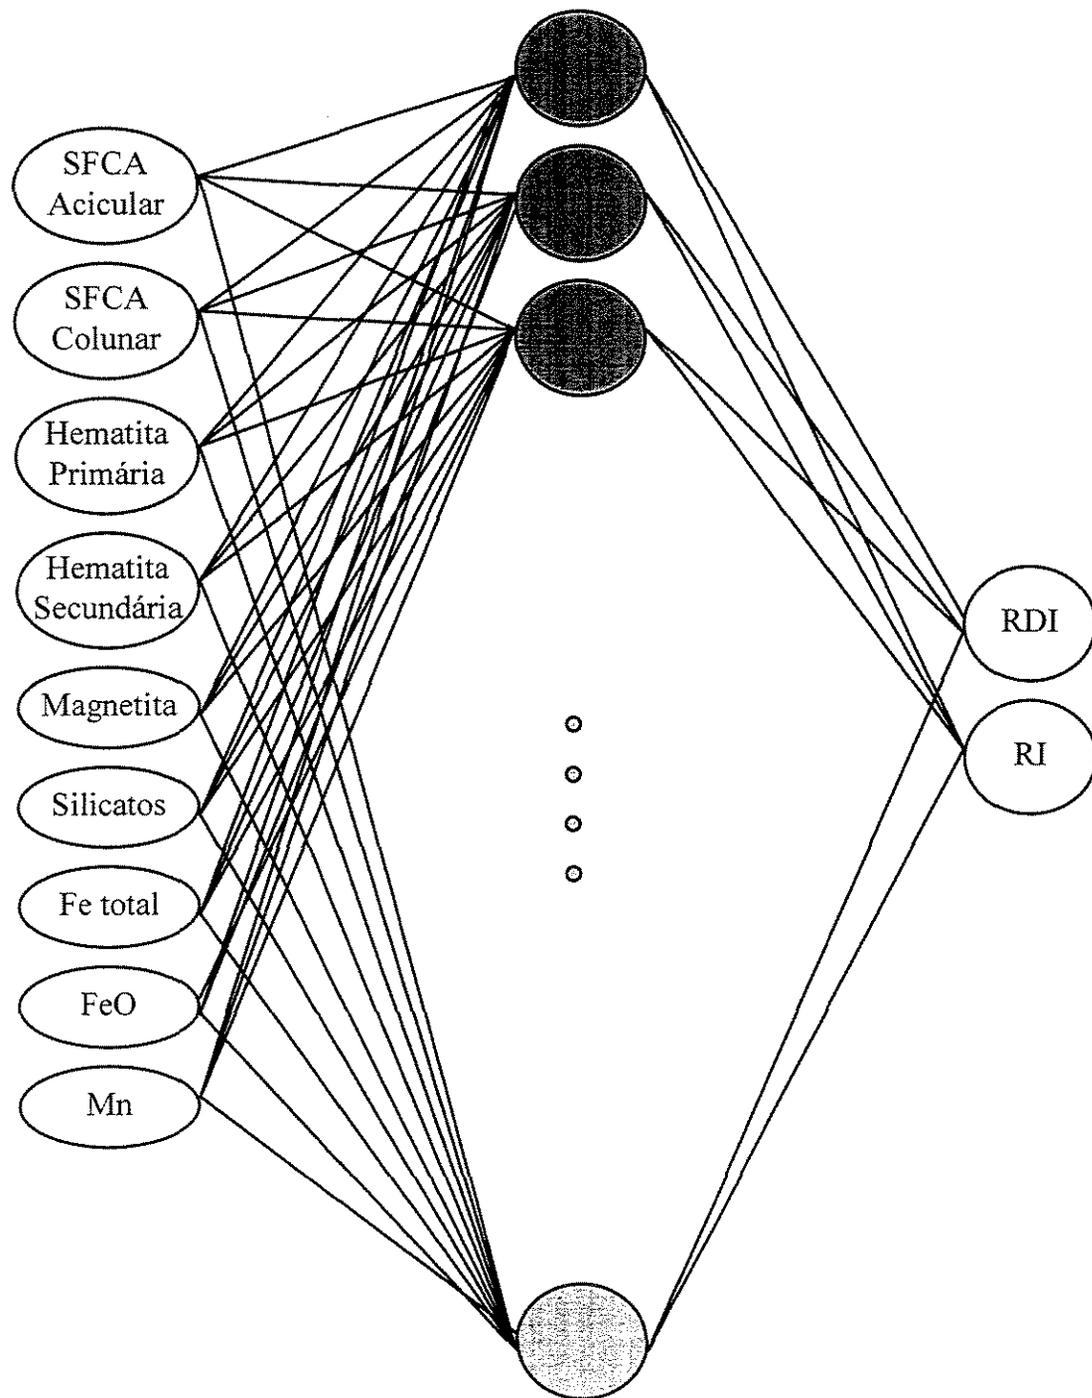


Figura 4.4 – Analisador Virtual Completo: Estrutura Neural de Previsão de RDI e RI a partir de análises químicas e mineralógicas.

Observa-se a ausência importante da basicidade, do volume de escória e dos percentuais de CaO e SiO₂. Entretanto há uma explicação para isto: estes dois importantes componentes químicos e a relação de interação entre eles, tais como a basicidade e o

volume de escória, estão agora representados pela combinação entre eles, ou seja, pelas fases mineralógicas, SFCA Acicular, Colunar e Silicatos. Os melhores resultados também necessitaram da ausência do % MgO. Esta informação, talvez pela pouca variação ou por erros de análise química, não ajudou na melhoria dos resultados finais de generalização.

4.5 MODELAGEM PARA A PREVISÃO DE QUALIDADE DO AÇO

Para tentar melhorar os resultados obtidos pelos modelos convencionais de previsão de teor de carbono e de temperatura de fim de sopro, foram realizados ajustes em modelagem com redes neurais, variando-se, segundo o planejamento de experimentos, os parâmetros de rede de acordo com erros de até 27% para C e de até 0,85% para temperatura. Os estudos envolveram tanto as variáveis disponíveis de entrada para o modelo estático quanto as disponíveis para o modelo dinâmico.

Para a simulação do modelo dinâmico foram consideradas 5030 corridas (filtradas de 15.000 corridas) para treinamento e 200 corridas para testes. Este conjunto de dados equivale a cerca de 4 anos de processamento na aciaria.

As quatro variáveis disponíveis no processo para este desenvolvimento são a temperatura do banho medida pela sublança (TIB), o percentual de carbono do banho calculado pela temperatura de solidificação, através do diagrama Fe.C, obtida pela amostra da sublança (CIB) e as quantidades de minério de ferro e de oxigênio utilizadas para o restante do sopro. A figura 4.5 ilustra a estrutura neural utilizada. Importantes variáveis, como altura da lança ao longo do sopro, a composição química dos gases e fumos e a quantidade e composição química da escória e do banho não estão disponíveis para a modelagem o que introduz limitações às previsões por redes neurais ou por qualquer modelo convencional ou alternativo.

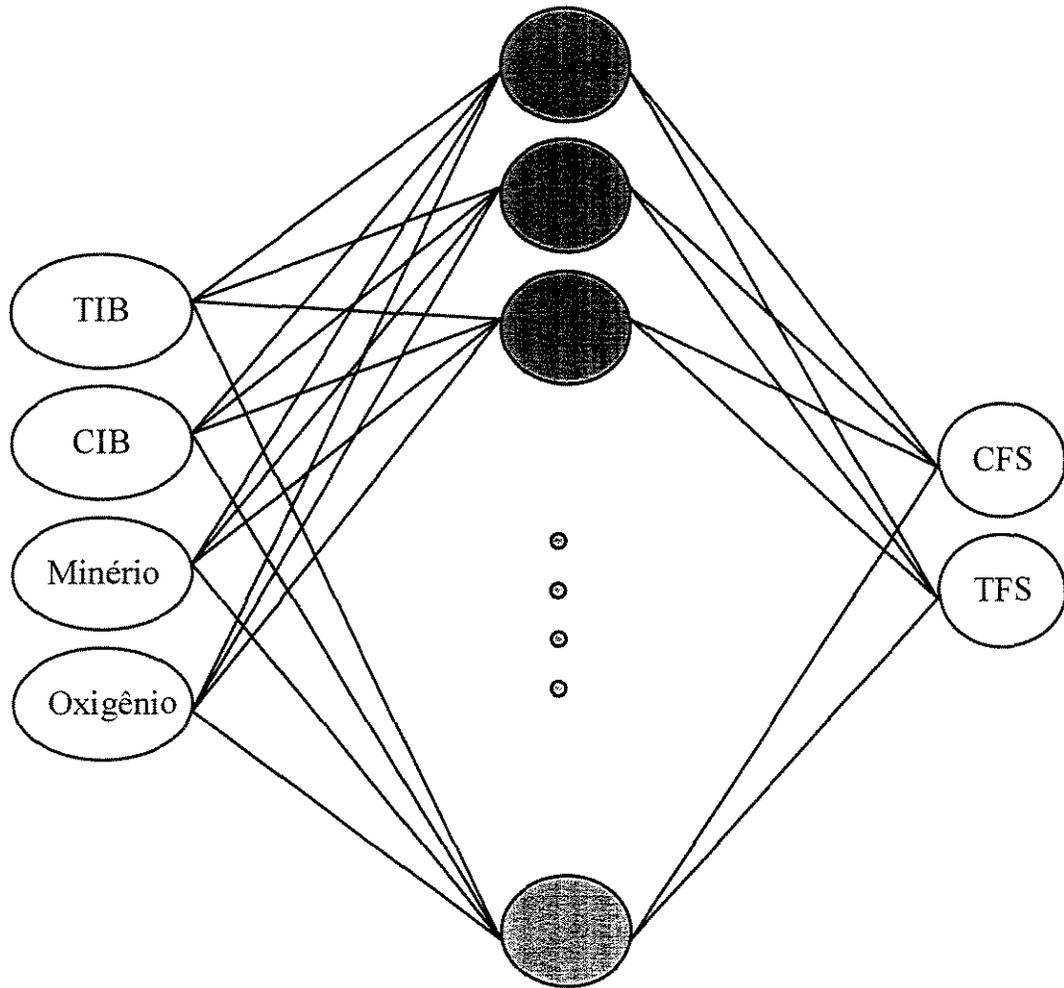


Figura 4.5 – Modelo Dinâmico: Estrutura Neural de Previsão de C e T a partir de variáveis que governam o processo de refino durante a atuação do controle dinâmico.

Para a simulação do modelo estático foram consideradas 3153 corridas para treinamento e 100 corridas para testes. Este banco de dados foi obtido de um banco de 5 anos, com 22.000 corridas. A triagem das variáveis envolveu somente a eliminação de variáveis que não produziram efeito na resposta final, ou seja, na generalização, tais como: sucata B, sucata de retorno, quartizito, fluorita, etc. Chegou-se à estrutura da figura 4.6. Os histogramas das variáveis estão registradas no anexo F.

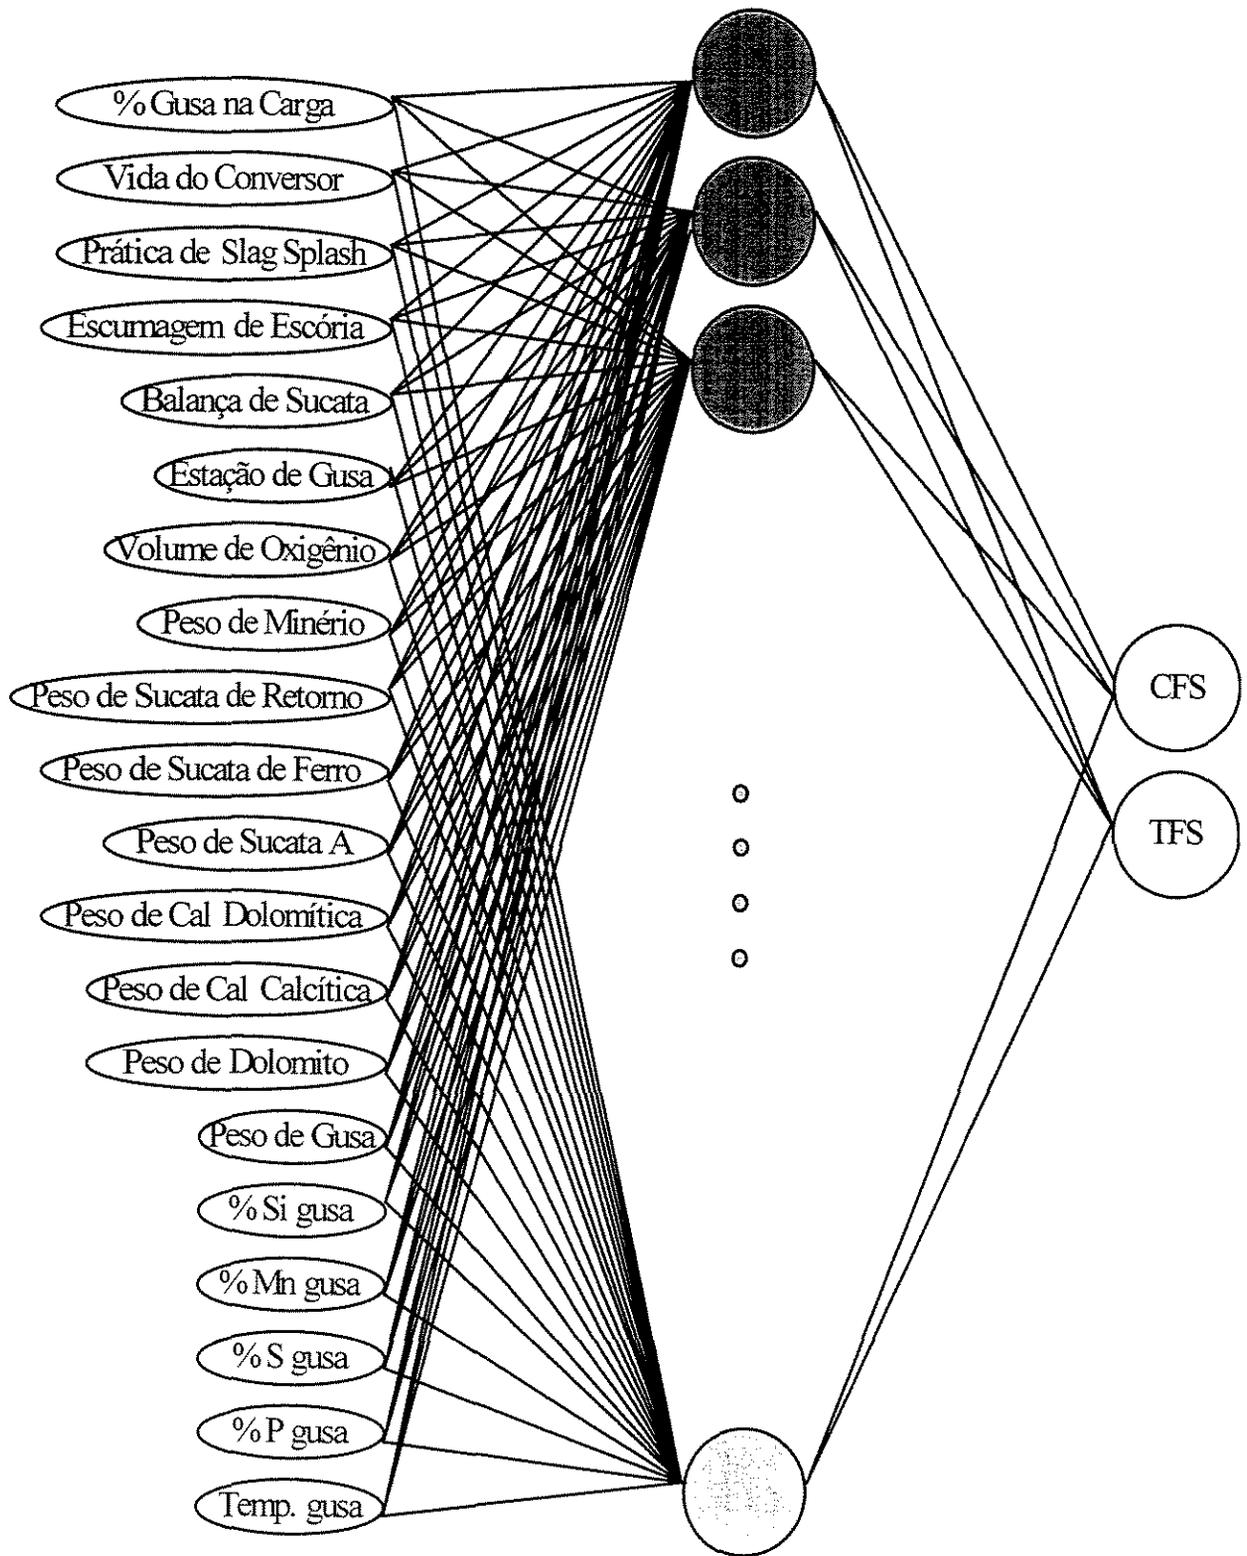


Figura 4.6 – Modelo Estático: Estrutura Neural de Previsão de C e T a partir de variáveis que governam o processo de definição das condições iniciais de refino.

CAPÍTULO 5 - RESULTADOS E DISCUSSÃO

5.1 EXPERIMENTOS PILOTO PARA SÍNTER

No Anexo G pode-se observar as características microscópicas das fases mineralógicas do sinter analisadas neste trabalho. Muitas variações da avaliação mineralógica podem ser encontradas na literatura. Para este trabalho, foram escolhidas as fases hematita primária, hematita secundária, sílico-ferrito de cálcio e alumínio acicular, sílico-ferrito de cálcio e alumínio colunar, magnetita e silicatos. Estas fases mineralógicas são as principais do sinter e as mais citadas na literatura especializada.

Para a atuação na mudança da qualidade do sinter foi utilizada a seguinte premissa: o aumento da basicidade do sinter na CSN é função do aumento do volume de escória (figura 5.1), pois a empresa não possui a flexibilidade de concentração do *sinter feed* ou da compra de outras matérias primas, o que proporcionaria um aumento de basicidade sem aumento do volume de escória. A prática atual na CSN é uma diminuição da quantidade de *sinter feed* e/ou aumento do consumo de calcário.

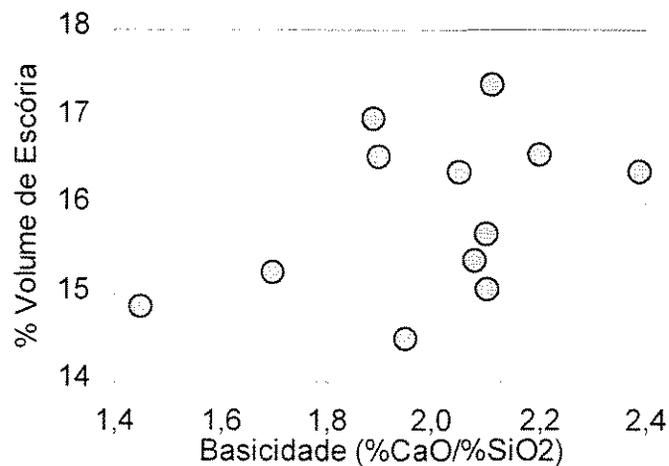


Figura 5.1 – Aumento da basicidade com o aumento do volume de escória.

A variação da basicidade indica um aumento da relação entre CaO e SiO₂, o que favorece a reação entre o Fe₂O₃ (sempre em excesso, devido a grande quantidade de sinter feed na mistura a sinterizar) e o CaO (em excesso, a partir do aumento da basicidade), favorecendo o aumento dos SFCA e a diminuição da formação de silicatos vitrosos. As figuras 5.2 e 5.3 indicam os resultados comentados, que concordam com a literatura estudada (Yang e Davis⁽¹⁰⁾ e Hsieh et al.⁽²³⁾).

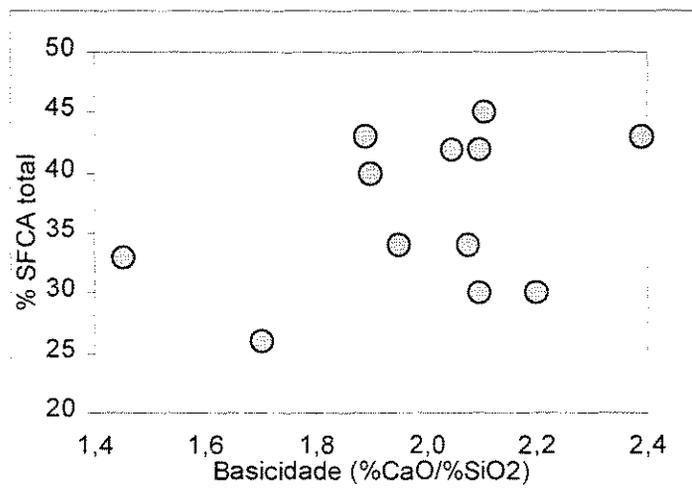


Figura 5.2 – Influência da variação da basicidade do sinter na formação de SFCA.

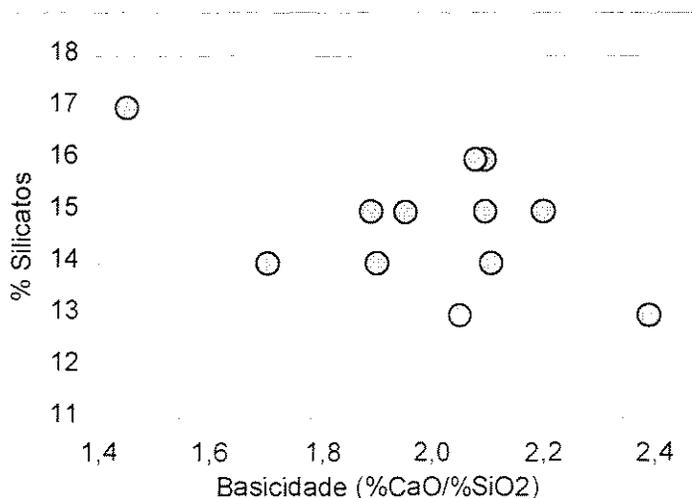


Figura 5.3 – Influência da variação da basicidade do sinter na formação de silicatos.

Com o aumento da basicidade e, conseqüentemente, do volume de escória, ocorre o já citado favorecimento da reação entre CaO e Fe₂O₃, produzindo-se menor quantidade da fase mineral hematita (figura 5.4), fato este citado por (Hsieh et al.⁽²³⁾).

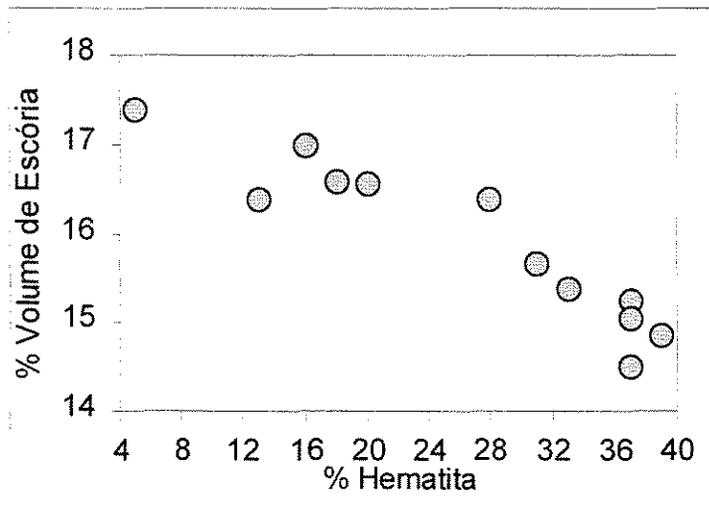


Figura 5.4 – Influência do aumento do volume de escória do sinter na formação de hematitas.

Conforme apresentado na literatura (Pimenta et al.⁽¹⁶⁾ e Costa et al.⁽¹⁷⁾), o aumento do aporte térmico propicia um favorecimento da formação de SFCA colunar e uma diminuição da fase mineralógica SFCA acicular, conforme pode ser observado nas figuras 5.5 e 5.6 (onde o combustível está sendo inferido pelo teor de FeO). Esse favorecimento é função da maior escorificação que ocorre com a maior temperatura, produzindo as fases mineralógicas mais compactas.

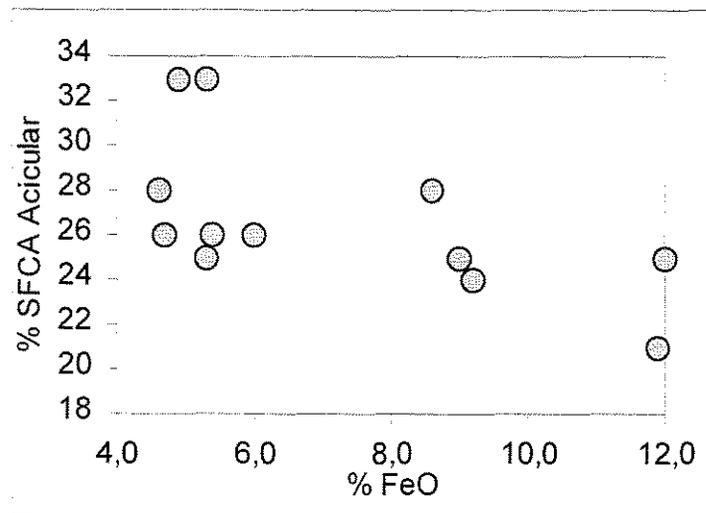


Figura 5.5 – Influência do aumento do aporte térmico (inferido pelo % FeO) na formação de SFCA acicular.

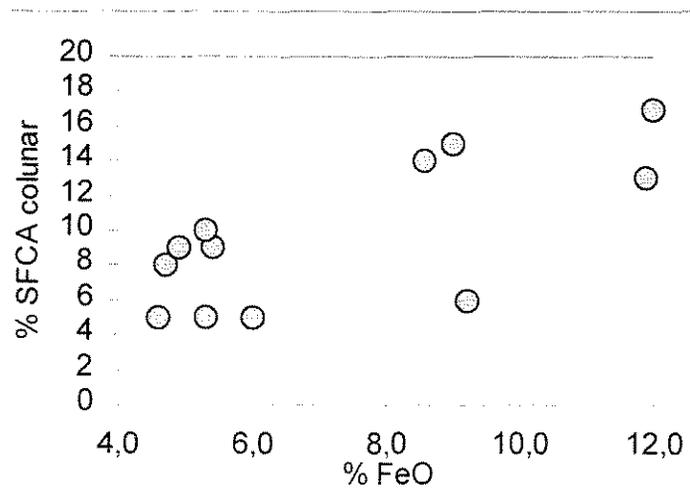


Figura 5.6 – Influência do aumento do aporte térmico (inferido pelo % FeO) na formação de SFCA colunar.

Com o aumento da temperatura, segundo Hida et al.⁽¹¹⁾, há uma maior formação de magnetita (confirmado neste trabalho, figura 5.7) e de silicatos (entretanto, este efeito não foi observado neste trabalho, conforme consta na figura 5.8) pela transformação de parte de SFCA nestas fases mineralógicas.

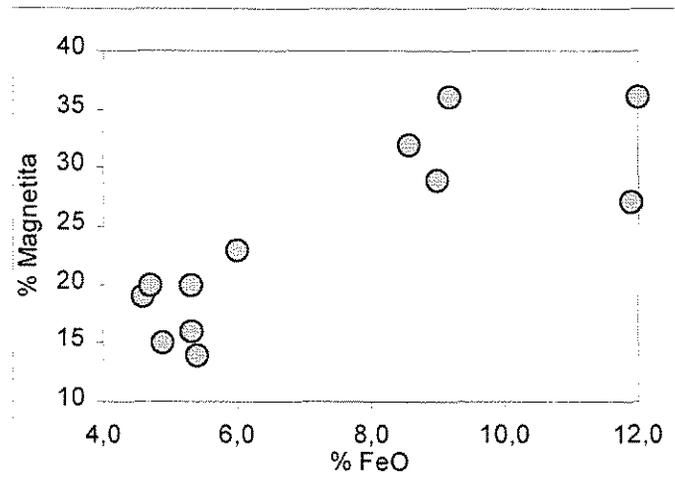


Figura 5.7 – Influência do aumento do aporte térmico (inferido pelo % FeO) na formação de Magnetita.

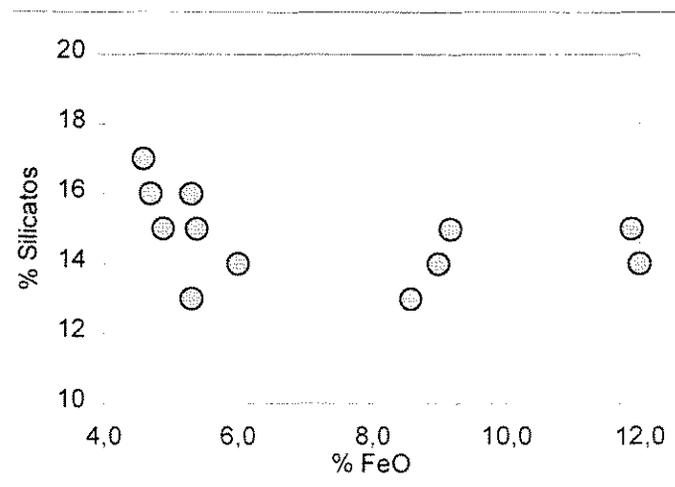


Figura 5.8 – Influência do aumento do aporte térmico (inferido pelo % FeO) na formação de Silicatos.

Baseado na variação das fases minerais, avaliou-se os resultados no RDI e no RI do sinter. De acordo com a figura 5.9, observou-se uma diminuição da degradação a quente sob atmosfera redutora do sinter (medida pelo RDI) através da diminuição da fase hematita. Sabe-se que esta fase mineral, quando em processamento em altos-fornos, produz dilatação

seguida de contração de volume pela formação de Fe_3O_4 e posteriormente de FeO . Esta variação de volume gera trincas no sínter, que se propagam gerando finos.

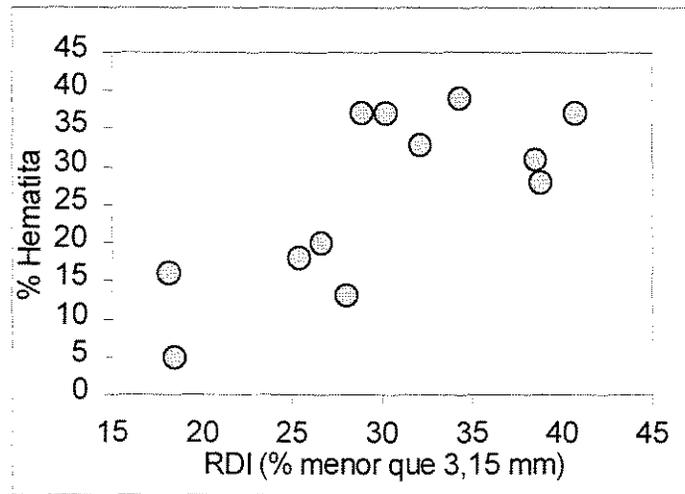


Figura 5.9 – Influência do aumento da fase mineral hematita no RDI do sínter.

Quando se aumenta o percentual da fase magnetita, o sínter já passou pela fase de dilatação e já sofreu solicitações mecânicas durante o transporte e o carregamento e, portanto, já está “estabilizado”. Assim, com o aumento desta fase e a diminuição conseqüente de hematita o RDI tende a cair (figura 5.10).

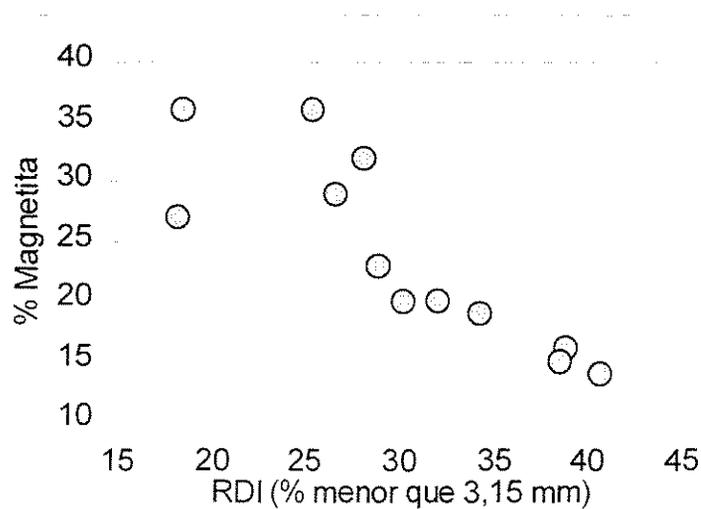


Figura 5.10 – Influência do aumento da fase mineral magnetita no RDI do sínter.

O SFCA acicular é mais poroso que o SFCA colunar, favorecendo as reações químicas promovidas durante a redução. Assim espera-se que a reação de óxido de cálcio com hematitas propicie um comportamento de degradação semelhante ao produzido pela fase hematita, só que em menor escala.

A maior presença de alumina no SFCA acicular indica um aumento no RDI pela maior difusão deste componente químico na estrutura cristalina das hematitas, gerando pontos de tensões (figuras 5.11 e 5.12). Esta teoria, comprovada pelos testes experimentais, foram observadas por Pimenta et al.⁽¹⁶⁾ e Hsieh et al.⁽²³⁾.

Para os silicatos, segundo Costa et al.⁽¹⁷⁾, o aumento da quantidade de silicatos, fase mineral de baixa dureza, favorece a propagação de trincas, gerando maior quantidade de finos nos altos-fornos pela degradação do sinter sob atmosfera aquecida e redutora, teoria esta, mesmo com tendência fraca, comprovada nesta avaliação (figura 5.13).

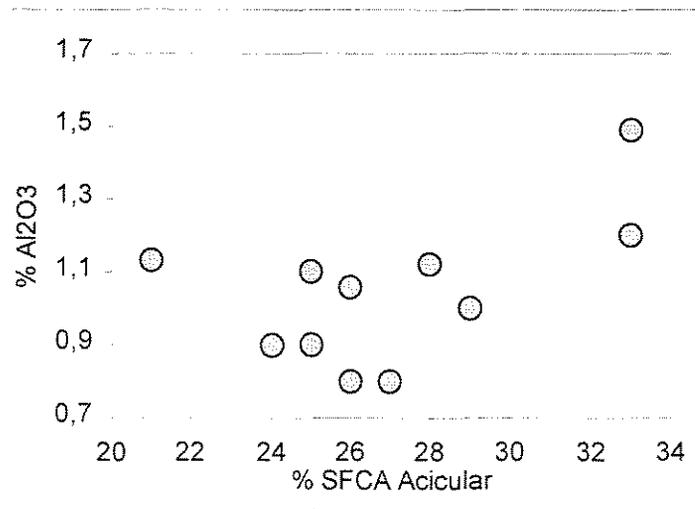


Figura 5.11 – Influência do aumento da alumina na fase mineral SFCA Acicular.

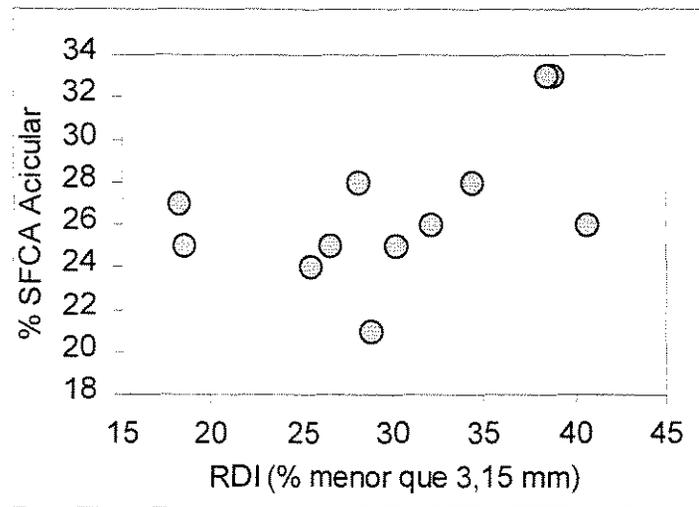


Figura 5.12 – Influência do aumento da fase mineral SFCa acicular no RDI do sínter.

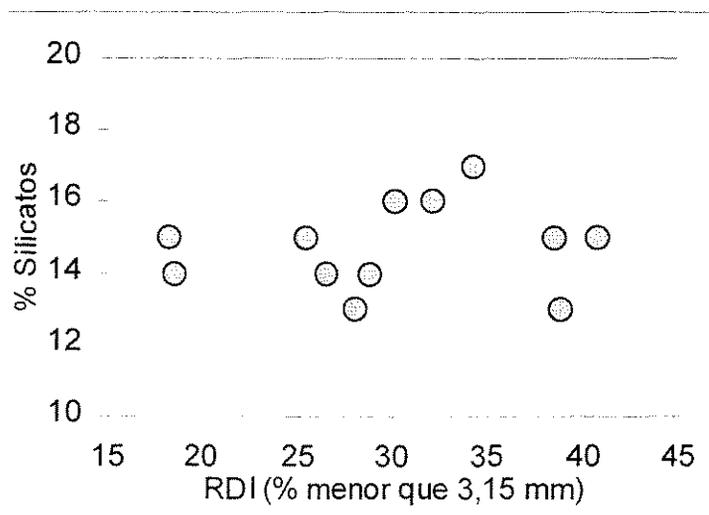


Figura 5.13 – Influência do aumento da fase silicatos no RDI do sínter.

Quanto à fase mineral SFCa colunar, observa-se que com o aumento desta fase ocorre a melhoria do RDI, favorecido pela maior taxa de escorificação. As observações feitas por Costa et al.⁽¹⁷⁾ foram confirmadas nesta batelada de sinterizações piloto (figura 5.14).

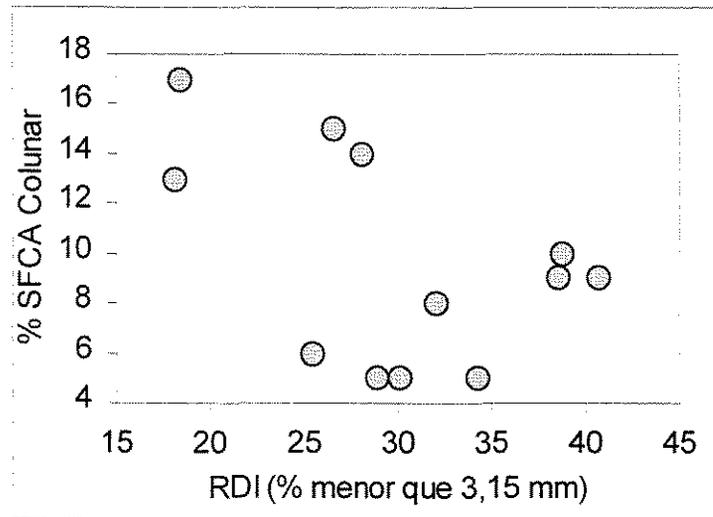


Figura 5.14 – Influência do aumento da fase mineral SFCA colunar no RDI do sínter.

Em relação as hematitas, espera-se pela literatura (Costa et al.⁽¹⁷⁾) uma menor influência na degradação a quente sob atmosfera redutora com a presença da hematita primária do que com a secundária, pois esta última normalmente recebe em sua estrutura cristalina aluminas que degradam o sínter sob as condições de redução a alta temperatura. Entretanto, nos testes realizados, estes efeitos foram bastante similares (observe figuras 5.15 e 5.16).

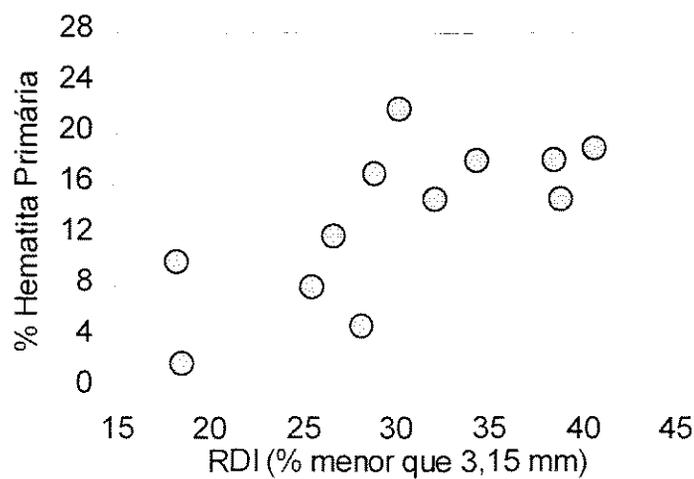


Figura 5.15 – Influência da fase mineral hematita primária no RDI do sínter.

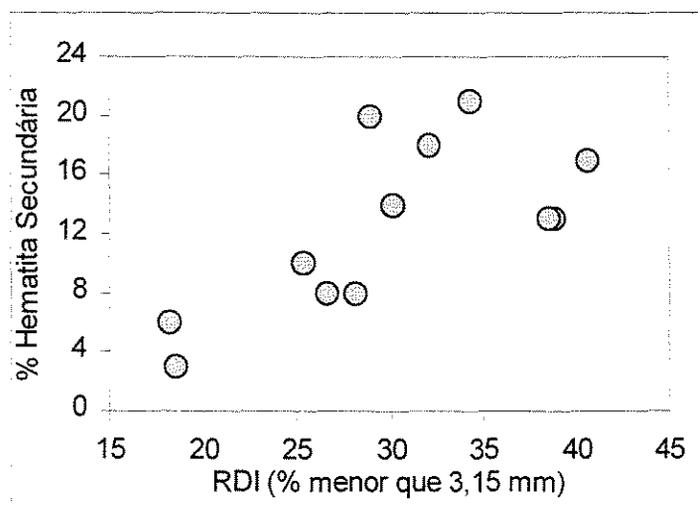


Figura 5.16 – Influência da fase mineral hematita secundária no RDI do sínter.

Quanto ao RI, observou-se um aumento da redutibilidade pelo aumento do conteúdo de hematitas (figura 5.17) e a diminuição da formação de magnetitas (figura 5.18), confirmando o conhecimento mais difundido desta propriedade, relatado em Maeda e Ono⁽¹⁵⁾, que atribuem à hematita, menor tempo de redução. Depois da hematita, as SFCA produzem ferro metálico em tempo menor que as magnetitas.

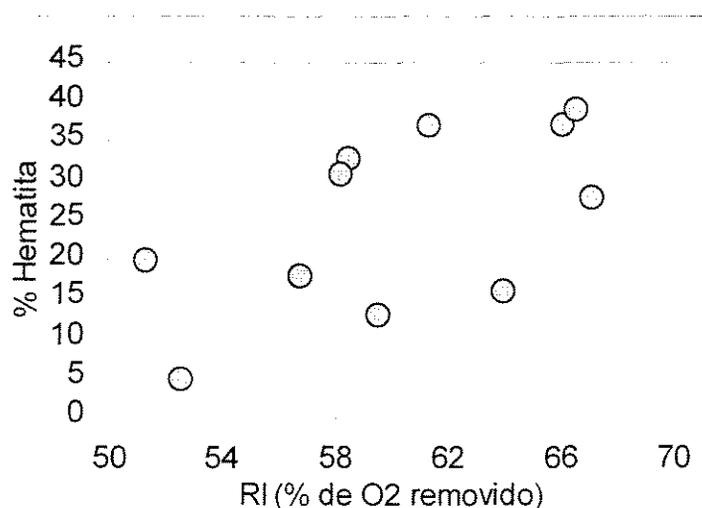


Figura 5.17 – Influência da fase mineral hematita no RI do sínter.

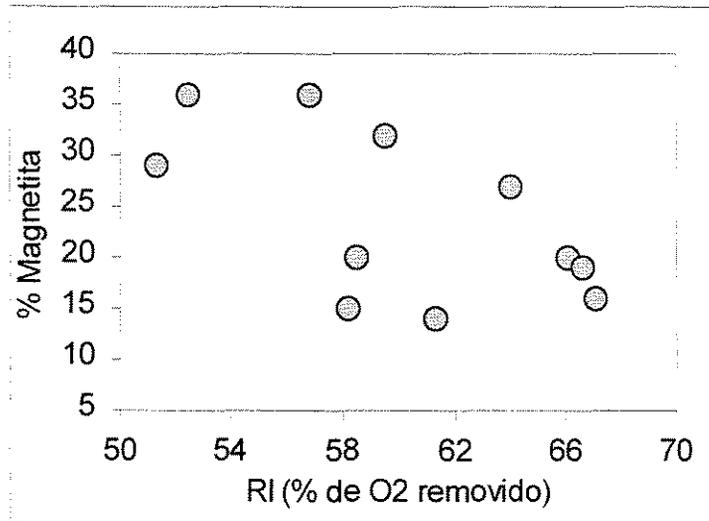


Figura 5.18 – Influência da fase mineral magnetita no RI do sínter.

Estudou-se neste trabalho a formação das hematitas primárias e secundárias. Observa-se a maior inclinação da curva para hematitas primárias, sendo esta fase a de melhor redutibilidade (figura 5.19). Na figura 5.20 está ilustrado o comportamento também positivo das hematitas secundárias no RI do sínter, porém com menor intensidade (apesar de bastante similar ao comportamento do RI em função da hematita primária).

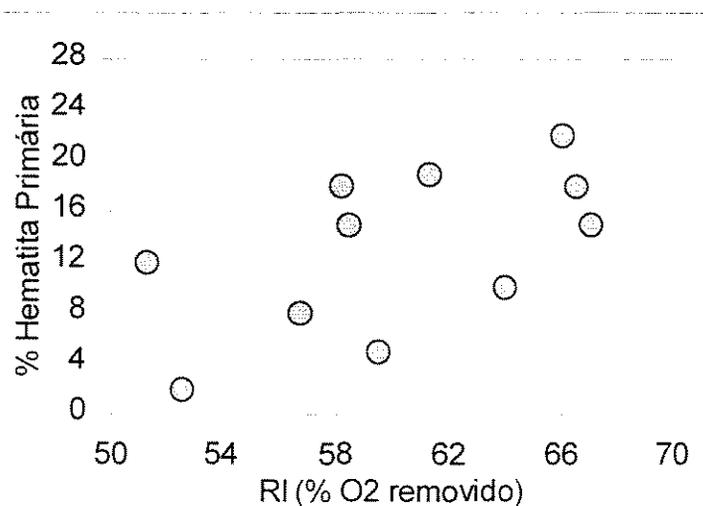


Figura 5.19 – Influência da fase mineral hematita primária no RI do sínter.

