

**JAYNE DOS SANTOS LIMA**

**MODELAGEM DE SENSOR VIRTUAL PARA MEDIÇÃO DE VAZÃO EM UMA  
USINA DO SETOR SUCROENERGETICO BASEADO EM REDES NEURAIAS  
ARTIFICIAIS**

Dissertação de mestrado a ser apresentado ao programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Paraíba para qualificação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

**Orientador: PROF. DR. JUAN MOISES MAURÍCIO VILLANUEVA**

**JOÃO PESSOA  
2022**

**JAYNE DOS SANTOS LIMA**

**MODELAGEM DE SENSOR VIRTUAL PARA MEDIÇÃO DE VAZÃO EM UMA  
USINA DO SETOR SUCROENERGETICO BASEADO EM REDES NEURAIAS  
ARTIFICIAIS**

Dissertação de mestrado a ser apresentado ao programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal da Paraíba para qualificação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

**Orientador: PROF. DR. JUAN MOISES MAURÍCIO VILLANUEVA**

**JOÃO PESSOA**

**2022**

**Catálogo na publicação**  
**Seção de Catalogação e Classificação**

L732m Lima, Jayne Dos Santos.

Modelagem de sensor virtual para medição de vazão em uma usina do setor sucroenergético baseado em redes neurais artificiais / Jayne dos Santos Lima. - João Pessoa, 2022.

74 f. : il.

Orientação: Juan Moises Mauricio Villaneuva.  
Dissertação (Mestrado) - UFPB/CEAR.

1. Usina 4.0. 2. Setor sucroenergético. 3. Sensores virtuais. 4. Inteligência artificial. 5. Redes neurais artificiais. 6. Dropout. 7. Avaliação de incerteza. I. Villaneuva, Juan Moises Mauricio. II. Título.

UFPB/BC

CDU 681.5(043)



**UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB**  
**CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE**

A Comissão Examinadora, abaixo assinada, aprova o Exame de Dissertação

**MODELAGEM DE SENSOR VIRTUAL PARA MEDIÇÃO DE VAZÃO EM UMA  
USINA DO SETOR SUCROENERGETICO BASEADO EM REDES NEURAIAS  
ARTIFICIAIS**

Elaborado por

**JAYNE DOS SANTOS LIMA**

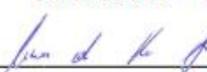
como requisito para obtenção do grau de  
**Mestre em Engenharia Elétrica.**

**COMISSÃO EXAMINADORA**



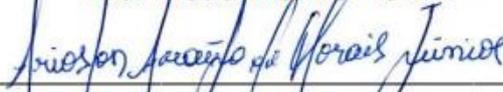
---

**PROF. DR. JUAN MOISES MAURICIO VILLANUEVA**  
Orientador – UFPB



---

**PROF. DR. CÍCERO DA ROCHA SOUTO**  
Examinador Interno – UFPB



---

**PROF. DR. ARIOSTON ARAUJO DE MORAIS JUNIOR**  
Examinador externo – UFPB



---

**PROF. DR. SEBASTIAN YURI CAVALCANTI CATUNDA**  
Examinador Externo – UFRN

João Pessoa/PB, 29 de Agosto de 2022.

---



A Deus, aos meus pais Genivaldo e Fátima e a minha irmã Jani, a eles todos os créditos...

Dedico

## AGRADECIMENTOS

A Deus por me amar e me conceder a oportunidade desenvolvimento, por ter me permitido chegar ao final desta etapa de minha vida e início de outras que estão por vir.

À Dona Fátima e Seu Genivaldo, minha mainha e meu painho, por todo amor, zelo e por sempre acreditarem nos meus sonhos.

À minha irmã, Janielly, por todo amor, pela valorização ao meu trabalho e encorajamento irrestritos em todos os momentos.

À Usina Central Olho D'Água S/A, pela liberação, investimento e apoio ao desenvolvimento deste projeto.

A toda equipe técnica da Usina Central Olho D'Água S/A, em especial a minha amiga Cirleide Santos, que me ajudaram a conduzir tão bem este trabalho em campo.

Ao meu Orientador, Prof. Dr. Juan Moises Mauricio Villanueva, que acolheu o projeto, me deu a oportunidade de trabalharmos juntos e compartilhou ensinamentos valiosos e experiência de vida.

A todos os Professores do Programa de Pós-Graduação em Engenharia Elétrica da UFPB.

À Coordenação do Programa de Pós-Graduação em Engenharia Elétrica da UFPB.

A minha amiga Anne, que dividiu tantos momentos difíceis do curso comigo, apesar da distância física, seguimos juntas e fortalecidas até o fim.

A todos aqueles que, de alguma maneira, contribuíram para que este trabalho fosse realizado.

“Não sou nada, sou apenas um instrumento, um pequeno lápis nas mãos do Senhor, com o qual Ele escreve aquilo que deseja. Por mais imperfeitos que sejamos Ele escreve magnificamente”.

**Madre Teresa de Calcutá**

## SUMÁRIO

<b>LISTA DE ILUSTRAÇÕES .....</b>	<b>VII</b>
<b>LISTA DE TABELAS .....</b>	<b>VIII</b>
<b>SIGLAS E ABREVIATURAS .....</b>	<b>IX</b>
<b>LISTA DE SÍMBOLOS .....</b>	<b>X</b>
<b>RESUMO.....</b>	<b>XI</b>
<b>ABSTRACT.....</b>	<b>XII</b>
<b>1 INTRODUÇÃO .....</b>	<b>14</b>
1.1 OBJETIVOS .....	16
1.2 MOTIVAÇÃO.....	16
1.3 CONTRIBUIÇÃO.....	17
1.4 ESTRUTURA DO TRABALHO.....	20
<b>2 FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>22</b>
2.1 USINA CENTRAL OLHO D'AGUA .....	22
2.1.1 Fabricação de açúcar.....	24
2.1.2 Fabricação de álcool .....	25
2.1.3 Produção de energia elétrica.....	26
2.2 <i>SOFT SENSORS</i> .....	27
2.3 REDES NEURAIS ARTIFICIAIS .....	31
2.4 ANÁLISE DE INCERTEZAS EM MODELOS DE RNA BASEADO NO <i>DROPOUT</i> .....	34
2.4.1 Descrição matemática do <i>dropout</i> .....	36
2.4.2 Avaliação de Incerteza por meio da Análise Monte Carlo Dropout .....	37
<b>3 METODOLOGIA PARA O DESENVOLVIMENTO DO <i>SOFT SENSOR</i>.....</b>	<b>42</b>
3.1.1 Coleta de dados .....	46
3.1.2 Pré-processamento de dados .....	48
<b>4 RESULTADOS DOS MODELOS DE <i>SOFT SENSOR</i>.....</b>	<b>53</b>
4.1.1 Coleta e Pré-processamento de dados .....	53
4.1.2 Seleção de Variáveis.....	55
4.1.3 Modelo 1 do <i>soft sensor</i> .....	56
4.1.4 Modelo 2 do <i>soft sensor</i> .....	60
4.1.5 Avaliação de incerteza de medição do modelo do <i>soft sensor</i> .....	64
<b>5 CONCLUSÕES .....</b>	<b>68</b>



## LISTA DE ILUSTRAÇÕES

FIGURA 1. DIAGRAMA DE BLOCOS SIMPLIFICADO DOS PROCESSOS. ....	23
FIGURA 2. CONJUNTOS TURBOGERADORES DA USICODA. ....	26
FIGURA 3. PROCEDIMENTO DE IDENTIFICAÇÃO DE UM SENSOR VIRTUAL. ....	29
FIGURA 4. REDE NEURAL ARTIFICIAL COM UMA CAMADA OCULTA. ....	32
FIGURA 5. ARQUITETURA DE UMA RNA COM NEURÔNIOS DESATIVADOS. ....	35
FIGURA 6. ARQUITETURA DA RNA <i>DROPOUT</i> DURANTE A FASE DE INFERÊNCIAS. ....	36
FIGURA 7. FLUXOGRAMA DE INFERÊNCIA COM O MODELO MONTE CARLO <i>DROPOUT</i> . ....	40
FIGURA 8. TUBO MEDIDOR DE VAZÃO DO CALDO CALEADO. ....	42
FIGURA 9. CONVERSOR APLICADO AO MEDIDOR DE CALDO CALEADO. ....	43
FIGURA 10. DECANTADOR DE CALDO. ....	44
FIGURA 11. CONFIGURAÇÃO DO MODELO <i>SOFT SENSOR</i> . ....	45
FIGURA 12. DIAGRAMA DE FLUXO DA METODOLOGIA ADOTADA. ....	46
FIGURA 13. ESQUEMA SIMPLIFICADO DO PROCESSO PARA A COLETA DE DADOS. ....	48
FIGURA 14. MODELO COM TODAS AS VARIÁVEIS. ....	50
FIGURA 15. MODELO COM REALIMENTAÇÃO. ....	51
FIGURA 16. REMOÇÃO DE <i>OUTLIERS</i> . ....	54
FIGURA 17. FILTRAGEM DO RUÍDO. ....	55
FIGURA 18. EXPERIMENTO 1 DO MODELO 1. ....	57
FIGURA 19. CURVAS DE VAZÃO DE CALDO CALEADO DO EXPERIMENTO 1 DO MODELO 1 (CONSIDERANDO TODAS AS VARIÁVEIS).....	58
FIGURA 20. EXPERIMENTO 2 DO MODELO 1 (DESCONSIDERANDO PH1 E PH2). ....	59
FIGURA 21. CURVAS DE VAZÃO DE CALDO CALEADO DO EXPERIMENTO 2 DO MODELO 1 (DESCONSIDERANDO AS VARIÁVEIS PH1 E PH2). ....	60
FIGURA 22. EXPERIMENTO 1 DO MODELO 2. ....	61
FIGURA 23. EXPERIMENTO 1 DO MODELO 2 CONSIDERANDO TODAS AS VARIÁVEIS. ....	62
FIGURA 24. EXPERIMENTO 2 DO MODELO 2 (DESCONSIDERANDO AS VARIÁVEIS PH1 E PH2). ....	62
FIGURA 25. CURVAS DE VAZÃO DE CALDO CALEADO DO EXPERIMENTO 2 DO MODELO 2 (DESCONSIDERANDO AS VARIÁVEIS PH1 E PH2). ....	63
FIGURA 26. VAZÃO DO CALDO CALEADO APÓS EXPERIMENTO 2 DO MODELO 2. ....	64
FIGURA 27. CURVA DE VAZÃO PARA O MODELO MONTE CARLO <i>DROPOUT</i> . ....	66

## LISTA DE TABELAS

TABELA 1. CORRELAÇÃO DAS VARIÁVEIS DE ENTRADA COM A VARIÁVEL DE SAÍDA Q2 (VAZÃO DO CALDO CALEADO).....	56
TABELA 2. MÉTRICAS DE AVALIAÇÃO DO <i>SOFT SENSOR</i> MODELO 1. ....	59
TABELA 3. MÉTRICAS DE AVALIAÇÃO DO <i>SOFT SENSOR</i> MODELO 2. ....	63
TABELA 4. HIPERPARÂMETRO DA REDE COM O MODELO MONTE CARLO DROPOUT.....	65
TABELA 5. MÉTRICAS DE AVALIAÇÃO DO MODELO MONTE CARLO DROPOUT.....	66

## **SIGLAS E ABREVIATURAS**

ANEEL - Agência Nacional de Energia Elétrica

BF - Blast Furnace

ETP - Effluent Total Phosphorus

FSSC - Food Safety System Certification

GLP - Gás Liquefeito de Petróleo

IoT - Internet das Coisas

KGF/CM<sup>2</sup> - quilograma força por centímetro quadrado

MDM - Model Driven Models

MI - Modelo Inferencial

MIT - Massachusetts Institute of Technology

MSDP - Multicast Source Discovery Protocol

PE - Pernambuco

PLS – Partial Least Squares

RBFNN - Rede Neural de Função Base Radial

RNA – Rede Neural Artificial

SV - Sensor Virtual

USICODA – Usina Central Olho D'Água

## LISTA DE SÍMBOLOS

$CO_2$  – Dióxido de Carbono

$H_2S$  – Sulfeto de Hidrogênio

$SO_2$  – Dióxido de Enxofre

inch - polegadas

cm - centímetros

kg - quilogramas

pH - potencial hidrogeniônico

kgf/cm<sup>2</sup> - quilogramas por centímetro quadrado

m<sup>3</sup>/h – metros cúbicos por hora

MW – Mega Watts

MWh – Mega Watts Hora

% - percentual

## RESUMO

Na busca do aumento da produtividade a indústria desenvolveu artifícios tecnológicos para atingir esse objetivo, uma dessas estratégias é denominada de Indústria 4.0. No setor sucroenergético, plantas industriais buscam ferramentas capazes de aprimorar os processos e diminuir o intervalo de tempo de paradas não programadas aliadas a um baixo custo com manutenção. Neste trabalho, realizou-se o desenvolvimento de um sensor virtual (*soft sensor*) para medição de vazão do caldo de entrada de um decantador (caldo caleado), utilizando a técnica de redes neurais artificiais. A vazão de caldo caleado é uma variável importante no processo de fabricação de açúcar e etanol, pois influencia diretamente no balanço térmico da usina, além de determinar a quantidade de insumos necessária para garantir a qualidade do açúcar. Nesta abordagem são utilizados os dados de uma planta sucroenergética localizada em Camutanga, no interior de Pernambuco, para criar um banco de conhecimento para o sistema através do histórico do sistema supervisório do tratamento de caldo da unidade. Desta forma, contruiu-se um modelo de sensor virtual capaz de prever a vazão de caldo caleado, a ser utilizado como uma possível redundância, no intuito de garantir eficiência de medição em casos de falhas e/ou não disponibilidade do equipamento físico. Os resultados apresentados pelo modelo a partir dos testes realizados, em dois cenários diferentes, mostraram a robustez do modelo proposto, e em todos os cenários o desvio padrão foi abaixo de 3%. Além disso, após análise da incerteza do medidor, verificou-se que o modelo proposto conta com erro de medição de 20 m<sup>3</sup>/h, que para a aplicação proposta é um valor bastante aceitável.

**Palavra-chave:** Setor sucroenergético; Usina 4.0; Sensores Virtuais; Inteligência Artificial; Redes Neurais Artificiais; Avaliação de Incerteza, Dropout.

## ABSTRACT

In the search for increased productivity, the industry has developed technological devices to achieve this goal; one of these strategies is called Industry 4.0. In the sugar-energy sector, industrial plants are looking for tools capable of improving processes and reducing the time of unscheduled stoppages combined with low maintenance costs. In this work, a virtual sensor (soft sensor) was developed to measure the flow rate of the inlet juice of a decanter (caleado broth) using the technique of artificial neural networks. The flow of lime juice is an essential variable in the process of manufacturing sugar and ethanol, as it directly influences the thermal balance of the plant, in addition to determining the number of inputs needed to guarantee the quality of the sugar. In this approach, data from a sugar-energy plant located in Camutanga, in the interior of Pernambuco, are used to create a knowledge bank for the system through the history of the supervisory system of the juice treatment of the unit. In this way, a virtual sensor model was built capable of measuring the flow of lime juice to be used as a possible redundancy in order to guarantee measurement efficiency in cases of failures and/or non-availability of the physical equipment. The results presented by the model from the tests performed in two different scenarios showed the robustness of the proposed model, and in all scenarios, the standard deviation was below 3%. In addition, after analyzing the uncertainty of the meter, it was found that the proposed model has a measurement error of 20 m<sup>3</sup>/h, which for the proposed application is a very acceptable value.

**Keyword:** Sugarcane setor; Factory 4.0; Soft Sensors; Artificial Inteligency; Artificial Neural Networks; Uncertainty Assessment, Dropout.

## **1 INTRODUÇÃO**

---

## 1 INTRODUÇÃO

A utilização de computadores em linhas de produção para realizar controle de processos, permitiram ganhos em escala sem precedentes, além de alta padronização e elevada qualidade, reduzindo drasticamente os custos de produção. A inserção da *internet* trouxe um novo conceito sobre comunicação, impactando diretamente os processos industriais. A ideia de integração e comunicação através de plataformas e utilização de dispositivos *online*, os *smartphones*, permitindo troca de informações, pesquisas, análise de dados, decisões e ações em tempo real e descentralizada (ALVARES, 2018).

Na busca pelo aprimoramento operacional, as indústrias buscam por tecnologias que possam aumentar a eficiência a partir de ferramentas inovadoras, e é nesse contexto de inovação que aconteceu a quarta revolução industrial, a revolução da Indústria 4.0. O termo Indústria 4.0 surgiu pela primeira vez em um artigo publicado pelo governo Alemão em 2011, o qual definia a estratégia para pesquisa e desenvolvimento de tecnologias de ponta (ZHOU, 2015). Atualmente, esse tema vem sendo discutido e é um dos temas de maior destaque na indústria. A Indústria 4.0 se baseia na integração do ambiente de tecnologia da informação e do ambiente da tecnologia da automação industrial, a fim de tornar o ambiente mais iterativo entre pessoas, máquinas e produtos, em tempo real, a partir de um sistema ciber físico (CPS – *Cyber Physical System*) (ZHOU, 2015).

O setor sucroenergético também evoluiu no quesito automação industrial. É possível identificar usinas com centro de controle operacional, executando tarefas de monitoramento e controle da planta, a partir de tecnologias de controladores programáveis, todos conectados em redes de informação e controle. As novas tecnologias que surgem como bandeiras desta nova revolução já estão presentes, porém estamos vivendo uma transição, sem estabelecer um limite de implantação, novos conceitos, tais como, Internet das Coisas (IoT) e Banco de Dados (*Big Data*), permeiam esse novo cenário. Neste aspecto, a medição das variáveis de campo precisa ser fidedigna ao processo, pois todo controle e tomada de decisões estão diretamente ligadas ao processo de medição.

As medições de variáveis físicas são garantidas de maneira satisfatória com o uso de inúmeros sensores físicos, como exemplo: termômetros e termopares na

---

medição de temperatura, transmissores e tubo de Bourdon na leitura de pressão, placa de orifício, rotâmetro e medidores magnéticos para medição de vazão, sensores de pressão diferenciais e flutuantes para medição nível, dentre outros. Por outro lado, quando se deseja medir em tempo real variáveis químicas e bioquímicas, não facilmente mensuráveis, tais como teor ou composição de produtos, biomassa e pH, surge o problema de como fazer tais medições. Para resolver essas e outras dificuldades surgiu então o conceito de *soft sensor*, também conhecido como sensor virtual (SV) ou modelo inferencial (MI) (MORAIS JR, 2015).

O SV é um modelo matemático utilizado para estimar variáveis de interesse em função de variáveis de entrada, ditas secundárias, de fácil medição. Essa alternativa surge de uma dificuldade operacional ou do alto custo na obtenção da variável desejada ou, ainda, utilizado na previsão de falha de um sensor físico, seja pela sua quebra ou pela sua retirada do processo para manutenção e calibração (MORAIS JR, 2011).

Segundo Lotufo e Garcia (2008), a necessidade de implantação de um SV surge de diversos problemas a serem enfrentados, tais como: inferência de variáveis, detecção de falhas, previsão de desempenho, aproximação de funções não lineares e identificação de padrões de processos os quais são requeridos.

A gama de tarefas a serem cumpridas pelos sensores virtuais é ampla, onde a sua área original de aplicação e ainda mais dominante é a predição de variáveis de processos, que podem ser determinadas a um baixo tempo/período de amostragem ou somente através de análises que não são em tempo real. Nestes casos, o SV pode ser uma boa alternativa em relação às medições tradicionais, desde que as variáveis de entradas (secundárias) possam ser fornecidas/medidas sem problemas e quando a simulação é utilizada para gerar os dados à construção do sensor (geralmente implementada em um *software*) seja capaz de fornecer a variável desejada de forma precisa (KADLEC et al., 2009).

