

Sensor virtual para estimação de consistência de pasta termomecânica de celulose

Rodrigo C. M. Matheus
Programa de Pós-Graduação em Engenharia de Produção
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Brasil
rodrigomatheus91@gmail.com

Dra Fernanda Cristina Correa
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Paraná
fernandacorrea@utfpr.edu.br

Dr Sergio Luiz Stevan Jr.
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Paraná
sstevanjr@utfpr.edu.br

Dr Hugo Valadares Siqueira
Programa de Pós-Graduação em Engenharia de Produção
Universidade Tecnológica Federal do Paraná
Ponta Grossa, Paraná
hugosiqueira@utfpr.edu.br

Resumo – No processo de fabricação de papel e celulose a polpação é uma etapa que consiste na separação da celulose dos demais compostos da madeira, o qual pode ser realizado de modo químico ou mecânico. As indústrias de papel e celulose na sua maioria possuem sistemas automatizados para monitoração e controle das variáveis, porém, os valores de alguns parâmetros importantes ainda são obtidos através de testes de laboratório, como a consistência da polpa, a qual refere-se ao percentual de material seco presente em uma amostra de polpa diluída. Considerando-se que a consistência é uma variável dependente de outras variáveis mais facilmente monitoradas no processo, a elaboração de um sensor virtual baseado em redes neurais artificiais (RNAs), pode vir a ser uma alternativa viável para a estimação desta variável de modo contínuo. Neste trabalho três tipos de RNAs são utilizados de modo comparativo para estimar a consistência da celulose obtida através do processo de polpação termomecânica (TMP): Perceptron de Múltiplas Camadas (MLP), rede de Função de Base Radial (RBF), e Máquinas de Aprendizado Extremo (ELM). Os resultados iniciais obtidos mostram que a rede MLP obteve a menor média de erro absoluto percentual em torno de 3,5%, permitindo concluir que as RNAs funcionando como sensores virtuais podem ser ferramentas úteis para a monitoração e controle de processo de produção de TMP.

Palavras-chave – redes neurais artificiais, sensor virtual, pasta termomecânica, estimação, consistência.

I. INTRODUÇÃO

No processo de fabricação de papel e celulose, umas das etapas mais importantes é a polpação, que consiste na separação da celulose dos demais compostos da madeira, este processo pode ser realizado de modo químico ou mecânico, sendo que este último fornece maior rendimento [1]. Os principais processos de polpação utilizados em escala industrial são o processo de polpação termomecânica (TMP), o processo de polpação quimtermomecânica (CTMP) e o processo de polpação química [2].

Em especial, no processo de TMP, a celulose é obtida pela fricção termomecânica através de equipamentos chamados de refinadores [2]. Neste caso o produto é comumente chamado de pasta termomecânica.

Atualmente para a obtenção de uma maior lucratividade e qualidade no processo de produção de celulose, alguns desafios precisam ser superados, como, consumo de energia mais eficiente, diminuição da poluição e fornecimento de uma pasta mais uniforme [3]. Já para garantir o bom funcionamento do processo não são permitidos desvios nas condições de operação, pois pode comprometer a qualidade do produto e gerar perdas [4].

No processo de TMP, além do monitoramento corriqueiro dos parâmetros de instrumentação industrial como pressão, temperatura e vazão, o monitoramento da consistência da pasta é de supra importância para um melhor desempenho do processo [4], através deste parâmetro pode-se evitar produção não-conforme e instabilidade no refinador. Entretanto, este monitoramento muitas vezes é carente de sensores ou técnicas de medição em tempo real, acarretando na necessidade de coletar periodicamente amostras e a realização de ensaios laboratoriais, os quais demandam tempo para apresentarem resultados, desta forma resultando em atuação corretiva sempre em atraso caso os parâmetros apresentem-se fora do padrão desejado.

Pode-se definir consistência como a quantidade de material seco (celulose) presente em uma amostra de polpa diluída [4]. Atualmente existem sensores para medição de consistência, como, o sensor de lâmina estacionária que é baseado na medição da força de cisalhamento que o fluido exerce na lâmina, o sensor óptico e o sensor rotativo [5], entretanto nem sempre estes sensores podem ser utilizados, devido ao valor da consistência da TMP produzida estar fora do range de medição do sensor.