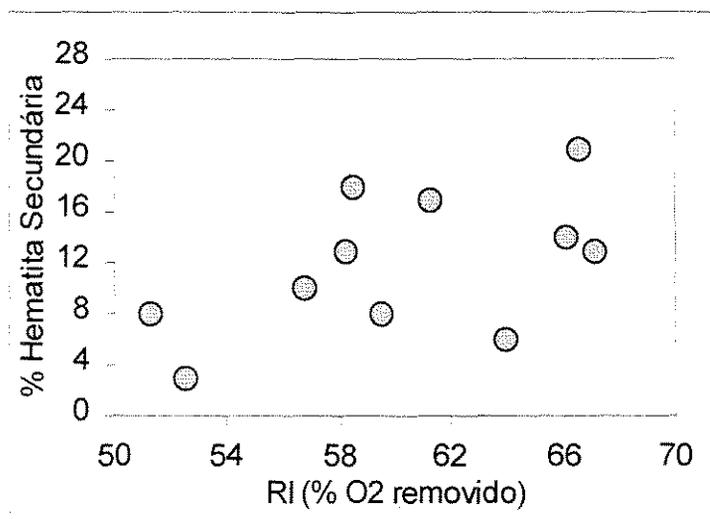


Figura 5.20 – Influência da fase mineral hematita secundária no RI do sinter.

Já para as fases SFCA, encontrou-se um aumento do RI com o aumento da fase SFCA acicular, mais porosa (mais reativa) e com mais Fe_2O_3 , (figura 5.21) e com a diminuição da fase SFCA colunar (figura 5.22), pois esta fase é menos porosa e possui menos Fe_2O_3 , resultado da maior escorificação do sinter, confirmando o estudo de Toda et al.⁽⁷⁾.

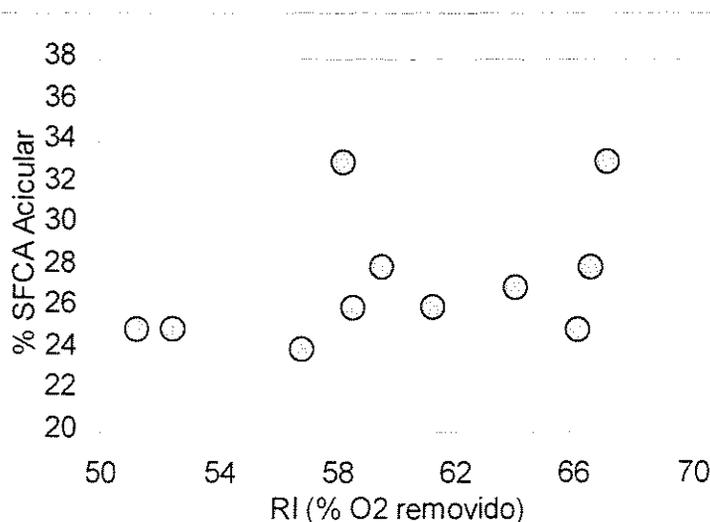


Figura 5.21 – Influência da fase mineral SFCA acicular no RI do sinter.

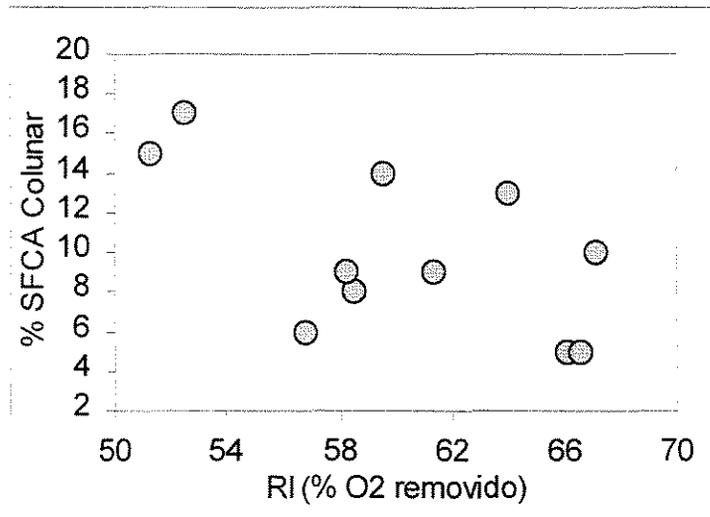


Figura 5.22 – Influência da fase mineral SFCA colunar no RI do sínter.

Assim, observa-se que as fases favoráveis à melhoria do RDI promovem a piora do RI do sínter. A figura 5.23 ilustra o comportamento inversamente proporcional destas duas propriedades, cabendo a cada empresa a escolha da estratégia de produção. Mas processos sem qualquer controle mineralógico podem levar a combinações desfavoráveis de baixa redutibilidade e alto RDI. Este efeito indesejável ocorre sem qualquer rastreamento da empresa que não considera as propriedades mineralógicas em sua matriz de qualidade.

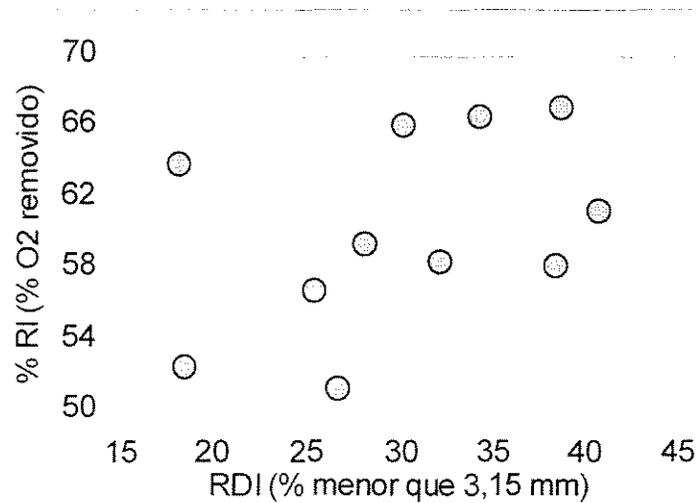


Figura 5.23 – Relação entre RI e RDI.

5.2 SIMULAÇÕES NUMÉRICAS PARA AJUSTE DAS REDES NEURAIIS

5.2.1 ANÁLISE DOS PARÂMETROS DE REDE

Esta etapa do trabalho avaliou os parâmetros de ajuste da rede neural em função da aplicação da técnica de planejamento e otimização de experimentos, considerando até três interações entre efeitos principais (já que a literatura indica que a interação só produz efeito significativo com até três efeitos).

Para acompanhamento das próximas tabelas, temos as seguintes definições para os efeitos principais avaliados:

- α – coeficiente de *momentum*;
- η – coeficiente de aprendizado;
- fa – tipo de função de ativação;
- w – faixa de pesos iniciais aleatórios;
- b_1 - bias da primeira camada;
- b_o – bias das outras camadas.

As interações entre os efeitos principais são representadas pelo sinal de multiplicação (ponto). A influência de cada efeito é obtida pelas respostas das generalizações, que é o acerto simultâneo entre carbono (C) e temperatura (T), para o processo de refino e entre RDI e RI (para o processo sinter), registrados nos Anexos H e I, respectivamente.

A primeira observação define claramente que as RNA's ajustadas com a função de ativação tangente hiperbólica produziu resultados inferiores, considerando os casos estudados para diferentes bancos de dados (com variação de tamanho e de origem, ou seja, de processos diferentes). A tabela 5.1 mostra os resultados.

Tabela 5.1 – Resultados das simulações numéricas com variação dos efeitos principais.

	ANALISADOR VIRTUAL		MODELO	
	simplificado	completo	dinâmico	estático
	4x9x2	9x19x2	4x9x2	20x41x2
α	3,7%	0,2%	2,5%	-0,3%
η	0,8%	0,1%	1,8%	-0,5%
b1	0,9%	1,0%	0,8%	-0,5%
bo	-1,2%	-0,1%	0,6%	-0,1%
w	0,6%	-1,3%	0,3%	-0,5%
fa	6,7%	15,7%	26,9%	12,0%
$\alpha.\eta$	-2,3%	-1,2%	-0,5%	-1,0%
$\alpha.b1$	-0,5%	-0,6%	0,3%	0,2%
$\alpha.bo$	0,0%	-0,3%	0,0%	-0,7%
$\alpha.w$	-0,4%	0,0%	0,2%	-0,1%
$\alpha.fa$	5,4%	1,0%	1,8%	0,7%
$\eta.b1$	-0,8%	-1,0%	0,2%	-0,1%
$\eta.bo$	-0,1%	-0,1%	-0,4%	-0,5%
$\eta.w$	-0,4%	-0,2%	-0,2%	-0,6%
$\eta.fa$	2,5%	1,7%	0,5%	0,5%
b1.bo	0,9%	0,4%	0,5%	-0,7%
b1.w	0,0%	0,4%	0,1%	0,3%
b1.fa	1,8%	0,7%	0,4%	0,4%
bo.w	-0,3%	-0,5%	0,1%	-0,1%
bo.fa	-0,8%	-0,7%	-0,8%	-0,6%
w.fa	0,6%	0,1%	0,6%	0,4%
$\eta.\alpha.b1$	0,8%	1,8%	0,1%	-0,3%
$\eta.\alpha.bo$	-0,6%	0,1%	-0,9%	-0,5%
$\eta.\alpha.w$	1,1%	0,6%	-0,2%	0,3%
$\eta.\alpha.fa$	-0,6%	-0,1%	-0,1%	0,6%
$\eta.b1.bo$	0,8%	0,5%	0,1%	-0,8%
$\eta.b1.w$	-0,6%	-0,7%	-0,2%	0,5%
$\eta.b1.fa$	0,0%	-0,7%	-0,1%	0,5%
$\eta.bo.w$	1,1%	0,6%	-0,2%	0,3%
$\eta.bo.fa$	-0,6%	-0,1%	-0,1%	0,6%
$\eta.w.fa$	-0,4%	0,5%	-0,2%	0,0%
$\alpha.b1.bo$	0,2%	0,3%	0,2%	-0,8%
$\alpha.b1.w$	0,7%	0,3%	-0,2%	0,4%
$\alpha.b1.fa$	0,3%	-0,6%	0,4%	0,6%
$\alpha.bo.w$	0,4%	0,4%	0,2%	0,4%
$\alpha.bo.fa$	0,4%	-0,5%	0,2%	-0,3%
$\alpha.w.fa$	-0,4%	-0,3%	0,2%	0,5%
b1.bo.w	0,8%	-0,4%	-0,2%	0,1%
b1.bo.fa	0,5%	0,3%	0,3%	0,6%
bo.w.fa	-0,7%	0,3%	0,1%	-0,4%

Nas tabelas 5.2 a 5.5 estão registrados os dados referentes ao estudo dos parâmetros de rede considerando somente a função sigmoïdal (esta simplificação foi resultado da primeira batelada de simulações). Este estudo levou às seguintes observações:

- i. Quanto maior o banco de dados utilizado para treinamento das redes neurais, menor a influência da variação dos parâmetros de rede nos resultados de generalização (isto considerando que as redes estudadas para os processos de sinterização possuem banco de dados pequenos, com 732 dados para o analisador virtual simplificado e 1342 dados para o analisador virtual completo, contra 71566 dados do modelo estático da aciaria e 31380 dados do modelo dinâmico deste mesmo processo). Atribui-se esta diferença aos erros inevitáveis de medida e de formação destes bancos de dados, que aumentam com o aumento das experiências (corridas industriais de produção) e com o aumento do número de variáveis de entrada;
- ii. Considerando ainda a intensidade de variação dos efeitos principais e interações sobre a generalização, observou-se também que as redes com quatro camadas sofrem maior influência das variações destes efeitos que as redes de três camadas, considerando aqui o mesmo número de neurônios ocultos entre as redes de três e quatro camadas;
- iii. Em todos os casos estudados, observou-se uma forte influência nos resultados de generalização causados não só pelos efeitos principais como também pelas interações entre duas e até entre três variáveis, **daí a grande importância de se utilizar uma técnica como a de planejamento de experimentos para verificar as interações entre as variáveis**;
- iv. Observou-se que as redes com o número de entrada maiores (analisador completo e modelo estático) sofreram maiores influências nos resultados de generalização em função dos pesos iniciais (tanto para redes com três quanto para quatro camadas). As redes com número pequeno de entradas foram mais influenciadas pela variação do coeficiente de *momentum* (tanto para três quanto para quatro camadas);
- v. O coeficiente de aprendizado influenciou todas as estruturas de rede estudadas, ficando em segundo lugar na intensidade de influência dos resultados;
- vi. O parâmetro b_0 atribuiu menor influência nos resultados;

- vii. As principais interações encontradas foram entre o coeficiente de aprendizado e entre o coeficiente de *momentum*, (a principal interação, que influenciou todos os resultados e foi citada como influente por Qiu et al.⁽⁶¹⁾) entre o coeficiente de aprendizado e entre bias da primeira camada, entre coeficiente de aprendizado, bias da primeira e das demais camadas, entre coeficiente de aprendizado, bias da primeira camada e pesos iniciais, entre coeficiente, entre coeficiente de aprendizado, coeficiente de *momentum* e bias da primeira camada e entre pesos iniciais e coeficiente de aprendizado;
- viii. A influência de todas estas variáveis e interações indicou variações em busca do melhor resultado de generalização, mas nenhuma apresentou influência maior que a função de ativação.

Tabela 5.2 – Resultados dos efeitos principais e das interações para o estudo de rede neural com dados da etapa dinâmica da aciaria.

	EFEITOS NO ACERTO SIMULTÂNEO DE C E T				EFEITOS MEDIOS				
	4x9x2	4x8x2	4x4x4x2	4x6x3x2	todas as simulações	(3 camadas)	(4 camadas)	neurônios ocultos=8	neurônios ocultos=9
α	2,5%	4,4%	2,1%	3,6%	3,2%	3,4%	2,9%	3,3%	3,0%
η	1,8%	3,0%	0,9%	1,9%	1,9%	2,4%	1,4%	2,0%	1,9%
b1	0,8%	1,0%	0,8%	0,3%	0,7%	0,9%	0,6%	0,9%	0,5%
bo	0,6%	0,7%	0,2%	0,7%	0,6%	0,6%	0,5%	0,5%	0,7%
w	0,3%	0,3%	1,4%	0,9%	0,7%	0,3%	1,1%	0,9%	0,6%
$\alpha.\eta$	0,5%	0,3%	1,9%	1,2%	1,0%	0,4%	1,6%	1,1%	0,9%
$\alpha.b1$	0,3%	0,0%	0,5%	1,0%	0,5%	0,2%	0,7%	0,3%	0,7%
$\alpha.bo$	0,0%	0,4%	0,4%	1,1%	0,5%	0,2%	0,8%	0,4%	0,5%
$\alpha.w$	0,2%	0,5%	0,5%	0,3%	0,4%	0,4%	0,4%	0,5%	0,3%
$\eta.b1$	0,2%	0,3%	1,0%	2,4%	1,0%	0,3%	1,7%	0,7%	1,3%
$\eta.bo$	0,4%	0,2%	0,0%	0,2%	0,2%	0,3%	0,1%	0,1%	0,3%
$\eta.w$	0,2%	0,8%	0,5%	0,3%	0,4%	0,5%	0,4%	0,6%	0,2%
b1.bo	0,5%	0,5%	0,6%	0,3%	0,5%	0,5%	0,4%	0,5%	0,4%
b1.w	0,1%	0,8%	0,4%	0,2%	0,4%	0,5%	0,3%	0,6%	0,2%
bo.w	0,1%	0,1%	0,2%	0,5%	0,2%	0,1%	0,3%	0,1%	0,3%
$\eta.\alpha.b1$	0,1%	0,2%	0,1%	1,1%	0,4%	0,1%	0,6%	0,2%	0,6%
$\eta.\alpha.bo$	0,9%	0,8%	0,2%	0,7%	0,6%	0,8%	0,4%	0,5%	0,8%
$\eta.\alpha.w$	0,2%	0,3%	0,6%	0,5%	0,4%	0,2%	0,5%	0,4%	0,3%
$\eta.b1.bo$	0,1%	0,0%	0,6%	1,5%	0,6%	0,0%	1,1%	0,3%	0,8%
$\eta.b1.w$	0,2%	0,3%	1,2%	0,7%	0,6%	0,3%	1,0%	0,7%	0,5%
$\eta.bo.w$	0,2%	0,3%	0,6%	0,5%	0,4%	0,2%	0,5%	0,4%	0,3%
$\alpha.b1.bo$	0,2%	0,4%	0,9%	0,1%	0,4%	0,3%	0,5%	0,6%	0,2%
$\alpha.b1.w$	0,2%	0,4%	0,7%	0,4%	0,4%	0,3%	0,5%	0,5%	0,3%
$\alpha.bo.w$	0,2%	0,0%	0,5%	1,0%	0,4%	0,1%	0,7%	0,3%	0,6%
b1.bo.w	0,2%	0,1%	0,3%	0,0%	0,2%	0,1%	0,2%	0,2%	0,1%

Tabela 5.3 – Resultados dos efeitos principais e das interações para o estudo de rede neural com dados da etapa estática da aciaria.

	EFEITOS NO ACERTO SIMULTÂNEO DE C E T			EFEITOS MEDIOS				
	20x41x2	20x40x2	20x20x20x2	todas as simulações	(3 camadas)	(4 camadas)	neurônios ocultos=40	neurônios ocultos=41
α	0,3%	0,6%	1,0%	0,6%	0,4%	1,0%	0,8%	0,3%
η	0,5%	0,3%	0,6%	0,5%	0,4%	0,6%	0,4%	0,5%
b1	0,5%	0,4%	0,1%	0,3%	0,5%	0,1%	0,2%	0,5%
bo	0,1%	1,3%	0,5%	0,6%	0,7%	0,5%	0,9%	0,1%
w	0,5%	1,1%	0,8%	0,8%	0,8%	0,8%	1,0%	0,5%
$\alpha.\eta$	1,0%	0,3%	0,0%	0,4%	0,6%	0,0%	0,1%	1,0%
$\alpha.b1$	0,2%	0,6%	0,1%	0,3%	0,4%	0,1%	0,3%	0,2%
$\alpha.bo$	0,7%	0,6%	0,0%	0,4%	0,7%	0,0%	0,3%	0,7%
$\alpha.w$	0,1%	0,1%	0,5%	0,2%	0,1%	0,5%	0,3%	0,1%
$\eta.b1$	0,1%	0,3%	0,2%	0,2%	0,2%	0,2%	0,2%	0,1%
$\eta.bo$	0,5%	0,2%	0,3%	0,3%	0,3%	0,3%	0,2%	0,5%
$\eta.w$	0,6%	0,7%	1,2%	0,8%	0,6%	1,2%	1,0%	0,6%
b1.bo	0,7%	0,6%	0,3%	0,5%	0,7%	0,3%	0,4%	0,7%
b1.w	0,3%	0,2%	1,0%	0,5%	0,3%	1,0%	0,6%	0,3%
bo.w	0,1%	0,5%	0,3%	0,3%	0,3%	0,3%	0,4%	0,1%
$\eta.\alpha.b1$	0,3%	0,6%	0,5%	0,4%	0,4%	0,5%	0,5%	0,3%
$\eta.\alpha.bo$	0,5%	0,0%	0,9%	0,5%	0,3%	0,9%	0,5%	0,5%
$\eta.\alpha.w$	0,3%	0,1%	0,4%	0,3%	0,2%	0,4%	0,3%	0,3%
$\eta.b1.bo$	0,8%	0,1%	0,3%	0,4%	0,5%	0,3%	0,2%	0,8%
$\eta.b1.w$	0,5%	0,2%	0,6%	0,4%	0,3%	0,6%	0,4%	0,5%
$\eta.bo.w$	0,3%	0,1%	0,4%	0,3%	0,2%	0,4%	0,3%	0,3%
$\alpha.b1.bo$	0,8%	0,0%	0,3%	0,4%	0,4%	0,3%	0,2%	0,8%
$\alpha.b1.w$	0,4%	0,2%	0,2%	0,3%	0,3%	0,2%	0,2%	0,4%
$\alpha.bo.w$	0,4%	0,5%	0,7%	0,5%	0,5%	0,7%	0,6%	0,4%
b1.bo.w	0,1%	0,9%	0,6%	0,5%	0,5%	0,6%	0,7%	0,1%

Tabela 5.4 – Resultados dos efeitos principais e das interações para o estudo de rede neural com dados do analisador virtual completo.

	EFEITOS NO ACERTO SIMULTÂNEO DE RDI E RI		EFEITOS MÉDIOS		
			todas as simulações	(3 camadas)	(4 camadas)
	9x19x2	9x13x6x2			
α	0,2%	2,1%	1,1%	0,2%	2,1%
η	0,1%	0,9%	0,5%	0,1%	0,9%
b1	1,0%	5,3%	3,1%	1,0%	5,3%
bo	0,1%	0,2%	0,1%	0,1%	0,2%
w	1,3%	10,4%	5,9%	1,3%	10,4%
$\alpha.\eta$	1,2%	5,7%	3,4%	1,2%	5,7%
$\alpha.b1$	0,6%	2,8%	1,7%	0,6%	2,8%
$\alpha.bo$	0,3%	0,8%	0,5%	0,3%	0,8%
$\alpha.w$	0,0%	1,9%	0,9%	0,0%	1,9%
$\eta.b1$	1,0%	1,0%	1,0%	1,0%	1,0%
$\eta.bo$	0,1%	2,6%	1,4%	0,1%	2,6%
$\eta.w$	0,2%	0,8%	0,5%	0,2%	0,8%
b1.bo	0,4%	2,0%	1,2%	0,4%	2,0%
b1.w	0,4%	0,7%	0,5%	0,4%	0,7%
bo.w	0,5%	1,2%	0,9%	0,5%	1,2%
$\eta.\alpha.b1$	1,8%	0,5%	1,1%	1,8%	0,5%
$\eta.\alpha.bo$	0,1%	0,5%	0,3%	0,1%	0,5%
$\eta.\alpha.w$	0,6%	1,6%	1,1%	0,6%	1,6%
$\eta.b1.bo$	0,5%	0,7%	0,6%	0,5%	0,7%
$\eta.b1.w$	0,7%	1,0%	0,8%	0,7%	1,0%
$\eta.bo.w$	0,6%	1,6%	1,1%	0,6%	1,6%
$\alpha.b1.bo$	0,3%	0,1%	0,2%	0,3%	0,1%
$\alpha.b1.w$	0,3%	1,2%	0,8%	0,3%	1,2%
$\alpha.bo.w$	0,4%	1,8%	1,1%	0,4%	1,8%
b1.bo.w	0,4%	1,1%	0,8%	0,4%	1,1%

Tabela 5.5 – Resultados dos efeitos principais e das interações para o estudo de rede neural com dados do analisador virtual simplificado.

	EFEITOS NO ACERTO SIMULTÂNEO DE RDI E RI			EFEITOS MEDIOS				
	4x9x2	4x8x2	4x6x3x2	todas as simulações	(3 camadas)	(4 camadas)	neurônios ocultos=8	neurônios ocultos=9
α	3,7%	7,4%	4,2%	5,1%	5,6%	4,2%	7,4%	3,9%
η	0,8%	3,1%	6,2%	3,4%	1,9%	6,2%	3,1%	3,5%
b1	0,9%	4,4%	4,8%	3,4%	2,7%	4,8%	4,4%	2,9%
bo	1,2%	0,2%	1,3%	0,9%	0,7%	1,3%	0,2%	1,2%
w	0,6%	0,1%	1,7%	0,8%	0,4%	1,7%	0,1%	1,2%
$\alpha.\eta$	2,3%	4,3%	2,7%	3,1%	3,3%	2,7%	4,3%	2,5%
$\alpha.b1$	0,5%	0,9%	2,0%	1,1%	0,7%	2,0%	0,9%	1,2%
$\alpha.bo$	0,0%	0,7%	0,8%	0,5%	0,3%	0,8%	0,7%	0,4%
$\alpha.w$	0,4%	0,2%	1,2%	0,6%	0,3%	1,2%	0,2%	0,8%
$\eta.b1$	0,8%	0,7%	2,1%	1,2%	0,8%	2,1%	0,7%	1,5%
$\eta.bo$	0,1%	1,2%	0,9%	0,7%	0,6%	0,9%	1,2%	0,5%
$\eta.w$	0,4%	0,2%	0,2%	0,3%	0,3%	0,2%	0,2%	0,3%
b1.bo	0,9%	0,2%	0,7%	0,6%	0,6%	0,7%	0,2%	0,8%
b1.w	0,0%	0,2%	0,2%	0,1%	0,1%	0,2%	0,2%	0,1%
bo.w	0,3%	0,1%	0,8%	0,4%	0,2%	0,8%	0,1%	0,6%
$\eta.\alpha.b1$	0,8%	1,6%	6,4%	2,9%	1,2%	6,4%	1,6%	3,6%
$\eta.\alpha.bo$	0,6%	0,3%	0,3%	0,4%	0,5%	0,3%	0,3%	0,5%
$\eta.\alpha.w$	1,1%	0,3%	0,0%	0,5%	0,7%	0,0%	0,3%	0,6%
$\eta.b1.bo$	0,8%	1,2%	1,0%	1,0%	1,0%	1,0%	1,2%	0,9%
$\eta.b1.w$	0,6%	0,3%	1,0%	0,6%	0,4%	1,0%	0,3%	0,8%
$\eta.bo.w$	1,1%	0,3%	0,0%	0,5%	0,7%	0,0%	0,3%	0,6%
$\alpha.b1.bo$	0,2%	0,3%	1,3%	0,6%	0,3%	1,3%	0,3%	0,8%
$\alpha.b1.w$	0,7%	0,7%	0,1%	0,5%	0,7%	0,1%	0,7%	0,4%
$\alpha.bo.w$	0,4%	0,2%	1,3%	0,7%	0,3%	1,3%	0,2%	0,9%
b1.bo.w	0,8%	0,2%	0,4%	0,5%	0,5%	0,4%	0,2%	0,6%

5.2.2 ANÁLISE DO DESEMPENHO DA RNA EM FUNÇÃO DA ARQUITETURA E DO TAMANHO DO BANCO DE DADOS

Nesta etapa do trabalho analisou-se os seguintes tópicos:

- i. Influência da quantidade de neurônios ocultos nas redes de quatro camadas;
- ii. Influência da relação entre estas camadas ocultas;
- iii. A relação entre generalização e tamanho da RNA;
- iv. Influência das conexões entre os neurônios das camadas das redes.

Observou-se um aumento da generalização com a diminuição da quantidade de neurônios ocultos para os casos do analisador virtual simplificado e para o modelo dinâmico (figuras 5.24 a 5.27). Mas para o modelo estático e para o analisador virtual completo os melhores resultados de generalização foram atingidos com o aumento do total de neurônios ocultos. A diferença entre estes dois comportamento está relacionada ao número de entradas: redes com um número pequeno de entradas necessitam de quantidades menores de neurônios ocultos para produzirem melhores resultados, ao passo que redes com um número grande de entradas necessitam mais neurônios ocultos para produzirem melhores resultados.

Assim, entende-se que redes com um número menor de entradas aprendem mais facilmente que redes com um número maior de entradas, pois estas necessitam criar mais conexões devido a uma modelagem mais complexa.

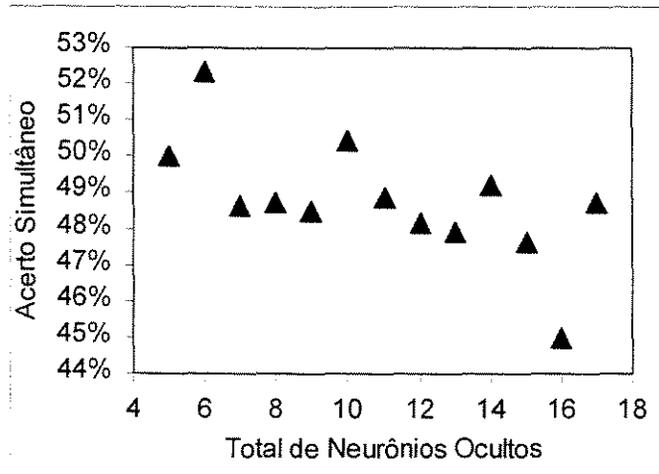


Figura 5.24 – Relação entre generalização e tamanho da RNA obtida para o analisador virtual simplificado.

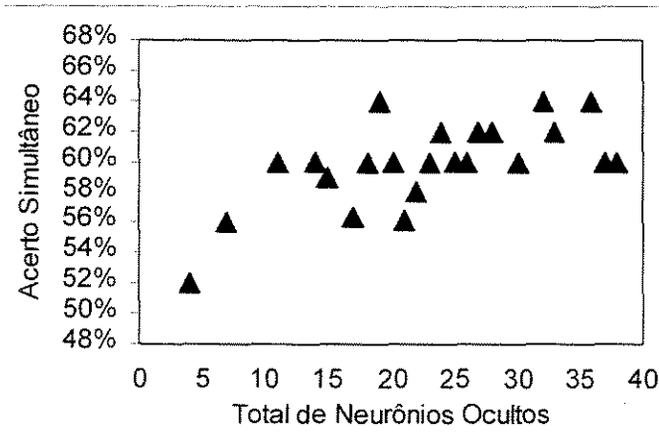


Figura 5.25 – Relação entre generalização e tamanho da RNA obtida para o analisador virtual completo.

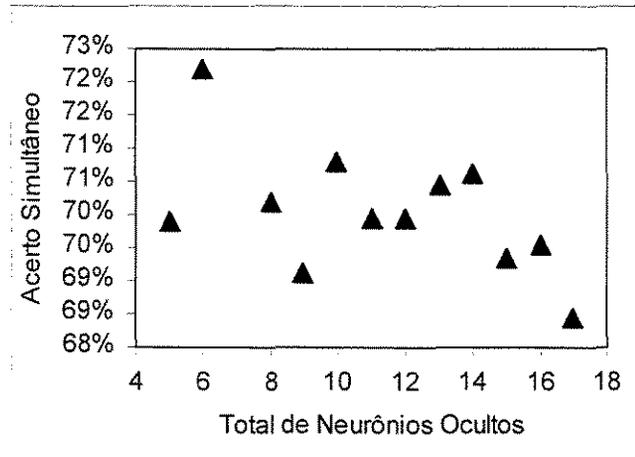


Figura 5.26 – Relação entre generalização e tamanho da RNA obtida para o modelo dinâmico.

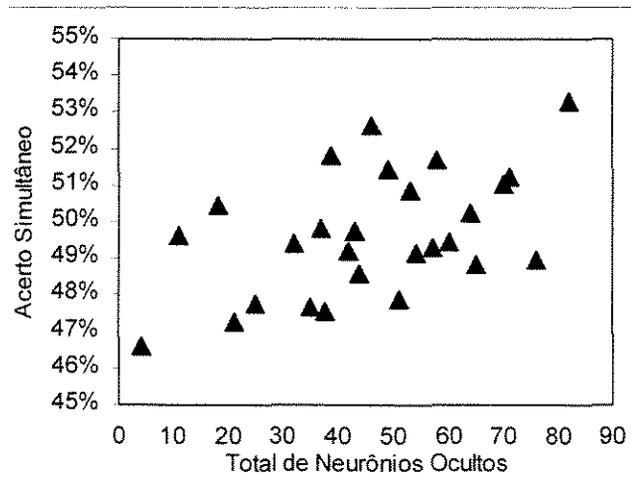


Figura 5.27 – Relação entre generalização e tamanho da RNA obtida para o modelo estático.

Observou-se nos resultados para os analisadores virtuais simplificado e completo uma tendência de melhoria da generalização com o aumento da quantidade de neurônios na segunda camada oculta e uma tendência de melhoria com a diminuição de neurônios na primeira camada oculta. Estes dois analisadores tem em comum a modelagem utilizando banco de dados pequenos, quando comparados aos modelos de aciaria (figuras 5.28 a 5.31).

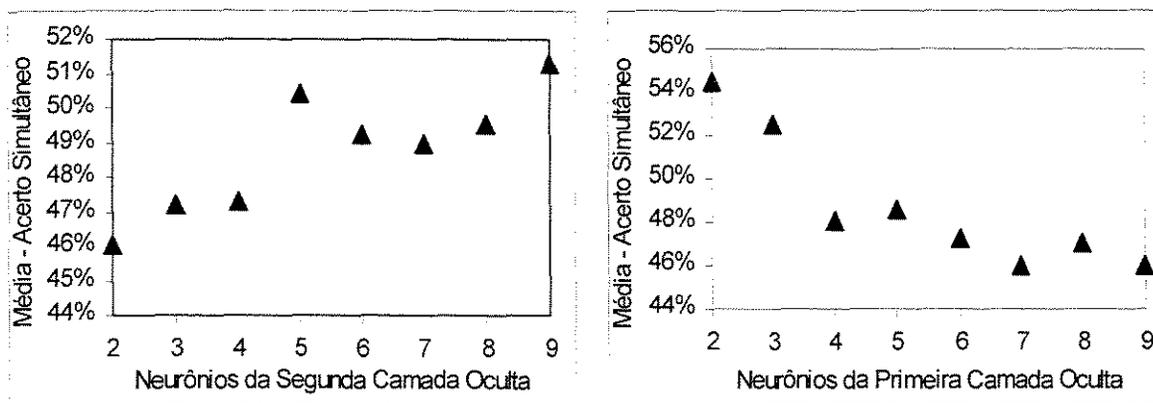


Figura 5.28 – Influência da quantidade de neurônios ocultos no acerto simultâneo de RDI e RI para o analisador virtual simplificado.

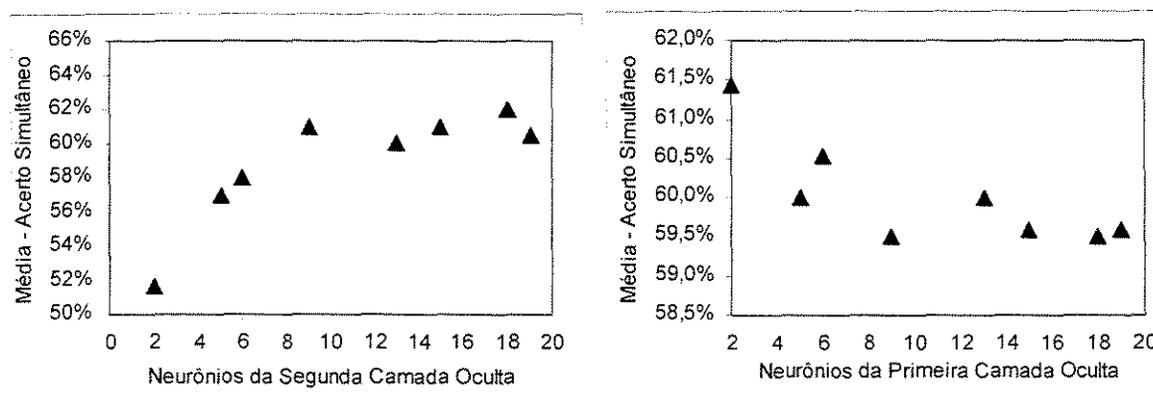


Figura 5.29 – Influência da quantidade de neurônios ocultos no acerto simultâneo de RDI e RI para o analisador virtual completo.

Dos modelos de aciaria estudados, observou-se uma melhoria da generalização com a diminuição da quantidade de neurônios na segunda camada oculta do modelo dinâmico e com o aumento do número de neurônios ocultos da segunda camada para a rede treinada com um banco de dados ainda maior, ou seja, o modelo estático.

Uma tendência de melhoria da generalização foi observada para analisadores virtuais com a diminuição de neurônios na primeira camada oculta. Para os modelos de

aciaria os melhores resultados foram conseguidos mediante aumento do número de neurônios da primeira camada oculta.

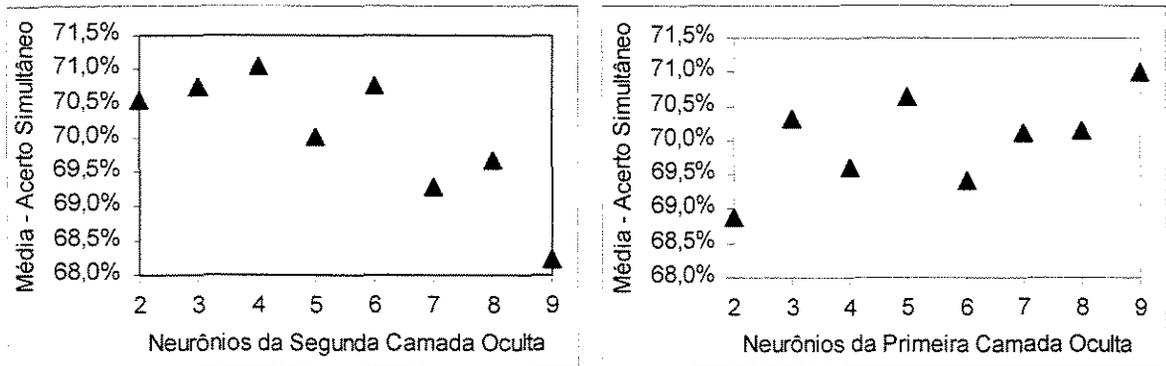


Figura 5.30 – Influência da quantidade de neurônios ocultos no acerto simultâneo de C e T para o modelo dinâmico.

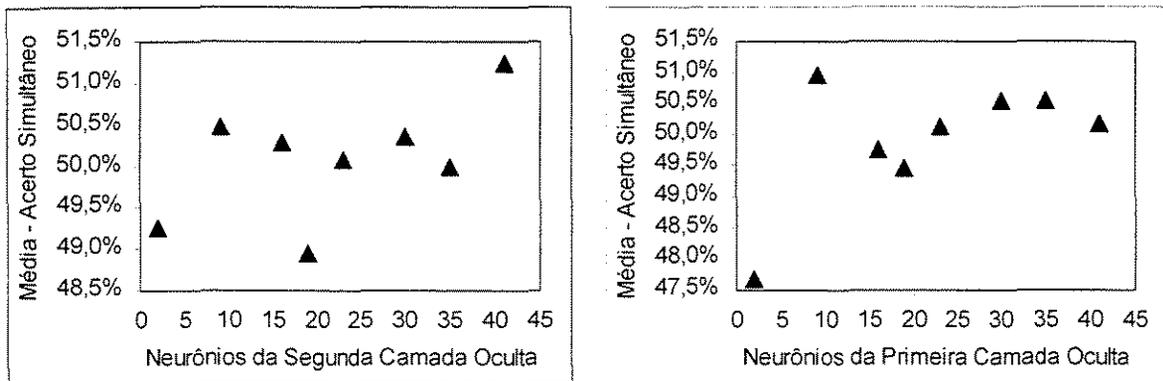


Figura 5.31 – Influência da quantidade de neurônios ocultos no acerto simultâneo de C e T para o modelo estático.

Os resultados das próximas figuras (5.32 a 5.35) mostram valores individuais para relação entre as camadas ocultas e confirmam, por um outro ponto de vista, os resultados comentados pela avaliação da quantidade de neurônios ocultos em cada camada (considerar nas figuras que Mn1 é o número de neurônios da primeira camada e Mn2 é o número de neurônios da segunda camada oculta).

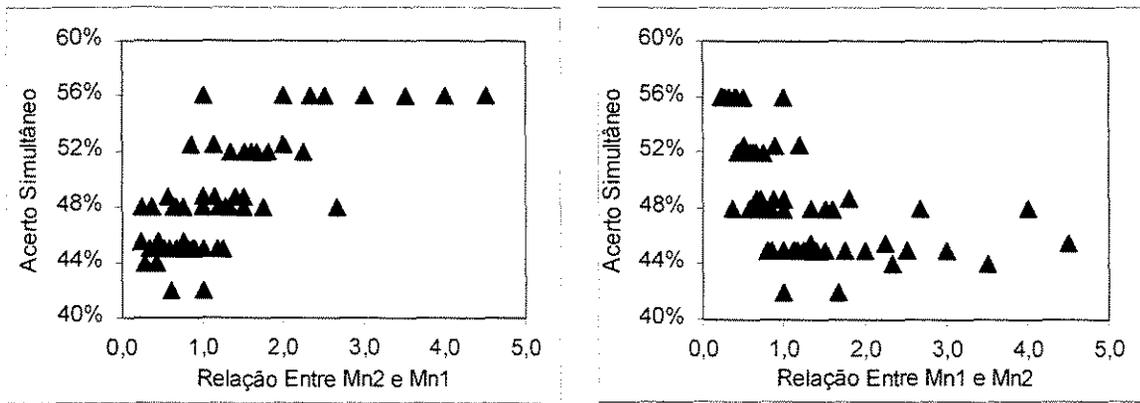


Figura 5.32 – Influência da relação entre as camadas ocultas no acerto simultâneo de RDI e RI para o analisador virtual simplificado.

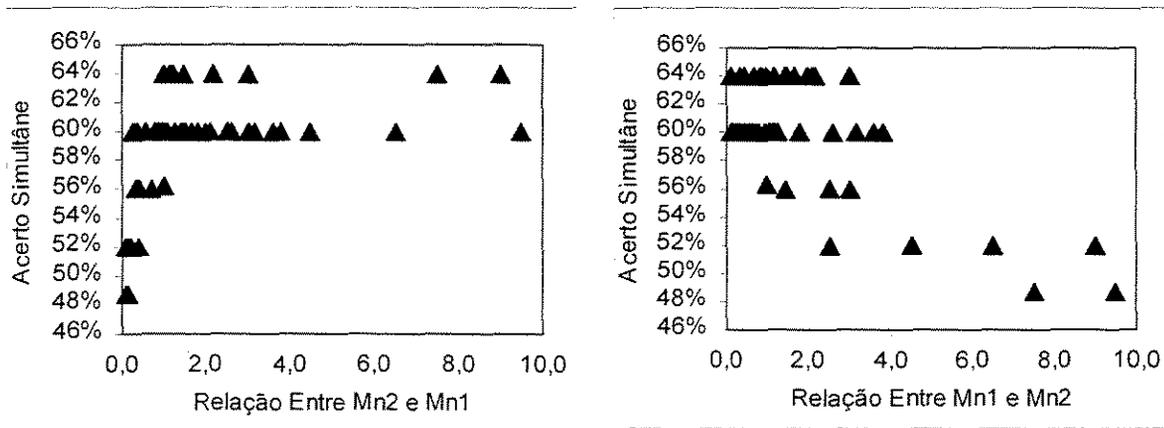


Figura 5.33 – Influência da relação entre as camadas ocultas no acerto simultâneo de RDI e RI para o analisador virtual completo.

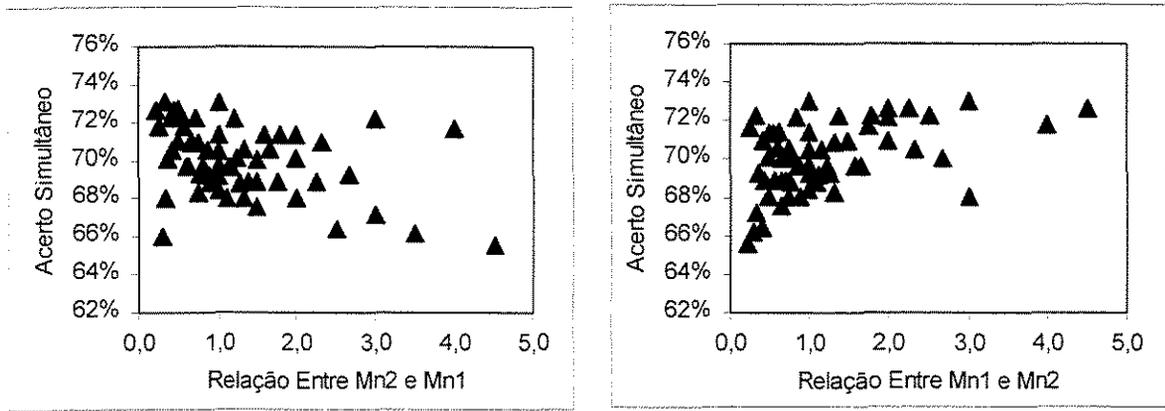


Figura 5.34 – Influência da relação entre as camadas ocultas no acerto simultâneo de C e T para o modelo dinâmico.

