

UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA QUÍMICA

WELLINGTON MARTINS SANTOS

MODELO *MACHINE LEARNING* DE UM TROCADOR  
DE CALOR TIPO PLACA VIA MODELO GERADO NO  
ASPEN

SÃO CARLOS – SP  
2022

WELLINGTON MARTINS SANTOS

MODELO *MACHINE LEARNING* DE UM TROCADOR DE CALOR TIPO PLACA VIA  
MODELO GERADO NO ASPEN

Trabalho de conclusão de curso  
apresentado ao Departamento de  
Engenharia Química da Universidade  
Federal de São Carlos, para obtenção do  
título de bacharel em Engenharia  
Química

Orientador: Prof. Dr. Marcelo Perencin de Arruda Ribeiro

São Carlos – SP  
2022

UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciência Exatas e de Tecnologia  
Departamento de Engenharia Química

**Folha de aprovação**

Assinatura dos membros da comissão examinadora que avaliou e aprovou o Trabalho de Conclusão de Curso do candidato Wellington Martins Santos, realizada em 12/09/2022:

---

Prof. Dr. Marcelo Perencin de Arruda Ribeiro  
UFSCar

---

Prof. Dr. Felipe Fernando Furlan  
UFSCar

---

Prof. Dr. Rodrigo Béttega  
UFSCar

## **BANCA EXAMINADORA**

Trabalho de Conclusão de Curso apresentado de forma presencial no dia 12 de setembro de 2022 perante à seguinte banca examinadora:

Orientador: Prof. Dr. Marcelo Perencin de Arruda Ribeiro, Departamento de Engenharia Química, Universidade Federal de São Carlos (DEQ/UFSCar).

Convidado: Prof. Dr. Felipe Fernando Furlan, Departamento de Engenharia Química, Universidade Federal de São Carlos (DEQ/UFSCar).

Professor da disciplina: Prof. Dr. Rodrigo Béttega, Departamento de Engenharia Química, Universidade Federal de São Carlos (DEQ/UFSCar).

## **DEDICATÓRIA**

Dedico este trabalho à minha mãe, Rosemeire. Sem ela, a caminhada até a conclusão deste trabalho seria muito mais difícil.

## AGRADECIMENTO

Agradeço a Deus, pela minha vida, por toda força, determinação, paciência e coragem para superar todos os obstáculos para a conclusão deste trabalho.

Aos meus familiares: Meu pai Luiz, meu irmão Wesley, minha irmã Mikaela, minha avó Maria, aos meus padrinhos (Vera Lucia e Abdias), meu irmão e anjo da guarda William, e em especial a minha mãe, Rosemeire, pelo amor incondicional que me faz querer superar todos os obstáculos.

À minha futura esposa Cristiane, que me apoiou durante toda a graduação. Foi um ponto focal para manter a escrita deste trabalho e jornada de atividades físicas em dia.

Aos meus amigos, em especial Hugo, Everton, Pedro, David, Fabiana e Felipe por estarem comigo nos momentos bons e nos momentos nem tão bons assim. Por toda troca de experiência que me permitiram crescer não apenas como pessoa, mas também como um formando.

A meu orientador, Marcelo, por todas as reuniões, conselhos e direções dadas que levaram à conclusão deste trabalho.

A todo time da Ambev, em especial minha gestora Patrícia, pela compreensão, sinergia e otimismo. Ao Pedro, Daniela, Tiago, Anna, Gabriel, Victor, Fabio, Vinicius Pivetta, Gabriela Naufal, Felipe, Jeferson, Thales, Egon, Alex, Matheus e Andressa por tornarem os meus dias como estagiário mais fácil, alegre e produtivo.

Aos meus professores e amigos do cursinho comunitário Prestes Vestibular: Joana, Larissa, Mauricio, Pato, Jonas, Paloma, Maisa, Joseane, Felipe, Marizete e aos demais amigos que passou neste local e guardo em minha memória.

A todas as pessoas que de alguma forma contribuíram ao longo dessa jornada árdua, mas valiosa e desafiadora.

## RESUMO

Métodos de otimização matemática tendem a ser cada vez mais aplicados, tanto pela maior capacidade dos computadores, quanto pelo maior conhecimento do comportamento dos sistemas e consequente conhecimento das variáveis a serem modificadas, para obter uma resposta otimizada. Na busca de oportunidades de melhorias em processos químicos como prever fluxo mássica de correntes de refrigeração na indústria de bebidas, passou-se a empregar comumente a inteligência artificial e *machine learning* (ML) que são utilizados nessa indústria desde os anos 80, pois são modelos suficientemente rigorosos e rápidos para ativar os dispositivos de controle de forma eficaz. Logo, este trabalho tem objetivo final de construir um modelo matemático utilizando *machine learning* que calcule a vazão mássica da corrente de entrada de etanol (fluido de refrigeração) no trocador de calor de placas na cervejaria. A partir de medições de temperatura, pressão e vazão das correntes reais dos trocadores de calor da empresa (AMBEV), desenvolveu-se um modelo em *Aspen HYSYS®*, para representar o comportamento desses trocadores. A partir de uma malha de entradas, utilizou-se o modelo para simular as saídas. Essas saídas foram utilizadas para construir um modelo empírico que representasse o processo. Três tipos de modelos empíricos foram utilizados para o aprendizado supervisionado: regressão linear, *perceptron* de múltiplas camadas e árvore de decisão. Para otimizar e avaliar os modelos, os dados foram separados em validação cruzada e teste. O modelo árvore de decisão conseguiu prever melhor a vazão mássica da corrente Etanol com desvio padrão de  $1,92 \times 10^{-08}$  e  $0 \frac{Kg}{s}$ , para os respectivos trocadores de calor.

**Palavras-chave:** *Machine learning*; Indústria de Bebidas; Inteligência Artificial; *Aspen HYSYS*; Trocador de Calor.

## ABSTRACT

Mathematical optimization methods tend to be increasingly applied, both due to the greater capacity of computers, as well as the greater knowledge of the behavior of the systems and consequent knowledge of the variables to be modified, in order to obtain an optimized response. In the search for opportunities for improvement in chemical processes, such as predicting mass flow of refrigeration streams in the beverage industry, artificial intelligence and machine learning (ML) have been commonly used, which have been used in this industry since the 1980s, as they are sufficiently rigorous models and quick to activate control devices effectively. Therefore, this work has the final objective of building a mathematical model using machine learning, which calculates the mass flow rate of the ethanol input stream (cooling fluid) in the plate heat exchanger at the brewery. From measurements of temperature, pressure and flow of the real currents of the company's heat exchangers (AMBEV), a model was developed in Aspen HYSYS®, to represent the behavior of these exchangers. From a mesh of inputs, the model was used to simulate the outputs. These outputs were used to build an empirical model that represented the process. Three types of empirical models were used for supervised learning: linear regression, multilayer perceptron and decision tree. To optimize and evaluate the models, data were separated into cross-validation and testing. The decision tree model was able to better predict the mass flow rate of the Ethanol stream with a standard deviation of  $1.92 \times 10^{-08}$  and  $0 \frac{Kg}{s}$ , for the respective heat exchangers.

**Keywords:** Machine learning; Beverage Industry; Artificial Intelligence; Aspen HYSYS; Heat exchanger.



## LISTA DE ILUSTRAÇÕES

<b>Figura 01</b> - Fluxograma de processo genérico da produção de cerveja. ....	6
<b>Figura 02</b> - Principais componentes de um trocador de calor a placas. ....	8
<b>Figura 03</b> - Exemplo de um arranjo em séries de um trocador de calor de placas com 10 canais. ....	9
<b>Figura 04</b> - Circuito térmico para a troca de calor no trocador de calor do tipo placas.....	12
<b>Figura 05</b> - Ilustração gráfica de Viés e Variância. ....	18
<b>Figura 06</b> - Uma camada oculta MPL.....	20
<b>Figura 07</b> - Árvore de decisão: Exemplo dados do Titanic. ....	22
<b>Figura 08</b> - Fluxograma do processo de resfriamento da cerveja. ....	24
<b>Figura 09</b> - O <i>Flowsheet</i> logo após a conexão das correntes. ....	29
<b>Figura 10</b> - Caracterização das correntes materiais de entrada e saída do trocador de calor (Condições Operacionais). ....	30
<b>Figura 11</b> – Resultado apresentado para as variáveis dependente. ....	36
<b>Figura 12</b> – Vazão real <i>versus</i> vazão predita da corrente Etanol no 1º primeiro trocador de calor para cada modelo de regressão. ....	38
<b>Figura 13</b> - Principais Variáveis do Modelo Árvore de Decisão no 1º Trocador de calor. ....	40
<b>Figura 14</b> - Vazão Mássica de Entrada da Corrente Etanol predita <i>versus</i> Eficiência do 1º Trocador de Calor.....	41
<b>Figura 15</b> - Vazão real <i>versus</i> vazão predita da corrente Etanol no 2º primeiro trocador de calor para cada modelo de regressão. ....	44
<b>Figura 16</b> - Principais Variáveis do Modelo Árvore de Decisão no 2º Trocador de calor. ....	46
<b>Figura 17</b> - Vazão Mássica de Entrada da Corrente Etanol predita <i>versus</i> Eficiência do 2º Trocador de Calor.....	47
<b>Figura 18</b> - Janela de seleção da lista de compostos para a simulação.....	56
<b>Figura 19</b> – Janela de seleção do modelo termodinâmico. ....	57
<b>Figura 20</b> – Seleção da interface do ambiente de simulação.....	57
<b>Figura 21</b> - Conectando correntes do 1º Trocador de calor de placas pela janela de propriedades do equipamento. ....	58

<b>Figura 22</b> – Conectando correntes 2º Trocador de calor de placas pela janela de propriedades do equipamento. ....	59
<b>Figura 23</b> - Inserção dos Parâmetros do 1º Trocador de Calor.....	60
<b>Figura 24</b> - Inserção dos Parâmetros do 2º Trocador de Calor.....	60
<b>Figura 25</b> – Caracterização das correntes materiais de entrada e saída do 1º trocador de calor (Condições Operacionais).....	61
<b>Figura 26</b> – Caracterização das correntes materiais de entrada e saída do 2º trocador de calor (Condições Operacionais).....	61
<b>Figura 27</b> – Caracterização das correntes do 1º trocador de calor (Fração molar)..	62
<b>Figura 28</b> – Caracterização das correntes do 2º trocador de calor (Fração molar)..	62

## LISTA DE TABELAS

<b>Tabela 01</b> – Dados das correntes do processo de resfriamento da cerveja. ....	25
<b>Tabela 02</b> - Graus de Liberdade. ....	26
<b>Tabela 03</b> – Dimensões do 1º Trocador de calor. ....	27
<b>Tabela 04</b> - Dimensões do 2º Trocador de calor. ....	28
<b>Tabela 05</b> – Configuração do case quanto as correntes materiais de entrada e saída dos trocadores de calor.....	31
<b>Tabela 06</b> - Parâmetros do Modelo MLP. ....	32
<b>Tabela 07</b> - Parâmetros do Modelo Árvore de Decisão. ....	33
<b>Tabela 08</b> - Coeficiente de determinação de treino e de teste dos modelos preditivos para vazão de etanol no 1º trocador de calor. ....	37
<b>Tabela 09</b> - Coeficientes de validação cruzada dos modelos preditivos para vazão de etanol no 1º trocador de calor.....	37
<b>Tabela 010</b> – Desvio Padrão e Erro Quadrático Médio dos Modelos no 1º Trocador de Calor. ....	38
<b>Tabela 011</b> - Tempo de treinamento dos modelos para predição da corrente mássica de etanol no 1º Trocador de calor. ....	39
<b>Tabela 12</b> - Dados do primeiro trocador de calor para uma ótima eficiência. ....	42
<b>Tabela 13</b> - Coeficiente de determinação de treino e de teste dos modelos preditivos para vazão de etanol no 2º trocador de calor. ....	43
<b>Tabela 14</b> - Coeficientes de validação cruzada dos modelos preditivos para vazão de etanol no 2º trocador de calor.....	43
<b>Tabela 15</b> – Desvio Padrão e Erro Quadrático Médio dos Modelos no 2.º Trocador de Calor. ....	44
<b>Tabela 16</b> - Tempo de treinamento dos modelos para predição da corrente mássica de etanol no 2º Trocador de calor. ....	45
<b>Tabela 17</b> - Dados do segundo trocador de calor para uma ótima eficiência. ....	48

## LISTA DE SÍMBOLOS

$A$	Área de troca térmica do trocador ( $m^2$ )
$A_p$	Área de troca térmica da placa ( $m^2$ )
$b$	Distância média entre duas placas (m)
$C$	Comprimento da placa (m)
$C_p$	Calor específico a pressão constante (J/kg.K)
$D_h$	Diâmetro hidráulico (m)
DP	Desvio Padrão
$E$	Eficiência (adimensional)
$\varepsilon_p$	Espessura da placa (m)
$F_t$	Fator de Correção (adimensional)
$h$	Coefficiente convectivo de troca térmica ( $W/m^2.K$ )
$k$	Condutividade térmica do fluido ( $W/m.K$ )
$k_p$	Condutividade térmica da placa ( $W/m.K$ )
$L$	Comprimento da placa (m)
$m$	Vazão mássica da corrente (kg/s)
$M_A$	Média aritmética dos dados
MSE	Erro quadrático médio
$n$	Quantidade de dados
$N_p$	Número de placas
$Q$	Taxa de calor (W)
$Q_{máx}$	Taxa de calor máxima (W)
$R$	Resistência térmica de incrustação, <i>fouling factor</i> ( $m^2.K/W$ )
$T$	Temperatura ( $^{\circ}C$ )
$U$	Coefficiente global de troca térmica ( $W/m^2.K$ )

$w$	Largura da placa (m)
$\Delta T_{MLDT}$	Média logarítmica das diferenças de temperaturas (K)
$Y_i$	Dados reais
$\hat{Y}_i$	Dados de ajuste.

### **Subscritos**

$e$	Entrada
$f$	Fluido frio ou de resfriamento
$q$	Fluido quente ou de Aquecimento
$s$	Saída

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>1</b>
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b> .....	<b>3</b>
2.1	AS ORIGENS DA CERVEJA .....	3
2.2	PRODUÇÃO DE CERVEJA .....	3
2.3	TROCADOR DE CALOR .....	6
2.3.1	Trocador de Calor de Placas .....	7
2.3.2	Balanco Global de Energia .....	10
2.4	<i>MACHINE LEARNING</i> .....	12
2.5	APRENDIZADO SUPERVISIONADO .....	14
2.6	ETAPA DO APRENDIZADO DE MÁQUINA .....	14
2.6.1	Identificação do Problema .....	15
2.6.2	Coleta e Identificação dos Dados .....	15
2.6.3	Pré-Processamento .....	15
2.6.4	Separação entre Grupos de Treino e Grupo de Teste .....	16
2.6.5	Escolha dos Modelos de Aprendizagem Supervisionada .....	17
2.6.5.1	Modelo Linear .....	19
2.6.5.2	Redes Neurais Artificiais <i>Multi-Layer Perceptron</i> (MLP) .....	19
2.6.5.3	Árvore de Decisões .....	21
<b>3</b>	<b>METODOLOGIA</b> .....	<b>24</b>
3.1	DIMENSIONANDO OS TROCADORES DE CALOR .....	25
3.2	IMPLEMENTAÇÃO EM ASPEN .....	28
3.3	CRIANDO DADOS DE TREINAMENTO .....	29
3.4	TRATAMENTO DOS DADOS .....	31
3.5	MODELOS DE <i>MACHINE LEARNING</i> .....	31
3.5.1	Parâmetros dos Modelos .....	32

3.6	VALIDAÇÃO DOS MODELOS .....	33
<b>4</b>	<b>RESULTADOS E DISCUSSÃO .....</b>	<b>36</b>
4.1	VAZÃO DA CORRENTE ETANOL, COEFICIENTE GLOBAL DE TRANSFERÊNCIA E EFICIÊNCIA.....	36
4.1.1	Análise da Seção do Primeiro Trocador de Calor. ....	37
4.1.2	Análise da Seção do Segundo Trocador de Calor. ....	42
<b>5</b>	<b>CONCLUSÕES .....</b>	<b>49</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>50</b>
	<b>APÊNDICES A – Aspen HYSYS.....</b>	<b>56</b>
	<b>APÊNDICES B – Código-fonte.....</b>	<b>63</b>
	<b>ANEXO A – Melhor Design: 1° Trocador De Calor .....</b>	<b>80</b>
	<b>ANEXO B – Dimensões: 1° Trocador De Calor .....</b>	<b>80</b>
	<b>ANEXO C – Custo/Peso: 1° Trocador De Calor .....</b>	<b>81</b>
	<b>ANEXO D – Melhor Design: 2° Trocador De Calor .....</b>	<b>82</b>
	<b>ANEXO E – Dimensões: 2° Trocador De Calor .....</b>	<b>82</b>
	<b>ANEXO F – Custo/Peso: 2° Trocador De Calor .....</b>	<b>83</b>

## 1 INTRODUÇÃO

Em 2014, realizou-se uma pesquisa pelo Ibope na qual constatou-se que a cerveja é a bebida mais popular nacionalmente. No ano precedente, outra verificação expôs que era a bebida mais-querida para comemorações pelo brasileiro (VASCONCELOS,2017). O Brasil é o terceiro maior fabricante e um dos consumidores fundamentais de cerveja no planeta, na retaguarda somente dos líderes China e Estados Unidos, havendo gerado 151,9 milhões de hectolitros da bebida em 2020 (CARRANÇA,2022). Nos últimos dez anos, a demanda cresceu a uma taxa média de 5% ao ano, com foco em cerveja artesanal, que apresentou um progresso anual de cerca de 20% (VASCONCELOS,2017).

No entanto, o território com os menores custos é aqui no Brasil e as cervejarias mais verticalizadas (que dominam integralmente os estágios do meio produtivo), tal qual a Ambev, resistem mais com a alta de custos. Assim, podendo estabelecer entre aumentar sua participação no mercado e não elevar com tal força os preços ou defender suas margens. Sem a mesma estrutura, empresas artesanais, estarão sob as mesmas pressões de custos (ALENCAR,2022).

