



**Modelagem por Redes Neurais para obtenção
de condições operacionais ótimas de produção de H₂
por Gaseificação de Biomassas**

Camilla Chaves Nunes de Oliveira

Fernanda Pires Domingues Cardoso Guedes

Paula Borges da Silveira Bezerra

**Projeto Final em Engenharia Química e Engenharia de
Bioprocessos**

Orientador:

Prof. Maurício Bezerra de Souza Jr., D.Sc.

Rio de Janeiro, abril de 2013

Modelagem por Redes Neurais para obtenção de condições operacionais ótimas de produção de H₂ por Gaseificação de Biomassas

Camilla Chaves Nunes de Oliveira

Fernanda Pires Domingues Cardoso Guedes

Paula Borges da Silveira Bezerra

Projeto Final em Engenharia Química e Engenharia de Bioprocessos submetida ao Corpo Docente da Escola de Química, como parte dos requisitos necessários à obtenção do grau de Engenheiro Químico e Engenheiro de Bioprocessos.

Aprovado por:

Álvaro José Boareto Mendes, D.Sc.

Douglas Alves Santos, M. Sc.

Vitor Loureiro Ximenes, Eng.

Orientado por:

Maurício Bezerra de Souza Jr., D.Sc.

Rio de Janeiro, RJ – Brasil

Abril de 2013

De Oliveira, Camilla Chaves Nunes.; Guedes, Fernanda Pires Domingues Cardoso.; Bezerra, Paula Borges da Silveira.

Modelagem por redes neuronais para otimização operacional de H₂ por gaseificação de biomassas/ Camilla Chaves Nunes de Oliveira; Fernanda Pires Domingues Cardoso Guedes; Paula Borges da Silveira Bezerra. Rio de Janeiro: UFRJ / EQ, 2013.

xiii, 64 p.; il.

(Projeto Final) – Universidade Federal do Rio de Janeiro, Escola de Química, 2013.

Orientador: Prof. Maurício Bezerra de Souza Jr.

1. Modelagem. 2. Redes Neuronais. 3. Gaseificação de Biomassa. 4. Projeto Final (Graduação – UFRJ / EQ). 5. Maurício Bezerra de Souza Jr, D.Sc.

“If you can’t explain it simply, you don’t understand it well enough.”

(Albert Einstein)

AGRADECIMENTOS

Agradeço a todos os Professores da Escola de Química, em especial aos Professores Eduardo Mach, Fernando Pellegrini, Donato Aranda e às Professora Maria Alice Coelho e Suzana Borschiver pela atenção e carinho comigo.

Agradeço ao meu orientador Maurício Bezerra, por ter me dado a oportunidade de trabalhar nesse projeto tão importante para a academia.

Agradeço aos meus pais por terem sempre me incentivado a estudar e a não desistir, mesmo em horas de desespero.

Agradeço ao meu avô Paulo, por ter despertado em mim a paixão pela ciência e matemática.

Agradeço ao meu namorado Guilherme, por estar sempre do meu lado, me apoiando em qualquer situação.

Agradeço à minha irmã Carolina, minhas avós Maria Angélica, Maria Alzira e Maria e aos meu avôs Zé e Cid e ao meu tio Sérgio e tia Maria Alzira por toda confiança depositada em mim nesse início da minha carreira.

Agradeço ao meu tio Luiz Mauro por já ter passado tardes comigo estudando cálculo e física.

Agradeço ao meu veterano Leonardo Michels, por desde o início da faculdade, mesmo no intercâmbio, ter me explicado tantas matérias e ter sido um tutor pra mim.

Agradeço a todos meus amigos da faculdade, principalmente Fernanda, Bárbara e Laura por terem me proporcionado ótimos momentos nessa fase inesquecível da faculdade

Agradeço às minhas amigas Paula e Fernanda por terem aceitado trabalhar comigo nesse projeto final e terem sido excelentes companheiras de estudos.

Camilla Chaves Nunes de Oliveira

Agradeço aos meus pais por terem me proporcionado toda a oportunidade de estudo desde pequena, por terem me apoiado nos momentos de fraqueza e me dado amor incondicional. Sem vocês não teria conseguido chegar até aqui.

Agradeço aos meus irmãos, Henrique e Maria, pela paciência, pela amizade e amor de irmão.

Agradeço ao meu namorado, Paulinho, por estar sempre do meu lado, pela paciência, pelos conselhos dados, por sua amizade e seu amor.

Agradeço a toda minha família, que sempre se preocupou, me incentivou e festejou junto a mim nos momentos de alegria.

Agradeço às amigas, Barbara, Camilla e Laura, pois nada teria sido tão perfeito se não estivéssemos uma ao lado da outra. Obrigada pelo apoio, pelas risadas e por todos os momentos inesquecíveis que me proporcionaram no período em que estivemos na faculdade.

E finalmente agradeço a Deus por ter me presenteado com pessoas tão maravilhosas como as que fazem parte da minha vida e por me proporcionar ser mais feliz a cada dia.

Fernanda Pires Domingues Cardoso Guedes

Agradeço a minha família por todo amor e estrutura que me deram, por todo apoio que me fizeram chegar até aqui. Agradeço especialmente a minha mãe Ligia e a minha irmã Patricia por toda a paciência e por acreditarem em mim sempre.

Agradeço também a minha família escolhida, meus amigos, que tornaram meus dias mais leves e divertidos e estiveram ao meu lado nos desafios, escolhas e momentos de conquistas.

Agradeço a meu namorado Fabio pela paciência, pela ajuda, pelo amor e por sempre fazer com que eu busque o meu melhor.

Paula Borges da Silveira Bezerra

Resumo do Projeto Final apresentado à Escola de Química como parte dos requisitos necessários para obtenção dos graus de Engenheiro Químico e Engenheiro de Bioprocessos.

Modelagem por Redes Neurais para obtenção de condições operacionais ótimas de produção de H₂ por Gaseificação de Biomassas

Camilla Chaves Nunes de Oliveira

Fernanda Pires Domingues Cardoso Guedes

Paula Borges da Silveira Bezerra

Abril, 2013

Orientador: Prof. Maurício Bezerra de Souza Jr., D.Sc.

A biomassa é um recurso natural muito promissor para um futuro energético sustentável e pode ser utilizada em muitos processos para produção de energia.

Neste contexto, a tecnologia de gaseificação é uma rota a ser considerada de grande relevância, por proporcionar uma combustão limpa e eficiente da biomassa. Porém, esta tecnologia é um processo que possui reações muito complexas, onde prever desempenhos e realizar modelagens são tarefas complicadas. Sendo assim, no presente trabalho, optou-se pela utilização das Redes Neurais Artificiais para realizar tais tarefas, por possuírem habilidade, após treinada, para representar adequadamente os processos complexos e não lineares.

Um dos subprodutos gasosos do processo é o hidrogênio (H₂) e é exatamente com base na otimização de sua produção que faremos o estudo deste trabalho. A escolha por este elemento foi feita pelo fato de seu uso como energia limpa estar ganhando cada vez maior atenção.

Assim, a biomassa escolhida para a simulação realizada neste trabalho é o bagaço de cana, por ser uma alternativa energética para usinas que o tem como resíduo de produção, e ser uma fonte de energia sustentável que contribui para a redução da emissão de gases do efeito estufa.

Os treinamentos das redes serão feitos em múltiplas camadas e, como os dados de bagaço de cana obtidos da literatura não são muitos, pelo fato de optar-se por utilizar apenas os dados de melhor desempenho, as condições de operação serão variadas com o objetivo de chegar-se a menor rede possível e assim evitar-se o sobreajuste dos dados.

SUMÁRIO

1	Introdução.....	1
1.1	Objetivo.....	3
1.2	Estrutura do trabalho.....	4
2	Gaseificação	5
2.1	Etapas do Processo de Gaseificação	5
2.1.1	Secagem	5
2.1.2	Pirólise	6
2.1.3	Combustão	6
2.2	Reações de Gaseificação.....	6
2.3	Tipos de Gaseificadores	7
2.3.1	Gaseificadores de Leito Fixo	7
2.3.2	Gaseificador de Leito Fluidizado.....	9
2.4	Agentes de Gaseificação	10
2.5	Revisão de modelagem da gaseificação por redes neuronais	12
3	Biomassa	14
3.1	Propriedades da Biomassa	15
3.1.1	Grau de Umidade	15
3.1.2	Teor de Cinzas	15
3.1.3	Teor de Voláteis	15
3.1.4	Poder Calorífico	15
3.1.5	Frações mássicas dos principais elementos químicos.....	16
3.2	Aplicações da tecnologia de Gaseificação de Biomassa.....	17
3.2.1	Produção de Energia Elétrica.....	17
3.2.2	Produção de Hidrogênio	17

4	Redes Neurais Artificiais (RNA)	19
4.1	Funcionamento.....	20
4.2	Redes multicamadas MLP	22
4.3	Algoritmo back-propagation.....	24
5	Metodologia	28
6	Resultados	33
6.1	Treinamento da rede	33
6.1.1	Rede com 9 variáveis	33
6.1.2	Redes com 8 variáveis	35
6.1.3	Redes com 7 variáveis	36
6.1.4	Rede com 6 variáveis	38
6.2	Análise de rede com dados de bagaço de cana	38
6.2.1	Rede com 9 variáveis	38
6.2.2	Rede com 8 variáveis	41
6.2.3	Rede com 7 variáveis	44
6.2.4	Rede com 6 variáveis	48
6.3	Análise de todas as redes	50
7	Conclusão	52
8	Bibliografia.....	53
	ANEXO 1	57
	ANEXO 2	64

ÍNDICE DE FIGURAS

Figura 1 - Oferta de energia elétrica nacional por fonte com base em 2011	3
Figura 2 - Gaseificador contracorrente	8
Figura 3 - Gaseificador co-corrente	9
Figura 4- Gaseificadores de leito fixo	10
Figura 5 - Funcionamento de uma célula a combustível	18
Figura 6 - Estrutura de um neurônio biológico.....	21
Figura 7 - Estrutura do neurônio artificial	22
Figura 8 - Esquema de rede MLP	23
Figura 9 - Resultado do treinamento com 9 variáveis	33
Figura 10 – Gráfico saída de H ₂ predito X observado (9 entradas)	35
Figura 11 - Resultado do treinamento com 8 variáveis, sem H.....	35
Figura 12 - Resultado treinamento, sem cinzas	36
Figura 13 - Resultado treinamento, sem voláteis	36
Figura 14 - Resultado treinamento com 7 variáveis, sem H e voláteis	37
Figura 15 - Resultado treinamento, sem H e cinzas	37
Figura 16 - Resultado treinamento, sem cinzas e voláteis.....	37
Figura 17 – Resultado treinamento com 6 variáveis	38
Figura 18 – Modelo 9 variáveis: H ₂ saída predito X observado.....	39
Figura 19 – Gráfico RE x T x H ₂ previsto: 9 variáveis.....	40
Figura 20 – Vista superior da Figura 18	41
Figura 21 – Modelo 8 variáveis: H ₂ saída predito X observado.....	42
Figura 22 - Gráfico RE X T X H ₂ previsto: 8 variáveis	43
Figura 23 – Vista superior Figura 21	44
Figura 24 – Modelo 7 variáveis: H ₂ saída predito X observado.....	45
Figura 25 - Gráfico RE x T x H ₂ previsto: 7 variáveis	46
Figura 26 – Vista superior Figura 24	47
Figura 27 - Extrapolação do modelo para temperaturas até 700°C.....	48
Figura 28 - Modelo 6 variáveis: H ₂ saída predito X observado	49
Figura 29 – Gráfico RE X T X H ₂ previsto: 6 variáveis.....	49
Figura 30 – Vista superior Figura 28.....	50

ÍNDICE DE TABELAS

Tabela 1 - Poder calorífico do gás de síntese em função do agente de gaseificação	11
Tabela 2 - PCI de diferentes tipos de biomassa.....	16
Tabela 3 - Resultados	51
Anexo 1 - Dados experimentais de biomassa	58
Anexo 2 - Dados experimentais de bagaço de cana	64

LISTA DE SIGLAS

BEN- Balanço Energético Nacional

BFGS – Broyden–Fletcher–Goldfarb–Shanno

EPE – Empresa de Pesquisa Energética

MDL – Mecanismo de Desenvolvimento Limpo

MIT - Massachusetts Institute of Technology

MLP – Multilayer Perceptron

PCI – Poder Calorífico Inferior (Kcal/kg)

PCS – Poder Calorífico Superior (Kcal/kg)

PSP – Função Potencial Pós-Sináptica

RNA – Redes Neurais Artificiais

SNN – *Statistica Neural Network*

SOS – Soma dos mínimos quadrados (*Sum of Squares*)

NOMENCLATURA

C	conjunto que inclui todos os neurônios da camada de saída da rede
d	resposta desejada para o neurônio
$e_j(n)$	O sinal de erro na saída do neurônio j da camada de saída na iteração n
j	neurônio da camada de saída
m	número total de entradas aplicadas ao neurônio j
n	número da iteração
N	número total de padrões utilizados no treinamento
N	normal
v_j	soma ponderada de todas as entradas sinápticas, comumente chamada de campo local induzido
w	peso sináptico, escolhido aleatoriamente no início do processamento
y	resposta obtida na saída do neurônio
RE	razão entre a quantidade de oxigênio fornecida ao sistema e a quantidade estequiométrica necessária para a combustão completa do combustível
S/B	razão vazão mássica de vapor por vazão mássica da biomassa
y_i	resposta do neurônio i , que se encontra na camada anterior ao neurônio j
ΔH	Calor de reação
$\varepsilon(n)$	valor instantâneo da energia total do erro na iteração n
\mathcal{E}_{med}	energia média do erro
φ	função de ativação que descreve a relação associada ao neurônio j
η	parâmetro da taxa de aprendizagem do algoritmo
$\delta_j(n)$	o gradiente local

1 INTRODUÇÃO

A questão principal da crise global do meio ambiente são as mudanças climáticas. Elas são o grande desafio que a humanidade tem de enfrentar em conjunto. E a questão energética pode vir a favor ou contra essas questões ambientais.

O mundo é altamente dependente das duas fontes que quando utilizadas causam impactos ao meio ambiente: carvão e petróleo. Porém, o uso extensivo dessas fontes de energéticas tem preocupado as nações devido à grande pressão do Desenvolvimento Sustentável. E, com isso, iniciou-se a grande busca pelas energias alternativas para dar solução a esse problema.

Segundo Lago & Pádua (1984), o primeiro grupo a discutir sustentabilidade, meio ambiente e limites de desenvolvimento, foi o Clube de Roma, em 1968, que reuniu políticos, economistas, cientistas, chefes de estado e associações internacionais. Foi publicado o relatório “Os Limites do Crescimento”, preparado por pesquisadores do *Massachusetts Institute of Technology*, MIT, que utilizou modelos matemáticos para mostrar que, devido à poluição, escassez de recursos naturais e energéticos, haveria uma redução drástica da população.

Em junho de 1972, ocorreu em Estocolmo a primeira percepção em âmbito mundial da relação entre desenvolvimento e meio ambiente. Foi a Conferência das Nações Unidas sobre o Ambiente Humano.

O termo Desenvolvimento Sustentável surgiu pela primeira vez, em 1980, no relatório “A Estratégia Global para a Conservação”, publicado pela União Internacional para a Conservação da Natureza. Porém, esse termo só foi formalizado em 1987, no relatório *Brundtland*, criado pela Comissão Mundial sobre Meio Ambiente e Desenvolvimento. Esse tão aclamado conceito abrangeria a questão ambiental, social e econômica.

E assim, outros eventos de cunho ambiental foram sendo organizados, como por exemplo, a recente Rio +20, que reconheceu a importância da energia sustentável e o seu papel na erradicação da pobreza. Melhorar a eficiência energética, aumentar a

proporção de energia renovável e usar tecnologias mais limpas são elementos essenciais para o Desenvolvimento Sustentável.

Com o intuito de solucionar a questão energética, várias fontes alternativas têm sido pesquisadas como a biomassa, eólica, solar, das marés, geotérmica, entre outras.

Biomassa é a fração biodegradável proveniente de produtos e resíduos da agricultura, pecuária e silvicultura, bem como resíduos urbanos e industriais (FERNANDES *et al.*, 2009).

Para Sachs (2000), as civilizações do passado se basearam no consumo da biomassa, usando-a para alimentação, combustível, vestimentas, madeira para construção de abrigos, etc. Assim, o objetivo é empregar o conhecimento dos povos numa moderna utilização de biomassa, onde o uso deste seria a base desta nova civilização, porém mais moderna e eficiente.

A biomassa é a alternativa mais promissora para o futuro energético sustentável. Ela é a solução de dois problemas: destino dos resíduos sólidos e demanda energética.

Segundo o Relatório Final do Balanço Energético Nacional publicado pela Empresa de Pesquisa Energética, EPE, em 2012, o Brasil ampliou para 88,8% a participação de energia renovável em sua matriz elétrica (Figura 1) Esse grande percentual se deve principalmente às suas usinas hidrelétricas. Mesmo essa fonte de energia sendo considerada renovável, ela tem sofrido grande resistência pelos seus impactos ambientais e sociais. Com isso, o Brasil tem investido em outras fontes de energia, embora muitos empreendimentos hidrelétricos tenham sido construídos e planejados.