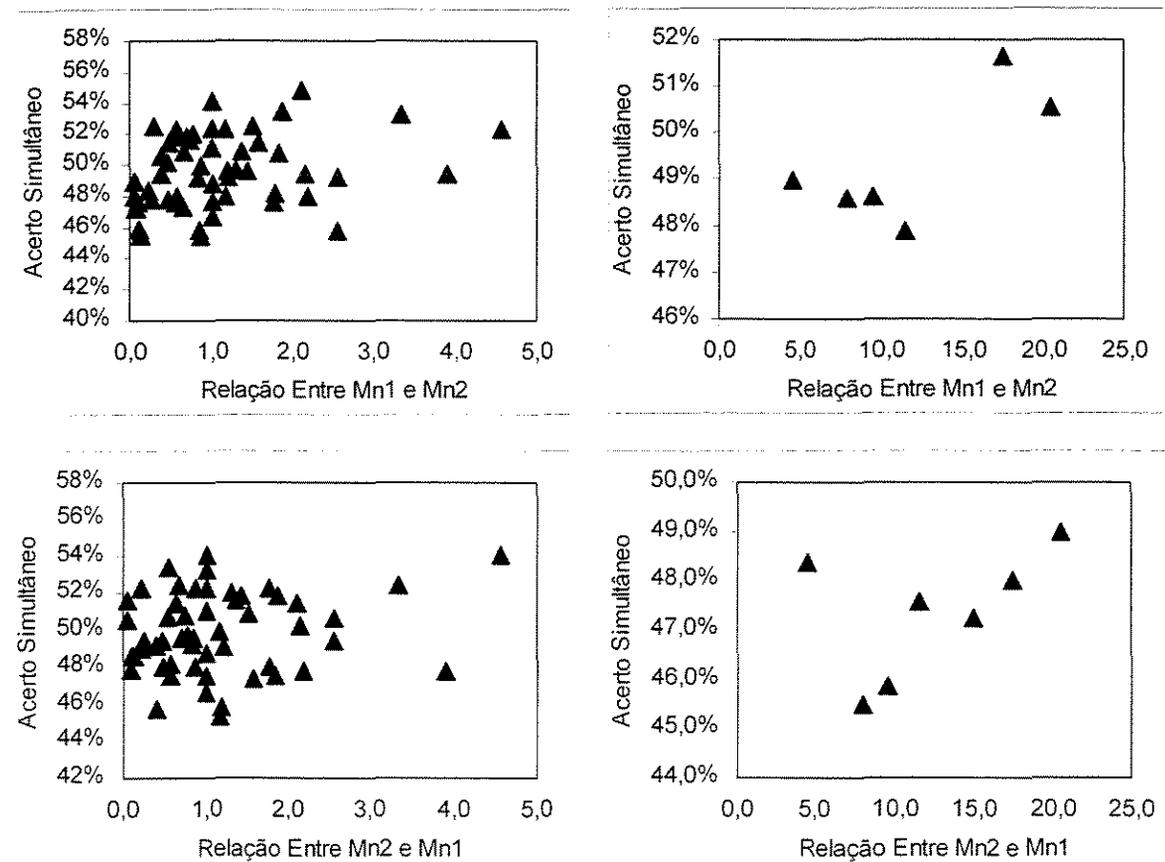


Figura 5.35 – Influência da relação entre as camadas ocultas no acerto simultâneo de C e T para o modelo estático.

A análise do número de conexões totais e entre o número de conexões entre as camadas das redes são mostradas nas figuras 5.36 a 5.39 (considere L_n o número de entradas e N_n o número de saídas).

Os números de conexões totais confirmam o que foi relatado com a análise do número de neurônios ocultos, ou seja, são necessárias maiores quantidades de conexões para redes com um número maior de entradas para obter melhor generalização.

Já o número de conexões entre o número de entradas e o número de neurônios da primeira camada oculta deve diminuir para redes que trabalham com um banco de dados pequeno e aumentar para redes que trabalham com um banco de dados grande, buscando a melhoria da generalização.

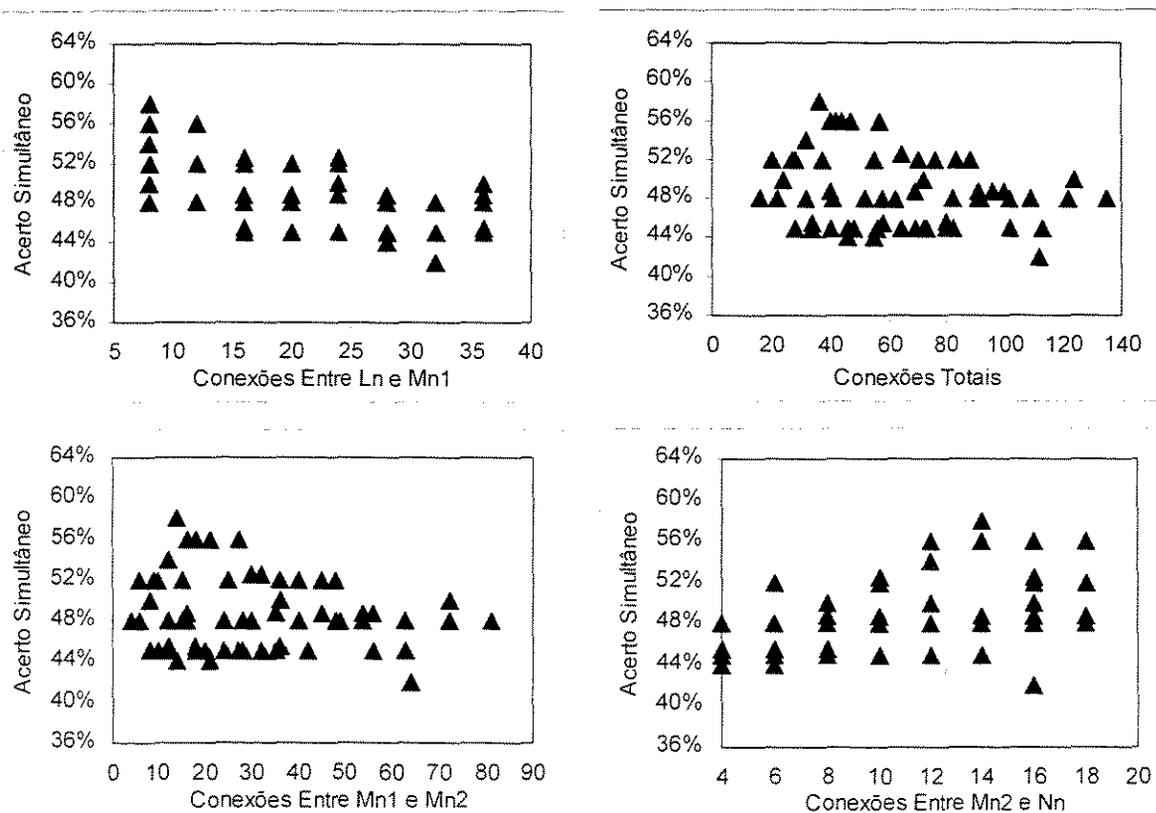


Figura 5.36 – Avaliação da influência da quantidade de conexões entre os neurônios no acerto simultâneo de RDI e RI para o analisador virtual simplificado.

O número de conexões entre Mn1 e Mn2 deve aumentar para se obter bom acerto simultâneo nos casos de redes com um número maior de entradas (como foi observado para o caso estudado do modelo estático e analisador completo).

Para as conexões entre Mn2 e Nn verificou-se que o aumento da generalização ocorreu com o aumento do número destas conexões para os casos dos dois analisadores virtuais e do modelo estático (baixa correlação para este último modelo). Já para o modelo dinâmico observou-se um comportamento contrário.

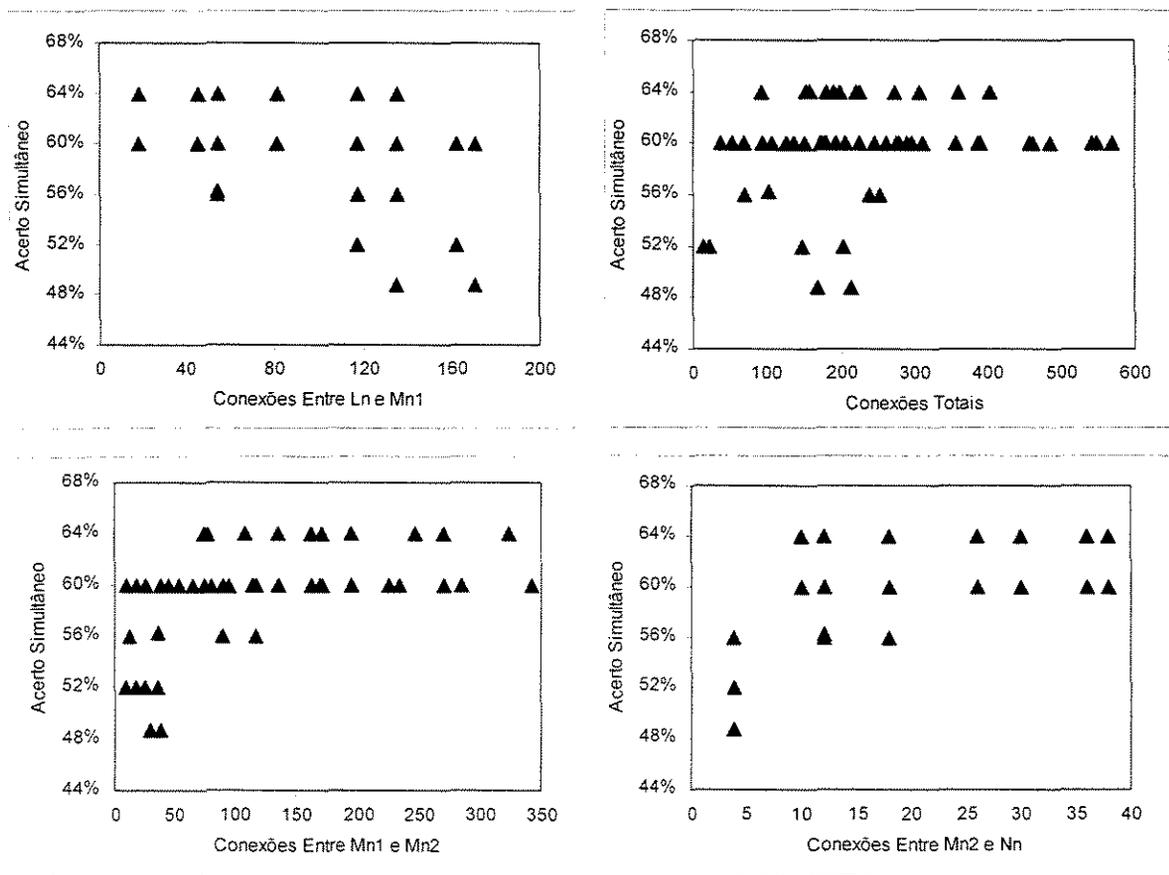


Figura 5.37 – Avaliação da influência da quantidade de conexões entre os neurônios no acerto simultâneo de RDI e RI para o analisador virtual completo.

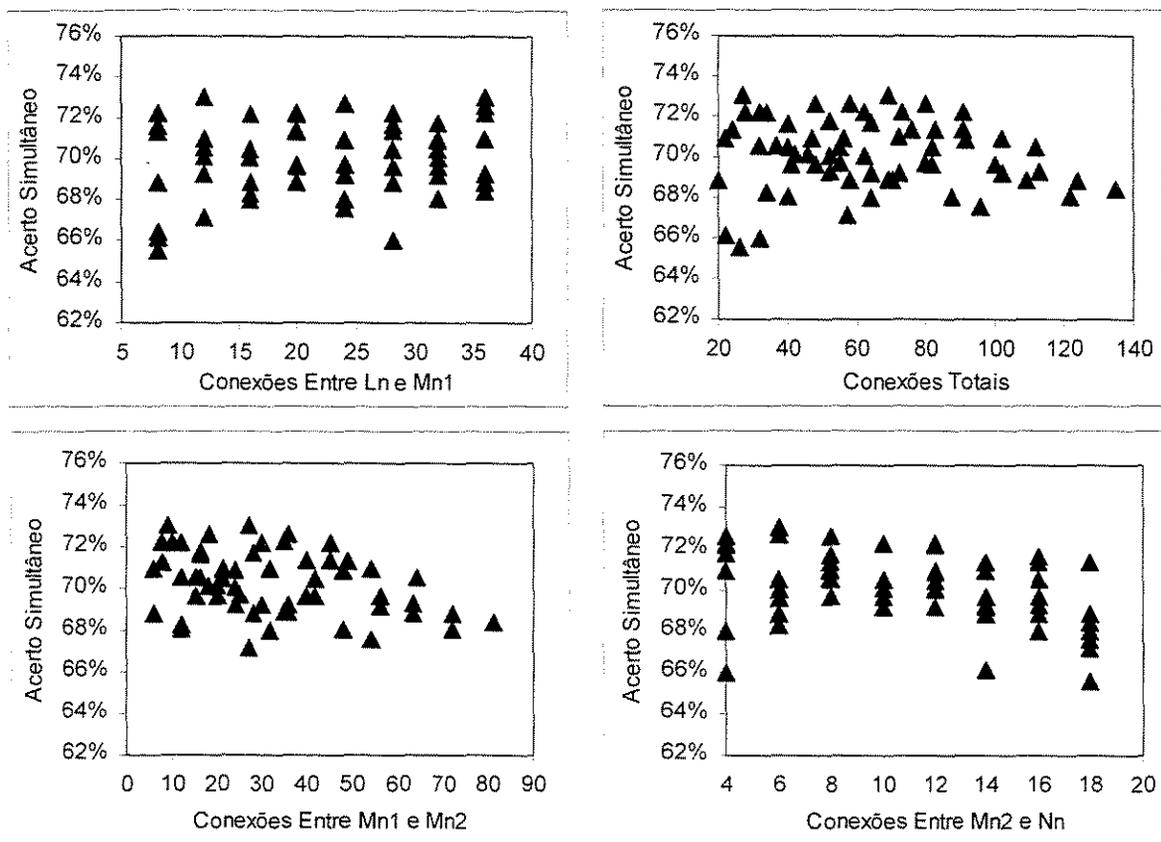


Figura 5.38 – Avaliação da influência da quantidade de conexões entre os neurônios no acerto simultâneo de C e T para o modelo dinâmico.

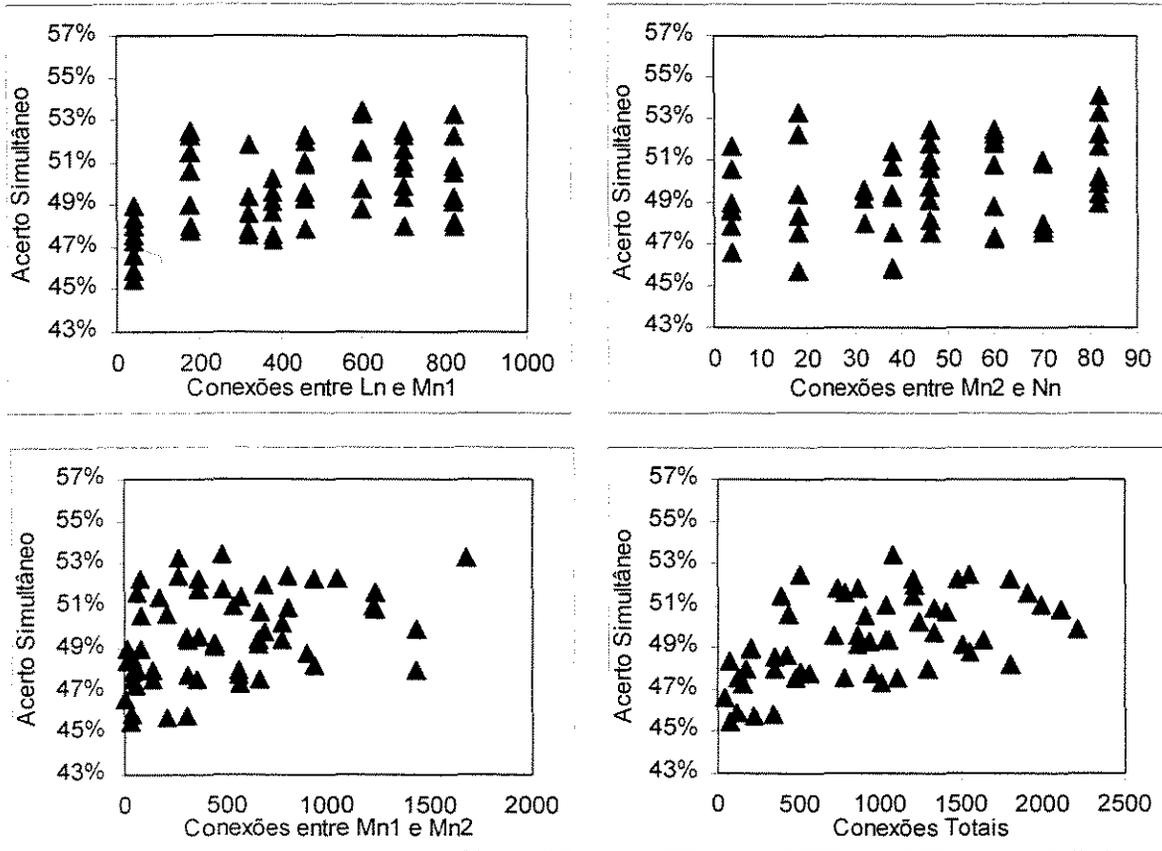


Figura 5.39 – Avaliação da influência da quantidade de conexões entre os neurônios no acerto simultâneo de C e T para o modelo estático.

Assim, em resumo, o total de conexões ocultas da rede neural define a generalização em função do número de entradas da rede. **Uma melhor generalização é obtida a partir do aumento dos neurônios ocultos quando o número de entradas da rede aumenta.**

Já o aumento do tamanho do banco de dados influi positivamente na generalização quando Mn1, a relação entre Mn1 e Mn2 e o número de conexões entre Ln e Mn1 aumentam. **Logo, o aumento do banco de dados necessita de um aumento do número de neurônios da primeira camada oculta para aumentar a generalização.**

Quando avaliamos a relação entre Mn2 e Mn1, a quantidade de Mn2 e a de conexões entre Mn2 e Nn, observamos que o aumento destas variáveis melhoraram a

generalização para os analisadores virtuais e para o modelo estático. **Desta forma, para banco de dados pequeno, independente do número de entradas, deve-se aumentar o Mn2 para se obter melhor generalização. E para banco de dados grande, deve-se diminuir o Mn2 para um número de entradas pequeno e aumentar-se o Mn2 para um número de entradas grande.**

5.3 AJUSTES FINAIS DOS PARÂMETROS DE REDES NEURAIIS ARTIFICIAIS

Através da utilização da técnica de planejamento e otimização de experimentos, pôde-se observar que para as redes estudadas, altos valores de coeficientes de aprendizado e de *momentum* trouxeram os melhores resultados, assim como o uso da função sigmoideal. Observou-se também que, para as redes que receberam um grande volume de dados para treinamento, foi necessário uma estrutura de quatro camadas, ao passo que as redes com três camadas foram as mais adequadas aos processos que trabalharam com pequeno banco de dados. E em geral, valores para as bias iguais a 1 produziram os melhores resultados. Os pesos entre -1 e $+1$ ajudaram os melhores resultados, concordando com a Atiya e Ji⁽⁵⁶⁾, que definiram que não são pesos iniciais pequenos que determinam melhores resultados.

Baseado nas informações obtidas das simulações com o planejamento e otimização de experimentos (onde se varia tudo ao mesmo tempo e avalia-se além dos efeitos principais os efeitos das interações), buscou-se melhores ajustes dos parâmetros de redes neurais mediante as melhores condições ajustadas neste planejamento de experimentos em combinação com variações de arquitetura.

5.3.1 RESULTADOS PARA OS ANALISADORES VIRTUAIS

Os resultados iniciais para o analisador virtual simplificado indicaram que a RNA de arquitetura 4x9x2 (generalização média = 48,0%) foi melhor que a de arquitetura 4x6x3x2 (generalização média = 44,0%), sendo as duas com a mesma quantidade de neurônios ocultos. Já a arquitetura de rede 4x8x2 (generalização média = 50,3%) possui a mesma quantidade de conexões que a rede 4x6x3x2, o que mostra melhores resultados para as redes com três camadas. Mesmo havendo um indicativo de melhor rede com a estrutura de três camadas, realizou-se um estudo de arquitetura para confirmar esta tendência, considerando não só as estruturas de três quanto as de quatro camadas. O ajuste para o analisador virtual simplificado considerou os parâmetros da tabela 5.7 e os resultados obtidos estão na tabela 5.8.

Tabela 5.7 - Valores dos parâmetros da RNA utilizados para ajuste dos analisadores virtuais.

Fatores	Valores
Coeficiente de Aprendizado	0,7
Coeficiente de Momentum	0,7
Tipo de Função de Ativação	Sigmoidal
Bias Residuais da Primeira Camada	1
Bias Residuais das Demais Camadas	1
Pesos Iniciais	Entre -1 e +1

Tabela 5.8 - Resultados das simulações com variação da arquitetura para o analisador virtual simplificado.

ESTUDO PARA 4 CAMADAS			
	RDI	RI	acertsim
4x2x2x2	80,0%	60,0%	48,0%
4x2x3x2	80,0%	65,0%	52,0%
4x2x4x2	80,0%	70,0%	56,0%
4x2x5x2	80,0%	70,0%	56,0%
4x2x6x2	80,0%	70,0%	56,0%
4x2x7x2	80,0%	70,0%	56,0%
4x2x8x2	80,0%	70,0%	56,0%
4x2x9x2	80,0%	70,0%	56,0%
4x3x2x2	80,0%	60,0%	48,0%
4x3x3x2	80,0%	70,0%	56,0%
4x3x4x2	80,0%	60,0%	48,0%
4x3x5x2	80,0%	65,0%	52,0%
4x3x6x2	80,0%	70,0%	56,0%
4x3x7x2	80,0%	70,0%	56,0%
4x3x8x2	80,0%	60,0%	48,0%
4x3x9x2	80,0%	70,0%	56,0%
4x4x2x2	75,0%	60,0%	45,0%
4x4x3x2	70,0%	65,0%	45,5%
4x4x4x2	75,0%	65,0%	48,8%
4x4x5x2	75,0%	60,0%	45,0%
4x4x6x2	80,0%	60,0%	48,0%
4x4x7x2	80,0%	60,0%	48,0%
4x4x8x2	75,0%	70,0%	52,5%
4x4x9x2	80,0%	65,0%	52,0%
4x5x2x2	75,0%	60,0%	45,0%
4x5x3x2	70,0%	60,0%	42,0%
4x5x4x2	75,0%	60,0%	45,0%
4x5x5x2	80,0%	70,0%	56,0%
4x5x6x2	80,0%	60,0%	48,0%
4x5x7x2	75,0%	65,0%	48,8%
4x5x8x2	80,0%	65,0%	52,0%
4x5x9x2	80,0%	65,0%	52,0%
4x6x2x2	75,0%	60,0%	45,0%
4x6x3x2	75,0%	60,0%	45,0%
4x6x4x2	75,0%	60,0%	45,0%
4x6x5x2	75,0%	70,0%	52,5%
4x6x6x2	75,0%	60,0%	45,0%
4x6x7x2	75,0%	60,0%	45,0%
4x6x8x2	80,0%	65,0%	52,0%
4x6x9x2	75,0%	65,0%	48,8%
4x7x2x2	80,0%	55,0%	44,0%
4x7x3x2	80,0%	55,0%	44,0%
4x7x4x2	75,0%	60,0%	45,0%
4x7x5x2	75,0%	60,0%	45,0%
4x7x6x2	75,0%	60,0%	45,0%
4x7x7x2	80,0%	60,0%	48,0%
4x7x8x2	75,0%	65,0%	48,8%
4x7x9x2	80,0%	60,0%	48,0%
4x8x2x2	80,0%	60,0%	48,0%
4x8x3x2	80,0%	60,0%	48,0%
4x8x4x2	75,0%	60,0%	45,0%
4x8x5x2	80,0%	60,0%	48,0%
4x8x6x2	80,0%	60,0%	48,0%
4x8x7x2	75,0%	60,0%	45,0%
4x8x8x2	70,0%	60,0%	42,0%
4x8x9x2	75,0%	70,0%	52,5%
4x9x2x2	70,0%	65,0%	45,5%
4x9x3x2	75,0%	60,0%	45,0%
4x9x4x2	70,0%	65,0%	45,5%
4x9x5x2	75,0%	65,0%	48,8%
4x9x6x2	80,0%	60,0%	48,0%
4x9x7x2	75,0%	60,0%	45,0%
4x9x8x2	75,0%	60,0%	45,0%
4x9x9x2	75,0%	60,0%	45,0%

ESTUDO PARA 3 CAMADA			
	RDI	RI	acertsim
4x7x2	80%	75%	60%
4x6x2	75%	75%	56%
4x5x2	75%	75%	56%
4x4x2	75%	75%	56%
4x3x2	75%	75%	56%
4x2x2	75%	75%	56%

A melhor rede neural foi a de arquitetura 4x7x2, com generalização máxima atingida em 60% para o acerto simultâneo, confirmando que a tendência encontrada no estudo do planejamento de experimentos indicava o caminho correto (redes com três camadas). E com esta rede neural, obteve-se os seguintes resultados de boa sensibilidade para a previsão de RDI, mas resultados com menor sensibilidade para RI:

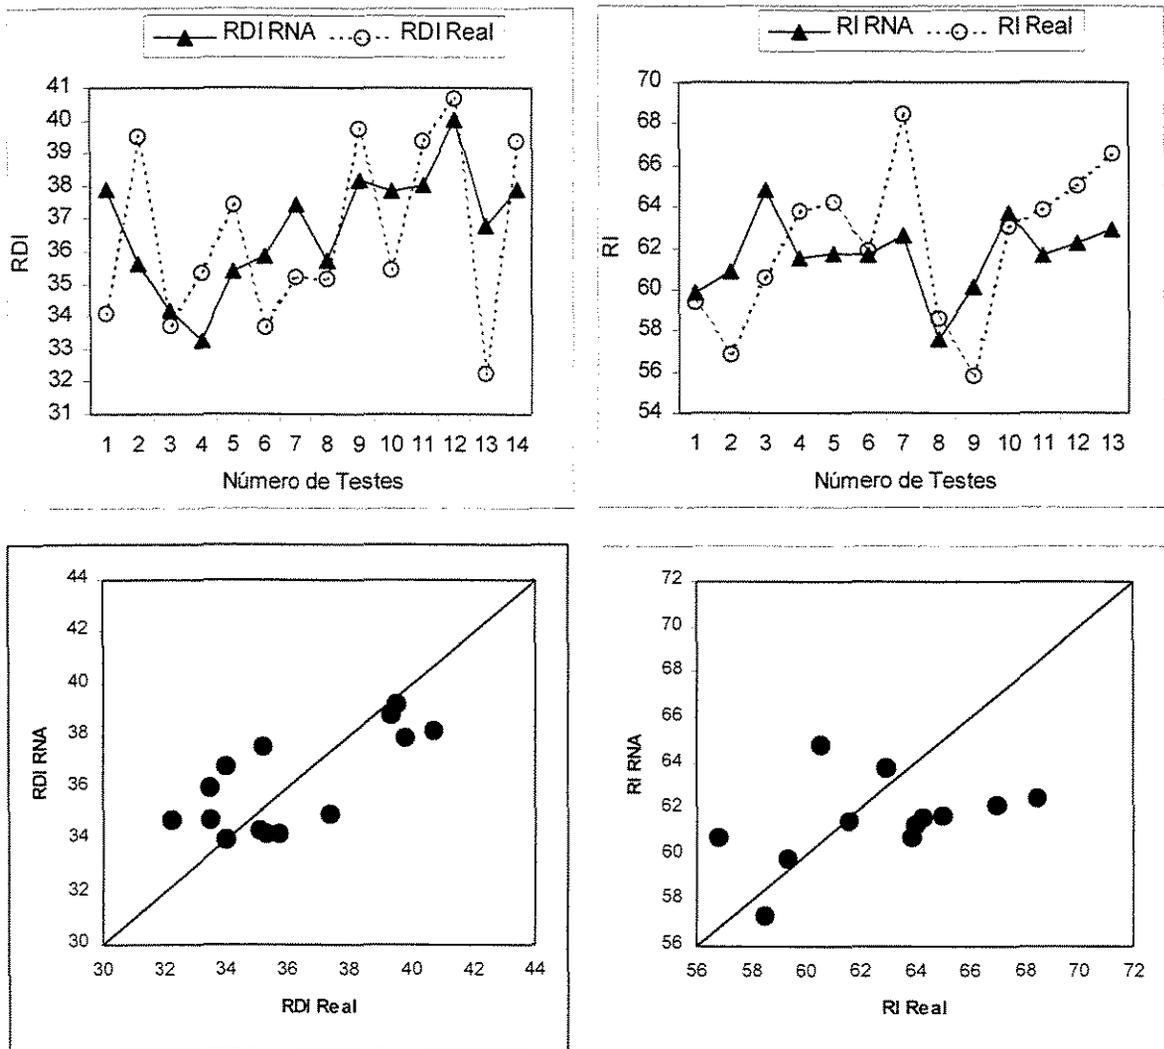


Figura 5.40 - Comparação entre resultados de RDI (% menor que 3,15 mm) e RI (% remoção de oxigênio) reais e calculados.

O ajuste para o analisador virtual completo considerou os parâmetros da tabela 5.7 e os resultados estão na tabela 5.9.

Tabela 5.9 - Resultados das simulações com variação da arquitetura para o analisador virtual completo.

ESTUDO PARA 4 CAMADAS			
	RDI	RI	acertsim
9x2x2x2	80,0%	65,0%	52,0%
9x2x3x2	80,0%	75,0%	60,0%
9x2x4x2	80,0%	80,0%	64,0%
9x2x5x2	80,0%	75,0%	60,0%
9x2x6x2	80,0%	75,0%	60,0%
9x2x7x2	80,0%	80,0%	64,0%
9x2x8x2	80,0%	80,0%	64,0%
9x2x9x2	80,0%	75,0%	60,0%
9x3x2x2	80,0%	65,0%	52,0%
9x3x3x2	80,0%	80,0%	64,0%
9x3x4x2	80,0%	80,0%	64,0%
9x3x5x2	80,0%	75,0%	60,0%
9x3x6x2	80,0%	75,0%	60,0%
9x3x7x2	80,0%	75,0%	60,0%
9x3x8x2	80,0%	75,0%	60,0%
9x3x9x2	80,0%	75,0%	60,0%
9x4x2x2	80,0%	70,0%	56,0%
9x4x3x2	80,0%	80,0%	64,0%
9x4x4x2	75,0%	75,0%	56,3%
9x4x5x2	80,0%	75,0%	60,0%
9x4x6x2	80,0%	80,0%	64,0%
9x4x7x2	80,0%	75,0%	60,0%
9x4x8x2	80,0%	80,0%	64,0%
9x4x9x2	80,0%	75,0%	60,0%
9x5x2x2	80,0%	65,0%	52,0%
9x5x3x2	80,0%	75,0%	60,0%
9x5x4x2	80,0%	80,0%	64,0%
9x5x5x2	80,0%	75,0%	60,0%
9x5x6x2	80,0%	75,0%	60,0%
9x5x7x2	80,0%	75,0%	60,0%
9x5x8x2	80,0%	75,0%	60,0%
9x5x9x2	80,0%	75,0%	60,0%
9x6x2x2	80,0%	65,0%	52,0%
9x6x3x2	80,0%	75,0%	60,0%
9x6x4x2	80,0%	80,0%	64,0%
9x6x5x2	80,0%	70,0%	56,0%
9x6x6x2	80,0%	75,0%	60,0%
9x6x7x2	80,0%	80,0%	64,0%
9x6x8x2	80,0%	75,0%	60,0%
9x6x9x2	80,0%	80,0%	64,0%
9x7x2x2	75,0%	65,0%	48,8%
9x7x3x2	80,0%	80,0%	64,0%
9x7x4x2	80,0%	70,0%	56,0%
9x7x5x2	80,0%	80,0%	64,0%
9x7x6x2	80,0%	75,0%	60,0%
9x7x7x2	80,0%	75,0%	60,0%
9x7x8x2	80,0%	80,0%	64,0%
9x7x9x2	80,0%	75,0%	60,0%
9x8x2x2	80,0%	65,0%	52,0%
9x8x3x2	80,0%	75,0%	60,0%
9x8x4x2	80,0%	80,0%	64,0%
9x8x5x2	80,0%	80,0%	64,0%
9x8x6x2	80,0%	65,0%	52,0%
9x8x7x2	80,0%	75,0%	60,0%
9x8x8x2	80,0%	80,0%	64,0%
9x8x9x2	80,0%	75,0%	60,0%
9x9x2x2	75,0%	65,0%	48,8%
9x9x3x2	80,0%	75,0%	60,0%
9x9x4x2	80,0%	75,0%	60,0%
9x9x5x2	80,0%	80,0%	64,0%
9x9x6x2	80,0%	80,0%	64,0%
9x9x7x2	80,0%	75,0%	60,0%
9x9x8x2	80,0%	75,0%	60,0%
9x9x9x2	80,0%	75,0%	60,0%

ESTUDO PARA 3 CAMADAS			
	RDI	RI	acertsim
9x18x2	80,0%	75,0%	60,0%
9x17x2	80,0%	80,0%	64,0%
9x16x2	80,0%	75,0%	60,0%
9x15x2	85,0%	80,0%	68,0%
9x14x2	85,0%	75,0%	63,8%
9x13x2	85,0%	75,0%	63,8%
9x12x2	80,0%	75,0%	60,0%
9x11x2	80,0%	75,0%	60,0%
9x10x3	80,0%	75,0%	60,0%
9x9x2	80,0%	80,0%	64,0%
9x8x2	80,0%	75,0%	60,0%
9x7x3	80,0%	75,0%	60,0%
9x6x2	80,0%	75,0%	60,0%
9x5x2	80,0%	75,0%	60,0%
9x4x2	80,0%	75,0%	60,0%
9x3x2	80,0%	75,0%	60,0%
9x2x2	75,0%	75,0%	56,3%

Os resultados do planejamento de experimentos (com as estruturas 9x19x2 e 9x13x6x2 de mesmo número de neurônios ocultos e praticamente a mesma quantidade de conexões totais) indicaram que, dos melhores ajustes, o melhor resultado médio foi obtido pela rede de três camadas, com o resultado de generalização médio de 52,3%, contra 51,8% para a rede de quatro camadas.

A melhor rede ajustada foi a de arquitetura 9x15x2, com generalização de 68%. Os resultados para esta rede estão na figura abaixo.

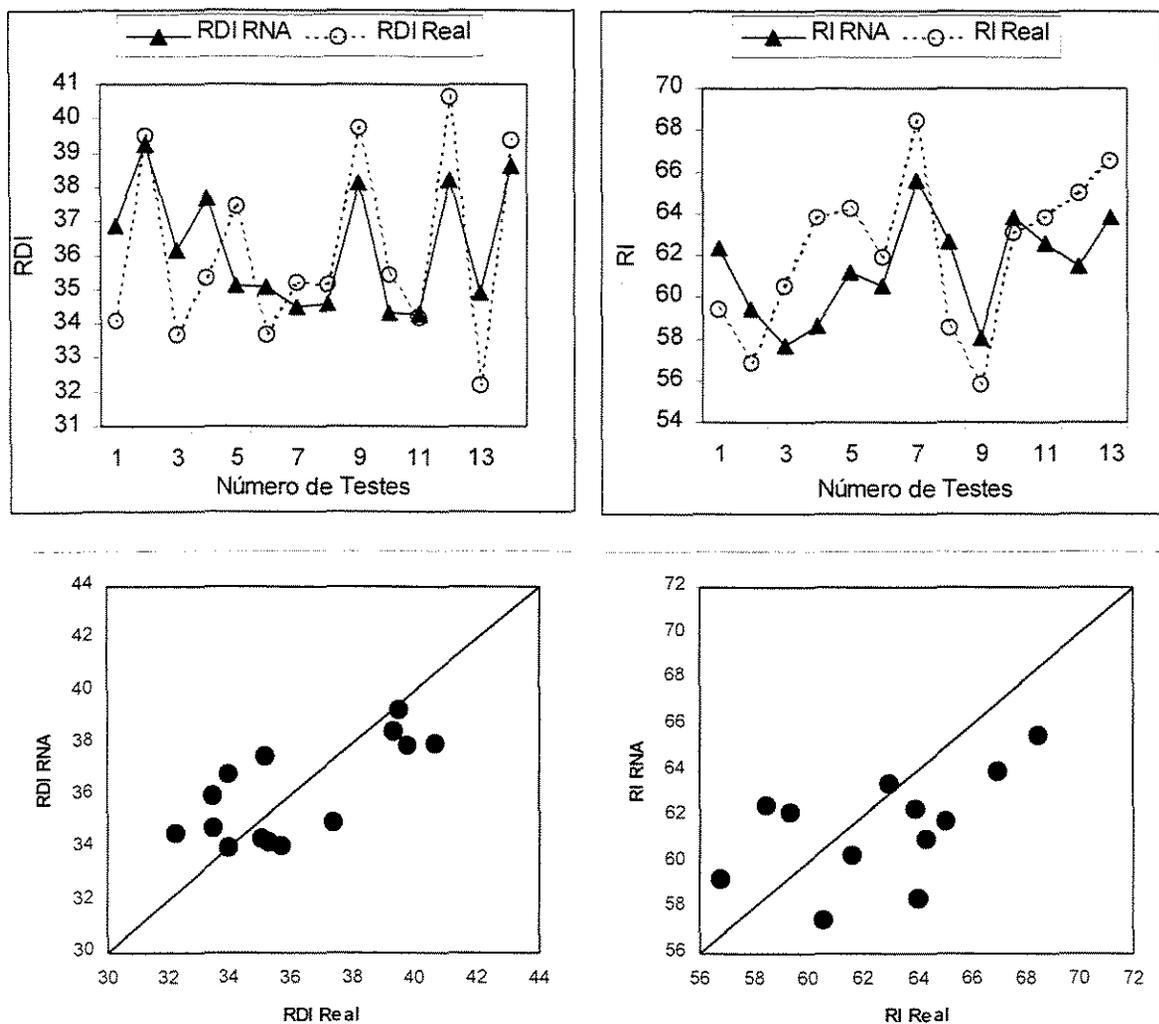


Figura 5.41 - Comparação entre resultados de RDI (% menor que 3,15 mm) e RI (% remoção de oxigênio) reais e calculados.

A figura 5.41 indica que os resultados obtidos via mineralogia e química, de forma combinada, apresentaram sensibilidade pouco maior que os obtidos com análise química.

Estes resultados finais dos analisadores virtuais indicaram que não houve diferença significativa de resultados entre os estudos para os analisadores simplificado e completo. O erro relativo médio foi de 4,5% para todas as variáveis estudadas (RDI e RI). Assim, os resultados de RDI não atingiram os níveis de erros relativos dos ensaios de laboratório com base na norma ISO 4696-1 (em torno de 2 a 4%). Mas os erros médios atingidos pela previsão de RI foram satisfatórios, uma vez que para o ensaio pela norma ISO 7215 é admitido um erro relativo entre 7 e 11%.

É importante notar que os resultados obtidos para RDI estão muito próximos dos erros permitidos pela norma ISO, o que prova que não só os resultados para RI foram satisfatórios. A proposta de um analisador virtual destas propriedades deverá se tornar viável a partir do enriquecimento do banco de dados com a inclusão de mais análises laboratoriais, o que determinará, segundo o fundamento de aprendizado de uma rede neural, uma maior capacidade de generalização da rede.

5.3.2 RESULTADOS PARA OS MODELOS DE ACIARIA

No estudo realizado para o modelo dinâmico (com distribuição normal das variáveis no anexo H) simulou-se situações em que redes com diferentes números de camadas possuíam a mesma quantidade de neurônios ocultos: as de arquitetura 4x8x2 (generalização média = 64,9%) e 4x4x4x2 (generalização média = 67,3%) e as de arquitetura 4x9x2 (generalização média = 64,8%) e 4x6x3x2 (generalização média = 66,5%). Os resultados médios obtidos para as redes com quatro camadas (67,3% e 66,5%) foram superiores aos obtidos com três camadas (64,9% e 64,8%). As redes 4x8x2 e 4x6x3x2 possuíam ainda o mesmo número de conexões e o resultado para a rede com quatro camadas também foi superior.

Como as simulações indicaram um melhor resultado para as redes de quatro camadas, um estudo foi realizado com os parâmetros que produziram o melhor resultado para as simulações somente com redes de quatro camadas. Os valores dos parâmetros de rede utilizados para o estudo da variação da arquitetura foram os da tabela 5.10.

Tabela 5.10 - Valores dos parâmetros da RNA utilizados para ajuste do modelo dinâmico.

Fatores	Valores
Coeficiente de Aprendizado	0,7
Coeficiente de Momentum	0,7
Tipo de Função de Ativação	Sigmoidal
Bias Residuais da Primeira Camada	0
Bias Residuais das Demais Camadas	1
Pesos Iniciais	Entre -1 e +1

As simulações com redes de quatro camadas apresentaram os resultados descritos na tabela 5.11.

Tabela 5.11 - Resultados das simulações com variação da arquitetura para o modelo dinâmico.

	C	T	acertsim
4x2x2x2	84,5%	67,0%	
4x2x3x2	81,0%	85,0%	68,9%
4x2x4x2	82,0%	87,0%	71,3%
4x2x5x2	82,0%	81,0%	66,4%
4x2x6x2	83,5%	86,5%	72,2%
4x2x7x2	76,5%	86,5%	66,2%
4x2x8x2	80,5%	89,0%	71,6%
4x2x9x2	79,0%	83,0%	65,6%
4x3x2x2	82,5%	86,0%	71,0%
4x3x3x2	83,0%	88,0%	73,0%
4x3x4x2	84,0%	84,0%	70,6%
4x3x5x2	83,0%	85,0%	70,6%
4x3x6x2	82,0%	85,5%	70,1%
4x3x7x2	82,5%	86,0%	71,0%
4x3x8x2	81,5%	85,0%	69,3%
4x3x9x2	79,5%	84,5%	67,2%
4x4x2x2	82,5%	87,5%	72,2%
4x4x3x2	78,5%	87,0%	68,3%
4x4x4x2	82,0%	86,0%	70,5%
4x4x5x2	82,5%	85,0%	70,1%
4x4x6x2	81,0%	86,5%	70,1%
4x4x7x2	81,0%	85,0%	68,9%
4x4x8x2	80,5%	84,5%	68,0%
4x4x9x2	82,0%	84,0%	68,9%
4x5x2x2	84,0%	86,0%	72,2%
4x5x3x2	80,5%	86,5%	69,6%
4x5x4x2	81,0%	86,0%	69,7%
4x5x5x2	83,0%	84,0%	69,7%
4x5x6x2	83,0%	87,0%	72,2%
4x5x7x2	81,5%	84,5%	68,9%
4x5x8x2	83,0%	86,0%	71,4%
4x5x9x2	82,5%	86,5%	71,4%
4x6x2x2	81,0%	84,0%	68,0%
4x6x3x2	83,5%	87,0%	72,6%
4x6x4x2	82,0%	86,5%	70,9%
4x6x5x2	80,5%	86,0%	69,2%
4x6x6x2	80,5%	86,0%	69,2%
4x6x7x2	81,5%	85,5%	69,7%
4x6x8x2	81,0%	84,0%	68,0%
4x6x9x2	80,0%	84,5%	67,6%
4x7x2x2	82,0%	80,5%	66,0%
4x7x3x2	81,5%	86,5%	70,5%
4x7x4x2	81,5%	88,0%	71,7%
4x7x5x2	84,5%	85,5%	72,2%
4x7x6x2	81,0%	87,0%	70,5%
4x7x7x2	83,0%	86,0%	71,4%
4x7x8x2	81,0%	86,0%	69,7%
4x7x9x2	80,5%	85,5%	68,8%
4x8x2x2	82,5%	87,0%	71,8%
4x8x3x2	81,0%	86,5%	70,1%
4x8x4x2	84,5%	84,0%	71,0%
4x8x5x2	81,0%	86,0%	69,7%
4x8x6x2	81,0%	87,5%	70,9%
4x8x7x2	80,0%	86,5%	69,2%
4x8x8x2	82,0%	86,0%	70,5%
4x8x9x2	82,5%	82,5%	68,1%
4x9x2x2	83,0%	87,5%	72,6%
4x9x3x2	83,0%	88,0%	73,0%
4x9x4x2	83,0%	87,5%	72,6%
4x9x5x2	84,0%	86,0%	72,2%
4x9x6x2	82,5%	86,0%	71,0%
4x9x7x2	82,0%	84,5%	69,3%
4x9x8x2	80,5%	85,5%	68,8%
4x9x9x2	81,0%	84,5%	68,4%

Uma das melhores redes, a de arquitetura 4x9x3x2, produziu os seguintes resultados:

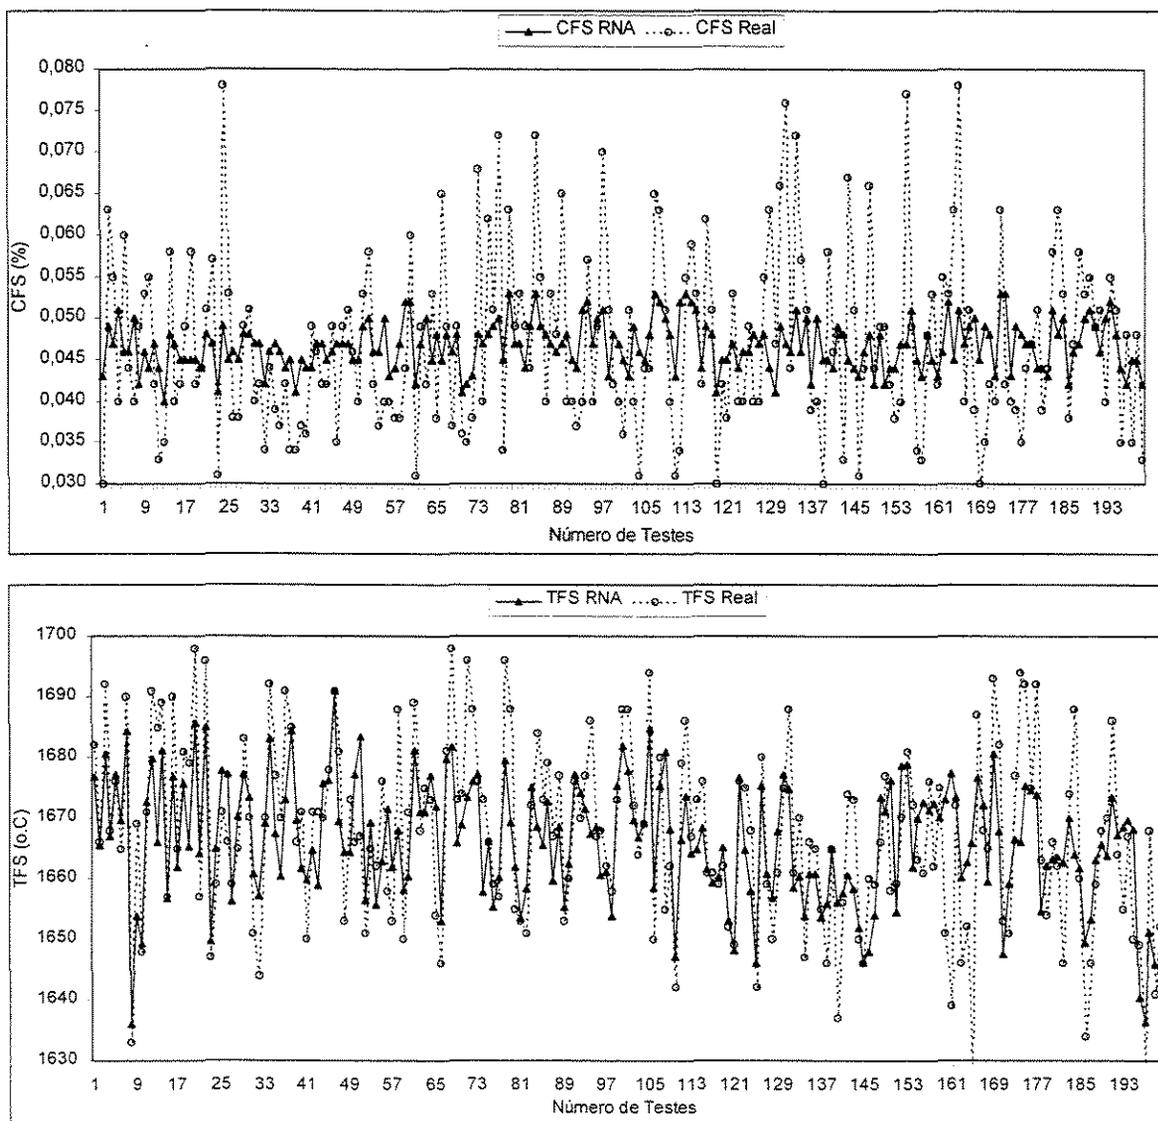


Figura 5.42 - Comparação dentre resultados de CFS e de TFS reais e calculados.