Um exemplo é o sensor de consistência de lâmina estacionária: este sistema é composto pelos seguintes componentes, um elemento sensor (lâmina), um elemento de deslocamento mecânico, conectado à lâmina, e um dispositivo de medição de deslocamento que gera um sinal de saída (consistência medida) [5]. A principal limitação deste sensor é seu range de medição, no qual o desqualifica para medições onde a consistência possui valores superiores a 20%, por exemplo.

Neste caso, o desenvolvimento de sistemas que permitam estimar a consistência em ranges de medição maiores (funcionando como um sensor virtual) permitem *feedback* de consistência em tempo real. Sensores virtuais são sistemas de inferência para estimação de variáveis baseados em informações *on-line* de outros sensores físicos já existentes no processo. Eles podem ser utilizados como uma fonte redundante de informação ou para a antecipação de resultados de testes laboratoriais [6].

Vários sistemas para estimação de consistência têm sido apresentados no meio acadêmico. Kortela [7] apresentou um sistema microprocessado compensador de ruídos, que recebe valores de outras variáveis, como vazão e pressão e através de regressão linear estima a consistência. Zhou *et al.* [5] utilizaram a técnica de decomposição esparsa para filtrar informações contidas no sinal de consistência medido com um sensor de lâmina estacionária, desta forma estimaram um valor mais preciso da consistência.

Recentemente redes neurais artificiais (RNAs) e outros sistemas de inteligência computacional vêm sendo utilizados como sensores virtuais e aplicados na indústria de papel e celulose. Sandkvist [8] utilizou dados de processo de um sistema de refino de celulose para implementar uma RNA que estima dois importantes parâmetros, o teor de fibras longas e o *freeness* (capacidade de drenagem da pasta). Karsimus [9] utilizou redes neurais convolucionais e dados de processo para desenvolver sensores virtuais que medem o *freeness*, e a consistência da polpa de celulose em um sistema de refino.

Nesta perspectiva este trabalho propõe a utilização de redes neurais artificiais para o desenvolvimento de um sensor virtual para a estimação do valor da consistência em um processo de refino de TMP. Para isto cinco variáveis físicas de processo, que se correlacionam com a consistência, são utilizadas como entradas da rede. Três tipos de rede são utilizados, a MLP, a RBF e a ELM, ao final os resultados dos testes são apresentados e discutidos.

O artigo está organizado da seguinte maneira: a Seção II apresenta de forma simplificada conceitos de redes neurais, as métricas utilizadas para avaliação de desempenho das redes e uma equação para cálculo teórico da consistência; a Seção III apresenta os materiais e métodos utilizados; a Seção IV mostra os resultados obtidos; e a Seção V apresenta as conclusões e as considerações finais.

II. REFERENCIAL TEÓRICO

A. Redes Neurais Artificiais

Redes neurais artificiais são algoritmos computacionais inspirados nas redes neurais biológicas e na sua capacidade de aprendizado [10]. Estes algoritmos se tornam inteligentes através da experiência, ou seja, contato e sintetização de informações de seu ambiente [11].

As RNAs têm sido utilizadas para a resolução de problemas em diversas áreas, como: previsão de séries temporais em economia, ecologia e climatologia [12]; indústria de processos [8]; e agricultura [13]. Suas aplicações envolvem classificação de padrões, aproximação universal de funções, previsão de séries temporais, otimização e controle de processos, entre outros [14].

Para o treinamento de uma rede neural é necessária a disponibilização de um conjunto de amostras contendo as características do processo e suas respectivas saídas (aprendizado supervisionado). O treinamento consiste em ajustar os pesos sinápticos para que a saída calculada pela rede tenha valores próximos das saídas desejadas [10].

A fim de se evitar um ajuste excessivo dos dados de treinamento (*overfitting*), que pode ocasionar em uma perda na capacidade de generalização, pode ser utilizada a técnica de validação cruzada, que divide uma parte dos dados para treinamento e outra parte para validação. Isto permite avaliar o desempenho do ajuste de pesos sinápticos para dados não apresentados durante o treinamento.

Dentre os principais tipos de redes neurais pode-se citar o Perceptron de Múltiplas Camadas (MLP, do inglês *Multi Layer Perceptron*), a rede de Função de base Radial (RBF, do inglês *Radial Basis Function*) e as Máquinas de Aprendizado Extremo (ELM, *Extreme Learning Machine*).

B. Perceptron simples e de Múltiplas Camadas

O Perceptron de camada única é a arquitetura mais básica de rede neural. Sua utilização envolve principalmente classificação de sistemas linearmente separáveis. E seu funcionamento se enquadra na categoria de aprendizado supervisionado. Como desvantagem pode-se citar a sua incapacidade de lidar com padrões não-lineares [15].