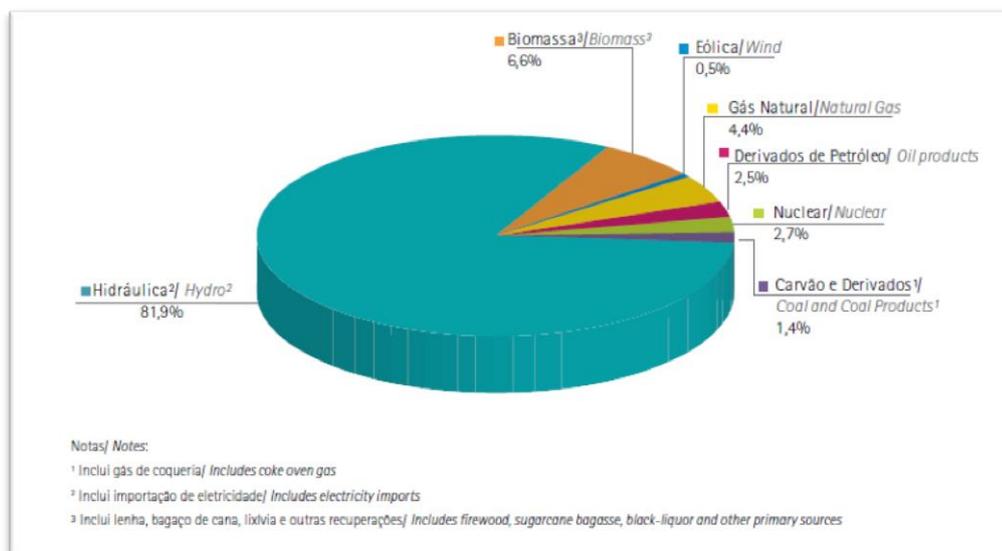


Figura 1 - Oferta de energia elétrica nacional por fonte com base em 2011

Fonte: BEN 2012/ Ano Base 2011 – EPE

Face às questões contemporâneas que estão sendo colocadas em pauta relacionadas à matriz energética, este presente trabalho tem como objetivo obter os parâmetros operacionais que maximizem a produção de hidrogênio no processo de gaseificação de bagaço de cana.

Foi realizada uma simulação por redes neurais artificiais, que consistem em extrair dados de entrada, reconhecê-los como padrão e assim, criar uma correlação com os dados de saída. Para tal, usamos o programa Statistica 8.0 (*Statistica Neural Network -SNN*).

1.1 OBJETIVO

O objetivo do presente trabalho é obterem-se condições operacionais que maximizem a produção de H₂ no processo de gaseificação de bagaço de cana, através da utilização de Redes Neurais Artificiais (RNA). Tal informação é relevante visto que o uso de hidrogênio na produção de energias limpas e sustentáveis tem tido cada vez mais relevância no mundo atual, ao mesmo tempo em que é preciso alcançar avanços no que diz respeito às técnicas de gaseificação.

A escolha pelo uso de Redes Neurais Artificiais seu deu porque as redes possuem uma ampla gama de aplicabilidade, bem como facilidade de armazenar o

conhecimento experimental e torná-lo disponível para uso (BHAGAT, 1990; SOUZA, 2005).

As RNA's possuem grande utilização em processos da indústria química, pois têm habilidade para a representação de processos complexos e não-lineares, exatamente como são a maioria dos processos químicos (CHITRA,1992; SOUZA, 2005).

1.2 ESTRUTURA DO TRABALHO

Primeiramente, no Capítulo 2, foi feita uma revisão do processo de gaseificação da biomassa, considerando aspectos operacionais e de reações químicas envolvidas. Também foram abordados os tipos de agentes de gaseificação, os tipos de gaseificadores e os processos químicos envolvidos. Por fim, fez-se uma revisão sobre literaturas existentes sobre a modelagem por redes neurais do processo de gaseificação.

No Capítulo 3 abordou-se os aspectos da biomassa que motivou o estudo, com uma revisão sobre as características do bagaço de cana. As aplicações da tecnologia de gaseificação de biomassa também foram apresentadas neste capítulo.

No Capítulo 4 fez-se uma introdução às redes neurais artificiais, com ênfase no tipo de rede utilizada no trabalho, no caso, a rede MLP.

No Capítulo 5 mostrou-se a metodologia utilizada no presente trabalho.

No Capítulo 6 os resultados obtidos estão expostos. Neste foram detalhadas as redes geradas, selecionadas e analisadas, bem como os resultados destas análises.

No Capítulo 7 foi feita a conclusão do presente trabalho.

2 GASEIFICAÇÃO

A gaseificação é um processo de conversão termoquímica, no qual materiais como carvão, biomassa, coque de petróleo, entre outros, são convertidos em gases combustíveis, gases redutores ou gases para síntese química (BASU,2006). A conversão ocorre em reatores conhecidos como gaseificadores e as reações são bastante complexas.

Os gaseificadores têm como subprodutos gasosos CO (monóxido de carbono), CO₂ (dióxido de carbono), H₂ (hidrogênio) e CH₄ (metano), além de água, alcatrão, condensáveis e um resíduo sólido de carbono não convertido (*char*) (NEMER,2010). Segundo Krause (1990), o produto proveniente do processo de gaseificação é um insumo energético limpo e flexível no seu uso e manuseio.

A tecnologia da gaseificação de biomassa já existe há mais de 100 anos, porém, ficou em esquecimento durante muito tempo, pois não era atrativa frente aos baixos preços dos combustíveis fósseis. Após as crises energéticas, seu estudo foi retomado e atualmente é vista como uma boa opção energética (HENRIQUES, 2009).

2.1 ETAPAS DO PROCESSO DE GASEIFICAÇÃO

Em geral, as etapas do processo de gaseificação consistem em (CASTELLANOS, 2012):

- Secagem;
- Pirólise;
- Combustão;
- Reações de Gaseificação.

2.1.1 Secagem

A etapa de secagem consiste na retenção da umidade da matéria-prima que é alimentada no gaseificador, devido às altas temperaturas presentes (temperaturas acima de 150°C) (NEMER, 2010).

2.1.2 Pirólise

A pirólise pode ser definida como a degradação térmica da biomassa em ausência total ou quase total de agente oxidante (OLIVEIRA, 2006). Esta etapa possui reações exotérmicas, as quais começam a ocorrer em temperaturas próximas a 400°C. Os produtos formados são gases não condensáveis, gases condensáveis e produtos sólidos. Os gases não condensáveis consistem em uma mistura de gases de baixo peso molecular, os quais fazem parte das reações das etapas posteriores do processo (H₂, CO, CO₂, H₂O e CH₄). Os gases condensáveis são alcatrão, vapor de água, óleo ou nafta (HIGMAN E VAN DER BURGT, 2008). Já o produto sólido é composto de carbono, oxigênio, hidrogênio e outras espécies como enxofre, e é também conhecido como resíduo sólido de carbono ou *char* (NEMER, 2010).

2.1.3 Combustão

A combustão é um processo exotérmico, com a temperatura variando entre 900°C e 1300°C, onde ocorre a reação entre o carbono presente na matéria-prima e o oxigênio do ar, através das reações a seguir:



A energia necessária para a ocorrência das outras etapas do processo é gerada na combustão, visto que, em geral, as reações de gaseificação são endotérmicas.

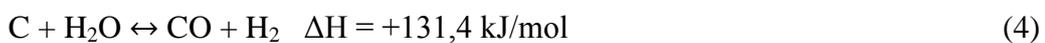
2.2 REAÇÕES DE GASEIFICAÇÃO

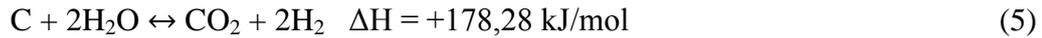
Nesta etapa ocorrem reações, em sua maioria endotérmica, através das quais são produzidos os gases combustíveis. A temperatura pode variar entre 800°C e 1100°C.

- Reação de Boudouard



- Reações Carbono Vapor

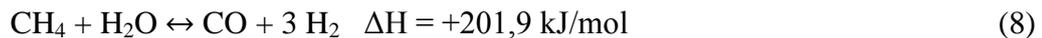
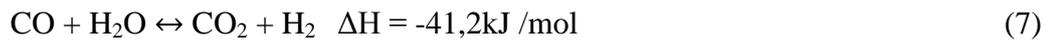




- Reação de formação do metano



- Reações de deslocamento de água



2.3 TIPOS DE GASEIFICADORES

2.3.1 Gaseificadores de Leito Fixo

A maioria dos gaseificadores em operação é de leito fixo. O movimento do combustível ocorre apenas por ação da gravidade. A conversão de biomassa é pequena, logo são indicados para projetos de pequeno porte.

Existem dois tipos de gaseificadores de leito fixo: contracorrente e co-corrente.

2.3.1.1 Contracorrente

Também chamado de gaseificador de fluxo ascendente, a alimentação nesse tipo de reator se dá pelo topo e desce em contracorrente com o ar (Figura 2). A biomassa e o ar entram em contato em uma região de temperatura elevada, ocorrendo sua combustão. O CO_2 e H_2O são reduzidos a CO , H_2 e CH_4 , em temperaturas mais baixas. A biomassa, em contato com os gases ascendentes, sofre uma secagem inicial e é pirolisada. É produzido o alcatrão nesta etapa que é arrastado pelos gases que deixa o gaseificador. Este alcatrão, por não ser craqueado na zona de combustão e ser levado para cima do gaseificador, pode causar incrustações nas tubulações. Alguns gaseificadores de grande porte possuem uma câmara no topo com o intuito de condensar os voláteis.

A eficiência térmica para este tipo de gaseificador é alta, pois os gases provenientes da zona combustão, pré-aquecem a carga de combustível ao passar por ela.

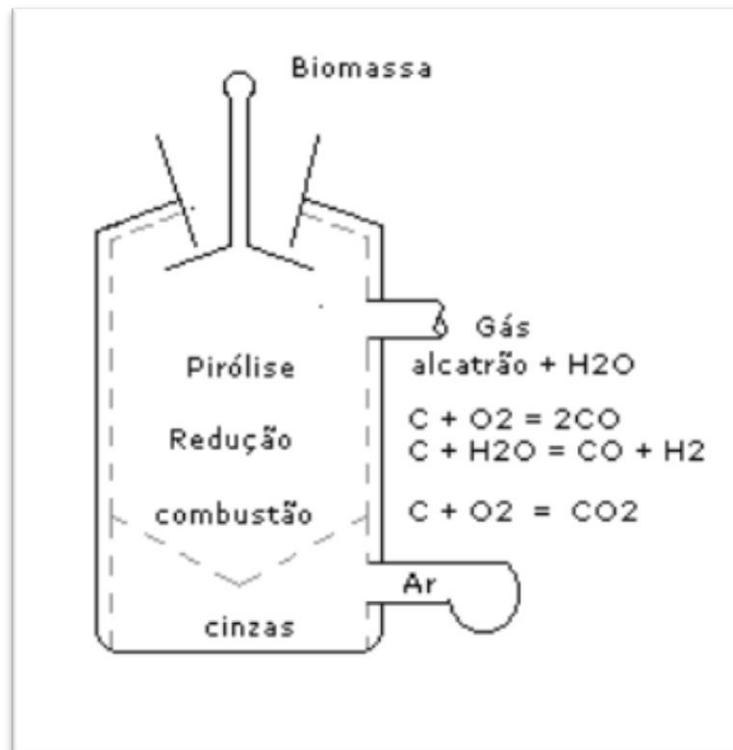


Figura 2 - Gaseificador contracorrente

Fonte: PIFFER, 1999

2.3.1.2 Gaseificador Co corrente

Este tipo de gaseificador de fluxo descendente consegue eliminar do gás os alcatrões e os óleos produzidos pela combustão (Figura 3). O ar e a biomassa são alimentados no topo e os alcatrões e voláteis ao passarem pela zona de combustão, são craqueados a gases simples ou a carbono.

Para garantir o craqueamento dos alcatrões, a temperatura deve ser uniforme por toda a seção, logo a zona de combustão é considerada um elemento crítico.

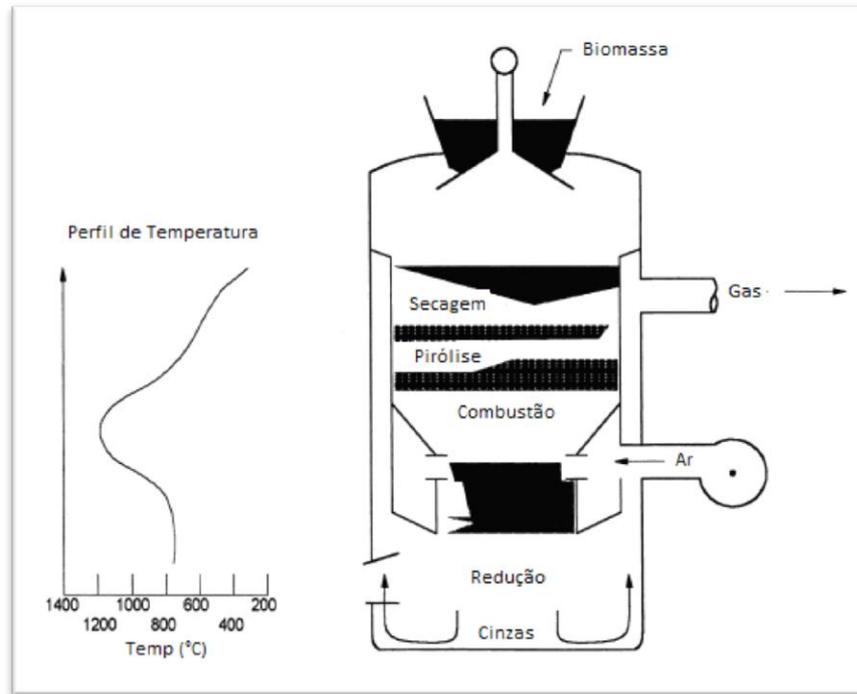


Figura 3 - Gaseificador co-corrente

Fonte:McKendry, 2002

2.3.2 Gaseificador de Leito Fluidizado

Neste tipo de gaseificador ocorre a formação de um leito de biomassa em suspensão produzido por efeito do fluxo de ar. Utiliza-se como leito um material inerte (areia, cinzas ou alumina) ou um material reativo (calcário ou um catalisador) que melhoram a eficiência da transferência de calor. Com a uniformidade da temperatura e ótimas condições de transferência de calor e massa, os voláteis entram em contato com as partículas do leito contribuindo para uma gaseificação completa e limpa. Este gaseificador tem a vantagem da facilidade de controle da temperatura pela variação na alimentação de ar e de combustível.

As temperaturas relativamente mais baixas que as dos gaseificadores de leito fixo diminuem a formação de óxidos de nitrogênio e reduzem bastante os teores de material particulado e enxofre.

A gaseificação em leito fluidizado é bastante promissora, pois possibilita a utilização de combustíveis em que a gaseificação é difícil por métodos tradicionais

devido às suas características de umidade, baixa densidade, granulometria, entre outras. Como exemplo de combustíveis, há o bagaço de cana, casca de arroz e biomassa barata.

Os gaseificadores de leito fluidizado podem ser de leito borbulhante ou circulante. O gaseificador de leito borbulhante tem velocidade da biomassa de 1 m/s. No de leito circulante, mais moderno, a velocidade na qual o percola atravessa é mais alta, entre 7 e 10 m/s, permitindo melhor mistura do ar com o combustível gaseificado. Além disso, há recirculação do leito e do material não convertido, aumentando a conversão da biomassa (Figura 4).

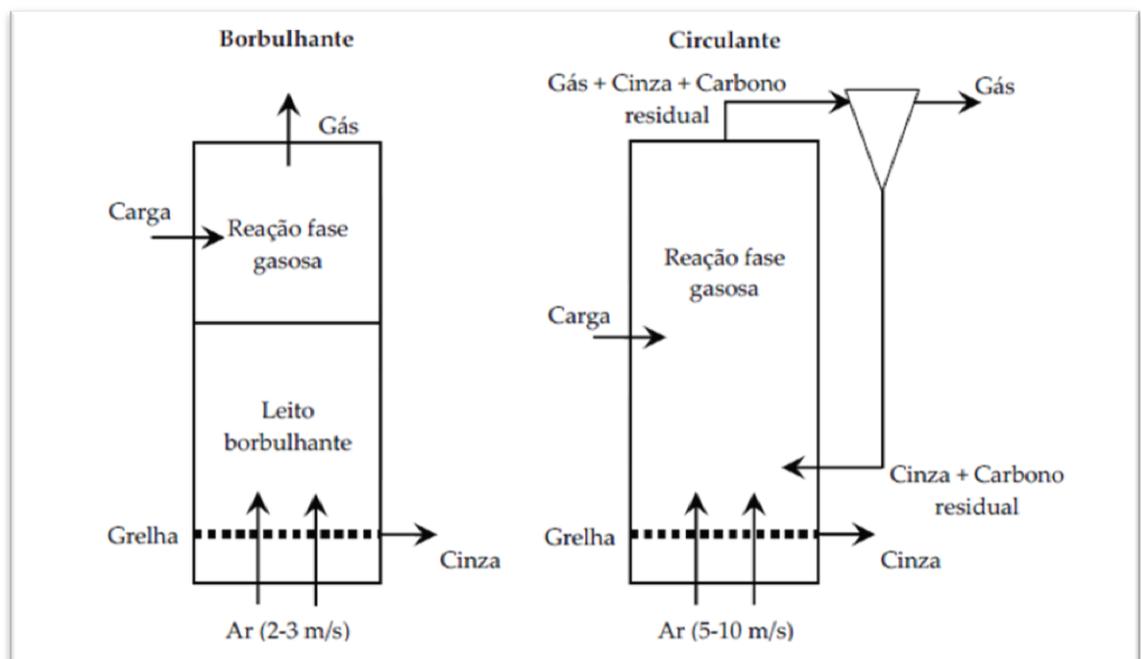


Figura 4- Gaseificadores de leito fixo

Fonte: Belgiorno *et al.*, 2003

2.4 AGENTES DE GASEIFICAÇÃO

A composição do gás de síntese e o desempenho do gaseificador vão depender do gás usado no processo que pode ser oxigênio, ar, vapor d'água ou uma combinação deles. Se o agente escolhido for o oxigênio ou o ar, não é preciso usar uma fonte de calor extra para manter a temperatura de operação, pois a reação entre o oxigênio e o combustível é exotérmica e será fonte de calor para o processo.