Para o caso da temperatura, foi encontrada melhor sensibilidade, com os resultados previstos acompanhando os reais. Isto é função do erro permissível para as duas variáveis, ou seja, 0,85% para TFS e 27% para CFS. A figura 5.43 mostra os resultados de uma outra forma. Entretanto, o importante é atingir o que o mercado está exigindo. Assim, apesar da avaliação das variáveis indicar um melhor resultado para a temperatura de fim de sopro, os limites de especificação dos aços permitem esta variação do carbono, que é grande para a

situação de fim de sopro mas extremamente pequena quando comparada ao aporte inicial de carbono, cerca de 3,5 a 4,5% na carga inicial. Uma das condições que ajudam o acerto de temperatura de fim de sopro é a utilização do mesmo medidor de nos momentos de atuação do modelo dinâmico e da verificação da temperatura do produto. Isto não ocorre para o carbono, que utiliza da inferência da temperatura de solidificação da amostra do aço para a estimativa do teor de carbono no momento da atuação do modelo dinâmico e a análise do teor de carbono de fim de sopro é realizada via aparelhos de raios X. Assim, o sistema atual foi montado de acordo com a exigência do mercado e, na verdade, o que importa é a obtenção do acerto simultâneo para o aumento da produtividade.

Desta forma, observa-se que o modelo estático é importante para a situação de início de sopro, para direcionar o refino até a atuação do modelo dinâmico.

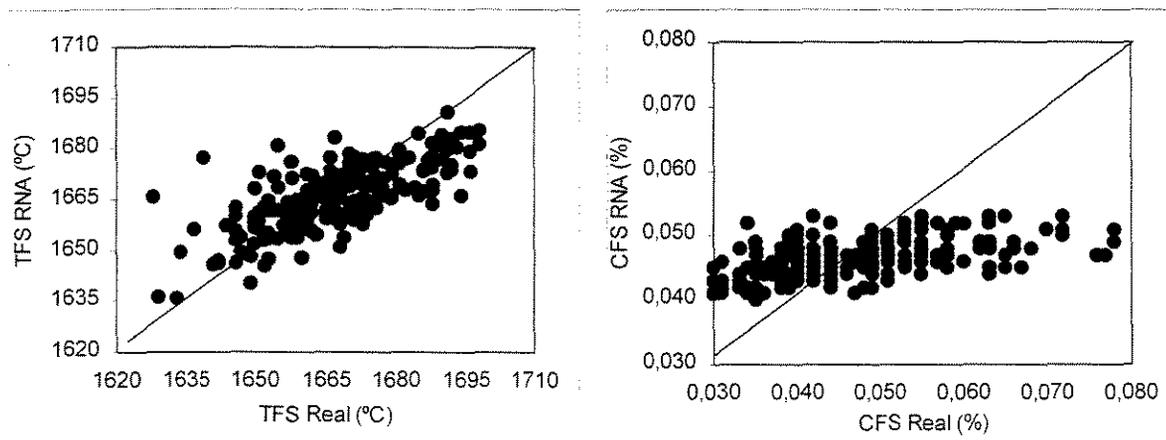


Figura 5.43 - Comparação dos resultados de TFS e CFS reais e calculados.

O último caso estudado foi o do modelo estático. Neste, a RNA de arquitetura 20x40x2 (generalização média = 48,1%) e a de arquitetura 20x20x20x2 (generalização média = 48,7%) possuíam a mesma quantidade de neurônios ocultos e a mesma quantidade de conexões. O resultado obtido para a rede neural artificial com quatro camadas foi um pouco superior. Foi também realizado um estudo para a avaliação da influência da arquitetura, considerando os parâmetros de rede da tabela 5.7, que também indicaram melhores ajustes para esta modelagem. Os resultados estão na tabela 5.12.

Tabela 5.12 - Resultados das simulações com variação da arquitetura para o modelo estático.

	C	T	acertsim
20x2x9x2	82,0%	59,0%	48,4%
20x2x16x2	75,0%	61,0%	45,8%
20x2x19x2	74,0%	62,0%	45,9%
20x2x23x2	78,0%	61,0%	47,6%
20x2x30x2	75,0%	63,0%	47,3%
20x2x35x2	75,0%	64,0%	48,0%
20x2x41x2	79,0%	62,0%	49,0%
20x9x9x2	83,0%	63,0%	52,3%
20x9x16x2	80,0%	60,0%	48,0%
20x9x19x2	83,0%	62,0%	51,5%
20x9x23x2	83,0%	61,0%	50,6%
20x9x30x2	82,0%	64,0%	52,5%
20x9x35x2	81,0%	59,0%	47,8%
20x9x41x2	82,0%	66,0%	54,1%
20x16x9x2	78,0%	61,0%	47,6%
20x16x16x2	82,0%	66,0%	54,1%
20x16x19x2	79,0%	58,0%	45,8%
20x16x23x2	81,0%	64,0%	51,8%
20x16x30x2	81,0%	64,0%	51,8%
20x16x35x2	81,0%	59,0%	47,8%
20x16x41x2	81,0%	61,0%	49,4%
20x19x9x2	83,0%	66,0%	54,8%
20x19x16x2	74,0%	67,0%	49,6%
20x19x19x2	78,0%	61,0%	47,6%
20x19x23x2	78,0%	63,0%	49,1%
20x19x30x2	74,0%	64,0%	47,4%
20x19x35x2	82,0%	58,0%	47,6%
20x19x41x2	81,0%	62,0%	50,2%
20x23x9x2	75,0%	61,0%	45,8%
20x23x16x2	80,0%	62,0%	49,6%
20x23x19x2	77,0%	64,0%	49,3%
20x23x23x2	81,0%	63,0%	51,0%
20x23x30x2	80,0%	65,0%	52,0%
20x23x35x2	76,0%	67,0%	50,9%
20x23x41x2	83,0%	63,0%	52,3%
20x30x9x2	82,0%	65,0%	53,3%
20x30x16x2	81,0%	66,0%	53,5%
20x30x19x2	83,0%	62,0%	51,5%
20x30x23x2	79,0%	63,0%	49,8%
20x30x30x2	80,0%	61,0%	48,8%
20x30x35x2	81,0%	56,0%	45,4%
20x30x41x2	82,0%	63,0%	51,7%
20x35x9x2	81,0%	61,0%	49,4%
20x35x16x2	80,0%	60,0%	48,0%
20x35x19x2	86,0%	59,0%	50,7%
20x35x23x2	82,0%	64,0%	52,5%
20x35x30x2	83,0%	63,0%	52,3%
20x35x35x2	81,0%	63,0%	51,0%
20x35x41x2	78,0%	64,0%	49,9%
20x41x9x2	83,0%	63,0%	52,3%
20x41x16x2	82,0%	60,0%	49,2%
20x41x19x2	81,0%	61,0%	49,4%
20x41x23x2	79,0%	61,0%	48,2%
20x41x30x2	82,0%	62,0%	50,8%
20x41x35x2	80,0%	60,0%	48,0%
20x41x41x2	82,0%	65,0%	53,3%

A melhor rede neural ajustada foi a de estrutura 20x19x9x2, que apresentou generalização de 54,8% e gerou os seguintes resultados de previsão para cada variável (figuras 5.44 e 5.45):

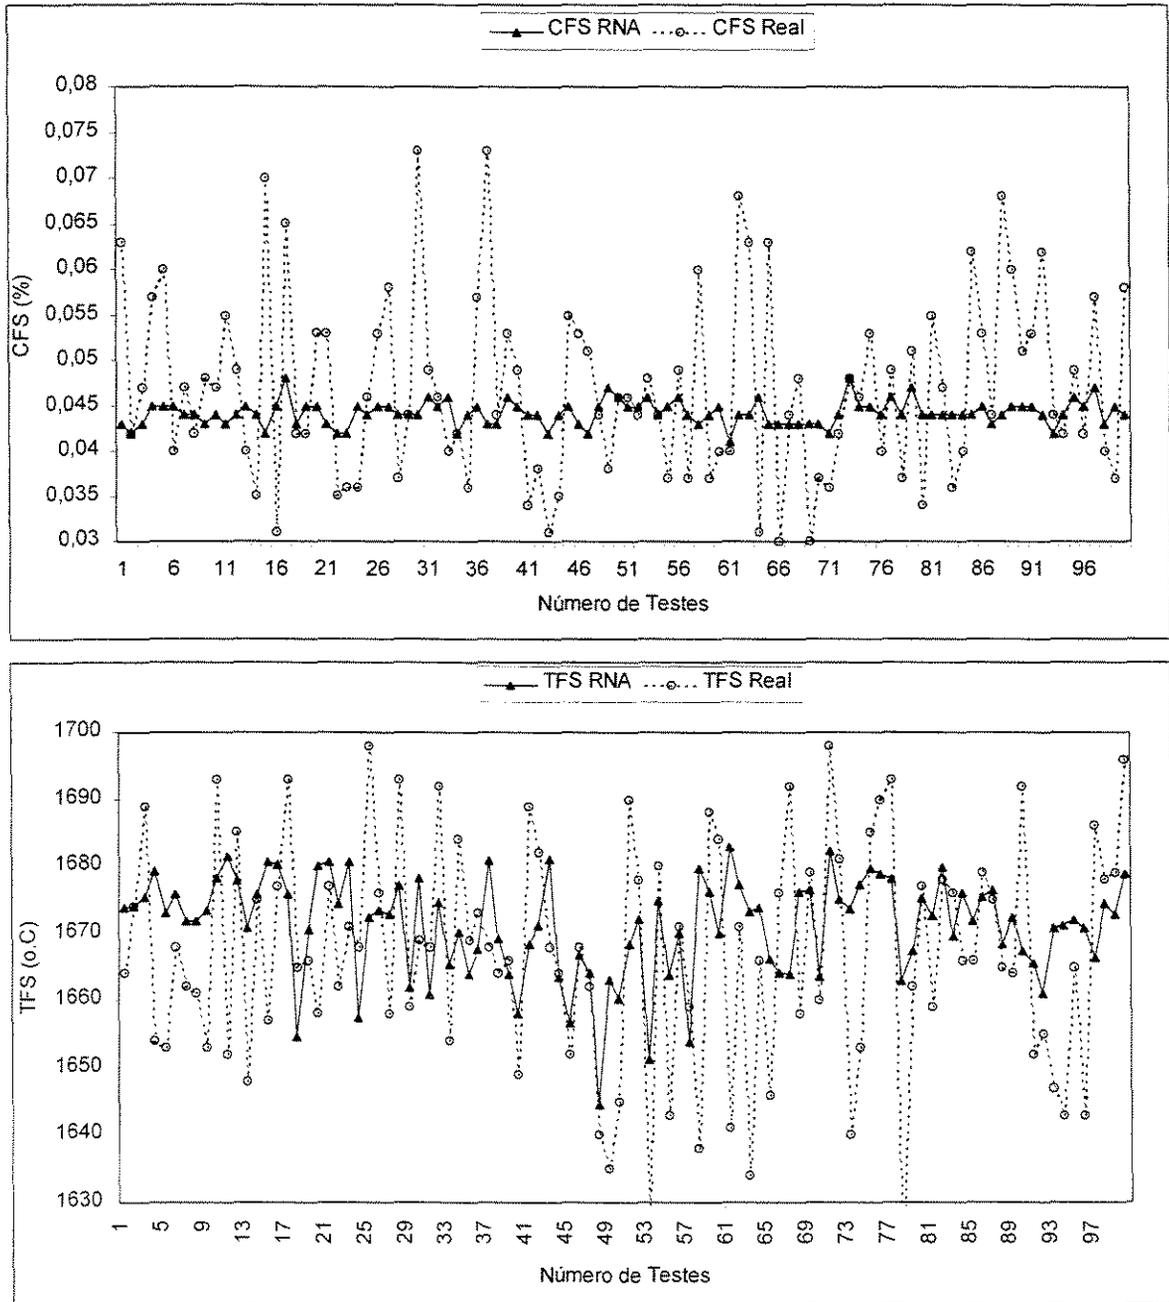


Figura 5.44 - Comparação dentre resultados de CFS e de TFS reais e calculados.

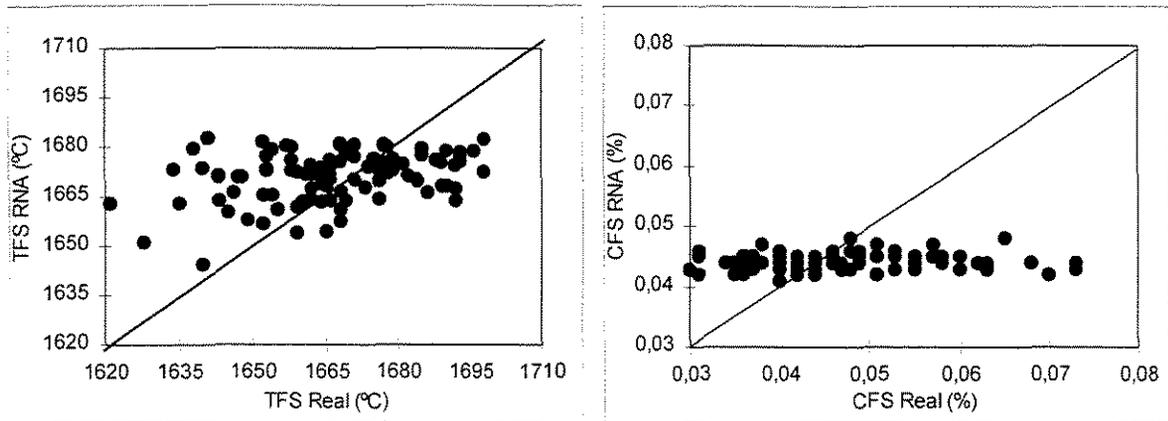


Figura 5.45 - Comparação dos resultados de TFS e CFS reais e calculados.

Novamente, foi obtida melhor sensibilidade para a previsão da TFS e fraca sensibilidade para a previsão do carbono de fim de sopro. Neste caso, além da atribuição de grande oscilação química das matérias primas (com algumas, como sucatas, sem caracterização) não se utiliza a análise do teor de carbono do gusa, o que prejudica muito o modelo de previsão.

Dos ajustes sugeridos na literatura para arquitetura de rede, somente o estudo para as variáveis do modelo dinâmico concordaram com o sugerido pelos autores Maren⁽⁵²⁾ (com a arquitetura de rede 4x9x3x2) e Villiers e Barnard⁽⁵⁶⁾ (com a arquitetura de rede 4x3x3x2).

Observou-se para a modelagem de redes neurais com variáveis do modelo estático e com a condição de erro relativo permitido em até 0,85% para a temperatura de fim de sopro e de até 27% para o carbono de fim de sopro, um acerto simultâneo de 54,8% contra 41% de acerto obtido pelo modelo estático convencional. Os erros relativos médios obtidos foram: 16,4% para o carbono e 0,78% para a temperatura.

Mas para o modelo dinâmico, com as mesmas premissas acima citadas, foi obtido um acerto simultâneo de 73%, contra 44% de acerto para o modelo convencional. Os erros relativos médios obtidos foram: 16,8% para o carbono e 0,48% para a temperatura.

5.4 TESTES INDUSTRIAIS

Na aciaria da CSN, são utilizados dois modelos matemáticos no processo de refino primário: o modelo estático, que define as condições iniciais de adições e utilidades buscando atingir a composição química e a temperatura final de acordo com as necessidades dos processos seguintes e do grau de aço desejado e o modelo dinâmico, que após a parada do sopro (com cerca de 88% do total da quantidade de oxigênio definido pelo modelo estático) define as condições finais de refino pelo cálculo das quantidades de oxigênio e de refrigerante necessárias a este ajuste fino para atingir os valores objetivados para o aço.

Como o modelo estático via redes neurais não apresentou resultados muito superiores aos do modelo estático convencional, definiu-se para estes testes industriais que este modelo convencional deveria ser mantido para a definição das condições iniciais. Assim, somente o modelo dinâmico convencional foi substituído pelo modelo dinâmico de redes neurais.

Os testes industriais foram realizados nos três conversores da CSN (cada um com produção de 220 toneladas de aço por corrida) num período de 5 dias. Os testes foram realizados com a ajuda de um *notebook*.

Os objetivos dos testes foram os seguintes:

- i. Verificar tempo de resposta do sistema em estudo (de suma importância pois poderia influenciar diretamente na produtividade da aciaria, onde cada minuto perdido por corrida corresponde a cerca de 220 toneladas de aço a menos produzido por dia);
- ii. Verificar o acerto simultâneo de temperatura e de teor de carbono no fim do sopro (foram considerados erros de até $-0,01\%$ e $+0,02\%$ de teor de carbono sobre o valor objetivado e de $\pm 15\text{ }^{\circ}\text{C}$ de temperatura sobre a temperatura objetivada, conforme a prática operacional da aciaria da CSN);
- iii. Levantar possíveis ganhos com a melhoria proposta.

O primeiro sistema testado envolveu a seguinte seqüência de atividades:

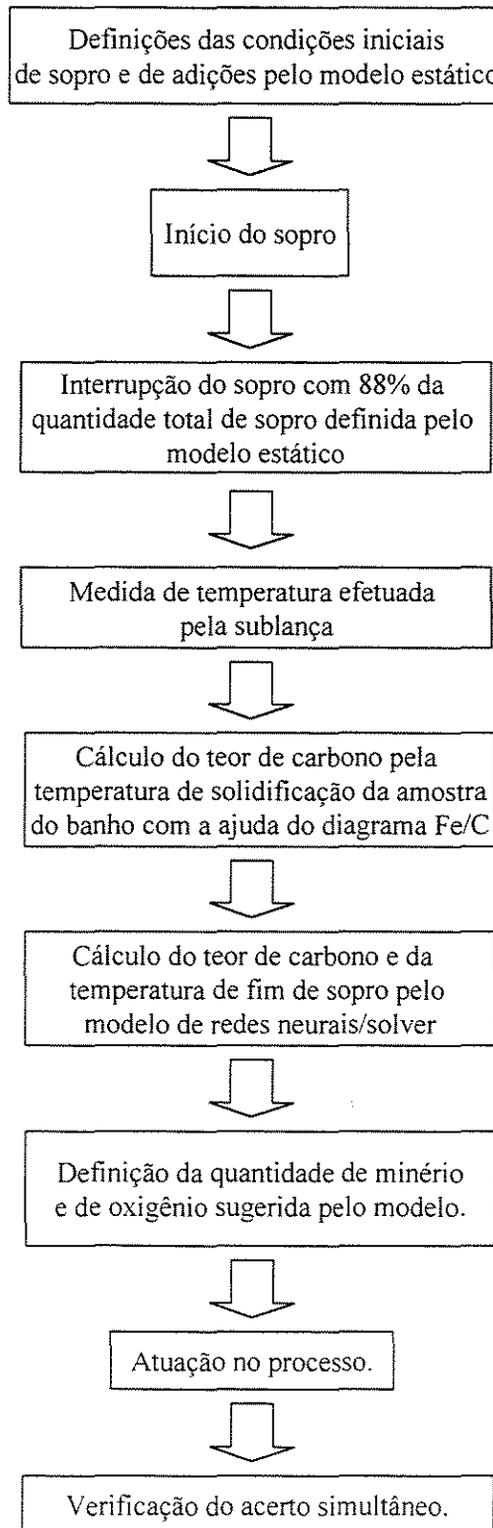


Figura 5.46 – Seqüência de atividades para teste industrial com modelo de redes neurais/solver.

A estrutura montada para teste industrial envolveu o modelamento mostrado na figura 5.47:

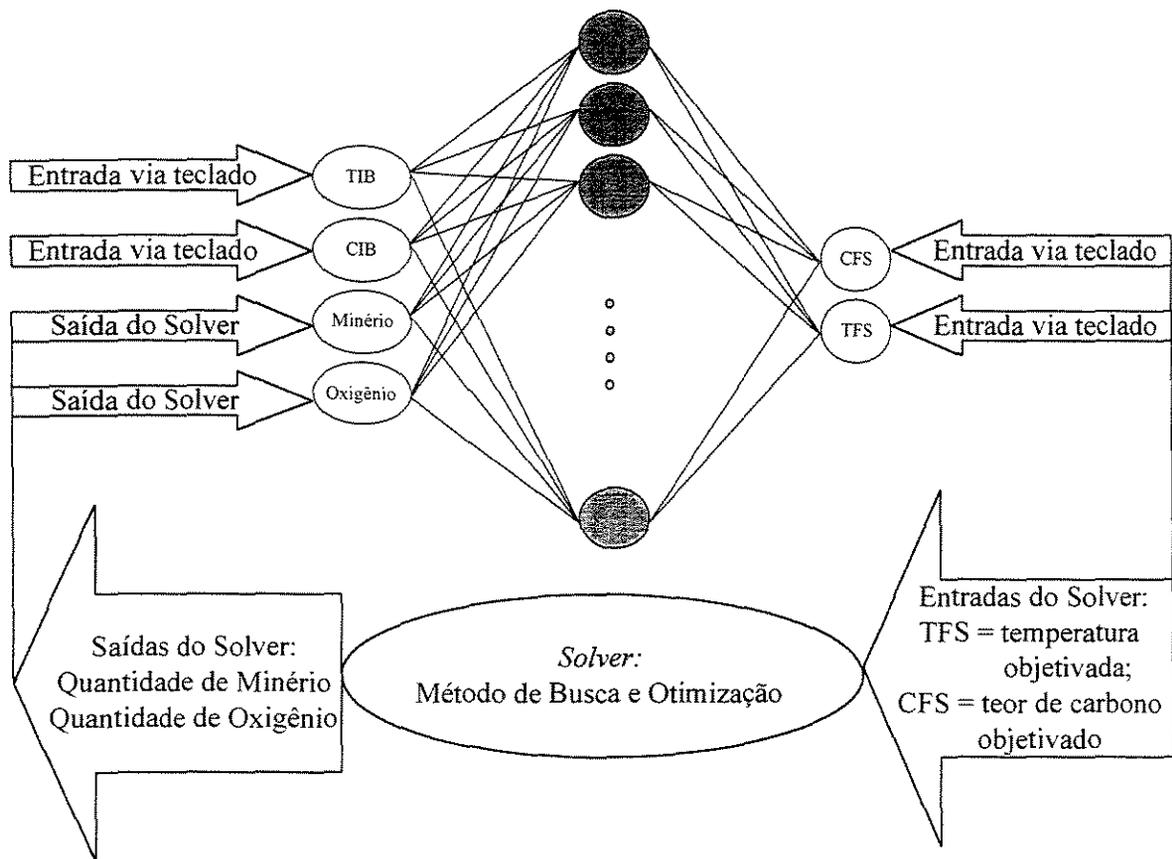


Figura 5.47 – Modelagem com Modelo Dinâmico via Redes Neurais e Método de Busca e Otimização (*Solver*, Excel).

Neste estudo, foi utilizada a estrutura neural ajustada para o modelo dinâmico e o cálculo da quantidade de minério e de oxigênio (entradas do modelo de redes neurais) foi realizado pelo programa de busca e otimização do excel (método quase-Newton) , o *solver*. O *solver* foi ajustado conforme tabela 5.13.

Tabela 5.13 – Condições de ajuste do modelo *solver*.

Função Objetivo	Minimizar consumo de oxigênio
Restrições	Quantidade de Minério entre 0 e 2890 kg Quantidade de Oxigênio entre 200 e 2200 Nm ³ Temperatura Objetivada igual a especificada para o aço Teor de Carbono Objetivado igual ao especificado para o aço
Células Variáveis	Quantidade de Minério e de Oxigênio (saídas destes programa)

Os testes industriais mostraram um problema com relação a este tipo de modelagem: quando eram efetuados os cálculos no método de busca e otimização, os resultados, na maioria das vezes, não eram atingidos numa primeira tentativa, levando a perdas de tempo de até 3 minutos, o que inviabilizou este sistema. Por este motivo, neste caso não foi avaliado o acerto simultâneo.

O segundo sistema montado foi o seguinte:

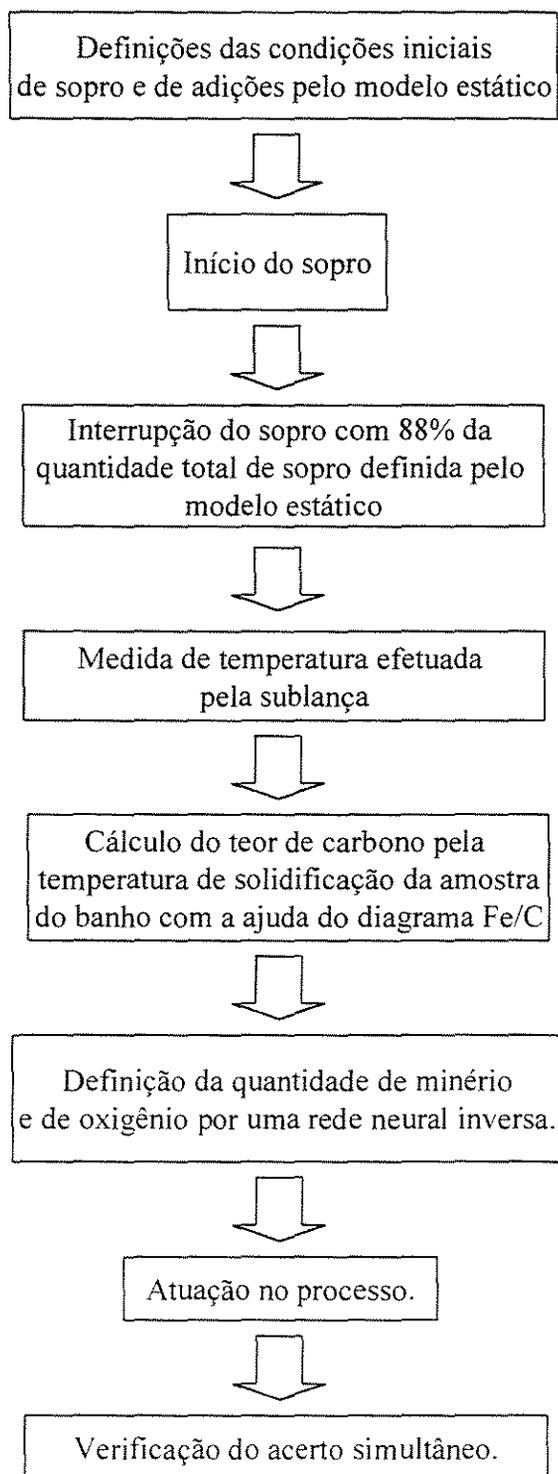


Figura 5.48 – Seqüência de atividades para teste industrial com modelo de rede neural inversa.

Neste novo sistema, desenvolveu-se uma rede neural inversa, onde as entradas passariam a ser os valores medidos pela sublança e valores objetivados para o fim do sopro e as saídas seriam as quantidades de minério e de oxigênio necessárias para atingir os valores objetivados.

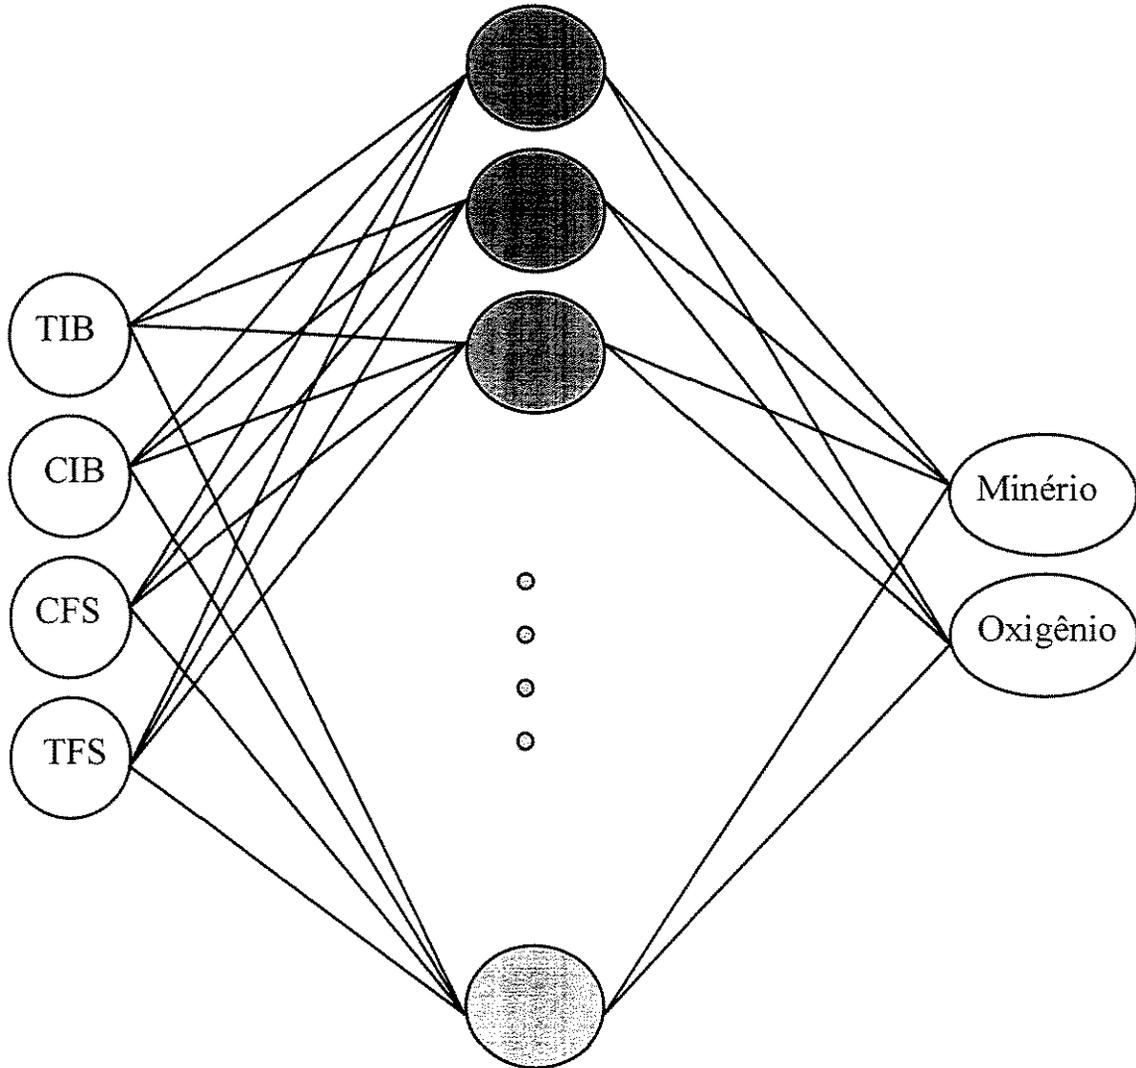


Figura 5.49 – Rede Neural Inversa para o modelo dinâmico.

A rede neural inversa foi ajustada com as mesmas condições de parâmetros de rede e de arquitetura que a melhor rede neural do modelo dinâmico. Para a avaliação da generalização, observou-se os erros admitidos no processo de aciaria, ou seja, +/- 300 Nm³ de oxigênio e +/- 500 kg de minério. Como pode ser observado pela figura 5.50 (onde os

pontos em triângulo indicam os resultados que ficaram fora do erro admitido), a generalização para o minério atingiu 80% e a generalização para o oxigênio atingiu 97%.

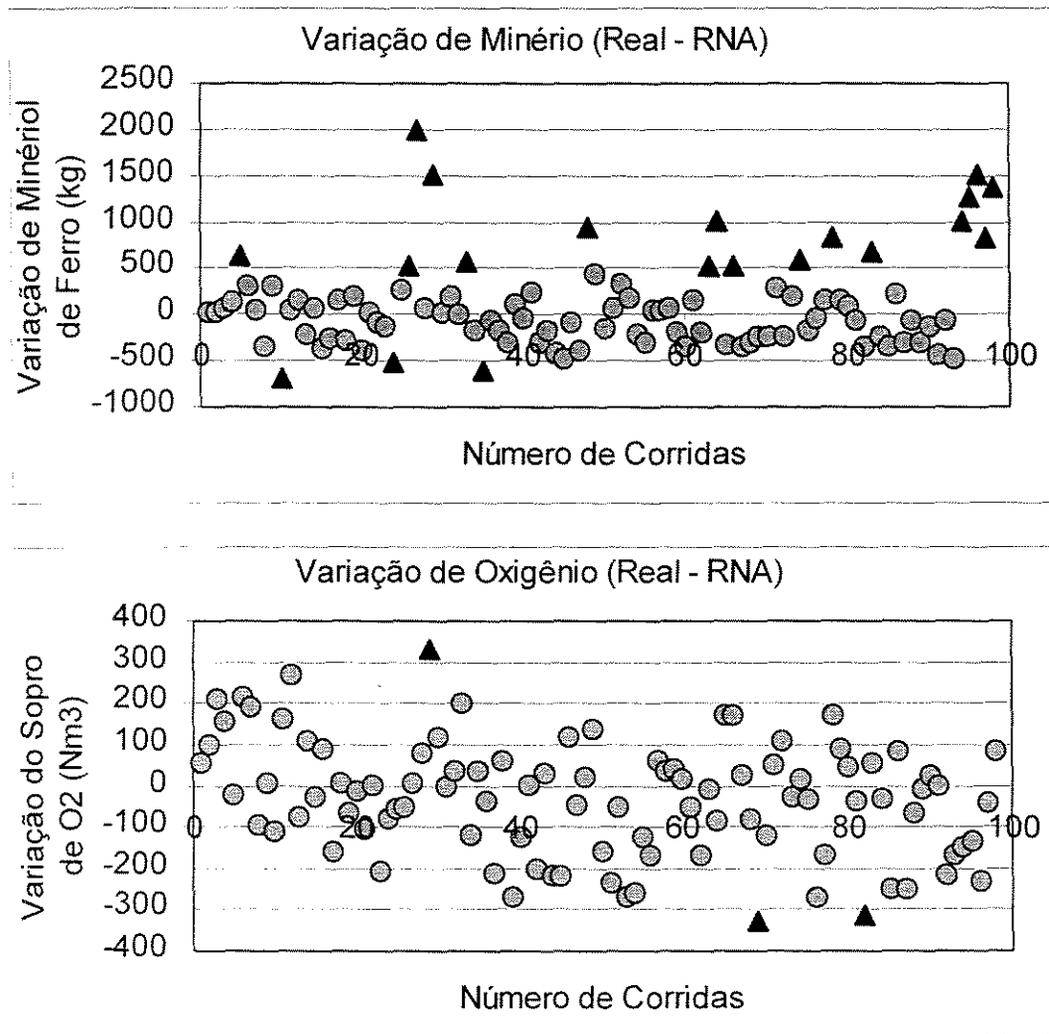


Figura 5.50 – Resultados dos erros (real – RNA) das quantidades de oxigênio e de minério de ferro.

Pela figura 5.51, observa-se que a variável quantidade de minério de ferro atingiu pouca sensibilidade para valores muito elevados, um ponto que deve ser melhorado em trabalhos futuros. Observa-se, entretanto, pela figura 5.52, que houve um acompanhamento do comportamento entre as variáveis medidas e as variáveis calculadas pela RNA.

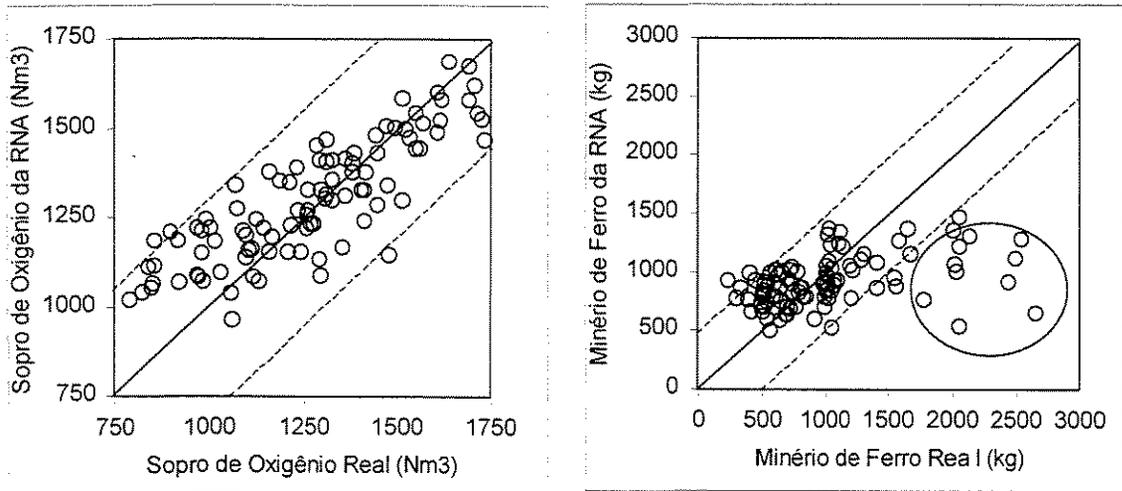


Figura 5.51 - Comparação dos resultados de quantidade de minério de ferro e de oxigênio reais e calculados.

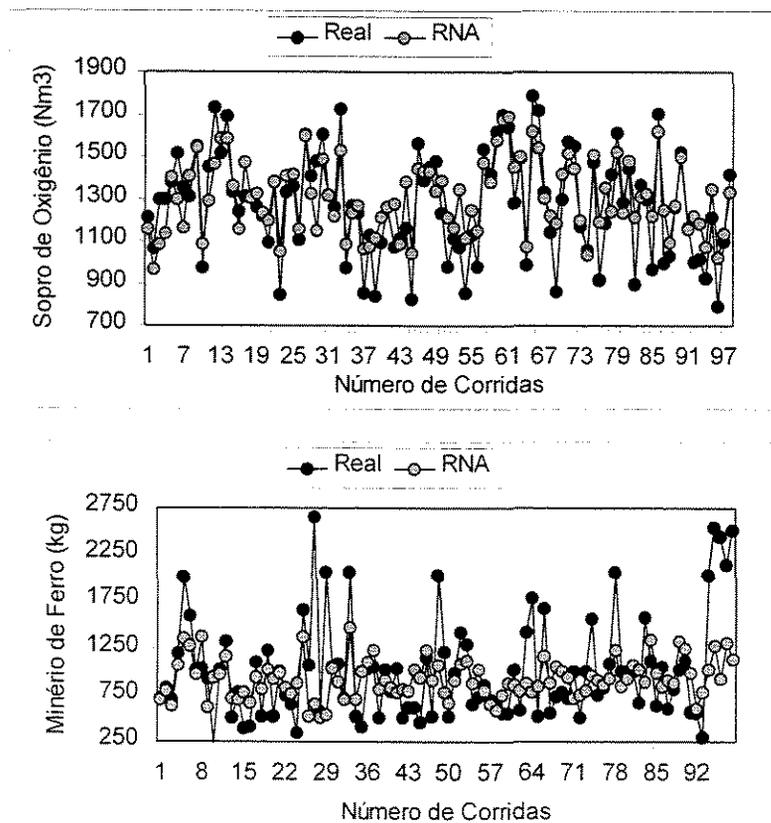


Figura 5.52 - Comparação dos resultados de quantidade de minério de ferro e de oxigênio reais e calculados.

Com este modelo de cálculo da quantidade de oxigênio e de minério o resultado é imediato e resolveu-se o problema de tempo de resposta. Assim, prosseguiu-se para os testes industriais para a verificação do acerto simultâneo de teor de carbono e de temperatura de fim de sopro. Foram realizadas 30 corridas durante cinco dias para vários graus de aço e diferentes rotas de processamento posterior (aços para forno-panela, para RH e direto para o lingotamento contínuo). Algumas condições observadas de anormalidades foram também consideradas nestas 30 corridas (tais como parada durante o sopro, antes da atuação de interrupção projetada aos 88% de sopro, problemas de cascão, problemas de desbalanceamento de temperatura e de pressão na lança, utilização de carga líquida - 100% de gusa na carga, entre outros). Estas condições anormais poderiam ter influenciado de forma negativa nos resultados, mas não ocorreram, indicando claramente que o banco de dados utilizado para treinamento da rede neural artificial cobriu amplamente as características do processo (exceto, é claro, pelas condições relacionadas às importantes variáveis não contempladas neste modelo, como volume de escória, teores de silício, de manganês, de fósforo, de enxofre, etc) .

O acerto simultâneo obtido nestas 30 corridas foi de 83,3%, sendo o acerto de temperatura atingido de 83,3% e o acerto de teor de carbono obtido de 100%. Isto comprova que os resultados obtidos pelas simulações numéricas, com baixa correlação para o teor de carbono entre valores reais e calculados pela rede, não influenciaram de forma significativa para atingir o objetivo final, o acerto simultâneo, mostrando que o sistema é ajustado conforme a necessidade de atendimento ao mercado. É importante salientar que mesmo esta “folga” de especificação para o teor de carbono do aço não permite ao sistema dinâmico convencional atingir valores maiores que 45% de acerto simultâneo. Assim, o resultado do teste industrial foi bastante significativo.

CAPÍTULO 6 – CONCLUSÕES E SUGESTÕES

6.1 CONCLUSÕES

O desenvolvimento de uma rede neural artificial foi importante, pois foi realizada uma programação de acordo com as necessidades das aplicações, que foram evoluindo ao longo das simulações. Uma importante etapa da programação foi disponibilizar o acompanhamento gráfico *on-line* dos resultados da generalização, principal propriedade deste modelo de inteligência artificial. Assim, permitia-se parar o programa na região de generalização máxima.

Neste trabalho foi desenvolvida uma metodologia de aplicação de redes neurais artificiais em processos metalúrgicos, com a importante execução do planejamento de experimentos fatorial, que facilitou o estudo em torno do entendimento da influência dos parâmetros de rede, assim como dos efeitos das interações entre estes parâmetros. Nos casos estudados, observou-se durante as simulações que algumas interações foram mais influentes nos resultados que alguns efeitos principais. Assim, a adoção desta ferramenta, novidade introduzida no caso do ajuste da rede neural (pois encontra-se na literatura estudos aprofundados em parâmetros isolados), foi de suma importância para o ajuste mais fino das redes neurais. E, quando se fala em siderurgia, qualquer resultado, por menor que possa parecer, tem um grande impacto no resultado econômico-financeiro das empresas, que produzem milhões de toneladas de aço por ano.

As redes neurais ajustadas com a função de ativação tangente hiperbólica, produziram resultados inferiores, considerando os casos estudados para diferentes bancos de dados (com variação de tamanho e de origem, ou seja, de processos diferentes).

Quanto maior o banco de dados utilizado para treinamento das redes neurais, menor foi a influência da variação dos parâmetros de rede nos resultados de generalização. Atribui-se esta diferença aos erros inevitáveis de medida e de formação destes bancos de

dados, que aumentam com o aumento das experiências (corridas industriais de produção) e com o aumento do número de variáveis de entrada.

Considerando ainda a intensidade de variação dos efeitos principais e interações sobre a generalização, observou-se também que as redes com quatro camadas sofrem maior influência das variações destes efeitos que as redes de três camadas, considerando aqui o mesmo número de neurônios ocultos entre as redes de três e quatro camadas.

Em todos os casos estudados, observou-se uma forte influência nos resultados de generalização causados não só pelos efeitos principais, como também pelas interações entre duas e até entre três variáveis, daí a grande importância de se utilizar uma técnica como a de planejamento de experimentos para verificar as interações entre as variáveis.

As redes com o número de entradas maiores (analisador completo e modelo estático), sofreram maiores influências nos resultados de generalização em função dos pesos iniciais, tanto para redes com três, quanto para quatro camadas. As redes com número pequeno de entradas foram mais influenciadas pela variação do coeficiente de *momentum* (tanto para três quanto para quatro camadas).

O coeficiente de aprendizado influenciou todas as estruturas de rede estudadas, ficando em segundo lugar na intensidade de influência dos resultados.

As principais interações encontradas foram entre o coeficiente de aprendizado e entre o coeficiente de *momentum* (sendo esta a principal interação), entre o coeficiente de aprendizado e entre bias da primeira camada, entre coeficiente de aprendizado, bias da primeira e das demais camadas, entre coeficiente de aprendizado, bias da primeira camada e pesos iniciais, entre coeficiente de aprendizado, coeficiente de *momentum* e bias da primeira camada e entre pesos iniciais e coeficiente de aprendizado.

A influência de todas estas variáveis e interações indicou variações em busca do melhor resultado de generalização, mas nenhuma apresentou influência maior que a função de ativação.