Em contraste com estas limitações o Perceptron de Múltiplas Camadas, que possui pelo menos uma camada intermediária, possui a capacidade de solucionar diversos problemas, tais como, aproximação universal de funções, classificação de padrões e previsão de séries temporais [11].

O treinamento da rede MLP se dá através da utilização do algoritmo de aprendizado *backpropagation*, um procedimento baseado em gradiente, que ajusta repetitivamente os pesos sinápticos com o objetivo de minimizar a diferença entre a saída real e a saída desejada [15].

C. Redes com Função de Base Radial

As redes com função de base radial são redes *feedforward* de apenas uma camada intermediária. A função de ativação da camada intermediária é do tipo base radial, geralmente gaussiana, e ela realiza um mapeamento não-linear entre as entradas e as saídas da camada intermediária. Já a função de ativação da camada de saída executa um mapeamento linear entre as saídas da camada oculta e as saídas da rede [16].

O treinamento da rede RBF é composto por dois estágios. O primeiro tem a função de calcular os centros e as variâncias da função de base radial. Para este estágio a técnica *k-means* pode ser utilizada, ela é auto-organizada, e tem o objetivo de colocar os centros das funções de base radial nas regiões onde os dados mais relevantes estão presentes [16].

O segundo estágio é supervisionado, neste, os algoritmos da regra delta generalizada ou dos mínimos quadrados médios podem ser utilizados para o ajuste dos pesos sinápticos da camada de saída.

D. Máquinas de Aprendizado Extremo

Máquinas de aprendizado extremo são redes neurais artificiais do tipo *feedforward*, de camada oculta única, e com um tempo de convergência de treinamento bem menor do que outros métodos tradicionais [10]. Este modelo de rede neural foi proposto por Huang, Zhu e Siew [17].

Os algoritmos de treinamento baseados em gradiente são simples de se implementar, porém podem convergir para mínimos locais e dessa forma não apresentar a melhor solução global. A forma como é realizada o treinamento da ELM se propõe a eliminar este problema [10].

Os pesos sinápticos da camada intermediária são gerados aleatoriamente e são mantidos constantes. No processo de treinamento somente os pesos da camada de saída são ajustados [18].

Esse ajuste é realizado através da resolução de um combinador linear, sem a necessidade de iteração, o que faz a rede convergir mais rápido e a torna mais econômica em termos de custo de processamento comparada às outras redes [19].

E. Métricas de avaliação das ferramentas de estimação

As métricas utilizadas para se medir e analisar o desempenho de estimação das redes neste trabalho são o erro quadrático médio (EQM) apresentado na equação (1), o erro percentual absoluto (EPA) apresentado na equação (2), o erro percentual absoluto médio (EPAM) apresentado na equação (3) e a Taxa de acerto apresentada na equação (4):

$$EQM = \frac{1}{n} \sum_{i=1}^n (d_i - y_i)^2 \quad (1)$$

$$EPA = \left| \frac{d_i - y_i}{d_i} \right| * 100 \quad (2)$$

$$EPAM = \frac{1}{n} \sum_{i=1}^n \left(\left| \frac{d_i - y_i}{d_i} \right| * 100 \right) \quad (3)$$

$$Taxa\ de\ acerto\ (\%) = 100 - EPA \quad (4)$$

em que, d_i é o valor real da saída, y_i é a saída computada pela rede, i é o número da amostra e n é o número de amostras.

F. Equação para o cálculo da consistência da TMP

Em uma amostra coletada de pasta termomecânica o cálculo da consistência da polpa pode ser realizado utilizando (5):

$$Cs\ (\%) = \frac{massa\ fibra}{massa\ fibra + massa\ água} * 100 \quad (5)$$

Kortela [7] afirma que a consistência é uma das principais variáveis a ser medida e controlada na indústria de papel e celulose, e que estas medições não são simples, pois a polpa não é um fluido newtoniano e seu comportamento é uma função não linear da taxa de vazão, temperatura, pH, valor absoluto da consistência e qualidade da polpa [7].

III. MATERIAIS E MÉTODOS

A. Descrição do Processo

O refinador é o principal equipamento no processo de fabricação de pasta termomecânica, sua tarefa é triturar cavacos ou fibras de madeira diluídos em água.