No contexto de uma planta sucroenergética, a necessidade de medição das variáveis dos processos é feita através de sensores físicos de alto custo de aquisição, instalação e manutenção. Considerando que a medição através de sensores virtuais é uma opção de baixo custo em relação aos sensores físicos surge a possibilidade de inserção de tais sensores no processo de medição das variáveis diversas em uma usina. No caso em questão, foi escolhida a medição da vazão do

---

caldo caleado, pois esta informação é de extrema importância para o controle do balanço energético de uma usina. A vazão de caldo caleado determina a demanda de vapor mediante a quantidade de caldo que chegará no processo de evaporação. Além disso, o controle e monitoramento da quantidade de caldo implicam na utilização correta dos insumos, garantindo eficiência e qualidade do produto final.

Em busca de ferramentas que possam melhorar o desempenho dos equipamentos de um processo de produção industrial de uma usina sucroenergética, reduzir custos com manutenção e novos investimentos (aquisição de equipamentos físicos), esta pesquisa tem como objetivo o desenvolvimento da modelagem de um sensor virtual para medição de vazão do caldo caleado utilizando redes neurais artificiais.

## 1.1 OBJETIVOS

Neste trabalho de dissertação, tem-se como objetivo o desenvolvimento de um *soft sensor* de vazão em uma usina do setor sucroenergetico.

Os objetivos específicos são:

- a. Coleta das variáveis de entrada para a modelagem do sensor virtual (criação do banco de dados);
- b. Aplicação de técnicas de seleção de variáveis e pré-processamento nos dados coletados;
- c. Modelagem do sensor virtual baseado em técnicas de inteligência artificial, especificamente redes neurais artificiais;
- d. Avaliação da incerteza de medição do modelo baseado na técnica do *dropout* sobre uma rede neural artificial;
- e. Validação do modelo com um modelo de sensor virtual de referência.

## 1.2 MOTIVAÇÃO

As variáveis de interesse em processos industriais são normalmente variáveis físicas e químicas, sendo que as mais comuns são temperatura, pressão, vazão e nível (ZANATA, 2005).

---

Um sensor virtual corresponde a um método indireto ou inferencial de medição, em que um modelo matemático estático, ou preferencialmente dinâmico do processo é empregado em conjunto com uma ou mais variáveis medidas, normalmente do tipo vazão, pressão ou temperatura (variáveis físicas), para as quais os medidores têm boa precisão e tempo de resposta, porém custos elevados.

Em uma usina sucroenégetica, os processos de medição utilizam medidores de vazão magnéticos com diâmetros superiores a 12". (304,8 mm), equipamentos de alto custo de aquisição e manutenção. Na usina em questão, existe a necessidade de calibração dos instrumentos a cada dois anos como atendimento às exigências da norma FSSC 22000 (*Food Safety System Certification*) que trata da segurança de alimentos. O alto custo com o envio destes equipamentos para calibração abre uma janela de oportunidade para estudo e avaliação de um sensor virtual que seja capaz de medir, de forma eficiente, diversos fluídos da planta industrial. Garantir a modelagem de um sensor virtual é de fundamental importância para uma possível implantação em chão de fábrica, de forma que estes sensores funcionem de forma redundante aos sensores físicos já existentes, como substitutos em casos de falha do sensor físico e em substituição a um sensor físico.

Neste trabalho, optou-se por realizar a modelagem de um sensor virtual para medição do caldo caleado. A medição de vazão do caldo deve ser exata, pois é neste processo onde são inseridos insumos para controle de proliferação de bactérias e cor do caldo que influenciam diretamente na qualidade do produto final, o açúcar. Associado a isto, está o controle do consumo de vapor da planta, que pode ser direcionado de forma errada e prejudicar os demais processos, como a exportação de energia, por exemplo.

### 1.3 CONTRIBUIÇÃO

Em 2016, REN desenvolveu um método de modelagem de *soft sensor* para medição de pH de um sistema de resfriamento de ar em um processamento de produção de refinaria. Ele usou modelagem e simulação em Aspen juntamente com os dados locais coletados. O Aspen é o principal simulador de processos químicos disponível no mercado. Foi desenvolvido em MIT (*Massachusetts Institute of Technology*) para o departamento de energia dos Estados Unidos. Nestes anos,

---

esta ferramenta tem sido amplamente utilizada, em diferentes setores da indústria química, com excelentes resultados (IGLESIAS, 2009). Primeiramente foi determinada a correlação entre os dados e em seguida foi realizado a modelagem do *soft sensor*, baseado em algoritmos de máquina de aprendizagem.

Em 2017, ZHU desenvolveu um sensor virtual para a monitoração do total de efluentes de fósforo (*Effluent Total Phosphorus* - ETP). Ele utilizou PLS para selecionar variáveis confiáveis do ETP baseado em dados experimentais. A regressão PLS (*partial least squares*) vem sendo amplamente utilizada em procedimentos de seleção de variáveis por sua capacidade de operar com grande número de variáveis correlacionadas e afetadas por ruído (ZIMMWER, 2014). Finalmente, foi utilizada uma rede neural de função base radial (*Radial Basis Function Neural Network* - RBFNN) para identificar a relação entre as variáveis secundárias e ETP.

Um sensor virtual foi desenvolvido por LIU (2018) para predição de qualidade de absorção de CO<sub>2</sub> em uma coluna através de uma estrutura de rede bayesiana. Devido à degradação do modelo, foi necessária a construção de um modelo adaptativo capaz de acompanhar as mudanças do processo. O modelo bayesiano demonstrou uma superioridade sobre os outros métodos, especialmente lidando com falta de dados e a habilidade de aprender casualidades. Validou-se o modelo em dados coletados em uma coluna debutanizadora e em uma coluna de absorção de CO<sub>2</sub>.

Uma abordagem para o desenvolvimento de soluções mais eficientes e menos complexas para sensores virtuais, a fim de maximizar a precisão, bem como minimizar o número de variáveis de entrada foi apresentada por BIDAR em 2018. A abordagem baseada em modelos de parâmetros dependentes de múltiplos estados (MSDP), em que os parâmetros do modelo são estimados em um espaço de estado empregando o filtro de Kalman. O sensor virtual baseado em MSDP proposto foi aplicado para uma unidade industrial de recuperação de enxofre, a fim de prever as concentrações de H<sub>2</sub>S e SO<sub>2</sub>. O modelo foi comparado com outras técnicas de detecção, baseadas no mesmo conjunto de dados de referência do estudo de caso. Os resultados apresentados indicaram que os sensores virtuais baseados em MSDP são mais robustos e exibem desempenho preditivo superior aos métodos de

---

detecção com base no erro médio quadrático e da correlação de Pearson ao usar menos variáveis de entrada.

Em 2019, Cang propôs uma estimativa *online* para medição das concentrações dos componentes principais de um reator de síntese de bisfenol-A (BPA). Cang propõe uma abordagem híbrida. Primeiro o modelo do mecanismo simplificado para a síntese de BPA é deduzido utilizando as variáveis de massa e energia. Em seguida, considerando que as concentrações iniciais de reagentes na entrada do reator de síntese de BPA não pode ser medida em tempo real, uma abordagem de regressão do processo Gaussiano anteriormente proposto pelos autores, é empregada para estimar *online* as concentrações iniciais de reagentes. Finalmente, a abordagem de modelagem híbrida para o processo de síntese de BPA é alcançada pela integração do modelo de mecanismo simplificado com os modelos de estimativa de concentrações iniciais e constantes de taxa de reação.

A temperatura da parede do alto-forno (BF - *Blast Furnace*) tem um papel fundamental para determinar se a operação do BF é eficiente. No entanto, esta medição não pode ser realizada diretamente porque o BF é um reator complexo fechado com estrutura e ambientes extremamente severos. Para lidar com este problema, SHEN em 2019 propôs uma modelagem estratégica de *soft sensor* para a temperatura da parede do BF com base em um algoritmo de extrapolação de elementos finitos de dimensão temporal-espacial (TS-FEEA). Os resultados da simulação demonstram a validade do *soft sensor* modelado e sua aplicabilidade em plantas industriais.

Diante do exposto, *soft sensors* ou sensores virtuais são ferramentas eficientes para previsão de variáveis de processo industriais e podem ser utilizados como alternativa em caso de redundância do sensor físico, para previsão da variável principal, com a vantagem de ter baixíssimos custos de instalação. A proposta para previsão da vazão de caldo caleado é acompanhada da análise d incerteza do medidor através do Monte Carlo Dropout.

## 1.4 ESTRUTURA DO TRABALHO

Além do capítulo introdutório, que contempla uma contextualização de sensores virtuais num ambiente de usinas 4.0 com os objetivos e a motivação deste projeto, este trabalho está composto por mais 4 capítulos.

No Capítulo 2, serão discutidas a fundamentação teórica envolvendo o funcionamento da usina sucroenergética descrevendo de forma resumida os processos de fabricação de açúcar, etanol e energia elétrica, os conceitos fundamentais sobre *soft sensors*, redes neurais artificiais e avaliação de incertezas em modelos baseados em redes neurais artificiais, enfatizando o Modelo Monte Carlo Dropout.

No Capítulo 3 será apresentada a proposta do trabalho, detalhando os procedimentos metodológicos para a construção do modelo do sensor virtual. São indicadas as características dos dois modelos propostos, bem como o processamento de dados realizado para obtenção do banco de dados utilizado.

No Capítulo 4 serão apresentados os resultados da pesquisa. São expostas as métricas de avaliação realizadas em cada modelo e indicado o que obteve o melhor desempenho após a realização dos testes e experimentos.

E, por fim, no Capítulo 5 serão apresentadas as conclusões desta pesquisa bem como sugestões de trabalhos futuros.

## **2 FUNDAMENTAÇÃO TEÓRICA**

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo contempla um breve histórico sobre localização e estrutura da Usina Central Olho D'Água, os processos de fabricação de açúcar, etanol e geração de energia elétrica. São apresentadas ainda, as definições de *soft sensors*, redes neurais artificiais e análise numérica de incertezas, ferramentas que foram utilizadas para construção deste trabalho.

### 2.1 USINA CENTRAL OLHO D'AGUA

A Usina Central Olho D'Água (USICODA), está localizada na Zona Rural na cidade de Camutanga - PE. Ela dispõe de 20 mil hectares de terras próprias, dos quais 15 mil cultivados com cana de açúcar. A produção é em torno de 3,1 milhões de sacos de açúcar de 50 kg/ano, 33 milhões de litros de álcool, gerando energia própria para consumo da fábrica e parte da irrigação. A maior parte da produção de açúcar é exportada (aproximadamente 65%) e a outra parte é fonte de abastecimento de importantes indústrias da região, o que consolida sua principal atividade no setor sucroenergético e a coloca como a maior produtora de açúcar do estado de Pernambuco.

A safra de cana de açúcar é sazonal e, normalmente inicia no mês de agosto com término no mês de fevereiro. O amadurecimento da cana de açúcar neste período acontece devido a fatores climáticos como falta de umidade, luminosidade e frio. Após o amadurecimento, as canas são cortadas (de forma manual) conforme um planejamento estratégico.

O transporte da cana de açúcar da lavoura até a unidade industrial é feito por meio de caminhões. Cada carga transportada pesa aproximadamente 16 toneladas. Depois de cortada e transportada para a usina, a cana de açúcar é enviada para a moagem, onde se inicia o processo de cogeração através da biomassa e a fabricação do açúcar e do álcool.

Na Figura 1 é apresentado um diagrama de blocos referente aos processos de fabricação de açúcar e etanol. Na etapa de moagem, a cana que chega à unidade industrial é processada o mais rápido possível. Este sincronismo entre corte, transporte e moagem é muito importante, pois a cana é uma matéria prima

sujeita a contaminações e de fácil deterioração. Antes da moagem, a cana passa por um sistema de lavagem para retirada de terra proveniente da lavoura.

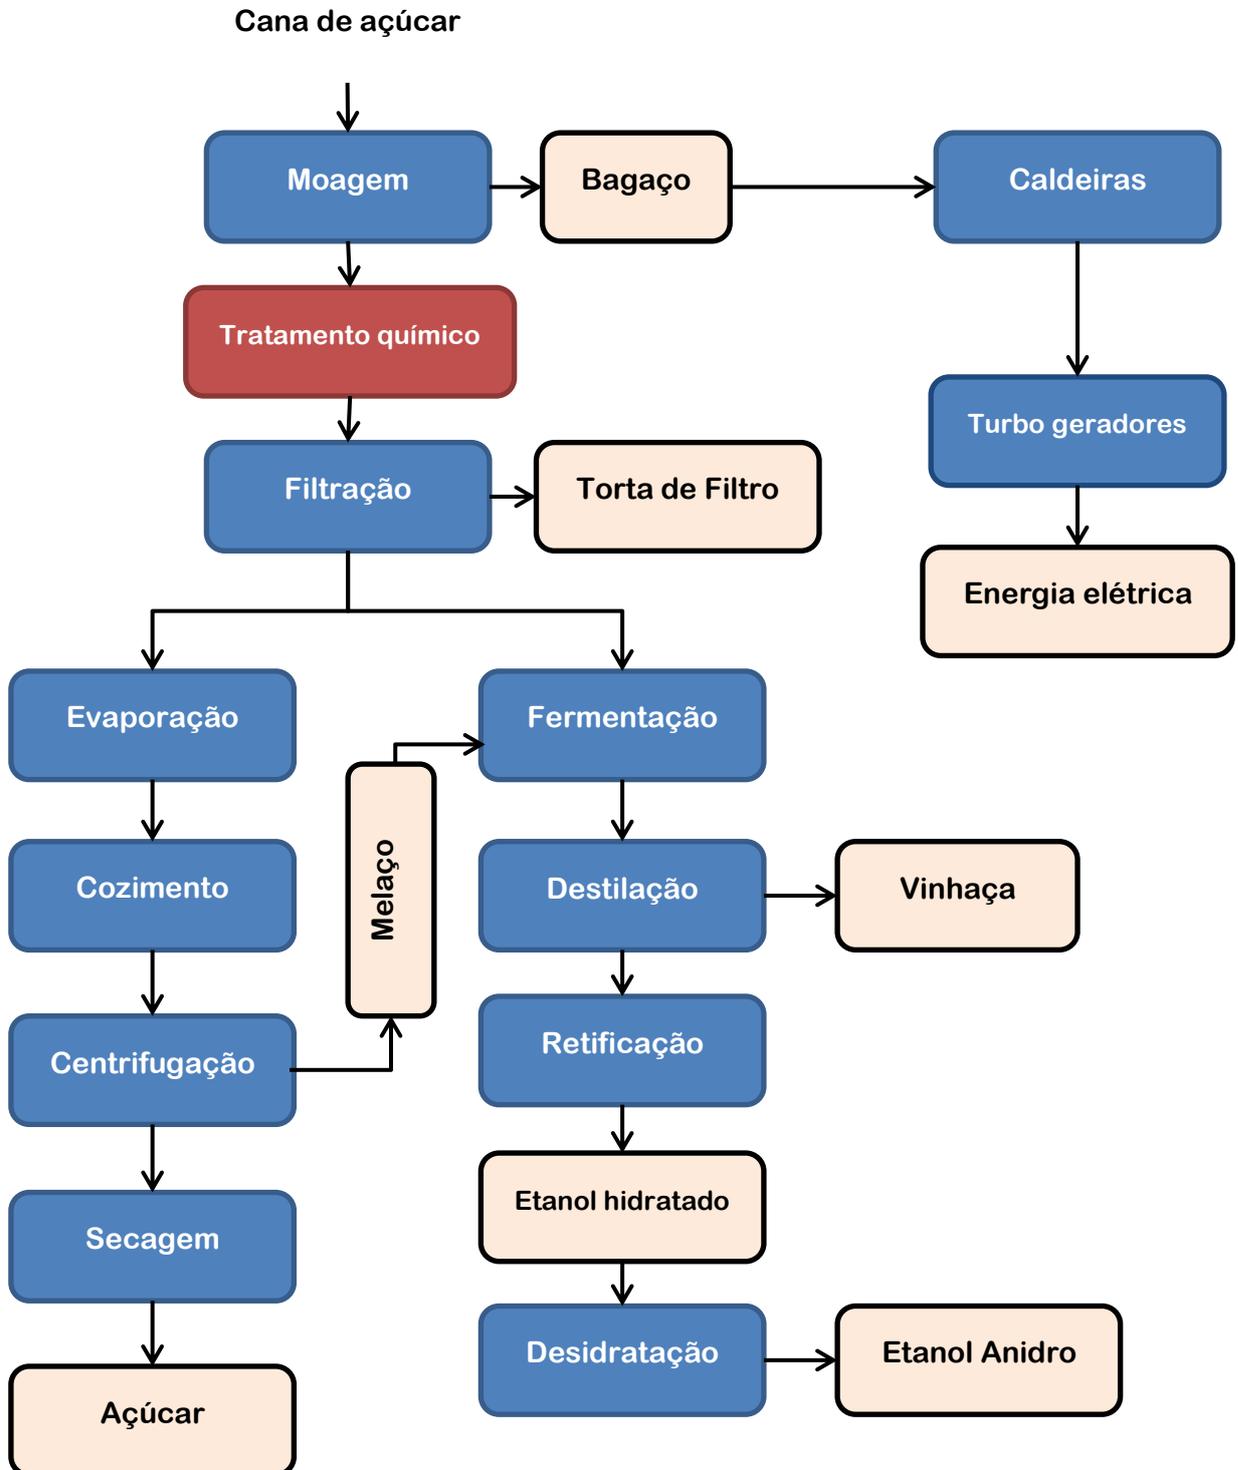


Figura 1. Diagrama de blocos simplificado dos processos.  
Fonte: Autoria Própria.

Em seguida, a cana passa por picadores que trituram os colmos, preparando-a para a moagem. Neste processo as células da cana são abertas sem perda do caldo. Em seguida, a cana desfibrada é enviada à moenda para ser moída e extrair o caldo. Na moenda, a cana desfibrada é exposta entre rolos submetidos a uma alta pressão de aproximadamente 160 kgf/cm<sup>2</sup> expulsando o caldo do interior das células. Este processo é repetido cinco vezes e a adição de água é efetuada nesse momento. Ao processo de adição de água dá-se o nome embebição, cuja função é embeber o interior das células da cana diluindo o açúcar ali existente e com isso aumentando a eficiência da extração, conseguindo-se assim quase 100% do açúcar contido na cana. O caldo extraído vai para o processo de tratamento do caldo e o bagaço para as caldeiras.

No tratamento químico, o caldo extraído na moenda, chamado de caldo misto, é um caldo impuro, sendo necessário passar por um processo de clarificação para retirada de sólidos em suspensão. O caldo é sulfitado e caleado (adição de enxofre e cal) para facilitar a floculação das substâncias coloidais. Após a dosagem destes insumos, o caldo é aquecido e enviado aos clarificadores que retêm o caldo por um período em regime contínuo. Neste tempo de retenção, ocorrem reações de floculação e precipitação do material em suspensão que são retirados na forma de lodo. O caldo clarificado e limpo segue o processo para evaporação e o lodo irá para filtração onde é recuperada a sacarose ainda existente.

A Filtração ocorre porque o lodo ainda é rico em sacarose. Nesta fase é realizada uma filtração nos filtros tipo prensa para reter o material líquido, chamado de caldo filtrado, que sofrerá novo tratamento de clarificação. O material sólido que fica retido nas telas dos filtros é chamamado de torta de filtro. Esta torta é enviada à lavoura, sendo utilizada como adubo. Nesta fase do processo ocorre a separação entre a produção de álcool e açúcar e cada um segue suas etapas de fabricação.

### 2.1.1 Fabricação de açúcar

A etapa da evaporação recebe o caldo clarificado (com cor de aproximadamente 20.000 ui) entra em um conjunto de evaporadores de múltiplo efeito para a retirada de maior parte da água, tomando consistência de um xarope. Este xarope é bombeado aos tachos de cozimento para a cristalização do açúcar.