Conseqüentemente, com um mercado de tamanha força, diversas ações inovadoras em institutos de pesquisa, universidades, agricultores e cervejarias, são estimuladas (VASCONCELOS,2017). Deste modo, se tem pesquisado ciência de dados para descobrir *insights* pertinentes e compreender as informações a interesse de melhorar a eficiência, o desempenho de processos, aperfeiçoar a qualidade do produto e conter os custos de produção. Empresas como GE, BP e ExxonMobil têm investido montantes consideráveis em inteligência artificial no intuito de executar na engenharia química melhorias de segurança nos processos, reconhecimento de novas associações para fluxos de trabalho, na agilidade de projetos e possibilidade do uso acelerado de dados de processos (YAN et al.,2020).

*Machine Learning* e Inteligência Artificial têm sido empregados na administração de energias renováveis, predição de propriedades físico-químicas de catalisadores e fluidos e em comandos de processo. Ou seja, na simulação e modelagem de processos químicos na engenharia química (VIEIRA,2021).



O modelo de inteligência artificial mais aplicado no setor de engenharia química são as redes neurais artificiais. Esses modelos são utilizados desde 1980 para tratar problemas de previsão (YAN et al,2020). Os benefícios deste algoritmo são a tolerância a falhas, depósito de informação em toda a rede, potencial de processamento paralelo, presença de memória distribuída e capacidade de trabalhar com informações inacabadas (MIJWELL, 2018).

Segundo os Dados da Associação Brasileira da Indústria de Cerveja (CervBrasil), quase 30 mil litros da bebida são produzidos no país a cada minuto. O setor fatura R\$ 70 bilhões anualmente, o que representou 1,6% do produto interno bruto (PIB) em 2015 (CERVBRASIL,2017). A demanda por esses produtos tem crescido, em parte pelo uso de ferramentas de IA tanto para tomarem decisões de mercado quanto na melhoria do próprio produto (MARR,2019).

Neste cenário, os trocadores de calor a placas desempenham um papel importante na produção industrial e artesanal de bebidas, garantindo a máxima rentabilidade de troca térmica por meio da recuperação de calor, com operação conveniente, bem como manuseio delicado do produto e máxima higiene (KELVION,2022). Logo, deixa diversas bebidas geladas e com temperatura ótima para o consumo em adegas, padarias, restaurantes e bares.

A utilização do modelo *machine learning* ao invés de um modelo fenomenológico neste trabalho, é devido a sua velocidade de processar uma quantidade ilimitada de dados e acompanhar a evolução das informações em tempo real ou muito próximo disso (FIA, 2021).

Perante o exposto, o propósito deste trabalho é avaliar o desempenho de modelos de aprendizagem de máquina mais simples, como regressão linear, *Perceptron* múltiplas camadas e árvore de decisão, para prever a demanda da vazão mássica do fluido refrigerante (água + etanol) de um trocador de calor de placas em uma fábrica de cerveja.

## 2 REVISÃO BIBLIOGRÁFICA

Nesse capítulo é exibida uma revisão acerca dos tópicos fundamentais relacionados à aplicação de inteligência artificial em processos químicos. Considerou-se em específico o processo de produção de cerveja. Este capítulo é dividido em três partes principais: a primeira parte é norteada à produção de cerveja, descrevendo um pouco a origem, contexto comercial, os processos e as reações envolvidas da cerveja. A segunda parte foca no trocador de calor de placas, expondo o funcionamento e termos técnicos. A terceira parte realça o conceito de *machine learning*, enfatizando o aprendizado supervisionado e os modelos utilizados.

### 2.1 AS ORIGENS DA CERVEJA

Há uma intensa associação acerca da história da cerveja e do pão, por incluírem os idênticos componentes, e em algum período do progresso das civilizações esses eram produtos que faziam parte da cultura e da alimentação de diversas populações (ARAÚJO et al., 2016).

O cervejeiro valeu-se membro significativo do corpo social na era do império mesopotâmico, de 1770 a.C. Dado que a correlação com a bebida no código de Hamurabi, diz-se que seria capaz de ser empregada pena de morte para o cervejeiro que falsificava sua mercadoria para o comércio, conforme o portal *Cervesia* (2015).

Quanto ao aparecimento da cerveja no Brasil, ocorreu devidamente ao colonialismo europeu em 1808, advinda da família real portuguesa após a abertura dos portos. Inumeráveis negociantes se situaram no país e iniciaram a comercializar a bebida que no momento era singular, persuadindo os hábitos da época. A data precisa da produção de cerveja no Brasil não se sabe, entretanto o registro sabido e principal na história é um anúncio de venda de cerveja no jornal do Comércio do Rio de Janeiro, de 27 de outubro de 1836. Em que existia algumas cervejarias, e a sua fabricação eram inteiramente artesanais e em baixa escala (ARAÚJO et al., 2016).

### 2.2 PRODUÇÃO DE CERVEJA

O Brasil encontra-se na terceira posição no ranking global de produção de bebida, acima de 13,3 bilhões de litros por ano, perdendo exclusivamente, em quantidade, para o Estados Unidos com 22,1 bilhões de L/ano e China com 46 bilhões de L/ano, segundo o Sindicato Nacional da Indústria da Cerveja (2016). Sendo assim, um dos superiores do planeta (Brasil,2005) e o mais importante do comércio sul-americano (Combinación, 2005).


Os ingredientes que exercem parte da formação da cerveja, alcançada através da fermentação alcoólica do mosto cervejeiro proveniente da água potável (corresponde à 93%, segundo Neto (2009)) e malte de cevada, em virtude da levedura, com a junção de lúpulo. E no que se refere, aos adjuntos cervejeiros serão capazes de substituir uma parte do malte de cevada, da qual utilizada não poderá ser maior a 45% em comparação ao extrato primitivo, consoante a legislação brasileira (BRASIL,2009). Regularmente, os adjuntos são produtos da beneficiação de cereais ou a demais vegetais ricos em carboidratos (MEGA et al.,2011).

O processo da cerveja é formado fundamentalmente por seis fases: mosturação (extração e hidrólise dos componentes da cevada malteada), filtração (separação dos componentes insolúveis), fervura (com a adição de lúpulo), fermentação primária, maturação e envase (filtração, estabilização, engarrafamento, etc.). Os cervejeiros denominam de brasagem o método que vai da mosturação à fervura, transitando pela filtração (ARAÚJO et al.,2016).

Inicialmente, a mosturação constitui-se no cozimento do malte, antecipadamente escolhido e moído devidamente, com finalidade de obter os açúcares fundamentais para alimentar subsequentemente os microrganismos encarregados pela fermentação. E com a intenção de inativar enzimas que extraem substâncias intoleráveis no produto e transformar o amido presente no cereal em substâncias digestíveis pelas leveduras, o controle da temperatura é primordial. Enquanto o objetivo da filtração é desprender a cevada do bagaço, cujo açúcares estão vigentes no líquido. Nesta fase opera os equipamentos filtrantes (filtro ou peneira) e é apropriado realizar a recirculação deste fluido, pois cresce a eficiência do processo (HUGHES, 2014).

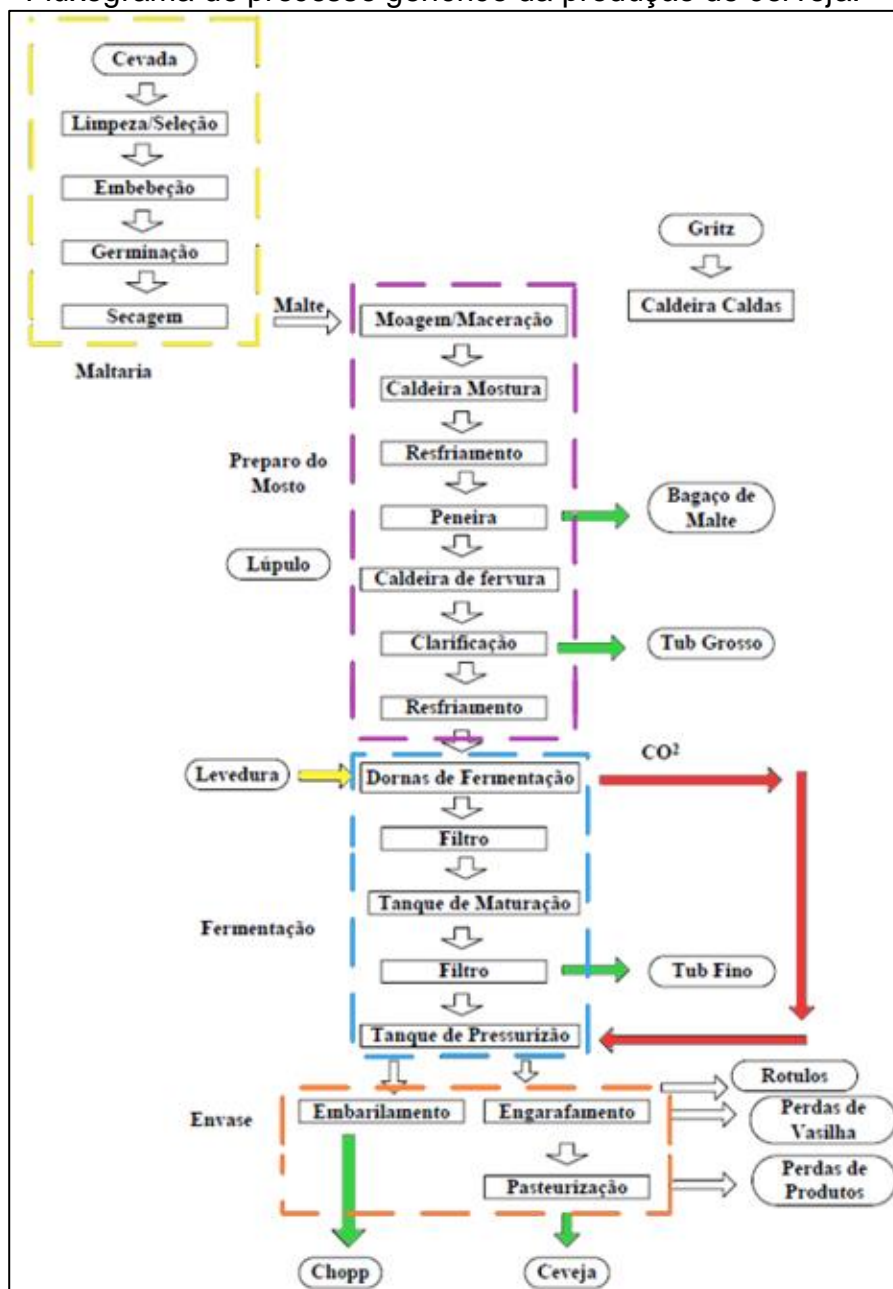
A esterilização da cerveja denomina-se a etapa da fervura, cuja evaporação da água sucede na concentração do fluido, e o tempo médio do processo é de uma hora e meia. E é acrescentado o lúpulo, incumbido pela conservação da cerveja,

aroma e amargor. Imediatamente passa-se pela etapa de fermentação (em um tanque cilindro cônico encamisado), com propósito de transformação das glicoses (açúcares) presente no mosto em dióxido de carbono, etanol e liberação de calor, sob condições anaeróbicas (equação 01). Onde ao lidar-se com microrganismos vivos, o sabor da bebida e o aroma desejado é facilmente modificado, devido a sensibilidade à contaminação do processo. Ao passo que na maturação, o objetivo é desunir-se o mosto do fermento. No qual as substâncias se estabilizam e se associam, a consequência é uma acentuação de aroma e sabor da cerveja (MORADO, 2011).



Em suma, o fluxograma das etapas essenciais do processo cervejeiro conforme exposto na Figura 01, com suas referentes entradas (insumos, matérias-primas) e saídas (resíduos gerados e produtos).

**Figura 01** - Fluxograma de processo genérico da produção de cerveja.



Fonte: Adaptado de Cervejas e Refrigerantes (CETESB, 2005).

### 2.3 TROCADOR DE CALOR

Há uma crescente intensificação a favor do estudo da otimização de processos industriais, e prontamente relaciona-se com a demanda de aperfeiçoar produtos e sofisticar técnicas em referência ao seu gasto de fabricação. Com relação à área térmica, a eficiência no uso de trocadores de calor tem um grande impacto na quantidade de energia utilizada no sistema de refrigeração. Conseqüentemente,

grande dedicação têm sido empregada no desenvolvimento e na pesquisa deste equipamento (PERUSSI, 2010).

Os trocadores de calor são categorizados em função do perfil do escoamento dos líquidos e da forma de construção. O trocador de calor mais elementar é aquele em que o escoamento dos fluidos frio e quente ocorrem na mesma direção ou em direções opostas (SILVA, 2010). Quando os fluidos frio e quente escoam no mesmo sentido e pela mesma extremidade iniciam e saem, se diz escoamento paralelo. Ao passo que, no arranjo em contracorrente os fluidos entram e deixam o sistema por extremidades opostas e escoam em sentidos contrários.

O trocador de calor Casco-tubos é um dos mais instalados nas indústrias, contendo um casco com múltiplos tubos, no qual o escoamento ocorre através de um único passe por meio do casco. Defletores ou Chicanas são geralmente introduzidos para pôr uma componente de velocidade de corrente cruzada e para melhorar o coeficiente de convecção do lado casco pela indução de turbulência (SILVA,2010).


### **2.3.1 Trocador de Calor de Placas.**

Próximo de 1900 foi inventado o trocador de calor de placas, e conforme os métodos abrangendo trocadores de calor de placa procederam se desenvolvendo desde a década de 30, a sua aplicação mais do que ser incluso em processos farmacêuticos e alimentícios, transitaram a ser utilizados em outras áreas, que normalmente lidavam com líquido-líquido (GUT, 2003).

Segundo ROETZEL et al. (1994), em processos que necessitassem alto grau de higiene e sanitização, como no processamento de fluidos alimentícios, os trocadores de calor de placas eram principalmente utilizados originalmente. Aplicações como indústria química de papel, petroquímicas e farmacêutica, particularmente para processos que envolvem resfriamento e aquecimento de fluidos, se ampliou nas últimas décadas. A motivação desta exigência na aplicação não se deve só pela sua forma compacta e pela facilidade de limpeza, e sim pela razão de ser possível aproximar alta taxa de transferência de calor em função da alta turbulência com velocidade de escoamento baixas se equiparado a diferentes trocadores de calor.

De acordo com Benze (2013), esses equipamentos são essencialmente compostos por algum perfil de corrugação, em suas finas placas, prensadas em um pedestal. Contém passagem para o fluido em seus orifícios e gaxetas para conceber canais de escoamento pelos quais os fluidos frio e quente circulam alternadamente, por meio das placas metálicas. O pedestal dispõe de uma placa de aperto móvel, barramentos superior e inferior, uma placa fixa e parafusos de aperto. A placa de aperto e a fixa têm bocais para junções das tubulações de coleta e de alimentação dos fluidos. Um esboço da organização de um trocador de calor de placas é exibido na Figura 02.

**Figura 02** - Principais componentes de um trocador de calor a placas.




Fonte: Adaptado de Wikimedia Commons (2022).

O espaço que há no meio de duas placas é designado de canal de escoamento. O arranjo do fluxo pelos canais do trocador é realizado na forma de “passes”, formados por um definido número de “passagens”. Na alteração de sentido do fluxo sucede a mudança de passe (GUT, 2003). A Figura 03 faz uma representação dos fluidos circulando de modo alternado trocando calor ao qual o fluxo

do fluido frio está escoando de forma contrária ao fluido quente retratando o fluxo como contracorrente. O dispositivo mostrado possui 10 canais.

**Figura 03** - Exemplo de um arranjo em séries de um trocador de calor de placas com 10 canais.



Fonte: Adaptado de SANTOS (2018).

Considerando as hipóteses de cálculo analítico em trocador de calor advertidas por Berto (2000) e Gut (2003): trocador de calor de placas operando com fluidos incompressíveis, sem transformação de fase e em estado estacionário.

O fluxo dos fluidos é ramificado entre os canais. O fluido logo escoa por dentro dos canais e ao término advém a mistura dos fluidos mais uma vez. No sentido de modelar a hidrodinâmica do trocador de calor são aplicadas as próximas considerações:

- 1º: Mistura perfeita dos fluxos que deixam os canais, ao final de cada passe;
- 2º: O fluxo principal é fracionado identicamente entre os canais (cada canal com a mesma vazão);
- 3º: Em regime permanente o sistema se encontra (propriedades são inalteráveis no tempo).

Admite a segunda hipótese de distribuição homogênea do fluxo. Dado que a modelagem apropriada para a distribuição de vazão pelos canais de um trocador de calor com configuração genérica inexistir.



### 2.3.2 Balanço Global de Energia.

A taxa de calor dissipado pela corrente quente ( $Q_q$ ) (Equação 03) e recebido pela corrente fria ( $Q_f$ ) (Equação 02) têm valores negativo e positivo respectivamente nessas equações. Nas equações 02 e 03,  $m$  representa a vazão mássica do fluido,  $C_p$ , seu calor específico, e  $T$ , a temperatura. Os subscritos ( $q$ ) e ( $f$ ) referem-se aos fluidos quente e frio, respectivamente, enquanto, a entrada e a saída do fluido são representados pelos subscritos ( $e$ ) e ( $s$ ).

$$Q_f = m_f \times C_{p_f} \times (T_{f,e} - T_{f,s}) \quad (02)$$

$$Q_q = m_q \times C_{p_q} \times (T_{q,e} - T_{q,s}) \quad (03)$$

A eficiência térmica do equipamento, que é importante para se avaliar o desempenho final de um trocador de calor, pode ser determinado comparando a razão da quantidade de calor trocado ( $Q = Q_f = -Q_q$ ) com a taxa máxima de calor possível que pode ser alcançado ( $Q_{m\acute{a}x}$ ). A troca térmica máxima ocorre quando o fluxo contracorrente passa sobre uma área de troca térmica infinita, portanto, a quantidade máxima de troca,  $Q_{m\acute{a}x}$ , é limitada pela capacidade calorífica mínima de um dos fluidos e também dependendo de qual temperatura está limitado a troca (GUT, 2003). As equações 04 e 05 definem  $Q_{m\acute{a}x}$  e eficiência.

$$Q_{m\acute{a}x} = (m \times C_p)_{min} \times (T_{q,e} - T_{f,e}) \quad (04)$$

$$E = \frac{Q}{Q_{m\acute{a}x}} \quad (05)$$

Onde:

$Q_{m\acute{a}x}$  = Taxa de calor máxima (W);  $(m \times C_p)_{min}$  = Produto mínimo entre vazão mássica e capacidade calorífica ( $\frac{KJ}{s \times C}$ );  $E$  = Eficiência (adimensional).