Neste trabalho, para que seja otimizada a produção de H₂, analisaremos qual será o agente de gaseificação que atingirá esta solução ótima.

- Ar

Este tipo de gaseificação é a mais simples entre elas e foi desenvolvida para aplicações industriais. Entretanto, ela produz um gás com baixo poder calorífico (4-6MJ/Nm³) e com apenas 8-14 vol% H₂. (XIAO *et al.*, 2007).

- Oxigênio

O uso de oxigênio puro como agente tem a grande desvantagem pelo alto custo do investimento, que está atribuído à dificuldade de separação deste do ar. Quando se usa oxigênio com ar, produz-se um gás com poder calorífico médio, em torno de 15 MJ/Nm³ (MCKENDRY, 2002).

- Vapor

O poder calorífico do gás produzido com este agente (com ou sem adição de oxigênio) é de 10-16 MJ/Nm³ com 30-60 vol% H₂. Este alto teor de H₂ na composição do gás é a grande vantagem deste tipo de gaseificação.

O aspecto negativo deste processo é que necessita de fonte de calor externa, já que as reações, neste caso, são endotérmicas. (XIAO *et al.*, 2007)

Na Tabela 1 estão relacionados os principais agentes gaseificadores com seus respectivos intervalos de poder calorífico do gás de síntese produzido.

Tabela 1 - Poder calorífico do gás de síntese em função do agente de gaseificação

Agente de Gaseificação	Poder Calorífico do Gás de Síntese [MJ/Nm ³]
Ar	4 a 6
Oxigênio	Aproximadamente 15
Vapor	10 a 16

Fonte: Adaptada de Catellanos (2012)

2.5 REVISÃO DE MODELAGEM DA GASEIFICAÇÃO POR REDES NEURONAIS

Muitas pesquisas já foram realizadas com relação ao processo de gaseificação de bagaço de cana, porém a maioria não se utilizou de redes neuronais para a modelagem empírica do processo, bem como não se objetivou a otimizar a produção de hidrogênio. Há muitos trabalhos na literatura que utilizam as redes neuronais para criar modelos de processos e otimizar a produção de hidrogênio, porém utilizando outros tipos de biomassa para simulação.

Gualdrón (2009) estudou a determinação do diâmetro de um gaseificador de leito fluidizado circulante para produzir gás de síntese a partir de bagaço de cana, o que permitiu o dimensionamento do gaseificador. Posteriormente previu as influências das condições operacionais sobre os parâmetros relacionados à qualidade do gás através do programa CSFMB (*Comprehensive Simulator of Fluidized and Moving Bed Equipment*).

Castro Cassiano e Ferreira (2009) realizaram a modelagem computacional do processo de gaseificação do bagaço de cana de açúcar para a obtenção de uma mistura gasosa rica em hidrogênio, utilizando o programa Aspen Plus®. Validou-se o modelo e, posteriormente, efetuaram-se simulações para a análise de sensibilidade do sistema de gaseificação, considerando condições distintas de vapor d'água, ar e fluxo de alimentação de biomassa nos equipamentos, com o objetivo de buscar condições operacionais otimizadas.

Xiao *et al.* (2008) utilizaram as redes neuronais para modelagem de um processo de gaseificação de resíduos sólidos urbanos em leito fixo, com o objetivo de prever o poder calorífico inferior do gás produzido, bem como sua taxa de produção a partir de variáveis de entrada como temperatura de gaseificação, valor de RE (razão equivalente) e tipo de resíduo utilizado. Os resultados positivos demonstraram a viabilidade de se utilizarem redes neuronais artificiais para a modelagem de processos como este.

De acordo com De Souza Jr. & Barreto Jr. (2009), as redes neuronais artificiais possuem capacidade em aprender e reconhecer relações altamente não lineares e então

organizarem-se em dados dispersos em um modelo não linear, o que pode ser de grande relevância para os estudos do processo de gaseificação de biomassa.

3 BIOMASSA

A biomassa pode ser definida como toda e qualquer matéria vegetal gerada através da fotossíntese e seus derivados, como também resíduos florestais e agrícolas, resíduos animais e a matéria orgânica contida em resíduos industriais, domésticos, municipais e etc (NOGUEIRA, 2000). Do ponto de vista energético é um recurso natural renovável, o qual pode ser utilizado em diversos processos como, por exemplo, a queima direta, a gaseificação, a pirólise, entre outros.

É possível referir-se à biomassa de duas maneiras distintas: Biomassa Moderna e Biomassa Tradicional. A primeira é utilizada de forma eficiente, gerando energia elétrica e calor a partir de tecnologias novas, assim como é produzida sustentavelmente. Já a segunda é utilizada de maneira pouco eficiente e obtida de forma não sustentável.

Podem-se citar alguns exemplos de biomassa: lenha, serragem, cana-de-açúcar, papel usado, galhos, folhas, casca de arroz, etc.

O uso da biomassa como fonte alternativa de energia pode desempenhar um papel fundamental na redução da utilização de combustíveis fósseis, tendo condições para ser uma solução efetiva aos problemas de natureza ambiental e energética, com os quais a sociedade atual convive.

Dentre os impactos positivos que a gaseificação da biomassa traz, pode ser citado o balanço neutro de carbono durante o processo de produção de energia. A biomassa, naturalmente, absorve o CO₂ da atmosfera durante sua fotossíntese, sendo que este mesmo CO₂ é retornado para o meio ambiente após o processo de combustão.

A biomassa utilizada para o estudo do presente trabalho foi o bagaço de cana de açúcar. Esta escolha foi baseada no fato de a gaseificação do bagaço ser uma terceira fonte de renda para os produtores de açúcar e etanol, pois o bagaço é uma parte inutilizada da cana de açúcar nestas usinas; de ser uma fonte de energia sustentável, que contribui com a redução da emissão de gases do efeito estufa; de ter a possibilidade de ser uma quarta fonte de renda para as usinas que o utilizam, pelo fato de ser um mecanismo de desenvolvimento limpo, MDL, podendo assim gerar créditos de carbono.

3.1 PROPRIEDADES DA BIOMASSA

3.1.1 Teor de Umidade

O teor de umidade (%) da matéria-prima alimentada no gaseificador é uma propriedade relevante ao passo que, para vaporizar-se um quilograma de água é necessária uma energia mínima de 2260 kJ não recuperável (CASTELLANOS, 2012). Sendo assim, biomassas com umidades muito elevadas dificultam a ignição e diminuem o poder calorífico do gás produzido.

3.1.2 Teor de Cinzas

Altos teores de cinzas podem alterar o desempenho do gaseificador, pois muitas vezes a temperatura do gaseificador é maior do que o ponto de fusão das cinzas causando assim problemas de aglomeração e incrustação.

3.1.3 Teor de Voláteis

A biomassa é mais reativa, quanto maior for o teor de voláteis, produzindo-se então menor quantidade de *char*.

3.1.4 Poder Calorífico

O poder calorífico pode ser definido como a quantidade de energia por unidade de massa ou volume (gases) liberada quando o combustível sofre o processo de combustão. Ele pode ser considerado de duas maneiras: Poder Calorífico Superior (P.C.S) e Poder Calorífico Inferior (P.C.I). O primeiro pode ser entendido como a quantidade total de energia liberada na forma de calor, desconsiderando a energia gasta na vaporização da água. Já o segundo é definido como a real quantidade de energia liberada, ou seja, considerando a energia consumida pela vaporização da água.

Na Tabela 2 abaixo podemos verificar o Poder Calorífico Inferior de alguns tipos de biomassas.

Tabela 2 - PCI de diferentes tipos de biomassa

Tipo de Biomassa	PCI(Kcal/Kg)
Carvão de Lenha	7355,0
Carvão de Resíduos Agrícolas	6137,1
Pinheiro	4776,0
Eucalipto	4632,7
Casca de Coco	4537,2
Sabugos de Milho	4489,4
Ramas de Algodão	4370,0
Bagaço-de-Cana	4131,2
Casca de Arroz	3844,7
Esterco	3247,7
Casca de Café	3199,9

Fonte: Nogueira, 2001

3.1.5 Frações mássicas dos principais elementos químicos

Quando se trabalha com biomassa é importante que sejam determinadas as frações mássicas dos principais elementos químicos presentes, os quais são: C (carbono), H (hidrogênio), N (nitrogênio), S (enxofre) e O (oxigênio). Tal caracterização é denominada Análise Elementar.

3.2 APLICAÇÕES DA TECNOLOGIA DE GASEIFICAÇÃO DE BIOMASSA

3.2.1 Produção de Energia Elétrica

A geração de energia elétrica a partir da gaseificação de biomassa é uma prática utilizada há muitos anos em todo o mundo, porém nos últimos vinte anos, muitas pesquisas têm sido realizadas com o objetivo de se alcançarem avanços tecnológicos.

Há muitos projetos de produção de energia elétrica a partir da gaseificação de biomassa pelo mundo. Uma das mais famosas plantas de gaseificação de biomassa está instalada na Áustria, na cidade de Güssing (PEREIRA *et al.*, 2012), onde além da energia gerada para abastecer a cidade há um excedente de 8MWh, o qual é vendido para o sistema nacional, o que acaba por gerar lucros para a economia local.

No Brasil, o projeto “Comparação entre Tecnologias de Gaseificação de Biomassa existentes no Brasil e no Exterior e Formação de Recursos Humanos na Região Norte – GASEIFAMAZ”, tem o objetivo de suprir a demanda de energia elétrica em comunidades isoladas na região Amazônica, através da implementação de uma tecnologia indiana de gaseificação de biomassa. O projeto visa avaliar as condições de operação deste sistema e formar recursos humanos na Região Norte do país, capacitando pessoal local na operação e manutenção (COELHO *et al.*, 2004).

A produção de energia elétrica a partir do processo de gaseificação se dá através dos gases produzidos, os quais podem sofrer queimas em caldeiras, em motores de combustão interna, em turbinas de combustão ou por combinações das opções anteriores (HENRIQUES, 2009).

3.2.2 Produção de Hidrogênio

A produção de hidrogênio através da gaseificação de biomassa tem ganhado cada vez mais atenção pelo seu uso como energia limpa (PEREIRA *et al.*, 2012). Projeta-se para a década de 2080 que 90% da energia provirá do hidrogênio (MARCHETTI E NAKICENOVIC, 1979).

Fazendo-se uma comparação entre o hidrogênio e qualquer outro combustível, ele possui a mais alta energia por unidade de peso, uma vez que não possui átomos de carbono como a gasolina, gasóleo, metano, propano, entre outros. Sendo assim, ele é muito utilizado em programas espaciais como combustível para propulsão de foguetes e cápsulas espaciais, onde o peso é um fator crucial.

As células a combustível são outro exemplo da aplicação do hidrogênio como fonte de energia. Elas são, em princípio, baterias, ou seja, conversores diretos de energia química em energia elétrica e térmica, produzindo corrente contínua pela combustão eletroquímica a frio de um combustível, geralmente hidrogênio (VIELSTICH, LAMM E GASTEIGER, 2003).

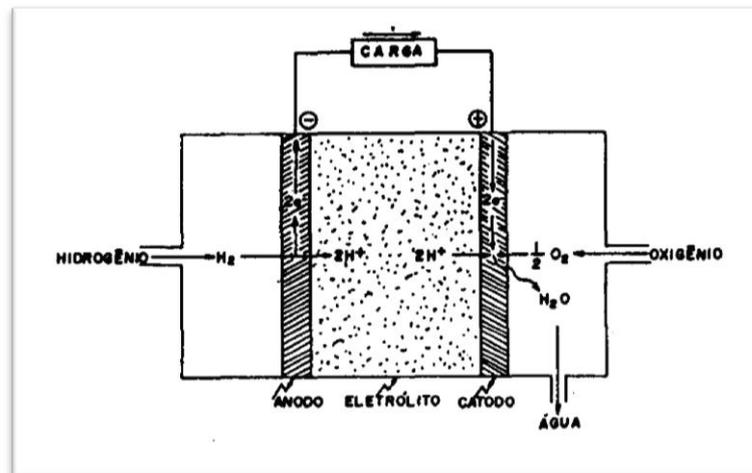


Figura 5 - Funcionamento de uma célula a combustível

Fonte: Ticianelu, 1989

Pereira *et al.* (2003) acreditam que se comparadas com outros métodos de produção de hidrogênio, as técnicas de gaseificação permanecem imaturas e mais pesquisas relacionadas a sua produção e conversão serão necessárias para que se tornem economicamente viáveis.

4 REDES NEURONAIS ARTIFICIAIS (RNA)

As redes neurais artificiais (RNA) têm seu conceito baseado no funcionamento do sistema nervoso humano. São modelos matemáticos inspirados nas redes de neurônios biológicos e em suas interligações complexas, associadas ao processamento de informações, e principalmente com a capacidade de aprendizado do neurônio biológico (GRECO, 2011).

Estes modelos apresentam algumas características cognitivas humanas, tais como capacidade de aprendizado, absorção de novos dados e interpretação de novos sinais através de experiências anteriores. Os princípios das redes neurais estão estritamente relacionados com áreas, tais como o reconhecimento de padrões, processamento de sinais e inteligência artificial (YEGNANARAYANA, 2006). As RNA's tem uma habilidade inerente de aprender e reconhecer relações altamente não lineares (SWINGLER, 1996), e então organizar dados dispersos em modelos não lineares (HECHT *apud* XIAO, 1989), o que as torna atrativas se comparadas a outras técnicas de estatísticas lineares convencionais.

Assim é esperado que uma rede neuronal tenha a característica de extrair dados de entrada, reconhecê-los como padrão e assim, criar uma correlação com os dados de saída. Esta característica faz com que as RNA's possuam aplicação para uma diversa gama de problemas. Segundo De Souza Jr (2005), as redes neurais estão sendo cada vez mais objeto de interesse, já que são ferramentas poderosas na resolução de problemas práticos, tais como diagnósticos médicos, controle automático, análise de risco de crédito, predição de tempo, entre outros.

Os problemas onde as RNA's podem ser aplicadas estão relacionados a uma destas categorias de tipo de aprendizagem (SWINGLE, 2001):

- Aproximações de funções contínuas, ou análise de regressão;
- Classificação;
- Processamento de dados;
- Robótica, incluindo controle computacional.

São extremamente úteis para estudos de engenharia. Onde através de dados experimentais, ou de funcionamento de plantas industriais é possível prever algumas situações futuras. Na engenharia, as tarefas que incluem classificação e aproximações de funções numéricas contínuas são as mais utilizadas. Swingle (2001) define estas tarefas como:

- *Classificação*: Tarefas onde as entradas são descrições de algum objeto a ser reconhecido e a saída é uma identificação da classe, na qual o objeto está inserido. São conhecidas como tarefas de classificação ou reconhecimento. A tarefa de classificação é a qual onde as saídas objetivas não podem ser dispostas ao longo de uma série contínua significativa, sendo cada saída possível da rede, uma entidade completamente separada, discretas a partir de todos os outros.

- *Funções numéricas contínuas*: Uma função contínua é aquela para a qual as saídas caem ao longo de uma série contínua significativa. Cada saída possível da rede tem o seu lugar ao longo da série. Pode haver muitos espaços contínuos tal para uma saída multidimensional. Essas funções descrevem a relação entre diferentes conjuntos de variáveis de um sistema físico real.

4.1 FUNCIONAMENTO

Sendo a rede neuronal inspirada no sistema de neurônios biológicos, esta funciona tentando simular a estrutura e funcionamento do sistema nervoso humano. Uma rede neuronal artificial é uma rede computacional que surgiu com intuito de funcionar de forma análoga ao cérebro. A ideia principal é poder reproduzir artificialmente a capacidade de aprendizagem do neurônio biológico (GRECO, 2011). Os neurônios são os conectores de informação, que depois de transportadas são processadas e compreendidas a partir de experiências anteriores, memórias, que permitem uma associação desta informação. Os neurônios artificiais formam uma rede que conecta e transporta a informação, para que esta possa ser processada computacionalmente.

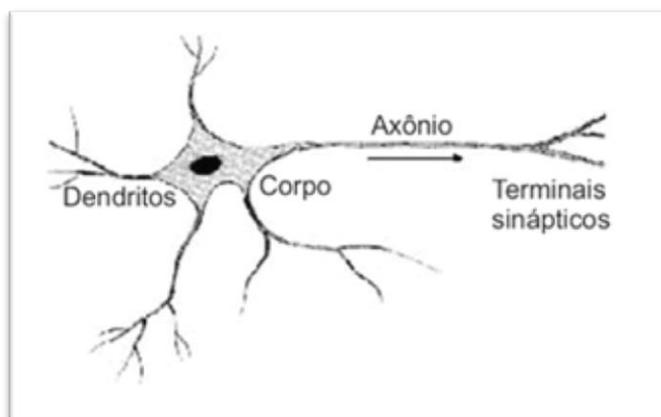


Figura 6 - Estrutura de um neurônio biológico

Fonte: Ferneda, 2006

Ainda que simplificados, e às vezes implausíveis no que concerne aos seus correspondentes biológicos, alguns tipos de redes apresentam características da cognição humana que os tornam bastante populares, tais como a aprendizagem através de exemplos e a capacidade de abstrair características relevantes a partir de dados abundantes (DE SOUZA JR, 2005).