O total de conexões ocultas da rede neural definem a generalização em função do número de entradas da rede. Uma melhor generalização é obtida a partir do aumento dos neurônios ocultos quando o número de entradas da rede aumentam.

Já o aumento do tamanho do banco de dados influi positivamente na generalização quando a primeira camada oculta da rede de quatro camadas, a relação entre a primeira camada oculta e a segunda e o número de conexões entre as entradas e a primeira camada aumentam. Logo, o aumento do banco de dados necessita de um aumento do número de neurônios da primeira camada oculta para aumentar a generalização.

Para banco de dados pequeno, independente do número de entradas, deve-se aumentar o tamanho da segunda camada para obter-se melhor generalização. E para banco de dados grande, deve-se diminuir o tamanho da segunda camada oculta para um número de entradas pequeno e aumentar-se o tamanho da segunda camada oculta para um número de entradas grande.

Através da utilização da técnica de planejamento e otimização de experimentos, pôde-se observar que para as redes estudadas, altos valores de coeficientes de aprendizado e de *momentum* trouxeram os melhores resultados, assim como o uso da função sigmoidal. Observou-se também que, para as redes que receberam um grande volume de dados para treinamento, foi necessária uma estrutura de quatro camadas, ao passo que as redes com três camadas foram as mais adequadas aos processos que trabalharam com pequeno banco de dados. E em geral, valores para as bias iguais a 1 produziram os melhores resultados. Os pesos entre -1 e $+1$ ajudaram os melhores resultados.

O banco de dados foi outro ponto muito importante estudado neste trabalho. A ajuda de técnicas estatísticas foi fundamental além do conhecimento do processo para se eliminar

erros dos banco de dados. Normalmente, devido ao estágio de transição do desenvolvimento científico para o de aplicação industrial das redes neurais, existem poucos registros sobre o estudo da influência do banco de dados no desempenho das redes. Os bancos de dados utilizados em universidades e centros de pesquisas são oriundos de simuladores matemáticos ou de plantas piloto e são normalmente pequenos, longe da realidade industrial, que arquiva dados com um grande número de variáveis e com inevitáveis erros de digitação, de transmissão de dados, de medidas, etc.

O processo de sinterização foi objeto de estudo neste trabalho através do desenvolvimento de analisadores virtuais de RDI e de RI de sínter. Estes analisadores serão de grande importância para a CSN pois permitirão ensaios até então não rotineiros de RDI e de RI de sínter. Estes ensaios possibilitarão o acompanhamento de perto destas variáveis que influem de forma significativa nos resultados de produtividade dos altos-fornos e de consumo de coque por estes reatores. Assim, relações como acréscimo de 1% de RI de sínter possibilitando a redução de consumo de coque em cerca de 4,5 kg por tonelada de gusa, passarão a ser possíveis, pela disponibilidade desta variável para análise e controle (a diminuição de 4,5 kg de coque por tonelada de gusa pode reduzir o custo deste produto de altos-fornos em cerca de US\$ 2,5 milhões por ano).

Para viabilizar os analisadores virtuais de RDI e de RI de sínter, foram necessárias análises de RDI e de RI de sínteres produzidos pelas três sinterizações da CSN. Estas amostras passaram por análises química e mineralógicas, pois procurou-se avaliar dois possíveis modelos, um completo (com análises químicas e mineralógicas) e outro só com análises químicas. O modelo com análise química de entrada foi estudado pois poderia ser aplicado de imediato sem qualquer investimento. E o modelo com mineralogia exigiu um estudo mais aprofundado da influência da mineralogia da qualidade do sínter. Este estudo concordou qualitativamente com resultados de pesquisas de outras empresas mundiais, e foi necessário para se ter uma idéia do comportamento e da variação quantitativa na CSN.

O planejamento de experimentos foi utilizado de forma diferente neste segmento de estudo, através de uma triagem de um grande montante de amostras de sínter, o que

possibilitou a redução dos custos de ensaio em cerca de 80% do orçado, e através do ajuste da variação mineralógica do sinter, obtida pela prática limite das variáveis químicas principais do processo de produção do sinter. Os resultados indicaram erros de RI dentro do permitido pela norma ISO 7215, e erros muito próximos aos permitidos pela norma ISO 4696-1 para RDI. Não se encontrou variação significativa entre os resultados dos modelos com e sem mineralogia de sinter como entradas.

No processo aço, observou-se durante os testes industriais que, na maioria dos casos, a tendência de ajuste das variáveis manipuladas (quantidade de oxigênio e quantidade de minério necessárias ao acerto de qualidade do aço ao final do refino) foram similares entre o modelo dinâmico de reações cinéticas/experimentais e o modelo dinâmico baseado em redes neurais, o que prova que os ajustes das redes neurais estavam coerentes com os fenômenos cinéticos que ocorrem no fim de sopro. Entretanto, o ajuste mais fino das redes neurais possibilitaram os resultados melhores, com acerto simultâneo de teor de carbono e de temperatura do aço de 83,3% (contra 44% de acerto para o modelo dinâmico).

Este nível de acerto poderá levar o sistema para atuação *on-line* o que possibilitando ganhos de produtividade, o que ajudaria de forma significativa a CSN a atingir um aumento de produção projetado (hoje a aciaria é a área da CSN que está com maior dificuldade no escoamento da produção de toda a empresa).

6.2 SUGESTÕES

Dentro do sistema de metalurgia da redução e do aço existem grandes processos com dificuldades e limitações de modelagem similares aos estudados nesta tese, que podem ser melhorados pela aplicação de redes neurais:

- 1) Utilização de dados de carvões de baterias de coque para se desenvolver um analisador virtual de resistência após reação deste coque, informação importante para o processo de produção de gusa, hoje indisponível;
- 2) Utilização para previsão de qualidade, produtividade e rendimento de sínter através de características químicas, granulométricas, mineralógicas, texturais e estruturais das matérias primas e/ou da mistura a sinterizar e dos processos unitários que compõem a fabricação de sínter;
- 3) Com um maior detalhamento da análise mineralógica, pode-se criar um analisador virtual de análise mineralógica de sínter a partir de análises químicas;
- 4) Utilização para previsão de qualidade de minério de ferro para altos-fornos (RDI, RI, crepitação e resistência a frio), através de características químicas, mineralógicas, texturais, estruturais e granulométricas deste material;
- 5) Utilização das redes neurais para melhoria da previsão de índices tecnológicos dos altos-fornos (como a temperatura de chama ou a permeabilidade);
- 6) Aplicação em processos de dessulfuração, numa tentativa de se reduzir o consumo de agente dessulfurante (que hoje é consumido em excesso como segurança), o que poderia trazer uma grande redução de custos para o gusa e para o aço;
- 7) Para laminação, além dos trabalhos citados na revisão bibliográfica pode-se utilizar para controle de espessura de revestimento de zinco em processos de zincagem ou para melhoria qualidade dos revestimentos, em função das variáveis de processo.

No caso dos processos estudados nesta tese, seria interessante estudar mais detalhadamente as fases mineralógicas do sínter, assim, como estudos de textura e estrutura deste produto, buscando-se um analisador virtual de RDI e de RI de sínter cada vez mais preciso. Um aumento do banco de dados também será vital para a melhoria dos resultados.

Quanto ao processo de refino, pode-se estudar a aplicação das redes neurais em pontos fracos do modelo estático (através da criação de correlações para etapas do balanço de massa e de energia que não respondem bem ao modelamento convencional), o que ajudaria o acerto do modelo dinâmico.

No modelo dinâmico, que atua após a medida de teor de carbono e de temperatura pela sublança, muitas informações importantes não estão disponíveis, como os teores de silício, de fósforo, de manganês e de enxofre do banho líquido, as informações referentes às massas de metal e de escória, a composição química da escória e a altura da lança que, se forem disponibilizadas, certamente elevarão o acerto simultâneo de fim de sopro.

Outra idéia de ajuste do modelo dinâmico de redes neurais é a separação dos dados em classes, o que certamente facilitará o acerto de fim de sopro, pois os modelos ficarão mais sensíveis a um determinado tipo de ajuste para uma corrida específica. Algumas classes são fáceis de se separar, como a produção com carga líquida ou não, grau de aços, destino do aço após a produção em conversores, prática ou não de *coating* ou de *slag splash*, etc. Este tipo de separação em classes do banco de dados é sugerida na literatura especializada em redes neurais para a melhoria dos resultados.

BIBLIOGRAFIA

1. Assis, P. S.

“Novos Processos de Produção de Ferro Primário”, ABM, CBL 95-4358, 1995.

2. Vieira, et al.

“Avaliação Técnica de Minérios de Ferro para Sinterização nas Siderúrgicas e Mineradoras Brasileiras: Análise Crítica.”, XXIV Seminário de Redução e Matérias Primas da ABM, Belo Horizonte, 1998.

3. Ishikawa, et al.

“Recent Progress in the Sintering Technology - High Reducibility and Improvement of Fuel Consumption”, Ironmaking Proceedings, Pittsburgh, AIME, V41, p. 80-89, 1982.

4. Goldring, D. C.; Fray, T. A. T.

“Characterisation of Iron Ores for Production of High Quality Sinter”, Ironmaking and Steelmaking, Vol. 16, No. 2, p. 83-89, 1989.

5. Karabasov, Y. S. et al.

“Effective Reactivity of Sintering Fuel and The Optimum Bed Height”, Steel in The USSR, Vol 3, p. 129-131, 1975.

6. Roller F. W. ; Firth, B. A

“Granulation of Iron Ore Sinter Feeds”, BHP Tech. Bull., 25 No. 1, p. 79-84, 1981.

7. Toda, H. et al

“The Morphological Classification and Quantification of Sinter Microstructure”, Transactions ISIJ, 24, p. 329, 1984.

8. Bristow, N. J.; Loo, C.E.

“Sintering Properties of Iron Mixes Containing Titanium”, ISIJ International, V32, No. 7, p. 819-828, 1992.

9. Ishikawa, Y. et al.

“Improvement of Sinter Quality Based on The Mineralogical Properties of Ores”, Aime Ironmaking Proc., 42, p. 17-29, 1983.

10. Yang, L. X. ; Davis, L.

“Assimilation and Mineral Formation during Sintering for Blends Containing Magnetite Concentrate and Hemtite/Pisolite Sintering Sintering Fines”, ISIJ International, 39, No. 3, p. 239-245, 1999.

11. Hida, Y. et al

“Effect of the Mineralogical Properties of Coarse Ores on Reducibility and the Productivity of Sinter”, Transactions ISIJ, 23, p.3, 1983.

12. Hida, Y. et al

“Application of Quantitative Image Analysis to Sintering Operation”, Transactions ISIJ, 24, p. 3, 1984.

13. Okazaki, J.; Hida, Y.

“Relation Between Chemical Composition of Adhering Fines in Pseudo-Particles Composed of High-Grade Iron Ores Containing Goethite and Their Microstructure After Sintering”, Transactions ISIJ, 28, p. 40, 1988.

14. Maeda, T. et al.

“Effects of Basicity and Porosity on the Reducibility of Iron Ore Sinter”, Transactions ISIJ, 24, p. 332, 1984.

15. Maeda, T.; Ono, Y.

“Behavior of Constituent Minerals in the Reduction of Low FeO Sinter”, Transactions ISIJ, 24, p. 4, 1984.

16. Pimenta, H. P. et al

“Caracterização da Estrutura do Sínter de Alto-Forno e Seu Comportamento Durante Redução a Baixas Temperaturas”, XXIV Seminário de Minério de Ferro da ABM, 1993.

17. Costa, E. et al

“Slag Formation in the Adhering Layer of Granules and Its Reaction with Nuclei in Iron Ore Sintering”, ISIJ International, Vol 35, No. 2, p. 138-147, 1995.

18. Jeulin, D.

“Relation Between Quality and Morphology of Sinter - Texture Analysis Contribution”, Ironmaking and Steelmaking”, Vol 10, No.4, p.145-154, 1983.

19. Kama, M. et al.

“Quantitative Analyzing Method of Microstructure of Sinter”, Transactions ISIJ, Vol. 24, pp. 71, 1984

20. Murray, R. P.

“Low Gangue Sintering in Australia”, Seminar on Sinter and Pellets, Brussels, Belgium, p. 139-155, 1999.

21. Ishikawa Y. et al

“Recent Progress in Sintering Technology - High Reducibility and Improvement of Fuel Consumption”, Ironmaking Conference Proceedings, Vol 41, p. 80-89, 1982.

22. Panigrahy S. C. et al

“Influence of MgO Addition on Mineralogy of Iron Ore Sinter”, Metallurgical Transactions, Vol 15B, p. 23-32, 1984.

23. Hsieh L. H. et al

“Effect of Raw Material Composition on the Mineral Phases in Lime-Fluxed Iron Ore Sinter”, ISIJ International, Vol 33, No. 4, p. 462-473, 1993.

24. Ghosh, D.N.

“Kinetics of The Decarburization of Fe-C Melts High Carbon Levels”, Ironmaking and Steelmaking, Vol 1, No.4, p.36-44, 1975.

25. Li, K. et al.

“Decarburization in Iron-Carbon System by Oxygen Top Blowing”, Transactions AIME, 230, p.71-80, 1964.

26. Kern, D.W.

“BOF Control Utilizing on in-furnace Liquidus Carbon and Temperature Sensor”, Iron and Steel Engineer, p. 83-92, 1968.

27. Nilles, P. ; Denis, E.M.

“Problems of Oxygen Transfer in BOF Steelmaking”, Journal of Metals, p. 74-9, 1969.

28. Barreto, A.F.M.

“Controle Estático de Fim de Sopro do Conversor LD”

Dissertação de Mestrado, UFMG, 1981.

29. Takemura, Y. et al

“BOF Dynamic Control Using Sublance System”, Nippon Steel Technical Report, No. 11, p. 57-68, 1978.

30. Neto, L.C.

“Modelo para Controle de Ressonâncias em Conversores LD e Avaliação estatística de sua Performance”

Dissertação de Mestrado, UFMG, 1981.

31. Kanemoto, M. et al

“An Application of Expert System to LD Converter Processes”, ISIJ International, Vol 30, No. 2, p. 128-135, 1990.

32. Tani, J. et al

“Recent Development in the BOF Automatic Blowing Control System at Kashima Steel Works”, European Oxygen Steelmaking Congress, Dusseldorf, p. 89-96, 1993.

33. Kustersitz, F. et al

“Integrated Automation System For Operating The LD-Converters at The LD-Steel Plant of Voest-Alpine, Linz, Austria”, European Oxygen Steelmaking Congress, Dusseldorf, p. 98-100, 1993.

34. Inoue, A. et al

“Recent Improvement of Automatic Refining Control System in BOF”, European Oxygen Steelmaking Congress, Dusseldorf, p. 102-106, 1993.

35. Hahlin, P.

“Dynamic Control of Metal Analysis and Bath Temperature in a Steel Converter”, European Oxygen Steelmaking Congress, Dusseldorf, Neuss, p. 154-158, 1993.

36. McCulloch, W. S.; Pitts, W.

“A logical calculus of the ideas immanent in nervous activity”
Bulletin of Math. Bio., n.5, p. 115-133, 1943.

37. Hebb, D.

“The Organization of Behavior”
John Wiley, New York, 1949.

38. Roseblatt, F.

“The Perceptron: a probabilistic model for information storage and organizations in the brain”

Psychol. Ver., v. 65, p. 386-408, 1958.

39. Widrow, B.

“Generalization and Information Storage in Networks of Adaline Neurons”

Self-Organization Systems, 1962.

40. Minsky, M.; Pappert, S.

“Perceptrons”

MIT Press, Cambridge, 1969.

41. Hopfield, J.J.

“Neural Networks and Physical System with Emergent Collective Computational Abilities”

Proceedings of National Academy of Sciences, vol 79, 1982.

42. Rumelhart, D.; McClelland, J.

“Parallel Distributed Processing”

MIT Press, Cambridge, 1986.

43. Wasserman, P. D.

“Neural Computing: Theory and Practice”

ANZA Research, Inc, 1989.

44. Kovács, Z. L..

“Redes Neurais Artificiais: Fundamentos e Aplicações”

Edição Acadêmica, 1996.

45. Fileti, A.M.F.

“Controle em Destilação em Batelada. Controle Adaptativo e Controle Preditivo com Modelo Baseado em Redes Neurais Artificiais”

Tese de Doutorado, FEQ/UNICAMP,1995.

46. Haykin, S.

“Neural Networks - A Comprehensive Foundation”

Macmillan College Publishing Company, New York.

47. Abelém, A. J.; Pacheco, M. A. C.; Vellasco, M. M. B. R.

“Modelagem de Redes Neurais Artificiais para Previsão de Séries Temporais”

II Simpósio Brasileiro de Redes Neurais, 1995, p. 107-112.

48. Barnard, E.; Holm, J. E. W.

“A Comparative Study of Optimization Techniques for Backpropagation”

Neurocomputing , No. 6, p. 19-29, 1994.

49. Villiers, J.; Barnard, E.

“Backpropagation Neural Nets with One and Two Hidden Layers”

IEEE Transactions on Neural Networks, Vol. 4, No. 1, p. 136-141, 1992.

50. Tamura, S.; Tateishi, M.

“Capabilities of a Four-Layered Feedforward Neural Network: Four Layers Versus Three” IEEE Transactions on Neural Networks, Vol. 8, No. 2, p. 251-254, 1997.

51. Hetch-Nielsen, R.

Neurocomputing , Addison-Wesley Publishing Company, 1990.

52. Maren, A.

Handbook of Neural Computing Applications, Academic Press, San Diego, 1990.

53. Lippman, R. P.

IEE ASSP Magazine, p. 4-22, April, 1987.

54. Mirchandani, G.; Cao, W.

“On Hidden Nodes for Neural Nets”

IEEE Transactions on Circuits and Systems, Vol. 36, No. 5, p. 661-664, 1989.

55. Hagiwara, M.

“Backpropagation with Selection-Reduction of Learning Time and Elimination of Hidden Units” Systems and Computers in Japan, Vol. 23, No. 8, p. 46-54, 1992.

56. Atiya, A.; Ji, C.

“How Initial Conditions Affect Generalization Performance in Large Networks”

IEEE Transactions on Neural Networks, Vol. 8, No. 2, p. 448-451, 1997

57. Schmidt, W.F.; Raudys, S.; Kraaijveld, M. S.; Skurikhina, M.; Duin, R. P. W.

“Inicializations, Backpropagation and Generalization of Feedforward Classifiers”

IEEE International Conference on Neural Networks, p. 598-604, 1993.

58. Hernández, C. A.; Espi, J.; Nakayama, K.

“Effects of Training Data Distribution on Backpropagation Generalization”

IEEE International Symposium on Circuits and Systems, Vol. 4, p. 2148-2151, 1993.

59. Wann, M.; Hediger, T.; Greenbaum, N. N.

“The Influence of Training Sets on Generalization in Feedforward Neural Networks”

International Joint Conference on Neural Networks – IJCNN, p. 137-142, 1990.

60. Lehmen, A. V.; Paek, E. G.; Liao, P. F.; Marrakchi, A.; Patel, J. S.

“Factors Influencing Learning by Backpropagation”

IEEE International Conference on Neural Networks, p. 335-341, 1988.

61. Qiu, G.; Varley, M. R.; Terrell, T. J.

“Accelerated Training of Backpropagation Networks by Using Adaptive Momentum Step” *Electronics Letters*, Vol. 28, No. 4, p. 377-378, 1992.

62. Leonard, J.; Kramer, M. A.

“Improvement of The Backpropagation Algorithm for Training of Neural Networks” *Computers Chem. Engng.*, Vol. 14, No. 3, p. 337-341, 1990.

63. Eaton, A. C. H.; Olivier, T. L.

“Learning Coefficient Dependence on Training Set Size” *Neural Networks*, Vol. 5, p. 283-288, 1990.

64. Tang, C. Z.; Kwan, H. K.

“Parameter Effects on Convergence Speed and Generalization Capability of Backpropagation Algorithm” *International Journal of Electronics*, Vol. 74, No. 1, p. 35-46, 1993.

65. Argyropoulos, S. A.

“Artificial Intelligence in Materials Processing Operations: A Review and Future Directions”, *ISIJ International*, Vol 30, No. 2, p. 83-89, 1990.

66. Caporalli, L.; Ottoni, R.; Silva, E. C.; Neto, A. N. S.

“Aplicação de Redes Neurais Artificiais na Descrição da Relação entre Microestrutura-Propriedades-Desempenho de minérios em processos de aglomeração” *II Simpósio Brasileiro de Redes Neurais*, 1995.

67. Prevost, P. H.; Isambert, A.; Depeyre, D.; Donadille, C.; Perisse, R.

“Some Practical Insights into Neural Network Implementation in Metallurgical Industry” *Computers chem, Engng.*, Vol. 18, No. 11/12, p. 1157-1170, 1994.

68. Levén, J.; Jonsson, N. G.; Wiklund, O.

“An artificial Neural Network for Rolling Applications”

Computers in Steel, Vol. 39, No. 6, p. 137-138, 1995.

69. Kominami, H.; Kamada, N.; Tanaka, T.; Naitoh, S.; Hamaguchi, C.; Endoh, H.

“Neural Network System for Breakout Prediction in Continuous Casting Process”

Nippon Steel Technical Report, No. 49, p. 34-38, 1991.

70. Singh, H.; Sridhar, N. V.; Deo B.

“Artificial Neural Nets for Prediction of Silicon Content of Blast Furnace Hot Metal”

Steel Research, No. 12, p. 521-527, 1996.

71. Neto, B. B. et al

“Planejamento e Otimização de Experimentos”

Editora da Unicamp, Segunda Edição, 1996.

72. Takano, C.

“Termodinâmica e Cinética no Processo de Dessulfuração de Ferro e Aço”

Conferência Internacional de Dessulfuração e Controle de Inclusões da ABM, p. 1-18, 1997.

73. Pehlke, R.D.; Fuwa, T.

“Control of sulfur in liquid iron and steel.”

International Metals Reviews, Vol. 30, No. 3, p. 125-140, 1985.

74. Turkdogan, E.T.

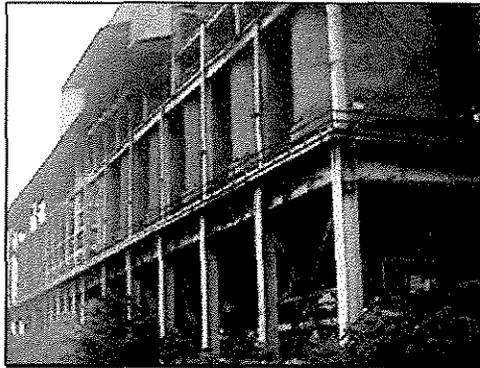
“Fundamentals of Steelmaking”, The Institute of Materials, London, 1996.

75. The Iron and Steel Society of The American Institute of Mining, Metallurgical and Petroleum Engineers.

“BOF Steelmaking”, The Iron and Steel Society, v.2, 1980.

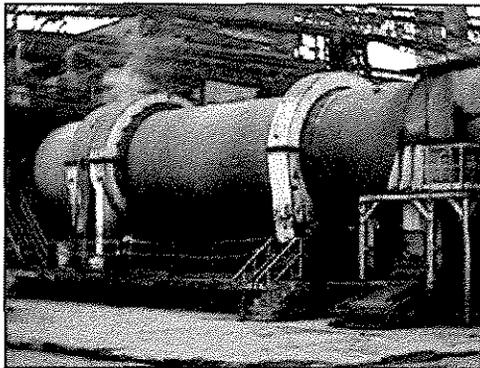
ANEXO A – FOTOS DA METALURGIA DA REDUÇÃO E DO AÇO DA CSN

O PROCESSO PRODUTIVO DE SÍNTER



Sinterização

Recebimento de Matérias Primas e
Formação da Mistura a Sinterizar



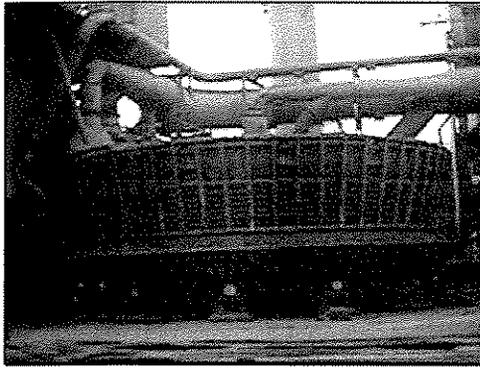
Sinterização

Misturador e Micropelotizador.



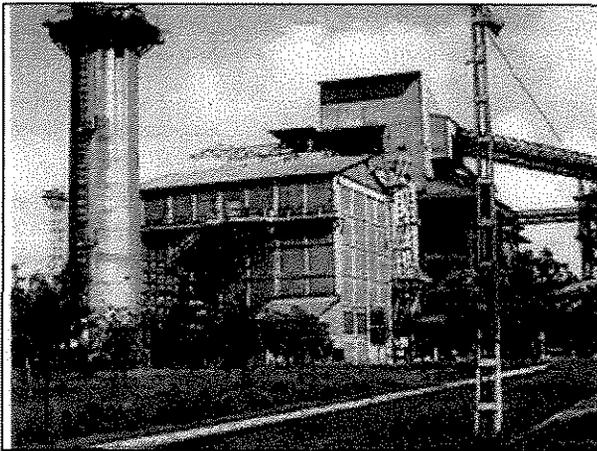
Sinterização

Recebimento das Micropelotas e
Sinterização.

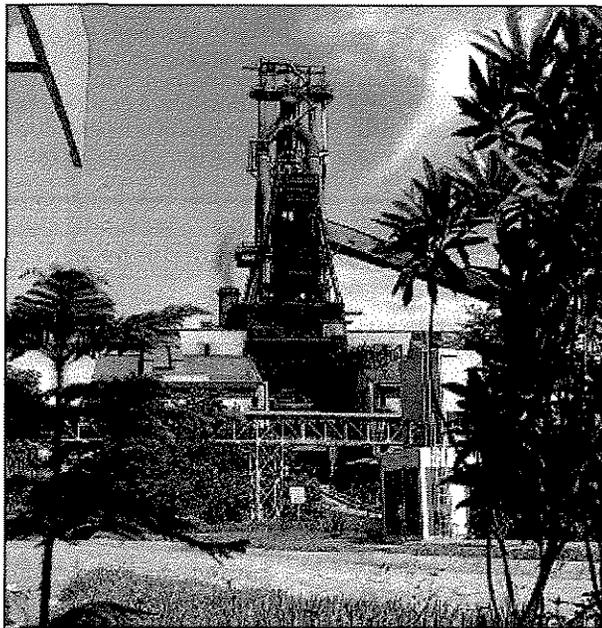


Sinterização
Resfriamento de Sínter.

VISTAS GERAIS DE SINTERIZAÇÃO E ALTO-FORNO

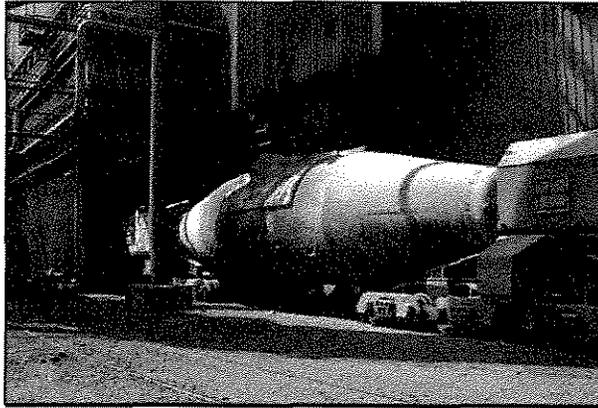


Sinterização
Produção de Sínter para
Altos-Fornos

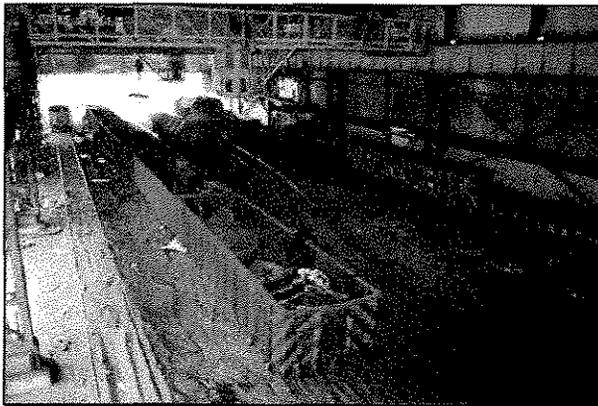


Alto-Forno
Produção de Gusa para a Aciaria,
através do sínter e outras matérias-
primas (coque, minério de ferro,
carvão injetado, etc.)

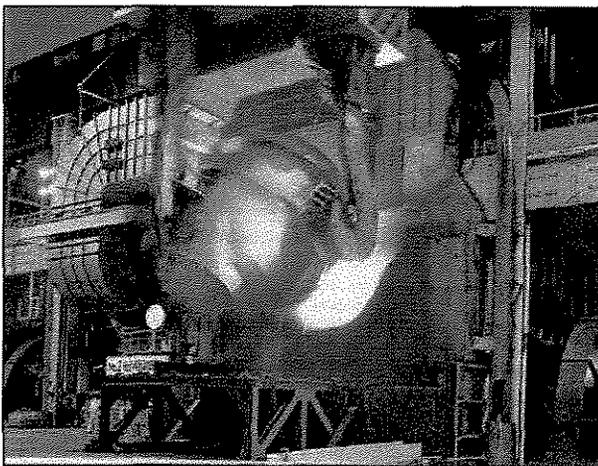
O PROCESSO PRODUTIVO DE AÇO



Carro Torpedo
Transporte do Gusa Líquido do Alto-Forno à Aciaria (Conversor)



Sucata
Pátio de Recebimento de Sucatas e formação da Carga Metálica Sólida



Panela - Conversor
Adição de Gusa ao Conversor para o Refino.

ANEXO B – MODELAGEM DA REDE NEURAL ARTIFICIAL EM VISUAL C

```
// DlgGraf.cpp : implementation file//

#include "stdafx.h"
#include "RNA.h"
#include "DlgGraf.h"
#include <math.h>
#include "CFXOCX.h"          // CHART FX 3.0 INCLUDE FILE
#include "RNADoc.h"
#include "RNAView.h"
#ifdef _DEBUG
#define new DEBUG_NEW
#undef THIS_FILE
static char THIS_FILE[] = __FILE__;
#endif

struct trnagraf graf;

#define          Z(msg) MessageBox(msg)          // %LGB

REAL          dt,
              v1[MAX_LN][MAX_MN1],             // PESOS: V1
              v2[MAX_MN1][MAX_MN2],           // PESOS: V2
              w[MAX_MN2][MAX_NN],             // PESOS: W
              G[MAX_NN],
              G_ARQ[MAX_TAMBDVERIF][MAX_NN];

REAL          ite;

clock_t        t1,t2;

extern int      Nn,                             // #CAMADAS SAÍDA
              Ln,                             // #CAMADAS ENTRADA
              Mn1,                             // #CAMADAS OCULTAS 1
              Mn2,                             // #CAMADAS OCULTAS 2
              g_ncamadas,                       // 3 ou 4 (1 ou 2 OCULTAS)
              V_TESTE,
              V_TREINO;

int            Ent_e_Sai=0,
              Crit=0;

int            pp=0,
              BDT=0,
              BDV=0,
              n=0;

extern int      g_funcao;

extern REAL     ETA,
              ALPHA,
```

```

        erro[],
        smax,
        smin,
        emax,
        emin,
        pesomax,
        pesomin;

REAL erro_recebido[MAX_NN];

REAL ERRO[MAX_NN],
      N,
      SEQ[MAX_NN];

REAL Doutmin[MAX_NN],
      Doutmax[MAX_NN],
      INmin[MAX_LN],
      INmax[MAX_LN],
      R1[MAX_NN],
      R2[MAX_NN],
      R3[MAX_NN],
      R1_ARQ[MAX_TAMBDVERIF][MAX_NN],
      R2_ARQ[MAX_TAMBDVERIF][MAX_NN],
      Gen[MAX_NN];

extern REAL bias1,
          biasx;

REAL SOMADELTA3[MAX_MN1],
      SOMADELTA2[MAX_MN1]; // indice de acordo com Mn1 ou Mn2 (o que for maior)

REAL SOMAX[MAX_CAMADAS][MAX_MN1],
      X[MAX_CAMADAS][MAX_MN1],
      DERV[MAX_CAMADAS][MAX_NN],
      DELTA[MAX_CAMADAS][MAX_MN1];

REAL PNPOT[MAX_LN],
      Aout[MAX_MN1],
      Bout1[MAX_MN1],
      Bout2[MAX_MN2],
      Cout[MAX_NN],
      Dout[MAX_NN],
      Erro[MAX_NN];

REAL DELTAv1[MAX_LN][MAX_MN1],
      DELTAv2[MAX_MN1][MAX_MN2],
      DELTaw[MAX_MN2][MAX_NN];

FILE *g_fpin; // PONTEIRO PARA ARQ. ENTRADA
static int flag_stopmainloop = 0;

static int g_modograf = 0;
static struct {
    FILE *ad;
    FILE *sq;
    FILE *sql;

```

```

} g_fpout; // PONTEIROS PARA ARQUIVOS DE SAÍDA (%LGB)

/*=====*/
/* Estrutura que armazena os valores lidos do arquivo de entrada */
/*=====*/

static float *pInputData = NULL; // %LGB
static long g_totlin, g_totcol;

// CONFIGURAÇÕES / PARÂMETROS GLOBAIS

extern struct st_rnaconfig g_config;
MSG m_msgCur;

// CDlgGraf dialog

CDlgGraf::CDlgGraf(CWnd* pParent /*=NULL*/)
: CDialog(CDlgGraf::IDD, pParent)
{
    //{{AFX_DATA_INIT(CDlgGraf)
    m_lbl_grafpos = _T("");
    //}}AFX_DATA_INIT
}

void CDlgGraf::DoDataExchange(CDataExchange* pDX)
{
    CDialog::DoDataExchange(pDX);
    //{{AFX_DATA_MAP(CDlgGraf)
    DDX_Control(pDX, IDOK, m_btfechar);
    DDX_Control(pDX, IDC_BT_PROCESSAR, m_btprocessar);
    DDX_Control(pDX, IDC_BT_PARAR, m_btparar);
    DDX_Text(pDX, IDC_LBL_GRAFPOS, m_lbl_grafpos);
    DDX_Control(pDX, IDC_MSFLEXGRID1, m_GriResult);
    DDX_Control(pDX, IDC_CHARTFX1, m_chart);
    //}}AFX_DATA_MAP
}

BEGIN_MESSAGE_MAP(CDlgGraf, CDialog)
    //{{AFX_MSG_MAP(CDlgGraf)
    ON_BN_CLICKED(IDC_BUTTON1, OnButton1)
    ON_BN_CLICKED(IDC_RAD_GRAF1, OnRadGraf1)
    ON_BN_CLICKED(IDC_RAD_GRAF2, OnRadGraf2)
    ON_BN_CLICKED(IDC_BT_PARAR, OnBtParar)
    ON_WM_SHOWWINDOW()
    ON_BN_CLICKED(IDC_BT_PROCESSAR, OnBtProcessar)
    //}}AFX_MSG_MAP
END_MESSAGE_MAP()

// CDlgGraf message handlers

void CDlgGraf::OnButton1()
{
    const int KGEN=0, KERR=1;
    int cPena, clter;

```

```

long nIter, nPenas;
char tempstr[200];
int modo = KGEN;
float valor, vmin=0.0, vmax=0.0;

switch (g_modograf)
{
case 1:
    modo = KGEN;
    break;

default:
    modo = KERR;
    break;
}
//modo = (int)m_listaTipoGraf.GetCurSel();

nPenas = Nn; // # de séries ( penas ) no gráfico

if (modo == KGEN)
    nIter = graf.gencount - 1;
else
    nIter = graf.errcount - 1;

if (nIter < 1)
{
    Z("Não há dados carregados em memória!");
    return;
}

// margens (%)
m_chart.SetBottomGap(40);
m_chart.SetTopGap(5);
m_chart.SetRightGap(2);

m_chart.OpenDataEx(COD_VALUES | COD_ADDPOINTS, nPenas, nIter);

for (cPena = 0; cPena < nPenas; cPena++)
{
    m_chart.SetThisSerie(cPena); // seleciona pena
    // define título dessa pena
    if (modo == KGEN)
    {
        sprintf(tempstr, "GEN_%d", cPena + 1);
        m_chart.SetTitle(CHART_LEFTTIT, "Gen (Nn)");
    }
    else
    {
        sprintf(tempstr, "ERR_%d", cPena + 1);
        m_chart.SetTitle(CHART_LEFTTIT, "Err (Nn)");
    }
    m_chart.SetSerLeg(cPena, tempstr);
    for (cIter = 0; cIter < nIter; cIter++)
    {
        if (modo == KGEN)
            valor = (float) (graf.gen[cPena][cIter]);
    }
}

```

```

        else
            valor = (float) (graf.err[cPena][cIter]);

        m_chart.SetValue(cIter, valor);

        if (valor > vmax) vmax = valor;
        if (valor < vmin) vmin = valor;
    }
}

// define limites do Eixo-Y
m_chart.SetAdm(CSA_MAX, vmax + vmax*0.10);
m_chart.SetAdm(CSA_MIN, 0.0);

if (modo == KGEN)
    m_chart.SetDecimalsNum(CD_ALL,0);
else
    m_chart.SetDecimalsNum(CD_ALL,3);

m_chart.ShowWindow(TRUE);
m_chart.Refresh();
m_chart.CloseData(COD_VALUES);
}

BEGIN_EVENTSINK_MAP(CDlgGraf, CDialog)
    {{{AFX_EVENTSINK_MAP(CDlgGraf)
        ON_EVENT(CDlgGraf, IDC_CHARTFX1, 25 /* MouseMoving */,
        OnMouseMoveChartfx1, VTS_I2 VTS_I2 VTS_PI2)
    }}}AFX_EVENTSINK_MAP
END_EVENTSINK_MAP()

void CDlgGraf::desenhar(int modo)
{
    g_modograf = modo;
    OnButton1();
}

void CDlgGraf::OnRadGraf1()
{
    // TODO: Add your control notification handler code here
    desenhar(1);
}

void CDlgGraf::OnRadGraf2()
{
    // TODO: Add your control notification handler code here
    desenhar(2);
}

int CDlgGraf::DoModal()
{
    // TODO: Add your specialized code here and/or call the base class

    // default: gráfico limpo.
    /*

```

```
m_chart.OpenDataEx(COD_VALUES, 1, 1);
m_chart.Refresh();
m_chart.CloseData(COD_VALUES);
*/
return CDialog::DoModal();
}

/*=====
Rotina/Funcao : GDR
Descricao    : Principal rotina do aplicativo, a qual executa todo o processamento da RNA.
Chamada por  : CDlgGraf::OnBtProcessar()
Parametros   :
Retorno      :
=====*/

void CDlgGraf::GDR()
{
    int i=0,
        j=0,
        k=0; // contadores

    char tempstr[1000];
    long int tam=0;

    long int cr=0,
        cc=0; // contadores: Row, Col

    float vfloat=0,
        tempfloat=0;

    char teste = 0;
    char *ptr;

    char *ptrdest,
        sval[20],
        ch;

    int Mn=0;
    int xxx=0;

    float vmin=0.0,
        vmax=0.0;

    ///logdeb("Criando arquivos de saída...");

    // %LGB
    if ((g_fpout.ad = fopen(g_config.s_arqsai1,"w")) == NULL)
    {
        MessageBox("Erro: Não foi possível criar arquivo de saída #1");
        OnBtParar();
        return;
    }
    if ((g_fpout.sq = fopen(g_config.s_arqsai2,"w")) == NULL)
    {
        MessageBox("Erro: Não foi possível criar arquivo de saída #2");
        OnBtParar();
    }
}
```

```

        return;
    }

    if((g_fpout.sql = fopen(g_config.s_arqsai3,"w")) == NULL)
    {
        MessageBox("Erro: Não foi possível criar arquivo de saída #3");
        OnBtParar();
        return;
    }

    /** Prepara Grafico Real Time ***/
    // m_chart.SetType(m_chart.GetType() | CT_EVENSPECING);
    // m_chart.SetMaxValues(10);
    // m_chart.SetRealTimeStyle(CRT_NOWAITARROW);
    // m_chart.SetDecimalsNum(CD_ALL,1);
    // m_chart.ShowWindow(TRUE);

    N=0;

    for (k = 0; k < Nn; k++)
    {
        //m_chart.SetThisSerie(k); // seleciona pena
        R3[k]=0;
        erro[k];
        Doutmin[k]=0;
        Doutmax[k]=0;
        Gen[k]=0;
        ERRO[k]=0;
        SEQ[k]=0;
        Cout[k]=0;
        Dout[k]=0;
        Erro[k]=0;

        R1[k]=0;
        R2[k]=0;
        G[k]=0;

        // define título dessa pena
        sprintf(tempstr, "ERR_%d", k + 1);
        //m_chart.SetTitle(CHART_LEFTTIT, "Err (Nn)");
        m_chart.SetSerLeg(k, tempstr);

        sprintf(tempstr, "GEN_%d", k + 1);
        //m_chart.SetTitle(CHART_LEFTTIT, "Gen (Nn)");
        m_chart.SetSerLeg(k+Nn, tempstr);

    }

    for (i = 0; i <= V_TESTE; i++)
    {
        for (k = 0; k <= Nn; k++)
        {
            G_ARQ[i][k] = 0;
            R1_ARQ[i][k] = 0;
            R2_ARQ[i][k] = 0;
        }
    }

```

```
}  
  
for (k = 0; k < Ln; k++)  
{  
    INmin[k]=0;  
    INmax[k]=0;  
    PNPOT[k]=0;  
}  
  
if (Mn2 > Mn1)  
    Mn = Mn2;  
else  
    Mn = Mn1;  
  
for (k=0; k<=Mn; k++)  
{  
    SOMADELTA3[k]=0;  
    SOMADELTA2[k]=0;  
}  
  
for (k=0; k<=Mn1; k++)  
{  
    Aout[k]=0;  
    Bout1[k]=0;  
}  
  
for (k=0; k<=Mn2; k++)  
{  
    Bout2[k]=0;  
}  
  
for (k=0; k<=Ln; k++)  
{  
    for (i=0; i<=Mn1; i++)  
    {  
        DELTA v1[k][i]=0;  
        v1[k][i]=0;  
    }  
}  
  
for (k=0; k<=Mn1; k++)  
{  
    for (i=0; i<=Mn2; i++)  
    {  
        DELTA v2[k][i]=0;  
        v2[k][i]=0;  
    }  
}  
  
for (k=0; k<=Mn2; k++)  
{  
    for (i=0; i<=Nn; i++)  
    {  
        DELTA w[k][i]=0;  
        w[k][i];  
    }  
}
```

```

    }

    for (k=0; k<=g_ncamadas; k++)
    {
        for (i=0; i<=Mn1; i++)
        {
            SOMAX[k][i]=0;
            X[k][i]=0;
            DELTA[k][i]=0;
        }
        for (i=0; i<=Nn; i++)
        {
            DERV[k][i]=0;
        }
    }

    for (k=0; k<=Nn; k++)
    {
        erro[k] = erro_recebido[k];
    }

    /*****INICIALIZAÇÃO DA RNA*****/

    logdeb("inicialização RNA...");

    /*Definição da Arquitetura e dos parâmetros de controle*/

    for(k=4; k > Nn; k--)
        erro[k]=0.0;

    for(k=1; k <= Nn; k++)
        erro[k]=erro[k]/100;

    /// V_TREINO = m_nTamBDTreino;
    /// V_TESTE      = m_nTamBDTeste;

    Ent_e_Sai = Ln+Nn;
    N = (float) V_TREINO;
    BDT = V_TREINO*Ent_e_Sai;
    BDV = (V_TESTE+V_TREINO)*Ent_e_Sai;

    g_totlin = V_TREINO+V_TESTE;
    sprintf(tempstr, "LINHAS.BD.TREINO=%d LINHA.BD.VERIF=%d TotLinhas=%d",
        V_TREINO, V_TESTE, g_totlin);
    logdeb(tempstr);

    g_totcol = Ln+Nn;
    sprintf(tempstr, "Colunas.Ln(IN)=%d Colunas.Nn(OUT)=%d TotColunas=%d",
        Ln, Nn, g_totcol
    );
    logdeb(tempstr);

    sprintf(tempstr, "Total de itens FLOAT a serem lidos do arquivo: %d =
    TOTLIN*TOTCOL", g_totlin*g_totcol);
    logdeb(tempstr);