A taxa de calor trocado geralmente é proporcional à área de troca térmica do trocador de calor que se atribui pela multiplicação do coeficiente global de troca

térmica ( $U$ ), com a área de troca térmica ( $A$ ) e com a variação de temperaturas entre os fluidos ( $\Delta T_{MLDT}$ ) como é expresso na equação 06:

$$Q = U \times A \times F_t \times \Delta T_{MLDT} \quad (06)$$

A diferença de temperaturas é estabelecida pela média logarítmica das temperaturas (Equação 07). Ao passo que o fator de correção ( $F_t$ ) igual a 1,0, o escoamento é definido como contracorrente. Porém, nos demais modelos de escoamento que não sejam justamente contracorrentes, é utilizado o fator de correção que altera entre 0 e 1.


$$\Delta T_{MLDT} = \frac{(T_{q,e} - T_{f,s}) - (T_{q,s} - T_{f,e})}{\ln \frac{(T_{q,e} - T_{f,s})}{(T_{q,s} - T_{f,e})}} \quad (07)$$

O inverso da resistência térmica de troca entre fluidos frios e quentes é designado como coeficiente global de troca de calor, conforme enunciado na equação 06. Para o cálculo, são aplicados o coeficiente de troca de calor por convecção ( $h$ ), a grossura da placa ( $\epsilon_p$ ), sua condutividade térmica ( $kp$ ) e fatores de incrustação ( $R$ ).

$$\frac{1}{U} = \frac{1}{h_f} + \frac{1}{h_q} + \frac{\epsilon_p}{k_p} + R_f + R_q \quad (08)$$

Na Figura 04 olhamos um circuito de aquecimento que, quando combinado, cria a equação 08 para um trocador de calor de placas.

**Figura 04** - Circuito térmico para a troca de calor no trocador de calor do tipo placas.



Fonte: Adaptado de GUT (2003).

## 2.4 MACHINE LEARNING

Segundo Reese (2017), *machine learning* (ML) é um aspecto mais extenso de refletir acerca dos avanços da inteligência de computadores, ao qual é um subtema da inteligência artificial (IA). Aplica-se ML para extrair informações e tomar decisões a partir de dados. É uma área de pesquisa da convergência da inteligência artificial, ciência da computação e estatística e também é denominado como aprendizado estatístico ou análise preditiva (MÜLLER & GUIDO, 2017). *Machine learning* pode ser determinado como método de criação de sistemas computacionais que automaticamente aperfeiçoam-se na companhia da experimentação e produzem um processo de aprendizagem (AYODELE, 2010).

Na ocasião em que se observa um *site* como Amazon, You Tube e Instagram, é possível que cada segmento da página apresente diversos modelos de *machine learning*. Por exemplo, sugestões de itens a serem adquiridos, que alimento solicitar

ou orientações automáticas de quais filmes visualizar, à identificação de parentes em suas fotografias e ao *streaming* de música personalizada (MÜLLER & GUIDO, 2017).

*Machine learning* é capaz de ser fragmentado em três categorias de algoritmos: Aprendizagem por reforço, aprendizado não supervisionado, e aprendizado supervisionado (SHIN et al., 2019). O aprendizado supervisionado, o qual iremos utilizar neste projeto para simular uma seção da planta de cervejaria, tem característica de automatizar processos de tomada de decisão com base em experiências apontadas. Neste formato, o usuário abastece ao algoritmo pares de entradas (variáveis independentes) e saídas (variáveis dependentes) esperadas, e o algoritmo descobre uma forma de fornecer a saída desejada dado uma entrada. Em particular, o algoritmo é ensinado a encontrar uma saída para uma entrada (MÜLLER & GUIDO, 2017).

Ao contrário do aprendizado supervisionado, onde são necessários dados de entradas e saídas, no aprendizado não supervisionado, só se utilizam dados de entrada no treinamento. Muitas vezes os métodos são utilizados como um método de pré-tratamento de dados de entrada para posteriormente ser utilizado em um aprendizado supervisionado.

Os modelos de aprendizado supervisionado e não supervisionado são orientados por dados. Enquanto o modelo de aprendizado reforçado é norteado através de problema a ser solucionado e não se submete uma regra do que realizar, e sim potencializar o sinal de recompensa. Sendo que, atrasado na recompensa e tentativas e erros, são as duas fundamentais particularidade desse modelo (VIEIRA,2021). Essa classe de aprendizado pode ser empregada no comando adaptativo de processos químicos, como refinarias de petróleo (SUTTON & BARTO, 1998).

Na engenharia química e de processos, a Inteligência artificial e *machine learning* têm vasta aplicabilidade, principalmente nas áreas de modelagem, estimativa, controle, simulação e predição de processos químicos (YAN et al., 2020). Estudos aplicando métodos de inteligência artificial para otimização de sistemas híbridos para gerenciamento de energia (Zahraee et al., 2016) também estão presentes na literatura. Um outro exemplo é a análise comparativa e estudo de previsão para emissões de gases efluentes em uma usina termelétrica a carvão, no

utilizando algoritmos de Modelos Autorregressivos, Regressão Linear Múltipla, Redes Neurais Artificiais e ferramentas estatísticas (Tunckaya & Koklukaya, 2015).

Apesar do deslocamento recente de computação mais rápido e influente tenha transportado uma intensidade de contentamento com o assunto da IA para todos os serviços fabris, abrangendo a engenharia química, a IA não é tão atual assim. No princípio da década de 1980, algoritmos genéticos e sistemas especialistas foram aplicados na indústria química no intuito de colaborar na predição de propriedades termofísicas de fluidos e no aperfeiçoamento de catalisadores. Posteriormente, as redes neurais artificiais acabaram se tornando o algoritmo mais presente na engenharia química em estimativas. Em virtude da sua habilidade de se adaptar bem a problemas diferentes e capacidade de decifrar questões não lineares (YAN et al., 2020).

## 2.5 APRENDIZADO SUPERVISIONADO

Aprendizado supervisionado é um dos mais usados e bem sucedidos tipos de *machine learning* (MÜLLER & GUIDO, 2017). Esse tipo de ML tenta descobrir as relações entre as variáveis de entrada (chamadas variáveis independentes) e as variáveis de saída (chamadas variáveis dependentes). A relação descoberta entre essas variáveis é representada numa estrutura chamada de modelo (MAINMON & ROKACH, 2005). No aprendizado supervisionado, as variáveis podem ser contínuas, categóricas ou binárias, e as variáveis de saída associadas às variáveis de entrada são conhecidas (KOTSIANTIS, 2007).

## 2.6 ETAPA DO APRENDIZADO DE MÁQUINA

As seguintes etapas estão envolvidas na resolução de um problema de aprendizagem supervisionado: definir o problema, identificar e coletar os dados necessários, pré-processamento dos dados, separando-os em dados de treinamento e teste, escolhendo o algoritmo, treinando o algoritmo/sintonização dos parâmetros e validação do modelo com o grupo de teste (KOTSIANTIS, 2007).

### 2.6.1 Identificação do Problema

As questões com aprendizagem supervisionada são divididas em duas categorias: questões de classificação e questões de regressão (MAINMON & ROKACH, 2005). A categoria estudada neste trabalho é de regressão, e o seu objetivo é prever o valor da variável de saída real (em termos matemáticos) (MÜLLER & GUIDO, 2017).

### 2.6.2 Coleta e Identificação dos Dados

O primeiro passo após a definição do problema é identificar e coletar os dados. Esta fase é conhecida como "Engenharia de Recursos" sendo dividida em quatro fases: *brainstorming*, criação, seleção e avaliação.

Durante a fase de *brainstorming*, identifique o problema dominante e reuni as informações para determinar quais atributos (características) poderia melhor transmitir os dados (BIANCHI, 2020). Neste caso, é aconselhável coletar informações sobre o maior número possível de características (atribuições) na esperança de isolar as variáveis mais importantes na ausência de um especialista (KOTSIANTIS, 2007).

Os recursos são criados durante a fase de criação. A fase de seleção permite a remoção ou expansão de algumas características, enquanto a fase de avaliação envolve estimar a qualidade do modelo utilizando as características escolhidas (Bianchi, 2020).

A coleta de dados geralmente inclui valores e erros, exigindo pré-processamento dos dados em um estágio posterior (Kotsiantis, 2007).

### 2.6.3 Pré-Processamento

Segundo Zhang et al. (2003), a fase de pré-processamento dos dados pode demorar mais e até mesmo proporcionar mais dificuldade do que a coleta e fase de identificação. Zhang et al. (2003) identificaram algumas razões pelas quais esta etapa é crucial:

- A preparação de dados produz dados de alta qualidade, o que pode ajudar na identificação de padrões de qualidade de dados.

- Os dados reais podem estar incompletos, cheios de erros e inconsistentes, que podem se desviar de práticas reais;

- A preparação de dados produz um conjunto menor de dados do que o original, talvez melhorando a eficácia da mineração de dados;

De acordo com Mainmon & Rokach (2005), existem os seguintes métodos genéricos de preparação de dados:

- Agrupamento: Identificação de outliers utilizando técnicas de agrupamento com base na distância Euclidiana;

- Regras da associação: Quando uma regra de associação é claramente definida, pontos que não se encaixam dentro da regra são considerados outliers.

- Padrão comportamental: detecção de outliers que se desviam das tendências dos dados disponíveis;

- Estatística: identificação de outliers usando desvio padrão, mediana e alcance com base na teoria chebyshev, levando em conta o intervalo de confiança para cada campo;

#### **2.6.4 Separação entre Grupos de Treino e Grupo de Teste**

Na Aprendizagem supervisionada, o objetivo é construir um modelo usando os dados do grupo de treinamento, para fazer previsões baseadas em dados novos, ainda não visíveis chamados de grupo de teste (MÜLLER & GUIDO, 2017). Normalmente, se assume que o grupo de treinamento é criado aleatoriamente e independentemente de acordo com algum tipo de distribuição estatística (MAINMON & ROKACH, 2005). Essa divisão de dados em grupos de treinamento e validação é conhecida como *Resampling* (reamostragem) (MOURA, 2016).

Três tipos de *resampling* foram listados por Moura (2016): validação cruzada, *bootstrap* e validação de *hold-out*. Os métodos de *resampling* são usados para medir a capacidade do modelo de generalizar informações utilizando medidas estatísticas como o desvio e média (BROWNLEE, 2019). O método mais simples de separar os dados é chamado de "*hold-out*", e nele uma parte dos dados é identificada como sendo "treino e teste". Usa-se frequentemente este método quando há muitos dados e acredita-se que a amostra tenha significado para representar a população.

Na metodologia *Bootstrap*, um conjunto de amostra é selecionado aleatoriamente e retirado do grupo de dados de treinamento. O modelo então é treinado com os dados de treinamento e testado com os dados separados. Assim, é possível medir a capacidade do modelo para prever dados que não estão incluídos no grupo de treinamento (BROWNLEE, 2019; YEN, 2019).

Existem vários tipos de validação cruzada (validação cruzada), mas a técnica mais utilizada é conhecida como *k-fold* validação cruzada. Neste método os dados são divididos em K partes, com cada um sendo reservado enquanto o modelo é treinado com as outras amostras. Os valores comuns de K para amostras estão entre 5 e 10. (MOURA, 2016).

Usa-se o grupo de treinamento para ajustar os parâmetros (ou pesos) do modelo de tal forma a reduzir o erro entre os “targets” (valores esperados) e a resposta do modelo. Se o grupo de treinamento e o grupo de teste compartilham um número suficiente de características, então espera-se que o modelo também será apropriado para o grupo de teste. No entanto, se os dois grupos forem muito diferentes, o modelo não será capaz de generalizar o conhecimento adquirido dos dados de treinamento. A mesma coisa acontece quando se constroem modelos realmente complexos. Quanto mais complexo o modelo, mais ele se ajustará aos dados de treinamento, mas a capacidade de generalizar o aprendizado fica inadequado (MÜLLER & GUIDO, 2017). *Overfitting* é o termo para modelos que se encaixam completamente em dados de treinamento, mas têm baixa capacidade de generalização (sobreajuste). Modelos que não correspondem bem aos dados são ditos *underfitting*.

### **2.6.5 Escolha dos Modelos de Aprendizagem Supervisionada**

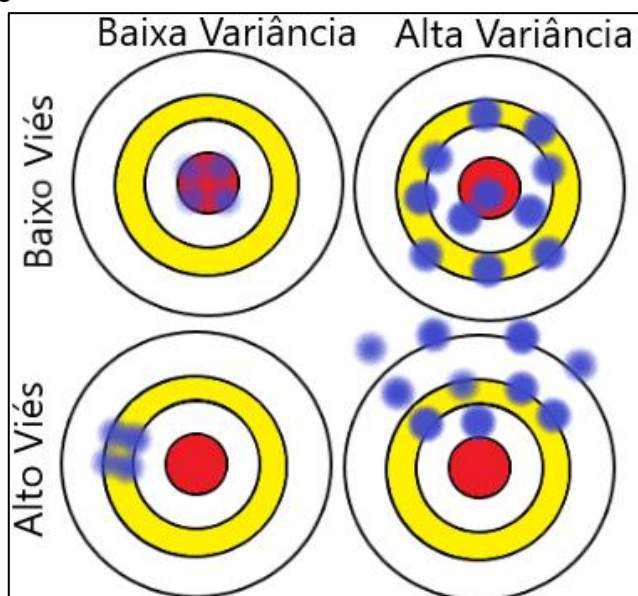
A seleção do algoritmo a ser usado é um passo crítico (KOTSIANTIS, 2007). Naturalmente, os melhores modelos são aqueles que produzem os resultados mais precisos; no entanto, outros fatores podem ser tão significativos, como, por exemplo, a complexidade computacional, além da compreensão e escalabilidade (MAINMON & ROKACH, 2005).

A escolha do algoritmo a ser usado normalmente envolve encontrar um equilíbrio entre as duas características primárias de variância e viés (bias). A variância



fala da consistência dos resultados obtidos pelo modelo adotado, enquanto o viés diz sobre a precisão do modelo adotado. A Figura 05 ilustra alguns casos em que a variância e o viés são observados como: O melhor modelo preditivo é aquele que pode combinar baixa viés e baixa variância (Figura 05, superior à esquerda), garantindo que os resultados obtidos sejam precisos e consistentes (BONFIM, 2020). Os modelos com alta variância e baixo viés são muitas vezes precisos, mas inconsistentes (Figura 05, superior à direita). Modelos com alto viés e baixa variância são confiáveis (Figura 05, inferior à esquerda), mas normalmente não são precisos. Modelos com alta variância e viés elevado não são precisos nem consistentes (Figura 05, inferior à direita).

**Figura 05** - Ilustração gráfica de Viés e Variância.



Fonte: Adaptado de Fortmann-Roe (2012).

De acordo com Müller (2017), é uma boa ideia começar com modelos simples para ver até onde pode chegar quando trabalhado com um novo conjunto de dados em geral. Depois de aprender mais sobre os dados, pode-se ir para modelos mais complexos. Ohri (2022) listou os dez principais algoritmos de aprendizagem baseados em supervisão usados na regressão, incluindo a regressão linear, redes neurais artificiais *Multi-Layer Perceptron* (MPL) e árvore de decisão. Esses modelos serão descritos nos parágrafos seguintes.

### 2.6.5.1 Modelo Linear

Na prática, modelos lineares são um tipo de modelos que são frequentemente utilizados. Este tipo de modelo prevê as saídas usando uma função linear das variáveis de entrada (MÜLLER & GUIDO, 2017). A equação 09 ilustra um modelo linear de previsão geral usado em uma regressão.

$$\hat{y} = w[0] * x[0] + w[1] * x[1] + \dots + w[p] * x[p] + b \quad (09)$$

Onde  $W$  e  $b$  são parâmetros aprendidos que deixam o modelo linear, e  $\hat{y}$  que é a previsão do modelo. Denota-se de  $x[0]$  até  $x[p]$  como variáveis de entrada de um único dado (MÜLLER & GUIDO, 2017). Uma regressão usando o modelo linear é referida como uma simples regressão linear, quando há apenas uma entrada variável. O nome é regressão linear múltipla, quando há duas ou mais variáveis de entrada.

Essa metodologia pressupõe linearidade entre as variáveis de entrada e saída. Neste estudo, utilizou-se o modelo de regressão linear de mínimos quadrados ordinários. Neste modelo, os parâmetros são calculados minimizando a soma quadrática das diferenças entre a saída predita e saída real (MÜLLER & GUIDO, 2017).

Como benefícios, os modelos lineares são rápidos em treinamento e previsão de dados, dimensionam bem para grandes conjuntos de dados e executar bem com dados limitados. Além disso, modelos lineares exibem boa compreensibilidade.


### 2.6.5.2 Redes Neurais Artificiais *Multi-Layer Perceptron* (MLP)

As redes neurais artificiais (ANN), que são modeladas baseado em redes neurais biológicas, são sistemas de computadores maciçamente paralelos compostos por um número muito grande de processadores básicos com muitas conexões (GUPTA, 2013). Esta família de algoritmos tem sido referida como aprendizado profundo. Algoritmos de aprendizagem profunda são geralmente criados sob demanda para fins específicos (MÜLLER & GUIDO, 2017).

Um exemplo básico de ANN seria: uma camada de entrada de neurônio, uma, duas ou três camadas de neurônios escondidos, e uma camada de alimentação final consiste em uma ANN (WANG, 2003). As entradas são multiplicadas por pesos (*weights*). Esses pesos são então calculados usando uma função matemática que determina quando os neurônios serão ativados. Outra função computa as saídas dos neurônios artificiais. Os neurônios desta rede sincronizam as suas entradas. Porque cada neurônio de entrada só pode processar uma entrada, os seus resultados são determinados multiplicando-se a entrada pelos pesos (GUPTA, 2013).

*Perceptron* múltiplas camadas (MLP) é um modelo de redes neurais artificiais usado em aprendizagem supervisionada. O modelo é uma função  $f(\cdot) : R^m \rightarrow R^o$ . A Figura 06 exibe um MLP de uma camada oculta com saída escalar.

Figura 06 - Uma camada oculta MPL.



Fonte: Adaptado de Scikit-Learn (2022).