Uma RNA é um processador eminentemente paralelo, composto por simples unidades de processamento, que possui uma propensão natural para armazenar conhecimento empírico e torná-lo acessível ao utilizador. Assemelha-se ao comportamento do cérebro em dois aspectos (NEVES, 2000):

- O conhecimento é adquirido a partir de um ambiente, através de um processo de aprendizagem.
- O conhecimento é armazenado nas conexões, também designadas por ligações ou sinapses, entre neurônios.

Isso significa que quando dados de entrada e saída de certo sistema são fornecidos a uma rede específica, ela é capaz de reproduzir o comportamento deste sistema, depois de ajustar as conexões entre os neurônios artificiais que a compõem (DE SOUZA JR., 2005).

Esse ajuste de conexões faz parte do processo de aprendizado da rede, que está relacionado à mudança do sistema de acordo com os dados recebidos, o qual altera o fluxo de informação e, assim, o tipo de rede.

Na Figura 7, observa-se o modelo de um neurônio artificial. São três os elementos principais deste: as sinapses, um somador e a função de ativação (NEMER, 2010). As sinapses são as conexões do sistema, cada uma tem seu peso sináptico. O somador compara com um valor limite, *bias*, a soma dos sinais de entrada, que já foram ponderados pelos seus pesos na sinapse. Essa comparação é chamada de função Potencial Pós-Sináptica (PSP). Após o somador, a função de ativação restringe a amplitude de saída de um neurônio para um limite padrão, tipicamente [0:1] ou [-1:1].

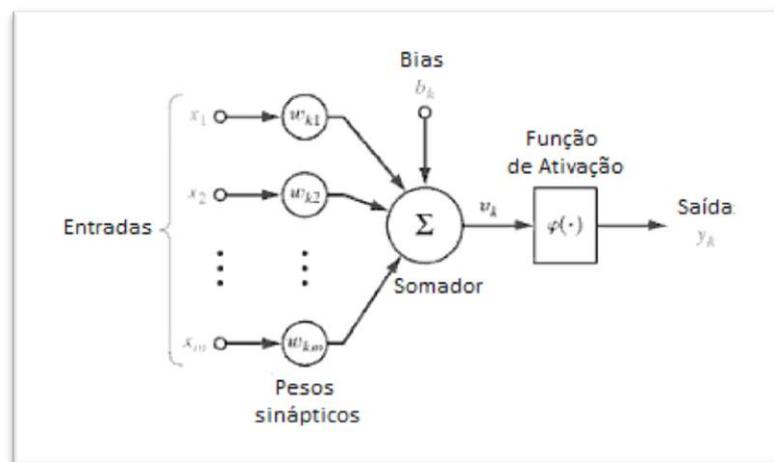


Figura 7 - Estrutura do neurônio artificial

Fonte: Haykin, 2001

No treinamento da rede os pesos e biases são ajustados a fim de encontrar o modelo que tenha um dado de saída que mais se assemelhe ao dado real (NEMER, 2010). As redes neurais são modelos estatísticos não lineares. Por isso, podem ser usados para modelar sistemas de complexas relações entre entradas e saídas.

4.2 REDES MULTICAMADAS MLP

As multicamadas *perceptron* é um tipo de arquitetura de rede neuronal e tem sido usada com frequência para a solução de problemas de classificação e também de regressão por sua simplicidade. Foi desenvolvida a partir do modelo *Perceptron*, como uma tentativa de resolver as limitações deste. É a rede mais usada atualmente e também a mais estudada e encontrada em livros sobre RNA (DE SOUZA JR., 2005).

Uma MLP é uma rede que contém no mínimo três camadas de processamento da informação. A camada de entrada, uma ou mais camadas escondidas intermediárias e uma camada de saída. As camadas são formadas por neurônios, ou nodos, que têm a capacidade de processar informações. As conexões entre os nodos são chamadas de sinapses, as quais fazem a transmissão da informação (NEVES, 2000). O número de neurônios de entrada e saída são definidos pelo problema a ser estudado, e o número de camadas escondidas é definido na solução do problema (BRANDÃO, 2010).

Na Figura 8 podemos visualizar o esquema de uma MLP de 3 camadas.

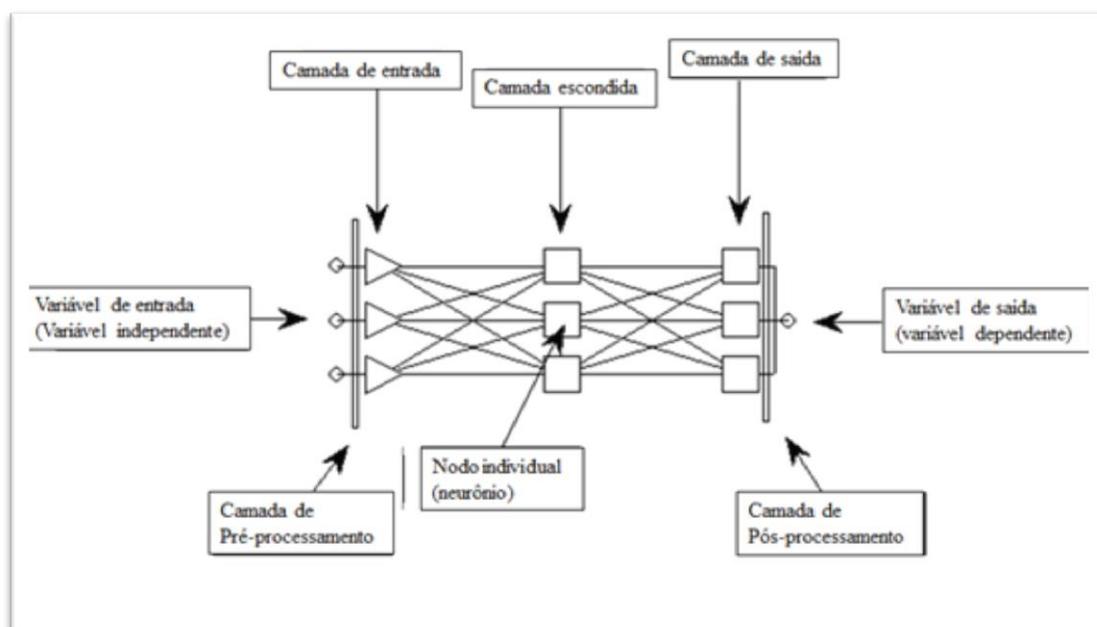


Figura 8 - Esquema de rede MLP

Fonte: Cortez *et al.*, 2000

A rede MLP é progressiva, uma rede do tipo *feedforward*. Cada neurônio alimenta a próxima camada, sem existir uma retroalimentação. A informação passa de camada a camada em sentido progressivo. É possível olhar esta rede neuronal como uma série de camadas (CASTRO, 2001).

Outra característica da MLP é o fato de todos os neurônios poderem estar completamente associados. O neurônio de uma camada pode estar conectado a todos os neurônios da camada seguinte. Porém, também pode ser apenas localmente conectada,

com alguns nodos possuindo peso igual a zero, não sendo relevante para a rede criada (CASTRO, 2001).

Pode-se dizer, de forma simplificada, que as camadas internas são as que mais têm trabalho, pois identificam as conexões de entrada e saída que estão associadas à função de transferência, a qual é a mais importante. A entrada é fixa, muitos estudos não as consideram como neurônios, já que não processam informação, e as camadas de saída possuem apenas interligação com uma camada, apesar de processarem informações (NEVES, 2000).

O treinamento da rede determina e modifica seus pesos e *biases*, usando dados históricos, de forma a aperfeiçoar sua atuação na predição dos valores de saída do sistema (BRANDÃO, 2010).

Sendo assim, para criar-se um projeto de MLP devem ser levados três fatores em consideração: o número de camadas escondidas, o número de neurônios das camadas escondidas e os pesos que interligam os neurônios das camadas. As camadas de entrada e saída são valores conhecidos e dependem da amostragem obtida (NEVES, 2000).

As redes neuronais podem ter inúmeras camadas e inúmeros neurônios em cada uma das camadas. O tamanho e a complexidade da rede refletem o nível de complexidade do processamento da informação (GANDELMAN, 2012).

Já em relação aos pesos, sua obtenção envolve a utilização de algoritmos de treino supervisionados, sendo o mais popular o algoritmo de retro propagação de erro, ou *back-propagation*. Esse algoritmo pode chegar aos melhores valores de peso para a rede através do aprendizado baseado na correção do erro (BRANDÃO, 2010).

Redes MLP podem ser treinadas por um dos seguintes algoritmos: Gradiente Conjugado Descendente, Quasi-Newton, Levenberg-Marquardt, Back Propagation, QuickPropagation, ou Delta-bar-Delta (DE SOUZA JR., 2005).

4.3 ALGORITMO BACK-PROPAGATION

A popularidade deste algoritmo se dá pelo fato de ser de simples implementação. A retro propagação armazena de forma eficiente a informação através dos pesos da rede,

os quais têm a capacidade de generalizar após devidamente treinados. Isso quer dizer que a retro propagação possui eficiência em encontrar valores de saída satisfatórios para dados de entrada que estejam dentro dos limites da camada. (FERNEDA, 2006)

A ideia central deste algoritmo é encontrar o erro do processamento da camada de saída e retro propagar este para as camadas anteriores, intermediárias. O algoritmo *back-propagation* consiste em duas fases, duas etapas através das camadas da rede, que são: um passo direto (*feedforward*) e um passo reverso (*feedback*). De Castro *et al.* (2009) descrevem estas etapas da seguinte forma:

- No passo direto um padrão de atividade do processo a ser aprendido (ou vetor de entrada) é aplicado aos nodos de entrada do MLP e o seu efeito se propaga através da rede, camada por camada, produzindo na camada de saída a resposta do MLP à excitação aplicada (vetor de saída). Durante o passo direto, os pesos sinápticos são todos fixos.
- Durante o passo reverso os pesos sinápticos são todos ajustados de acordo com a regra de aprendizado por correção de erro. Especificamente, a resposta MLP à excitação é subtraída de um padrão de resposta desejado para aquela excitação aplicada, de forma a produzir um sinal de erro. Este sinal de erro é, então, propagado de volta através dos mesmos neurônios utilizados no passo direto, mas no caminho contrário do fluxo de sinal nas conexões sinápticas. Os pesos sinápticos são, então, ajustados de forma que a resposta obtida do MLP aproxime-se mais do padrão de resposta desejado.

O desenvolvimento matemático do algoritmo de retro propagação está descrito na sequência, conforme Haykin (2001) *apud* Nemer (2010):

O sinal de erro na saída do neurônio j (da camada de saída) é determinado para a iteração n por:

$$e_j(n) = d_j(n) - y_j(n) \quad (1)$$

onde:

- d é a resposta desejada para o neurônio.

- y é a resposta obtida na saída do neurônio.

O valor instantâneo da energia do erro para o neurônio j é definido como: $\frac{1}{2} e_j^2(n)$.

Assim, temos que o valor instantâneo da energia total do erro é obtido somando-se os termos $\frac{1}{2} e_j^2(n)$ de todos os neurônios da camada de saída.

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

onde o conjunto C inclui todos os neurônios da camada de saída da rede.

Sendo N o número total de padrões utilizados no treinamento, a energia média do erro quadrático é obtida por:

$$\varepsilon_{med} = \frac{1}{N} \sum_{n=1}^N \varepsilon(n) \quad (3)$$

A energia média do erro é uma função de todos os parâmetros livres da rede (pesos sinápticos e níveis de *bias*) e representa a função objetivo como uma medida do desempenho de aprendizagem da rede. Então, o final do treinamento se dará quando os ajustes dos parâmetros livres da rede tenham minimizado a função de ε_{med} .

A soma ponderada de todas as entradas sinápticas acrescida do *bias*, comumente chamada de campo local induzido, que constitui o sinal aplicado à função de ativação associada com o neurônio j é definida como:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n) \quad (4)$$

Onde:

- m é o número total de entradas (excluindo o *bias*) aplicadas ao neurônio j .
- w é o peso sináptico, escolhido aleatoriamente no início do processamento.
- y_i é a resposta do neurônio i , que se encontra na camada anterior ao neurônio j .

Assim, o sinal funcional obtido na saída do neurônio j na iteração n , após a atuação da função de ativação, é:

$$y_j(n) = \varphi_j(v_j(n)) \quad (5)$$

Onde $\varphi (\cdot)$ representa a função de ativação que descreve a relação associada ao neurônio j .

O algoritmo de retro propagação aplica uma correção ao peso sináptico, que é proporcional à derivada parcial $\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}$. Usando a regra da cadeia do cálculo elementar, podemos expressar esse gradiente da seguinte forma:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \cdot \frac{\partial e_j(n)}{\partial y_j(n)} \cdot \frac{\partial y_j(n)}{\partial v_j(n)} \cdot \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (6)$$

Essa derivada representa um fator de sensibilidade que vai determinar a direção de busca no espaço de pesos.

Diferenciando as equações (1), (2), (4) e (5) em relação, respectivamente, a $y_j(n), e_j(n), w_{ji}(n)$ e $v_j(n)$ e substituindo na equação (6), temos que:

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = -e_j(n) \cdot \varphi'_j \left(v_j(n) \right) \cdot y_i(n) \quad (7)$$

A regra delta define a correção feita aos pesos sinápticos da seguinte forma:

$$\Delta w_{ji}(n) = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} \quad (8)$$

Onde η é o parâmetro da taxa de aprendizagem do algoritmo. O sinal negativo indica a descida do gradiente no espaço de pesos, ou seja, a busca pela redução do valor de $\varepsilon(n)$. O parâmetro taxa de aprendizado tem grande influência durante o treinamento. Valores muito baixos tornam o aprendizado muito lento, enquanto uma taxa muito elevada provoca oscilações e impede a convergência do processo de aprendizado. Geralmente, seu valor varia de 0,1 a 1,0.

Substituindo a equação (7) em (8), tem-se que:

$$\Delta w_{ji}(n) = -\eta (-e_j(n)) \cdot \varphi'_j \left(v_j(n) \right) \cdot y_i(n) \quad (9)$$

Assim, define-se o gradiente local $\delta_j(n)$, que aponta as modificações necessárias nos pesos sinápticos:

$$\delta_j(n) = -e_j(n) \cdot \varphi_j'(v_j(n)) \quad (10)$$

$$\Delta w_{ji}(n) = -\eta \cdot \delta_j(n) \cdot y_i(n) \quad (11)$$

Uma forma de melhorar o algoritmo de aprendizagem é variando-se o η . Para valores de η pequenos, menor é a mudança no peso das ligações. Se desejar-se acelerar o processo, pode-se aumentar o valor de η . Porém, este parâmetro não pode ser tão alto a ponto de instabilizar o treino.

5 METODOLOGIA

No presente trabalho utilizou-se o programa Statistica 8.0 (*Statistica Neural Network* - SNN) a fim de se obterem condições operacionais para maximizar a produção de H_2 no processo de gaseificação de bagaço de cana.

Os seguintes passos foram seguidos para realização do trabalho:

- Levantamento de dados da literatura sobre gaseificação de diversos tipos de biomassa (ANEXO 1);
- Treinamento de alguns tipos de rede utilizando o programa SNN;
- Análise das redes e escolha da qual representa o modelo de forma mais simples, com menor número de camadas escondidas e alta correlação entre os dados de entrada e saída, além de erro pequeno de predição;
- Seleção dos dados da literatura que utilizam bagaço de cana como biomassa (ANEXO 2);
- Análise de gráficos de superfície para este tipo de biomassa com as redes escolhidas previamente;
- Identificação, através dos gráficos, do ponto de operação que otimize a produção de H_2 .

Utilizaram-se dados da literatura sobre o processo de gaseificação de bagaço de cana e estes foram treinados pelo SNN. Como havia apenas dez dados de bagaço, para evitar o sobreajuste, o treinamento da rede foi realizado com dados tanto do bagaço de cana como de outros tipos de biomassa e esta rede treinada foi salva. Após o

treinamento, realizou-se a análise dos gráficos com apenas os dados do bagaço, porém, baseando-se na rede treinada e salva anteriormente.

Todos os dados, tanto de bagaço como de outros tipos de biomassas, foram obtidos de uma mesma fonte, Castellanos (2012), na qual já havia simulado anteriormente o processo de gaseificação de biomassa e obtiveram-se os melhores parâmetros para o processo em leito fluidizado borbulhante. A escolha por apenas os melhores resultados se deu em função da otimização do presente trabalho.

A escolha das variáveis de entrada importantes para o modelo teve como base duas condições: chegar-se a um modelo mais simples, onde não haja problemas como o sobreajuste; e considerar-se as variáveis de operação do sistema, as quais devem ser analisadas para futuras modificações, com o objetivo de otimizar-se o processo.

Num primeiro momento, para treinamento inicial da rede foram usados 124 dados, independente do tipo de biomassa utilizada. Não foram utilizados dados referentes apenas à biomassa do estudo (bagaço), pois estes eram poucos para gerar uma rede confiável. As biomassas utilizadas foram madeira, serragem de pinho, palha de trigo, casca de amêndoa, poda de noz e o bagaço de cana. Todos os dados são de reatores de leito fluidizado borbulhante e não utilizaram catalisadores em seus processos. Os agentes de gaseificação foram ar, vapor, ou a mistura destes.

Os dados da literatura continham os seguintes parâmetros: Composição da biomassa de entrada em termos de quantidade em porcentagem de massa de C, H e O, umidade, teor de cinzas, teor de voláteis e as variáveis operacionais como temperatura de operação, S/B e RE. Os dados da literatura tiveram a seguinte faixa de variação:

- C: 36,27 - 50,54%; de massa total
- H: 3,94 -7,08% de massa total
- O: 32,38 - 45, 43% de massa total
- Umidade: 4,26 – 14,30%
- Teor de cinzas: 0,32 – 26,40%
- Teor de voláteis: 58,80 – 82,29%
- Temperatura: 649 – 1044°C

- S/B: 0,00 – 4,70
- RE: 0,00 – 0,90

O S/B é um parâmetro que indica razão entre a vazão mássica de vapor e a vazão mássica de alimentação da biomassa. Este parâmetro é igual a zero para processos que utilizam apenas ar como agente de gaseificação.