```

```
// DEFINE QUANTIDADE DE MEMÓRIA NECESSÁRIA
tam = (g_totlin * g_totcol) * sizeof(float);
sprintf(tempstr, "Alocando memória para carregar dados: %lu bytes", tam);
logdeb(tempstr);

//
// ABRE ARQUIVO DE ENTRADA (MASSA DE DADOS)
// Leitura do banco de dados para o treinamento/teste
//
if ((g_fpin=fopen(g_config.s_arqent,"r")) == NULL)
{
    msgerro("Erro: arquivo de entrada não foi encontrado: " +
CString(g_config.s_arqent));
    OnBtParar();
    return;
}

if (pInputData != NULL)
{
    free(pInputData); // LIBERA MEMÓRIA PREVIAMENTE ALOCADA
    pInputData = NULL;
}
// ALOCA MEMÓRIA NECESSÁRIA PARA CARREGAMENTO DOS DADOS DE
ENTRADA
pInputData = (float *)malloc(tam);
if (!pInputData)
{
    sprintf(tempstr, "Erro: Não foi possível alocar memória para ler dados: %lu bytes",
tam);
    msgerro(tempstr);
    OnBtParar();
    return;
}

logdeb("Lendo dados de entrada: " + CString(g_config.s_arqent));

cc = 0;
for(i=0; i < g_totlin*g_totcol; i=i+cc)
{
    fgets(tempstr, 1000, g_fpin);

    if feof(g_fpin)
    {
        msgerro("Erro: Qtde de linhas do arquivo diferente da qtde
configurada.");
        OnBtParar();
        return;
    }

    ptr = &tempstr[0];

    for(cc=0; cc < g_totcol; cc++)
    {
        // VALORES SEPARADOS POR <TAB>
        ptrdest = &sval[0];
```

```

do
{
    ch = *ptr;
    if (ch == '\t' || ch == '\n')
    {
        if (ch == '\n' && cc < g_totcol-1)
        {
            msgerro("Erro: Qtde de colunas do arquivo
diferente da qtde configurada.");
            OnBtParar();
            return;
        }
        *ptrdest = 0; // null terminate
        ptr++;
        break;
    }
    else
    {
        *ptrdest++ = ch;
        ptr++;
    }
} while (1);

vfloat = (float) atof(sval);

// ARMAZENA EM MEMÓRIA O VALOR LIDO DO ARQUIVO EM
DISCO
pInputData[i+cc] = vfloat;
}
}

fclose(g_fpin); // fecha o arquivo de entrada

//
// Definição das entradas/saídas máximas e mínimas
// (MAX/MIN DE CADA COLUNA DO ARQUIVO DE ENTRADA)
//
for(cr=0; cr < g_totlin; cr++)
{
    // Ln
    for(cc=1; cc <= Ln; cc++)
    {
        if(cr==0)
        {
            INmin[cc] = indataRC(0, cc-1);
            INmax[cc] = indataRC(0, cc-1);
        }
        tempfloat = indataRC(cr, cc-1);
        if(tempfloat < INmin[cc]) INmin[cc]=tempfloat;
        if(tempfloat > INmax[cc]) INmax[cc]=tempfloat;
    }
    // Nn
    for(cc=1; cc <= Nn; cc++)
    {
        if(cr==0)

```

```

        {
            Doutmin[cc]=indataRC(0, cc+Ln-1);
            Doutmax[cc]=indataRC(0, cc+Ln-1);
        }
        tempfloat = indataRC(cr, cc+Ln-1);
        if(tempfloat < Doutmin[cc]) Doutmin[cc]=tempfloat;
        if(tempfloat > Doutmax[cc]) Doutmax[cc]=tempfloat;
    }
}

//
// Inicialização randômica dos pesos
//
srand((unsigned) time(NULL));
for(i=1;i<=Ln;i++)
{
    for(j=1;j<=Mn1;j++)
    {
        if (g_config.inipesos1)
        {
            v1[i][j]=1;
        }
        else
        {
            if((pesomax-pesomin) != 0)
            v1[i][j]=(float)(rand() % (int)((pesomax-pesomin)*100));
            v1[i][j]=pesomax-v1[i][j]/100;
        }
    }
}
if(g_ncamadas==4)
{
    for(i=1;i<=Mn1;i++)
    {
        for(j=1;j<=Mn2;j++)
        {
            if (g_config.inipesos1)
            {
                v2[i][j]=1;
            }
            else
            {
                if((pesomax-pesomin) != 0)
                v2[i][j]=(float)(rand() % (int)((pesomax-
pesomin)*100));
                v2[i][j]=pesomax-v2[i][j]/100;
            }
        }
    }
}
if(g_ncamadas==3) Mn2=Mn1;

if(Nn>=1)
{
    for(j=1;j<=Mn2;j++)
    {

```

```

        for(k=1;k<=Nn;k++)
        {
            if (g_config.inipesos1)
            {
                w[j][k]=1;
            }
            else
            {
                if((pesomax-pesomin) != 0)
                w[j][k]=(float)(rand() % (int)((pesomax-
                pesomin)*100));
                w[j][k]=pesomax-w[j][k]/100;
            }
        }
    }
}

t1=clock();

//
// Inicialização das variáveis dos pesos
//
for(i=1;i<=Ln;i++) for(j=1;j<=Mn1;j++) DELTAv1[i][j]=0.0;

if(g_ncamadas==4) for(i=1;i<=Mn1;i++) for(j=1;j<=Mn2;j++) DELTAv2[i][j]=0.0;

if(Nn>=1) for(j=1;j<=Mn2;j++) for(k=1;k<=Nn;k++) DELTAw[j][k]=0.0;

//
// Definição dos neurônios bias/thresholds
//
Crit = (Mn1 >= Mn2) ? Mn1 : Mn2; // Crit = MAIOR ENTRE Mn1 e Mn2

//
//
//***** TREINAMENTO DA RNA *****//
//
//

flag_stopmainloop = 0;

ite = 1; // NA VERSÃO ANTERIOR NÃO ZERAVA... POIS ESSA ROTINA
        // SOMENTE ERA EXECUTADA 1 VEZ NA VERSÃO DOS,
        // E DEPOIS DISSO
        // O PROGRAMA TERMINAVA.

do
{
    // VERIFICA FLAG DE INTERRUÇÃO DO LAÇO
    if (flag_stopmainloop == 1)
        break;

    /* Parametrização das entradas e saídas */

    for(pp=0;pp<=BDT-Ent_e_Sai;pp=pp+Ent_e_Sai) // para todas as linhas de dados
    {

```

```

for(i=1; i<=Ln; i++) // todas colunas de camada de entrada
{
    vfloat = indataRC(pp / g_totcol, i-1);
    if (INmax[i] != 0 || INmin[i] != 0)
        PNPOT[i]=emax-((emax-emin)*(INmax[i]-vfloat)/(INmax[i]-
        INmin[i]));
    else
        PNPOT[i]=0;
}

for(k=1; k<=Nn; k++) // todas colunas de camada de saída
{
    vfloat = indataRC(pp / g_totcol, k-1+Ln);
    Dout[k]=smax-((smax-smin)*(Doutmax[k]-
    vfloat)/(Doutmax[k]-Doutmin[k]));
}

do
{
    for(j=1; j<= Crit+1; j++)
    {
        SOMADELTA3[j]=0.0;
        SOMADELTA2[j]=0.0;
    }

    /* SISTEMA FEEDFORWARD */
    feed_forward();

    teste = FALSE;
    for(k=1;k<=Nn;k++)
    {
        if (fabs(R3[k]) > erro[k]*R2[k])
            teste = TRUE;
    }
    if (teste == TRUE)
    {
        /* SISTEMA BACKPROPAGATION */

        /* Calculando o Grad.Descend.DELTA[3][k] para a
        camada de saída */
        if(Nn>=1)
        {
            for(k=1;k<=Nn;k++)
            {
                if(g_ncamadas==3 || g_ncamadas==4)
                {
                    if(g_funcao==1)
DERV[g_ncamadas][k]=exp(-X[g_ncamadas][k])/pow((1.0+ exp(-X[g_ncamadas][k])),2.0);
                    if(g_funcao==2)
DERV[g_ncamadas][k]=pow((1.0-((1.0-exp(-2.0*X[g_ncamadas][k]))/(1.0+exp(-
2.0*X[g_ncamadas][k])))),2.0);
                    DELTA[g_ncamadas][k]=Erro[k]*DERV[g_ncamadas][k];
                }
            }
        }
    }
}

```

```

/* Calculando o Grad.Descend.DELTA[2][j] para a(s)
camada(s) oculta(s) */
if(Nn>=1)
{
    if(g_ncamadas==3 || g_ncamadas==4)
    {
        for(j=1;j<=Mn2;j++) // camadas
            {
                if(g_funcao==1)
                DERV[g_ncamadas-1][j]=exp(-X[g_ncamadas-1][j])/pow((1.0+exp(-X[g_ncamadas-1][j])),2.0);
                if(g_funcao==2)
                DERV[g_ncamadas-1][j]=pow((1.0-((1.0-exp(-2.0*X[g_ncamadas-1][j])))/(1.0+exp(-2.0*X[g_ncamadas-1][j]))),2.0);
                for(k=1;k<=Nn;k++)
                    SOMADELTA3[j]=SOMADELTA3[j]+DELTA[g_ncamadas][k]*w[j][k];
                DELTA[g_ncamadas-1][j]=DERV[g_ncamadas-1][j]*SOMADELTA3[j];
            }
    }
}

if(g_ncamadas==4)
{
    for(j=1;j<=Mn1;j++) // camadas ocultas 1
    {
        if(g_funcao==1) DERV[2][j]=exp(-X[2][j])/pow((1.0+exp(-X[2][j])),2.0);
        if(g_funcao==2)
        DERV[2][j]=pow((1.0-((1.0-exp(-2.0*X[2][j])))/(1.0+exp(-2.0*X[2][j]))),2.0);
        for(k=1;k<=Mn2;k++)
            SOMADELTA2[j]=SOMADELTA2[j]+DELTA[3][k]*v2[j][k];
        DELTA[2][j]=DERV[2][j]*SOMADELTA2[j];
    }
}

//
// Obtendo os novos pesos v[i][j],w[j][k]
//

// DELTA-V1
for(i=1;i<=Ln;i++)
{
    for(j=1;j<=Mn1;j++) // camadas ocultas 1
    {
        DELTAv1[i][j]=(ETA*DELTA[2][j]*Aout[i]) + (ALPHA*DELTAv1[i][j]);
        v1[i][j]=v1[i][j]+DELTAv1[i][j];
    }
}

// DELTA-V2
if(g_ncamadas==4)
{

```

```

for(i=1;i<=Mn1;i++) // camadas ocultas 1
{
    for(j=1;j<=Mn2;j++) // camadas
        {
            DELTAv2[i][j]=(ETA*DELTA[3][j]*Bout1[i] + (ALPHA*DELTAv2[i][j]));
            v2[i][j]=v2[i][j]+DELTAv2[i][j];
        }
    }
}

// DELTA-W
if(g_ncamadas==3 || g_ncamadas==4)
{
    if(Nn>=1)
    {
        for(j=1;j<=Mn2;j++) // camadas
            {
                for(k=1;k<=Nn;k++)
                {
                    DELTAw[j][k]=(ETA*DELTA[g_ncamadas][k]*Bout1[j]) + (ALPHA*DELTAw[j][k]);
                    w[j][k]=w[j][k]+DELTAw[j][k];
                }
            }
        }
    }
}

// RECEBEU PEDIDO DE ENCERRAMENTO, PARAR
if (flag_stopmainloop)
    break;
}
while(fabs(R3[1])>erro[1]*R2[1] && fabs(R3[2])>erro[2]*R2[2] &&
fabs(R3[3])>erro[3]*R2[3] && fabs(R3[4])>erro[4]*R2[4]);
}

// RECEBEU PEDIDO DE ENCERRAMENTO, PARAR PROCESSAMENTO
if (flag_stopmainloop)
    break;

```

```

//
//
/***** VERIFICAÇÃO DA EFICIÊNCIA DA RNA *****/
//
//

for (i=1;i<MAX_NN;i++)
    G[i]=0.0;

for(pp=0, n=0; pp<=BDV-Ent_e_Sai; pp=pp+Ent_e_Sai)
{
    n++;

    for(i=1;i<=Ln;i++)
    {
        vfloat = indataRC(pp / g_totcol, i-1);
        if (INmax[i] != 0 || INmin[i] != 0)
            PNPOT[i]=emax-((emax-emin)*(INmax[i]-vfloat)/(INmax[i]-
            INmin[i]));
        else
            PNPOT[i]=0;
    }
    if(Nn>=1)
        for(k=1;k<=Nn;k++)
        {
            vfloat = indataRC(pp / g_totcol, k-1+Ln);
            Dout[k]=smax-((smax-smin)*(Doutmax[k]-
            vfloat)/(Doutmax[k]-Doutmin[k]));
        }

    /*
    * SISTEMA FEEDFORWARD
    */
    feed_forward();

    /*
    * Cálculo da GENERALIZAÇÃO e do ERRO da rede
    */
    for(k=1;k<=Nn;k++)
    {
        if(R3[k]<R2[k]*erro[k])
            if(n > V_TREINO && n<= (V_TREINO+V_TESTE))
                G[k]=(G[k]+1.0);

        // Armazena as generalizações para serem gravadas no arquivo
        // qdo for clicado o botão "Parar"
        if (n > V_TREINO)
        {
            G_ARQ[n-V_TREINO-1][k] = G[k] / V_TESTE *
            100.0;
        }
    }

    ///fprintf(g_fpout.sql,"%1.2f      %1.2fn",R1[2],R2[2]);

```

```

        if(pp==0.0)
        {
            for(k=1;k<=Nn;k++) SEQ[k]=0.0;
        }
        for(k=1;k<=Nn;k++)
            SEQ[k]=SEQ[k]+pow(R3[k],2.0);
    }

    //
    // APRESENTAÇÃO DE RESULTADOS DESSA ITERAÇÃO...
    //

    m_GriResult.SetTextMatrix(0, 0, "Iterações");
    sprintf(tempstr, "%1.0f", ite);
    m_GriResult.SetTextMatrix(0, 1, tempstr);

    sprintf(tempstr, "Nn=%d", Nn);
    m_GriResult.SetTextMatrix(2, 0, tempstr);
    m_GriResult.SetTextMatrix(3, 0, "Erro (Nn)");
    m_GriResult.SetTextMatrix(4, 0, "Generalizações (Nn)");

    if(n > V_TREINO)
    {
        /* Arquivo de Erros (ite, gen) (24/02/2001) */
        fprintf(g_fpout.sq, "%1.0f", ite);
    }

    /** Grafico Real Time ***/
    if (ite == 1)
        m_chart.OpenDataEx(COD_VALUES, Nn*2, 1);
    else
        m_chart.OpenDataEx(COD_VALUES | COD_ADDPOINTS, Nn*2, 1);

    for(k = 1; k <= Nn; k++)
    {
        //-----
        // ERR
        //-----

        sprintf(tempstr, "loop k(1..Nn=%d) k=%d", Nn,k);
        //Z(tempstr);

        SEQ[k] = (1.0 / N) * SEQ[k];

        // CALCULA ERRO PARA A CAMADA DE SAÍDA (Nn)
        ERRO[k] = (pow(SEQ[k], 0.5));

        sprintf(tempstr, "%d", k);
        m_GriResult.SetTextMatrix(2, k, tempstr);

        sprintf(tempstr, "%.3f", ERRO[k]);
        m_GriResult.SetTextMatrix(3, k, tempstr);

        /** Grafico Real Time ***/
    }

```

```

m_chart.SetThisSerie(k-1); // seleciona pena
m_chart.SetValue(0, (float) ERRO[k]);

if (ERRO[k] > vmax) vmax = (float) ERRO[k];
if (ERRO[k] < vmin) vmin = (float) ERRO[k];

//-----
// GEN
//-----
Gen[k] = G[k] / V_TESTE * 100.0;

if(n > V_TREINO)
{
    sprintf(tempstr, "%.3f", Gen[k]);
    m_GriResult.SetTextMatrix(4, k, tempstr);

    /** Grafico Real Time **/
    m_chart.SetThisSerie(k+Nn-1); // seleciona pena
    m_chart.SetValue(0, (float) Gen[k]);

    /* Arquivo de Erros (ite, gen) (24/02/2001) */
    fprintf(g_fpout.sq, "  %1.3f", Gen[k]);

}

}

if(n > V_TREINO)
{
    fprintf(g_fpout.sq, "\n");
}

m_chart.CloseData(COD_VALUES | COD_REALTIMESCROLL |
COD_SMOOTH);
m_chart.Scroll(7, 0);

if (!::SendMessage(&m_msgCur, NULL, NULL, NULL))
{
    AfxMessageBox("SAIDA");
}

// process this message
if (!PreTranslateMessage(&m_msgCur))
{
    ::TranslateMessage(&m_msgCur);
    ::DispatchMessage(&m_msgCur);
}

UpdateWindow();

//fprintf(sq, "%1.0f  %1.2f  %1.1f\n", ite.ERRO, G/V_TESTE*100.0);

// RECEBEU PEDIDO DE ENCERRAMENTO, PARAR PROCESSAMENTO
if (flag_stopmainloop)
    break;

```

```

//
// INCREMENTA #ITERAÇÕES
//
ite++;

Sleep(100);
} while (SEQ[1] >= 0.00001);

fim_treinamento(); // FIM DE TREINAMENTO DA REDE

// FECHA ARQUIVOS DE SAÍDA
fclose(g_fpout.sq);
fclose(g_fpout.sq1);

return;
}

void CDlgGraf::zlog(const char * s)
{
    char tempstr[100];
    time_t long_time;
    struct tm *ptm;

    time( &long_time );
    ptm = localtime( &long_time );

    //sg_funcao_e_t strftime( char *strDest, sg_funcao_e_t maxsg_funcao_e, const char *format,
const struct tm *timeptr );
    strftime( tempstr, 100, "%H:%M:%S - ", ptm );

    /// m_list_logs.AddString( CString(tempstr) + s );
}

/*=====
Rotina/Funcao : feed_forward
Descricao    : Executa o "calculo" feed forward.
Chamada por  : void CDlgGraf::GDR()
Parametros   :
Retorno      :
=====*/

void CDlgGraf::feed_forward()
{
    int i, j;

    /*** Usar este trecho comentado no outro programa!!!
        for(i=1;i<=Ln;i++)
        {
            vfloat = indataRC(pp / g_totcol, i-1);
            if (INmax[i] != 0 || INmin[i] != 0)
                PNPOT[i]=emax-((emax-emin)*(INmax[i]-
vfloat)/(INmax[i]-INmin[i]));
            else
    
```

```

PNP[PUT][i]=0;
    }
    if(Nn>=1)
        for(k=1;k<=Nn;k++)
            {
                vfloat = indataRC(pp / g_totcol, k-1+Ln);
                Dout[k]=smax-((smax-smin)*(Doutmax[k]-
vfloat)/(Doutmax[k]-Doutmin[k]));
            }

    ***/
    for(i=1;i<=Ln;i++)
    {
        // X são as variaveis de entrada
        X[1][i]=PNP[PUT][i]-bias1;
        Aout[i]=X[1][i];
    }

    for(i=2; i <= g_ncamadas; i++)
        for(j=1;j<=Crit+1;j++)
            SOMAX[i][j]=0.0;

    for(j=1;j<=Mn1;j++)
    {
        for(i=1;i<=Ln;i++)
            SOMAX[2][j]=SOMAX[2][j]+v1[i][j]*Aout[i];
        X[2][j]=SOMAX[2][j]+biasx;
        if(g_funcao==1) Bout1[j]=(1./(1.+exp(-X[2][j])));
        if(g_funcao==2) Bout1[j]=(1.0-exp(-2.0*X[2][j]))/(1.0+exp(-2.0*X[2][j]));
    }

    if(g_ncamadas==4)
    {
        for(j=1;j<=Mn2;j++)
        {
            for(i=1;i<=Mn1;i++)
                SOMAX[3][j]=SOMAX[3][j]+v2[i][j]*Bout1[i];
            X[3][j]=SOMAX[3][j]+biasx;
            if(g_funcao==1) Bout2[j]=(1./(1.+exp(-X[3][j])));
            if(g_funcao==2) Bout2[j]=(1.0-exp(-2.0*X[3][j]))/(1.0+exp(-
2.0*X[3][j]));
        }
    }
    if(Nn>=1)
    {
        if(g_ncamadas==3)
            for(j=1;j<=Mn2;j++)
                for(i=1;i<=Nn;i++)
                    SOMAX[3][i]=SOMAX[3][i]+w[j][i]*Bout1[j];
        if(g_ncamadas==4) for(j=1;j<=Mn2;j++) for(i=1;i<=Nn;i++)
            SOMAX[4][i]=SOMAX[4][i]+w[j][i]*Bout2[j];
    }

    if(g_ncamadas==3 || g_ncamadas==4)
    {
        if(Nn>=1)

```

```

        {
            for(i=1;i<=Nn;i++)
            {
                X[g_ncamadas][i]=SOMAX[g_ncamadas][i]+biasx;
                if(g_funcao==1) Cout[i]=(1./(1.+exp(-X[g_ncamadas][i])));
                if(g_funcao==2) Cout[i]=(1.0-exp(-
2.0*X[g_ncamadas][i]))/(1.0+exp(-2.0*X[g_ncamadas][i]));
            }
        }

        if(Nn>=1)
        {
            for(i=1;i<=Nn;i++)
            {
                Erro[i]=Dout[i]-Cout[i];
                R1[i]=((Cout[i]-smax)*(Doutmax[i]-Doutmin[i])+(smax-
smin)*Doutmax[i])/(smax-smin);
                R2[i]=((Dout[i]-smax)*(Doutmax[i]-Doutmin[i])+(smax-
smin)*Doutmax[i])/(smax-smin);
                R3[i]=fabs(R2[i]-R1[i]);

                // Condição acrescentada (em 14/02/01) para armazenar
                // as "saidas" (R1 e R2) somente qdo o programa estiver "lendo"
                // as linhas de verificacao do arquivo de entrada.
                if (n > V_TREINO)
                {
                    R1_ARQ[n-V_TREINO-1][i] = R1[i];
                    R2_ARQ[n-V_TREINO-1][i] = R2[i];
                }
            }
        }

        return;
    }

```

```

/*=====
Rotina/Funcao : fim_treinamento
Descricao    : Gera o arquivo de pesos e os arquivos de saída real e
                calculada. É executada quando é clicado o botão
"Parar".
Chamada por  : void CDlgGraf::GDR()
Parametros   :
Retorno      :
*/=====

```

```

void CDlgGraf::fim_treinamento()
{
    int i, j, k; // contadores

    logdeb("fim do treinamento");

```

```

if (g_fpout.sq == NULL)
{
    MessageBox("erro. stream sq == NULL !!!");
    return;
}

if (g_fpout.sql == NULL)
{
    MessageBox("erro. stream sql == NULL !!!");
    return;
}

if (g_fpout.ad == NULL)
{
    MessageBox("erro. stream ad == NULL !!!");
    return;
}

/* Arquivo de Pesos (v1, v2, w) */
for(i=1;i<=Ln;i++)
    for(j=1;j<=Mn1;j++)
    {
        fprintf(g_fpout.ad,"%f\n",v1[i][j]);
    }

if(g_ncamadas==4)
{
    for(i=1;i<=Mn1;i++)
    {
        for(j=1;j<=Mn2;j++)
        {
            fprintf(g_fpout.ad,"%f\n",v2[i][j]);
        }
    }
}

if (Nn >= 1)
{
    for(j=1;j<=Mn2;j++)
    {
        for(k=1;k<=Nn;k++)
        {
            fprintf(g_fpout.ad,"%f\n",w[j][k]);
        }
    }
}

for(j=0; j < V_TESTE; j++)
{
    for(k=1; k <= Nn; k++)
    {
        /* Arquivo de Saída Real e Saída Calculada (R1[], R2[]) */
        fprintf(g_fpout.sql,"%1.3f%1.3f  ",R1_ARQ[j][k],R2_ARQ[j][k]);
    }
}

```

```

        fprintf(g_fpout.sq,"\\n");
        fprintf(g_fpout.sq1,"\\n");
    }

    fclose(g_fpout.ad);

    TRACE("\\n\\n\\n\\t\\t FIM DO TREINAMENTO!!!\\n\\n");
    t2=clock();
    dt=(float)(t2-t1)/(CLK_TCK);

    TRACE("\\n\\n\\n\\t\\t\\a Treinamento efetuado em %1.0f minutos.",dt/60.0);
    TRACE("\\n\\n\\t\\t Total de Iteracoes=%1.0f\\n\\n",ite);

    for(i=1;i<=Nn;i++)
        TRACE("\\n\\t\\t Generalizaçao=%2.1f%",G[i]/V_TESTE*100.0);

    return;
}

/*=====
Rotina/Funcao : indataRC
Descricao : Retorna o item da massa de dados lida na linha R, coluna C
do arquivo de entrada.
Chamada por : void CDlgGraf::GDR()
Parametros :
Retorno :
=====*/

float CDlgGraf::indataRC(long r, long c)
{
    return (pInputData[r * g_totcol + c]);
}

void CDlgGraf::logdeb(const char * msg)
{
    //#if ZS_DEBUG
        //AfxMessageBox(msg);
        zlog(msg);
    //#endif
}

void CDlgGraf::msgerro(const char * msg)
{
    zlog(msg);
    AfxMessageBox(msg, MB_ICONSTOP + MB_OK);
}

void CDlgGraf::OnBtParar()
{
    // TODO: Add your control notification handler code here
    m_btparar.EnableWindow(FALSE);
    m_btprocessar.EnableWindow(TRUE);
    m_btfechar.EnableWindow(TRUE);
}

```

```
// seta flag para interromper loop principal de processamento
// consequentemente a rotina fim_treinamento() será executada...
flag_stopmainloop = 1;

if (pInputData != NULL)
{
    free(pInputData); // LIBERA MEMÓRIA PREVIAMENTE ALOCADA
    pInputData = NULL;
}
}

void CDlgGraf::OnMouseMoveChartfx1(short x, short y, short FAR* nRes)
{
    // TODO: Add your control notification handler code here
    char tempstr[200];

    sprintf(tempstr, "x:%d y:%d", x, y);
    m_lbl_grafpos = tempstr;
    UpdateData(FALSE);
}

void CDlgGraf::OnShowWindow(BOOL bShow, UINT nStatus)
{
    CDialog::OnShowWindow(bShow, nStatus);
    int x;

    // TODO: Add your message handler code here

    m_GriResult.SetRows(6);
    m_GriResult.SetCols(Nn+1);

    m_GriResult.SetBackColor(0xFE00); // cor de fundo p/ planilha
    m_GriResult.SetFixedRows(0);
    m_GriResult.SetFixedCols(1);
    m_GriResult.SetColWidth(0, 12*256);
    m_GriResult.SetColWidth(1, 5*256);

    for (x=0; x<=Nn; x++)
    {
        erro_recebido[x]=erro[x];
    }

    logdeb("INICIANDO PROCESSAMENTO DA REDE NEURAL.");
}

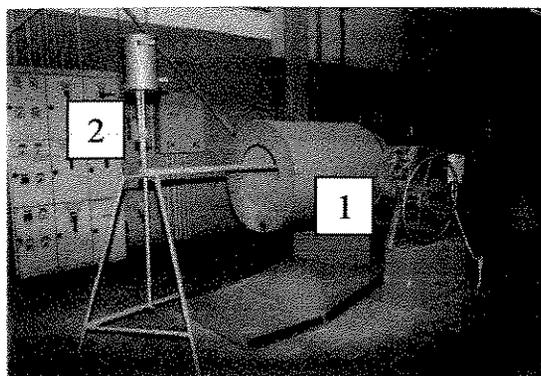
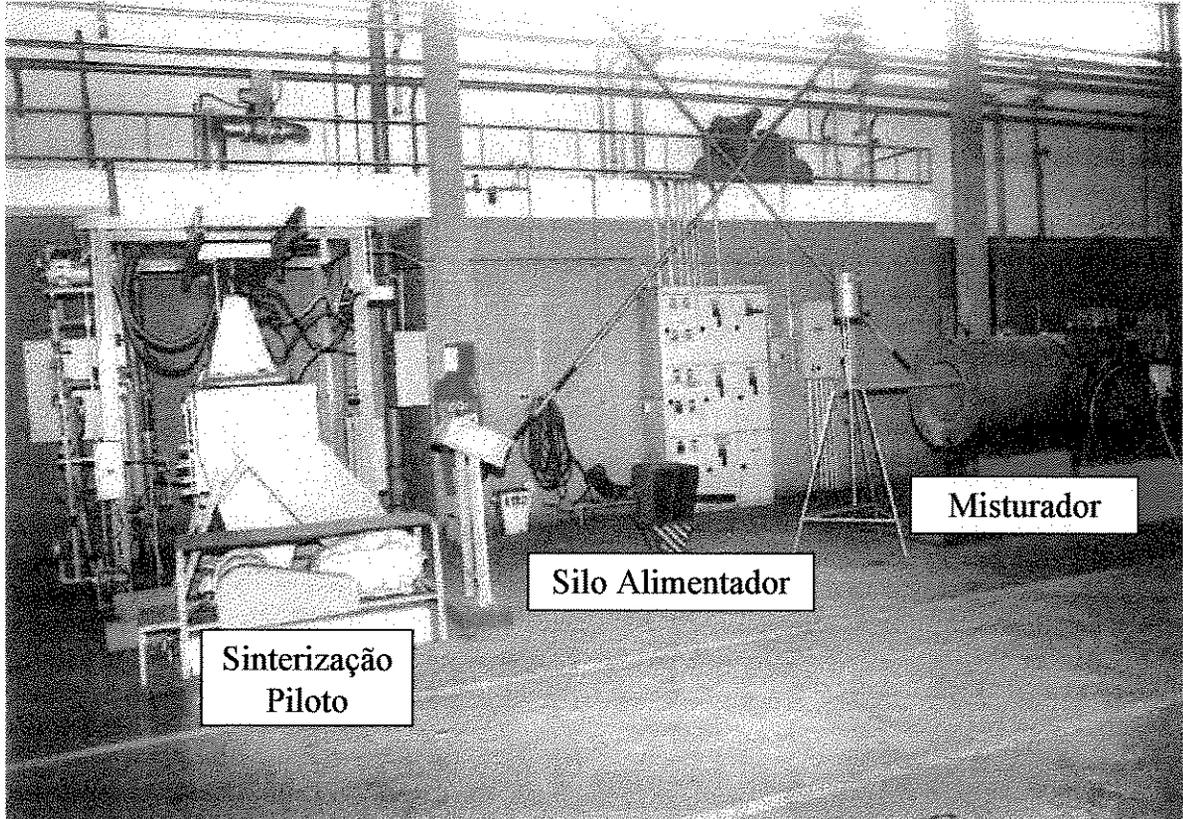
void CDlgGraf::OnBtProcessar()
{
    // TODO: Add your control notification handler code here

    m_btprocessar.EnableWindow(FALSE);
    m_btparar.EnableWindow(TRUE);
    m_btfechar.EnableWindow(FALSE);

    GDR();
}
```

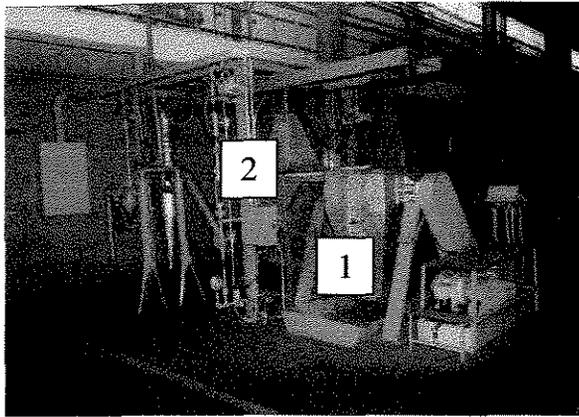
```
}  
  
BOOL CDlgGraf::OnInitDialog()  
{  
    CDialog::OnInitDialog();  
  
    // TODO: Add extra initialization here  
  
    // Set Real-Time attributes  
    m_chart.SetType(m_chart.GetType() | CT_EVENSACING | CT_SHOWZERO);  
    m_chart.SetRealTimeStyle(CRT_NOWAITARROW);  
    m_chart.SetStyleEx(m_chart.GetStyleEx() | CSE_FASTLEGENDS);  
  
    // Init data arrays  
    m_chart.OpenDataEx(COD_VALUES,2,0);  
    m_chart.CloseData(COD_VALUES);  
  
    m_chart.SetToolPos(CTOOL_SERLEGEND, CTP_BOTTOM);  
  
    return TRUE; // return TRUE unless you set the focus to a control  
                // EXCEPTION: OCX Property Pages should return FALSE  
}
```

ANEXO C - SISTEMA PILOTO DE SIMULAÇÃO E CARACTERIZAÇÃO DE SÍNTERES



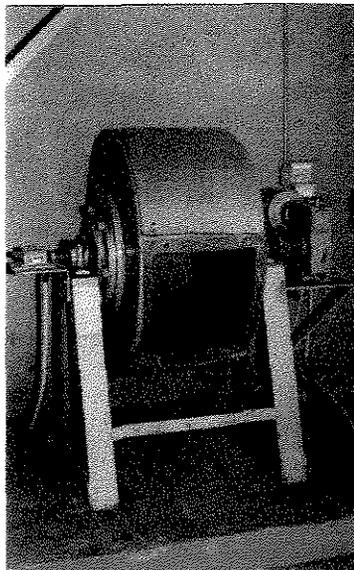
Detalhe do Misturador

As matérias primas são pesadas, conforme uma proporção de mistura a siinterizar e são misturadas pelo Misturador (1). Em seguida adiciona-se cerca de 6% em peso de água (2) e, com o Misturador em movimento, formam-se as micropelotas.



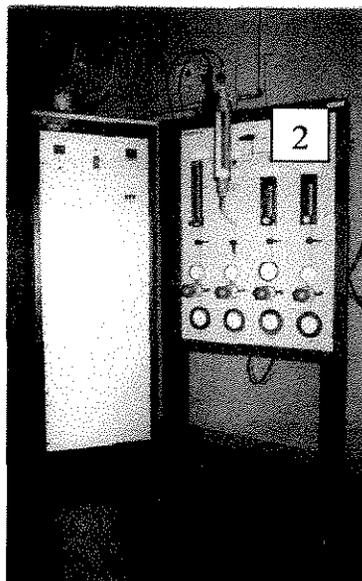
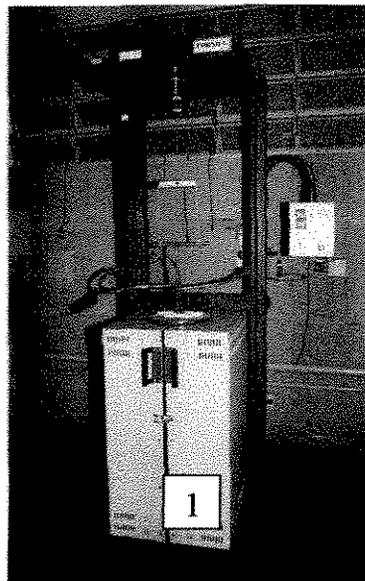
Detalhe da Sinterização Piloto

As micropelotas (110 a 120 kg) são adicionadas na máquina de síter (1) e com o forno de ignição (2) inicia-se, com a ajuda de um sistema de exaustão, a sinterização, com propagação da frente de queima de cima para baixo.



Tamboramento

Após produzido e resfriado, o síter é tamborado neste equipamento para a simulação das quebras e degradações, objetivando a estabilização do tamanho médio do produto. Em seguida o material é peneirado em faixas granulométricas de acordo com o tipo de caracterização necessária.



Fornos para RDI e RI

Dentro das faixas granulométricas específicas de cada ensaio e do peso de material necessário, são adicionados sínteres no interior dos fornos (1) e, com a atmosfera devidamente controlada, os ensaios são realizados com um sistema de controle das variáveis (2).

ANEXO D – NORMAS ISO DE ENSAIOS DE RDI/RI E PROCEDIMENTO DE ANÁLISE MINERALÓGICA DE SÍNTER

ENSAIO DE RDI

OBJETIVO	Determinar o índice de degradação após redução.
APLICAÇÃO	Alto-Forno
NORMA	ISO 4696-1 1996.
PRODUTO AVALIADO	Pelota, granulado e sinter.
MASSA (g)	500,0g +/- 1 partícula para cada porção de teste.
FAIXA GRANULOMETRICA (mm)	Pelota: (-12,5; +10,0). granulado /sinter; (-12,5; +10,0). (incorporação +12,5 britado).
ENSAIO	Mínimo de 2 porções teste .
EQUIPAMENTOS	Forno elétrico vertical; retorta de diâmetro interno igual a 75 +/- 1mm e comprimento de 1050 mm; tambor de 130 mm de diâmetro interno por 200 mm de comprimento com duas aletas.
CONDIÇÕES DE ENSAIO	Temperatura: 500 +/- 5°C; aquecimento: 20NI/min de N ₂ ; estabilização: 20NI/min de N ₂ (por +/- 15 min); redução: 20 NI/min (20% CO ; 58% N ₂ ; 20%CO ₂ ; 2% H ₂) por 60 minutos; resfriando: 20NI/min de N ₂ ; tamboramento a 30 +/- 1 rpm por 300 voltas.
PENEIRAMENTO ANTES MALHAS (mm) DEPOIS	Retirada da faixa 6,3; 3,15 e 0,50.
EXPRESSÃO DE RESULTADO	$RDI +6,3 \text{ mm} = (m1/m0) \times 100$ $RDI -3,15 \text{ mm} = ((m0 - (m1 + m2)) / m0) \times 100$ $RDI -0,50 \text{ mm} = ((m0 - (m1 + m2 + m3)) / m0) \times 100$ Onde: $RDI +6,3 \text{ mm} = (\%+6,3\text{mm})(\text{resultado com uma casa decimal})$ $RDI -3,15 \text{ mm} = (\%-3,15\text{mm})(\text{resultado com uma casa decimal})$ $RDI -0,50 \text{ mm} = (\%0,50\text{mm})(\text{resultado com uma casa decimal})$ m0 = massa da porção teste após da redução e antes do tamboramento. (g). m1 = massa da porção teste retida em 6,3mm (g). m2 = massa da porção teste retida em 3,15mm (g). m3 = massa da porção teste retida em 0,50mm (g).
TOLERANCIA PERMISSÍVEL	a diferença entre duas porções teste tem que ser menor ou igual a 1 % (95% de confiança).
TEMPO (h)	9,7

ENSAIO DE RI

OBJETIVO	Obter o grau de redução de uma amostra quando submetida a condições de temperatura e atmosfera redutora.
APLICAÇÃO	Alto-Forno
NORMA	ISO 7215: 1995.
PRODUTO AVALIADO	Pelota, granulado e sinter.
MASSA (g)	500,0g +/- 1 partícula para cada porção de teste.
FAIXA GRANULOMETRICA(mm)	Pelota: (-12,5; +10,0). granulado /sinter; (-20,0; +18,0).
ENSAIO	Mínimo de 3 porções teste (1 porção teste para análise química) .
EQUIPAMENTOS	Forno elétrico vertical; painel controlado dotado de balança com capacidade para aproximadamente 16Kg; retorta de diâmetro interno igual a 75 +/- 1mm e comprimento de 1050 mm.
CONDIÇÕES	Temperatura :900 +/- 5°C; aquecimento: 5NI/min de N ₂ ; estabilização:15NI/min de N ₂ (por +/- 30 min); redução: 15 NI/min (30% CO e 70% N ₂) por 180 minutos; resfriando: 5NI/min de N ₂ .
PENEIRAMENTO ANTES MALHAS (mm) DEPOIS	Retirada da faixa Não utilizada.
EXPRESSÃO DE RESULTADO	$\%RI = ((m1-m2) / (m0 \times (0,43 \times Fe_t - 0,111 \times FeO))) \times 10000$. Onde: %RI = grau de redução (resultado com uma casa decimal). m0 = massa inicial da porção- teste (g). m1 = massa da porção - teste imediatamente antes da redução (g) m2 = massa da porção - teste após 180min de redução. Fe t = teor de ferro total contido na porção teste. FeO = teor de óxido de ferro II contido na porção teste.
TOLERÂNCIA PERMISSÍVEL	PELOTA: a diferença entre duas porções teste < 3 %. SINTER: a diferença entre duas porções teste < 5 %. GRANULADO: não especificado.
TEMPO (h)	15,8

ENSAIO CSN DE MINERALOGIA DE SÍNTER

A) PREPARAÇÃO DE CORPOS DE PROVA DE SINTER

A preparação consiste de 3 etapas:

- 1) Embutimento: Mede-se 10ml de amostra homogeneizada, mede-se separadamente em um becker 10ml de resina, adicionar a esta resina 09 gotas de catalisador. Homogeneizar a resina com catalizador e adicionar a amostra previamente medida. Aguardar 06horas para a polimerização da resina;
- 2) Lixamento: Lixar utilizando sequencialmente as lixas 220, 320, 400, 600 e 1200.
- 3) Polimento: Utilizamos as pastas de diamante de 6, 3 e 1 micron para o polimento.

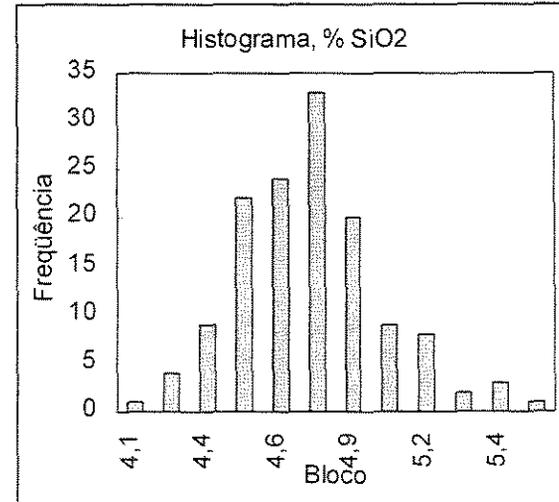
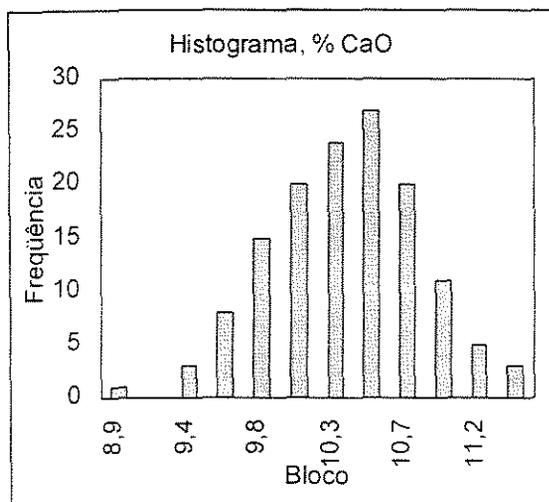
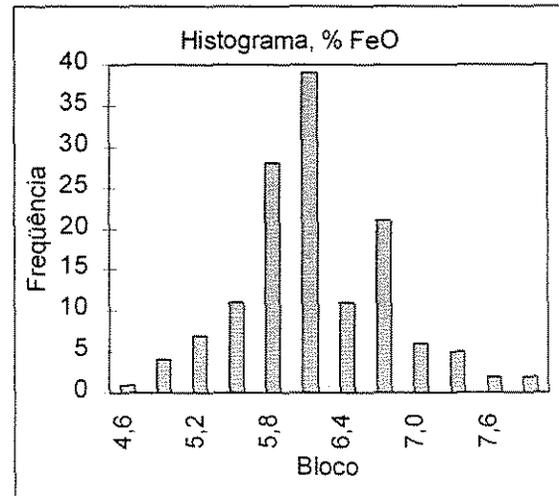
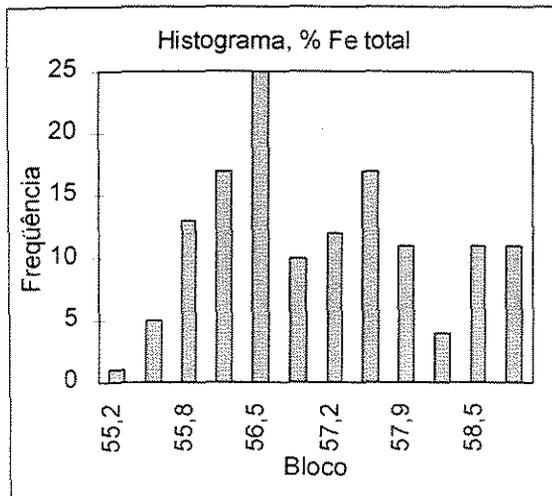
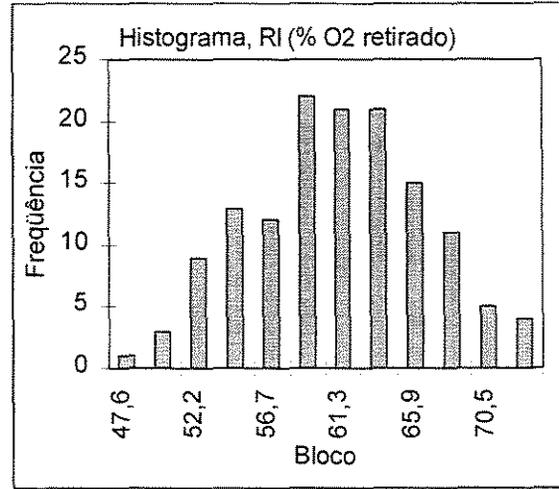
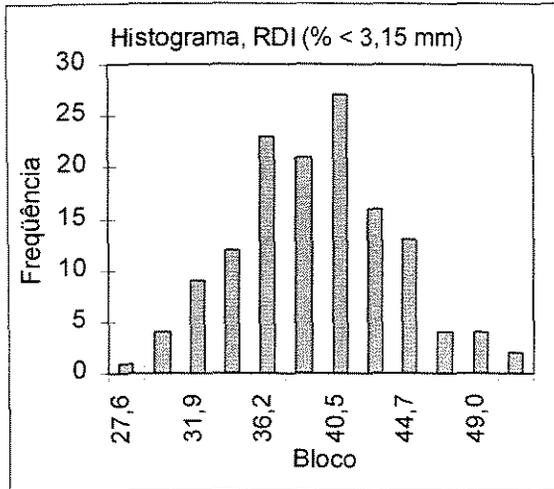
B) ANÁLISE MINERALÓGICA

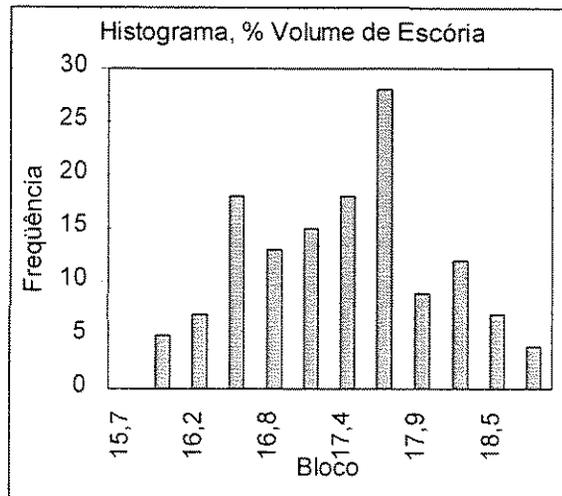
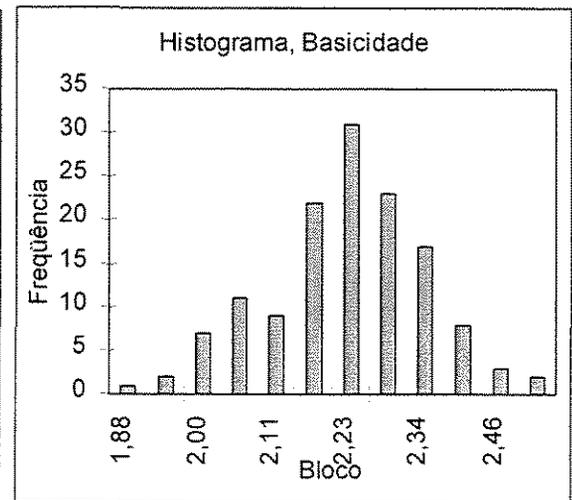
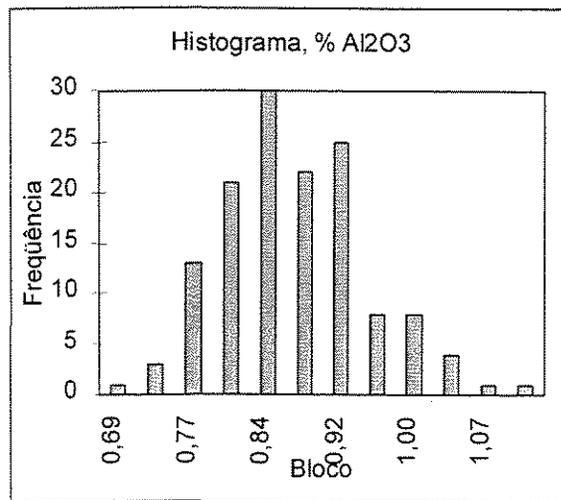
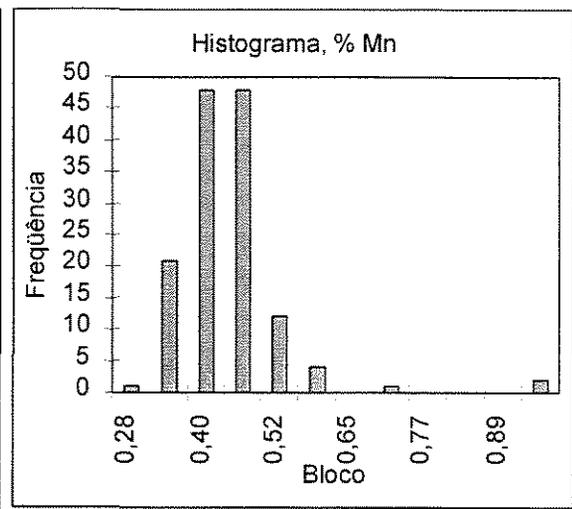
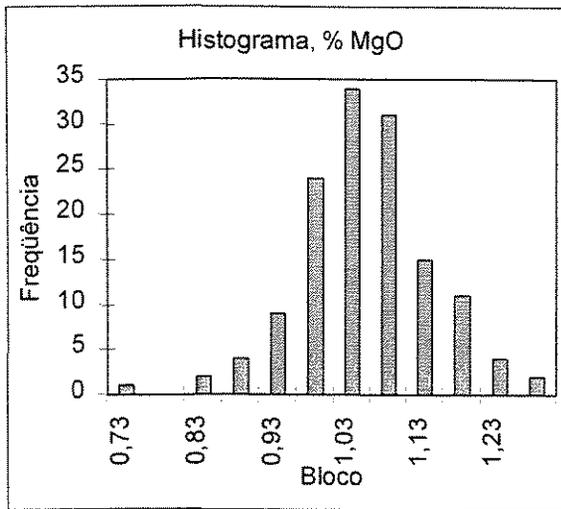
A análise é realizada utilizando um microscópio ótico convencional acoplado a um contador de pontos. O contador possui 11 teclas disponíveis para identificação das fases e uma outra para a soma da resina utilizada no embutimento, mas que não é contabilizada. Cada tecla do contador de pontos é correspondente a uma fase do sinter. Uma vez identificada a imagem (fase) sob o retículo colocado em uma das oculares do microscópio, aperta-se a tecla do contador de pontos correspondente a fase encontrada.