---

O cozimento no processo de fabricação do açúcar é dividido em três tipos: Cozimentos A, B e C. No cozimento os tachos de cozimento são equipamentos que continuam a evaporação do xarope, tornando o meio supersaturado dando as condições necessárias à cristalização da sacarose. As centrífugas são responsáveis por separar o mel do açúcar. O mel proveniente desta separação volta para o processo para reaproveitamento, enquanto o açúcar (refinado ou demerara) vai para o ensacamento, onde é embalado e comercializado.

Na etapa de secagem o açúcar passa no secador para a retirada da umidade contida nos cristais. Na saída do secador, o açúcar é enviado por esteiras sanitárias até a moega de açúcar (reservatório próprio para açúcar), de onde é feito o ensacamento. Em seguida, no ensacamento açúcar é ensacado em sacos de 50 kg ou em contêineres ("*big bags*") de 1250 kg.

### 2.1.2 Fabricação de álcool

Durante o processo de fermentação ocorre a transformação dos açúcares em etanol. Utiliza-se uma levedura especial para fermentação alcoólica. No processo de transformação dos açúcares em etanol há desprendimento de gás carbônico e calor, portanto, é necessário que as dornas (grandes tanques metálicos) sejam fechadas para recuperar o álcool arrastado pelo gás carbônico e o uso de trocadores de calor para manter a temperatura nas condições ideais para as leveduras.

Após a fermentação, a levedura é recuperada do processo por centrifugação, em separadores que segregam o fermento do vinho. O vinho delevurado irá para os aparelhos de destilação onde o álcool é separado, concentrado e purificado. O fermento, com uma concentração de aproximadamente 60%, é enviado às cubas de tratamento.

Na destilação do vinho obtem-se um subproduto importante, a vinhaça. A vinhaça é rica em água, matéria orgânica, nitrogênio, potássio e fósforo, e é utilizada na lavoura para irrigação da cana, na chamada fertirrigação. Após o processo de destilação ocorre a retificação onde são acrescentadas substâncias corretivas até que o álcool esteja pronto para a fase de desidratação e origine o etanol anidro.

### 2.1.3 Produção de energia elétrica

Segundo definição da Agência Nacional de Energia Elétrica (Aneel) a cogeração de energia é o processo de produção combinada de calor útil e energia mecânica, geralmente convertida total ou parcialmente em energia elétrica, a partir da energia química disponibilizada por um ou mais combustíveis. A cogeração trata-se da associação da geração simultânea combinada de dois ou mais tipos de energia, utilizando um único tipo de fonte energética. No caso em questão, a fonte energética é o bagaço de cana que, ao ser queimado na fornalha das caldeiras, gera energia térmica em forma de vapor e, por sua vez, energia mecânica através da movimentação dos rotores das turbinas de acionamento dos geradores e por sua vez energia elétrica. A unidade possui capacidade instalada de geração de energia de 30 MW (um conjunto turbogerador de 15 MW, um conjunto turbogerador de 10 MW e um conjunto turbogerador de 05 MW). Na safra 2020/2021 (ano de coleta das informações) a planta possuía uma produção média de 17 MWh, dos quais 11 MWh eram consumidos pela fábrica, 4 MWh eram destinados para irrigação da cana de açúcar e o excedente 2 MWh eram destinados a exportação de energia elétrica. Na Figura 2 estão ilustrados os 03 (três) turbogeradores da USICODA.

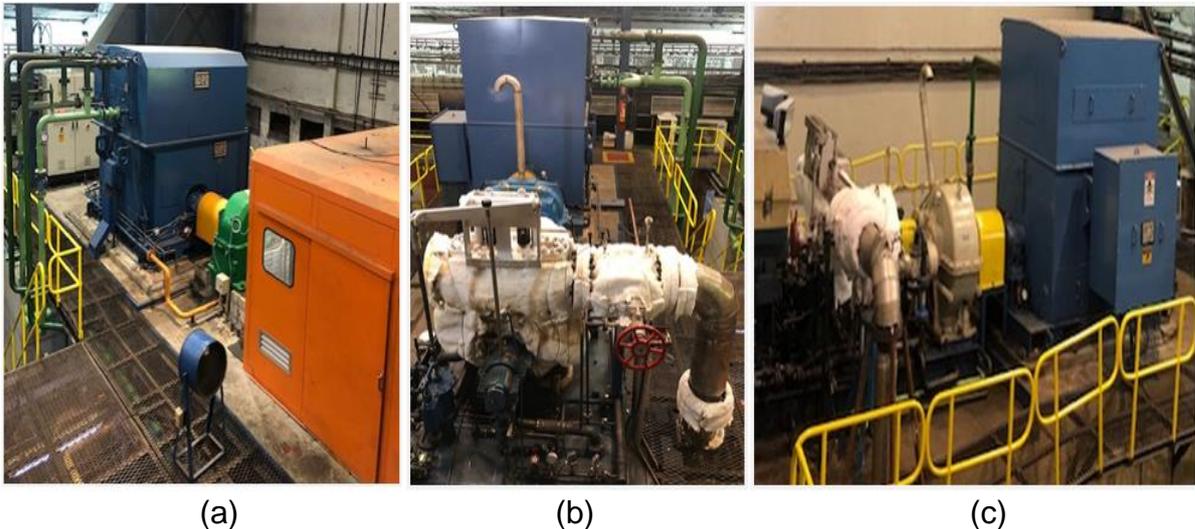


Figura 2. Conjuntos turbogeradores da USICODA.  
(a) TG3 – 15 MW, (b) TG2 – 10 MW E (c) TG1 05 MW.  
Fonte: Autoria Própria.

---

A unidade opera com dois conjuntos turbogeradores (normalmente o TG2 e TG3) e o terceiro conjunto (TG1) fica em modo *stand by*.

## 2.2 SOFT SENSORS

O termo *soft sensor* tem aparecido repetidamente no monitoramento de processos industriais. O termo combina as palavras "*software*", porque os modelos de avaliação do sinal do sensor são normalmente implementados em programas de computador, e "*sensors*", porque esses modelos estão entregando informações semelhantes aos sensores físicas. A ideia central por trás de um *soft sensor* é usar dados *on-line* (ou não) facilmente acessíveis para estimar variável que são difíceis de medir (LUTTMANN, 2012).

O *soft sensor* é um tipo de modelo matemático que representa o funcionamento de um sensor. O modelo recebe dados de variáveis secundárias e obtém o valor calculado da variável de processo requerida. Nesse sentido, os *soft sensors* podem ser utilizados como substitutos ou verificadores de desempenho aos sensores tradicionais, quando sua performance está aquém do esperado ou quando não existe possibilidade de uso de um sensor tradicional (LOTUFO, 2008). Alguns itens refletem a necessidade de implementação de *soft sensors*, são eles: erros de medição, disponibilidade e confiabilidade, atrasos de medição, distância do ponto de medição, ambiente de medição inapropriado e custo.

De forma geral, existem dois tipos de *soft sensors*, denominados *soft sensors* orientados por modelo e orientados por dados. Os orientados por modelos também são chamados de modelos de caixa branca porque eles têm conhecimento completo sobre os antecedentes do processo. Em contrapartida, os modelos baseados em dados são chamados de técnicas de caixa preta porque o modelo em si não tem conhecimento sobre o processo e é baseado em observações empíricas do processo (BODYGAN, 2009).

Os *soft sensors* orientados a modelos (MDM - *Model Driven Models*), são desenvolvidos principalmente para fins de planejamento e desenvolvimento das plantas do processo. Esses modelos são baseados em equações que descrevem os princípios químicos e físicos subjacentes ao processo. Um exemplo típico é o uso de princípios de preservação de massa, equações exotérmicas, balanços de energia,

cinética de reação na forma de equações de taxa de reação para este propósito. A desvantagem deste tipo de modelo é que seu desenvolvimento requer muito conhecimento específico dos processos. Esse conhecimento nem sempre está disponível. Por exemplo, para processos bioquímicos, muitas vezes não há conhecimento fenomenológico suficiente para uma descrição precisa dos processos em questão (BOGDAN, 2009).

Ao considerar o desenvolvimento de sensores virtuais orientados a dados, ferramenta tratada neste trabalho, tem-se como principal abordagem as técnicas aplicadas na área da identificação de sistemas para obtenção de modelos. A área de identificação de sistemas tem como objetivo propor métodos para a obtenção de modelos que sejam capazes de explicar a relação de causa e efeito presente em dados de entrada e saída. Uma das “vantagens” e principais características dessas técnicas está no fato de que não é necessário, em primeira instância, ter conhecimento sobre a física do sistema que se deseja identificar. Com isso, essas técnicas são referidas como identificação caixa-preta ou modelagem empírica (AGUIRRE, 2015).

Para sensores virtuais orientados a dados, Fortuna et al. (2007) apresenta a metodologia descrita na Figura 3, para o procedimento de identificação quando apenas dados históricos estão disponíveis para o projeto de um sensor virtual.

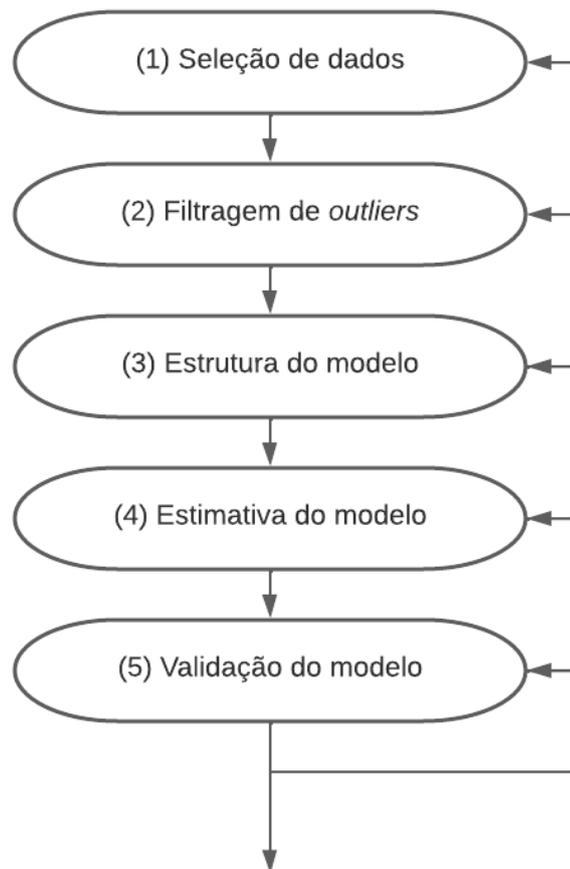


Figura 3. Procedimento de identificação de um sensor virtual.  
Fonte: FORTUNA, 2007.

Disponer apenas de dados históricos de uma planta industrial é uma situação comumente encontrada nos casos reais para o projeto de sensores virtuais. Nem sempre testes podem ser realizados. Assim, uma análise dos dados disponibilizados sobre a operação do processo de interesse deve ser realizada de modo a determinar se esses dados são ou não adequados para o projeto de sensores. Após análise dos dados históricos para detecção de transientes, passo (1), um segundo passo pode ser realizado para tratamento desses dados, dependendo da qualidade deles. No passo (2), tem-se o uso de técnicas relacionadas a processamento e filtragem de sinais, de modo a eliminar valores espúrios e outliers.

No passo (3), é necessário determinar qual representação matemática e qual estrutura será usada no modelo a ser identificado. Para esse caso, têm-se diversas estruturas possíveis, e não se tem uma forma fechada para determinar qual

---

é a melhor para ser usada. Em (Aguirre, 2015), são abordados alguns dos tipos de modelos que são comumente utilizados para representação de sistemas.

Ao se determinar a estrutura aplicada ao modelo, passa-se a etapa (4), o qual tem por objetivo determinar quais os valores de parâmetros que melhor ajustam os dados coletados do sistema ao modelo proposto para descrever a dinâmica implícita nos mesmos. Por fim tem-se o passo (5), o qual corresponde à validação do modelo. Nesse passo são desenvolvidas análises de modo a avaliar em diferentes trechos de dados, em relação aos que foram usados para identificação, quão representativo o modelo obtido é para descrever a dinâmica do sistema identificado. Assim, caso os resultados atendam aos requisitos pré-especificados como desejáveis, o procedimento de identificação é finalizado. Caso contrário, deve-se reavaliar um dos passos que sejam necessários até que um modelo satisfatório seja encontrado.

Esse procedimento adotado por Fortuna et al. (2007) para o projeto de sensores virtuais orientados a dados faz referência aos passos da técnica de identificação de sistemas. Um *soft sensor* pode ser projetado para substituir a indisponibilidade momentânea ou permanente de um sensor em uma planta. Esta substituição pode ser exigida porque o sensor real tenha falhado ou porque ele foi removido para manutenção. Pode também acontecer que o sensor real seja usado em uma forma compartilhada (*time-sharing*), ou não exista no mercado um sensor razoável disponível.

Um exemplo que pode ser mencionado para a aplicação do uso desse tipo de sensor é no caso de fermentação de processos, em que não existem sensores capazes de medir em tempo real a concentração de biomassa e de seus produtos secundários, sendo necessária a análise por um cromatógrafo (custo de \$ 8000,00 - em 2008) ou a medição manual e análise por um especialista. Isso ocasiona lentidão nos processos industriais (LOTUFO, 2008). Outro exemplo de emprego dos *soft sensors* é estimar frações molares de Gás Liquefeito de Petróleo - GLP (Butano, Propano, Etano e Pentano) através de variáveis secundárias como temperatura, pressão, vazão e volume ao longo do processo (LIMA, 2018). Outras aplicações de *soft sensors* são para a substituição de um sensor físico real quando este passa por um período de falha ou manutenção, impedindo a parada dos processos.

---

Nesse sentido, os *soft sensors* são sistemas de inferência com o objetivo de modelar uma relação entre variáveis primárias, de difícil (ou impossível) medição, com variáveis secundárias, de medição direta (LIMA, 2018). Segundo Lima (2018), um problema que deve ser levado em consideração quando se pretende obter dados da variável primária em tempo real é que um sensor virtual deve ser realimentado pelos valores que ele mesmo estima das variáveis primárias. Porém, com o passar das estimativas, um acúmulo de erros será gerado, podendo até levar o sistema a um percentual de erro não aceitável para o que se propõe a fazer.

Para minimizar esse problema é necessário criar estratégias de correção dos *soft sensors* partir de outras medições ou calibração. Os modelos mais utilizados para caracterização desses sensores na literatura são Redes Neurais Artificiais (RNA), Lógica Fuzzy, Algoritmos genéticos e modelos autorregressivos.

### 2.3 REDES NEURAIAS ARTIFICIAIS

O desenvolvimento das redes neurais artificiais (RNA) foi motivado pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um sistema de processamento de informação altamente complexo, não linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos muito mais rapidamente que o mais rápido computador digital (HAYKIN, 1999).

As redes neurais tentam, de alguma forma, mimetizar este funcionamento. Estima-se que haja aproximadamente 10 bilhões de neurônios no córtex cerebral e 50 trilhões de sinapses (ou conexões entre neurônios). A função de um neurônio isolado é relativamente bem conhecida, porém, o seu comportamento coletivo e interações no conglomerado de elementos cerebrais são pouco claros e carentes de postulados. Conseqüentemente, a arquitetura das redes neurais é baseada em um conhecimento primitivo das funções de um sistema nervoso biológico (WILLIS et al, 1992).

Segundo Haykin (1999), a rede neural artificial funciona como um processador paralelo distribuído, constituído de unidades simples de processamento, que possui uma propensão natural para armazenar conhecimento de experiências.

Ela imita o cérebro em dois aspectos: o conhecimento é adquirido do ambiente pela rede através do processo de aprendizado e o conhecimento adquirido é armazenado através da definição de pesos internos, análogos às conexões sinápticas dos neurônios.

Os neurônios artificiais são, portanto, formado por unidades de processamento simples, que são interconectados por ligações com um peso associado e possuem um valor de limiar, conhecido como *bias*. A Figura 4 mostra um exemplo de uma rede neural simples. A camada de entrada é responsável por receber os dados (informações), sinais, características ou medições. Essas entradas são geralmente, normalizadas com relação às faixas de variações dinâmicas produzidas por alguma das funções de ativações anteriormente definidas. A camada oculta é responsável por extrair as características que estão associadas ao processo ou sistema. A camada de saída é responsável pela produção e apresentação dos resultados finais da rede, os quais são oriundos dos processamentos efetuados pelos neurônios das camadas anteriores.

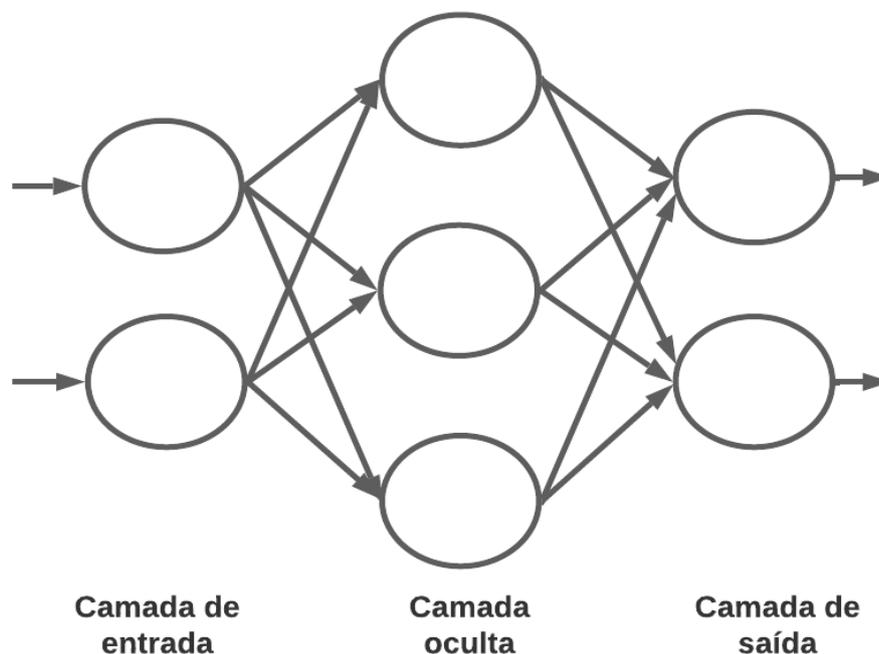


Figura 4. Rede Neural Artificial com uma camada oculta.  
Fonte: HAYKIN, 1999.

---

A capacidade de aprender através de exemplos e de generalizar a informação aprendida são, sem dúvida, os atrativos principais da solução de problemas através de redes neurais artificiais. A generalização, que está associada à capacidade da rede aprender através de um conjunto reduzido de exemplos e posteriormente dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das redes neurais vai muito além do que simplesmente mapear relações de entrada e saída. Elas são capazes de extrair informações não apresentadas de forma explícita através dos exemplos. As redes neurais são capazes de atuar como mapeadores universais de funções multivariáveis, com custo computacional que cresce apenas com o número de variáveis. Outras características importantes são a capacidade de auto-organização e de processamento temporal que, aliadas àquelas citadas anteriormente, fazem das redes neurais artificiais uma ferramenta computacional extremamente poderosa e atrativa para solução de problemas complexos (BRAGA; CARVALHO; LUDEMIR, 1998).

A solução de problemas através de redes neurais artificiais é bastante atrativa, pois a forma como estes são representados internamente e o paralelismo natural inerente à arquitetura criam a possibilidade de um desempenho superior aos modelos convencionais. As principais propriedades e capacidades que as tornam tão difundidas são: não linearidade (a rede neural é capaz de entender as não linearidades e esta característica é distribuída por toda a rede), tolerância a falhas (devido a sua natureza redundante e distribuída a rede pode sofrer perdas de neurônios locais que o comportamento geral é pouco afetado), adaptabilidade (uma rede neural pode facilmente adaptar seus pesos sinápticos para uma situação e assim acompanhar alterações do ambiente em que foi treinada) e mapeamento de entrada/saída (através dos exemplos de entrada/saída a rede é capaz de aprender a reconhecer padrões, em um processo que lembra a inferência estatística não paramétrica) (ZANATA, 2005).