O termo RE é a razão entre a quantidade de oxigênio fornecida ao sistema e a quantidade estequiométrica necessária para a combustão completa do combustível. (BASU, 2006). Em uma combustão, a quantidade de ar fornecida é determinada pela estequiometria, que depende da composição do combustível e excesso de ar requerido. Por outro lado, num gaseificador, o fornecimento de ar é apenas uma fração da taxa estequiométrica.

A qualidade do gás obtido de um gaseificador depende do valor de RE empregado, que deve ser menor que 1,0 para garantir uma combustão completa.

Valores muito baixos de RE ($< 0,2$) causam gaseificação incompleta, formação excessiva de resíduo sólido de carbono e baixo poder calorífico do gás produzido. Por outro lado, valores muito altos ($> 0,4$) resultam na formação excessiva de produtos da combustão diminuindo também o poder calorífico do gás (BASU, 2006).

Em relação às variáveis de saída, os dados foram filtrados para composição de H_2 presente no gás de saída, já que esta é a variável que tem relevância para o objetivo do trabalho. Os demais componentes do gás de saída, como CO, CH_4 , CO_2 , entre outros possíveis hidrocarbonetos, não foram utilizados na rede. A composição do gás produzido no processo é dada em porcentagem volumétrica.

Utilizando a ferramenta *Automated Neural Networks* (ANN) do SNN foram treinados diferentes tipos de redes, com diferentes entradas possíveis:

- Com 9 entradas, umidade, voláteis, cinzas, C, H, O, RE, S/B e temperatura;
- Com 8 entradas, considerando todas as variáveis de entrada menos o H ou voláteis ou cinzas;
- Com 7 entradas, retirando dois parâmetros H, voláteis e cinzas, em combinações;

- Com 6 entradas, retirando os três parâmetros H, voláteis e cinzas.

Foram treinadas redes do tipo MLP (Multicamadas *perceptrons*), a qual é uma rede progressiva *feedforward*. Como vimos anteriormente, uma RNA é dita *feedforward* quando as saídas dos neurônios em qualquer camada se conectam unicamente às entradas dos neurônios das camadas seguintes, sem a presença de laços de realimentação (NEVES, 2000).

Foram usados 100 redes para treino e destes, 10 foram retidos para teste. Expondo a rede repetidamente a dados experimentais, os pesos e *biases* da função PSP são ajustados usando algoritmos de treinamento especiais, até que a rede atue tão bem quanto possível na predição correta de valores de saída. O algoritmo de treinamento usa o erro na predição para ajustar esses parâmetros para cada unidade na rede. O procedimento continua até que a função de erro global seja suficientemente minimizada.

O erro global é também computado para um segundo subconjunto de dados: Dados de seleção (também chamados de verificação ou validação). Estes dados não tomam parte no ajuste de T (*threshold ou bias*) e W durante o treinamento, mas o desempenho da rede é continuamente checado para este subconjunto durante o treinamento. Se o erro para os dados de teste para de diminuir ou começa a aumentar, o treinamento é parado.

O uso de um subconjunto de teste é importante, porque treinamento ilimitado das redes leva a “sobretreinamento” dos dados de treinamento. Se não são impostas restrições no treinamento, uma rede neural pode descrever os dados de treinamento quase perfeitamente, mas pode generalizar muito mal para dados novos. Em muitos casos, é aconselhável criar um terceiro subconjunto de dados de validação para servir como uma checagem adicional independente da capacidade de generalização da rede neural (DE SOUZA JR, 2005).

As redes geradas têm apenas uma camada escondida. Sabe-se que quanto maior o número de parâmetros livres (maior complexidade da rede), maior deve ser a quantidade de padrões usados no seu treinamento para evitar *overfitting* (sobreajuste) dos dados (NEMER, 2010).

As redes escolhidas foram salvas. Para análise da melhor rede, foram levados em consideração dados estatísticos como o erro da rede e tamanho da rede, para evitar o sobreajuste de dados, já que se detêm de poucos padrões para esta análise.

Foram escolhidas 4 redes para posterior análise, afim de compararmos os resultados de otimização para os possíveis casos de parâmetros de entrada. Uma rede para cada quantidade de variáveis de entrada foi selecionada. Ou seja, foi levado para análise posterior um caso com 9 variáveis de entrada, 8, 7 e 6.

Após a obtenção das redes, foram selecionados os dados referentes à biomassa de estudo. Para cada rede foi analisada a qualidade da rede para o bagaço, através de gráfico de predição *versus* valores reais de saída de H₂.

Com isso, fizeram-se gráficos de superfície que relacionassem as condições operacionais, S/B, RE e T com % de H₂ predito pelo modelo de saída. Os gráficos gerados foram analisados para identificação do ponto operacional que levasse à maior quantidade de H₂.

6 RESULTADOS

6.1 TREINAMENTO DA REDE

A partir de 124 padrões de entrada-saída obtidos da literatura, foram treinadas redes tendo como variável de saída apenas o H_2 .

Primeiramente 100 redes foram treinadas, considerando todas as variáveis de entrada possíveis. Destas, dez foram retidas como as de melhor desempenho. Porém, as redes apresentavam muitas variáveis livres (9 entradas). Apesar da boa correlação, a complexidade da rede fez com que fossem estudados outros casos. Casos com variáveis de saída variando de 9 a 6.

Foram sendo retirados parâmetros que são operacionais, RE, S/B e temperatura, e que não estão relacionados a características mais relevantes da biomassa levando em consideração o processo de gaseificação, como a composição em porcentagem de massa de carbono e oxigênio e teor de umidade.

6.1.1 Rede com 9 variáveis

Após o treinamento de 100 redes, considerando todas as variáveis possíveis de entrada, foram retidas 10 redes com melhor desempenho (Figura 9). Destas, a rede selecionada como melhor para análise posterior foi a #9, por possuir menor número de neurônios em sua camada escondida, evitando complexidade da rede e possível sobreajuste.

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 9-12-1	0.998616	0.998748	BFGS 80	SOS
2	#2	MLP 9-8-1	0.998670	0.999058	BFGS 124	SOS
3	#3	MLP 9-6-1	0.998846	0.999265	BFGS 144	SOS
4	#4	MLP 9-6-1	0.996683	0.998700	BFGS 37	SOS
5	#5	MLP 9-10-1	0.996650	0.998861	BFGS 56	SOS
6	#6	MLP 9-9-1	0.998263	0.998501	BFGS 108	SOS
7	#7	MLP 9-10-1	0.998366	0.998745	BFGS 103	SOS
8	#8	MLP 9-7-1	0.998634	0.998901	BFGS 95	SOS
9	#9	MLP 9-5-1	0.997751	0.998663	BFGS 113	SOS
10	#10	MLP 9-8-1	0.994094	0.998501	BFGS 40	SOS

Figura 9 - Resultado do treinamento com 9 variáveis

Na primeira coluna temos o nome da rede encontrada. Os nomes das redes são dados pelo tipo de arquitetura utilizada, no caso MLP e pela quantidade de neurônios contida em cada camada. O primeiro número, no caso, 9, significa o número de dados de entrada, o número intermediário representa a quantidade de neurônios na camada intermediária e o último número as variáveis de saída, no caso do trabalho 1, o H_2 .

As colunas 4 e 5 da performance do treino e do teste indicam a performance da rede no tipo de grupo usado. A medida de performance depende da variável de saída real. Para problemas de regressão, a performance é a media do coeficiente de correlação do treino e do teste.

Na coluna algoritmo é mostrado um resumo sobre o algoritmo que foi utilizado para otimizar a rede. Mostra-se o algoritmo seguido pelo número de ciclos do mesmo que foram realizados até se chegar àquela rede mostrada. Por exemplo, a rede 9, significa que usou BFGS (ou Quasi-Newton) e teve 113 ciclos até chegar a rede atual. BFGS é um algoritmo de treino de segunda ordem com convergência muito rápida, mas com grande uso de memória computacional, já que armazena uma matriz Hessiana ao longo dos cálculos.

Outro parâmetro que foi analisado foi a soma dos pesos e *biases*. Estes tendem a diminuir a medida que a rede é simplificada, tem menos conexões existentes.

A coluna de erro indica a função de erro usada. Nesse caso o SOS é a soma dos quadrados (*sum of squares*).

A rede com configuração 9-5-1 apresentou um bom resultado, possuindo um coeficiente de pearson de 0.997. Nesta rede, a soma de pesos e *biases* é 5,0. A Figura 10 mostra a relação entre os dados preditos e observados, dados da literatura, em relação ao H_2 .

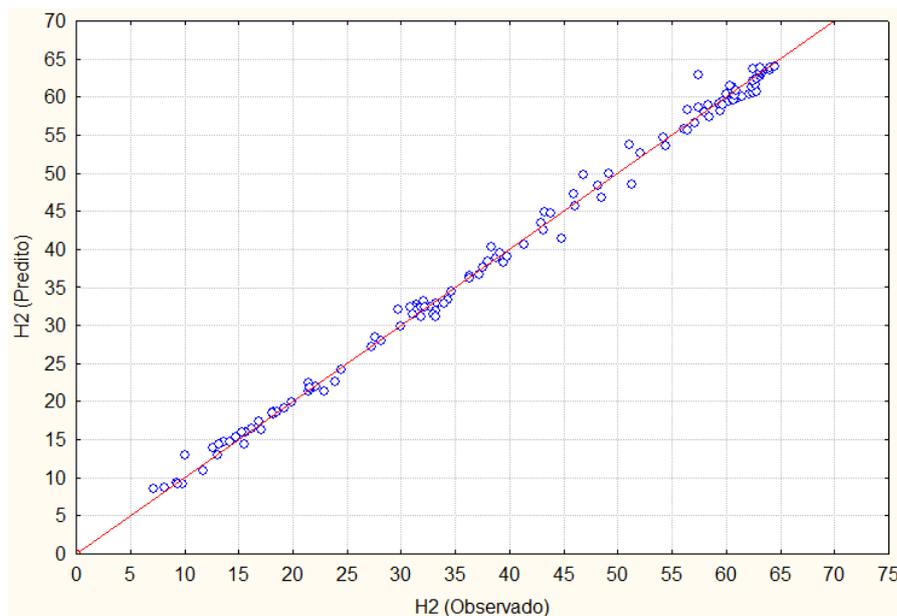


Figura 10 – Gráfico saída de H2 predito X observado (9 entradas)

6.1.2 Redes com 8 variáveis

Foram feitos três treinamentos utilizando oito parâmetros de entrada. Desconsiderando os voláteis ou cinzas ou H, presentes na biomassa.

A Figura 11 mostra as redes retidas, com melhor desempenho, para o caso dos parâmetros voláteis, cinzas, umidade, C, O, RE, S/B e temperatura, ou seja, em relação ao treinamento anterior foi retirado apenas o H. Neste caso, a rede #8, MLP 8-7-1 foi a escolhida por seu desempenho, com coeficiente de correlação de 0,998 e sete neurônios na camada escondida. A soma dos pesos e *biases* desta rede foram de 1,36.

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 8-12-1	0.996386	0.999186	BFGS 63	SOS
2	#2	MLP 8-10-1	0.998400	0.998878	BFGS 68	SOS
3	#3	MLP 8-11-1	0.998662	0.998828	BFGS 122	SOS
4	#4	MLP 8-11-1	0.998592	0.998716	BFGS 94	SOS
5	#5	MLP 8-8-1	0.998481	0.999016	BFGS 108	SOS
6	#6	MLP 8-12-1	0.996054	0.998698	BFGS 47	SOS
7	#7	MLP 8-11-1	0.998394	0.999073	BFGS 79	SOS
8	#8	MLP 8-7-1	0.998117	0.998881	BFGS 79	SOS
9	#9	MLP 8-7-1	0.997417	0.999075	BFGS 77	SOS
10	#10	MLP 8-9-1	0.998891	0.998936	BFGS 135	SOS

Figura 11 - Resultado do treinamento com 8 variáveis, sem H

O outro treinamento considerando apenas oito parâmetros foi feito desconsiderando apenas a quantidade de cinzas presente na biomassa (Figura 12). O

melhor desempenho observado foi da rede MLP 8-5-1, com coeficiente de correlação de 0.998 e a soma dos pesos e *biases* foi de 11,60.

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 8-8-1	0.998128	0.998696	BFGS 73	SOS
2	#2	MLP 8-11-1	0.998623	0.998862	BFGS 110	SOS
3	#3	MLP 8-8-1	0.997926	0.998618	BFGS 89	SOS
4	#4	MLP 8-7-1	0.994991	0.998744	BFGS 63	SOS
5	#5	MLP 8-6-1	0.997914	0.998730	BFGS 62	SOS
6	#6	MLP 8-8-1	0.997113	0.998986	BFGS 66	SOS
7	#7	MLP 8-12-1	0.996627	0.999053	BFGS 37	SOS
8	#8	MLP 8-5-1	0.997966	0.998903	BFGS 90	SOS
9	#9	MLP 8-12-1	0.998704	0.998565	BFGS 103	SOS
10	#10	MLP 8-5-1	0.997472	0.998558	BFGS 86	SOS

Figura 12 - Resultado treinamento, sem cinzas

O ultimo treino das 100 redes, com 8 entradas apenas, foi realizado sendo excluído apenas os voláteis das variáveis. A rede #1, MLP 8-5-1 apresentou um coeficiente de correlação muito bom, 0.999, com apenas 5 neurônios intermediários. Nesta rede o somatório dos pesos e *biases* foi 3,26 (Figura 13).

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 8-5-1	0.998675	0.998946	BFGS 197	SOS
2	#2	MLP 8-7-1	0.998932	0.998717	BFGS 136	SOS
3	#3	MLP 8-11-1	0.998557	0.998982	BFGS 88	SOS
4	#4	MLP 8-9-1	0.998169	0.998538	BFGS 96	SOS
5	#5	MLP 8-9-1	0.998558	0.998814	BFGS 99	SOS
6	#6	MLP 8-9-1	0.998546	0.998717	BFGS 95	SOS
7	#7	MLP 8-7-1	0.997457	0.998557	BFGS 52	SOS
8	#8	MLP 8-9-1	0.998527	0.998704	BFGS 89	SOS
9	#9	MLP 8-9-1	0.998491	0.998793	BFGS 79	SOS
10	#10	MLP 8-5-1	0.998444	0.998559	BFGS 89	SOS

Figura 13 - Resultado treinamento, sem voláteis

Do ponto de vista estatístico, as redes tiveram desempenho semelhante. O que as diferenciou foi a quantidade de neurônios envolvidos. Como um critério de escolha para posterior análise leva-se em conta a camada intermediária, optou-se pela rede que desconsiderou os voláteis para ser usada para posterior análise. Esta será referida como MLP 8-5-1 apenas, a partir de agora.

6.1.3 Redes com 7 variáveis

Considerando apenas sete parâmetros de entrada, foram realizados 300 treinos. Sendo 100 para a rede com as variáveis H e voláteis desconsideradas, 100 para H e cinzas desconsideradas e 100 para cinzas e voláteis desconsiderados no treino.

Das 10 redes retidas após treino de 100 redes, retirando dos mesmos o H da composição da biomassa e voláteis, a rede MLP 7-5-1, #4, foi a que teve melhor

desempenho em termos de tamanho e dados estatísticos. A soma dos pesos e *biases* foram de -6,39 e o coeficiente de correlação de 0,99 (Figura 14).

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 7-9-1	0.998673	0.998804	BFGS 130	SOS
2	#2	MLP 7-6-1	0.997979	0.998648	BFGS 59	SOS
3	#3	MLP 7-8-1	0.998455	0.998269	BFGS 107	SOS
4	#4	MLP 7-5-1	0.994648	0.998594	BFGS 48	SOS
5	#5	MLP 7-8-1	0.998719	0.998804	BFGS 146	SOS
6	#6	MLP 7-7-1	0.998802	0.998630	BFGS 155	SOS
7	#7	MLP 7-7-1	0.995675	0.998419	BFGS 88	SOS
8	#8	MLP 7-11-1	0.998401	0.998685	BFGS 87	SOS
9	#9	MLP 7-9-1	0.997209	0.998609	BFGS 65	SOS
10	#10	MLP 7-10-1	0.998543	0.998611	BFGS 139	SOS

Figura 14 - Resultado treinamento com 7 variáveis, sem H e voláteis

Para as redes treinadas desconsiderando o H e as cinzas como variáveis de entrada, a rede #7, MLP 7-4-1 foi selecionada por seu melhor desempenho, conforme a Figura 15. Com coeficiente de correlação de 0.996 e 4 neurônios intermediários, obteve uma soma de pesos e *biases* de -2,88.

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 7-7-1	0.998336	0.998634	BFGS 154	SOS
2	#2	MLP 7-11-1	0.997038	0.998786	BFGS 43	SOS
3	#3	MLP 7-8-1	0.995868	0.998700	BFGS 58	SOS
4	#4	MLP 7-10-1	0.990889	0.998593	BFGS 32	SOS
5	#5	MLP 7-9-1	0.994096	0.998823	BFGS 46	SOS
6	#6	MLP 7-6-1	0.998066	0.998966	BFGS 133	SOS
7	#7	MLP 7-4-1	0.996916	0.998639	BFGS 86	SOS
8	#8	MLP 7-11-1	0.994593	0.999083	BFGS 52	SOS
9	#9	MLP 7-9-1	0.992731	0.999002	BFGS 55	SOS
10	#10	MLP 7-6-1	0.995087	0.998801	BFGS 87	SOS

Figura 15 - Resultado treinamento, sem H e cinzas

No caso do treino das 100 redes que retiraram dos parâmetros de entrada as variáveis voláteis e cinzas, a rede # 7, MLP 7-7-1 apresentou o melhor desempenho. Teve coeficiente de correlação de 0,99 e soma dos pesos e *biases* de -3,05 (Figura 16).