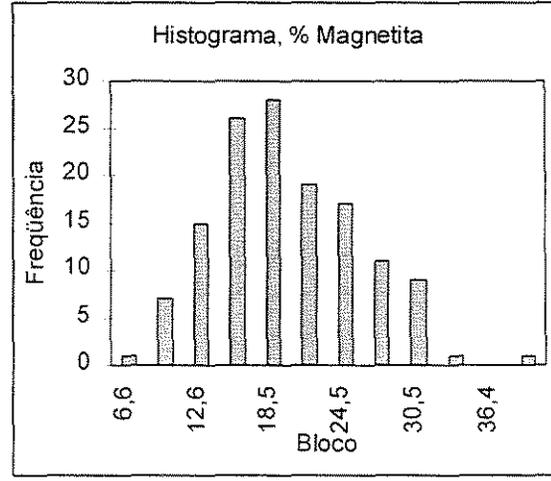
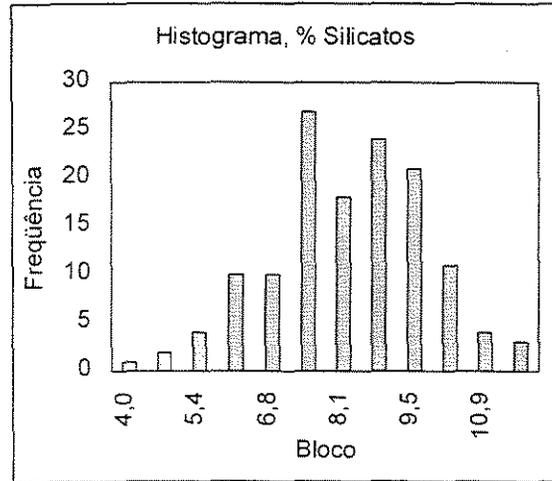
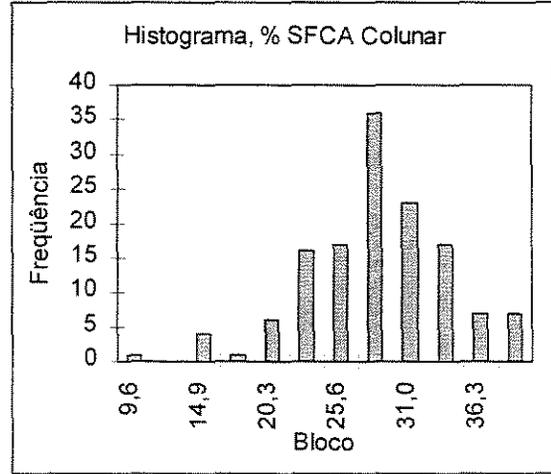
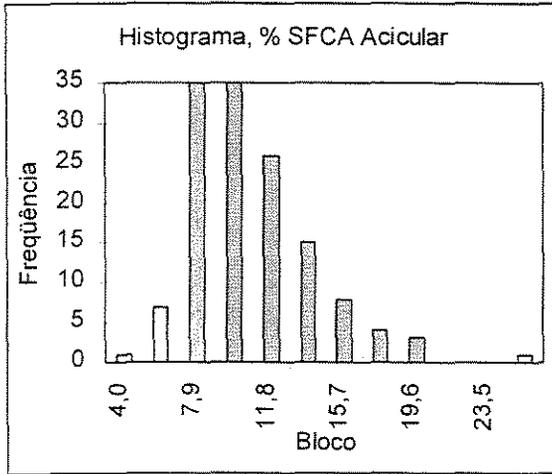
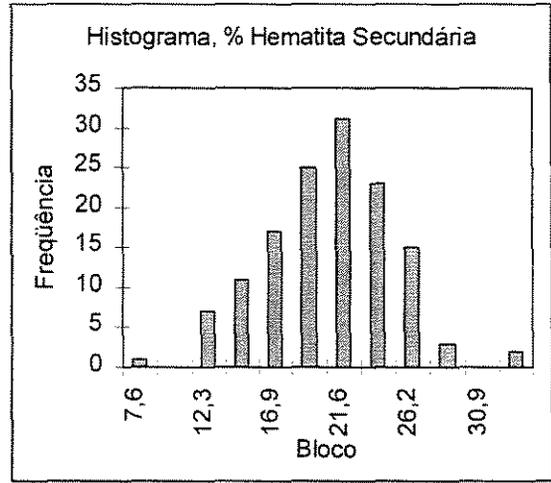
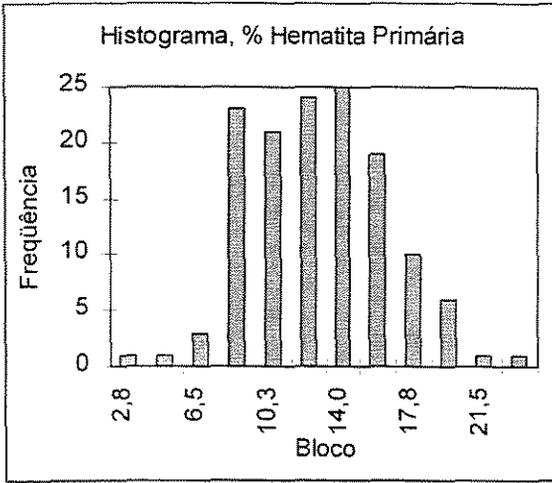
Utiliza-se um passo de 0,4 x 0,6 (mm) no contador de pontos e ampliação de 200x no microscópio ótico.

Para cada amostra são contados quinhentos pontos e os resultados são apresentados em percentuais volumétricos.

ANEXO E – COMPORTAMENTO DAS VARIÁVEIS DE SÍNTER

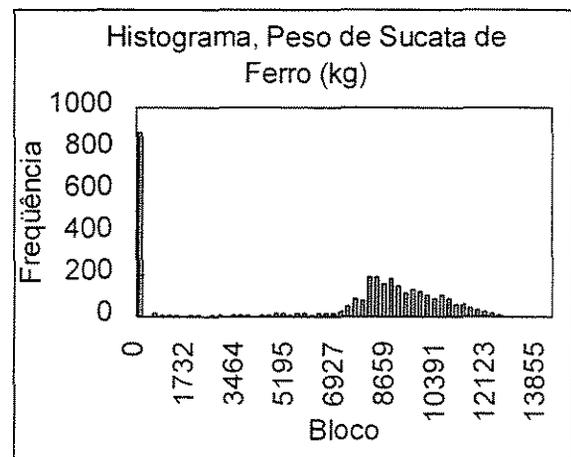
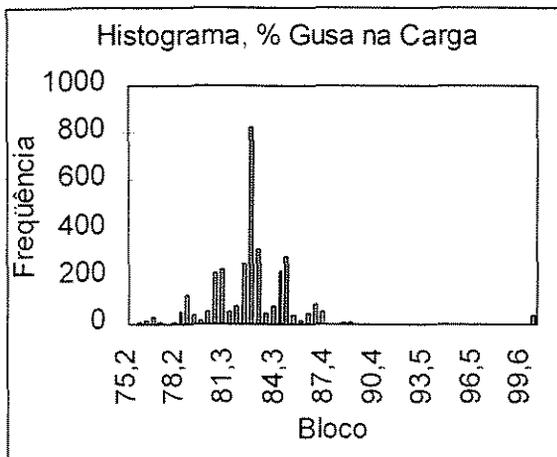
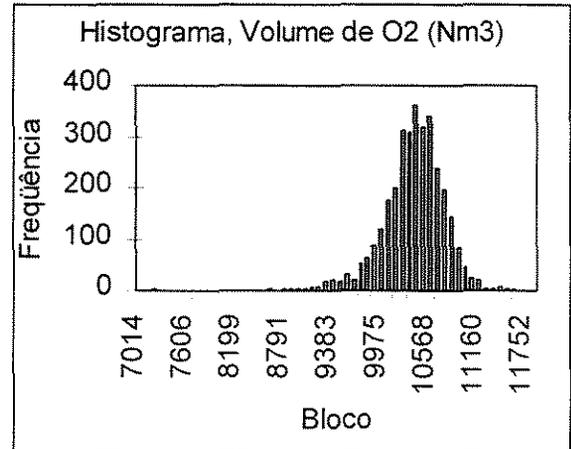
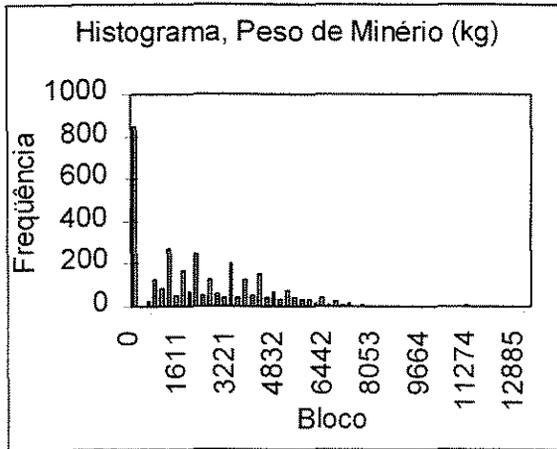
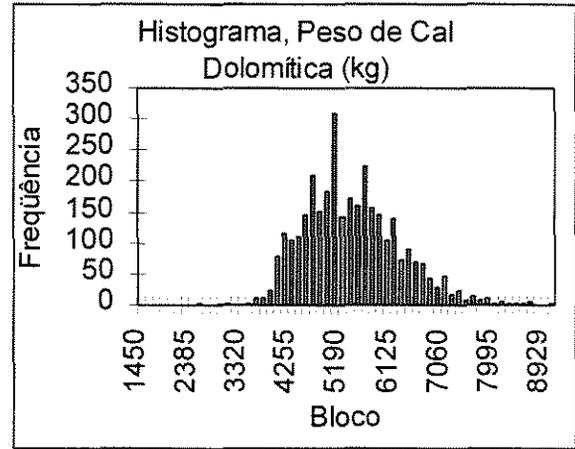
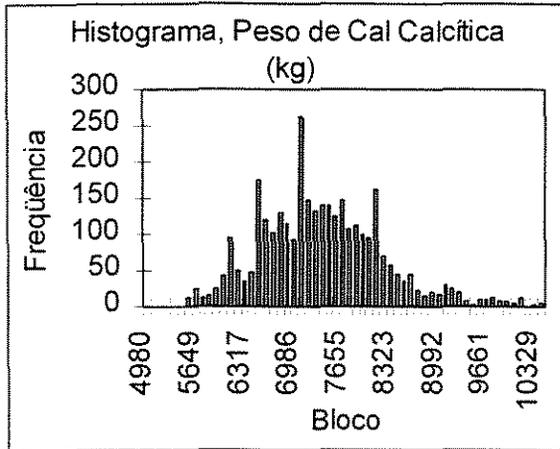


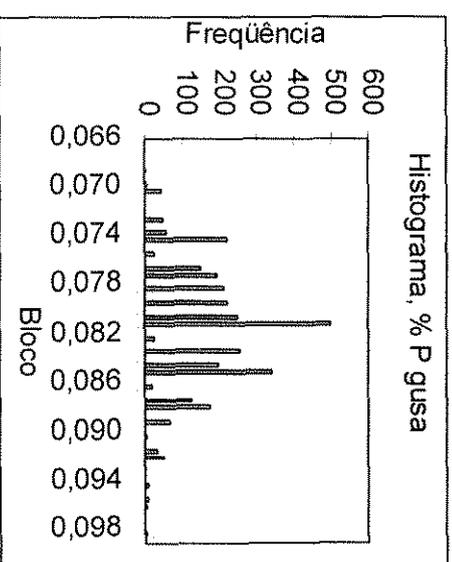
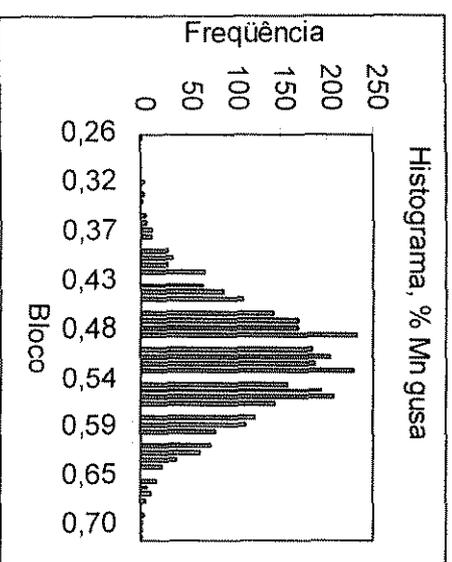
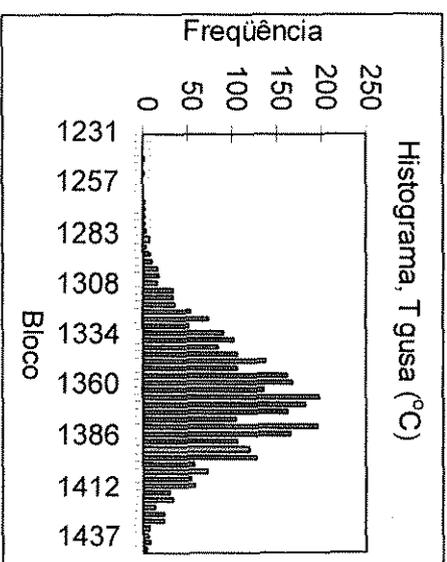
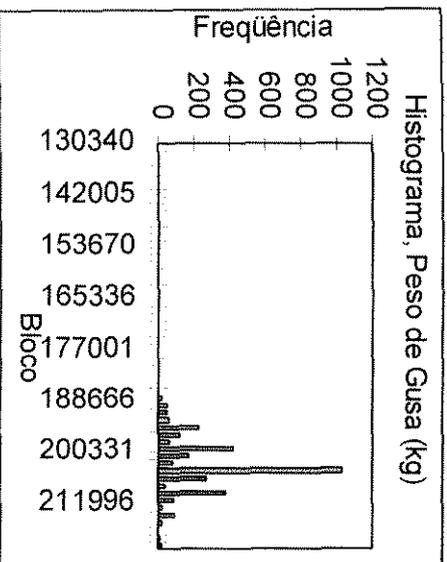
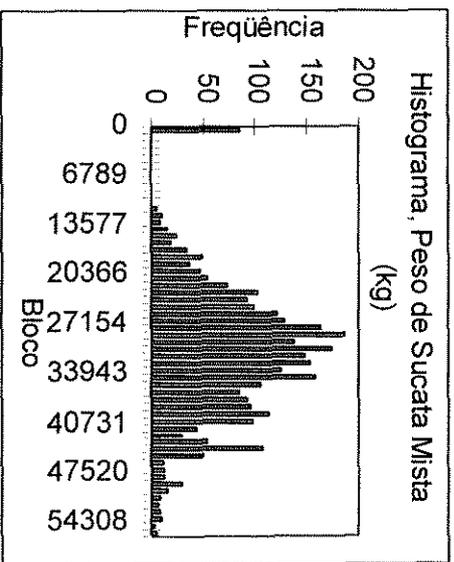
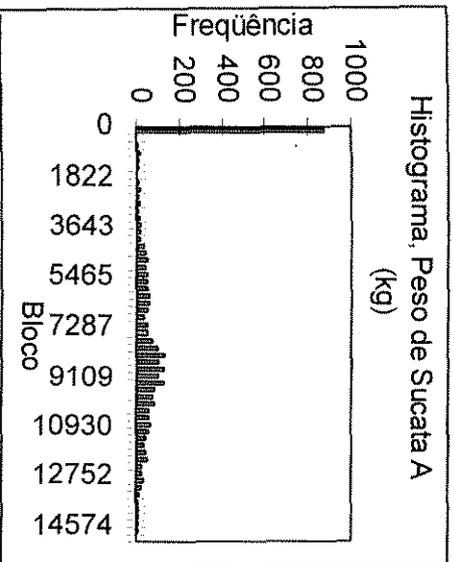


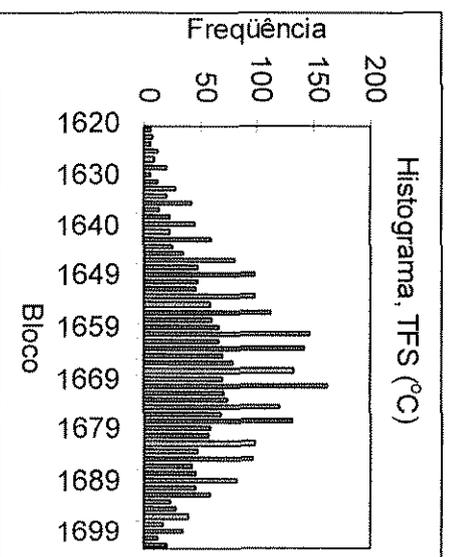
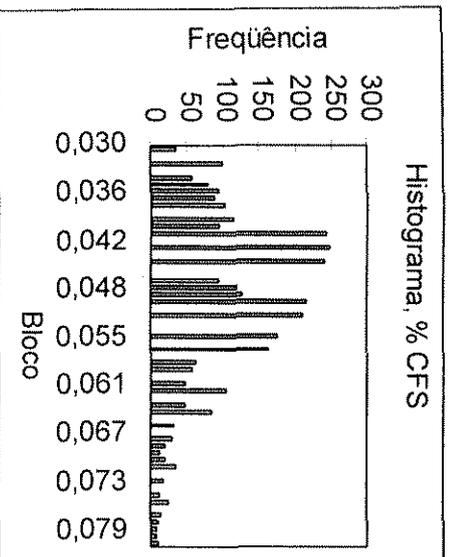
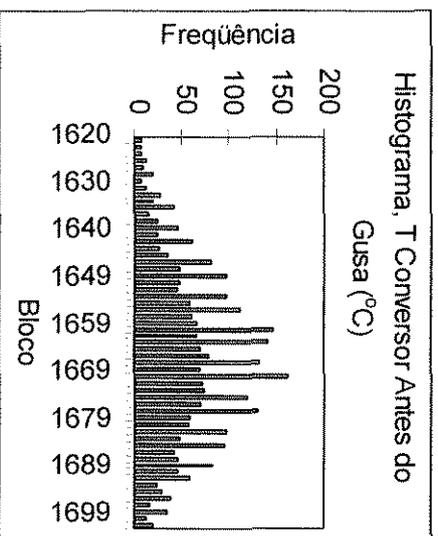
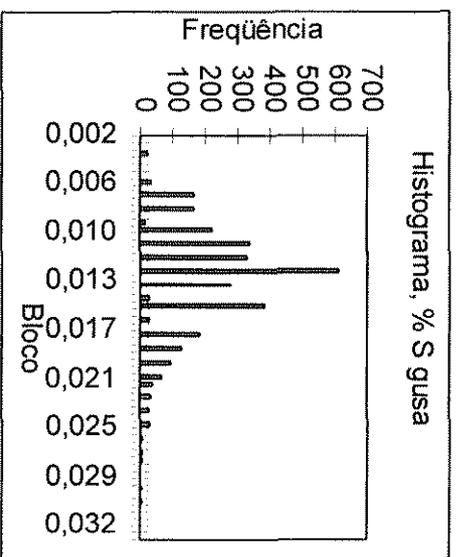
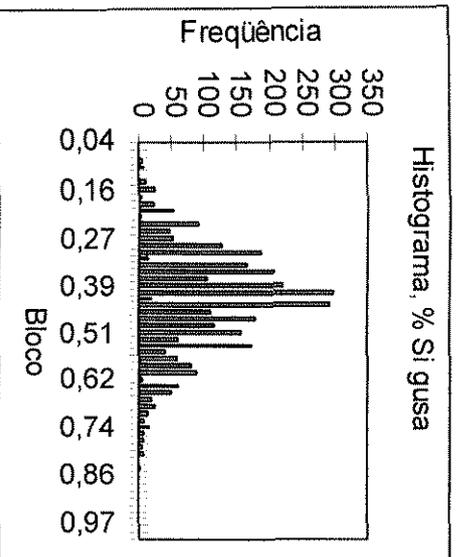


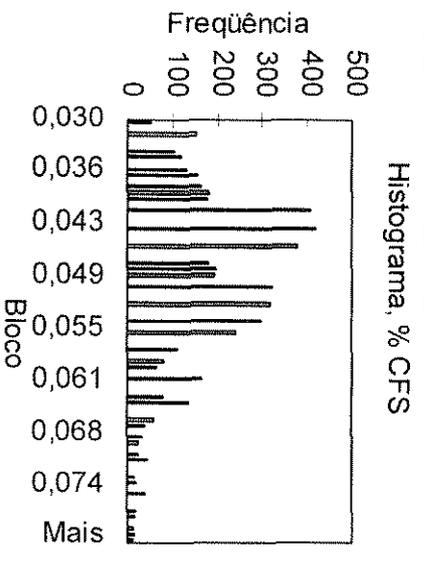
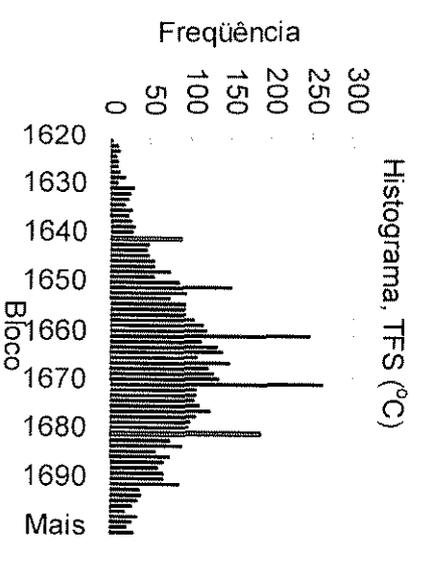
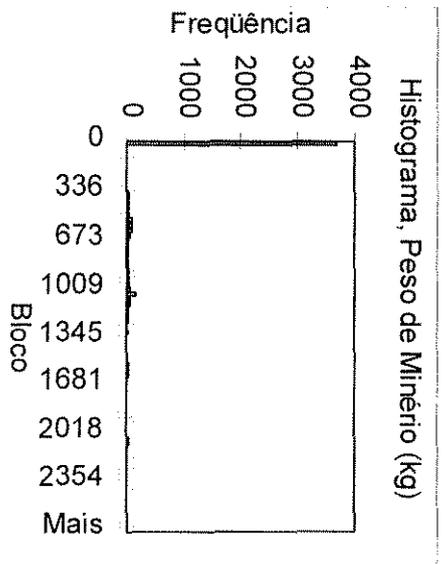
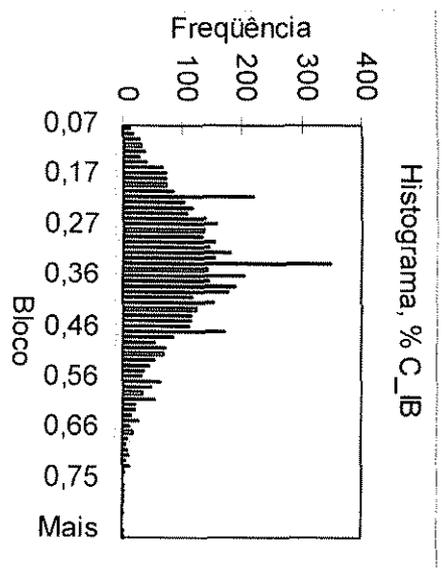
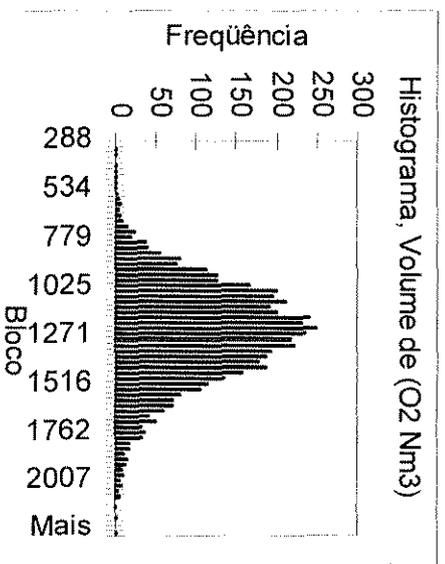
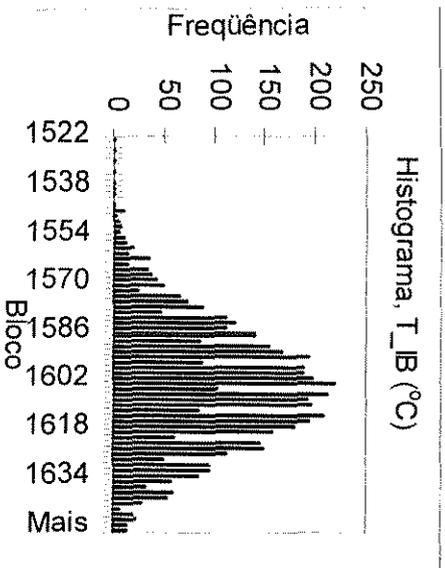
ANEXO F – COMPORTAMENTO DAS VARIÁVEIS DE ACIARIA

PARA O MODELO ESTÁTICO

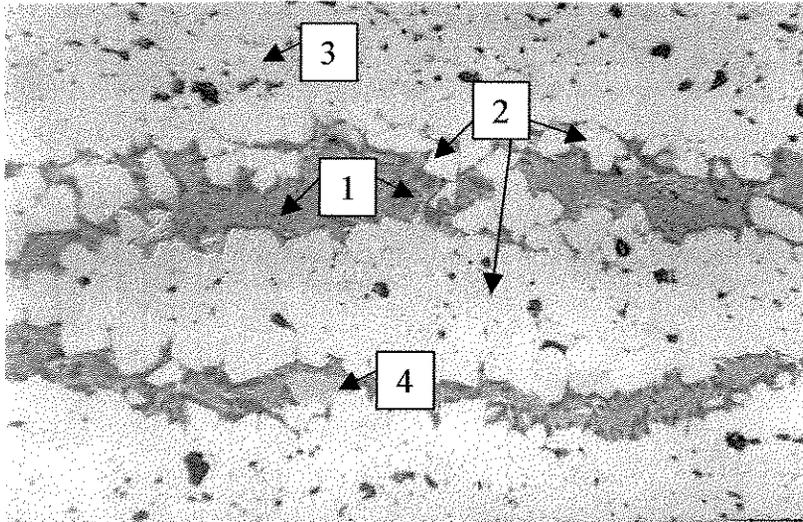




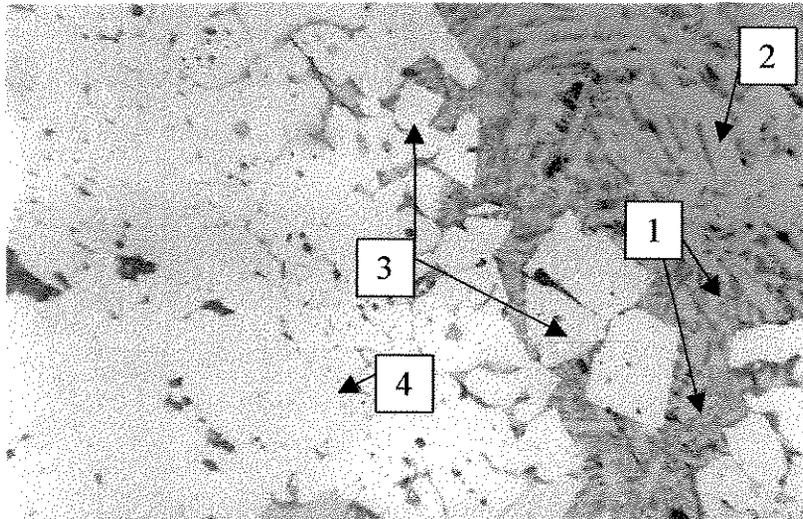




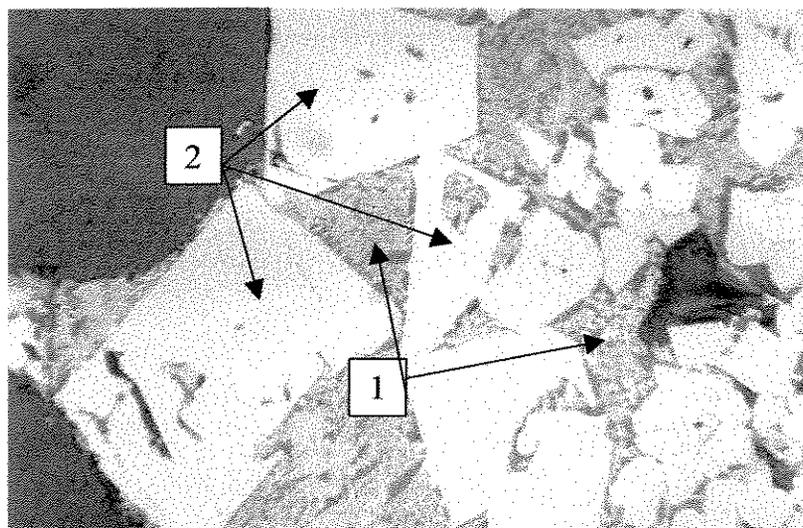
ANEXO G – ANÁLISE MINERALÓGICA DE SÍNTER



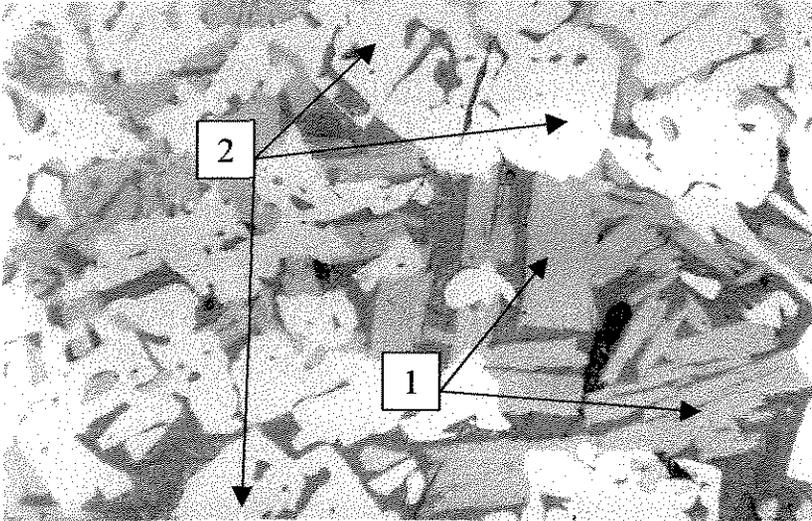
Esta foto mostra SFCA Acicular (1), grãos de Hematita Secundária (2), região de Hematita Primária (3) e um grão de Magnetita (4). Estes caminhos preferenciais de SFCA favorecem o aumento do RDI e do RI. Entre os grãos de SFCA estão os Silicatos.



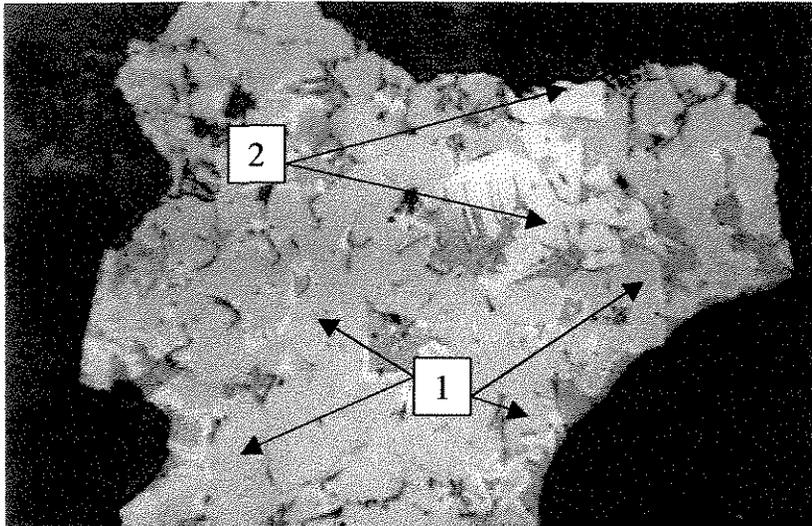
Esta foto mostra SFCA Acicular (1), SFCA Colunar (2), região de Hematita Secundária (3) e região de Hematita Primária (4).



Esta foto mostra SFCA Acicular (1) e grãos de Hematita Secundária, com os contornos bem definidos (2).



Esta foto mostra SFCA Colunar (1) e Hematita Secundária (2).



Esta foto mostra Magnetita (1) e Hematita Secundária (2).

ANEXO H – RESULTADOS DAS SIMULAÇÕES NUMÉRICAS PARA OS MODELOS DE ACIARIA

Simulações	Média	α	η	b1	bo	w	fa	α .fa	bo.fa	η . α .bo	C	t	acertsim
1	1	1	1	-1	-1	-1	1	1	-1	-1	81,5%	84,0%	68,5%
2	1	1	1	-1	-1	-1	-1	-1	1	-1	47,0%	81,0%	38,1%
3	1	1	1	-1	-1	1	1	1	-1	-1	80,0%	85,5%	68,4%
4	1	1	1	-1	-1	1	-1	-1	-1	-1	47,0%	82,0%	38,5%
5	1	1	1	-1	1	-1	1	1	1	1	77,5%	80,0%	62,0%
6	1	1	1	-1	1	-1	-1	-1	-1	1	52,5%	76,5%	40,2%
7	1	1	1	-1	1	1	1	1	1	1	76,5%	88,5%	67,7%
8	1	1	1	-1	1	1	-1	-1	-1	1	48,0%	78,0%	37,4%
9	1	1	1	1	-1	-1	1	1	-1	-1	80,5%	85,5%	68,8%
10	1	1	1	1	-1	-1	-1	-1	-1	1	47,0%	83,5%	39,2%
11	1	1	1	1	-1	1	1	1	-1	-1	81,5%	85,0%	69,3%
12	1	1	1	1	-1	1	-1	-1	1	-1	47,0%	81,0%	38,1%
13	1	1	1	1	1	-1	1	1	1	1	79,5%	88,0%	70,0%
14	1	1	1	1	1	-1	-1	-1	-1	1	52,0%	74,5%	38,7%
15	1	1	1	1	1	1	1	1	1	1	78,0%	87,0%	67,9%
16	1	1	1	1	1	1	-1	-1	-1	1	51,5%	77,0%	39,7%
17	1	1	-1	-1	-1	-1	1	1	-1	1	78,5%	82,5%	64,8%
18	1	1	-1	-1	-1	-1	-1	-1	1	1	50,0%	74,5%	37,3%
19	1	1	-1	-1	-1	1	1	1	-1	1	79,5%	82,0%	65,2%
20	1	1	-1	-1	-1	1	-1	-1	-1	1	47,0%	77,5%	36,4%
21	1	1	-1	-1	1	-1	1	1	1	-1	76,0%	85,5%	65,0%
22	1	1	-1	-1	1	-1	-1	-1	-1	-1	47,0%	82,0%	38,5%
23	1	1	-1	-1	1	1	1	1	1	1	78,0%	86,0%	67,1%
24	1	1	-1	-1	1	1	-1	-1	-1	-1	47,0%	81,5%	38,3%
25	1	1	-1	1	-1	-1	1	1	-1	1	76,5%	84,0%	64,3%
26	1	1	-1	1	-1	-1	-1	-1	-1	1	47,0%	78,0%	36,7%
27	1	1	-1	1	-1	1	1	1	-1	1	79,5%	84,0%	66,8%
28	1	1	-1	1	-1	1	-1	-1	1	1	47,0%	78,5%	36,9%
29	1	1	-1	1	1	-1	1	1	1	-1	78,5%	85,5%	67,1%
30	1	1	-1	1	1	-1	-1	-1	-1	-1	47,0%	82,5%	38,8%
31	1	1	-1	1	1	1	1	1	1	-1	79,0%	87,5%	69,1%
32	1	1	-1	1	1	1	-1	-1	-1	-1	47,0%	84,0%	39,5%
33	1	-1	1	-1	-1	-1	1	-1	-1	1	77,5%	83,5%	64,7%
34	1	-1	1	-1	-1	-1	-1	1	1	1	51,5%	73,5%	37,9%
35	1	-1	1	-1	-1	1	1	-1	-1	1	74,0%	85,5%	63,3%
36	1	-1	1	-1	-1	1	-1	1	1	1	47,0%	78,5%	36,9%
37	1	-1	1	-1	1	-1	1	-1	1	-1	75,0%	85,5%	64,1%
38	1	-1	1	-1	1	-1	-1	1	-1	-1	47,0%	82,0%	38,5%
39	1	-1	1	-1	1	1	1	-1	1	-1	79,5%	81,0%	64,4%
40	1	-1	1	-1	1	1	-1	1	-1	-1	47,0%	82,5%	38,8%
41	1	-1	1	1	-1	-1	1	-1	-1	1	75,5%	84,0%	63,4%
42	1	-1	1	1	-1	-1	-1	1	1	1	47,0%	80,5%	37,8%
43	1	-1	1	1	-1	1	1	-1	-1	1	75,5%	85,5%	64,6%
44	1	-1	1	1	-1	1	-1	1	1	1	47,0%	81,5%	38,3%
45	1	-1	1	1	1	-1	1	-1	1	-1	76,5%	84,0%	64,3%
46	1	-1	1	1	1	-1	-1	1	-1	-1	50,0%	80,0%	40,0%
47	1	-1	1	1	1	1	1	-1	1	-1	78,0%	83,0%	64,7%
48	1	-1	1	1	1	1	-1	1	-1	-1	50,0%	80,0%	40,0%
49	1	-1	-1	-1	-1	-1	1	-1	-1	-1	76,5%	79,5%	60,8%
50	1	-1	-1	-1	-1	-1	-1	1	-1	-1	47,0%	77,5%	36,4%
51	1	-1	-1	-1	-1	1	1	-1	-1	-1	78,0%	80,0%	62,4%
52	1	-1	-1	-1	-1	1	-1	1	1	-1	47,0%	76,0%	35,7%
53	1	-1	-1	-1	1	-1	1	-1	1	1	79,0%	75,5%	59,6%
54	1	-1	-1	-1	1	-1	-1	1	-1	1	47,0%	82,0%	38,5%
55	1	-1	-1	-1	1	1	1	-1	1	1	76,0%	79,5%	60,4%
56	1	-1	-1	-1	1	1	-1	1	-1	1	48,0%	75,5%	36,2%
57	1	-1	-1	1	-1	1	-1	-1	-1	-1	79,5%	77,5%	61,6%
58	1	-1	-1	1	-1	-1	-1	1	1	-1	47,0%	76,5%	36,0%
59	1	-1	-1	1	-1	1	1	-1	-1	-1	76,5%	81,5%	62,3%
60	1	-1	-1	1	-1	1	-1	1	1	-1	47,0%	76,5%	36,0%
61	1	-1	-1	1	1	-1	1	-1	1	1	74,5%	82,0%	61,1%
62	1	-1	-1	1	1	-1	-1	1	-1	1	47,0%	79,5%	37,4%
63	1	-1	-1	1	1	1	1	-1	1	1	76,5%	80,0%	61,2%
64	1	-1	-1	1	1	1	-1	1	-1	1	47,0%	80,0%	37,6%
	51,4%	2,5%	1,8%	0,8%	0,6%	0,3%	26,9%	1,8%	-0,8%	-0,9%			

Resultados do
Planejamento de
Experimentos
Fatorial para 4x9x2

Anexo H – Resultados das Simulações Numéricas para os Modelos de Aciaria

Simulações	Media	α	η	b1	bo	w	$\eta.w$	b1.w	$\eta.\alpha.bo$	C	I	acertsim
1	1	1	1	-1	-1	-1	-1	1	-1	81,0%	84,5%	68,4%
3	1	1	1	-1	-1	1	1	-1	-1	79,5%	86,5%	68,8%
5	1	1	1	-1	1	1	1	-1	1	78,0%	87,0%	67,9%
7	1	1	1	-1	1	1	1	-1	1	77,0%	88,5%	68,1%
9	1	1	1	1	-1	-1	-1	-1	-1	80,0%	84,5%	67,6%
11	1	1	1	1	-1	1	1	1	-1	80,0%	85,5%	68,4%
13	1	1	1	1	1	-1	-1	-1	1	79,0%	88,0%	69,5%
15	1	1	1	1	1	1	1	1	1	79,0%	88,0%	69,5%
17	1	1	-1	-1	-1	-1	1	1	1	78,5%	82,5%	64,8%
19	1	1	-1	-1	-1	1	-1	-1	1	79,5%	81,0%	64,4%
21	1	1	-1	-1	1	-1	1	1	-1	78,5%	84,5%	64,6%
23	1	1	-1	-1	1	1	-1	-1	-1	79,0%	84,0%	66,4%
25	1	1	-1	1	-1	-1	1	-1	1	79,0%	81,5%	64,4%
27	1	1	-1	1	-1	1	-1	1	1	79,0%	84,0%	66,4%
29	1	1	-1	1	1	-1	1	-1	-1	78,0%	85,5%	66,7%
31	1	1	-1	1	1	1	-1	1	-1	79,0%	87,0%	66,7%
33	1	-1	1	-1	-1	-1	-1	1	1	76,5%	84,5%	64,6%
35	1	-1	1	-1	-1	1	1	-1	1	74,0%	83,5%	61,8%
37	1	-1	1	-1	1	-1	-1	1	-1	77,5%	86,0%	66,7%
39	1	-1	1	-1	1	1	1	-1	-1	74,0%	85,0%	62,9%
41	1	-1	1	1	-1	-1	-1	-1	1	74,5%	85,5%	63,7%
43	1	-1	1	1	-1	1	1	1	1	78,0%	83,0%	64,7%
45	1	-1	1	1	1	-1	-1	-1	-1	77,0%	84,5%	65,1%
47	1	-1	1	1	1	1	1	1	-1	76,5%	86,0%	65,8%
49	1	-1	-1	-1	-1	-1	1	1	-1	77,0%	79,0%	60,8%
51	1	-1	-1	-1	-1	1	-1	-1	-1	77,5%	79,0%	61,2%
53	1	-1	-1	-1	1	-1	1	1	1	76,5%	78,0%	69,7%
55	1	-1	-1	-1	1	1	-1	-1	1	77,0%	78,5%	60,4%
57	1	-1	-1	1	-1	-1	1	-1	-1	77,5%	79,5%	61,6%
59	1	-1	-1	1	-1	1	-1	1	-1	77,5%	80,0%	62,0%
61	1	-1	-1	1	1	-1	1	-1	1	75,0%	80,5%	60,4%
63	1	-1	-1	1	1	1	-1	1	1	77,0%	81,0%	62,4%
	64,9%	4,4%	3,0%	1,0%	0,7%	0,3%	-0,8%	0,8%	-0,8%			