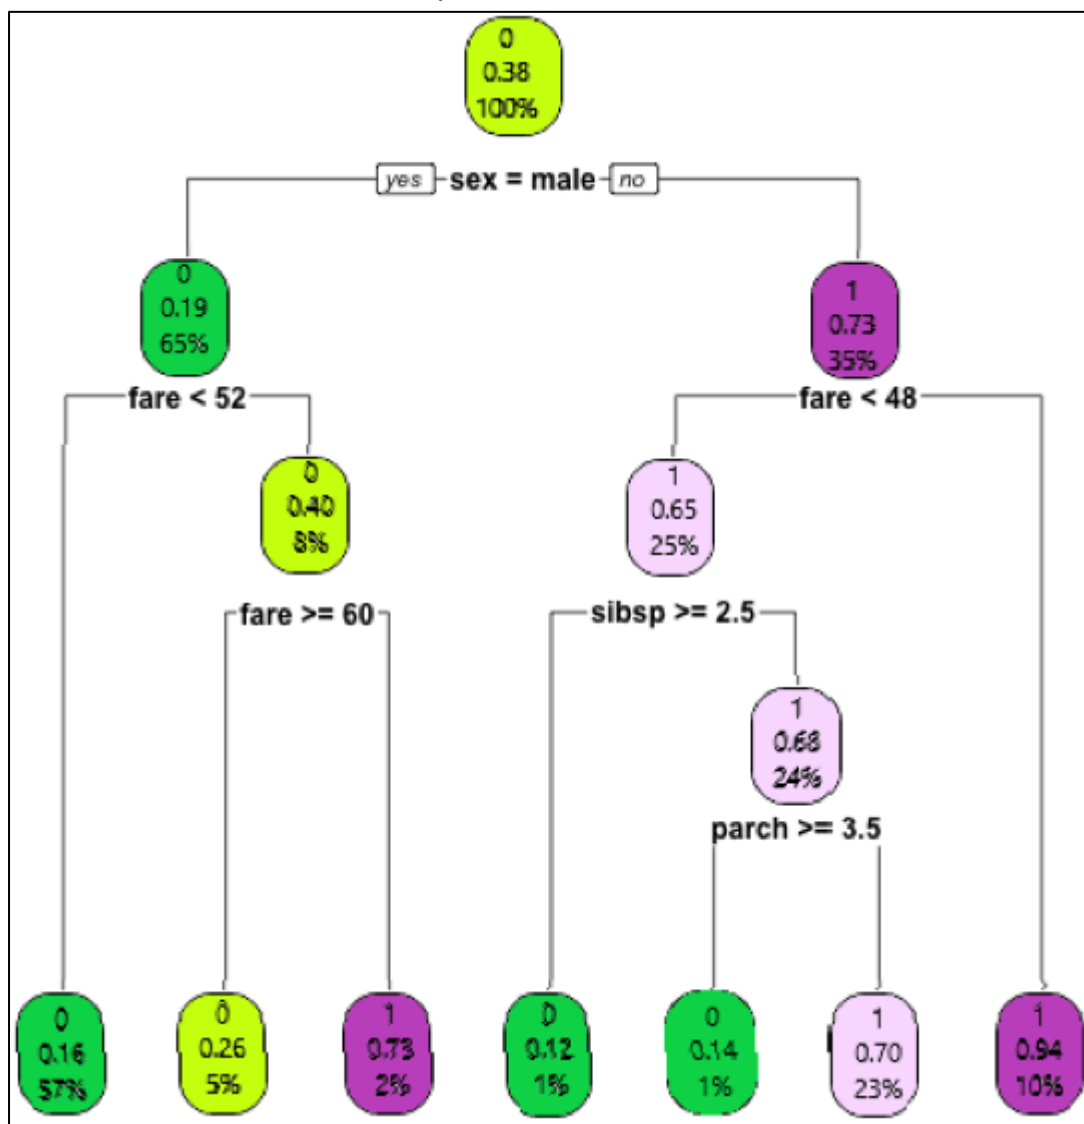
Algumas vantagens desse tipo de metodologia são apresentadas em Scikit-Learn (2022). As vantagens incluem capacidade de aprender comportamentos não lineares e capacidade de aprender modelos em tempo real (aprendizagem *on-line*).

### 2.6.5.3 Árvore de Decisões

Na modelagem da árvore de decisão, uma árvore de decisão empírica representa uma segmentação dos dados e é criada aplicando um conjunto de regras simples (TSO & YAU, 2007). O objetivo é chegar à resposta correta a uma série de perguntas se/senão (número real, quando utilizado para regressão, ou categoria quando utilizado para classificação) (MÜLLER & GUIDO, 2017).

O algoritmo da árvore de decisão funciona da seguinte maneira: um teste preliminar é realizado para tentar reproduzir o modelo. Os dados são avaliados e dado uma resposta de "verdadeiro" ou "falso". Uma segunda rodada de testes é então conduzida para o grupo verdadeiro e o grupo falso. Isso continua até que todos os testes propostos sejam totalmente representativos dos dados (MÜLLER & GUIDO, 2017). Um exemplo de árvore de decisão é mostrado na Figura 07.

Figura 07 - Árvore de decisão: Exemplo dados do Titanic.



Fonte: Adaptado de Ribeiro (2018).

Os modelos de árvore de decisão tendem a ter um viés muito alto, ou então os coeficientes dos valores de determinação acabam sendo 1 ou muito perto dele, devido à característica de aumentar o número de testes até que todos os dados são levados em conta. Um viés muito alto indica que o modelo combina bem com o grupo de treinamento, mas pode não generalizar esta compreensão também para o grupo de teste, o que caracterizaria como *overfitting*. Além disso, este modelo tem outras desvantagens, como o fato de que ele tem um desempenho ruim com variáveis contínuas, pequenas diferenças nos dados podem resultar em grandes diferenças na estrutura da árvore, levando à instabilidade, os cálculos envolvidos podem se tornar mais complexos quando comparados com outros algoritmos, o que aumenta o

treinamento tempo e custo. Alta compreensão de modelos para não especialistas e a não variação do modelo no escalonamento de dados são duas de suas vantagens (MÜLLER & GUIDO, 2017).

A utilidade do atributo (variável) para classificação é o critério utilizado para a realização das decisões tomadas nos ramos da árvore de decisão. De acordo com esse critério, cada atributo recebe uma quantidade específica de ganho de informação. O atributo que tem o maior ganho de informação é o escolhido para servir como teste do corrente nó. A partir desta aplicação, um novo processo seletivo será implementado.

Os critérios de classificação mais conhecidos em situações em que a árvore é utilizada são a entropia e o índice de Gini. (Onoda, 2001).

Conrado Gini criou o índice Gini em 1912 e é usado neste trabalho para medir o grau de heterogeneidade de dados. Assim, pode ser usado para medir a impureza de um nó (Onoda, 2001).

Este índice num determinado nó é dado por:

$$1 - \sum_{i=1}^c p_i^2 \quad (10)$$

Onde:

$p_i$  é a frequência relativa de cada classe em cada nó

$c$  é o número de classes

Quando este índice é igual a zero, o nó é puro. Por outro lado, quando ele se aproxima do valor um, o nó é impuro (aumenta o número de classes uniformemente distribuídas neste nó).

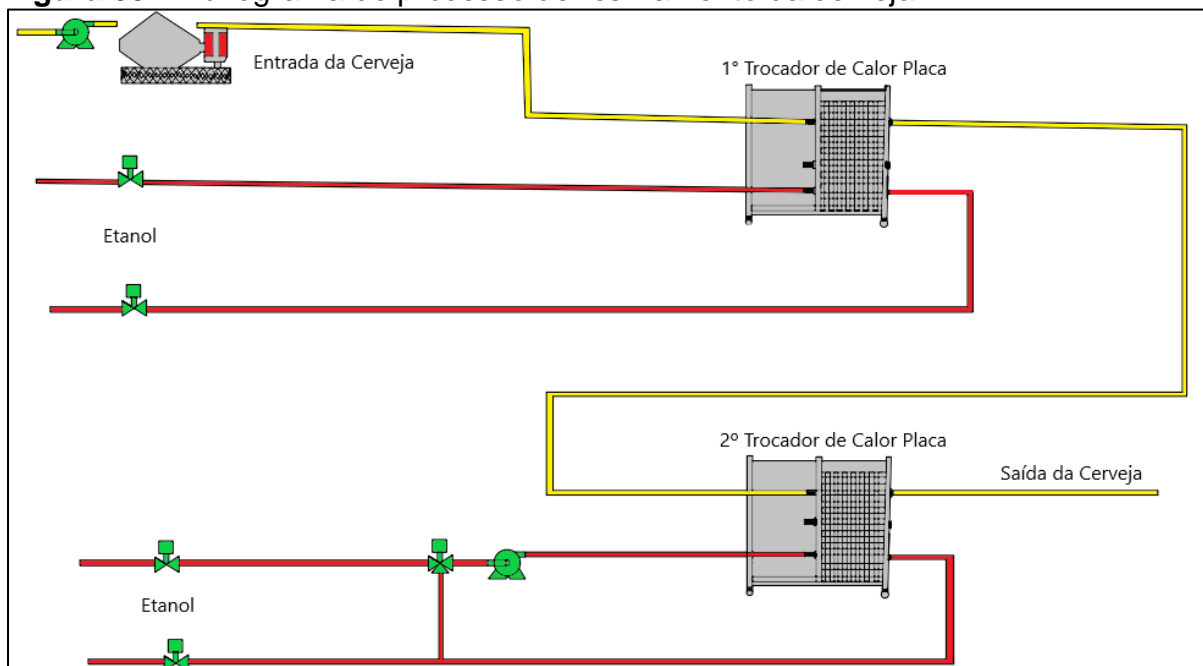
Quando o critério de Gini é usado para árvores de classificação com partições binárias tende-se a isolar em um ramo os dados, que correspondem à classe mais comum.

### 3 METODOLOGIA

A construção de modelos baseados em IA para descrever os dois trocadores da cervejaria tem como base dados reais de processo. Esses dados estão indicados na Tabela 01. A Figura 08 retrata o diagrama do processo do sistema real de resfriamento de cerveja de onde os dados são provenientes. No entanto, as configurações dos trocadores de calor de placas reais não estão disponíveis.

A construção de modelos baseados em IA para descrever os dois trocadores de calor foram feitos por intermédio do *software* de simulação de processos *Aspen HYSYS®*. O processo real de resfriamento da cerveja é retratado na Figura 08. Dados reais de processo das correntes mostradas nessa figura estão disponíveis na Tabela 01. No entanto, as configurações dos trocadores de calor de placas reais não estão disponíveis.

**Figura 08** - Fluxograma do processo de resfriamento da cerveja.



Fonte: Elaborado pelo autor no *AutoCAD Web App*.

**Tabela 01** – Dados das correntes do processo de resfriamento da cerveja.

<b>1.º Trocador de Calor Placa</b>					
Corrente Quente / Cerveja			Corrente Fria / Etanol + Água		
	Entrada	Saída		Entrada	Saída
Vazão [kg/s]	9,82	9,82	Vazão [kg/s]	$x$	$x$
Temperatura [°C]	16,3	5,47	Temperatura [°C]	3,12	8,06
Pressão [kgf/cm <sup>2</sup> ]	3,33	3,04	Pressão [kgf/cm <sup>2</sup> ]	2,96	1,42
<b>2.º Trocador de Calor Placa</b>					
Corrente Quente / Cerveja			Corrente Fria / Etanol + Água		
	Entrada	Saída		Entrada	Saída
Vazão [kg/s]	9,82	9,82	Vazão [kg/s]	$y$	$y$
Temperatura [°C]	5,47	-0,52	Temperatura [°C]	-2,56	0,27
Pressão [kgf/cm <sup>2</sup> ]	3,04	2,23	Pressão [kgf/cm <sup>2</sup> ]	4,89	1,86

Fonte: Elaborado pelo autor.

### 3.1 DIMENSIONANDO OS TROCADORES DE CALOR

As variáveis independentes que devem ser especificadas para definir completamente um processo são seus graus de liberdade (resultado da coleção de equações que caracterizam a dinâmica do sistema, equação 11).

*Graus de liberdade = n<sup>o</sup> variáveis independentes - n<sup>o</sup> de equações independentes*

$$f = V - E \quad (11)$$

Na Tabela 02 são listadas tanto as variáveis, como as equações independentes do processo.



**Tabela 02** - Graus de Liberdade.

Variáveis independentes ( $V$ )	Equações independentes ( $E$ )
$Q$	
$\dot{m}_f$	Equação 02
$T_{f,e}$	
$T_{f,s}$	
$\dot{m}_q$	Equação 03
$T_{q,e}$	
$T_{q,s}$	
$U$	
$A$	Equação 06
$\Delta T_{MLDT}$	Equação 07
$F_t$	

Fonte: Elaborado pelo autor

Note que, na Tabela 02, o calor trocado foi assumido como uma variável apenas  $Q$ , pois assume-se que o calor cedido pelo fluido quente é o calor recebido pelo fluido frio. Os valores de  $c_p$  das equações 02 e 03 dependem da composição dos líquidos e da temperatura e são calculados por correlações presentes no *Aspen*. As variáveis  $U$ ,  $A$  e  $F_t$ , dependem de vários parâmetros do processo, inclusive das configurações dos trocadores, o que não está disponível. Logo, os graus de liberdade do sistema (Equação 12) é:

$$f = V - E = 6 - 2 = 2 \quad (12)$$

Assim, o produto  $U.A.F_t$  é encarado como uma variável apenas, função das configurações do trocador e representa sua capacidade de troca térmica. Dessa forma, os graus de liberdade se fecham. O sistema foi resolvido utilizando o *Aspen EDR (Exchanger Design & Rating)*. Como resposta, o *software* sugere várias

configurações de trocadores de calor de placa que capazes de prover a capacidade de troca térmica necessária.

Dentre os dozes *designs* sugeridos pelo *software*, foi escolhido o melhor no primeiro trocador (Anexo A), e dentre os nove *designs* gerados, somente um no segundo trocador (Anexo D). As configurações escolhidas para o 1º e 2º trocadores estão apresentadas nas Tabelas 03 e 04. Mais detalhes dos equipamentos como peso e custo se encontram nos anexos B, C, E e F. Dado o equipamento, área de troca térmica é também dada pelo simulador, sendo 104,52 e 58 m<sup>2</sup> para o 1º e 2º trocador, respectivamente.

**Tabela 03** – Dimensões do 1º Trocador de calor.

Ângulo de Inclinação <i>Chevron</i> (na horizontal) [graus]	30
Outro ângulo de Inclinação <i>Chevron</i> ( <i>mixed plate</i> ) [graus]	30
Distancia horizontal dos centros dos orifícios [mm]	260
Distancia vertical dos centros dos orifícios [mm]	1368,42
Espessura da placa [mm]	0,6
<i>Compressed plate pitch</i> [mm]	3,52
Diâmetro do orifício [mm]	100
Largura do Prato [mm]	380
Área do prato [m <sup>2</sup> ]	0,52
Número de pratos por área [m <sup>2</sup> ]	1

Fonte: Elaborado pelo autor com base em *Aspen EDR*.

**Tabela 04** - Dimensões do 2º Trocador de calor.

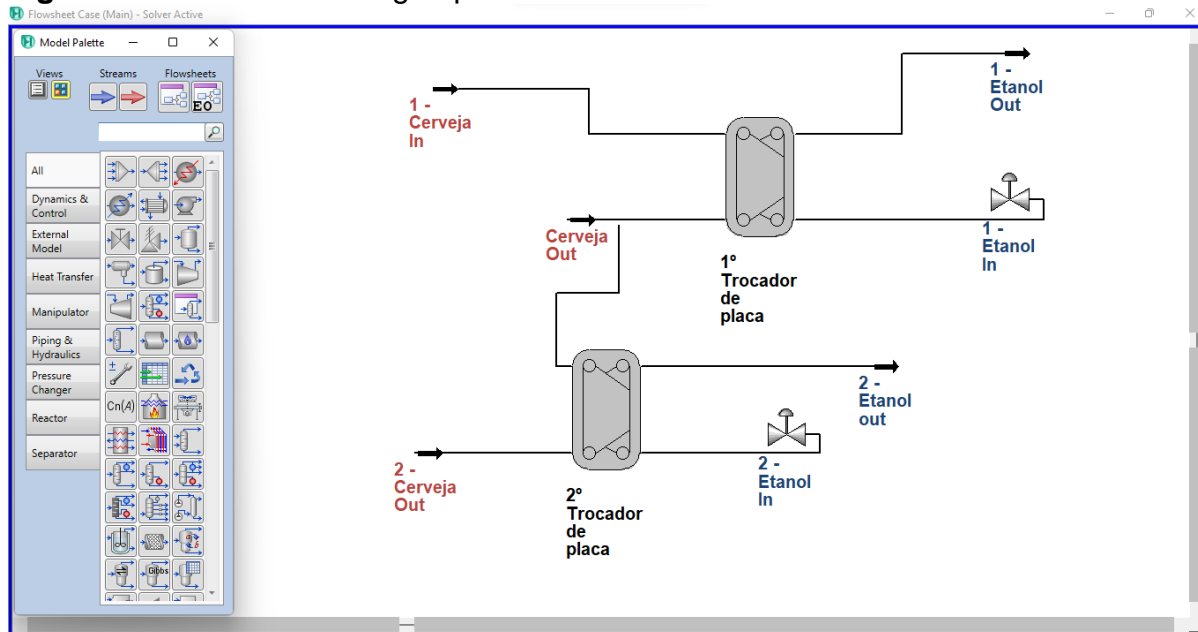
Ângulo de Inclinação <i>Chevron</i> (na horizontal) [graus]	30
Outro ângulo de Inclinação <i>Chevron</i> ( <i>mixed plate</i> ) [graus]	30
Distancia horizontal dos centros dos orifícios [mm]	260
Distancia vertical dos centros dos orifícios [mm]	1052,63
Espessura da placa [mm]	0,6
<i>Compressed plate pitch</i> [mm]	3,52
Diâmetro do orifício [mm]	100
Largura do Prato [mm]	380
Área do prato [m <sup>2</sup> ]	0,4
Número de pratos por área [m <sup>2</sup> ]	1

Fonte: Elaborado pelo autor com base em *Aspen EDR*.

### 3.2 IMPLEMENTAÇÃO EM ASPEN

Para a simulação considerou-se que a cerveja é composta por 4,5% de etanol, 0,50% de dióxido de carbono e 95% de água. Os valores reais variam conforme o tipo de cerveja produzido (De Keukelerie, 2000; Aquarone et al., 1983). Ao passo que a corrente fria de etanol e água possuem 25 e 75%, respectivamente. O NRTL foi utilizado para descrever a não idealidade nos líquidos. A Figura 09 mostra a implementação final dos trocadores no *Aspen*.