As redes neurais artificiais têm se destacado devido à facilidade de implementação com poucos hiperparâmetros para ajustar, apresentar boa adaptação a sistemas não lineares, alta tolerância a dados ruidosos. (HAN; KAMBER; PEI, 2011; HAYKIN, 2009).

---

Neste trabalho se pretende empregar redes neurais artificiais para desenvolver o sensor virtual (*soft sensor*), para medição de vazão do caldo caledado, por ela ser uma técnica que tem sido bastante utilizada nos últimos anos nesse tipo de aplicação e apresentando resultados acima da média comparado com outras técnicas de identificação de sistemas.

## 2.4 ANÁLISE DE INCERTEZAS EM MODELOS DE RNA BASEADO NO *DROPOUT*

As RNAs são modelos complexos, com uma elevada quantidade de parâmetros e hiperparâmetros. Porém, uma das dificuldades frequentemente encontrada ao escolher esse modelo é o *overfitting*, ou seja, a perda da capacidade de generalização da RNA. Alguns métodos de regularização são utilizados para atenuar esse problema como, por exemplo, o Early Stopping, a Regularização L1 e L2 e o entre outros. O *dropout* diferentemente dos métodos citados, utiliza de ferramentas probabilísticas para reduzir a complexidade do modelo.

Em um processo ideal em que o custo computacional não fosse um problema, utilizar a média ponderada da previsão do modelo com diferentes parâmetros, com pesos determinados pela probabilidade a posteriori dos dados, seria a melhor maneira de realizar uma previsão.

Com a finalidade de utilizar esse resultado de uma maneira simplificada, o *dropout* combina várias redes neurais a partir da desativação de neurônios aleatoriamente durante a fase de treinamento, determinada por uma probabilidade  $p$ .

Durante a fase de teste, todos os neurônios são ativados, porém os pesos treinados recebem um ganho  $p$ , assim, pode-se interpretar a previsão da rede neural nessa fase como uma média das previsões das várias redes treinadas.

O *dropout* é uma técnica utilizada para evitar que o modelo da RNA não fique sobreajustado (*overfitting*) durante o processo de treinamento. Os neurônios que serão desativados durante cada camada em treinamento são escolhidos de forma aleatória. A rede, geralmente, é configurada para eliminar (*dropout*) as ligações entre neurônios e camadas. A utilização de *dropout* aumenta consideravelmente a quantidade de interações necessárias para que a rede acabe convergindo, no entanto, isso é compensado pela redução de épocas necessárias

para que o objetivo seja alcançado, conforme apresentado na Figura 5 (SRIVASTAVA, 2014).

Utilizando este resultado de maneira simplificada, o *dropout* combina várias redes neurais artificiais a partir da desativação aleatória de neurônios durante a fase de treinamento, determinada por uma probabilidade  $\rho \sim \text{Bernoulli}$ , conhecida como probabilidade de *dropout*.

A Figura 5 ilustra a arquitetura da RNA durante uma iteração com desativação dos neurônios (os neurônios e conexões desativados são os ilustrados com linhas pontilhadas).

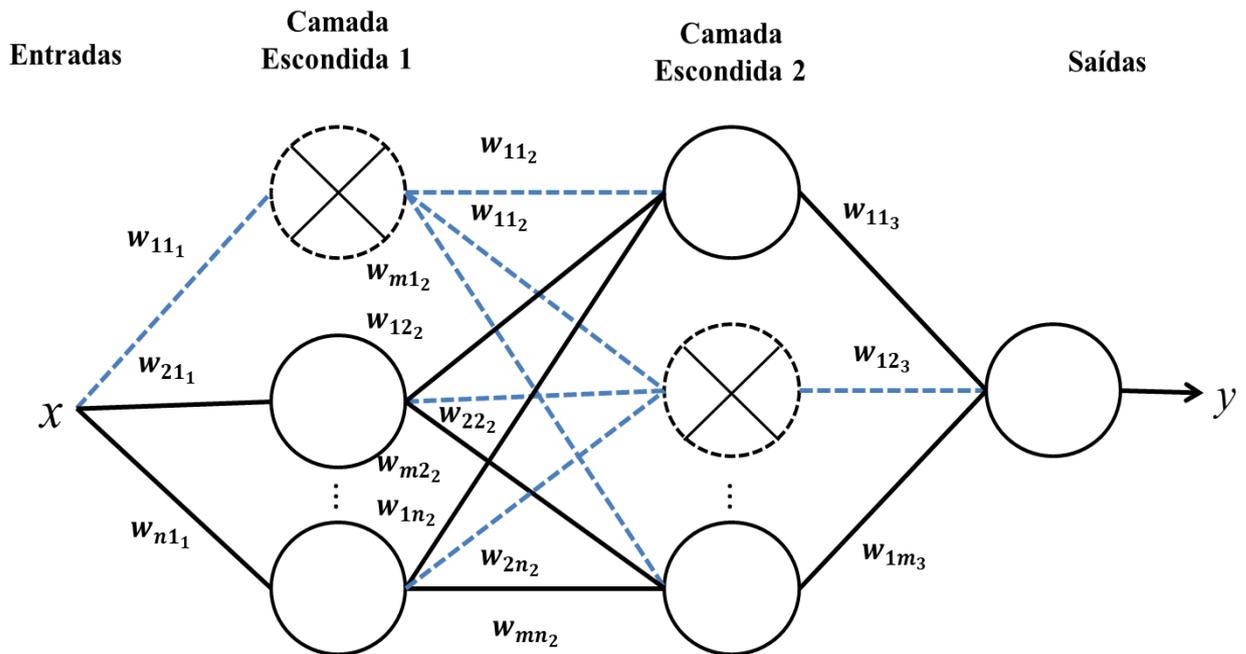


Figura 5. Arquitetura de uma RNA com neurônios desativados.

Fonte: Autoria própria.

Já na fase de inferência, todos os neurônios são ativados e os pesos sinápticos multiplicados pela probabilidade de *dropout*. Ao utilizar esse método, é possível interpretar as saídas da rede neural treinada como uma média ponderada das saídas de diferentes redes neurais. A Figura 6 ilustra a arquitetura da rede durante a fase de inferências ao utilizar a técnica *dropout*.

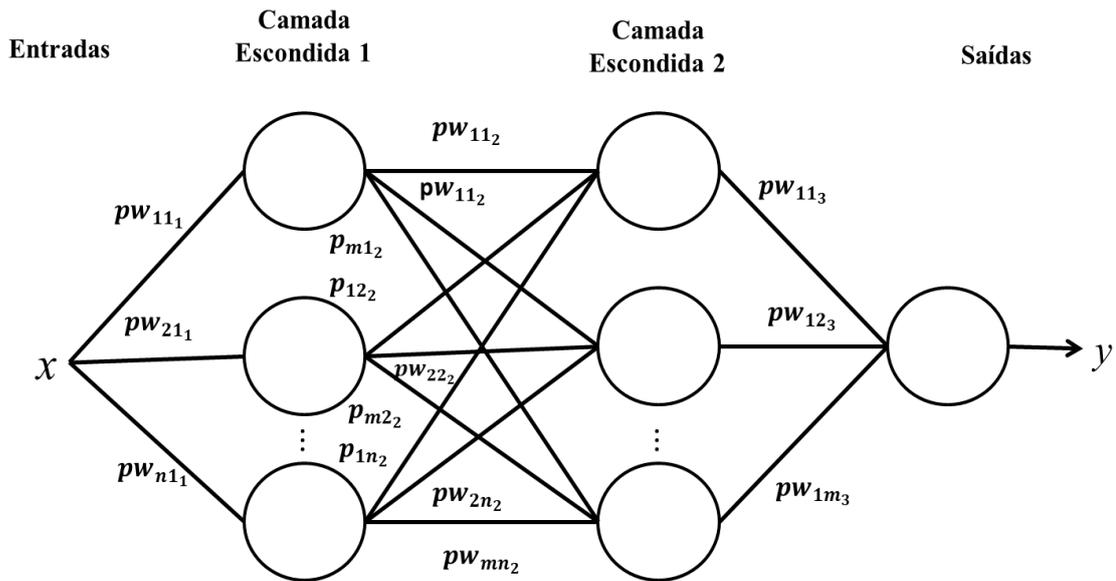


Figura 6. Arquitetura da RNA *dropout* durante a fase de inferências.  
Fonte: Autoria própria.

#### 2.4.1 Descrição matemática do *dropout*

Considerando uma rede neural com  $L$  camadas ocultas, sendo  $l$  o índice da camada,  $l \in \{0, 1, \dots, L - 1\}$ . Ainda, sendo  $y^{(l)}$  o vetor de saídas da camada  $l$ ,  $W^{(l)}$  os pesos e  $b^{(l)}$  os bias da camada  $l$ .

$$y^{(l+1)} = f(W^{(l+1)}y^l + b^{(l+1)}) \quad (1)$$

em que:  $f$  é a função de ativação usada nos neurônios. Sendo  $r^{(l)}$  a variável aleatória determinada por uma distribuição Bernoulli  $r \in \{1, 0\}$ . Podemos descrever matematicamente as operações *feed-forward* (sinal partindo da entrada até a saída) do modelo com o *dropout* e compará-lo com o modelo padrão.

$$r_i^l \sim \text{Bernoulli}(p) \quad (2)$$

$$\tilde{y}^{(l)} = r^{(l)} * y^{(l)} \quad (3)$$

$$y^{(l+1)} = f(W^{(l+1)}\tilde{y}^{(l+1)} + b^{(l+1)}) \quad (4)$$

---

Em que, “ $*$ ” representa a multiplicação elemento a elemento (produto Hadamard).

Durante a fase de teste a matriz de peso é escalonada:  $W_{test} = pW_{train}$ . A probabilidade de *dropout*,  $p$ , é um hiperparâmetro que define a chance da variável aleatória  $r_i^{(l)}$  ser igual a 0, representando assim a desativação do neurônio. Segundo Srivastava et. al, o uso do Dropout é normalmente otimizado com os valores de  $p = 50\%$  para as camadas escondidas e  $p = 80\%$  para a camada de entrada (SRIVASTAVA, 2014).

#### 2.4.2 Avaliação de Incerteza por meio da Análise Monte Carlo Dropout

O trabalho de Daminanou e Lawrence (2013) apresenta o fato de que uma Rede Neural com *dropout* aplicado a camada é matematicamente equivalente a um processo Gaussiano profundo. Seguindo este enfoque, Gal e Ghahramani (2016), desenvolveram um método para utilizar essa técnica e obter a incerteza associada a um valor estimado pela rede neural artificial com baixo custo computacional.

A técnica de regularização *dropout* padrão é ativada durante a fase de treinamento, ajustando várias configurações de redes neurais, e desativada durante a fase de inferência, as várias redes são utilizadas em conjunto fazendo uma média ponderada das previsões. Porém, no modelo Monte Carlo Dropout, é proposto que o *dropout* mantenha-se ativado durante a fase de teste, permanecendo com a característica não determinística da rede e assim possibilitando a coleta de amostras diferentes de uma mesma previsão. Com isso, pode ser calculada uma média e uma variância da rede que demonstram a incerteza do modelo.

Apesar de a matemática envolvida na explicação do modelo Monte Carlo Dropout como uma aproximação de modelos Bayesianos, esta envolve conhecimentos avançados de estatística que não se fazem necessário nesta pesquisa, o entendimento dos resultados pode ser realizado de maneira simples e faz-se importante para compreender sua utilização prática.

Além disso, toda prova matemática e os resultados explanados neste trabalho podem ser visualizados através do apêndice: “Dropout as a Bayesian Approximation: Appendix” (GAL and GHAHRAMANI, 2016).

Como pode ser visto na Equação 5, esse método consiste na adição de penalidades ao aumento do módulo dos pesos na função de custo.

$$\mathcal{L}_{dropout} := E + \lambda_1 \|W_1\|^2 + \lambda_2 \|W_2\|^2 + \lambda_3 \|b\|^2 \quad (5)$$

Em que:  $\mathcal{L}_{dropout}$  é a função de custo com que o algoritmo irá minimizar  $E$ , o erro obtido pela diferença entre saídas e os valores alvos e, por fim  $\lambda$  é o vetor “*weight-decay*” que define o quão penalizado o modelo será pelo aumento dos pesos.

Para uma rede com  $L$  camadas, com  $T$  amostras dos vetores da distribuição de Bernoulli  $\{r_1^t, \dots, r_L^t\}_{t=1}^T$ , dados os pesos  $W_1^T, \dots, W_L^T$ , estima-se o momento de primeira ordem através da Equação (6):

$$E_{q(y^*|x^*)}(y^*) \approx \frac{1}{T} \sum_{t=1}^T \hat{y}^*(x^*, W_1^t, \dots, W_L^t) \quad (6)$$

Durante os procedimentos para realizar o cálculo há a necessidade de utilizar o método de Monte Carlo Dropout à técnica. Na prática, o método é equivalente a performar  $T$  vezes a rede com a mesma entrada e realizar a média das saídas.

Junto a isso, como a variância das saídas nas  $T$  vezes performadas é dada por:

$$Var^T = \frac{1}{T} \sum_{t=1}^T \hat{y}^*(x^*, W_1^t, \dots, W_L^t)^T \hat{y}^*(x^*, W_1^t, \dots, W_L^t) - E_{q(y^*|x^*)}(y^*)^T E_{q(y^*|x^*)}(y^*) \quad (7)$$

O momento de segunda ordem poderá ser estimado como:

$$Var_{q(y^*|x^*)}(y^*) \approx \tau^{-1} I_D + Var^T \quad (8)$$

Ou seja, o momento de segunda ordem do modelo é dado pela soma algébrica da variância das  $T$  saídas com o inverso de  $\tau$ , variável compreendida como precisão do modelo.

A literatura adota a variância como principal medida de incerteza, porém também pode-se adotar o desvio padrão como incerteza ao calcular a raiz quadrada da variância obtida após os  $T$  *forward-passes*. A precisão do modelo é determinada

utilizando a quantidade de dados de treinamento ( $N$ ) e por meio dos hiperparâmetros: probabilidade de retenção ( $1 - p$ ), peso da regularização  $L_2(\lambda)$  e *length scale* ( $l$ ) que refere-se a crença da frequência da série: quanto menor for  $l$  maior será a crença na variação abrupta (maior frequência) dos dados. Esta expressão é dada pela Equação (9).

Como dito anteriormente, utilizando este procedimento será possível obter a média e a variância das previsões e dessa forma capturar a incerteza do modelo.

$$\tau = \frac{(1-p)^2}{2N\lambda} \quad (9)$$

A Figura 7 descreve o fluxograma que explicita a sequência relativa a fase de inferência de um vetor de saídas com a utilização do algoritmo Monte Carlo Dropout

A ferramenta para análise da incerteza de medição foi utilizada em linguagem Python, pois não há rotinas bem desenvolvidas no MATLAB para este algoritmo. A primeira etapa ocorre em  $t = 1$ , em seguida ocorre à determinação dos hiperparâmetros. O próximo passo é a atualização da RNA desativando neurônios (*dropout*), e em seguida realimentando a rede. Armazenam-se os dados de saída e continua o processo até  $t = T$ . Na sequência, calcula-se a média e a variância para avaliação dos resultados obtidos.

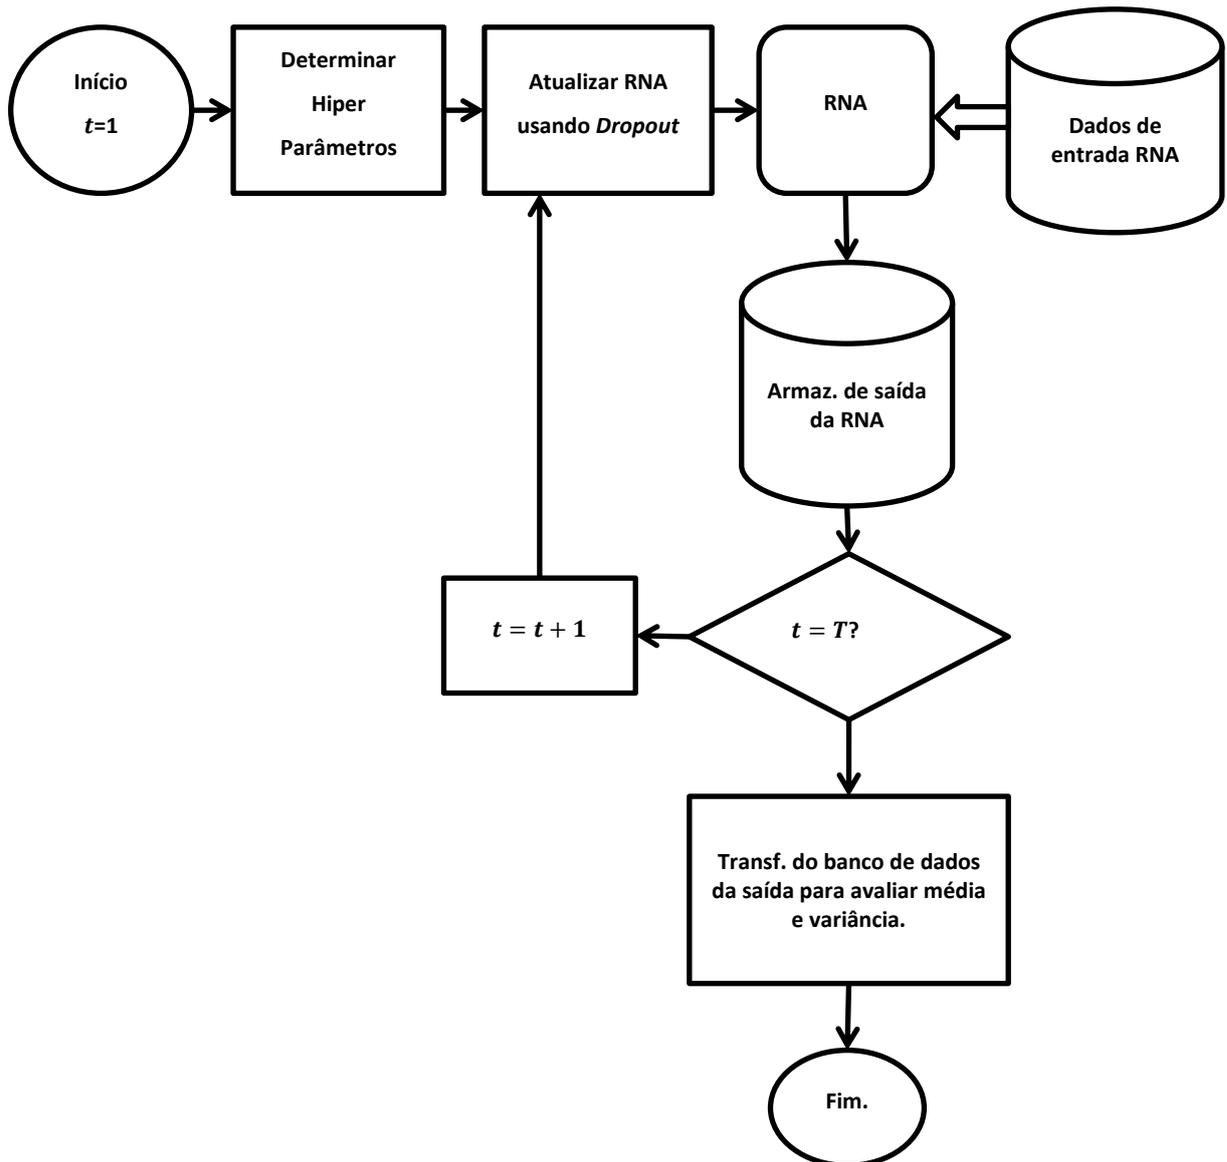


Figura 7. Fluxograma de inferência com o modelo Monte Carlo Dropout.  
Fonte: Autoria própria.