Resultados do Planejamento de Experimentos Fatorial para 4x8x2

Simulações	Media	α	η	b1	bo	w	$\alpha.\eta$	$\eta.b1$	$\eta.b1.w$	C	I	acertsim
1	1	1	1	-1	-1	-1	-1	-1	1	81,5%	87,0%	70,9%
3	1	1	1	-1	-1	1	1	-1	-1	79,5%	87,5%	69,6%
5	1	1	1	-1	1	-1	1	-1	1	80,0%	82,0%	65,6%
7	1	1	1	-1	1	1	1	-1	-1	82,0%	85,5%	70,1%
9	1	1	1	1	-1	-1	1	1	-1	79,5%	81,0%	64,4%
11	1	1	1	1	-1	1	1	1	1	81,0%	81,0%	65,6%
13	1	1	1	1	1	-1	1	1	-1	79,5%	83,5%	66,4%
15	1	1	1	1	1	1	1	1	1	82,0%	85,5%	70,1%
17	1	1	-1	-1	-1	-1	-1	1	-1	82,0%	82,0%	67,2%
19	1	1	-1	-1	-1	1	-1	1	1	81,0%	86,0%	69,7%
21	1	1	-1	-1	1	-1	-1	1	-1	82,0%	83,0%	68,1%
23	1	1	-1	-1	1	1	-1	1	1	82,0%	86,0%	70,5%
25	1	1	-1	1	-1	-1	-1	-1	1	81,0%	85,0%	68,9%
27	1	1	-1	1	-1	1	-1	-1	-1	79,5%	85,0%	67,6%
29	1	1	-1	1	1	-1	-1	1	1	83,0%	86,0%	71,4%
31	1	1	-1	1	1	1	-1	-1	-1	77,5%	86,5%	67,0%
33	1	-1	1	-1	-1	-1	-1	-1	1	78,0%	86,0%	67,1%
35	1	-1	1	-1	-1	1	-1	-1	-1	81,0%	85,0%	68,9%
37	1	-1	1	-1	1	-1	-1	1	1	81,5%	84,0%	68,5%
39	1	-1	1	-1	1	1	-1	-1	-1	79,0%	86,5%	68,3%
41	1	-1	1	1	-1	-1	-1	1	-1	81,0%	81,5%	66,0%
43	1	-1	1	1	-1	1	-1	1	1	81,0%	84,5%	68,4%
45	1	-1	1	1	1	-1	-1	1	-1	77,5%	84,0%	65,1%
47	1	-1	1	1	1	1	-1	1	1	81,0%	84,5%	68,4%
49	1	-1	-1	-1	-1	-1	1	1	-1	77,5%	80,0%	62,0%
51	1	-1	-1	-1	-1	1	1	1	1	82,5%	81,5%	67,2%
53	1	-1	-1	-1	-1	1	-1	1	-1	81,5%	79,0%	64,4%
55	1	-1	-1	-1	1	1	1	1	1	81,5%	79,0%	64,4%
57	1	-1	-1	1	-1	-1	1	-1	1	83,5%	78,5%	65,5%
59	1	-1	-1	1	-1	1	1	-1	-1	81,5%	80,0%	65,2%
61	1	-1	-1	1	1	-1	1	-1	1	78,5%	80,5%	63,2%
63	1	-1	-1	1	1	1	1	-1	-1	79,0%	84,0%	66,4%
	67,3%	2,1%	0,9%	-0,8%	0,2%	1,4%	-1,9%	-1,0%	1,2%			

Resultados do Planejamento de Experimentos Fatorial para 4x4x4x2

Anexo H – Resultados das Simulações Numéricas para os Modelos de Aciaria

Simulações	Média	α	η	b1	bo	w	$\alpha.\eta$	$\eta.b1$	$\eta.b1.bo$	C	f	acertSim
1	1	1	1	-1	-1	-1	1	-1	1	82,5%	87,0%	71,8%
3	1	1	1	-1	-1	1	1	-1	1	81,5%	87,0%	70,9%
5	1	1	1	-1	1	-1	1	-1	-1	80,0%	86,0%	68,8%
7	1	1	1	-1	1	1	1	-1	-1	83,5%	87,0%	72,6%
9	1	1	1	1	-1	-1	1	1	-1	81,5%	80,0%	65,2%
11	1	1	1	1	-1	1	1	1	-1	83,0%	78,5%	65,2%
13	1	1	1	1	1	-1	1	1	1	81,5%	83,5%	68,1%
15	1	1	1	1	1	1	1	1	1	80,5%	83,0%	68,8%
17	1	1	-1	-1	-1	-1	-1	1	1	78,0%	86,0%	67,1%
19	1	1	-1	-1	-1	1	-1	1	-1	83,0%	79,5%	66,0%
21	1	1	-1	-1	1	-1	-1	1	1	81,5%	81,5%	66,4%
23	1	1	-1	-1	1	1	-1	1	1	80,0%	85,5%	68,4%
25	1	1	-1	1	-1	-1	-1	-1	1	82,0%	84,5%	69,3%
27	1	1	-1	1	-1	1	-1	-1	1	81,0%	86,5%	70,1%
29	1	1	-1	1	1	-1	-1	-1	-1	83,5%	78,5%	65,5%
31	1	1	-1	1	1	1	-1	-1	-1	82,0%	87,0%	71,3%
33	1	-1	1	-1	-1	-1	-1	-1	1	79,0%	86,0%	67,9%
35	1	-1	1	-1	-1	1	-1	-1	1	81,0%	86,5%	70,1%
37	1	-1	1	-1	1	-1	-1	-1	-1	80,0%	79,5%	63,6%
39	1	-1	1	-1	1	1	-1	-1	-1	79,5%	81,5%	64,8%
41	1	-1	1	1	-1	-1	-1	1	-1	80,5%	81,0%	65,2%
43	1	-1	1	1	-1	1	-1	1	-1	80,0%	84,0%	67,2%
45	1	-1	1	1	1	-1	-1	1	1	80,0%	83,5%	66,8%
47	1	-1	1	1	1	1	-1	1	1	78,0%	83,0%	64,7%
49	1	-1	-1	-1	-1	-1	1	1	-1	79,0%	77,0%	60,8%
51	1	-1	-1	-1	-1	1	1	1	-1	78,0%	81,0%	63,2%
53	1	-1	-1	-1	1	-1	1	1	1	77,5%	81,0%	62,8%
55	1	-1	-1	-1	1	1	1	1	1	81,5%	76,0%	61,9%
57	1	-1	-1	1	-1	-1	1	-1	1	78,0%	85,0%	66,3%
59	1	-1	-1	1	-1	1	1	-1	1	79,0%	81,5%	64,4%
61	1	-1	-1	1	1	-1	1	-1	-1	78,5%	79,0%	62,0%
63	1	-1	-1	1	1	1	1	-1	-1	82,5%	77,5%	63,9%
	66,5%	3,6%	1,9%	-0,3%	-0,7%	0,9%	-1,2%	-2,4%	1,5%			

Resultados do Planejamento de Experimentos Fatorial para 4x6x3x2

Anexo H – Resultados das Simulações Numéricas para os Modelos de Aciaria

Simulações	Media	α	η	b1	bo	w	fa	$\alpha.\eta$	b1.bo	$\eta.b1.bo$	C	f	acertsim
1	1	1	1	-1	-1	-1	1	1	1	1	79,0%	63,0%	49,8%
2	1	1	1	-1	-1	-1	-1	1	1	1	60,0%	62,0%	37,2%
3	1	1	1	-1	-1	1	1	1	1	1	77,0%	64,0%	49,3%
4	1	1	1	-1	-1	1	-1	1	1	1	60,0%	50,0%	30,0%
5	1	1	1	-1	1	-1	1	1	-1	-1	76,0%	61,0%	46,4%
6	1	1	1	-1	1	-1	-1	1	-1	-1	60,0%	65,0%	39,0%
7	1	1	1	-1	1	1	1	1	-1	-1	80,0%	58,0%	46,4%
8	1	1	1	-1	1	1	-1	1	-1	-1	60,0%	62,0%	37,2%
9	1	1	1	1	-1	-1	1	1	-1	-1	78,0%	63,0%	49,1%
10	1	1	1	1	-1	-1	-1	1	-1	-1	60,0%	61,0%	36,6%
11	1	1	1	1	-1	1	1	1	-1	-1	81,0%	62,0%	50,2%
12	1	1	1	1	-1	1	-1	1	-1	-1	60,0%	62,0%	37,2%
13	1	1	1	1	1	-1	1	1	1	1	80,0%	60,0%	48,0%
14	1	1	1	1	1	-1	-1	1	1	1	60,0%	50,0%	30,0%
15	1	1	1	1	1	1	1	1	1	1	81,0%	60,0%	48,6%
16	1	1	1	1	1	1	-1	1	1	1	60,0%	50,0%	30,0%
17	1	1	-1	-1	-1	-1	1	-1	1	-1	77,0%	63,0%	48,5%
18	1	1	-1	-1	-1	-1	-1	-1	1	-1	60,0%	62,0%	37,2%
19	1	1	-1	-1	-1	1	1	-1	1	-1	77,0%	63,0%	48,5%
20	1	1	-1	-1	-1	1	-1	-1	1	-1	60,0%	60,0%	36,0%
21	1	1	-1	-1	1	-1	1	-1	-1	1	77,0%	63,0%	48,5%
22	1	1	-1	-1	1	-1	-1	-1	-1	1	60,0%	64,0%	38,4%
23	1	1	-1	-1	1	1	1	-1	-1	1	76,0%	65,0%	49,4%
24	1	1	-1	-1	1	1	-1	-1	-1	1	60,0%	62,0%	37,2%
25	1	1	-1	1	-1	-1	1	-1	-1	1	82,0%	61,0%	50,0%
26	1	1	-1	1	-1	-1	-1	-1	-1	1	60,0%	61,0%	36,6%
27	1	1	-1	1	-1	1	1	-1	-1	1	80,0%	63,0%	50,4%
28	1	1	-1	1	-1	1	-1	-1	-1	1	60,0%	60,0%	36,0%
29	1	1	-1	1	1	-1	1	-1	1	-1	76,0%	63,0%	47,9%
30	1	1	-1	1	1	-1	-1	-1	1	-1	60,0%	64,0%	38,4%
31	1	1	-1	1	1	1	1	-1	1	-1	81,0%	59,0%	47,8%
32	1	1	-1	1	1	1	-1	-1	1	-1	60,0%	63,0%	37,8%
33	1	-1	1	-1	-1	-1	1	-1	1	1	76,0%	64,0%	48,6%
34	1	-1	1	-1	-1	-1	-1	-1	1	1	60,0%	61,0%	36,6%
35	1	-1	1	-1	-1	1	1	-1	1	1	79,0%	60,0%	47,4%
36	1	-1	1	-1	-1	1	-1	-1	1	1	60,0%	62,0%	37,2%
37	1	-1	1	-1	1	-1	1	-1	-1	-1	78,0%	66,0%	51,5%
38	1	-1	1	-1	1	-1	-1	-1	-1	-1	60,0%	64,0%	38,4%
39	1	-1	1	-1	1	1	1	-1	-1	-1	76,0%	62,0%	47,1%
40	1	-1	1	-1	1	1	-1	-1	-1	-1	60,0%	63,0%	37,8%
41	1	-1	1	1	-1	-1	1	-1	-1	-1	83,0%	58,0%	48,1%
42	1	-1	1	1	-1	-1	-1	-1	-1	-1	60,0%	63,0%	37,8%
43	1	-1	1	1	-1	1	1	-1	-1	-1	80,0%	60,0%	48,0%
44	1	-1	1	1	-1	1	-1	-1	-1	-1	60,0%	60,0%	36,0%
45	1	-1	1	1	1	-1	1	-1	1	1	76,0%	64,0%	48,6%
46	1	-1	1	1	1	-1	-1	-1	1	1	60,0%	63,0%	37,8%
47	1	-1	1	1	1	1	1	-1	1	1	77,0%	62,0%	47,7%
48	1	-1	1	1	1	1	-1	-1	1	1	60,0%	60,0%	36,0%
49	1	-1	-1	-1	-1	-1	1	1	1	-1	74,0%	63,0%	46,6%
50	1	-1	-1	-1	-1	-1	-1	1	1	-1	60,0%	61,0%	36,6%
51	1	-1	-1	-1	-1	1	1	1	1	-1	78,0%	66,0%	51,5%
52	1	-1	-1	-1	-1	1	-1	1	1	-1	60,0%	61,0%	36,6%
53	1	-1	-1	-1	1	-1	1	-1	1	1	78,0%	63,0%	49,1%
54	1	-1	-1	-1	1	-1	-1	1	-1	1	60,0%	62,0%	37,2%
55	1	-1	-1	-1	1	1	1	1	-1	1	79,0%	60,0%	47,4%
56	1	-1	-1	-1	1	1	-1	1	-1	1	60,0%	62,0%	37,2%
57	1	-1	-1	1	-1	-1	1	1	-1	1	80,0%	60,0%	48,0%
58	1	-1	-1	1	-1	-1	-1	1	-1	1	60,0%	59,0%	35,4%
59	1	-1	-1	1	-1	1	1	1	-1	1	79,0%	59,0%	46,6%
60	1	-1	-1	1	-1	1	-1	1	-1	1	60,0%	59,0%	35,4%
61	1	-1	-1	1	1	-1	1	1	1	-1	76,0%	62,0%	47,1%
62	1	-1	-1	1	1	-1	-1	1	1	-1	60,0%	62,0%	37,2%
63	1	-1	-1	1	1	1	1	1	1	-1	75,0%	64,0%	48,0%
64	1	-1	-1	1	1	1	-1	1	1	-1	60,0%	63,0%	37,8%
	42,4%	-0,3%	-0,5%	-0,5%	-0,1%	-0,5%	12,0%	-1,0%	-0,7%	-0,8%			

Resultados do Planejamento de Experimentos Fatorial para 20x41x2

Anexo H – Resultados das Simulações Numéricas para os Modelos de Aciaria

Simulações	Média	α	η	b1	bo	w	$\alpha.b1$	$\alpha.bo$	$\eta.w$	C	ρ	acertism
1	1	1	1	-1	-1	-1	-1	-1	-1	81,0%	62,0%	50,2%
3	1	1	1	-1	-1	1	-1	-1	1	80,0%	61,0%	48,8%
5	1	1	1	-1	1	-1	-1	1	-1	73,0%	60,0%	43,8%
7	1	1	1	-1	1	1	-1	1	1	83,0%	61,0%	50,6%
9	1	1	1	1	-1	-1	1	-1	-1	81,0%	62,0%	50,2%
11	1	1	1	1	-1	1	1	-1	1	80,0%	60,0%	48,0%
13	1	1	1	1	1	-1	1	1	-1	75,0%	61,0%	45,8%
15	1	1	1	1	1	1	1	1	1	82,0%	61,0%	50,0%
17	1	1	1	-1	-1	1	-1	-1	1	77,0%	61,0%	47,0%
19	1	1	-1	-1	-1	-1	-1	-1	-1	79,0%	64,0%	50,6%
21	1	1	-1	-1	1	-1	-1	1	1	76,0%	63,0%	47,9%
23	1	1	-1	-1	1	1	-1	1	-1	78,0%	57,0%	44,5%
25	1	1	-1	1	-1	-1	1	-1	1	82,0%	61,0%	50,0%
27	1	1	-1	1	-1	1	1	-1	-1	81,0%	62,0%	50,2%
29	1	1	-1	1	1	-1	1	1	1	77,0%	63,0%	48,5%
31	1	1	-1	1	1	1	1	1	-1	80,0%	61,0%	48,8%
33	1	-1	1	-1	-1	-1	1	1	-1	78,0%	62,0%	48,4%
35	1	-1	1	-1	-1	1	1	1	1	77,0%	63,0%	48,5%
37	1	-1	1	-1	1	1	1	-1	-1	72,0%	65,0%	46,8%
39	1	-1	1	-1	1	1	1	-1	1	77,0%	63,0%	48,5%
41	1	-1	1	1	-1	-1	-1	1	-1	83,0%	58,0%	48,1%
43	1	-1	1	1	-1	1	-1	1	1	82,0%	59,0%	48,4%
45	1	-1	1	1	1	1	-1	-1	-1	75,0%	61,0%	45,8%
47	1	-1	1	1	1	1	-1	-1	1	79,0%	64,0%	50,6%
49	1	-1	-1	-1	-1	-1	1	1	1	76,0%	61,0%	46,4%
51	1	-1	-1	-1	-1	1	1	1	-1	75,0%	68,0%	51,0%
53	1	-1	-1	-1	1	-1	1	-1	1	76,0%	63,0%	47,9%
55	1	-1	-1	-1	1	1	1	-1	-1	77,0%	60,0%	46,2%
57	1	-1	-1	1	-1	-1	-1	1	1	79,0%	60,0%	47,4%
59	1	-1	-1	1	-1	1	-1	1	-1	75,0%	63,0%	47,3%
61	1	-1	-1	1	1	-1	-1	-1	1	78,0%	61,0%	47,6%
63	1	-1	-1	1	1	1	-1	-1	-1	75,0%	63,0%	47,3%
	48,1%	0,6%	0,3%	0,4%	-1,3%	1,1%	0,6%	-0,6%	0,7%			

Resultados do Planejamento de Experimentos Fatorial para 20x40x2

Simulações	Média	α	η	b1	bo	w	$\eta.w$	b1.w	$\eta.\alpha.bo$	C	ρ	acertism
1	1	1	1	-1	-1	-1	-1	1	-1	77,0%	64,0%	49,3%
3	1	1	1	-1	-1	1	1	-1	-1	77,0%	66,0%	50,8%
5	1	1	1	-1	1	-1	-1	1	1	78,0%	61,0%	47,6%
7	1	1	1	-1	1	1	1	-1	-1	82,0%	63,0%	51,7%
9	1	1	1	1	-1	-1	-1	-1	-1	78,0%	60,0%	46,8%
11	1	1	1	1	-1	1	1	1	-1	80,0%	62,0%	49,6%
13	1	1	1	1	1	-1	-1	-1	1	77,0%	63,0%	48,5%
15	1	1	1	1	1	1	1	1	1	80,0%	65,0%	52,0%
17	1	1	-1	-1	-1	-1	1	1	1	78,0%	62,0%	48,4%
19	1	1	-1	-1	-1	1	-1	-1	1	77,0%	64,0%	49,3%
21	1	1	-1	-1	1	-1	1	1	-1	79,0%	65,0%	51,4%
23	1	1	-1	-1	1	1	-1	-1	-1	73,0%	62,0%	45,3%
25	1	1	-1	1	-1	-1	1	-1	1	78,0%	64,0%	49,9%
27	1	1	-1	1	-1	1	-1	1	1	79,0%	65,0%	51,4%
29	1	1	-1	1	1	-1	1	-1	-1	75,0%	62,0%	46,5%
31	1	1	-1	1	1	1	-1	1	-1	79,0%	62,0%	49,0%
33	1	-1	1	-1	-1	-1	-1	1	1	76,0%	65,0%	49,4%
35	1	-1	1	-1	-1	1	1	-1	1	72,0%	66,0%	47,5%
37	1	-1	1	-1	1	-1	-1	1	-1	77,0%	61,0%	47,0%
39	1	-1	1	-1	1	1	1	-1	-1	82,0%	61,0%	50,0%
41	1	-1	1	1	-1	-1	-1	-1	1	76,0%	66,0%	50,2%
43	1	-1	1	1	-1	1	1	1	1	76,0%	65,0%	49,4%
45	1	-1	1	1	1	-1	-1	-1	-1	77,0%	59,0%	45,4%
47	1	-1	1	1	1	1	1	1	-1	80,0%	62,0%	49,6%
49	1	-1	-1	-1	-1	-1	1	1	-1	79,0%	61,0%	48,2%
51	1	-1	-1	-1	-1	1	-1	-1	-1	75,0%	64,0%	48,0%
53	1	-1	-1	-1	1	-1	1	1	1	80,0%	62,0%	49,6%
55	1	-1	-1	-1	1	1	-1	-1	1	78,0%	60,0%	46,8%
57	1	-1	-1	1	-1	-1	1	-1	-1	78,0%	61,0%	47,6%
59	1	-1	-1	1	-1	1	-1	1	-1	77,0%	62,0%	47,7%
61	1	-1	-1	1	1	-1	1	-1	1	79,0%	60,0%	47,4%
63	1	-1	-1	1	1	1	-1	1	1	73,0%	66,0%	48,2%
	48,7%	1,0%	0,6%	-0,1%	-0,5%	0,8%	1,2%	1,0%	0,9%			

Resultados do Planejamento de Experimentos Fatorial para 20x20x20x2

ANEXO I – RESULTADOS DAS SIMULAÇÕES NUMÉRICAS PARA OS ANALISADORES VIRTUAIS DE SÍNTER

Simulações	Media	α	η	b1	bo	w	fa	$\alpha.\eta$	$\alpha.fa$	$\eta.fa$	b1.fa	RDI	Rf	acertism
1	1	1	1	-1	-1	-1	1	1	1	1	-1	80,0%	70,0%	56,0%
2	1	1	1	-1	-1	-1	-1	1	-1	-1	1	70,0%	65,0%	45,5%
3	1	1	1	-1	-1	1	1	1	1	1	-1	75,0%	75,0%	56,3%
4	1	1	1	-1	-1	1	-1	1	-1	-1	1	70,0%	65,0%	45,5%
5	1	1	1	-1	1	-1	1	1	1	1	-1	80,0%	65,0%	52,0%
6	1	1	1	-1	1	-1	-1	1	-1	-1	1	70,0%	60,0%	42,0%
7	1	1	1	-1	1	1	1	1	1	1	-1	80,0%	65,0%	52,0%
8	1	1	1	-1	1	1	-1	1	-1	-1	1	70,0%	60,0%	42,0%
9	1	1	1	-1	-1	-1	1	1	1	1	1	75,0%	75,0%	56,3%
10	1	1	1	-1	-1	-1	-1	1	-1	-1	-1	70,0%	60,0%	42,0%
11	1	1	1	-1	-1	1	1	1	1	1	1	80,0%	75,0%	60,0%
12	1	1	1	-1	-1	1	-1	1	-1	-1	-1	65,0%	60,0%	39,0%
13	1	1	1	-1	-1	-1	1	1	1	1	1	75,0%	75,0%	56,3%
14	1	1	1	-1	-1	1	-1	1	-1	-1	-1	65,0%	60,0%	39,0%
15	1	1	1	-1	-1	1	1	1	1	1	1	80,0%	75,0%	60,0%
16	1	1	1	-1	-1	1	-1	1	-1	-1	-1	70,0%	60,0%	42,0%
17	1	1	-1	-1	-1	-1	1	-1	1	-1	-1	80,0%	70,0%	56,0%
18	1	1	-1	-1	-1	-1	-1	-1	-1	-1	1	70,0%	65,0%	45,5%
19	1	1	-1	-1	-1	1	1	-1	1	-1	-1	75,0%	75,0%	56,3%
20	1	1	-1	-1	-1	1	-1	-1	-1	1	1	70,0%	65,0%	45,5%
21	1	1	-1	-1	1	-1	1	-1	1	-1	-1	80,0%	70,0%	56,0%
22	1	1	-1	-1	1	-1	-1	-1	-1	1	1	70,0%	65,0%	45,5%
23	1	1	-1	-1	1	1	1	-1	1	-1	-1	75,0%	70,0%	52,5%
24	1	1	-1	-1	1	1	-1	-1	-1	1	1	70,0%	65,0%	45,5%
25	1	1	-1	-1	-1	-1	1	-1	1	-1	-1	75,0%	75,0%	56,3%
26	1	1	-1	-1	-1	-1	-1	-1	-1	1	-1	70,0%	65,0%	45,5%
27	1	1	-1	-1	-1	1	1	-1	1	-1	1	75,0%	75,0%	56,3%
28	1	1	-1	-1	-1	1	-1	-1	-1	1	-1	70,0%	65,0%	45,5%
29	1	1	-1	-1	1	-1	1	-1	1	-1	1	80,0%	70,0%	56,0%
30	1	1	-1	-1	1	-1	-1	-1	-1	1	-1	70,0%	65,0%	45,5%
31	1	1	-1	-1	1	1	1	-1	1	-1	1	75,0%	75,0%	56,3%
32	1	1	-1	-1	1	1	-1	-1	-1	1	-1	70,0%	65,0%	45,5%
33	1	-1	1	-1	-1	-1	1	-1	-1	1	-1	75,0%	65,0%	48,8%
34	1	-1	1	-1	-1	-1	-1	-1	1	-1	1	70,0%	65,0%	45,5%
35	1	-1	1	-1	-1	1	1	-1	-1	1	-1	80,0%	70,0%	56,0%
36	1	-1	1	-1	-1	1	-1	-1	1	-1	1	70,0%	65,0%	45,5%
37	1	-1	1	-1	-1	-1	1	-1	-1	1	-1	80,0%	60,0%	48,0%
38	1	-1	1	-1	-1	-1	-1	-1	1	-1	1	70,0%	65,0%	45,5%
39	1	-1	1	-1	-1	1	1	-1	-1	1	-1	80,0%	60,0%	48,0%
40	1	-1	1	-1	-1	1	-1	-1	1	-1	1	70,0%	65,0%	45,5%
41	1	-1	1	-1	-1	-1	1	-1	-1	1	1	75,0%	70,0%	52,5%
42	1	-1	1	-1	-1	-1	-1	-1	1	-1	-1	70,0%	65,0%	45,5%
43	1	-1	1	-1	-1	1	1	-1	-1	1	1	70,0%	65,0%	45,5%
44	1	-1	1	-1	-1	1	-1	-1	1	-1	-1	70,0%	65,0%	45,5%
45	1	-1	1	-1	-1	1	1	-1	-1	1	1	75,0%	70,0%	52,5%
46	1	-1	1	-1	-1	-1	-1	-1	1	-1	-1	70,0%	65,0%	45,5%
47	1	-1	1	-1	-1	1	1	-1	-1	1	1	75,0%	65,0%	48,8%
48	1	-1	1	-1	-1	1	-1	-1	1	-1	-1	70,0%	65,0%	45,5%
49	1	-1	-1	-1	-1	-1	1	-1	-1	-1	-1	65,0%	60,0%	39,0%
50	1	-1	-1	-1	-1	-1	-1	1	1	1	1	70,0%	65,0%	45,5%
51	1	-1	-1	-1	-1	1	1	1	-1	-1	-1	70,0%	65,0%	45,5%
52	1	-1	-1	-1	-1	1	-1	1	1	1	1	70,0%	65,0%	45,5%
53	1	-1	-1	-1	1	-1	1	1	-1	-1	-1	65,0%	60,0%	39,0%
54	1	-1	-1	-1	1	-1	-1	1	1	1	1	70,0%	65,0%	45,5%
55	1	-1	-1	-1	-1	1	1	1	-1	-1	-1	65,0%	60,0%	39,0%
56	1	-1	-1	-1	1	1	-1	1	1	1	1	70,0%	65,0%	45,5%
57	1	-1	-1	-1	-1	-1	1	1	-1	-1	1	75,0%	60,0%	45,0%
58	1	-1	-1	-1	-1	-1	-1	1	1	1	-1	70,0%	65,0%	45,5%
59	1	-1	-1	-1	-1	1	1	1	-1	-1	1	80,0%	65,0%	52,0%
60	1	-1	-1	-1	-1	1	-1	1	1	1	-1	70,0%	65,0%	45,5%
61	1	-1	-1	-1	1	-1	1	1	-1	-1	1	70,0%	60,0%	42,0%
62	1	-1	-1	-1	1	-1	-1	1	1	1	-1	70,0%	65,0%	45,5%
63	1	-1	-1	-1	1	1	1	1	-1	-1	1	80,0%	60,0%	48,0%
64	1	-1	-1	-1	1	1	-1	1	1	1	-1	70,0%	65,0%	45,5%
	48,0%	3,7%	0,8%	0,9%	-1,2%	0,6%	6,7%	-2,3%	5,4%	2,5%	1,8%			

Resultados do
Planejamento de
Experimentos
Fatorial para 4x9x2

Anexo I – Resultados das Simulações Numéricas para os Analisadores Virtuais de Sinter

Simulações	Media	α	η	b1	bo	w	α,η	η,bo	$\eta,\alpha,b1$	RDI	RI	acertism
1	1	1	1	-1	-1	-1	1	-1	-1	75,0%	70,0%	52,5%
3	1	1	1	-1	-1	1	1	-1	-1	75,0%	70,0%	52,5%
5	1	1	1	-1	1	-1	1	1	-1	80,0%	60,0%	48,0%
7	1	1	1	-1	1	1	1	1	-1	75,0%	65,0%	48,8%
9	1	1	1	-1	-1	-1	1	-1	1	75,0%	75,0%	56,3%
11	1	1	1	1	-1	1	1	-1	1	75,0%	75,0%	56,3%
13	1	1	1	1	1	-1	1	1	1	75,0%	75,0%	56,3%
15	1	1	1	1	1	1	1	1	1	75,0%	75,0%	56,3%
17	1	1	-1	-1	-1	-1	-1	1	1	80,0%	65,0%	52,0%
19	1	1	-1	-1	-1	1	-1	-1	1	80,0%	65,0%	52,0%
21	1	1	-1	-1	1	-1	-1	-1	1	80,0%	70,0%	56,0%
23	1	1	-1	-1	1	1	-1	-1	1	80,0%	70,0%	56,0%
25	1	1	-1	1	-1	-1	-1	1	-1	75,0%	75,0%	56,3%
27	1	1	-1	1	-1	1	-1	1	-1	75,0%	75,0%	56,3%
29	1	1	-1	1	1	-1	-1	-1	-1	80,0%	70,0%	56,0%
31	1	1	-1	1	1	1	-1	-1	-1	75,0%	70,0%	52,5%
33	1	-1	1	-1	-1	-1	-1	-1	1	80,0%	60,0%	48,0%
35	1	-1	1	-1	-1	1	-1	-1	1	80,0%	60,0%	48,0%
37	1	-1	1	-1	1	-1	-1	1	1	80,0%	60,0%	48,0%
39	1	-1	1	-1	1	1	-1	1	1	80,0%	60,0%	48,0%
41	1	-1	1	1	-1	-1	-1	-1	-1	75,0%	70,0%	52,5%
43	1	-1	1	1	-1	1	-1	-1	-1	75,0%	70,0%	52,5%
45	1	-1	1	1	1	-1	-1	1	-1	75,0%	70,0%	52,5%
47	1	-1	1	1	1	1	-1	1	-1	75,0%	70,0%	52,5%
49	1	-1	-1	-1	-1	-1	1	1	-1	65,0%	60,0%	39,0%
51	1	-1	-1	-1	-1	1	1	1	-1	65,0%	60,0%	39,0%
53	1	-1	-1	-1	1	-1	1	-1	-1	70,0%	60,0%	42,0%
55	1	-1	-1	-1	1	1	1	-1	-1	65,0%	60,0%	39,0%
57	1	-1	-1	1	-1	-1	1	1	1	75,0%	60,0%	45,0%
59	1	-1	-1	1	-1	1	1	1	1	75,0%	60,0%	45,0%
61	1	-1	-1	1	1	-1	1	-1	1	75,0%	60,0%	45,0%
63	1	-1	-1	1	1	1	1	-1	1	75,0%	65,0%	48,8%
	50,3%	7,4%	3,1%	4,4%	0,2%	-0,1%	-4,3%	-1,2%	1,6%			

Resultados do Planejamento de Experimentos Fatorial para 4x8x2

Simulações	Media	α	η	b1	bo	w	α,η	$\alpha,b1$	$\eta,b1$	$\eta,\alpha,b1$	RDI	RI	acertism
1	1	1	1	-1	-1	-1	1	-1	-1	-1	80,0%	65,0%	52,0%
3	1	1	1	-1	-1	1	1	-1	-1	-1	80,0%	65,0%	52,0%
5	1	1	1	-1	1	-1	1	-1	-1	-1	70,0%	65,0%	45,5%
7	1	1	1	-1	1	1	1	-1	-1	-1	70,0%	65,0%	45,5%
9	1	1	1	1	-1	-1	1	1	1	1	70,0%	65,0%	45,5%
11	1	1	1	1	-1	1	1	1	1	1	70,0%	65,0%	45,5%
13	1	1	1	1	1	-1	1	1	1	1	80,0%	60,0%	48,0%
15	1	1	1	1	1	1	1	1	1	1	70,0%	70,0%	49,0%
17	1	1	-1	-1	-1	-1	-1	-1	1	1	60,0%	60,0%	36,0%
19	1	1	-1	-1	-1	1	-1	-1	1	1	60,0%	60,0%	36,0%
21	1	1	-1	-1	1	-1	-1	-1	1	1	60,0%	60,0%	36,0%
23	1	1	-1	-1	1	1	-1	-1	1	1	65,0%	60,0%	39,0%
25	1	1	-1	1	-1	-1	-1	1	-1	-1	80,0%	65,0%	52,0%
27	1	1	-1	1	-1	1	-1	1	-1	-1	80,0%	65,0%	52,0%
29	1	1	-1	1	1	-1	-1	1	-1	-1	80,0%	65,0%	52,0%
31	1	1	-1	1	1	1	-1	1	-1	-1	80,0%	65,0%	52,0%
33	1	-1	1	-1	-1	-1	-1	1	-1	1	70,0%	60,0%	42,0%
35	1	-1	1	-1	-1	1	-1	1	-1	1	75,0%	60,0%	45,0%
37	1	-1	1	-1	1	-1	-1	1	-1	1	65,0%	65,0%	42,3%
39	1	-1	1	-1	1	1	-1	1	-1	1	70,0%	60,0%	42,0%
41	1	-1	1	1	-1	-1	-1	-1	1	-1	80,0%	60,0%	48,0%
43	1	-1	1	1	-1	1	-1	-1	1	-1	80,0%	70,0%	56,0%
45	1	-1	1	1	1	-1	-1	-1	1	-1	80,0%	60,0%	48,0%
47	1	-1	1	1	1	1	-1	-1	1	-1	80,0%	60,0%	48,0%
49	1	-1	-1	-1	-1	-1	1	1	-1	-1	80,0%	60,0%	36,0%
51	1	-1	-1	-1	-1	1	1	1	-1	-1	70,0%	60,0%	42,0%
53	1	-1	-1	-1	1	-1	1	1	1	-1	80,0%	60,0%	36,0%
55	1	-1	-1	-1	1	1	1	1	-1	-1	65,0%	60,0%	39,0%
57	1	-1	-1	1	-1	-1	1	-1	-1	1	60,0%	60,0%	36,0%
59	1	-1	-1	1	-1	1	1	-1	-1	1	65,0%	60,0%	39,0%
61	1	-1	-1	1	1	-1	1	-1	-1	1	60,0%	60,0%	36,0%
63	1	-1	-1	1	1	1	1	-1	-1	1	60,0%	60,0%	36,0%
	44,0%	4,2%	6,2%	4,8%	-1,3%	1,7%	-2,7%	2,0%	-2,1%	-6,4%			

Resultados do Planejamento de Experimentos Fatorial para 4x6x3x2

Anexo I – Resultados das Simulações Numéricas para os Analisadores Virtuais de Sinter

Simulações	Média	α	η	b1	bo	w	fa	$\alpha.\eta$	$\eta.f_a$	$\eta.\alpha.b1$	RDI	Ri	acersim
1	1	1	1	-1	-1	-1	1	1	1	-1	80,0%	80,0%	64,0%
2	1	1	1	-1	-1	-1	-1	1	-1	-1	70,0%	60,0%	42,0%
3	1	1	1	-1	-1	1	1	1	1	-1	80,0%	75,0%	60,0%
4	1	1	1	-1	-1	1	-1	1	-1	-1	70,0%	60,0%	42,0%
5	1	1	1	-1	1	-1	1	1	1	-1	80,0%	70,0%	56,0%
6	1	1	1	-1	1	-1	-1	1	-1	-1	80,0%	55,0%	44,0%
7	1	1	1	-1	1	1	1	1	1	-1	80,0%	75,0%	60,0%
8	1	1	1	-1	1	1	-1	1	-1	-1	70,0%	60,0%	42,0%
9	1	1	1	1	-1	-1	1	1	1	1	80,0%	80,0%	64,0%
10	1	1	1	1	-1	-1	-1	1	-1	1	80,0%	50,0%	40,0%
11	1	1	1	1	-1	1	1	1	1	1	80,0%	75,0%	60,0%
12	1	1	1	1	-1	1	-1	1	-1	1	80,0%	55,0%	44,0%
13	1	1	1	1	1	-1	1	1	1	1	80,0%	75,0%	60,0%
14	1	1	1	1	1	-1	-1	1	-1	1	80,0%	60,0%	48,0%
15	1	1	1	1	1	1	1	1	1	1	80,0%	80,0%	64,0%
16	1	1	1	1	1	1	-1	1	-1	1	65,0%	60,0%	39,0%
17	1	1	-1	-1	-1	-1	1	-1	-1	1	80,0%	80,0%	64,0%
18	1	1	-1	-1	-1	-1	-1	-1	1	1	70,0%	65,0%	45,5%
19	1	1	-1	-1	-1	1	1	-1	-1	1	80,0%	75,0%	60,0%
20	1	1	-1	-1	-1	1	-1	-1	1	1	80,0%	55,0%	44,0%
21	1	1	-1	-1	1	-1	1	-1	-1	1	80,0%	80,0%	64,0%
22	1	1	-1	-1	1	-1	-1	-1	1	1	70,0%	65,0%	45,5%
23	1	1	-1	-1	1	1	1	-1	-1	1	80,0%	70,0%	56,0%
24	1	1	-1	-1	1	1	-1	-1	1	1	70,0%	65,0%	45,5%
25	1	1	-1	1	-1	-1	1	-1	-1	-1	80,0%	75,0%	60,0%
26	1	1	-1	1	-1	-1	-1	-1	1	-1	70,0%	65,0%	45,5%
27	1	1	-1	1	-1	1	1	-1	-1	-1	80,0%	75,0%	60,0%
28	1	1	-1	1	-1	1	-1	-1	1	-1	70,0%	65,0%	45,5%
29	1	1	-1	1	1	-1	1	-1	-1	-1	80,0%	75,0%	60,0%
30	1	1	-1	1	1	-1	-1	-1	1	-1	70,0%	65,0%	45,5%
31	1	1	-1	1	1	1	1	-1	-1	-1	80,0%	75,0%	60,0%
32	1	1	-1	1	1	1	-1	-1	1	-1	70,0%	65,0%	45,5%
33	1	-1	1	-1	-1	-1	1	-1	1	1	80,0%	80,0%	64,0%
34	1	-1	1	-1	-1	-1	-1	-1	-1	1	70,0%	65,0%	45,5%
35	1	-1	1	-1	-1	1	1	-1	1	1	80,0%	75,0%	60,0%
36	1	-1	1	-1	-1	1	-1	-1	-1	1	70,0%	65,0%	45,5%
37	1	-1	1	-1	1	-1	1	-1	1	1	80,0%	80,0%	64,0%
38	1	-1	1	-1	1	-1	-1	-1	-1	1	80,0%	55,0%	44,0%
39	1	-1	1	-1	1	1	1	-1	1	1	80,0%	75,0%	60,0%
40	1	-1	1	-1	1	1	-1	-1	-1	1	80,0%	55,0%	44,0%
41	1	-1	1	1	-1	-1	1	-1	1	-1	80,0%	75,0%	60,0%
42	1	-1	1	1	-1	-1	-1	-1	-1	-1	70,0%	65,0%	45,5%
43	1	-1	1	1	-1	1	1	-1	1	-1	80,0%	75,0%	60,0%
44	1	-1	1	1	-1	1	-1	-1	-1	-1	70,0%	60,0%	42,0%
45	1	-1	1	1	1	-1	1	-1	1	-1	80,0%	75,0%	60,0%
46	1	-1	1	1	1	-1	-1	-1	-1	-1	80,0%	60,0%	48,0%
47	1	-1	1	1	1	1	1	-1	1	-1	80,0%	75,0%	60,0%
48	1	-1	1	1	1	1	-1	-1	-1	-1	70,0%	60,0%	42,0%
49	1	-1	-1	-1	-1	-1	1	1	-1	-1	80,0%	65,0%	52,0%
50	1	-1	-1	-1	-1	-1	-1	1	1	-1	70,0%	65,0%	45,5%
51	1	-1	-1	-1	-1	1	1	1	-1	-1	75,0%	75,0%	56,3%
52	1	-1	-1	-1	-1	1	-1	1	1	-1	70,0%	60,0%	42,0%
53	1	-1	-1	-1	1	-1	1	1	-1	-1	80,0%	70,0%	56,0%
54	1	-1	-1	-1	1	-1	-1	1	1	-1	70,0%	65,0%	45,5%
55	1	-1	-1	-1	1	1	1	1	-1	-1	80,0%	65,0%	52,0%
56	1	-1	-1	-1	1	1	-1	1	1	-1	70,0%	65,0%	45,5%
57	1	-1	-1	1	-1	-1	1	1	-1	1	80,0%	75,0%	60,0%
58	1	-1	-1	1	-1	-1	-1	1	1	1	70,0%	65,0%	45,5%
59	1	-1	-1	1	-1	1	1	1	-1	1	80,0%	80,0%	64,0%
60	1	-1	-1	1	-1	1	-1	1	1	1	70,0%	65,0%	45,5%
61	1	-1	-1	1	1	-1	1	1	-1	1	80,0%	80,0%	64,0%
62	1	-1	-1	1	1	-1	-1	1	1	1	70,0%	65,0%	45,5%
63	1	-1	-1	1	1	1	1	1	-1	1	80,0%	75,0%	60,0%
64	1	-1	-1	1	1	1	-1	1	1	1	70,0%	65,0%	45,5%
	52,3%	0,2%	0,1%	1,0%	-0,1%	-1,3%	15,7%	-1,2%	1,7%	1,8%			

Resultados do Planejamento de Experimentos Fatorial para 9x19x2

Anexo I – Resultados das Simulações Numéricas para os Analisadores Virtuais de Sínter

Simulações	Média	α	η	b1	bo	w	$\alpha.\eta$	$\alpha.b1$	$\eta.bo$	b1.bo	RDI	R!	acentsim
1	1	1	1	-1	-1	-1	1	-1	-1	1	65,0%	65,0%	42,3%
3	1	1	1	-1	-1	1	1	-1	-1	1	80,0%	60,0%	48,0%
5	1	1	1	-1	1	-1	1	-1	1	-1	65,0%	65,0%	42,3%
7	1	1	1	-1	1	1	1	-1	1	-1	80,0%	65,0%	52,0%
9	1	1	1	1	-1	-1	1	-1	-1	-1	70,0%	60,0%	42,0%
11	1	1	1	1	-1	1	1	1	-1	-1	80,0%	80,0%	64,0%
13	1	1	1	1	1	-1	1	1	1	1	70,0%	70,0%	49,0%
15	1	1	1	1	1	1	1	1	1	1	80,0%	80,0%	64,0%
17	1	1	-1	-1	-1	-1	-1	-1	1	1	80,0%	60,0%	48,0%
19	1	1	-1	-1	-1	1	-1	-1	1	1	80,0%	75,0%	60,0%
21	1	1	-1	-1	1	-1	-1	-1	-1	-1	70,0%	60,0%	42,0%
23	1	1	-1	-1	1	1	-1	-1	-1	-1	80,0%	70,0%	56,0%
25	1	1	-1	1	-1	-1	-1	1	1	-1	80,0%	65,0%	52,0%
27	1	1	-1	1	-1	1	-1	1	1	-1	80,0%	80,0%	64,0%
29	1	1	-1	1	1	-1	-1	1	-1	1	80,0%	70,0%	56,0%
31	1	1	-1	1	1	1	-1	1	-1	1	80,0%	80,0%	64,0%
33	1	-1	1	-1	-1	-1	-1	1	-1	1	80,0%	60,0%	48,0%
35	1	-1	1	-1	-1	1	-1	1	-1	1	80,0%	70,0%	56,0%
37	1	-1	1	-1	1	-1	-1	1	1	-1	80,0%	60,0%	48,0%
39	1	-1	1	-1	1	1	-1	1	1	-1	75,0%	75,0%	56,3%
41	1	-1	1	1	-1	-1	-1	-1	-1	-1	80,0%	70,0%	56,0%
43	1	-1	1	1	-1	1	-1	-1	-1	-1	80,0%	65,0%	52,0%
45	1	-1	1	1	1	-1	-1	-1	1	1	80,0%	65,0%	52,0%
47	1	-1	1	1	1	1	-1	-1	1	1	80,0%	80,0%	64,0%
49	1	-1	-1	-1	-1	-1	1	1	1	1	80,0%	60,0%	48,0%
51	1	-1	-1	-1	-1	1	1	1	1	1	80,0%	65,0%	52,0%
53	1	-1	-1	-1	1	-1	1	1	-1	-1	60,0%	60,0%	36,0%
55	1	-1	-1	-1	1	1	1	1	-1	-1	80,0%	65,0%	52,0%
57	1	-1	-1	1	-1	-1	1	-1	1	-1	70,0%	60,0%	42,0%
59	1	-1	-1	1	-1	1	1	-1	1	-1	80,0%	70,0%	56,0%
61	1	-1	-1	1	1	-1	1	-1	-1	1	70,0%	60,0%	42,0%
63	1	-1	-1	1	1	1	1	-1	-1	1	80,0%	65,0%	52,0%
	51,8%	2,1%	0,9%	5,3%	-0,2%	10,4%	-5,7%	2,8%	2,6%	2,0%			

Resultados do
Planejamento de
Experimentos
Fatorial para
9x13x6x2