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 7-11-1	0.997956	0.998692	BFGS 65	SOS
2	#2	MLP 7-8-1	0.998810	0.998807	BFGS 282	SOS
3	#3	MLP 7-7-1	0.998044	0.998465	BFGS 48	SOS
4	#4	MLP 7-10-1	0.996574	0.998244	BFGS 60	SOS
5	#5	MLP 7-12-1	0.998156	0.998377	BFGS 41	SOS
6	#6	MLP 7-7-1	0.997725	0.998337	BFGS 61	SOS
7	#7	MLP 7-7-1	0.998681	0.998585	BFGS 97	SOS
8	#8	MLP 7-8-1	0.997711	0.998311	BFGS 100	SOS
9	#9	MLP 7-9-1	0.997877	0.998801	BFGS 50	SOS
10	#10	MLP 7-12-1	0.997616	0.998543	BFGS 47	SOS

Figura 16 - Resultado treinamento, sem cinzas e voláteis

Como o desempenho destas redes não foi alterado do ponto de vista estatístico (assim como aconteceu com 8 entradas) selecionou-se a melhor rede como aquela com menores quantidades de variáveis na camada escondida. A rede MLP 7-4-1, que desconsiderou H e cinzas no treino, foi escolhida para comparação com os demais casos.

6.1.4 Rede com 6 variáveis

Das 100 redes treinadas foram retidas as seguintes:

Index	Net. ID	Net. name	Training perf.	Test perf.	Algorithm	Error
1	#1	MLP 6-9-1	0.998368	0.998455	BFGS 107	SOS
2	#2	MLP 6-7-1	0.998100	0.999014	BFGS 60	SOS
3	#3	MLP 6-11-1	0.997805	0.999088	BFGS 56	SOS
4	#4	MLP 6-11-1	0.998269	0.998823	BFGS 96	SOS
5	#5	MLP 6-9-1	0.996722	0.998556	BFGS 122	SOS
6	#6	MLP 6-7-1	0.998195	0.998866	BFGS 74	SOS
7	#7	MLP 6-7-1	0.996091	0.998834	BFGS 64	SOS
8	#8	MLP 6-10-1	0.997054	0.998484	BFGS 53	SOS
9	#9	MLP 6-7-1	0.996569	0.998685	BFGS 119	SOS
10	#10	MLP 6-10-1	0.996908	0.998526	BFGS 59	SOS

Figura 17 – Resultado treinamento com 6 variáveis

Com base no erro analisado nos testes e levando-se em consideração a rede formada mais simples, foi selecionada a rede #6, uma rede MLP 6-7-1 com correlação de 0.998 no treino. Dentre as duas redes mais simples, com 7 neurônios na camada escondida, a rede #6 apresentou um coeficiente de correlação maior que a #2 e #7 (0,998). Nesta rede a soma dos pesos e *biases* foram de -8,45.

Estes foram os últimos treinos realizados, já que consideram o mínimo possível de parâmetros de entrada que representam o modelo.

6.2 ANÁLISE DE REDE COM DADOS DE BAGAÇO DE CANA

Tendo sido escolhidas as redes, foram selecionados os dados referentes apenas ao bagaço (ANEXO 2). Assim, analisou-se se para cada caso a rede que seria adequada para os 12 casos presentes.

6.2.1 Rede com 9 variáveis

A rede apresentou um bom desempenho, apesar de ter sido menor do que o obtido com todos os dados. O coeficiente de correlação resultante foi de 0,982, ao invés

de 0.997, entre os dados observados e os dados preditos. A Figura 18 mostra a comparação entre os dados preditos e os observados.

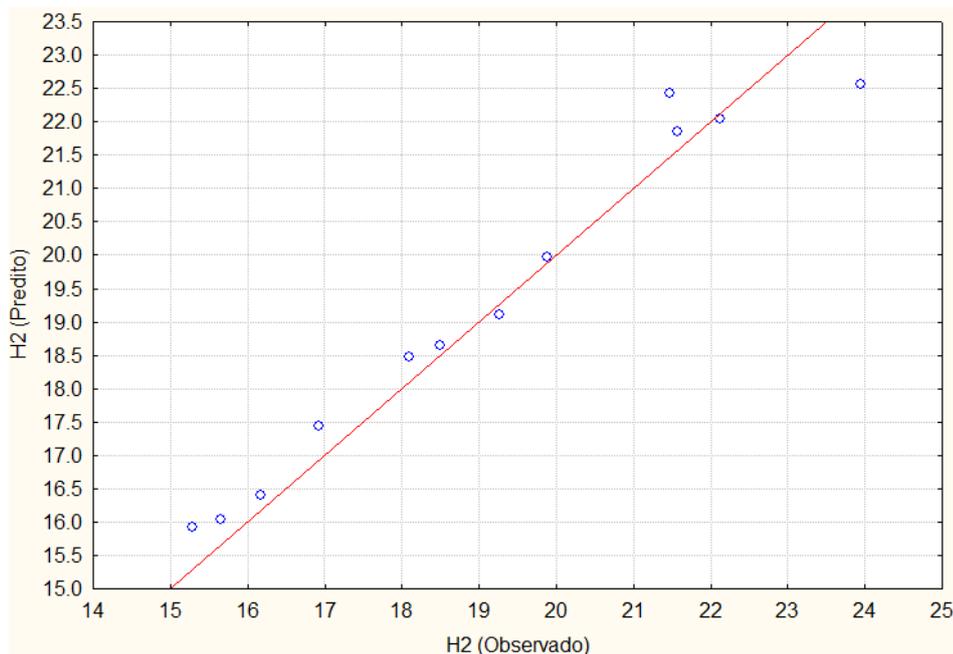


Figura 18 – Modelo 9 variáveis: H₂ saída predito X observado

A partir da rede treinada e da validação que é necessária para a predição de um modelo, foram analisados 3 gráficos, nos quais foram ajustados os parâmetros operacionais da gaseificação (Temperatura, RE e S/B) em função da otimização da produção de H₂.

Os gráficos gerados, com um dos eixos sendo o S/B, tiveram que ser dispensados em sua forma 3D, já que os dados de biomassa da literatura continham apenas exemplos de gaseificação usando o ar como agente, o qual tem a relação S/B igual a zero. Todos os pontos estão em um plano S/B = 0.0. Desta forma, não faz sentido utilizar na análise este parâmetro.

A relação entre estas variáveis de entrada e saída estudada não é linear, sendo assim, criou-se um novo modelo através das redes neurais. Nesse caso, as variáveis analisadas são T e RE, e seu comportamento em relação à produção de H₂. Abrangendo os valores para o modelo criado pela rede neural escolhida nos treinamentos realizados, temos o seguinte modelo, representado pela Figura 19:

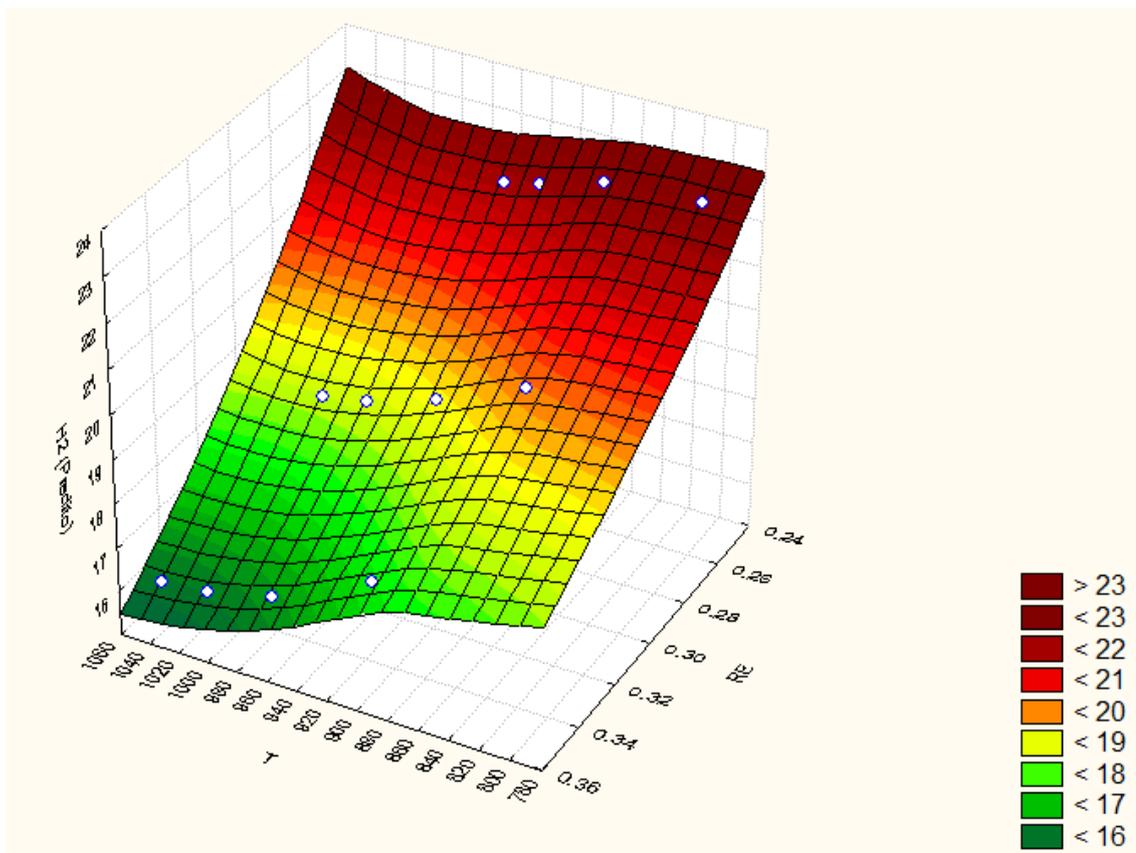


Figura 19 – Gráfico RE x T x H2 previsto: 9 variáveis

Percebe-se pelas curvas de níveis do modelo criado que a região representada pela cor mais escura, como mostrado em destaque (Figura 20), é a que representa os maiores valores em porcentagem de produção de H₂, ou seja, maiores que 23%. Esta região apresenta valores de RE entre 0.26 e 0.24 e temperaturas variando de 780°C a 940°C. Podemos verificar, então, que tendo como faixa de trabalho a faixa apresentada nos dados, as melhores condições operacionais para maximizar o H₂ seriam os menores valores de RE e temperatura, na faixa citada.

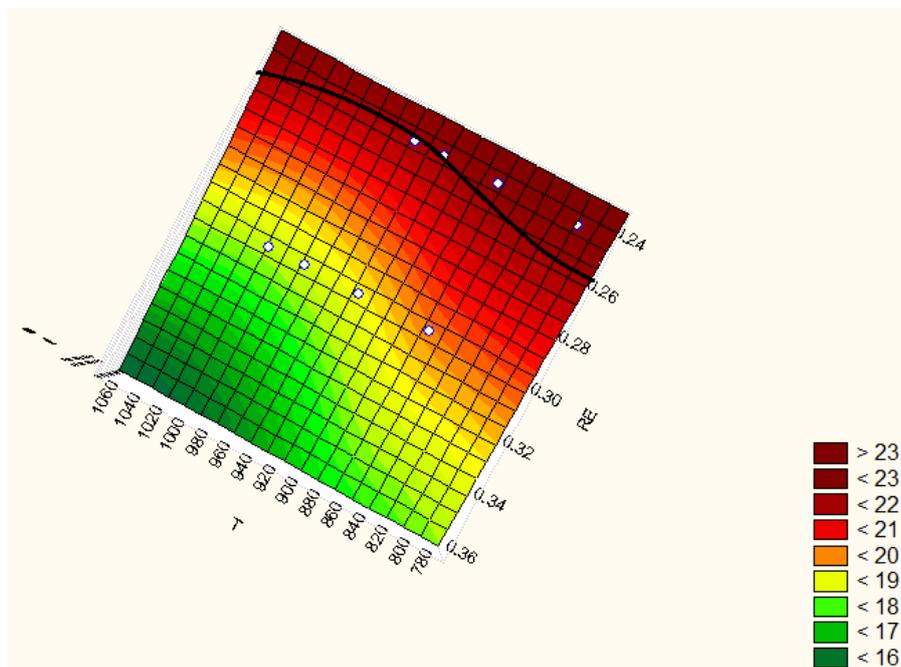


Figura 20 – Vista superior da Figura 18, com área de análise em destaque

6.2.2 Rede com 8 variáveis

A rede escolhida com 8 parâmetros de entrada para análise dos dados apenas do bagaço foi a MLP 8-5-1, que desconsidera os voláteis. Esta apresentou um bom desempenho para os dados de bagaço, com coeficiente de correlação de 0,955, apesar de ter sido menor do que o obtido com todos os dados, de 0,998. A Figura 21 mostra a comparação entre os dados preditos e os observados de H_2 para este caso.

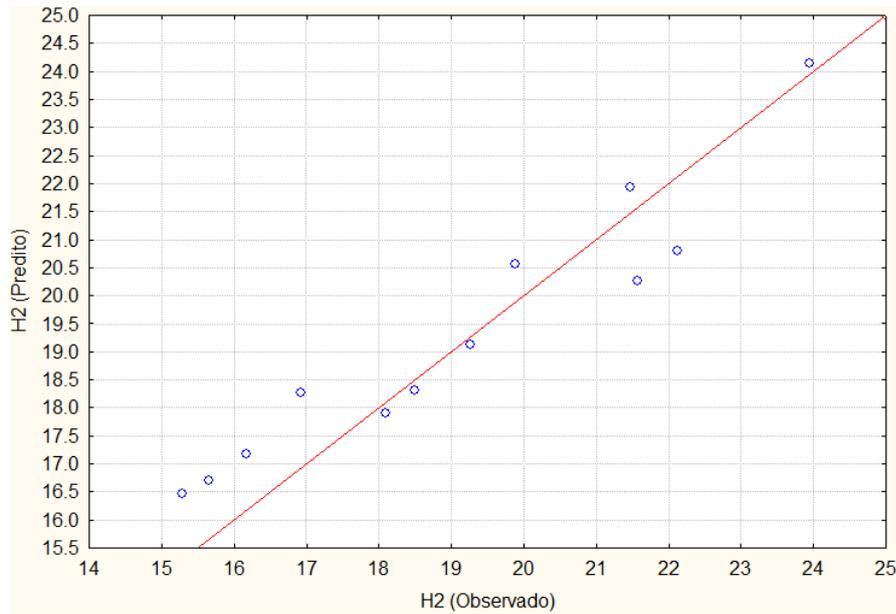


Figura 21 – Modelo 8 variáveis: H₂ saída predito X observado

A partir da rede treinada e da validação, foi analisado o gráfico 3D (Temperatura, RE e H₂) em função da otimização da produção de H₂. Como visto anteriormente, o parâmetro S/B não foi levado em consideração para esta análise, pois seu valor é constante e igual a zero no caso em análise.

A relação entre estas variáveis de entrada e saída estudada não é linear, sendo assim, criou-se um novo modelo através das redes neurais que correlaciona as variáveis operacionais à saída desejada. Abrangendo os valores para o modelo criado pela rede neuronal escolhida nos treinamentos realizados, tem-se o seguinte modelo, representado pela Figura 22.

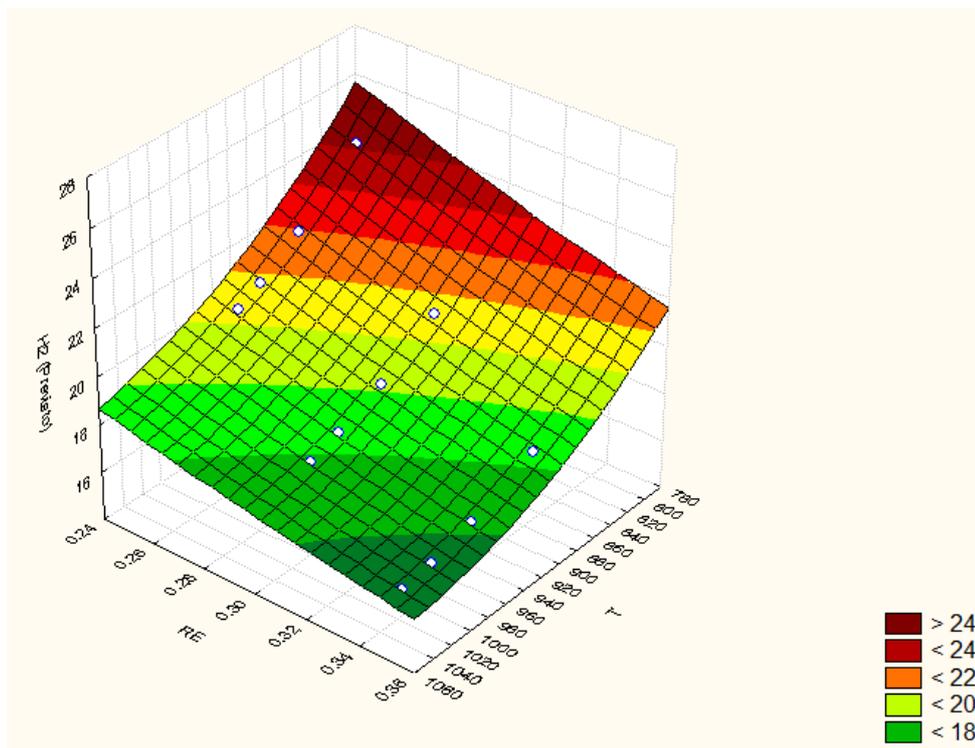


Figura 22 - Gráfico RE X T X H₂ previsto: 8 variáveis

Percebe-se pelas curvas de níveis do modelo criado que a região representada pela cor mais escura, como mostrado em destaque (Figura 23), é a que representa os maiores valores em percentagem de produção de H₂, ou seja, maiores que 23%. Esta região apresenta valores de RE entre 0.26 e 0.24 e temperaturas menores que 800°C. Podemos verificar, então, que tendo como faixa de trabalho a faixa apresentada nos dados, as melhores condições operacionais para maximizar o H₂ seriam os menores valores de RE e temperatura, na faixa citada.