**Figura 09** - O *Flowsheet* logo após a conexão das correntes.



Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

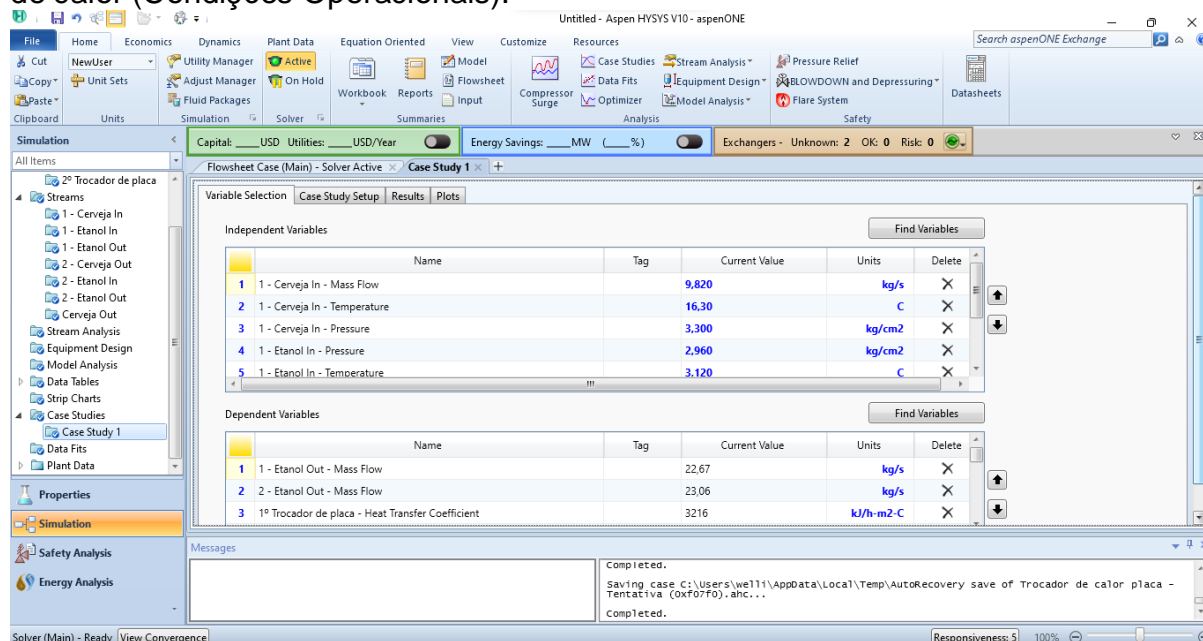
### 3.3 CRIANDO DADOS DE TREINAMENTO

Para criar dados para o treinamento dos modelos baseados em AI, foi utilizada a ferramenta de análise de sensibilidade do *Aspen*. Essas análises compreendem em alterar as variáveis independentes (entrada) do processo primeiramente definidos, e calcular as variáveis dependentes (saída).

Para isso, foram escolhidas a vazão, pressão e temperatura de entrada da corrente de cerveja no 1º trocador de calor, bem como a temperatura e pressão de entrada da corrente de etanol em ambos trocadores de calor, que sofrem alterações durante a operação do processo e se configura para trabalhar em uma faixa de alimentação, e assim prever com mais exatidão as vazões das correntes de etanol.

Em seguida, foi construída uma análise de sensibilidade dessas variáveis, produzindo um estudo de caso (Figura 10).

**Figura 10** - Caracterização das correntes materiais de entrada e saída do trocador de calor (Condições Operacionais).



Fonte: Elaborado pelo autor no Aspen HYSYS, n.d.

Na Tabela 05, verifica-se os valores de *input* das variáveis de entrada com as seguintes informações de: intervalo (entrada e saída) e passo. Do qual compõem variação de  $\pm 10\%$  com base nos dados do caso real da cervejaria. Com finalidade de introduzir esses valores acessou-se a aba *Case Study Setup*.

**Tabela 05** – Configuração do case quanto as correntes materiais de entrada e saída dos trocadores de calor.

Nome da Corrente	Unidade	Começo	Fim	Passo	*Quantidade de passos
1 - Cerveja In – <i>Mass Flow</i>	$\frac{kg}{s}$	8,838	10,80	0,2	10
1 - Cerveja In – <i>Temperature</i>	°C	14,67	17,93	0,4	9
1 - Cerveja In – <i>Pressure</i>	$\frac{kgf}{cm^2}$	2,997	3,663	0,1	7
1 - Etanol In – <i>Pressure</i>	$\frac{kgf}{cm^2}$	2,664	3,256	0,1	6
1 - Etanol In – <i>Temperature</i>	°C	2,808	3,432	0,2	4
2 - Etanol In – <i>Temperature</i>	°C	-2,816	-2,304	0,2	3
2 - Etanol In – <i>Pressure</i>	$\frac{kgf}{cm^2}$	4,401	5,379	0,5	2
<b>Total de Linhas</b>					<b>90720</b>

Fonte: Elaborado pelo autor no *Aspen HYSYS*.

\*Quantidade de passos é preenchido e multiplicado automaticamente após inserção do passo, e que conseqüentemente gera o total de linhas.

### 3.4 TRATAMENTO DOS DADOS

Uma vez coletado um total de 90720 dados no *software Aspen HYSYS® V10*, procedeu-se em armazená-los em planilha no *Microsoft Service Excel* e os processar em *Python* usando o *Google Collaboratory* (COLLABORATORY, n.d.). Com auxílio do *matplotlib*, *numpy*, *sklearn* e *pandas* como bibliotecas para plotagem e modelo preditivo de aprendizado de máquina.

### 3.5 MODELOS DE MACHINE LEARNING

Conforme já mencionado, um modelo de *machine learning* supervisionado foi aplicado para prever o comportamento da variável de interesse, fluxo de etanol, no

primeiro e segundo trocador de calor, a saber: Regressão linear, Rede Neural Artificial (RNA) com *Perceptron* múltiplas camadas (MLP) e Árvore de decisão.

As informações são divididas em dados de teste e dados de treinamento. Os dados de treinamento são utilizados para treinar o modelo, ou seja, para calcular os parâmetros/coeficientes do modelo. O conjunto de teste possui como propósito aferir a eficácia do modelo de generalizar informações. Isso significa quão bem o modelo erigido com os dados de treinamento é capaz de ser utilizados para prever dados que o algoritmo de modo algum viu. Em seguida a esta fase, os modelos são verificados.

### 3.5.1 Parâmetros dos Modelos.

*Perceptron* múltiplas camadas (MLP):

Os principais parâmetros configurados em *default* e utilizados em *Perceptron* múltiplas camadas (MLP) foram:

Tabela 06 - Parâmetros do Modelo MLP.

<b>Parâmetros</b>	<b><i>hidden_layer_sizes</i></b> : <i>tupla</i> , comprimento = $n\_layers - 2$ , <i>default</i> = (100,) Este atributo representa o número de camada e de neurônios na camada oculta.
	<b><i>Activation</i></b> {'identidade', 'logística', 'tanh', 'relu'}, <i>default</i> = 'relu' Função de ativação para a camada oculta. <ul style="list-style-type: none"> <li>'relu', a função da unidade linear retificada, retorna <math>f(x) = \max(0, x)</math></li> </ul>
	<b><i>Solver</i></b> {'lbfgs', 'sgd', 'adam'}, <i>default</i> ='adam' O solucionador para otimização de peso. 'adam' refere-se a um otimizador baseado em gradiente estocástico proposto por Kingma, Diederik e Jimmy Ba

Fonte: Adaptado de Scikit-Learn (2022).

Nota: O solucionador padrão 'adam' funciona muito bem em conjuntos de dados relativamente grandes (com milhares de amostras de treinamento ou mais) em

termos de tempo de treinamento e pontuação de validação. Para pequenos conjuntos de dados, no entanto, 'lbfgs' podem convergir mais rápido e ter melhor desempenho.

Árvore de decisão:

Já no modelo árvore de decisão se configurou os seguintes parâmetros:

**Tabela 07** - Parâmetros do Modelo Árvore de Decisão.

	<b><i>Splitter</i></b> {"best", "random"}, default = "best"
	A estratégia usada para escolher a divisão em cada nó. A estratégia utilizada foi "best" para escolher a melhor divisão.
	<b><i>max_depthint</i></b> , default = Nenhum
<b>Parâmetros</b>	A profundidade máxima da árvore. Se Nenhum, então os nós são expandidos até que todas as folhas estejam puras ou até que todas as folhas contenham menos de <i>min_samples_split</i> amostras.
	<b><i>min_samples_split</i></b> : int ou float, default=2
	O número mínimo de amostras necessárias para dividir um nó interno:  Utilizou-se float, então é uma fração e são o número mínimo de amostras para cada $\text{split.min\_samples\_split} \lceil \text{min\_samples\_split} * n\_samples \rceil$

Fonte: Adaptado de Scikit-Learn (2022).

### 3.6 VALIDAÇÃO DOS MODELOS

Examinar a acurácia do modelo para o ajuste dos dados de treinamento, tal como para a generalização da aprendizagem para os dados de teste fazem parte da fase de validação. Os valores do coeficiente de correlação variam de 0 a 1. Quanto mais perto de 1 o valor é, melhor o modelo se encaixa nos dados. Para o modelo de regressão linear, *Perceptron* múltiplas camadas e árvore de decisão, os dados de treinamento e de teste foram verificados os seus respectivos coeficientes de determinação ( $R^2$ ). Vale notar que, como o modelo base (fenomenológico) é determinístico, ou seja, não tem um ruído associado, espera-se que o modelo obtido no final tenha um  $R^2$  muito próximo de 1. É importante verificar se os dados de teste também tenham comportamento similar sem erros tendenciosos.



O método da validação cruzada foi usado para dividir dados de forma mais eficaz em dois grupos de treinamento e teste, apesar da quantidade enorme de dados coletados. Na validação cruzada, os dados são separados em N grupos com cerca de mesmo número de dados. Um desses N grupos é selecionado para ser o grupo de teste, à medida que os outros N-1 grupos são selecionados para treinar o modelo. Logo após, os próximos N-1 grupos restantes (contendo o primeiro grupo) são então decididos para servir como o grupo de treinamento do modelo após um segundo grupo ser selecionado como um grupo de teste. O procedimento é repetido até que todos os N grupos sejam selecionados como o grupo de teste (MÜLLER, 2017).

Usando este método, são obtidos N valores do coeficiente de correlação, em seguida calcula-se a média. Em vez de obter um único valor de coeficiente de correlação.

O Segundo processo de validar os modelos é através da análise dos resíduos (ou erros). Os resíduos são a variação entre o valor previsto e o valor real da variável dependente usando modelos ajustados.

Neste trabalho, foi aplicado o erro quadrático médio (Equação 13, MSE da sigla em inglês *Mean Squared Error*).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (13)$$

Onde,

$Y_i$ : dados reais

$\hat{Y}_i$ : dados de ajuste.

$n$ : quantidade de dados.

Para avaliar o resultado, utilizou-se a raiz quadrada do erro médio quadrado dos dados de validação, já que denota o desvio padrão do erro de validação e tem a mesma unidade da variável de saída.

$$DP = \sqrt{MSE} \quad (14)$$

Terceiro processo de validação do modelo, foi análise das *Feature importance* (Variáveis importantes), do qual refere-se a uma classe de técnicas para atribuir pontuações a variáveis de entrada a um modelo preditivo que indica a importância relativa de cada variável ao fazer uma previsão (Brownlee,2020).

Scores de importância de características podem ser calculados para problemas que envolvem prever um valor numérico, chamado regressão, e aqueles problemas que envolvem a previsão de um rótulo de classe, chamado classificação.

As pontuações são úteis e podem ser usadas em uma série de situações em um problema de modelagem preditiva, tais como:

- Melhor entender os dados;
- Melhor entender um modelo;
- Reduzindo o número de variáveis de entrada.

As pontuações de importância da variável podem fornecer uma visão do conjunto de dados. Os scores relativos podem destacar quais características podem ser mais relevantes para o alvo, e o inverso, quais características são as menos relevantes. Isso pode ser interpretado por um especialista e pode ser usado como base para a coleta de mais ou diferentes dados.

As pontuações de importância da variável podem fornecer uma visão do modelo. A maioria dos scores de importância são calculadas por um modelo preditivo que foi encaixado no conjunto de dados. Inspeccionar a pontuação de importância fornece uma visão sobre esse modelo específico e quais características são as mais importantes e menos importantes para o modelo ao fazer uma previsão. Este é um tipo de interpretação de modelo que pode ser realizada para os modelos que o suportam.

A importância da variável pode ser usada para melhorar um modelo preditivo. Isso pode ser alcançado usando as pontuações de importância para selecionar essas variáveis para excluir (pontuações mais baixas) ou aquelas variáveis a manter (pontuações mais altas). Este é um tipo de seleção de variáveis e pode simplificar o problema que está sendo modelado, acelerar o processo de modelagem (a exclusão de recursos é chamada de redução de dimensionalidade), e, em alguns casos, melhorar o desempenho do modelo (Brownlee,2020).

## 4 RESULTADOS E DISCUSSÃO

Os resultados deste capítulo incluem as análises realizadas, tal como as discussões sobre os resultados abordados.

A Figura 11 apresenta os resultados numéricos das vazões mássicas e temperaturas de saída das correntes de Etanol e coeficiente global de transferência de calor do primeiro e segundo trocador de calor, para cada um dos estados previamente definidos. Esse conjunto de estados representam os “targets”, ou seja, os valores de saída que os modelos empíricos devem aprender.

**Figura 11** – Resultado apresentado para as variáveis dependente.

State	1 - Cerveja In - Mass Flow [kg/s]	1 - Cerveja In - Temperature [C]	1 - Cerveja In - Pressure [kg/cm2]	1 - Etanol In - Pressure [kg/cm2]	1 - Etanol In - Temperature [C]	2 - Etanol In - Temperature [C]	2 - Etanol In - Pressure [kg/cm2]	1 - Etanol Out - Mass Flow [kg/s]	2 - Etanol Out - Mass Flow [kg/s]	1º Trocador de calor - Heat Transfer Coefficient [kJ/h-n C]
Case 1	8,838	14,67	2,997	2,664	2,808	-2,816	4,401	11,93	13,09	321
Case 2	8,838	14,67	2,997	2,664	2,808	-2,816	4,901	11,93	13,12	321
Case 3	8,838	14,67	2,997	2,664	2,808	-2,616	4,401	11,93	14,88	321
Case 4	8,838	14,67	2,997	2,664	2,808	-2,616	4,901	11,93	14,92	321
Case 5	8,838	14,67	2,997	2,664	2,808	-2,416	4,401	11,93	17,43	321
Case 6	8,838	14,67	2,997	2,664	2,808	-2,416	4,901	11,93	17,48	321
Case 7	8,838	14,67	2,997	2,664	3,008	-2,816	4,401	12,83	13,09	321
Case 8	8,838	14,67	2,997	2,664	3,008	-2,816	4,901	12,83	13,12	321
Case 9	8,838	14,67	2,997	2,664	3,008	-2,616	4,401	12,83	14,88	321
Case 10	8,838	14,67	2,997	2,664	3,008	-2,616	4,901	12,83	14,92	321
Case 11	8,838	14,67	2,997	2,664	3,008	-2,416	4,401	12,83	17,43	321
Case 12	8,838	14,67	2,997	2,664	3,008	-2,416	4,901	12,83	17,48	321
Case 13	8,838	14,67	2,997	2,664	3,208	-2,816	4,401	13,96	13,09	321
Case 14	8,838	14,67	2,997	2,664	3,208	-2,816	4,901	13,96	13,12	321
Case 15	8,838	14,67	2,997	2,664	3,208	-2,616	4,401	13,96	14,88	321
Case 16	8,838	14,67	2,997	2,664	3,208	-2,616	4,901	13,96	14,92	321
Case 17	8,838	14,67	2,997	2,664	3,208	-2,416	4,401	13,96	17,43	321
Case 18	8,838	14,67	2,997	2,664	3,208	-2,416	4,901	13,96	17,48	321
Case 19	8,838	14,67	2,997	2,664	3,408	-2,816	4,401	15,40	13,09	321
Case 20	8,838	14,67	2,997	2,664	3,408	-2,816	4,901	15,40	13,12	321

Fonte: Elaborado pelo autor no Aspen HYSYS, n.d.

### 4.1 VAZÃO DA CORRENTE ETANOL, COEFICIENTE GLOBAL DE TRANSFERÊNCIA E EFICIÊNCIA.

Nesta seção, são apresentadas as análises da vazão da corrente Etanol, coeficiente global de transferência de calor e Eficiência que serão divididas em duas partes: (i) seção do primeiro trocador de calor e (ii) seção do segunda trocador de calor.

#### 4.1.1 Análise da Seção do Primeiro Trocador de Calor.

Os modelos aplicados na predição da vazão de etanol no primeiro trocador de calor foram analisados, com base na vazão real da corrente de etanol (Figura 12). A Tabela 08 expõe os coeficientes de determinação de treino e de teste dos modelos preditivos para a vazão de etanol no primeiro trocador de calor. A Tabela 09 mostra os coeficientes de determinação descobertos na validação cruzada e consigo a média deles para cada modelo.

**Tabela 08** - Coeficiente de determinação de treino e de teste dos modelos preditivos para vazão de etanol no 1º trocador de calor.

	Coeficientes de determinação	
	Treino	Teste
<b>Regressão Linear</b>	0,834	0,834
<b>Regressão MLP</b>	0,865	0,865
<b>Árvore de decisão</b>	1,000	0,999

Fonte: Elaborado pelo autor.

**Tabela 09** - Coeficientes de validação cruzada dos modelos preditivos para vazão de etanol no 1º trocador de calor.

	Coeficiente de determinação				
	1	2	3	4	Médio
<b>Regressão Linear</b>	0,835	0,836	0,835	0,830	0,834
<b>Regressão MLP</b>	0,869	0,871	0,921	0,919	0,895
<b>Árvore de Decisão</b>	0,999	0,999	0,999	0,999	0,999

Fonte: Elaborado pelo autor.

Através da validação cruzada, é possível verificar que o coeficiente de determinação médio para o modelo Árvore de Decisão é 0,999, indicando que o modelo representa com precisão os dados coletados. Quanto ao desvio e o erro quadrático médio de cada modelo é apresentado na Tabela 10.