De maneira simplificada o refinador é composto por dois discos montados em paralelo, um estacionário e outro rotativo, que é conectado ao eixo do motor principal. Os discos possuem barras milimétricas chamadas de segmentos que tem por objetivo triturar as fibras através do atrito. A distância entre os discos, por onde as fibras são submetidas, é chamada de *gap*. O ajuste do *gap* pode ser feito utilizando um cilindro hidráulico. A pasta é introduzida no refinador através de roscas helicoidais, e a taxa de produção é controlada por meio de instrumentos controladores de vazão de material.

No processo de refino estudado neste trabalho a pasta contida em um tanque de armazenamento é bombeada para uma prensa desaguadora. A pasta que sai da prensa vai para o refinador através de roscas helicoidais. Note que geralmente estes refinadores são movidos por motores de alta potência. Neste estudo o motor em questão é de 18 MW. A Figura 1 ilustra o processo de refinação de TMP, mostrando suas entradas e saídas.

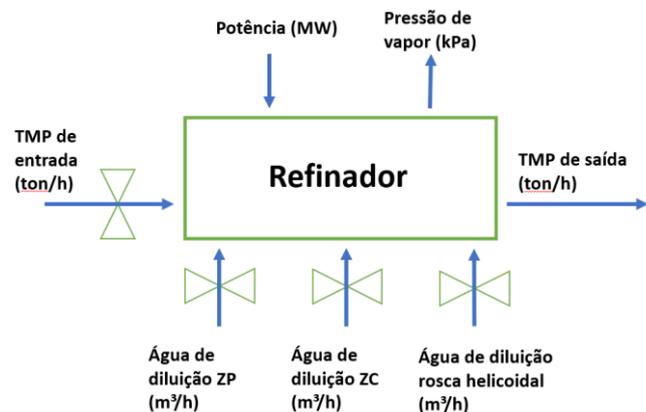


Fig. 1. Diagrama de processo de refino.

O produto é a pasta termomecânica refinada, as variáveis de interesse são a taxa de produção, a consistência e o *freeness*, que serve para avaliar a qualidade da pasta. O ajuste da consistência dentro do refinador é realizado modificando os valores de vazão das águas de diluição (m^3/h).

Em condições normais de operação a consistência de TMP deve ter valores entre 47 a 50%. Valores fora desta faixa devem ser evitados, pois com uma consistência acima de 50% o efeito térmico da fricção pode queimar a TMP, a pasta pode não ser refinada integralmente e podem ocorrer entupimentos na linha de produção. Já com uma consistência abaixo de 47% podem ocorrer a quebra indesejada das fibras de TMP e instabilidade no refinador.

B. Obtenção da base de dados

A seleção das variáveis de processo utilizadas como entradas da rede neural foi feita utilizando a equação (5) apresentada anteriormente, dessa forma foi escolhida a taxa

de produção (ton/h) e a taxa de água de diluição (m³/h). Também foi levado em consideração o fato de que parte da água introduzida no refinador é evaporada devido ao efeito térmico produzido pela fricção dos segmentos com as fibras de madeira [8]. Esta quantidade de água evaporada depende da quantidade de energia consumida pelo refinador e pelo tempo de uso dos segmentos. Diante disso, mais três variáveis foram escolhidas: a potência consumida pelo refinador (MW), as horas trabalhadas dos segmentos (h) e a pressão de carcaça do refinador (kPa).

Para a formação da base de dados foram utilizados dados reais obtidos através de instrumentos de medição e testes de laboratório. As coletas de material para teste de laboratório são realizadas quando o processo de refino está estabilizado.

As variáveis de entrada foram coletadas no servidor de dados de acordo com as datas e horários em que as respectivas amostras de material foram coletadas para análise de consistência em laboratório.

Com o objetivo de diminuir a chance de erro foram coletadas 5 amostras consecutivas de cada variável de entrada com um intervalo de 5 segundos e calculado a média aritmética destes valores, utilizando a equação (6)

$$\mu = \frac{1}{N} \cdot \sum_{t=1}^N x(n) \quad (6)$$

então estes valores médios foram inseridos no *dataset*. A última amostra sempre corresponde a data e horário em que foi coletado o material para teste no laboratório (saída da rede).

A tabela 1 apresenta as entradas, a saída e os respectivos instrumentos utilizados para medição.

Tabela 1. Entradas e saídas da rede.