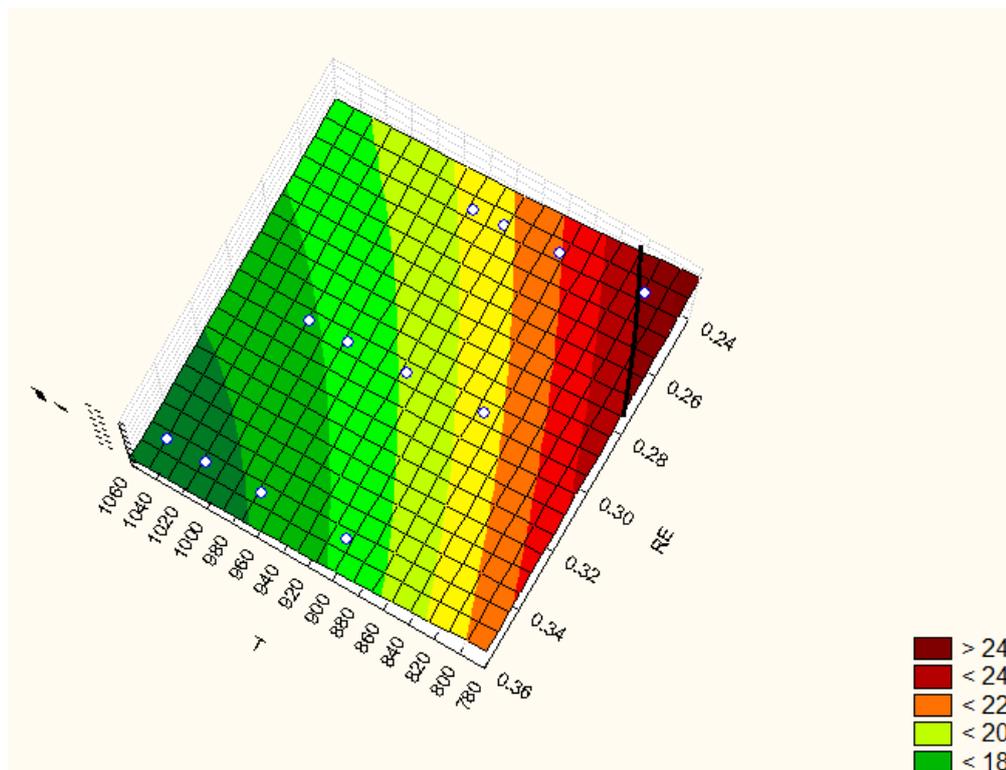


Figura 23 – Vista superior Figura 21

6.2.3 Rede com 7 variáveis

A rede MLP 7-4-1 foi a selecionada para análise dos dados de bagaço. Esta desconsiderou os parâmetros cinzas e H, e apresentou um bom desempenho para os dados de bagaço, com coeficiente de correlação 0,975, apesar menor do que o obtido com todos os dados, de 0,997. A Figura 24 mostra a comparação entre os dados preditos e os observados de H_2 para este caso.

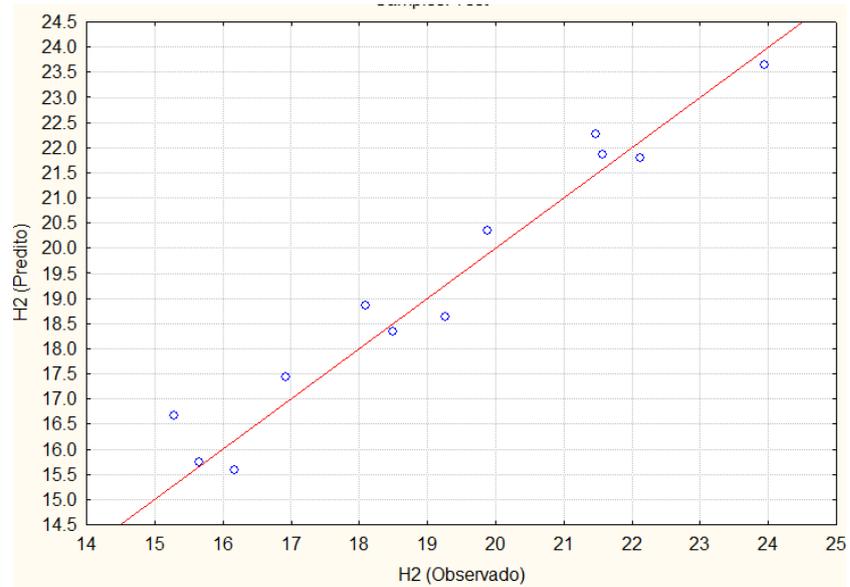


Figura 24 – Modelo 7 variáveis: H₂ saída predito X observado

Assim como feito nos casos anteriores, a partir da rede treinada e da validação, foi analisado o gráfico 3D (Temperatura, RE e H₂) em função da otimização da produção de H₂, desconsiderando o S/B.

Como a análise não pode ser feita de forma isolada, já que se têm dois parâmetros operacionais importantes, será realizada uma análise do gráfico do modelo como um todo. O modelo criado pela rede neural escolhida nos treinamentos realizados, gera o seguinte modelo, representado pela Figura 25:

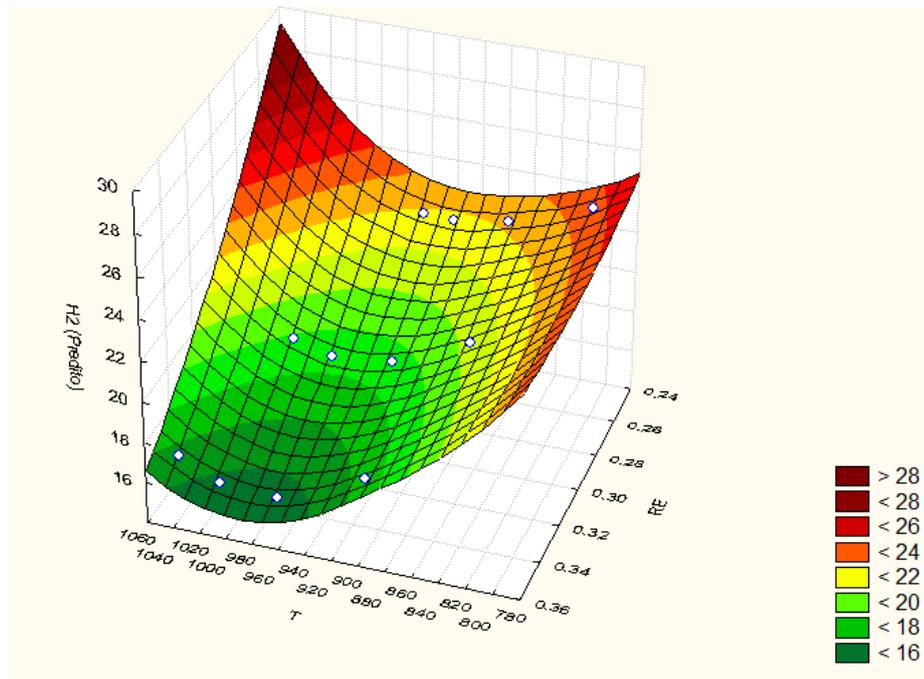


Figura 25 - Gráfico RE x T x H₂ previsto: 7 variáveis

As curvas de níveis do modelo criado mostram que a região representada pela cor mais escura é a que representa maiores valores de saída de H₂, sendo estes maiores que 28% da composição do gás de saída (Figura 26). Apesar das temperaturas menores, contidas na amostragem dos pontos, representarem as maiores quantidades de H₂, no modelo criado prevê-se que a região com maiores temperaturas seriam as que apresentariam esta tendência. Este modelo, em relação à temperatura, não está de acordo com os anteriores, que mostram as baixas temperaturas como os pontos ótimos. Em relação ao RE, o gráfico mostra o mesmo que os anteriores, ou seja, que as menores faixas são as que correspondem ao ponto ótimo.

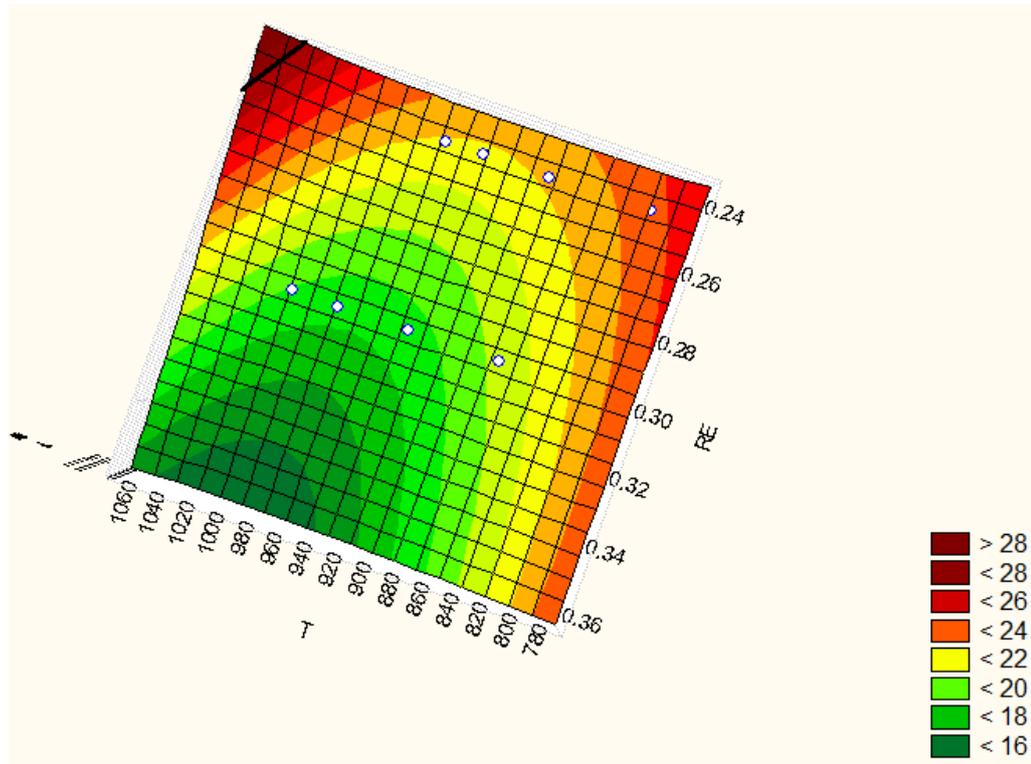


Figura 26 – Vista superior Figura 25

Porém, aumentando o intervalo de aplicação do modelo para temperaturas menores, percebemos que este mostra duas áreas diferentes de otimização. Nesta extrapolação do modelo, vemos que as menores temperaturas, menores que 780°C, também apresentam pontos ótimos (Figura 27).

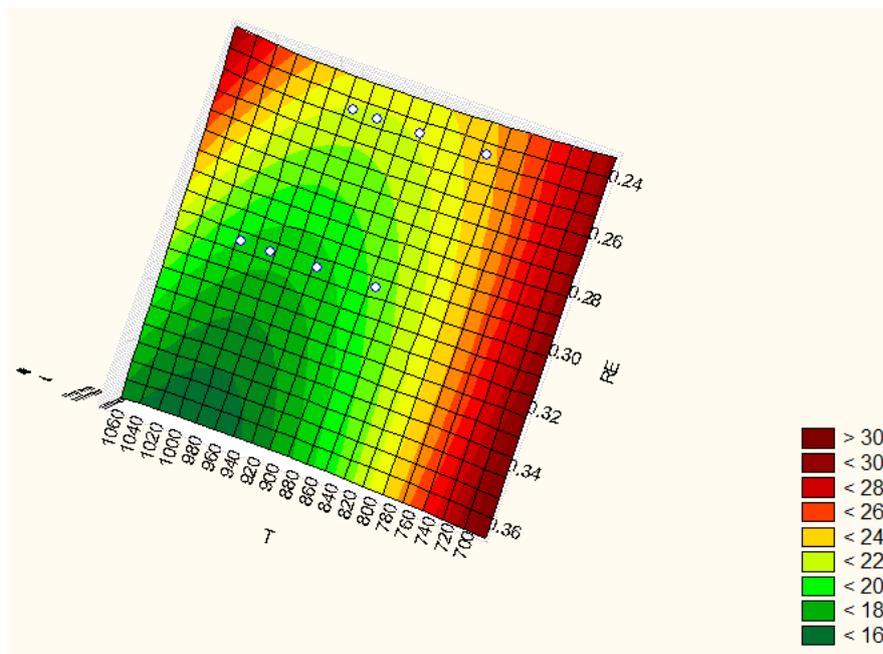


Figura 27 - Extrapolação do modelo para temperaturas até 700°C

6.2.4 Rede com 6 variáveis

O último modelo de redes treinadas foi a que apresentou o menor número de parâmetros possível, seis. A rede escolhida com 6 parâmetros de entrada para análise dos dados apenas de bagaço foi a MLP 6-7-1, que desconsidera os voláteis, cinzas e porcentagem de H na composição da biomassa. Esta apresentou um bom coeficiente de correlação para os dados de bagaço, 0,998, apesar deste ser menor do que o obtido com todos os dados, 0,974. A Figura 28 mostra a comparação entre os dados preditos e os observados de H_2 para este caso.

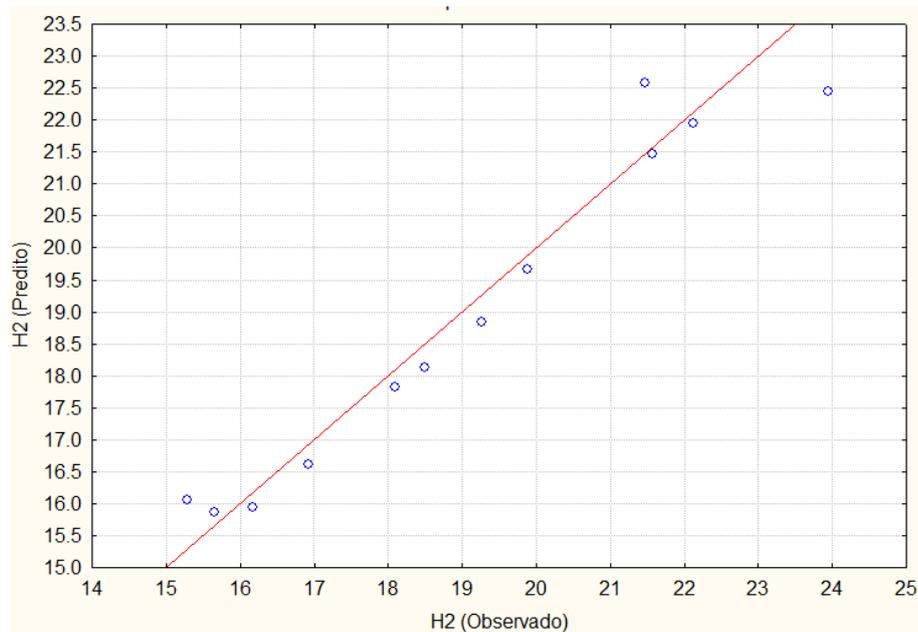


Figura 28 - Modelo 6 variáveis: H₂ saída predito X observado

O modelo criado através das redes neurais gerou o gráfico que foi analisado, considerando os dois parâmetros. Pela análise do gráfico perceberam-se resultados semelhantes aos anteriores.

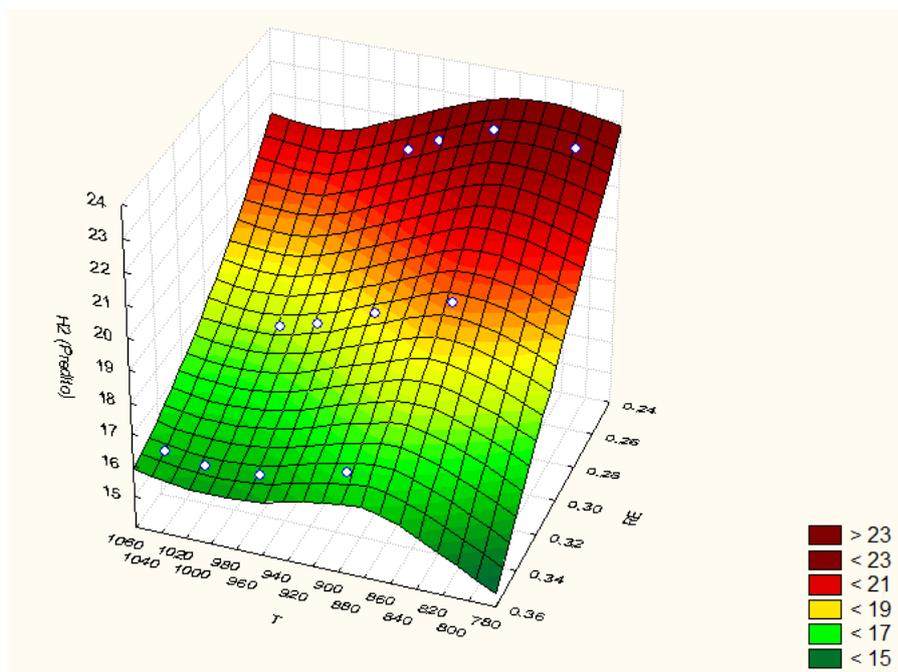


Figura 29 – Gráfico RE X T X H₂ previsto: 6 variáveis

Analisando a parte destacada da Figura 30 vemos que a região de temperaturas menores que 940°C e RE menor que 0,25 é a área que apresenta a maior produção de H₂

previsto no gás de saída, com valores maiores que 23%. O resultado para 6 parâmetros de entrada se assemelha aos anteriores.