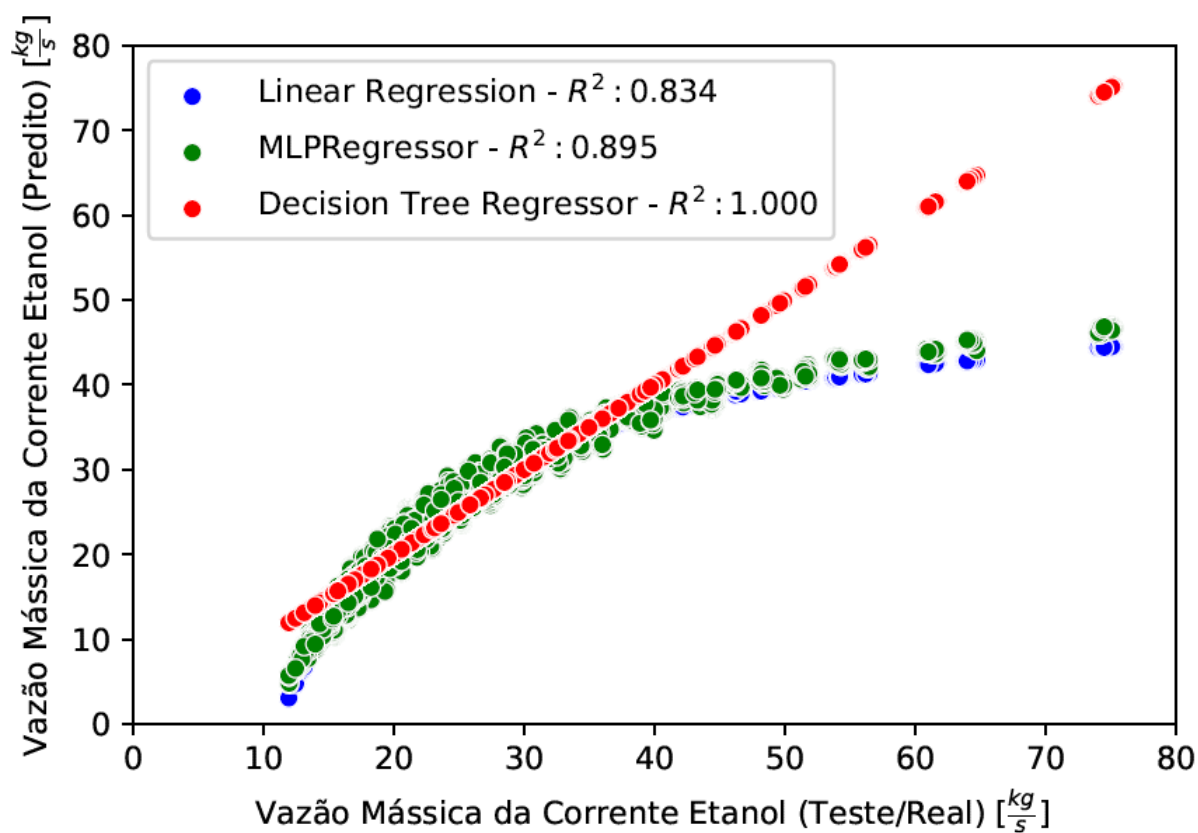
**Tabela 010** – Desvio Padrão e Erro Quadrático Médio dos Modelos no 1º Trocador de Calor.

	Desvio Padrão	Erro Quadrático Médio
<b>Regressão Linear</b>	$2,33 \times 10^{-03}$	12,85
<b>Regressão MLP</b>	$2,50 \times 10^{-02}$	10,44
<b>Árvore de Decisão</b>	$1,92 \times 10^{-08}$	$1,47 \times 10^{-06}$

Fonte: Elaborado pelo autor.

Com os resultados calculados para os três modelos no primeiro trocador de calor, pode-se afirmar mais uma vez que o modelo Árvore de Decisão sobressaiu quanto o desvio e erro quadrático médio com os menores valores computados.

**Figura 12** – Vazão real versus vazão predita da corrente Etanol no 1º primeiro trocador de calor para cada modelo de regressão.



Fonte: Elaborado pelo autor.

O modelo de regressão linear e *perceptron* múltiplas camadas obtiveram comportamentos similares em todos os estágios, na previsão da corrente de etanol no primeiro trocador de calor, o que justifica a proximidade nos valores dos coeficientes de determinação 0,834 e 0,895, respectivamente. Divergindo do modelo de árvore de decisão na fase inicial e final, do qual o desvio é menor em relação aos dados de teste/reais. O erro sistemático obtido pelo regressor linear é esperado devido à natureza não linear do fenômeno, principalmente a relação logarítmica entre as temperaturas (Equação 08). Já o comportamento da rede neural não era esperado. Sabe-se que os *perceptrons* de múltiplas camadas é um aproximador universal e portanto, ao aumentar a complexidade da rede (número de neurônios intermediários), ele deve ser capaz de descrever qualquer função contínua. A proximidade do resultado com o de um sistema linear sugere que a função ativação implementada pelo software utilizado é uma função puramente linear. Uma melhor exploração nos parâmetros da função de treinamento e criação da arquitetura da rede neural poderá levar a resultado melhores deste modelo.

A árvore de decisão apresentou também um bom desempenho de treinamento na predição da vazão mássica da corrente Etanol, em 0,68 segundos, conforme a Tabela 11. Quando equiparado ao modelo de regressão linear neste quesito, não há disparidade de tempo apesar dos coeficientes de determinação distantes. Diferente do modelo Regressão MLP, onde o período foi extremamente maior em relação aos demais modelos.

**Tabela 011** - Tempo de treinamento dos modelos para predição da corrente mássica de etanol no 1º Trocador de calor.


<b>Modelos</b>	<b>Tempo</b>
<b>Regressão Linear</b>	00 min 00,18 seg
<b>Regressão MLP</b>	05 min 18,54 seg
<b>Árvore de Decisão</b>	00 min 00,68 seg

Fonte: Elaborado pelo autor no COLABORATORY, n.d.

Uma análise mais aprofundada no que diz respeito ao modelo árvore de decisão na predição da vazão da corrente de Etanol, encontra-se na Figura 13.

Constando-se o grau de importância das variáveis de entrada no processo medidas em percentagem.

**Figura 13** - Principais Variáveis do Modelo Árvore de Decisão no 1º Trocador de calor.

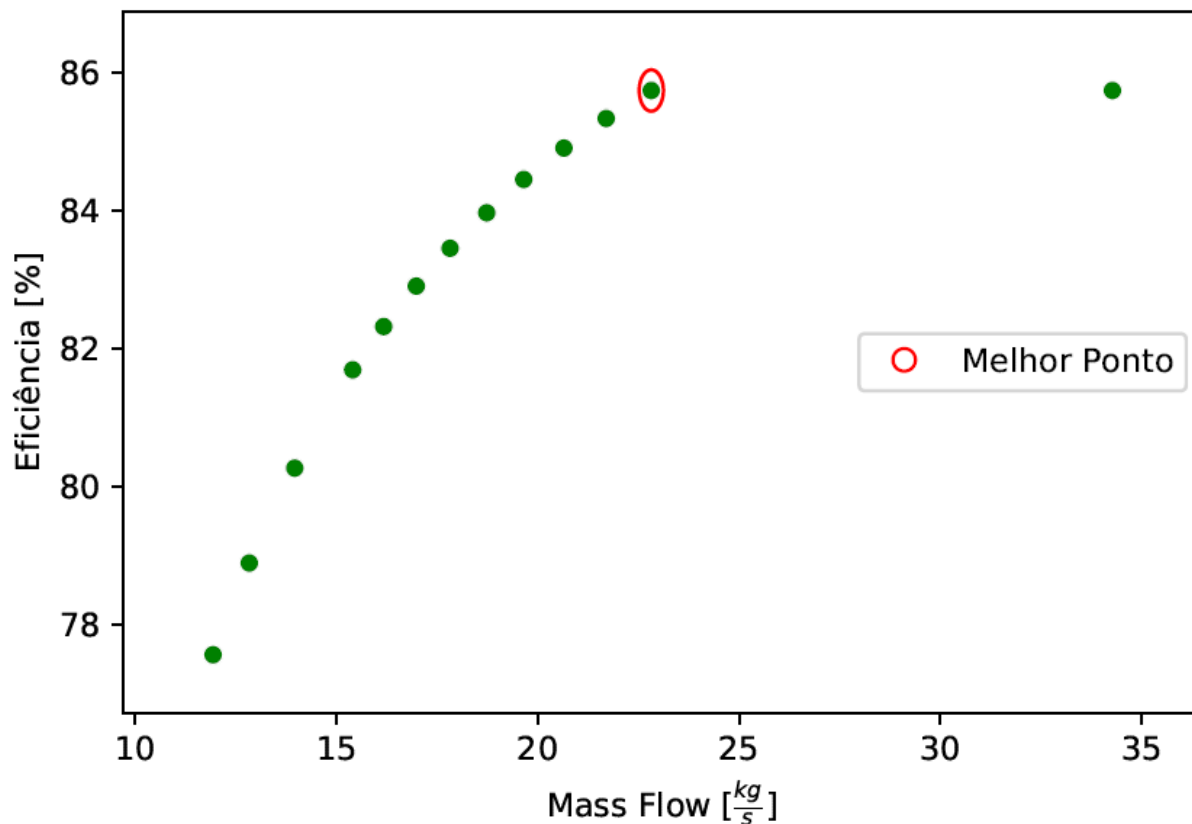


Fonte: Elaborado pelo autor no COLABORATORY, n.d.

As variáveis independentes mais expressivas no equacionamento do modelo árvore de decisão no primeiro trocador de calor são respectivamente: Vazão mássica de entrada da cerveja (45,88%), temperatura de entrada da cerveja (28,57%) e a temperatura de entrada da corrente Etanol (25,54%). Ou seja, já era esperado que variáveis no que concerne a pressão das correntes não influenciassem no cálculo do modelo, o que justifica as equações 02 e 03.

Por fim, utilizando-se a equação 06 realizou-se análise referente ao comportamento da Eficiência do primeiro trocador de calor (Figuras 14), a partir da variação da variável vazão mássica da corrente Etanol predita pelo modelo.

**Figura 14** - Vazão Mássica de Entrada da Corrente Etanol predita versus Eficiência do 1º Trocador de Calor.



Fonte: Elaborado pelo autor no COLABORATORY, n.d.

Observa-se na figura 14, que o aumento da eficiência com a variável modificada, assim, apresentando boa correlação. Nota-se que a eficiência se estabiliza e torna-se máxima a partir de 85,74% para uma vazão mássica de  $22,82 \frac{kg}{s}$ .

Com base nisso, foi averiguado quais seriam os valores das variáveis independentes e dependentes para obter a melhor eficiência do primeiro trocador de calor (Tabela 12).



**Tabela 12** - Dados do primeiro trocador de calor para uma ótima eficiência.

Nome da Corrente	Unidade	Valores
1 – Cerveja In – <i>Mass Flow</i>	$\frac{kg}{s}$	8,84
1 – Cerveja In – <i>Temperature</i>	°C	17,87
1 – Cerveja In – <i>Pressure</i>	$\frac{kgf}{cm^2}$	2,99
Cerveja Out – <i>Temperature</i>	°C	5,47
Cerveja Out – <i>Pressure</i>	$\frac{kgf}{cm^2}$	3,04
1 – Etanol In – <i>Temperature</i>	°C	3,41
1 – Etanol In – <i>Pressure</i>	$\frac{kgf}{cm^2}$	2,66
1 – Etanol Out – <i>Temperature</i>	°C	8,50
1 – Etanol Out – <i>Pressure</i>	$\frac{kgf}{cm^2}$	1,42
1 – Etanol Out – <i>Mass Flow</i>	$\frac{kg}{s}$	22,82
<b>Coefficiente Global de Transferência de Calor</b>	$\frac{kJ}{h \times m^2 \times C}$	3216
<b>Eficiência</b>	–	85,74

Fonte: Elaborado pelo autor no COLABORATORY, n.d.

Identifica-se que o coeficiente global de transferência de calor foi de  $3216 \frac{kJ}{h \times m^2 \times C}$ , porém nas análises não houve alteração para quais quer mudanças nas variáveis, segundo o qual Perry diz que em muitos casos práticos, é possível calcular um coeficiente global médio constante ( $U_{om}$ ) a partir da equação 09 (PERRY,2014).

#### 4.1.2 Análise da Seção do Segundo Trocador de Calor.

Nesta seção, os modelos aplicados na predição da vazão mássica da corrente Etanol serão sobre o segundo trocador de calor, com fundamento na vazão real da corrente de etanol (Figura 15). Ao qual valida-se os modelos exibindo os coeficientes de determinação de treino e de teste conforme a Tabela 13. Bem como, a Tabela 14 demonstrando os coeficientes de determinação calculados na validação cruzada e consigo a média deles para cada modelo.

**Tabela 13** - Coeficiente de determinação de treino e de teste dos modelos preditivos para vazão de etanol no 2º trocador de calor.

	Coeficientes de determinação	
	Treino	Teste
<b>Regressão Linear</b>	0,888	0,887
<b>Regressão MLP</b>	0,999	0,999
<b>Árvore de decisão</b>	1,000	1,000

Fonte: Elaborado pelo autor.

**Tabela 14** - Coeficientes de validação cruzada dos modelos preditivos para vazão de etanol no 2º trocador de calor.

	Coeficiente de determinação				
	1	2	3	4	Médio
<b>Regressão Linear</b>	0,888	0,888	0,889	0,887	0,888
<b>Regressão MLP</b>	0,996	0,999	0,999	0,999	0,998
<b>Árvore de Decisão</b>	1,000	1,000	1,000	1,000	1,000

Fonte: Elaborado pelo autor.

Nos dois métodos de abordagem para calcular o coeficiente de determinação chega-se como melhor modelo, a árvore de decisão. Em vista do seu valor ser igual a 1 em ambos os casos, e assim se ajustar perfeitamente ao processo. Aprofundado neste resultado também pode-se averiguar que o modelo não está enviesado, devido a sua constância no valor do coeficiente de determinação.

Assim como na primeira seção, foi calculado o desvio e erro quadrático médio dos modelos, identificados na Tabela 15, a seguir:

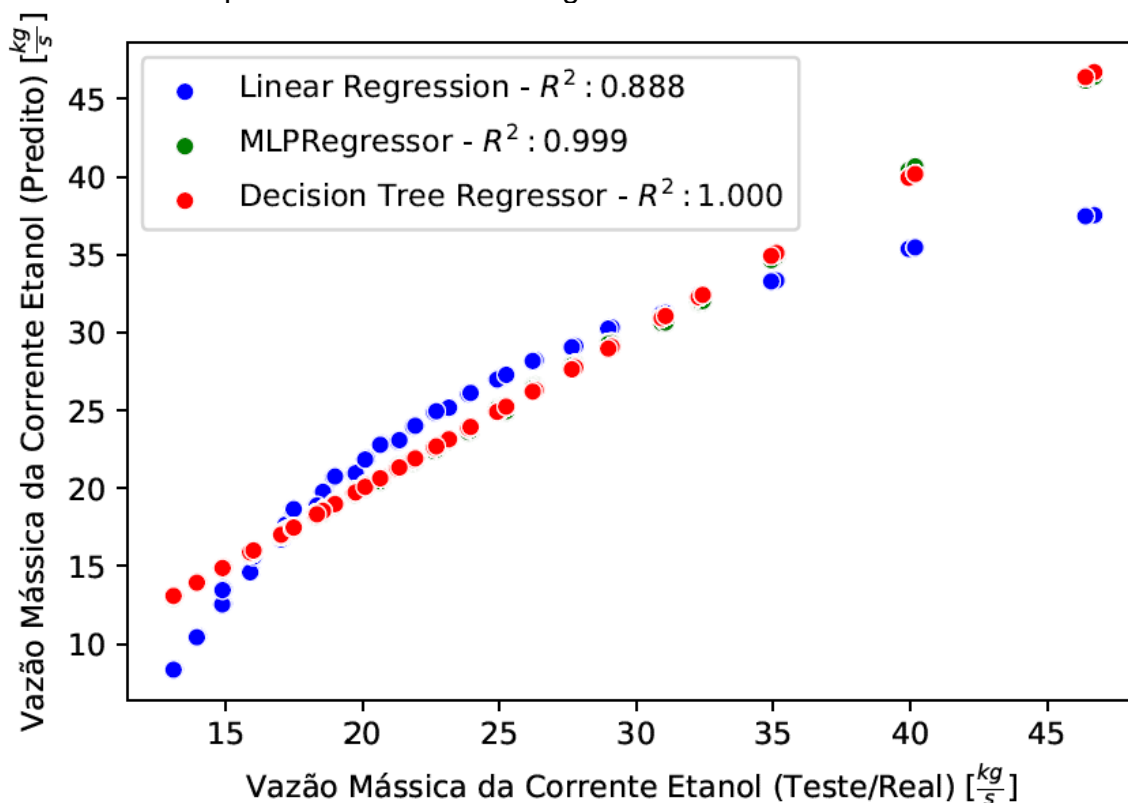
**Tabela 15** – Desvio Padrão e Erro Quadrático Médio dos Modelos no 2.º Trocador de Calor.

	Desvio Padrão	Erro Quadrático Médio
<b>Regressão Linear</b>	$7,33 \times 10^{-04}$	6,72
<b>Regressão MLP</b>	$1,19 \times 10^{-03}$	$1,10 \times 10^{-02}$
<b>Árvore de Decisão</b>	0	$8,54 \times 10^{-26}$

Fonte: Elaborado pelo autor.

O desvio padrão aponta alto grau de uniformidade dos dados para o modelo árvore de decisão, em razão do valor ser igual a zero. Enquanto a validação por meio do resíduo (ou erro) verifica-se baixo valor de  $8,54 \times 10^{-26}$ , avantejando-se entre os modelos de regressão linear e regressão MLP.

**Figura 15** - Vazão real *versus* vazão predita da corrente Etanol no 2º primeiro trocador de calor para cada modelo de regressão.



Fonte: Elaborado pelo autor no COLABORATORY, n.d.

O modelo *perceptron* múltiplas camadas e árvore de decisão tiveram desempenhos semelhantes em todas seções da Figura 15, na previsão da corrente Etanol no segundo trocador de calor, o que explica a proximidade dos valores para os coeficientes de determinação, 0,999 e 1,000, respectivamente. Divergindo do modelo de regressão linear na fase inicial e final, cujo o desvio é maior em referência aos dados reais/teste.