### **3 MATERIAIS E MÉTODOS**

### 3 METODOLOGIA PARA O DESENVOLVIMENTO DO *SOFT SENSOR*

Neste capítulo será apresentada a metodologia para o desenvolvimento de um modelo de *soft sensor* para medição de vazão de caldo caledado do sistema de tratamento de caldo da usina. Nesta abordagem foi previsto um novo método de modelagem de medição de vazão, seguindo os conceitos fundamentais de *soft sensors*.

A medição de vazão do caldo caledado é realizada por meio de um tubo medidor tipo magnético com diâmetro de 12 polegadas, modelo OPTIFLUX 4000F, fabricante Conault, ilustrado na Figura 8 e o conversor modelo IFC050W, fabricante Krohne, precisão de medição de  $\pm 0,5\%$  do valor medido, repetibilidade de  $\pm 0,1\%$  do valor medido (calibrado para 0 a 600 m<sup>3</sup>/h) conforme ilustrado na Figura 9. Os medidores de vazão eletromagnética, ou magnetômetros, são compostos de um transmissor e sensor que juntos medem a vazão. O sensor do medidor de vazão magnética é colocado na tubulação e mede uma tensão induzida gerada pelo fluido conforme ele flui pelo tubo. O transmissor captura a tensão gerada pelo sensor, converte em uma medição da vazão e transmite essa medição da vazão para um centro de controle operacional.



Figura 8. Tubo medidor de vazão do caldo caledado.  
Fonte: Autoria própria.

Estes equipamentos possuem alto custo (aproximadamente R\$ 45.00,00 – valores em 2022) em sua aquisição. Além do custo com a compra a calibração deve ser realizada a cada dois anos, exigência da qualidade do produto. Outro detalhe importante é que as aferições destes equipamentos só podem ser realizadas por laboratórios específicos e credenciados, pois os certificados precisam ser apresentados nas auditorias de qualidade do açúcar. A aferição quando optada por ser feita em campo, utiliza sensores ultrassônicos, que possuem um custo de instalação elevado e a metodologia exige a garantia de uma determinada velocidade do fluido e pressão, variáveis que nem sempre estão disponibilizadas no chão de fábrica.

A operação estável e constante do decantador de caldo (local de entrada do caldo caleado) aliada a uma moagem contínua reflete em um correto funcionamento da evaporação e conseqüentemente um controle térmico (balanço) adequado, tendo como benefícios a qualidade do cozimento do açúcar e a eficiência energética do processo. Na Figura 10, está ilustrado o decantador de caldo (local onde entra o caldo caleado).

A gestão eficiente do processo deve contar com o acesso a indicadores importantes durante a operação para tomar de decisões estratégicas assertivas.



Figura 9. Conversor aplicado ao medidor de caldo caleado.  
Fonte: Autoria própria.

Com este propósito, torna-se fundamental e conveniente o desenvolvimento de um modelo de *soft sensor*, técnica na qual uma variável qualquer é relacionada por um modelo adequado associado a várias outras variáveis de processo que são passíveis de medições diretas e por meio do sistema de aquisição e automação da planta. Essa técnica é capaz de prever em tempo real variáveis de processo como por exemplo: pressão, temperatura, nível e vazões de diversos fluidos do processo.



Figura 10. Decantador de caldo.  
Fonte: Autoria própria.

O modelo de *soft sensor* desenvolvido neste trabalho tem a configuração apresentada na Figura 11. Os dados de vazão obtidos através do medidor físico são coletados através do histórico de dados do supervisor Indusoft 2020, fabricante Schneider, do tratamento de caldo da usina, cujo detalhamento será apresentado na seção da metodologia do trabalho. As saídas do sensor físico são comparadas aos dados de saída do modelo do sensor virtual. Em seguida, o erro é comparado e o modelo é ajustado utilizando a técnica de Redes Neurais Artificiais.

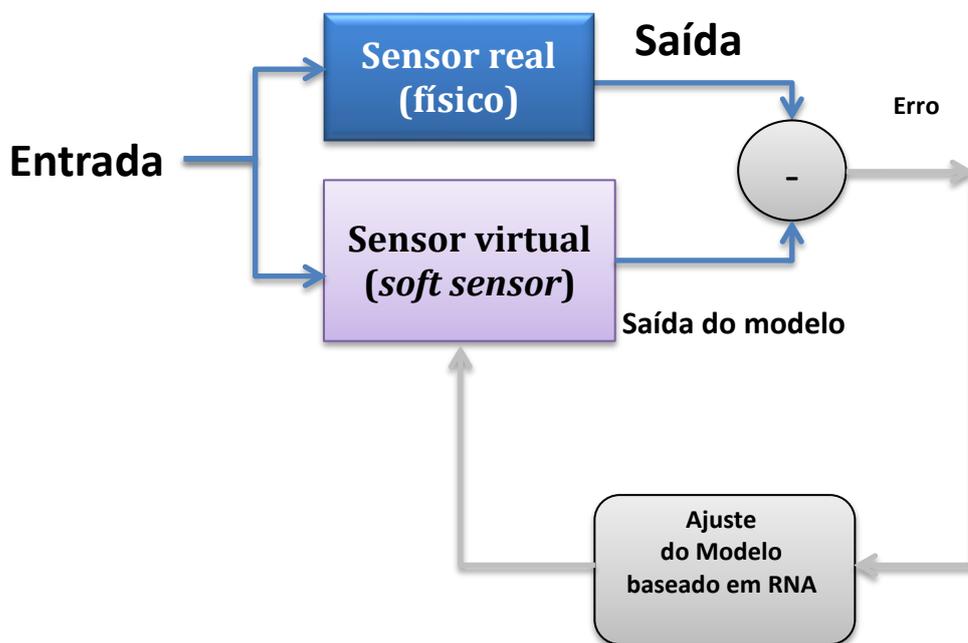


Figura 11. Configuração do modelo *soft sensor*.  
Fonte: Autoria própria.

A interatividade entre as variáveis de processos industriais permite que o estado de algumas dessas variáveis reflita no estado de outras variáveis. Dessa forma, um conjunto de dados obtidos através de sensores físicos instalados na própria planta podem fornecer as variáveis de entradas, tais como: temperaturas, pressões, níveis, vazões, entre outras com o objetivo de estimar a variável desejada, através de um sensor virtual.

A coleta dos dados das variáveis secundárias, etapa 1 da Figura 12, é a fase mais importante para obtenção da inferência de composição, pois se os dados forem não confiáveis, os modelos dos sensores virtuais também serão ruins (CAMPOS et

al., 2013). Muitas vezes, os dados fornecidos necessitam da remoção de estados estacionários ou de um pré-processamento (remoção de erros grosseiros). No entanto, a influência de certas variáveis pode ser apenas parcialmente independente de outras, ou pode variar com a região operacional do processo. Então, para obtenção do grupo de variáveis independentes (entradas) que irão compor o modelo, eliminam-se influências ambíguas (seleção de variáveis).

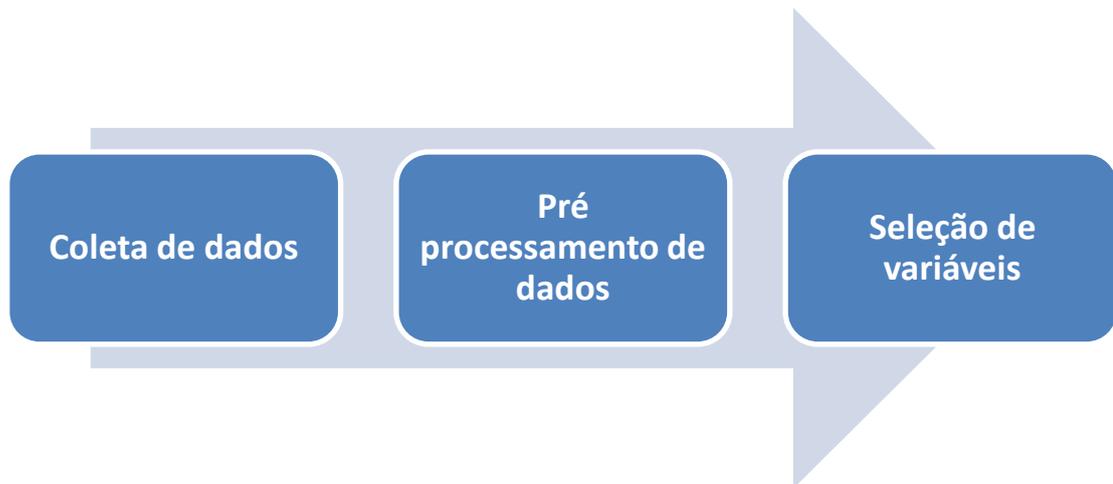


Figura 12. Diagrama de fluxo da metodologia adotada.  
Fonte: Autoria própria.

### 3.1.1 Coleta de dados

Devido às paradas para manutenção da planta (que funciona durante seis meses e sofre parada para manutenção durante seis meses) os dados gravados no banco de dados contêm uma grande quantidade de registros que caracterizam planta desligada, tais dados não apresentam utilidade para o modelo. Além disso, durante o processo de funcionamento, existem paradas planejadas para manutenção, assim, buscou-se no banco de dados intervalos de operação com maior tempo de funcionamento ininterrupto da planta no ano de 2021, para que contivesse o mínimo de informações de dados de planta desligada.

Foi extraído então um banco de dados com 8.641 amostras de algumas variáveis do processo denominadas de: Q1, SP\_Q1, PH1, SP\_PH1, H1, H2, N1, N2, PH2, SP\_PH2 e Q2, dados estes equivalentes ao período de moagem ocorrido em

---

20 de fevereiro 2020, com tempo de amostragem de dez segundos para cada uma das variáveis. O processo do tratamento de caldo está ilustrado na Figura 13. A seguir são apresentadas as legendas das variáveis do processo que foram coletadas para este trabalho.

- Q1 = vazão de saída do tanque de caldo misto;
- SP\_Q1 = *set point* de vazão de saída do tanque de caldo misto;
- PH1 = pH do caldo pré caleado;
- SP\_PH1 = *set point* do pH do caldo pré caleado;
- N1 = rotação da bomba de caldo misto;
- N2 = rotação da bomba de caldo caleado;
- H1 = nível do tanque de caldo misto;
- H2 = nível do tanque de caldo caleado;
- PH2 = pH do caldo caleado;
- SP\_PH2 = *set point* do pH do caldo caleado;
- Q2 = vazão de saída do tanque de caldo caleado (mexedeira).

Algumas das variáveis coletadas foram inicialmente descartadas, por se tratarem de set points, ou seja, são valores constantes desejáveis para as variáveis de processo. O tanque de caldo misto é um reservatório com capacidade 62 mil litros que recebe o caldo proveniente da moenda após a adição de água na etapa da extração. Em seguida, esse caldo (agora denominado caldo misto) é bombeado para um novo reservatório (denominado tanque da mexedeira de caldo) onde irá ser misturado com o sacarato de cálcio, (cal dissolvida em uma solução açucarada). Parte desta adição de sacarato acontece na própria tubulação e a outra parte dentro do próprio reservatório. A etapa de adição de sacarato que acontece antes do caldo entrar no tanque da mexedeira de caldo é chamada de pré caleação e a mistura realizada dentro da mexedeira, caleação. Toda dosagem de sacarato de cálcio é feita de forma automática utilizando eletrodos que conseguem medir o pH da mistura (entrada do controlador lógico programável) e inversores de frequência que controlam a velocidade dos conjuntos motobombas (saída do controlador). O controlador utilizado neste processo é o Citrino fabricante FERTRON.

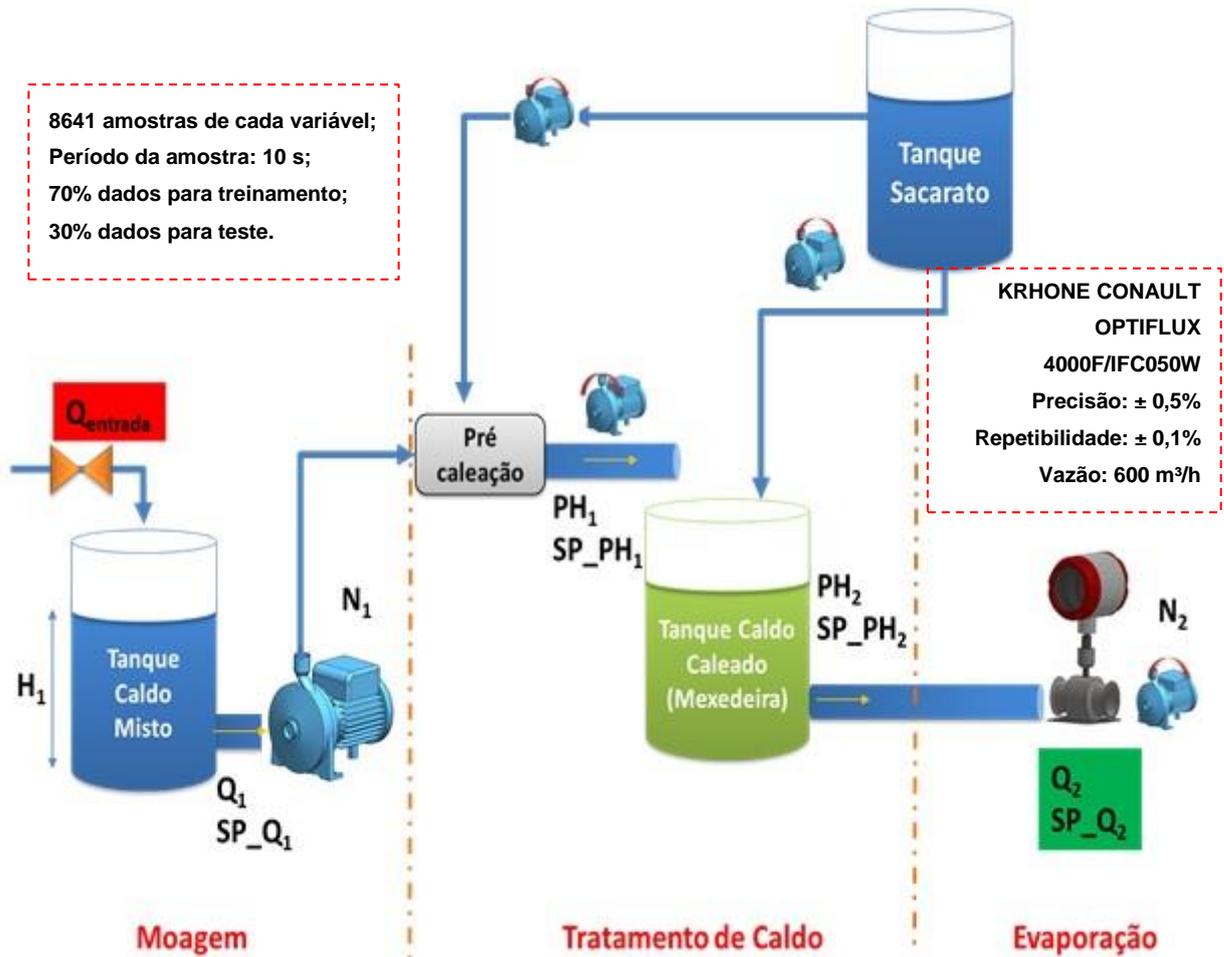


Figura 13. Esquema simplificado do processo para a coleta de dados.  
 Fonte: Autoria própria.

### 3.1.2 Pré-processamento de dados

A fase de pré-processamento inicia tão logo os dados são coletados e organizados na forma de um conjunto de dados. Podem existir diversos objetivos na fase de pré-processamento. Um deles é solucionar problemas nos dados, tais como identificar e tratar dados corrompidos, atributos irrelevantes e valores desconhecidos. Pode-se também estar interessado em aprender mais a respeito dos dados, o que pode ser feito, por exemplo, por meio de visualizações. Ou ainda, pode-se estar interessado em alterar a estrutura dos dados, por exemplo, por meio da alteração do grau de granulariedade dos dados. As ações realizadas na fase de

pré-processamento visam preparar os dados para que a fase seguinte, a fase de extração de conhecimento, seja mais afetiva (BATISTA, 2003).

De uma forma geral, pré-processamento de dados é um processo semiautomático. Por semiautomático entende-se que essa fase depende da capacidade da pessoa que a conduz em identificar os problemas presentes nos dados, além da natureza desses problemas, e utilizar os métodos mais apropriados para solucionar cada um dos problemas (BATISTA, 2003).

Para garantir que não sejam extraídas características incoerentes para as regras do sistema foi necessário o tratamento dos dados brutos com o objetivo de eliminar os dados espúrios, que podem ser gerados a partir da falha de conexão entre sensor e controlador, rompimento do cabo do sensor ou curto-circuito na malha de alimentação dos sensores, entre outros.

Foi utilizado um procedimento para detectar os dados considerados *outliers* a partir da média móvel de uma janela dos dados (100 pontos) e substituir esses pontos pelos valores limites considerados não espúrios. Como o tempo de amostragem foi 10 segundos, tem-se uma janela de 1000 segundos, o que equivale a 16 minutos, que é um tempo suficiente para recuperar amostras faltantes.

Nesta etapa de suavização a função *movmean* (para estabelecer a filtragem do ruído pela média móvel dos dados) foi aplicada. Utilizou-se o artifício da média móvel simples, que calcula a média a partir de uma sequência de amostras dentro da população, sendo bastante utilizada para se observar tendência de um conjunto de dados. Portanto, dada uma sequência:  $X = (x_1, x_2, \dots, x_n)$  e sendo  $n$  o número de elementos (ou o tamanho da janela de dados) de uma subsequência de  $X$ , a média móvel pode ser representada pela Equação 1.

$$\bar{x} = \frac{x_{i+1} + \dots + x_{i+n}}{n} = \frac{1}{n} \sum_{j=1}^n x_{i+j} \quad (1)$$

A função *replaceOutlierByMean* (para substituição dos valores e/ou *outliers* maiores que  $N$  (no caso analisado  $N = 3$ ) vezes o desvio padrão pela média móvel dos dados, cuja expressão é dada pela Equação 2.

$$z = \frac{x - \mu}{\sigma} \quad (2)$$

Onde,  $x$  é o valor da amostra,  $\mu$  é a média do conjunto de amostras e  $\sigma$  é o desvio padrão do conjunto de amostras.

### 3.4 MODELOS DO SOFT SENSORES DE VAZÃO USANDO RNA

Nesta etapa do projeto, foram criados dois modelos de *soft sensor*. O primeiro modelo, denominado Modelo 01, possui como entradas da RNA as variáveis apresentadas anteriormente na Tabela 1. A proposta consiste na implementação de um modelo de rede neural artificial, considerada comum, onde todas as entradas originais de dados de interesse são introduzidas diretamente nas entradas da rede, como exibido na Figura 16.

Para o Modelo 01, foram feitos dois testes. Um destes experimentos considerava todas as variáveis coletadas como entradas da rede. O outro experimento foram retiradas das entradas da RNA do modelo variáveis que não tinham correlação com a saída Q2. As variáveis do banco de dados passam por uma seleção e as variáveis selecionadas são inseridas na entrada da rede até obtermos a saída Q2 obtida através da RNA.