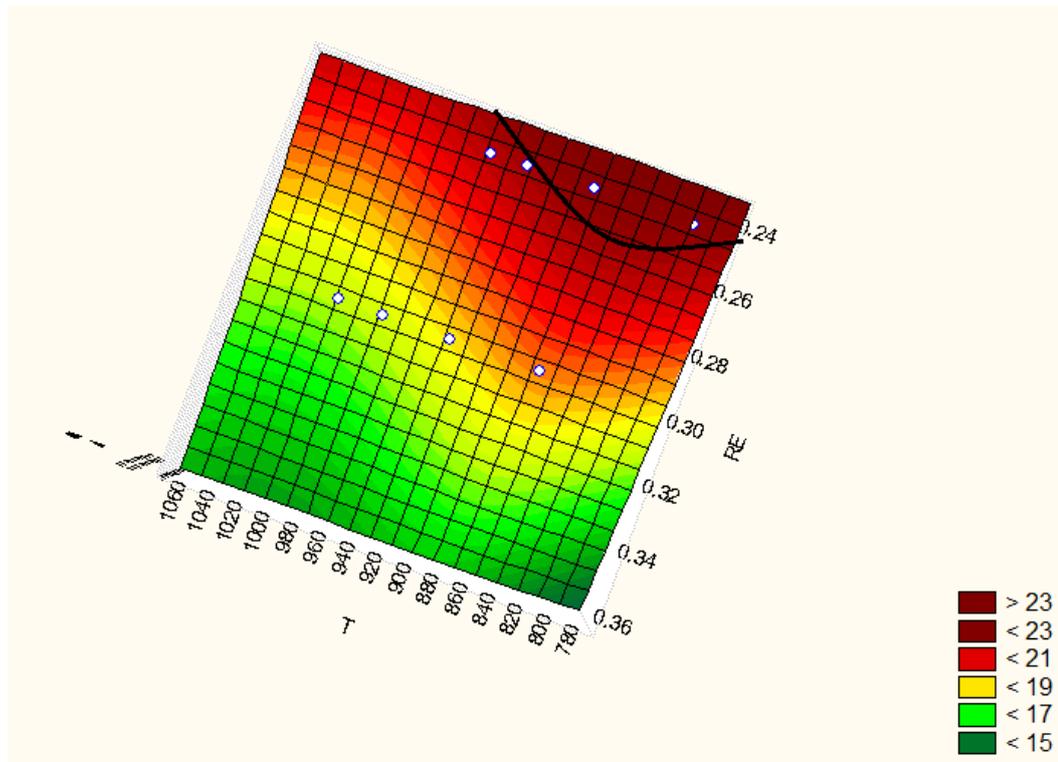


Figura 30 – Vista superior Figura 29

6.3 ANÁLISE DE TODAS AS REDES

Considerando todos os modelos criados e todos os treinamentos feitos em termos de modificação do número de parâmetros, percebemos que todos tiveram semelhança em relação ao comportamento estatístico e também em relação ao resultado mostrado. Ambos os modelos apresentaram correlações maiores que 0,97, ou seja, puderam representar bem o gaseificador e a produção estimada de hidrogênio gasoso.

Em todos os casos as regiões com menores valores de RE foram as que apresentaram maiores valores de produção de H₂, combinada com a região de menores temperaturas.

Podemos sumarizar que o ponto ótimo para a produção é com RE < 0,25 e T < 800 (Tabela 3).

Tabela 3 - Resultados

	% H2 saída	Faixa T (°C)	RE
9 variáveis	> 23	> 780	0,24 – 0,26
8 variáveis	> 24	780 - 840	0,24 – 0,26
7 variáveis	> 28	< 740* ou >1060	0,24 – 0,26
6 variáveis	> 23	780 - 940	< 0,25

Este resultado contradiz o que encontra-se na literatura sobre o assunto, onde as temperaturas mais altas possuem o maior resultado. O trabalho apresentado mostra que este valor seria menor que 800°C. Isso deve ter ocorrido, pois o programa não extrapola resultados e os dados de bagaço que foram utilizados para a análise possuem uma faixa pequena de temperatura..

7 CONCLUSÃO

Com os resultados obtidos no presente trabalho, foram obtidas as seguintes conclusões:

- 1) Como o desempenho das redes está ligado à quantidade de dados e variedade de padrões usados no treinamento, é necessário levantar muitos dados da literatura, para se evitar o sobreajuste.
- 2) As redes neuronais são eficientes para obtenção de modelos e de pontos ótimos de operação de processos como os de gaseificação, os quais são complexos e não-lineares.
- 3) As redes neuronais tem bons resultados apenas para a faixa de dados de entrada, não permitindo boa extrapolação.
- 4) A conclusão não condiz com o que se observa em outros trabalhos analisados.
- 5) A análise gráfica permite uma avaliação simples e pode ser feita para combinação das diversas variáveis que se quer maximizar ou analisar.

Como sugestões para trabalhos futuros pode-se citar:

- Aumentar a base de dados para o bagaço de cana;
- Implementar algoritmos de otimização numérica;
- Buscar dados que validem os resultados da otimização;
- Realizar o mesmo estudo para outros gases
- Realizar o mesmo tipo de estudo para minimizar alcatrão, o que é um problema nas plantas de gaseificação de biomassa;
- Comparar o modelo de redes neuronais com outros tipos de modelos.

8 BIBLIOGRAFIA

BASU, P. (2006).; Combustion and gasification in fluidized beds. Taylor & Francis Group. Castro, M. (2007). Redes Neurais Artificiais. PUCRS

BELGIORNO, V.; DE FEO, G.; DELLA ROCCA, C.; NAPOLI, R. M. A.; Energy from gasification of solid wastes, *Waste Management*, v.23, n.1, p.1-15, 2003.

BHAGAR, P.. An introduction to neural nets. Chemical engineering progress 86.8 (1990): 55-60.

CASTRO, A.J.A.; CASSIANO, D.A.; FERREIRA, N.L. Gaseificação de bagaço de cana-de-açúcar: modelagem, análise e comparação com sistema real. Exacta, São Paulo, v.7, n.1, p. 39-47, jan./mar. 2009.

CASTRO, M.F; Redes Neurais Artificiais, Mestrado em Engenharia Elétrica, PUCRS, 2001

CHITRA, S.P. (1992) Neural Network Applications in Chemical Engineering. AI Expert, pp. 20-25 (November 1992) e Neural Network Special Report, (Miller-Freeman, Inc.).

COELHO, S. T. *et al.*; Geração de energia elétrica para comunidades isoladas da região Amazônica a partir de sistemas de gaseificação de biomassa. Congresso Internacional de Bioenergia. 2004.

CORTEZ, P.; NEVES, J..; Redes Neurais Artificiais. Universidade do Minho, Braga, Portugal, 2000.

C. MARCHETTI; N. NAKICENOVIC; The dynamics of energy systems and the logistic substitution model, International Institute for Applied System Analysis, Austria.

DE SOUZA JR., M. (2005).; Redes Neurais Artificiais na Engenharia Química. *Apostila*. Rio de Janeiro, Brasil.

De SOUZA JR., M., BARRETO JR., A. (2009). Investigação da Correlação entre as Características da Biomassa e o Produto Final dos Processos de Gaseificação Através do Uso de Redes Neurais Multicamadas. 1º Relatório Parcial. Projeto/Programas Específicos em P&D em Energia: Biocombustíveis

EPE-EMPRESA DE PESQUISA ENERGÉTICA, Balanco Energético Nacional 2012: Ano Base 2011. Rio de Janeiro, 2012

FERNANDES E.; MARQUES V.; PIMENTA C.; *et al.* Energias Renováveis - Portugal, 2009.

GUALDRÓN, M. A. M. (2009), Projeto e Avaliação Computacional do Desempenho de um Gaseificador de Leito Fluidizado Circulante para Obtenção de Gás de Síntese a partir de Bagaço de Cana de Açúcar, Itajubá, 144p. Dissertação (Mestrado em Conversão de Energia) - Instituto de Engenharia Mecânica, Universidade Federal de Itajubá.

HENRIQUES, R.M.; Potencial para Geração de Energia Elétrica no Brasil com Resíduos de biomassa através da Gaseificação / Rachel Martins Henriques. – Rio de Janeiro: UFRJ/COPPE, 2009.

HIGMAN C; VAN DER BURGT M.; Gasification. Amsterdam: Gulf Professional Publishers/Elsevier Science. 2008

KRAUSE, G.G., Avaliação da Tecnologia de Sistemas Integrados Gaseificação – Ciclo Combinado para geração termelétrica no Brasil. Dissertação de mestrado. PPE/COPPE/ UFRJ. Rio de Janeiro, 1990

LAGO, A.; PÁDUA, J.A.; O que é Ecologia, Brasiliense, 1984

MCKENDRY, P. (2002). Energy production from biomass (part 3): gasification technologies. *Bioresource Technology* 83, pp. 55-63.

NEMER, L.. Modelagem do processo de gaseificação de biomassa empregando redes neurais. Rio de Janeiro. UFRJ/EQ, 2010.

NEVES; J. *et al.* Redes Neurais Artificiais. Escola de Engenharia da Universidade do Minho, 2000.

NOGUEIRA, L. *et al.* Dendroenergia: fundamentos e aplicações – Brasília: ANEEL, 2000.

OLIVEIRA, R.A.F.D. A geração de Energia Elétrica através do uso de biomassa na Bahia: Condicionantes e Oportunidades/ Tese de Mestrado – UNIFACS. Salvador, 2006.

PEREIRA, EMANUELE GRACIOSA, *et al.* Sustainable energy: A review of gasification technologies. *Renewable and Sustainable Energy Reviews* 16.7 (2012): 4753-4762.

PIFFER, L., Análise Paramétrica de um Gaseificador de Resíduos de Madeira. Monografia. Departamento de Engenharia Química, Universidade de Caxias do Sul, Dezembro, 1999.

SACHS, I. Caminhos para o Desenvolvimento Sustentável. Editora Garamond, Rio de Janeiro, RJ, 2000.

StatSoft STATISTICA 8.0.360 - English Edition, Enterprise Single User

SWINGLE, K., Applying neural networks: a practical guide (2001).

TICIANELÜ, EDSON A.; ERNESTO R. Gonzalez.; Células a combustível: uma alternativa promissora para a geração de eletricidade. *Química Nova* 12.3 (1989): 11989.

VIELSTICH, W.; LAMM, A.; GASTEIGER, H. A.; Handbook of fuel cells - fundamentals, technology and applications, v. 1, Inglaterra, John Wiley & Sons Ltd, 2003

VILLAMIL CATELLANOS, ANDRÉS BERNARDO, Análise Unidimensional Detalhada da Gaseificação de Bagaço de Cana em Reator de Leito Fluidizado Borbulhante Dissertação de mestrado Programa de Engenharia Mecânica/COPPE/UFRJ. – Rio de Janeiro, 2012.

XIAO, J.; GAO, Y.; SHEN, L.; Simulation of hydrogen production of biomass gasification in interconnected fluidized beds – China, 2007.

XIAO, G, Ni, M.; Jin, B.; Gasification characteristics of MSW and na ANN prediction model. – China, 2008.

YEGNANARAYANA, B; Artificial Neural Networks – India, 2006

ANEXO 1

Biomassa	Agente de gaseificação	Umidade	Cinzas	Voláteis	C	H	O	RE	S/B	T	H ₂
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	88,01	6,04	45,43	0,18	1,40	750	31,40
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,18	1,40	800	37,20
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,18	1,40	850	38,80
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,18	1,40	900	38,30
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,18	1,40	950	44,80
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,37	1,70	850	27,60
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,28	1,70	850	34,30
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,43	0,18	1,70	850	39,10
Madeira	Vapor + Oxigênio	7,50	0,32	76,78	48,01	6,04	45,3	0,09	1,70	850	43,20
Madeira	Vapor	7,50	0,32	76,78	48,01	6,04	45,43	0,00	1,70	850	46,80
Madeira	Vapor	7,50	0,32	76,78	48,01	6,04	45,43	0,00	1,10	800	46,00
Madeira	Vapor	7,50	0,32	76,78	48,01	6,04	45,43	0,00	1,40	800	48,50
Madeira	Vapor	7,50	0,32	76,78	48,01	6,04	45,43	0,00	1,80	800	51,30
Madeira	Vapor	7,50	0,32	76,78	48,01	6,04	45,43	0,00	2,70	800	54,40
Madeira	Vapor	7,50	0,32	76,78	48,01	6,04	45,43	0,00	4,70	800	57,40
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,70	700	21,48
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,70	750	28,18

Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,70	800	32,10
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,70	850	36,33
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,70	900	39,40
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,19	1,56	800	32,24
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,21	1,56	800	31,13
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,23	1,56	800	31,44
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,25	1,56	800	31,11
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,27	1,56	800	31,86
Serragem de Pinho	Ar	8,00	0,55	82,29	50,54	7,08	41,11	0,22	0,00	800	33,22
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	0,61	800	31,84
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	1,35	800	29,78
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,02	800	30,81
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,22	2,70	800	32,10
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,35	0,00	875	13,63
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,25	0,00	805	15,50
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,20	0,00	732	11,70
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,17	0,00	677	9,86
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,35	0,00	848	12,66
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,25	0,00	820	14,75

Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,20	0,00	693	9,23
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,17	0,00	649	7,11
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,35	0,00	875	14,15
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	,78	44,15	0,25	0,00	782	13,08
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	5,78	44,15	0,20	0,00	685	9,36
Palha de Trigo	Ar	10,50	3,59	77,80	45,97	5,78	44,15	0,17	0,00	661	8,21
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,19	1,56	800	34,00
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,21	1,56	800	32,80
Serragemde Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,23	1,56	800	33,20
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,25	1,56	800	33,00
Serragem de Pinho	Ar + Vapor	8,00	0,55	82,29	50,54	7,08	41,11	0,27	1,56	800	33,20
Casca de Amêndoa	Ar	9,00	26,40	58,80	36,27	3,94	32,38	0,06	0,00	736	21,67
Poda de Noz	Ar	14,30	3,40	80,81	48,20	4,41	44,34	0,09	0,00	744	18,18
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	650	38,03
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	675	42,90
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	700	48,15
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	725	52,10
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	750	56,05
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	775	58,00

Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	800	59,65
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	825	60,00
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	850	60,60
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	875	60,60
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	900	60,30
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,40	800	56,49
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,45	800	57,43
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,50	800	58,37
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,55	800	59,31
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,60	800	60,25
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,65	800	60,57
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,70	800	61,19
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,75	800	61,51
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,80	800	62,13
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,85	800	62,45
Palha (straw)	Vapor	8,50	9,41	71,02	36,57	4,91	40,70	0,00	0,90	800	62,76
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,05	0,00	800	49,21
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,10	0,00	800	45,93
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,15	0,00	800	43,84

Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,20	0,00	800	43,15
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,25	0,00	800	41,34
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,30	0,00	800	39,76
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,35	0,00	800	37,59
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,40	0,00	800	36,29
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,45	0,00	800	34,65
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,50	0,00	800	32,17
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,55	0,00	800	29,91
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,60	0,00	800	27,26
Serragem de Pinh	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,65	0,00	800	24,44
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,70	0,00	800	22,89
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,75	0,00	800	18,19
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,80	0,00	800	17,15
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,85	0,00	800	13,22
Serragem de Pinho	Ar	9,40	0,90	82,00	45,20	5,40	39,00	0,90	0,00	800	10,00
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,11	800	51,05
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,23	800	54,21
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,34	800	56,48
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,45	800	57,14

Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,57	800	58,44
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,68	800	59,44
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,79	800	59,70
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	0,90	800	60,71
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,02	800	60,75
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,13	800	60,90
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,24	800	62,36
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,36	800	62,74
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,47	800	62,42
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,58	800	62,84
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,70	800	63,12
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,81	800	63,31
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	1,92	800	63,16
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	2,03	800	63,08
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	2,15	800	63,99
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	2,26	800	62,49
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	2,37	800	64,09
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	2,49	800	63,15
Serragem de Pinho	Vapor	9,40	0,90	82,00	45,20	5,40	39,00	0,00	2,60	800	64,54

Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	808	23,95
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	872	21,48
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	915	22,12
Bagaco	Ar	,26	6,72	77,99	45,6	5,9	36,8	0,25	0	939	21,58
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	863	19,89
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	923	19,27
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	969	18,5
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	999	18,1
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	902	16,93
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	969	16,17
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	1013	15,65
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	1044	15,28

ANEXO 2

Biomassa	Agente de gaseificação	Umidade	Cinzas	Voláteis	C	H	O	RE	S/B	T	H2
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	808	23,95
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	872	21,48
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	915	22,12
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,25	0	939	21,58
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	863	19,89
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	923	19,27
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	969	18,5
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,3	0	999	18,1
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	902	16,93
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	969	16,17
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	1013	15,65
Bagaco	Ar	4,26	6,72	77,99	45,6	5,9	36,8	0,35	0	1044	15,28