Variável	Instrumento
Taxa de produção (m ³ /h), produto da vazão e da consistência de entrada na prensa desaguadora	FIC – controlador e indicador de vazão NIC – controlador e indicador de consistência
Taxa de água de diluição (m ³ /h)	FIC – controlador e indicador de vazão
Potência consumida pelo refinador (MW)	JI – indicador de potência
Pressão de carcaça do refinador (kPa)	PIC – controlador e indicador de pressão
Horas trabalhadas dos segmentos	Contador digital de tempo
Consistência	Teste de laboratório

A Figura 2 apresenta o caminho percorrido pelos dados oriundos dos instrumentos de medição de campo:

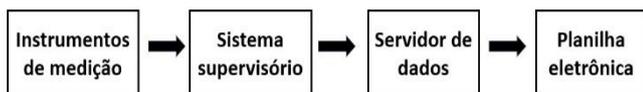


Fig. 2. Rede de dados.

O período escolhido para a formação da base de dados foi de acordo com um ciclo completo de vida útil dos segmentos. Desta forma obteve-se 197 amostras.

A tabela 2 descreve as entradas da rede, a saída da rede (última linha), seus respectivos valores mínimos, máximos e desvio padrão.

Tabela 2. Informações das variáveis.

Descrição	Valor mínimo	Valor máximo	Desvio padrão
Taxa de produção (ton/h)	8,01	9,29	0,19
Taxa de água de diluição (m ³ /h)	8,95	14,93	0,93
Potência consumida (MW)	8,55	13,76	0,73
Pressão de carcaça (kPa)	106,5	219,4	16,24
Horas dos segmentos (h)	2	1240	358,5
Consistência (%)	44	58	2,6

Todas as redes discutidas neste trabalho foram executadas utilizando o software Matlab®.

Para cada tipo de rede (MLP, RBF e ELM) o número de amostras, o número de entradas, o número de camadas intermediárias e o número de saídas foram mantidos constantes, em todas as rodadas de treinamento. A única característica que foi modificada foi a quantidade de neurônios na camada intermediária.

C. Implementação da rede MLP

A rede do tipo Perceptron de Múltiplas Camadas foi a primeira a ser implementada.

Das 197 amostras, 70% foram utilizados para treinamento, 15% para validação e 15% para teste. Os dados foram normalizados no intervalo [-1;1], este intervalo foi escolhido devido ao fato da função de ativação dos neurônios da camada intermediária ser a função tangente hiperbólica.

Para o treinamento da rede foi utilizado o algoritmo gradiente descendente munido do *backpropagation*. Também foi implementada a validação cruzada do tipo *holdout*. Dessa forma os pesos sinápticos utilizados na fase de teste foram aqueles obtidos na época em que a validação apresentou o menor erro quadrático médio (EQM).

A tabela 3 a seguir apresenta os parâmetros utilizados nos treinamentos, validações e testes das redes MLP:

Tabela 3. Parâmetros para a MLP.

Parâmetro	Valor
Função de ativação na camada intermediária	Tangente hiperbólica
Função de ativação na camada de saída	Linear
Taxa de aprendizado	0,01
Precisão requerida	0,000001
Número máximo de épocas	2000

Foram estipuladas 3 quantidades de neurônios na camada intermediária (2, 5 e 10 neurônios). Em todos os treinamentos os valores dos pesos sinápticos iniciais foram gerados aleatoriamente. O critério de parada para cada treinamento foi definido como a diferença entre dois erros quadráticos médio consecutivos menor do que a precisão requerida. Cada topologia foi executada 30 vezes.

D. Implementação da rede RBF

A rede Função de Base Radial foi o segundo tipo de rede implementado.

O treinamento desta rede é composto por dois estágios. No primeiro estágio foi utilizada a técnica *k-means* para a clusterização das amostras. A função de ativação do tipo gaussiana foi implementada na camada intermediária. O segundo estágio é supervisionado, neste foi utilizado a regra delta generalizada para ajustes dos pesos sinápticos da camada de saída. No treinamento da rede foi utilizada a técnica de validação cruzada do tipo *holdout*. Das 197 amostras, 70% foram utilizados para treinamento, 15% para validação e 15% para teste. Os dados foram normalizados no intervalo [0;1].

A tabela 4 apresenta os parâmetros utilizados nos treinamentos, validações e testes:

Parâmetro	Valor
Função de ativação na camada intermediária	Gaussiana
Técnica de agrupamento	<i>k-means</i>
Função de ativação na camada de saída	Linear
Taxa de aprendizado	0,01
Precisão requerida	0,000001
Número máximo de épocas	2000

Foram estipuladas 3 quantidades de neurônios na camada intermediária (2, 3 e 5 neurônios). Os pesos sinápticos iniciais da camada de saída foram gerados aleatoriamente. O critério de parada para cada treinamento foi definido como a diferença entre dois erros quadráticos médio consecutivos menor do que a precisão requerida. Cada topologia foi executada 30 vezes.