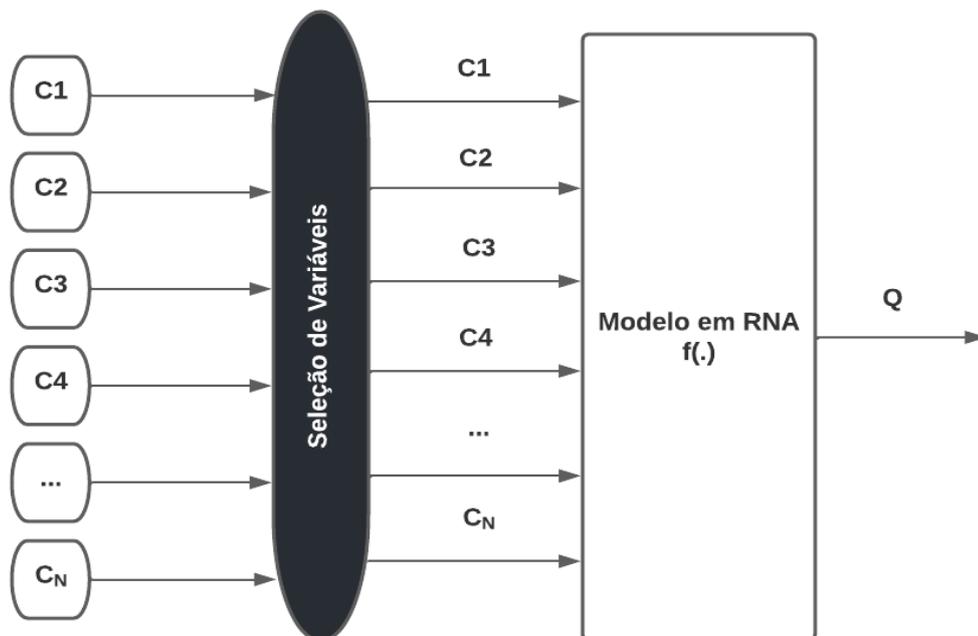


Figura 14. Modelo com todas as variáveis.

Fonte: Autoria própria.

O segundo modelo criado, denominado Modelo 02, é um melhoramento do Modelo 01, que inclui atrasos unitários nas variáveis primárias e realimentação com dados defasados em uma unidade dos valores de Q2 como apresentado na Figura 17. Assim como foi feito para o Modelo 01, foram descartadas as variáveis que não tinham correlação com a saída em nos experimentos realizados.

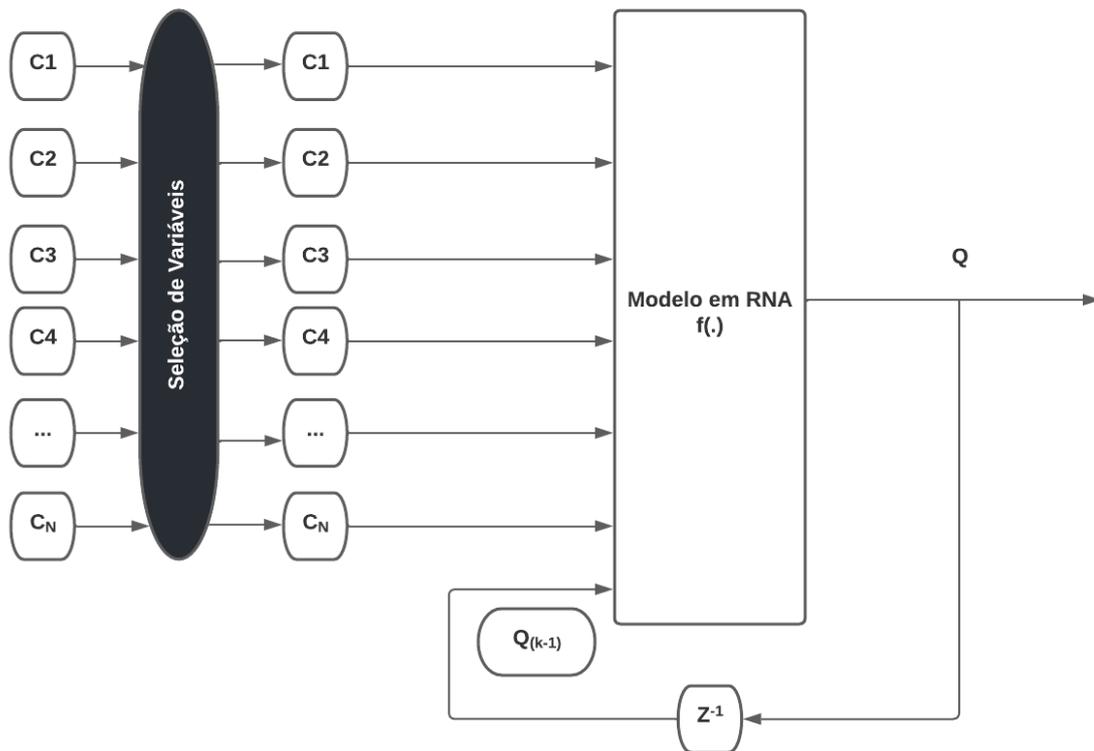


Figura 15. Modelo com realimentação.  
Fonte: Autoria própria.

## **4 RESULTADOS**

## 4 RESULTADOS DOS MODELOS DE *SOFT SENSOR*

Esta seção apresenta os resultados de cada etapa da metodologia especificada na seção 3. Primeiramente, são apresentados os diversos experimentos feitos em cada modelo criado. Em seguida, o procedimento de avaliação da incerteza de medição é detalhado, bem como a comparação entre os modelos. Será descrito o detalhamento da criação de dois modelos de *soft sensor* bem como avaliação de cada resultado apresentado em cada um dos modelos e experimentos realizados.

Nos dois modelos foi utilizada a seleção e divisão de 70% (6048 amostras) e 30% (2593 amostras) para divisão do banco de dados (treinamento/teste). Além disso, as mesmas funções de ativação e método de resolução de algoritmo foram utilizadas (*trainlm*). Foram utilizadas duas camadas com 10 e 5 neurônios, respectivamente.

### 4.1.1 Coleta e Pré-processamento de dados

Seguindo a metodologia apresentada na seção 3, foi realizado o pré-processamento. Todas as variáveis coletadas passaram pela etapa de pré-processamento de dados, a título de ilustração é apresentado apenas a variável Q2 (vazão de caldo caleado) na Figura 16. A curva azul retrata os dados originais obtidos através do banco de dados e a curva laranja representa a vazão após a utilização da função *replaceOutlierByMean*. Ainda na Figura 16, é possível verificar que, na amostra próxima de 5400, existe um *outlier*, que foi substituído pela média dos dados para posterior filtragem.

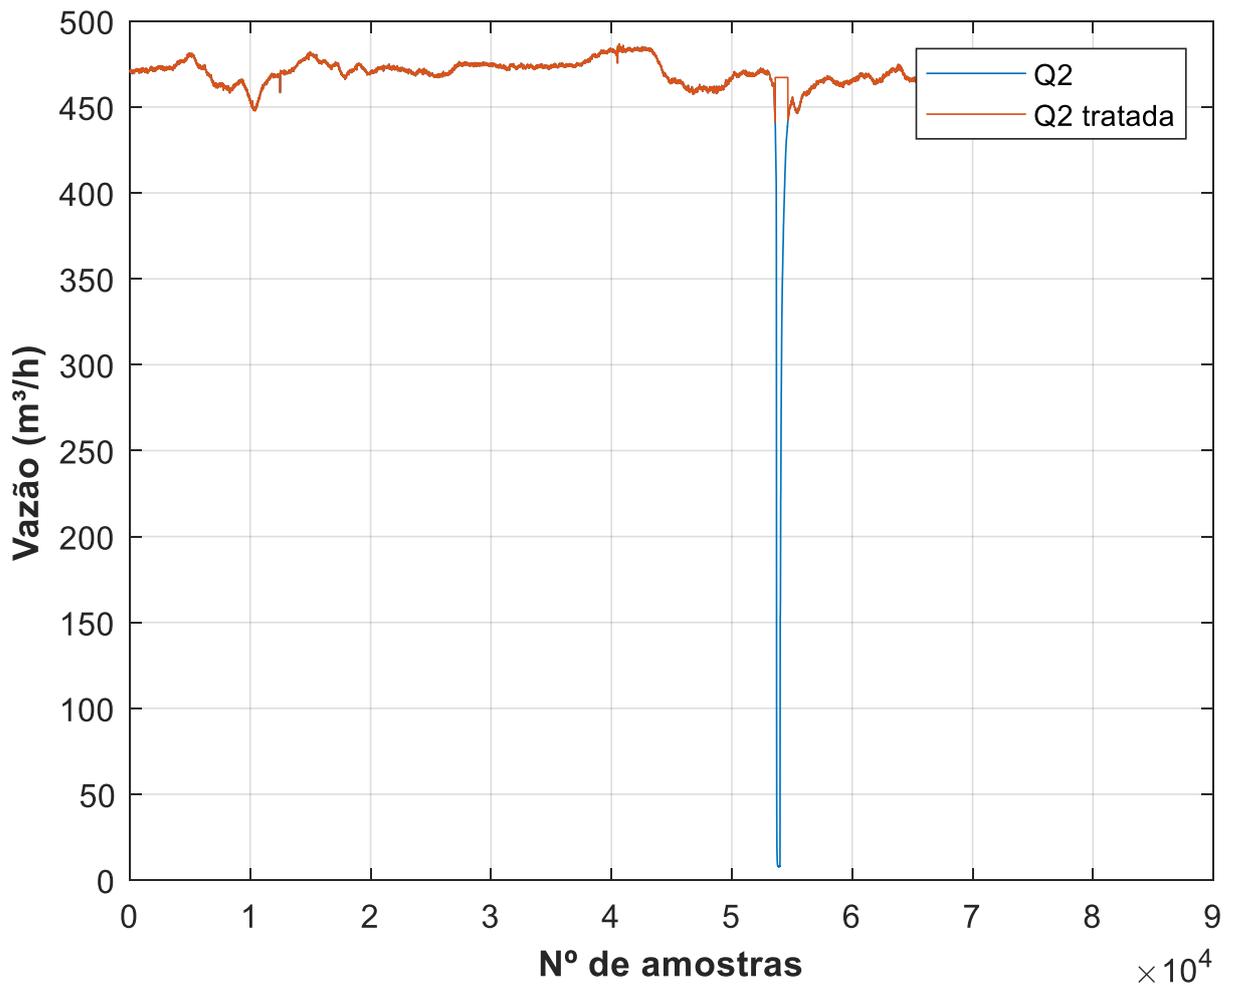


Figura 16. Remoção de *outliers*.  
Fonte: Autoria própria.

Na Figura 17, está ilustrado o gráfico da curva de vazão de caldo caleado original e a mesma curva após a utilização da função *movmean*. Para variável Q2 (vazão do caldo caleado), o número de pontos escolhidos para uma média móvel foi de 100 pontos, obtendo desta forma a variável Media Movel (curva azul ilustrada no gráfico da Figura 17).

Na curva denominada Media Movel é possível verificar que os valores que sofreram maior alteração estão no intervalo entre as amostras 5000 e 6000, região onde provavelmente ocorreu uma falha na conexão de rede entre supervisor e controlador da planta.

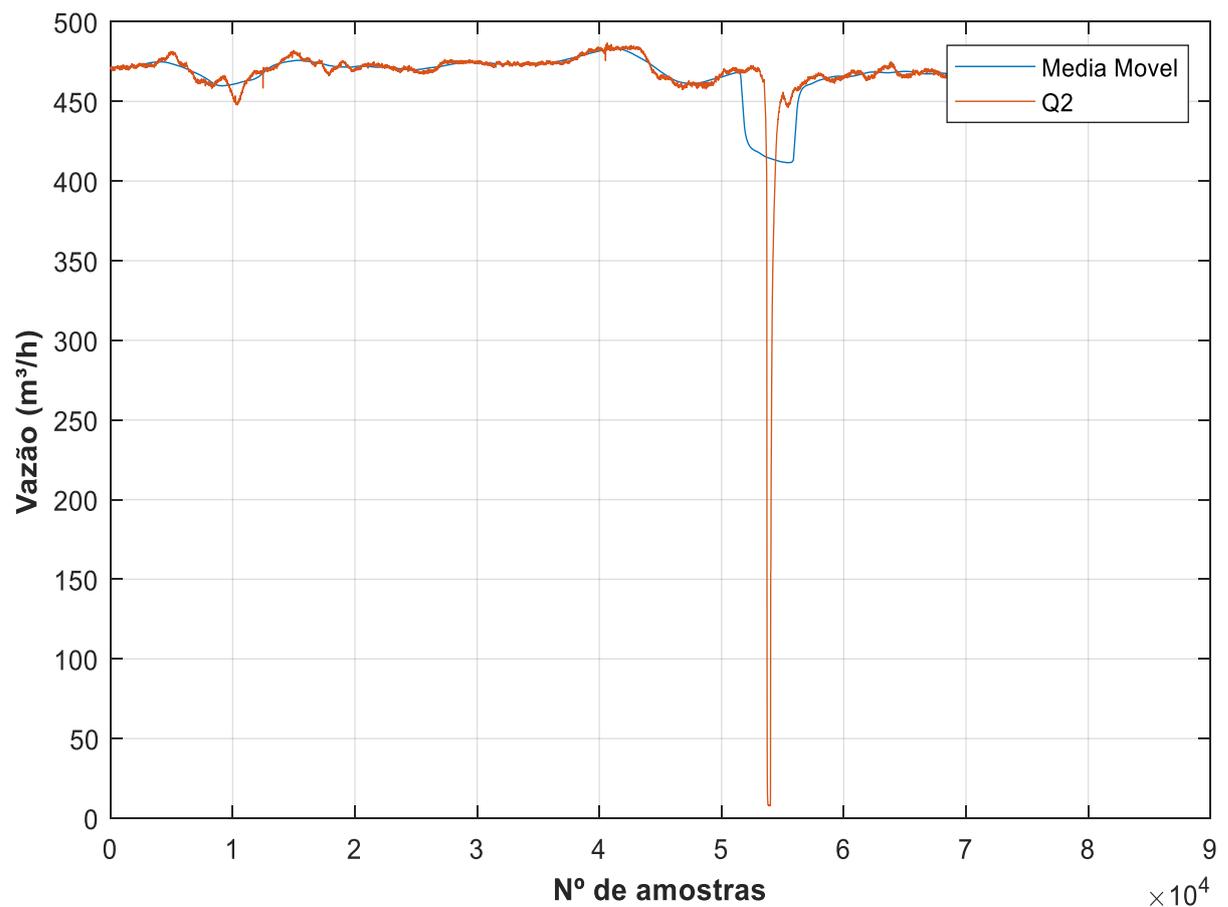


Figura 17. Filtragem do ruído.  
Fonte: Autoria própria.

#### 4.1.2 Seleção de Variáveis

No processo de seleção de variáveis de entrada para a construção do modelo do *soft sensor* realizou-se uma análise através da correlação entre os dados de entrada e de saída. Após a análise dos resultados chegou-se a correlação dos dados de entrada em relação a Q2 (vazão do caldo caleado) que estão apresentados na Tabela 1.

Com o conhecimento prévio do processo, sabia-se de antemão, que algumas variáveis não possuíam correlação com a variável desejada e, estes resultados foram confirmados após os testes de correlação.

Tabela 1. Correlação das variáveis de entrada com a variável de saída Q2 (vazão do caldo caleado).

Variável	Correlação
PH1 (pH do caldo pré caleado)	0,280
PH2 (pH do caldo caleado)	0,074
N1 (rotação da bomba de pré caleação)	0,294
N2 (rotação da bomba da caleação)	0,362
Q1 (vazão de saída do tanque de caldo misto)	0,569
H1 (nível do tanque de caldo misto)	0,335

Fonte: Autoria própria.

A partir dos dados apresentados na Tabela 1, observa-se que a variável PH2 é descorrelacionada de Q2. As demais variáveis apresentam uma correlação moderada com relação à saída, tendo em vista que conforme os níveis dos tanques sobem, as velocidades das bombas aumentam e conseqüentemente as vazões aumentam também. A variável Q1 (vazão caldo misto) apresentou uma correlação maior que 50%. Esta informação foi utilizada para alguns testes realizados. Foram feitos testes com todas as variáveis e testes desconsiderando algumas delas, para confirmar os resultados de correlação.

A seqüência da pesquisa é a criação de alguns modelos com a utilização da técnica de inteligência artificial de redes neurais artificiais.

#### 4.1.3 Modelo 1 do *soft sensor*

O Modelo 1 consiste em uma rede neural artificial, considerada comum, onde as variáveis de entradas são introduzidas diretamente nas entradas da rede, como exibido na Figura 18. Observa-se que neste experimento (denominando Experimento 1), não houve seleção de variáveis, ou seja, todas as variáveis coletadas para o banco de dados foram introduzidas na entrada da rede.

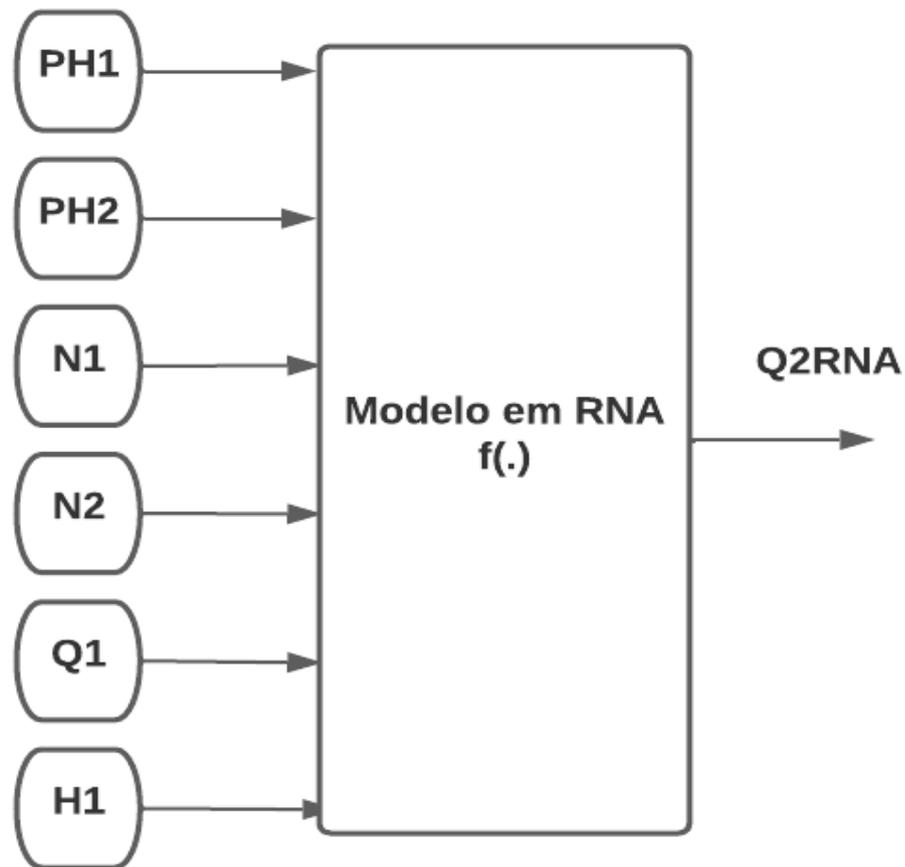


Figura 18. Experimento 1 do Modelo 1.  
Fonte: Autoria própria.

Na Figura 19, estão ilustradas as curvas de vazão de caldo caledado. A curva na cor vermelha indica a saída da RNA do modelo. A curva na cor azul refere-se a vazão real de caldo caledado. Neste experimento, obteve-se MAPE de 0,0025% (1,5 m<sup>3</sup>/h) e desvio padrão do erro 1.724, indicando que os pontos da curva do modelo tendem a estar do valor esperado ou valor real.