Vale notar o baixo esforço computacional observado para treinar o modelo de árvore de decisão (Tabela 16), assim como observado no primeiro trocador de calor. Enquanto, a regressão MLP apresenta um maior tempo de treinamento.


**Tabela 16** - Tempo de treinamento dos modelos para predição da corrente mássica de etanol no 2º Trocador de calor.

<b>Modelos</b>	<b>Tempo</b>
<b>Regressão Linear</b>	00 min 00,16 seg
<b>Regressão MLP</b>	06 min 36,33 seg
<b>Árvore de Decisão</b>	00 min 0,38 seg

Fonte: Elaborado pelo autor no COLABORATORY, n.d.

Uma análise mais relacionada no que concerne ao modelo árvore de decisão na predição da vazão da corrente de etanol situa-se na Figura 16, na medida em que, nota-se o grau de importância das variáveis de entrada em percentagem.

**Figura 16** - Principais Variáveis do Modelo Árvore de Decisão no 2º Trocador de calor.



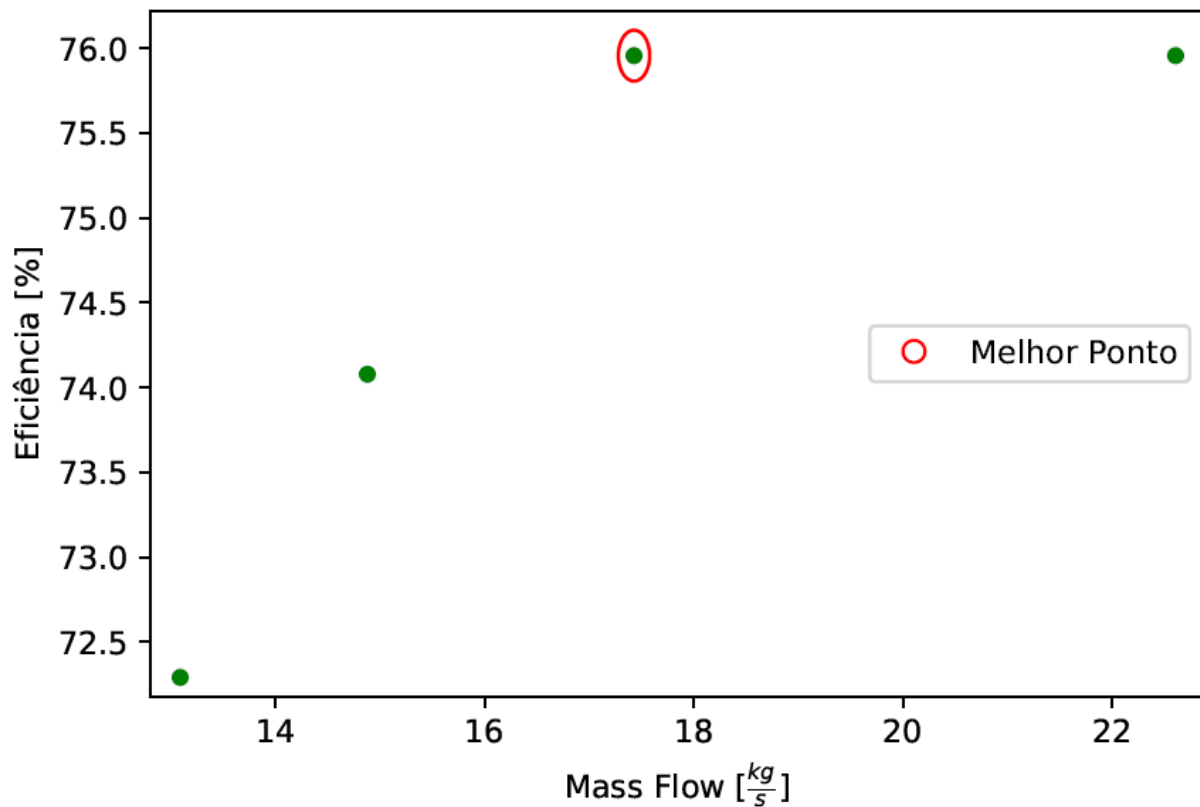
Fonte: Elaborado pelo autor no *COLABORATORY*, n.d.

A vazão mássica da cerveja na entrada e temperatura de entrada da corrente Etanol têm os valores respectivos à 64,60 e 35,39%. Cujo os resultados nos dizem as variáveis independentes mais relevantes na modelagem da árvore de decisão no segundo trocador de calor.

Vale salientar que a vazão mássica da cerveja permanece constante desde a entrada do primeiro trocador até a saída do segundo. Além da variável no que concerne a pressão das correntes poderem ser consideradas desprezíveis no cálculo do modelo.

Finalmente, sucedeu-se análise relacionando ao comportamento da eficiência no segundo trocador de calor (Figuras 17), baseado na variação da variável vazão mássica da corrente Etanol na predição do modelo.

**Figura 17** - Vazão Mássica de Entrada da Corrente Etanol predita versus Eficiência do 2º Trocador de Calor.



Fonte: Elaborado pelo autor no COLABORATORY, n.d.

A eficiência do segundo trocador de calor foi de 75,96% para uma taxa de fluxo mássico de  $17,43 \frac{kg}{s}$ , assim sendo menor quando comparada com a eficiência energética no primeiro trocador de calor. No entanto, tem-se vantagem em gastar menor vazão mássica do fluido refrigerante.

Segundo ao qual foi determinado quais seriam os valores das variáveis independentes e dependentes, a fim de maximizar a eficiência do segundo trocador de calor (Tabela 17).

**Tabela 17** - Dados do segundo trocador de calor para uma ótima eficiência.

<b>Nome da Corrente</b>	<b>Unidade</b>	<b>Valores</b>
1 – Cerveja In – <i>Mass Flow</i>	$\frac{kg}{s}$	8,84
*Cerveja Out – <i>Temperature</i>	°C	5,47
*Cerveja Out – <i>Pressure</i>	$\frac{kgf}{cm^2}$	3,04
2 – Cerveja Out – <i>Temperature</i>	°C	-0,52
2 – Cerveja Out – <i>Pressure</i>	$\frac{kgf}{cm^2}$	2,23
2 – Etanol In – <i>Temperature</i>	°C	-2,42
2 – Etanol In – <i>Pressure</i>	$\frac{kgf}{cm^2}$	4,40
2 – Etanol Out – <i>Temperature</i>	°C	0,79
2 – Etanol Out – <i>Pressure</i>	$\frac{kgf}{cm^2}$	1,86
2 – Etanol Out – <i>Mass Flow</i>	$\frac{kg}{s}$	17,43
<b>Coefficiente Global de Transferência de Calor</b>	$\frac{kJ}{h \times m^2 \times C}$	4378
<b>Eficiência</b>	–	75,96

Fonte: Elaborado pelo autor no COLABORATORY, n.d.

\* Cerveja Out - É a corrente de cerveja que conecta a saída do primeiro trocador, com a entrada do segundo trocado.

A vazão mássica da cerveja permanece constante como já abordado anteriormente, porém poderia haver melhor eficiência energética dos trocadores de calor para uma dada vazão de cerveja. Felizmente, repara-se o mesmo fluxo de  $8,84 \frac{kg}{s}$  para ambos trocadores.

Deve-se notar que o coeficiente global de transferência de calor foi de  $4378 \frac{kJ}{h \times m^2 \times C}$ , mas não houve alteração perceptíveis nas análises para quaisquer alterações nas variáveis, como também foi observado no primeiro trocador de calor.

## 5 CONCLUSÕES

Este trabalho teve como objetivo simular um caso presente na cervejaria (AMBEV); os trocadores de calor tipo placas no software *Aspen HYSYS®*. Tal como prever e analisar a vazão mássica da corrente Etanol, através de modelos *machine learning* de aprendizagem supervisionada realizados no *google colab*. Além de descobrir ponto de maximização da eficiência energética para cada um dos trocadores.

A relevância deste estudo é encontrar um modelo com tempo de resposta instantâneo na operação de resfriamento da cerveja pelo fluido refrigerante (etanol + água), assim o controle de operação torna-se automático (sem supervisão de um operador)

A análise do modelo árvore de decisão revelou resultados excepcionais no primeiro e segundo trocador de calor, com os coeficientes de determinação iguais à 1, afora validação do modelo utilizando desvio ( $1,92 \times 10^{-08}$  e 0, na devida ordem dos trocadores) e erro quadrático médio ( $1,47 \times 10^{-06}$  e  $8,54 \times 10^{-26}$ ) baixíssimos. E obtenção de valores rápidos no período de efetuar operações matemáticas em 0,68 e 0,38 segundos, respectivamente. Podendo ser confirmado neste estudo como o melhor modelo de predição da vazão mássica da corrente Etanol.

Finalmente, buscou-se também saber a melhor eficiência energética para o 1º e 2º trocador de calor tipo placas: chegando-se em 85,74 e 75,96%, de modo respectivo. Ao qual se encontrou valores das variáveis independente e dependente tornando-se o *setpoint* das correntes.

Sendo assim, os objetivos deste trabalho foram alcançados, sugere-se nos estudos futuros a implementação e monitoramento do modelo de árvore de decisão na cervejaria. Quanto ao modelo MLP recomenda-se passar por ajuste de hiperparâmetros para se sair melhor. E também propõe-se ampliar a variação dos dados de entrada no sistema.



## REFERÊNCIAS BIBLIOGRÁFICAS

AQUARONE, E.; LIMA, U.A.; BORZANI, W. Biotecnologia: alimentos e bebidas produzidos por fermentação. v. 5. São Paulo: Edgard Blucher, 1983.

ARAÚJO, H. S., Leite, M. A., & Paula, A. R. V. Cerveja e sociedade. **Revista de Comportamento, Cultura e Sociedade**, 2016, v.4, p. 85-91. Disponível em: < 73\_C A\_artigo\_revisado.pdf (senac.br) >. Acesso em: 15 de maio de 2022.

ASPEN TECHNOLOGY, INC. **Aspen HYSYS® V10.0**, n.d. Disponível em:< <https://www.aspentech.com/en/solutions/artificial-intelligence-of-things>> Acesso em: 19 de jul. de 2022.

ASPEN TECHNOLOGY, INC. **Aspen HYSYS® Unit Operations Guide**. Burlington, MA, USA , 2011. 1728 p.

ASPEN TECHNOLOGY, INC. **Jump Start: Aspen HYSYS® V10.0**. Burlington, MA, USA, 2013. 27 p.

BENZE, Rafael Viana. Modelagem matemática do processo térmico contínuo de alimentos líquidos em trocadores de calor a placas. Dissertação (Mestrado em Engenharia Química) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2013.

BERTO, M. I. Modelagem matemática e simulação dinâmica de trocadores de calor de placas para o resfriamento de sucos de laranja natural e concentrado. Dissertação (Mestrado em Engenharia de Alimentos) – Universidade Federal de Campinas, Campinas, 2000.

BIANCHI, A. L. (2020). **Engenharia de features e dados: como ter um aprendizado de máquina eficiente**. Viceri. Disponível em: <<https://www.viceri.com.br/insights/engenharia-de-features-e-dados-como-ter-um-aprendizado-de-maquina-eficiente>> Acesso em: 21 de ago. de 2022.

BONFIM-ROCHA, Lucas & Silva, Rodrigo & Pavão, Leandro & Yoshi, Henryck. (2017). Projeto de Trocador de Calor em Aspen Hysys® utilizando o método "Rigorous Shell and Tube ".

BRASIL. **Engarrafador moderno**, São Paulo, n.134, p.34-40, 2005.

BROWNLEE, J. (2019). **A Gentle Introduction to the Bootstrap Method. Machine Learning Mastery**. Disponível em: < <https://machinelearningmastery.com/a-gentle-introduction-to-the-bootstrap-method/>> Acesso em: 22 de ago. de 2022.

BROWNLEE, J. (2020). **How to Calculate Feature Importance With Python. Machine Learning Mastery**. Disponível em: < <https://machinelearningmastery.com/calculate-feature-importance-with-python/>> Acesso em: 28 de ago. de 2022.

CARRANÇA, Thais. Cerveja: por que bebida vai ficar mais cara em 2022 com a guerra na Ucrânia. **BBC News Brasil**, 2022. Disponível em: < <https://www.bbc.com/portuguese/brasil-60866162>>. Acesso em: 16 de abr. de 2022.

CERVBRASIL. **Mercado Cervejeiro**, 2017. Disponível em:< <http://www.cervbrasil.org.br/paginas/?page=mercado-ERVEJEIRO-03>>. Acesso em: 17 de abr. de 2022.

CERVESIA – Soluções em tecnologia cervejeira e gestão de processos. A cerveja e sua história. Disponível em: <<http://www.cervesia.com.br/historia-da-cerveja/76-a-cerveja-e-sua-historia.html>>. Acesso em: 15 maio de 2022.

CETESB - COMPANHIA DE TECNOLOGIA DE SANEAMENTO AMBIENTAL, Cervejas e Refrigerantes, 2005. Disponível em: < [https://cetesb.sp.gov.br/consumosustentavel/wp-content/uploads/sites/20/2013/11/cervejas\\_refrigerantes.pdf](https://cetesb.sp.gov.br/consumosustentavel/wp-content/uploads/sites/20/2013/11/cervejas_refrigerantes.pdf)>. Acesso em: 17 maio de 2022.

COLABORATORY. (n.d.). Google. Disponível em: < [https://colab.research.google.com/notebooks/intro.ipynb?utm\\_source=scsindex#recent=true](https://colab.research.google.com/notebooks/intro.ipynb?utm_source=scsindex#recent=true)>. Acesso em: 19 jul de 2022.

COMBINACIÓN Exitosa. *Brewing and Beverage Industry Español*, **Mindelhein**, n. 3, p. 40-47, 2005.

DE KEUKELERIE, D. Fundamentals of beer and hop chemistry. *Química Nova*, n. 23, p. 108-112, 2000.

FIA, BUSINESS SCHOOL, 2021. *Machine Learning*: como funciona, benefícios, tipos e exemplos. Disponível em: < <https://fia.com.br/blog/machine-learning/#:~:text=%C3%89%20para%20isso%20que%20serve,de%20forma%20autom%C3%A1tica%20e%20r%C3%A1pida.> >. Acesso em: 23 de sep de 2022.

FORTMANN-ROE, S. *Understanding the Bias-Variance Tradeoff*, 2012. Disponível em: < <https://scott.fortmann-roe.com/docs/BiasVariance.html>>. Acesso em: 03 maio de 2022.

GOUVEIA, R. Desvio Padrão, **Toda Matéria**, n.d. Disponível em: < <https://www.todamateria.com.br/desvio-padrao/>>. Acesso em: 30 de Jul de 2022.

GUPTA, N. (2013). *Artificial Neural Network* (Vol. 3).

GUT, J. A. W.; PINTO, K. M. *Modeling of plate heat exchangers with generalized configurations*. *International Journal of Heat and Mass Transfer*, 2003.

HUGHES, G. Cerveja Feita em Casa: Tudo sobre os ingredientes, os equipamentos e as técnicas para produzir a bebida em vários estilos. **Publifolha**. 1 ed. São Paulo, 2014.

INCROPERA, F. P. & WITT, D. P., **Fundamentos de Transferência de Calor e de Massa**, terceira edição, 1998.

KAYRI, M., Kayri, I., & Gencoglu, M. T. (2017). ***The performance comparison of Multiple Linear Regression, Random Forest and Artificial Neural Network by using photovoltaic and atmospheric data.*** 2017 14th International Conference on Engineering of Modern Electric Systems, EMES 2017, 1–4. Disponível em: <<https://doi.org/10.1109/EMES.2017.7980368>>. Acesso em: 23 de ago de 2022.

KELVION, 2022. TROCADORES DE CALOR PARA APLICAÇÕES DE CERVEJARIA, Disponível em: <<https://www.kelvion.com/br/industries/market/cevejarria/>>. Acesso em: 23 de sep de 2022.

KOTSIANTIS, S. B. *Supervised Machine Learning: A Review of Classification Techniques.* ***In Informatica***,2007. (Vol. 31, Issue 1, pp. 249–268). Disponível em: <[https://books.google.com.br/book?s?hl=pt-BR&lr=&id=vLiTXDHr\\_sYC&oi=fnd&pg=PA3&dq=Supervised+Machine+Learning:+A+Review+of+Classification+Techniques&ots=CZpsyZCfl&sig=cfCQIZHPiZ50lyuO\\_Ds6nQgq8X4#v=onepage&q=Supervised%20Machine%20Learning%3A%20A%20Review%20of%20Classification%20Techniques&f=false](https://books.google.com.br/book?s?hl=pt-BR&lr=&id=vLiTXDHr_sYC&oi=fnd&pg=PA3&dq=Supervised+Machine+Learning:+A+Review+of+Classification+Techniques&ots=CZpsyZCfl&sig=cfCQIZHPiZ50lyuO_Ds6nQgq8X4#v=onepage&q=Supervised%20Machine%20Learning%3A%20A%20Review%20of%20Classification%20Techniques&f=false)>. Acesso em: 07 de maio de 2022.

MAINMON, O., & Rokach, L. *The Data Mining and Knowledge Discovery Handbook.* **Springer**,2005. Disponível em: <<https://sci-hub.se/https://doi.org/10.1007/b107408>>. Acesso em: 07 de maio de 2022.

MARR, B. Como usar a inteligência artificial para fazer cerveja. **Forbes**,2019. Disponível em: <<https://forbes.com.br/negocios/2019/02/como-usar-a-inteligencia-artificial-para-fazer-cerveja/#:~:text=A%20intelig%C3%A2ncia%20artificial%20oferece%20um,para%20melhorar%20o%20pr%C3%B3prio%20produto.>> Acesso em: 15 de set de 2022.

MEGA, J. F., Neves, E., & Andrade, C. J. A PRODUÇÃO DA CERVEJA NO BRASIL. Associação Nacional Instituto Hestia de Ciência e Tecnologia, HESTIA,2011. Disponível em: <<http://www.hestia.org.br/wp-content/uploads/2012/07/CITINOAno1V01N1Port04.pdf>>. Acesso em: 20 de maio de 2022.

MELAKU M., FREESTON D.H.; *Perfomance of plate heat exchangers under single and two-phase flow conditions – experimental results,* **Geothermal Workshop**, 1993.

MIJWEL, M. M. *Artificial Neural Networks Advantages and Disadvantages.* **ResearchGate**, 2018. Disponível em:<<https://www.researchgate.net/publication/323665827>>. Acesso em: 07 de maio de 2022.