E. Implementação da rede ELM

A rede ELM foi o terceiro tipo de rede implementado. Das 197 amostras, 85% foram utilizadas para treinamento e 15% foram utilizadas para teste, a normalização foi de [-1,1].

Foi construído o código para os cálculos da matriz inversa de Moore-Penrose e da matriz de características. A função de ativação utilizada na rede foi a tangente hiperbólica. Utilizando a matriz de características a rede pode computar as saídas utilizando as amostras de teste.

Foram estipuladas três quantidades de neurônios para a camada intermediária (2, 3 e 5 neurônios), e cada topologia foi rodada 30 vezes.

IV. RESULTADOS

A figura 3 apresenta um gráfico boxplot com os resultados dos testes para as três topologias das redes MLP, RBF e ELM em termos do erro quadrático médio.

No eixo horizontal tem-se as topologias implementadas, já no eixo vertical tem-se os valores do EQM.

Nas redes MLP e RBF as topologias que apresentaram menor EQM foram as que possuem dois neurônios na camada

intermediária, já na rede ELM a topologia com 3 neurônios na camada intermediária obteve o menor EQM.

Pode-se notar que um aumento na quantidade de neurônios na camada oculta para as redes MLP e RBF ocasionou em EQMs maiores. Isto comprova o fato de que nem sempre um aumento na quantidade de neurônios na camada intermediária significa um melhor desempenho da rede.

Nos testes da rede RBF nota-se uma amplitude pequena nos valores do EQM para cada topologia. Já nos testes da ELM tem-se uma maior variabilidade nos valores do EQM, vale destacar a topologia ELM com 3 neurônios na camada intermediária que possui o menor e o maior valor do EQM.

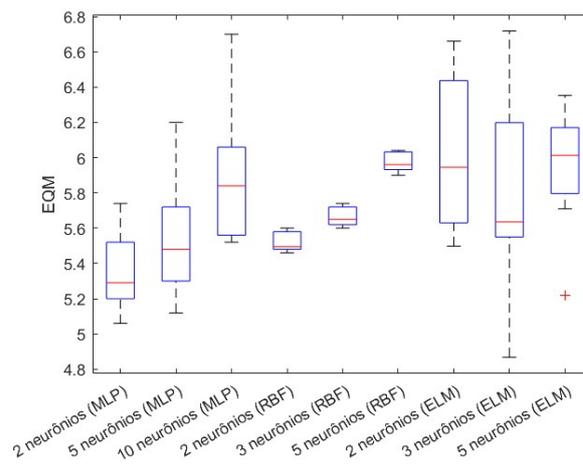


Fig. 3. Boxplot em termos do EQM.

A figura 4 apresenta os gráficos comparando os valores reais e os estimados pelas redes MLP, RBF e ELM, respectivamente. Pode-se observar que os valores estimados estão próximos dos valores reais para a maioria das amostras de teste.

Comparando os resultados da MLP (a) em relação aos da RBF (b) e ELM (c) na figura 4, verifica-se que sua precisão é a maior (7 amostras com valores idênticos aos dos testes de laboratório). Ao indicar corretamente para o operador que a consistência está alta (acima de 50%) o sensor virtual contribui para a prevenção de um possível entupimento na linha de produção, além do fato de que uma consistência acima de 50% pode ocasionar em uma perda do potencial de refino e consequentemente um retrabalho.

No processo de refino em questão, uma consistência de TMP com valores abaixo de 47% pode gerar a quebra excessiva das fibras de celulose acarretando a produção de uma TMP não-conforme. Desta forma ao indicar um valor coerente de consistência o sensor virtual contribui para evitar estes problemas e consequentemente evita o desperdício de energia e o atraso nas entregas.

Na figura 5 são apresentados os gráficos com o erro percentual absoluto entre os valores reais e os estimados. Nas três redes observa-se que o maior erro foi de 11%. A rede MLP obteve a menor média de erro absoluto percentual (EPAM) 3,5%, enquanto a rede RBF obteve 3,9% e a rede ELM 3,6%.

Comparando os resultados em termos do EPA verifica-se que as redes MLP (a), RBF (b) e ELM (c) obtiveram resultados próximos, mas a MLP foi a que teve melhor desempenho.