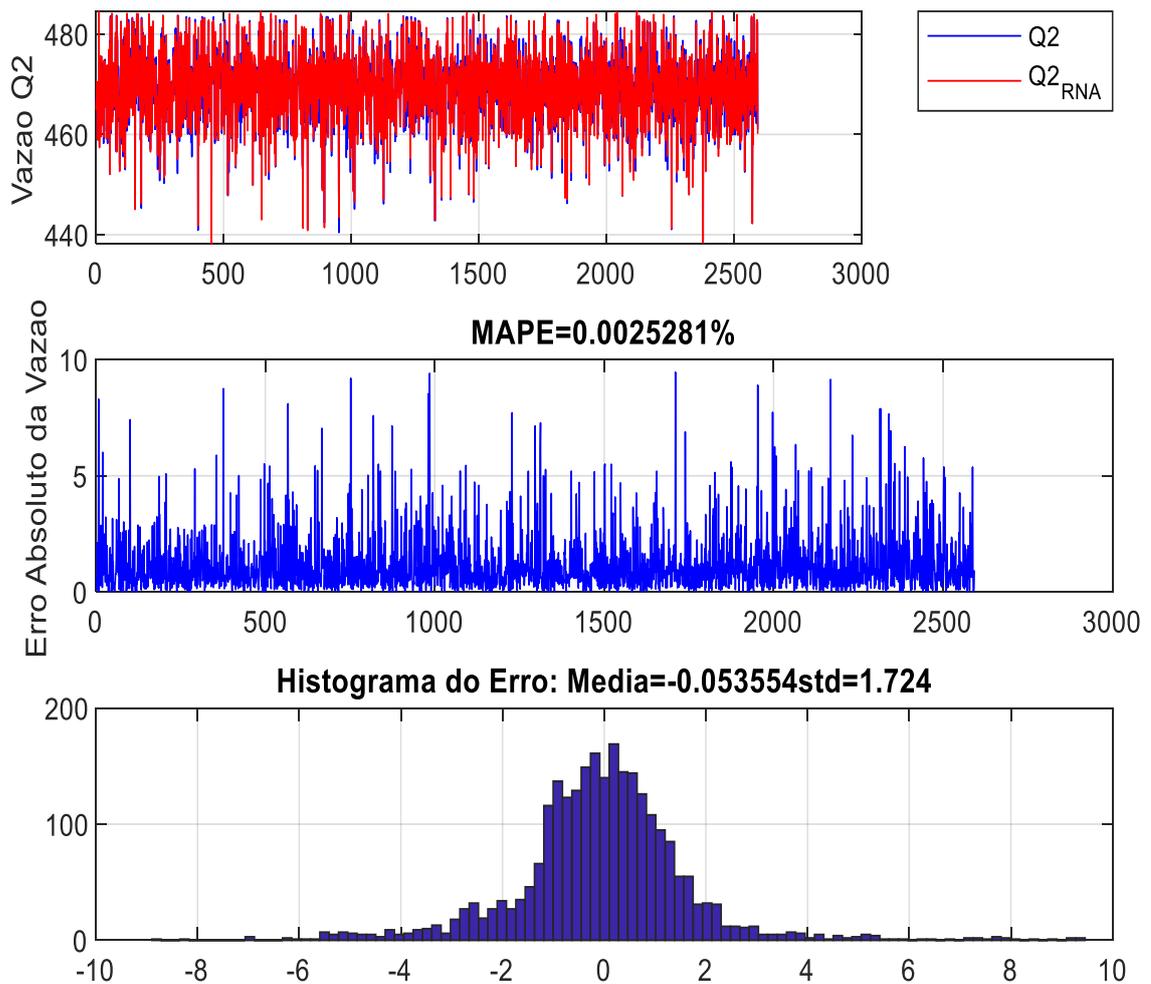


Figura 19. Curvas de vazão de caldo caaleado do Experimento 1 do Modelo 1 (considerando todas as variáveis).  
Fonte: Autoria própria.

Foi realizado um segundo experimento com o Modelo 1, denominado Experimento 2. Neste, foram eliminadas as variáveis PH1 e PH2, descorrelacionadas com a saída Q2, conforme resultado apresentado anteriormente na Tabela 1, na entrada da rede. O formato dos dados de entrada deste experimento está ilustrado na Figura 20.

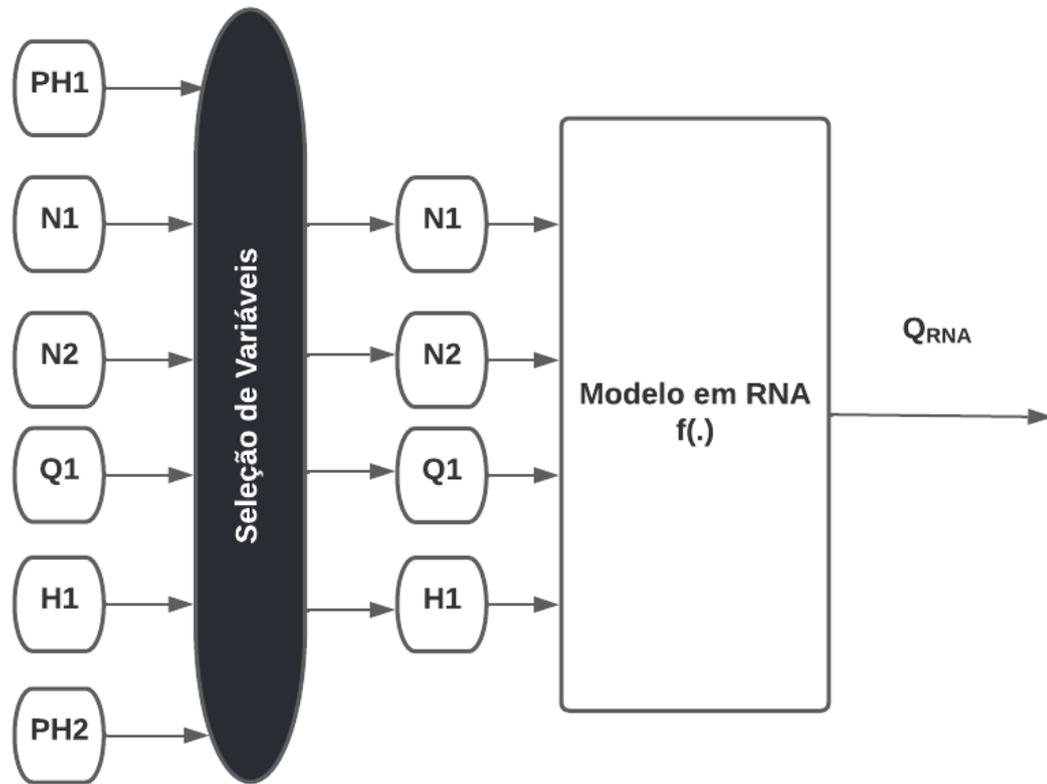


Figura 20. Experimento 2 do Modelo 1 (desconsiderando PH1 e PH2).  
Fonte: Autoria própria.

Na Figura 21, estão ilustradas as curvas de vazão de caldo caleado do experimento 2. A curva na cor vermelha indica a saída do modelo. A curva na cor azul refere-se a vazão real de caldo caleado. Neste experimento, obteve-se MAPE de 0,0021% (1,26 m<sup>3</sup>/h) com desvio padrão do erro de 1,4413. Neste caso, conforme esperado, os valores de MAPE e desvio padrão foram melhores quando comparados com o Experimento 1, pois retirou-se uma variável com correlação fraca com a variável desejada.

Na Tabela 2, são apresentados os resultados obtidos com os dois experimentos realizados com o modelo 1.

Tabela 2. Métricas de avaliação do *soft sensor* Modelo 1.

	MAPE	DESVIO PADRÃO
<b>Experimento 1</b>	0,0025%	1.7240
<b>Experimento 2</b>	0,0024%	1.6878

Fonte: Autoria própria

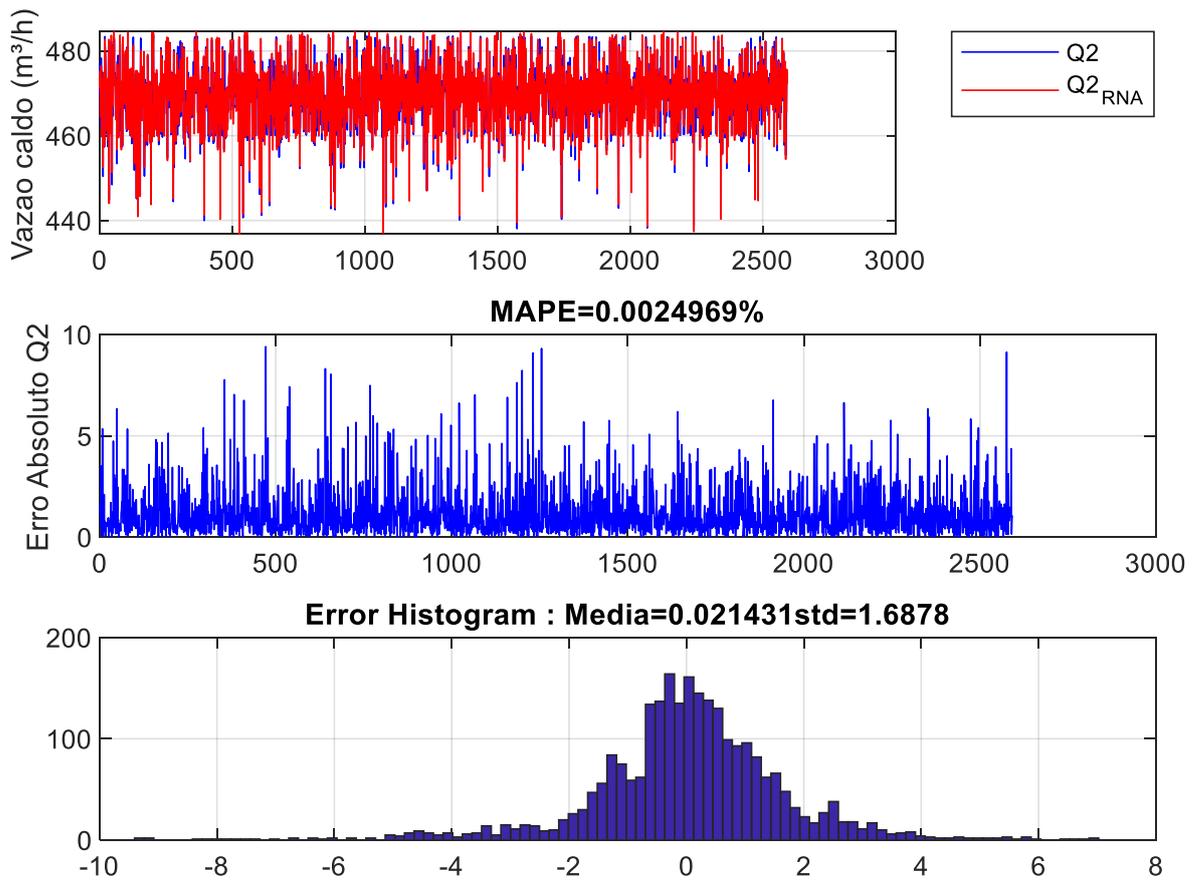


Figura 21. Curvas de vazão de caldo caleado do Experimento 2 do Modelo 1 (desconsiderando as variáveis PH1 e PH2).  
Fonte: autoria própria.

#### 4.1.4 Modelo 2 do *soft sensor*

O Modelo 2 é um modelo de *soft sensor* que inclui atrasos unitários nas variáveis primárias e realimentação com dados defasados em uma unidade dos valores de Q2. O Modelo 2 foi exposto ao mesmo processamento de dados, para remoção de ruídos e *outliers*, que o Modelo 1. As características foram mantidas, com número de neurônios da primeira camada igual a 10, número de neurônios na segunda camada igual a 5, erro de treinamento de 0,001, 100 épocas e LR (*Learning Rate*) igual a 0,01. Na Figura 22, mostra-se a representação do Modelo 2 com todas as variáveis

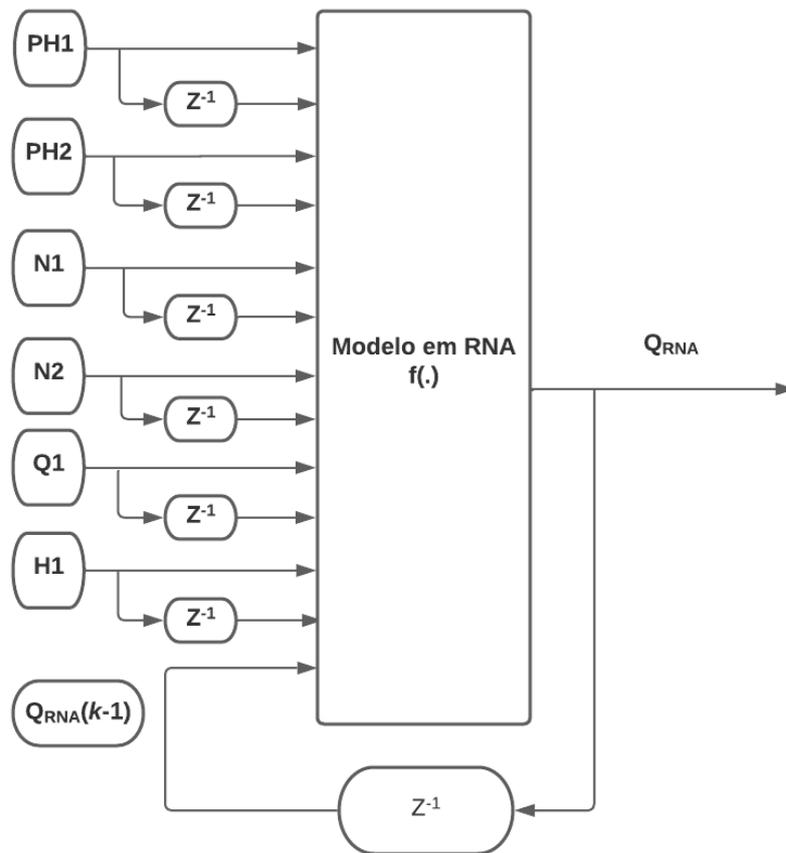


Figura 22. Experimento 1 do Modelo 2.  
Fonte: Autoria própria.

É possível verificar que as curvas de teste e de estimativa do modelo estão sobrepostas. Pode-se verificar ainda, o erro obtido com o modelo, bem próximo de zero, ilustrado no histograma da Figura 23.

No segundo experimento realizado com o Modelo 2, denominado Experimento 2 foram eliminadas as variáveis PH1 e PH2, variável decorrelacionada, conforme resultado apresentado anteriormente na Tabela 1, na entrada da rede. O formato dos dados de entrada deste experimento está ilustrado na Figura 24.

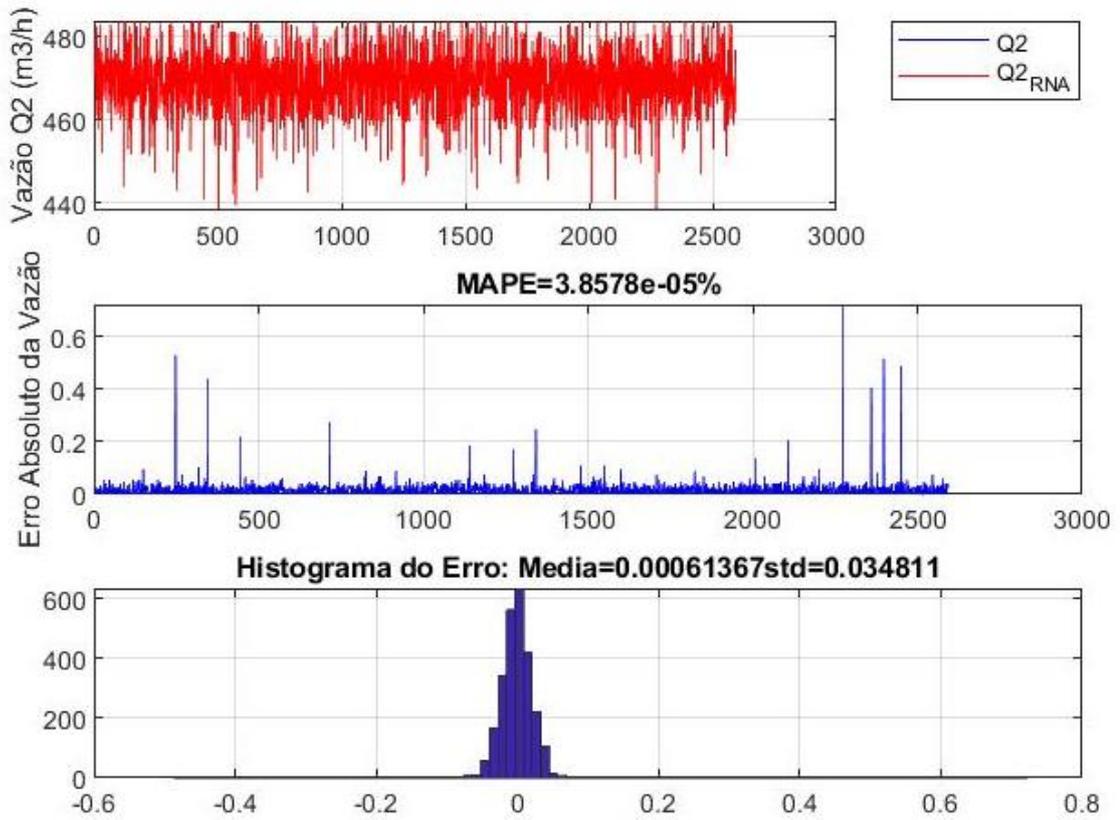


Figura 23. Experimento 1 do Modelo 2 considerando todas as variáveis.  
Fonte: Autoria própria.

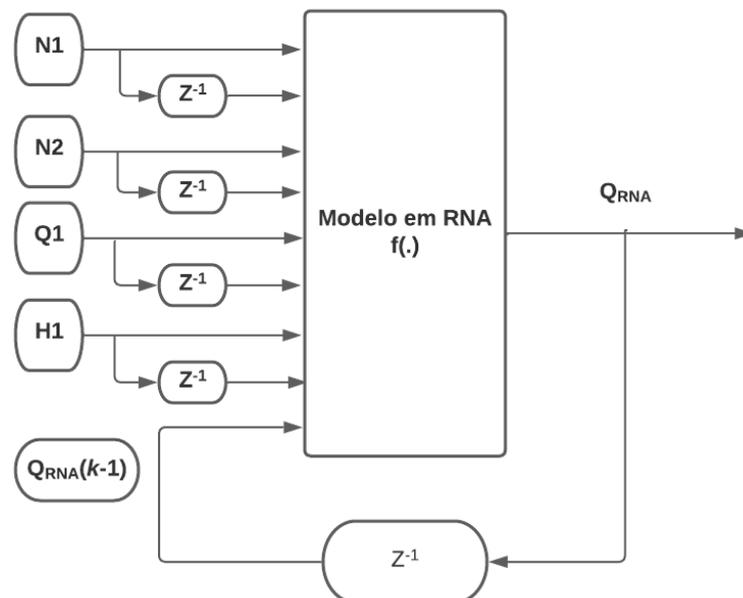


Figura 24. Experimento 2 do Modelo 2 (desconsiderando as variáveis PH1 e PH2).  
Fonte: Autoria própria.

Através dos resultados na Figura 25, é possível verificar que as curvas de teste e de estimativa do modelo possuem menor desvio padrão e menor MAPE. Pode-se verificar ainda, o erro obtido com o modelo, bem próximo de zero, ilustrado no histograma também na Figura 25.

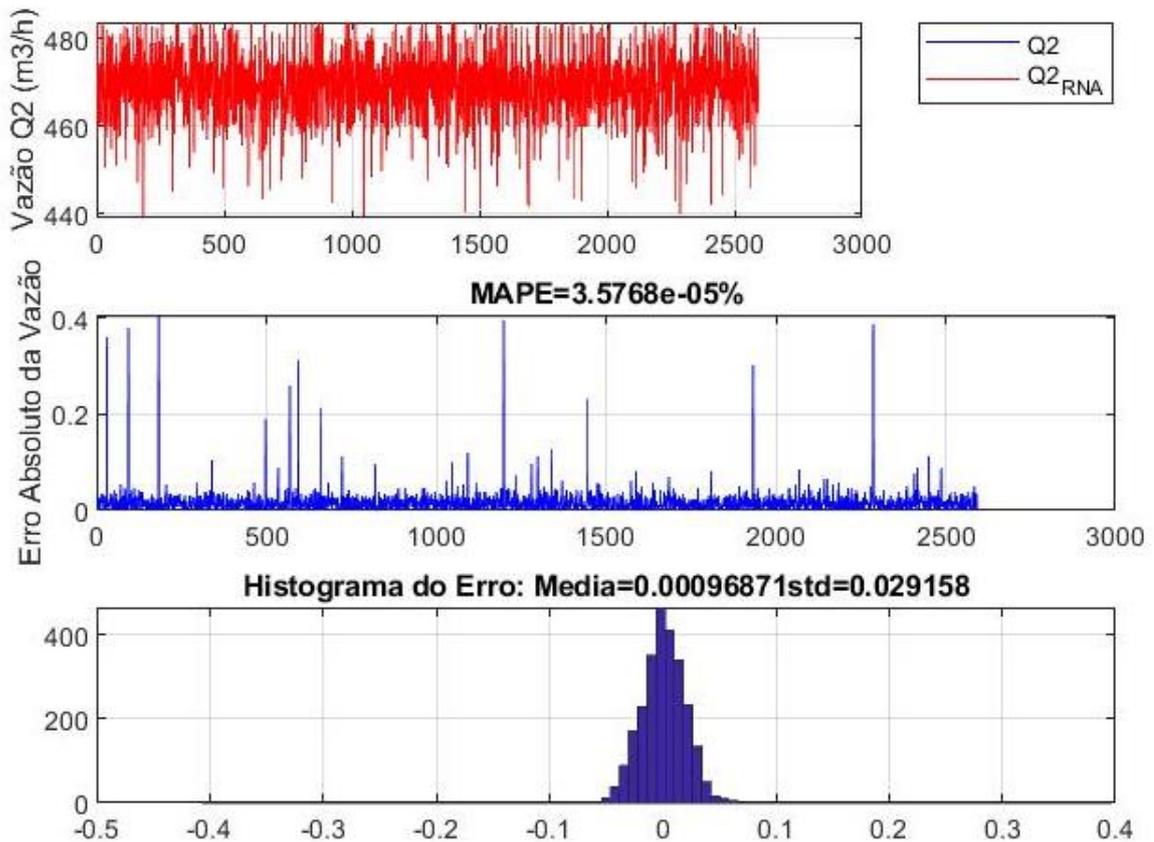


Figura 25. Curvas de vazão de caldo caaleado do Experimento 2 do Modelo 2 (desconsiderando as variáveis PH1 e PH2).

Fonte: Autoria própria.

Na Tabela 3, são apresentadas as métricas de avaliação com os resultados obtidos com os experimentos realizados com o Modelo 2.

Tabela 3. Métricas de avaliação do *soft sensor* Modelo 2.

	MAPE	Erro Máximo	DESVIO PADRÃO
<b>Experimento 1</b>	$3,8578 * 10^{-5}\%$	0,95	0.034811
<b>Experimento 2</b>	$3,5768 * 10^{-5}\%$	0,59	0,029158

Fonte: Autoria própria.

Na Figura 26, é apresentado um gráfico de vazão de caldo caleado. A curva vermelha equivale ao resultado do Experimento 2 do Modelo 2, melhor condição apresentada. A curva azul corresponde a vazão de caldo medida pelo sensor real. Na Figura 26, foram utilizadas apenas 1000 amostras para facilitar a visualização das duas curvas que estão sobrepostas.

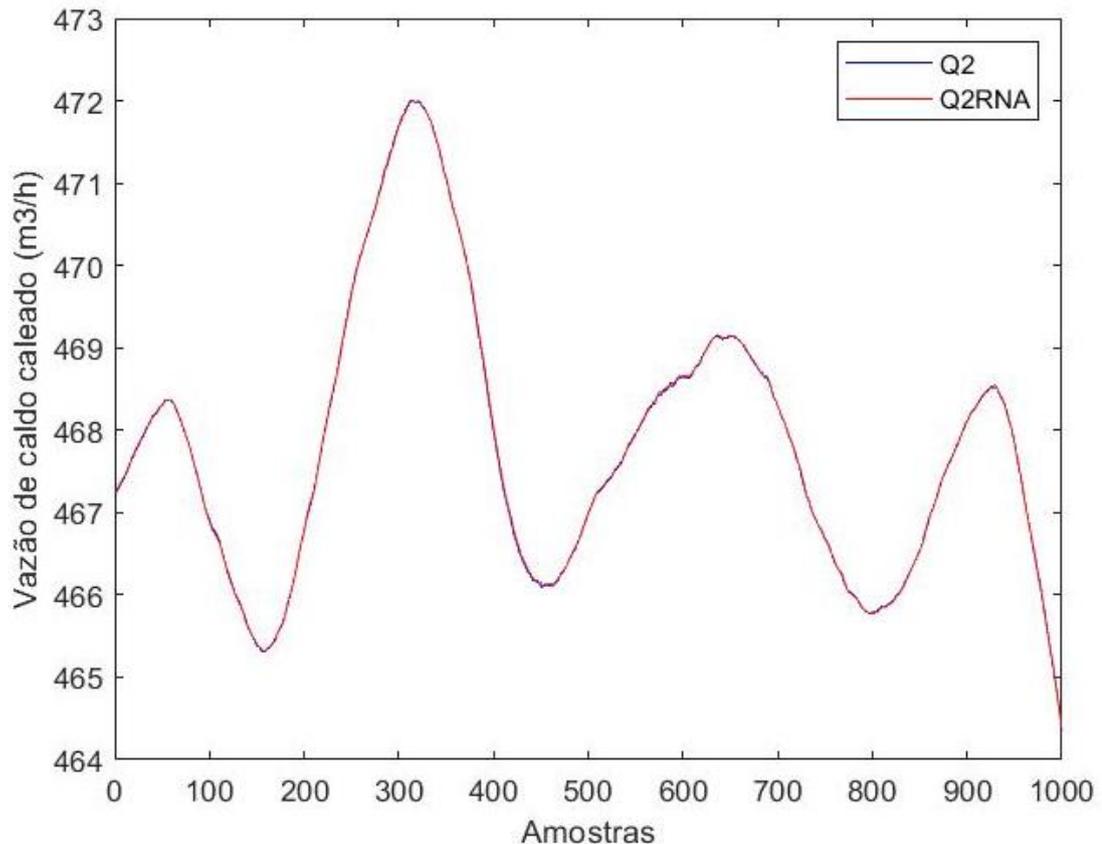


Figura 26. Vazão do caldo caleado após Experimento 2 do Modelo 2.  
Fonte: Autoria própria.

#### 4.1.5 Avaliação de incerteza de medição do modelo do *soft sensor*

Nesta etapa de avaliação, será utilizado o Experimento 2 do Modelo 2 (com realimentação da saída e sem as variáveis PH1 e PH2).

Com o objetivo de reduzir o erro causado através de overfitting da RNA, foi utilizado o Monte Carlo *Dropout*. Nesta etapa de avaliação da incerteza do modelo,

foram feitos alguns testes ajustando alguns hiperparâmetros do modelo dropout monte carlo. Alguns parâmetros foram fixados como o  $p$  (probabilidade dropout),  $T$  (número de vezes de execução do algoritmo) e  $l$  (*length scale*). Outros parâmetros foram variados de forma a obter o melhor valor de máxima verossimilhança, foram avaliados ainda o RMSE e a incerteza.

Inicialmente, verificou-se a necessidade de aumentar a quantidade de neurônios. Esse aumento foi realizado fazendo alguns testes com a rede e observando o seu comportamento. A partir das observações ficou pré-definido a utilização de 50 e 100 neurônios para os demais testes. A fim de analisar a influência do parâmetro  $\tau$  na incerteza do modelo, serão feitas mudanças nos valores das variáveis de  $\tau$ , peso da regularização L2 ( $\lambda$ ). Estas mudanças têm o objetivo de explorar a melhor configuração dos hiperparâmetros associados ao Monte Carlo Dropout para encontrar a melhor rede neural artificial. Os hiperparâmetros fixados e variados estão apresentados na Tabela 4.

Tabela 4. Hiperparâmetro da rede com o modelo Monte Carlo Dropout.

Sequência	PARÂMETROS FIXOS			PARÂMETROS VARIADOS			
	T	l	p	$\lambda$	$\tau$	n_train	n_neuronios
1	10	0,0001	0,05	1,57E-04	50	10	50
2	10	0,0001	0,05	1,57E-04	50	50	50
3	10	0,0001	0,05	7,85E-05	100	100	50
4	<b>10</b>	<b>0,0001</b>	<b>0,05</b>	<b>7,85E-05</b>	<b>10000</b>	<b>500</b>	<b>50</b>
5	10	0,0001	0,05	1,57E-04	50	10	100
6	10	0,0001	0,05	1,57E-04	50	50	100
7	10	0,0001	0,05	7,85E-05	100	100	100
8	10	0,0001	0,05	1,57E-04	50	500	100

Fonte: Autoria própria.

Após a definição e testes com os hiperparâmetros ilustrados na Tabela 4, chegou-se ao resultado apresentado na Tabela 5. É possível verificar que para os valores escolhidos e calculados para os hiperparâmetros anteriores apresentados, a maior máxima verossimilhança foi encontrada no teste cuja sequência possui número 4. A incerteza de medição do modelo, neste caso, é de aproximadamente 21 m<sup>3</sup>/h, que dentro do contexto da indústria sucroenergético e para aplicação na medição de vazão de caldo (que pode chegar até 600 m<sup>3</sup>/h), é um valor bastante aceitável.

Na Figura 27 está ilustrado o valor do erro obtido para o melhor resultado na Tabela 5. A curva em vermelho representa o valor real da vazão de caldo caleado e a curva azul o valor previsto pelo modelo apresentado. A curva lilás (através das duas curvas) representa a incerteza de medição.

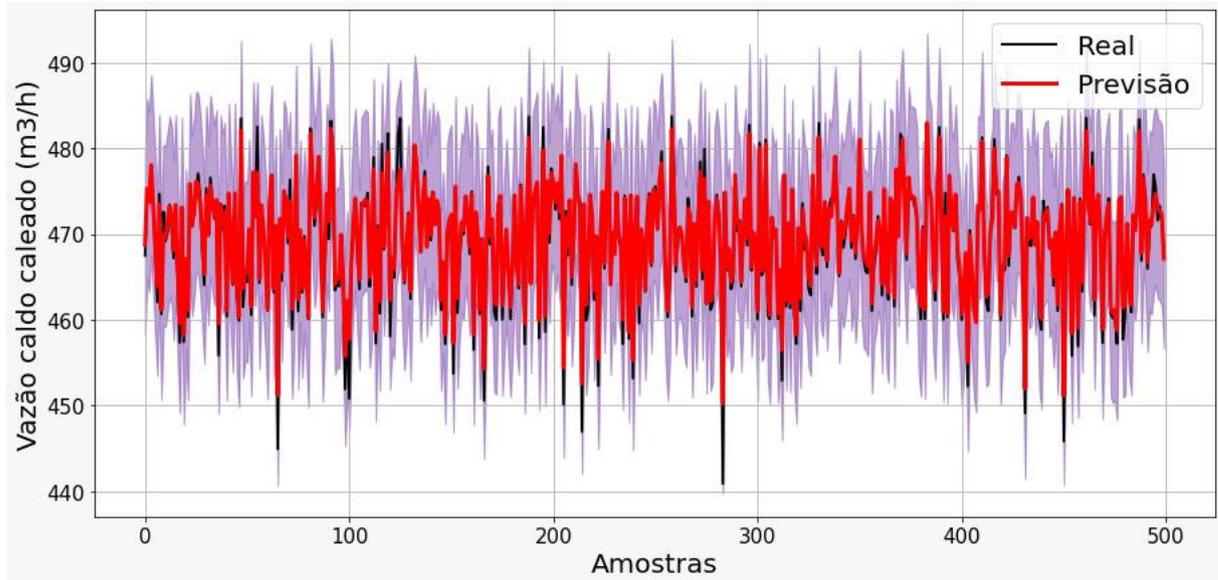


Figura 27. Curva de vazão para o modelo Monte Carlo Dropout.  
Fonte: Autoria própria.

Tabela 5. Métricas de avaliação do modelo Monte Carlo Dropout.

RESULTADOS				
Sequência	Incerteza (%)	Incerteza (m <sup>3</sup> /h)	RMSE	Max. Verosimilhança
1	4,458	20,945	0,433	0,602
2	4,464	20,945	0,422	0,628
3	4,464	20,945	0,391	0,734
4	<b>4,458</b>	<b>20,945</b>	<b>0,179</b>	<b>1,427</b>
5	4,468	20,946	0,434	0,608
6	4,467	20,945	0,420	0,627
7	4,468	20,845	0,391	0,732
8	4,463	20,945	0,144	0,999

Fonte: Autoria própria.

## **5 CONCLUSÃO**

## 5 CONCLUSÕES

Neste trabalho, realizou-se um trabalho de coleta de dados em uma planta industrial de uma usina do setor sucroenergético. Foi realizado um pré-processamento dos dados e criado um banco de dados para construção do modelo do *soft sensor*. Foi observado que a técnica de média móvel é capaz de corrigir os *outliers* encontrando e substituindo o valor por outro mais aproximado e fazendo a inferência de qual seria o melhor valor aproximado.

Após a análise dos resultados obtidos com os modelos testados, é possível afirmar que as redes neurais artificiais são ferramentas eficientes quando utilizadas com os *soft sensors* por sua capacidade de reconhecimento de padrões em um conjunto de dados, no melhor caso, com MAPE 0,0024% e desvio padrão do erro 1.6878, obtidos através do Modelo 1 e MAPE 0,000035768% e desvio padrão do erro de 0,029158 obtidos pelo Modelo 2. Através da análise dos resultados dos MAPES, é possível afirmar que os valores obtidos estão muito aproximados dos valores reais.

Considerando o melhor resultado obtido nos testes realizados, através do Experimento 2 do Modelo 2, modelo com a realimentação e atraso unitário), foi realizada a análise da incerteza do medidor proposto, obtendo erro de medição de aproximadamente 20 m<sup>3</sup>/h, valor bastante aceitável para a aplicação proposta (medição de caldo na entrada de um decantador).

Os resultados apresentados indicam o uso da inteligência artificial para auxiliar na tomada de decisões e/ou previsão está ganhando espaço. A utilização de técnicas de IA em *soft sensors* tendem a ganhar mais popularidade devido a sua eficácia na previsão e otimização, mantendo a simplicidade em não utilizar grandes formalismos matemáticos como em métodos iterativos, por exemplo. No caso da medição de vazão em questão, os *soft sensors* podem sim substituir sensores físicos em casos de não disponibilidade do sensor físico, por motivos de manutenção e/ou erros de medição.

Os estudos realizados nesse trabalho se restringiram ao uso de um único tipo de rede neural artificial (perceptron multicamadas). Sugere-se que outras RNA possam ser avaliadas como, por exemplo, NARX, LSTM, etc.

---

## REFERÊNCIAS

AGUIRRE, L. A. (2015). Introdução à identificação de sistemas - Técnicas lineares e não-lineares aplicadas a sistemas reais. Editora UFMG, Belo Horizonte, 4 edição.

ALVARES, et al. Desenvolvimento de um sistema para monitoramento e Teleoperação de máquinas-ferramenta cnc via internet Aderente à indústria 4.0. ISSN: 2446-9580, 2018.

BRAGA, A.P; LUDERMIR, T. B. e de LEON, A. C. P. Redes neurais artificiais: teoria e aplicações. Livros Técnicos e Científicos Editora, 2000.

BATISTA, G. E. de a. P. A., Pré-Processamento de Dados em Aprendizado de Máquina Supervisionado. Tese ICMC-USP (Instituto de pesquisas Matemáticas e de Computação. São Carlos-SP, 2003.

CANG, W. YANG, H. Hybrid soft sensor modeling for bisphenol-A synthesis reaction process. Asia-Pacific Journal of Chemical Engineering. DOI: 10.1002/apj.2378.

FORTUNA, L.; GRAZIANI, S.; RIZZO, A.; & XIBILIA, M.G. Soft sensors for monitoring and control of industrial processes. London, UK: Springer, 2007.

GALICIA, HECTOR J.; PETER, Q. HE; AND WANG, JIN. Adaptive Outlier Detection and Classification for Online Soft Sensor Update. 8th IFAC Symposium on Advanced Control of Chemical Processes Furama Riverfront, Singapore, July 10-13, 2012.

HAN, J.; KAMBER, M.; PEI, J. Data Mining: Concepts and Techniques. 3rd. ed. Waltham: Morgan Kaufmann Publishers, 2011.

HAYKIN, S. Neural Networks and Learning Machines. 3nd. ed. Upper Saddle River: Prentice-Hall, 2009.

---

IGLESIAS, J. M. C. Simulação de sistemas térmicos para gerenciamento energético de uma usina sucroalcooleira. Dissertação de mestrado. UFSC - 2009.

KADLEC, P., GABRYS, B., e STRANDT, S. (2009). Data-driven soft sensors in the process industry. *Computers and Chemical Engineering*, 33(4):795–814.

LIMA et al. "Soft sensor aplicado a plantas de processamento de gás natural baseado em redes neurais artificiais," Master's thesis, 2018.

LIU, Z.; GE, Z.; CHEN, G.; SONG, Z. Adaptive soft sensors for quality prediction under the framework of Bayesian network. *Control Engineering Practice*, v.72, p. 19-28, 2018.

LOTUFO et al. Sensores virtuais ou Soft sensors: Uma introdução," in 7th Brazilian Conference on Dynamics, Control and Applications, Presidente Prudente, 2008.

LUTTMANN, et al. Soft sensors in bioprocessing: A status report and recommendations. *Biotechnology Journal*. *Biotechnol. J.* 2012, 7, 1040–1048.

MORAIS JR, A. A. Elaboração de um Analisador Virtual Utilizando Sistema Híbrido Neuro-Fuzzy para Inferenciar a Composição em um Processo de Destilação. Dissertação de mestrado, Universidade Federal de Alagoas, 2011.

MORAIS JR, A. A. Uso de sensores virtuais (soft sensors) para estimativa de impurezas em colunas de destilação de alta pureza. Tese de doutorado, Universidade Federal de Campina Grande, 2015.

SILVA, I. N.; SPATTI, D. H.; e FLAUZINOR, R. A. Redes neurais artificiais para engenharia e Ciências aplicadas: curso prático. São Paulo, Editora Artliver, 2010.

SRIVASTAVA, N.; HINTON, G.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), p. 1929-1958, 214.

ZANATA, D. R. P., Desenvolvimento de sensor virtual empregando redes neurais para medição da composição em uma coluna de destilação. São Paulo, 2005. 229p. Dissertação – Escola Politécnica da Universidade de São Paulo. Departamento de engenharia

ZHU, S; HONGGUI, H; MIN, H; JUFEI, Q. A data-derived soft-sensor method for monitoring effluent total phosphorus. Chinese journal of chemical engineering, v. 25, n. 12, p. 1791-1797, 2017.

ZHOU, P. et al. Multivariable dynamic modeling for molten iron quality using online sequential random vector functional-link networks with self-feedback connections. Information Sciences, v. 325, p. 237–255, 2015b.

ZIMMER, J. et al. Um novo método para seleção de variáveis preditivas com base em índices de importância. Production, v. 24, n. 1, p. 84-93, jan./mar. 2014. Doi: <http://dx.doi.org/10.1590/S0103-65132013005000030>.