Em um caso hipotético, como as variáveis de entrada estão disponíveis em tempo real, o sensor virtual estimaria a consistência também em tempo real e desta forma o operador do processo poderia ter uma noção de quanto está o valor da consistência com uma taxa de acerto média maior do que 96%.

Os resultados mostram que estas redes (sensores virtuais) podem ser importantes ferramentas para, juntamente com os testes de laboratório, auxiliar a operação no processo de tomada de decisão. Principalmente a rede MLP que obteve o menor EPAM.

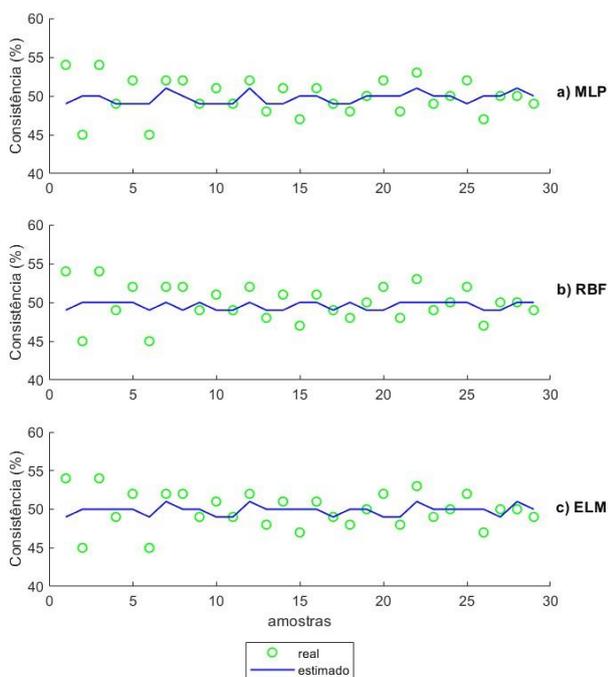


Fig. 4. Real x estimado.

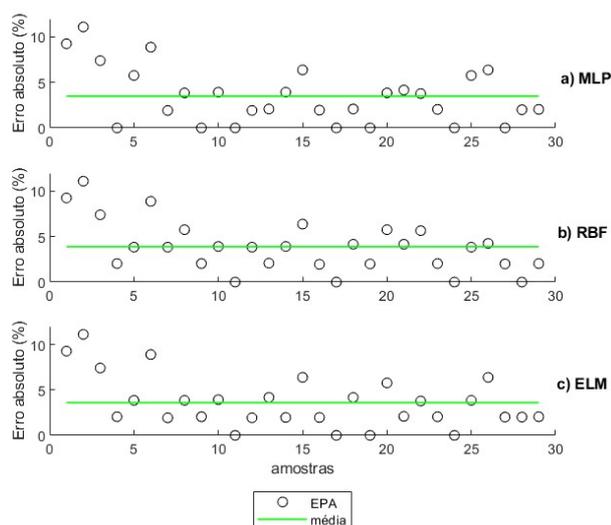


Fig. 5. Erro percentual absoluto.

V. CONCLUSÕES

A consistência é uma variável importantíssima no processo de fabricação de TMP, mas apresenta dificuldade de

ser medida de forma contínua por sensores em alguns processos. Nesta perspectiva, sensores virtuais baseados em redes neurais artificiais são candidatos promissores a estimar de forma contínua a consistência da celulose obtida através do processo TMP na produção de papel.

Neste trabalho três tipos de rede neurais foram utilizados para estimar a consistência e para cada tipo de rede três topologias foram implementadas. Na maioria dos testes apresentados os resultados foram promissores, destacando a rede MLP que obteve o melhor desempenho em termos de assertividade, com uma média de erro absoluto percentual em torno de 3,5%, enquanto a rede RBF obteve 3,9% e a rede ELM 3,6%.

Desta forma, considera-se que as redes analisadas conseguiram estimar valores próximos dos reais na maioria dos casos. Ao indicar coerentemente para o operador o valor da consistência estimado as RNAs podem contribuir para um melhor desempenho do processo, pois possibilitariam a correção dos parâmetros de produção de forma mais ativa e constante, evitariam produção não-conforme, possíveis entupimentos da linha de produção e instabilidade no refinador.

REFERÊNCIAS

- [1] ALMEIDA, Karina Moita. **Tratamento do efluente alcalino do branqueamento da polpa de celulose pelo processo de separação por membranas**. 2002. 139 f. Dissertação (Mestrado) – Curso de Mestrado em Engenharia Química. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2002.
- [2] BO PAPER. **Afinal, o que são fibras termomecânicas de alto rendimento?** Disponível em: <https://www.bopaper.com.br/about-5-2>. Acesso em: 24 maio 2023.
- [3] LI, Mingjie et al. Nonlinear multiobjective MPC-based optimal operation of a high consistency refining system in papermaking. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 50, n. 3, p. 1208-1215, 2017.
- [4] TÖRMÄNEN, Matti; NIEMI, Jan; LÖFQVIST, Torbjörn; MYLLYLÄ, Risto. Pulp consistency determined by a combination of optical and acoustical measurement techniques. **Measurement Science And Technology**, [S.L.], v. 17, n. 4, p. 695-702, 10 fev. 2006. IOP Publishing. <http://dx.doi.org/10.1088/0957-0233/17/4/014>.
- [5] ZHOU, Qiang; TIAN, Xingzhi; WANG, Yabo; LI, Junyu; TUO, Ling. An integrated measurement method for pulp consistency and pulp flow. **Measurement Science And Technology**, [S.L.], v. 31, n. 4, p. 045303, 17 jan. 2020. IOP Publishing. <http://dx.doi.org/10.1088/1361-6501/ab4f24>.
- [6] CUNHA, P. M. C.; ALMEIDA, G. M.. Sensor virtual para classificação de emissões de so2 baseado em k-NN (k-Nearest Neighbors). **Revista Ibero Americana de Ciências Ambientais**, v.12, n.9, p.278-292, 2021. DOI: <http://doi.org/10.6008/CBPC2179-6858.2021.009.0022>
- [7] KORTELA, U. Pulp consistency measurement and control system. **IFAC Proceedings Volumes**, v. 13, n. 4, p. 1-7, 1980.
- [8] SANDKVIST, Filip. **Optimization of paper pulp production using Artificial Neural Networks and Simulated Annealing**. 2013. 35 f. TCC (Graduação) - Curso de Theoretical Physics, Lund University, Lund, 2013.
- [9] KARSIMUS, Miika. **Applying machine learning based soft sensors to a pulp refining process**. 2021. 90 f. Dissertação (Mestrado) - Curso de Master's Programme In Automation And Electrical Engineering, Aalto University, Helsinki, 2021.
- [10] WANG, Jian; LU, Siyuan; WANG, Shui-Hua; ZHANG, Yu-Dong. A review on extreme learning machine. **Multimedia Tools And Applications**, [S.L.], v. 81, n. 29, p. 41611-41660, 22 maio 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11042-021-11007-7>.

- [11] SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas - curso prático**. 1. ed. São Paulo: ARTLIBER, 2010. ISBN 978-85-88098-53-4.
- [12] KHASHEI, Mehdi; BIJARI, Mehdi. An artificial neural network (p,d,q) model for time series forecasting. **Expert Systems With Applications**, [S.L.], v. 37, n. 1, p. 479-489, jan. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.eswa.2009.05.044>.
- [13] SUDHA, L. et al. Optimization of process parameters in feed manufacturing using artificial neural network. **Computers and electronics in agriculture**, v. 120, p. 1-6, 2016.
- [14] HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. ISBN 978-85-7307-718-6.
- [15] SINGH, Jaswinder; BANERJEE, Rajdeep. A study on single and multi-layer perceptron neural network. In: **2019 3rd International Conference on Computing Methodologies and Communication (ICCMC)**. IEEE, 2019. p. 35-40.
- [16] ZHANG, Jing Wei et al. Filtering out antenna effects from GPR data by an RBF neural network. **IEEE Geoscience and Remote Sensing Letters**, v. 16, n. 9, p. 1378-1382, 2019.
- [17] HUANG, G. H.; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: IEEE. **Proceedings of International Joint Conference on Neural Networks**. [S.l.], 2004. v. 2, p. 985-990.
- [18] BELOTTI, Jônatas Trabuco. **Previsão de vazões afluentes utilizando redes neurais artificiais e ensembles**. 2018. 137 f. Dissertação (Mestrado) - Curso de Mestrado em Ciência da Computação, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2019.
- [19] SIQUEIRA, H. V.; BOCCATO, L.; ATTUX, R. R. F.; LYRA FILHO, C. Echo state networks in seasonal streamflow series prediction. **Learning and Nonlinear Models**, v. 10, p. 181-191, 2012.