MORADO, R. Larousse da Cerveja. **Larousse do Brasil**. 1 ed, São Paulo, 2011.

MOURA, W. (2016). **Resampling: separando os dados entre treino, validação e teste.** Hacking Analytics. Disponível em:<<https://hackinganalytics.com/2016/09/04/resamplingseparando-os-dados-entre-treino-validacao-e-teste/>>. Acesso em: 21 de ago de 2022.

MÜLLER, A. C., & Guido, S. *Introduction to Machine Learning with Python* (D. Schanafelt & Judy McConville (Eds.); 1st ed.). **O'Reilly Média, Inc**, 2017. Disponível em: <[https://doi.org/10.1007/978-3-030-36826-5\\_10](https://doi.org/10.1007/978-3-030-36826-5_10)>. Acesso em: 03 de maio de 2022.

NETO, H.P. Anotações da palestra ministrada em 28/08/2009 na Universidade Federal Rural do Rio de Janeiro (UFRRJ).

OHRI, A. (2022). 10 Popular Regression Algorithms In Machine Learning Of 2022. **Jigsaw Academy**. Disponível em: <<https://www.jigsawacademy.com/popular-regressionalgorithms-ml/>>. Acesso em: 25 de ago. de 2022.

ONODA, M.; EBECKEN, N. Implementação em java de um algoritmo de Árvore de decisão acoplado a um sgbd relacional. In: . [S.l.: s.n.], 2001. p. 55–64

PEDROSA, M. *Machine Learning: aplicações práticas na indústria de petróleo, PetroPET*, 2022. Disponível em: <<http://petropet.uff.br/machine-learning-aplicacoes-praticas-na-industria-de-petroleo/>>. Acesso em: 15 de sep. de 2022.

PENTEADO, K., Métricas de avaliação para séries temporais. **Alura**, 2021. Disponível em: <<https://www.alura.com.br/artigos/metricas-de-avaliacao-para-series-temporais#:~:text=O%20erro%20quadr%C3%A1tico%20m%C3%A9dio%2C%20MSE,desses%20erros%20quadr%C3%A1ticos%20%C3%A9%20calculada.>>. Acesso em: 30 de Jul de 2022.

PERRY, R. H. (2014). **Perry's Chemical Engineers' Handbook (7th Edition 11 Section)**. Disponível em: <<https://imtk.ui.ac.id/wp-content/uploads/2014/02/perrys-handbook-LENGKAP.pdf>>. Acesso em: 29 de ago de 2022.

PERUSSI, R., **Análise do desempenho de trocadores de calor de fluxo cruzado por simulação numérica**. Dissertação de Mestrado em Engenharia Mecânica - Escola de Engenharia de São Carlos (EESC), São Carlos-SP, 2010. Disponível em: <<https://www.teses.usp.br/teses/disponiveis/18/18147/t de-05072013-104947/publico/RonaldoPerussi.pdf>>. Acesso em: 21 de maio de 2022.

REESE, H. *Understanding the differences between AI, machine learning, and deep learning*. pp (1–4), 2017. Disponível em: <<https://www.techrepublic.com/article/understanding-the-differences-between-ai-machine-learning-and-deep-learning/>>. Acesso em: 03 de maio de 2022.

RIBEIRO, W. P. (2018). **O que é árvore de decisão (decision tree)? Exemplos em R**. Ciência&Negócios.Com. Disponível em: <<https://cienciaenegocios.com/o-que-e-arvore-dedecisao-decision-tree-linguagem-r/>>. Acesso em: 24 de ago de 2022.

ROETZEL, W.; DAS, S. K. e LUO, X. *Measurement of the heat Transfer coefficient in plate heat exchangers using a temperature oscillation technique*. **International Journal of Heat and Mass Transfer**, v.37, n.1, p.325-331, 1994.

SANTOS, L. O. Otimização de Trocadores de Calor do Tipo Placas para Microcervejarias. **Universidade Federal da Fronteira Sul**, 2018. disponível em:

<<https://rd.uffs.edu.br/bitstream/prefix/2354/1/SANTOS.pdf>>. Acesso em: 27 de maio de 2022.

SCIKIT-LEARN. *Neural network models (supervised)*. **Multi-layer Perceptron, 2022**. Disponível em: <[https://scikit-learn.org/stable/modules/neural\\_networks\\_supervised.html#mlp-tips](https://scikit-learn.org/stable/modules/neural_networks_supervised.html#mlp-tips)>. Acesso em: 26 de maio de 2022.

SHIN, J., Badgwell, T. A., Liu, K. H., & Lee, J. H. *Reinforcement Learning – Overview of recent progress and implications for process control*. **Computers and Chemical Engineering**, 127, pp( 282–294),2019. Disponível em: <<https://doi.org/10.1016/j.compchemeng.2019.05.029>>. Acesso em: 05 de maio de 2022.

SILVA, M. P., **Controle Preditivo em Rede Aplicado a um Trocador de Casco-Tubos**. Dissertação de Mestrado em Engenharia Elétrica - Universidade Federal de Campina Grande (UFCG), Campina Grande -PB, 2010.

SINDICATO NACIONAL DA INDÚSTRIA DA CERVEJA - SINDICERV. **O setor em números**, 2016. Disponível em: <<https://www.sindicerv.com.br/o-setor-em-numeros/>>. Acesso em: 16 de maio de 2022.

SUTTON, R. S., & Barto, A. G. *Reinforcement Learning: an introduction*. **The MIT Press**,1998. Disponível em: <<https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>>. Acesso em: 06 de maio de 2022.

VASCONCELOS, Yuri. Inovações cervejeiras. **PesquisaFAPESP**,2017. Disponível em: <<https://revistapesquisa.fapesp.br/inovacoes-cervejeiras/>>. Acesso em: 16 de abr. de 2022.

VIEIRA, Mateus Vitor. Utilização de aprendizado supervisionado na predição da demanda de energia no processo de produção de cumeno. **Repositório UFSCar**,2021. Disponível em: <[https://repositorio.ufscar.br/handle/ufscar/14630?locale-attribute=pt\\_BR](https://repositorio.ufscar.br/handle/ufscar/14630?locale-attribute=pt_BR)>. Acesso em: 17 de abr. de 2022.

TSO, G. K. F., & Yau, K. K. W. (2007). **Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks**.

*Energy*, 32(9), 1761–1768. <https://doi.org/10.1016/j.energy.2006.11.010>

TUNCKAYA, Y., & Koklukaya, E. *Comparative analysis and prediction study for effluent gas emissions in a coal-fired thermal power plant using artificial intelligence and statistical tools*. **Journal of the Energy Institute**, 88(2), pp (118–125),2015.

Disponível em: <<https://doi.org/10.1016/j.joei.2014.07.003>>. Acesso em: 06 de maio de 2022.

Wang, S. C. (2003). **Artificial neural network (ANNs)**. In *Interdisciplinary Computing in Java Programming* (pp. 81–100). Kluwer Academic Publishers. Disponível em: [https://doi.org/10.1007/978-3-319-67466-7\\_4](https://doi.org/10.1007/978-3-319-67466-7_4)>. Acesso em: 26 de ago de 2022.

WIKIMEDIA COMMONS. *Plate heat exchanger*,2022. Disponível em: <[https://commons.wikimedia.org/wiki/File:Plate\\_heat\\_exchanger\\_LS.JPG](https://commons.wikimedia.org/wiki/File:Plate_heat_exchanger_LS.JPG)>. Acesso em: 23 de sep de 2022.

WITTEK, P. *Unsupervised Learning. Quantum Machine Learning*, 2014. Pp. 57–62. Disponível em: <<https://doi.org/10.1016/b978-0-12-800953-6.00005-0>>. Acesso em: 05 de maio de 2022.

WUJEK, B., Hall, P., & Günes, F. *Best Practices for Machine Learning Applications* (No. 2360), 2016. Disponível em: <[https://www.lexjansen.com/wuss/2016/154\\_Final\\_Paper\\_PDF.pdf](https://www.lexjansen.com/wuss/2016/154_Final_Paper_PDF.pdf)>. Acesso em: 07 de maio de 2022.

YAN, Y., Borhani, T. N., & Clough, P. T. *Machine Learning Applications in Chemical Engineering. In Machine Learning in Chemistry: The Impact of Artificial Intelligence* (CPI Group, pp. 340–371). **Royal Society of Chemistry**, 2020. Disponível em: <<https://search.ebscohost.com/login.aspx?direct=true&scope=site&db=nlebk&db=nlabk&AN=2577126>><https://public.ebookcentral.proquest.com/choice/publicfullrecord.aspx?p=6317305>><https://doi.org/10.1039/9781839160233>><http://www.vlebooks.com/vleweb/product/>>. Acesso em: 17 de abr. de 2022.

ZAHRAEE, S. M., Khalaji Assadi, M., & Saidur, R. *Application of Artificial Intelligence Methods for Hybrid Energy System Optimization. Renewable and Sustainable Energy Reviews*, 66, pp (617–630). Disponível em: <2016.<https://doi.org/10.1016/j.rser.2016.08.028>>. Acesso em: 06 de maio de 2022.

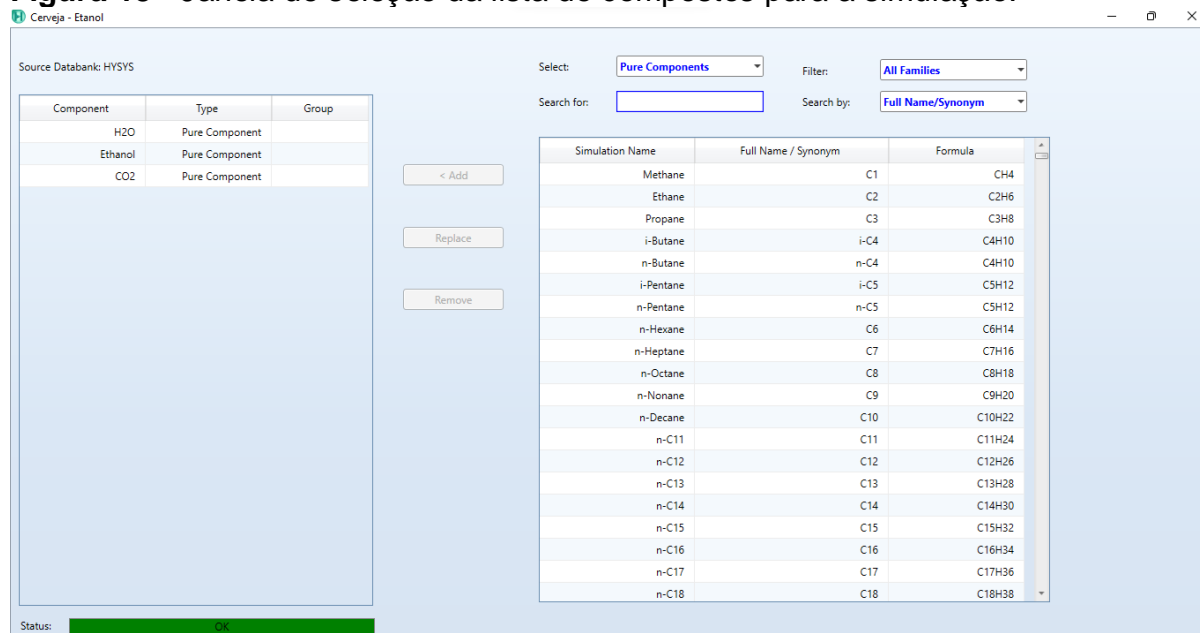
ZHANG, S., Zhang, C., & Yang, Q. (2003). **Data Preparation for Data Mining**. *Appl. Artif. Intel.*, 17(5–6), 375–381. Disponível em: <<https://doi.org/10.1080/08839510390219264>>. Acesso em: 06 de maio de 2022.

## APÊNDICES A – Aspen HYSYS

Ao produzir um novo caso a configuração inicial é fundamental. Selecionando componentes, parâmetros de interação, dado termodinâmico e outras informações necessárias para modelagem. O HYSYS estrutura essas informações em listagens de componentes e pacotes de fluidos (pacotes de dados para cálculo das propriedades termodinâmicas dos fluidos); ambos os grupos são capazes de armazenar separadamente para uso posterior em novos casos.

Primeiramente, consideraremos a seguinte composição da cerveja para consumo e da corrente fria de etanol e água.

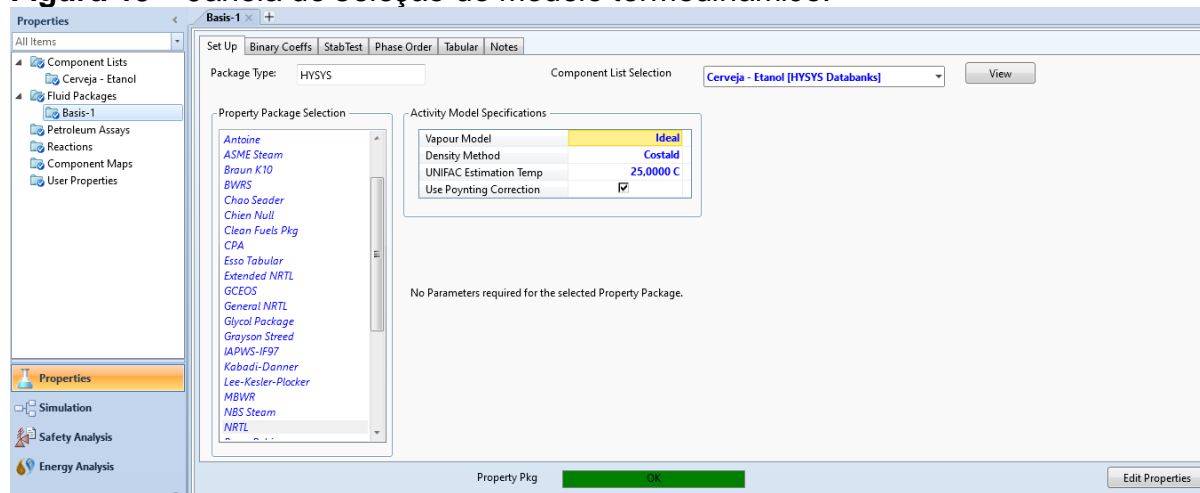
**Figura 18** - Janela de seleção da lista de compostos para a simulação.



Fonte: Elaborado pelo autor no Aspen HYSYS, n.d.

Utilizando o *Property Package Selection Assistant* do Aspen HYSYS (ASPEN TECHNOLOGY, INC., 2013), responde-se algumas questões para escolha do melhor modelo como: o tipo de componente do sistema? Sistema químico, O sistema tem pressão maior do que 10 bar? Não, por fim tem-se duas fases líquidas e assim, a propriedade do pacote selecionado para o cálculo foi *NRTL* (Figura 19).

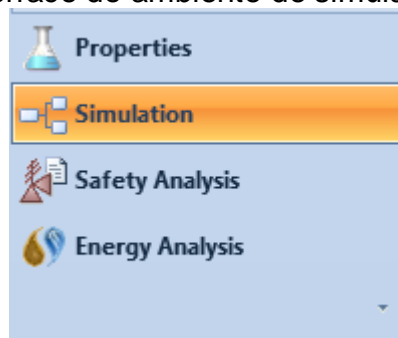
**Figura 19** – Janela de seleção do modelo termodinâmico.



Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

Após seleccionar os compostos presentes para o processo desejado e associá-los a pacotes termodinâmicos para calcular suas propriedades, o caso fica completo com a configuração de suas propriedades. Em seguida, foi acessado o ambiente de simulação (Figura 20).

**Figura 20** – Seleção da interface do ambiente de simulação.



Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

## ACOPLANDO OS FLUIDOS AO TROCADOR DE CALOR

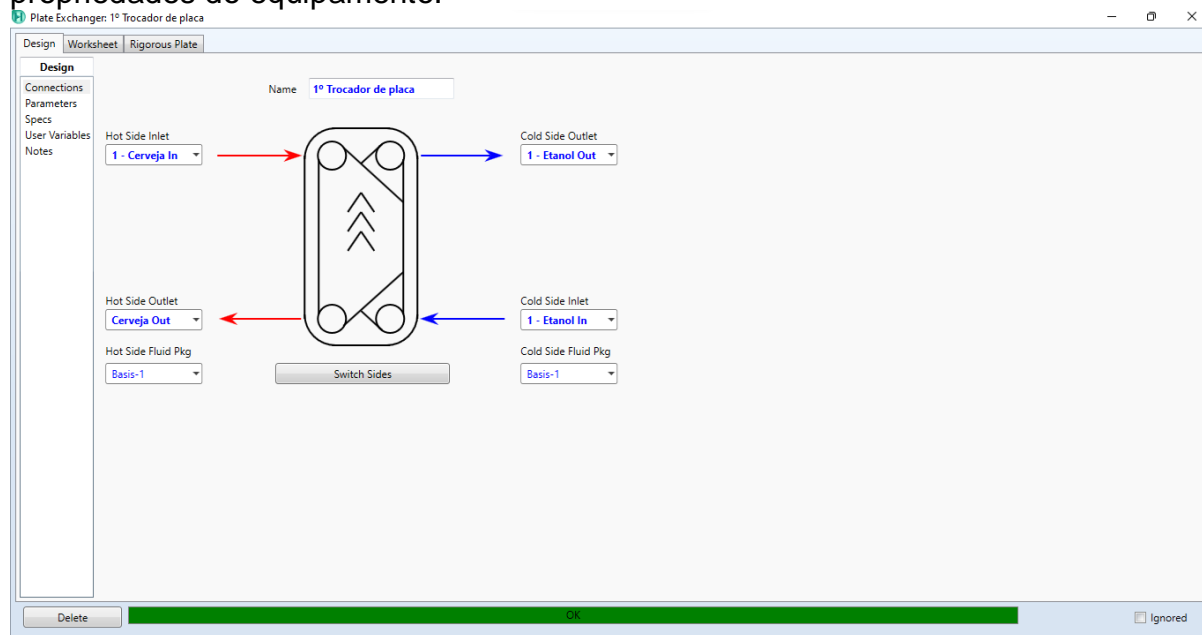
A etapa subsequente é introduzir o bloco *Plate Exchanger* (sob a guia *Model Palette*), entre suas correntes (quente e fria).

Prontamente colocado o equipamento no *Flowsheet* e as correntes materiais, é preciso os conectar. É possível ser realizado de dois modos: O primeiro deles, modificando exatamente nas configurações do equipamento, frequentemente



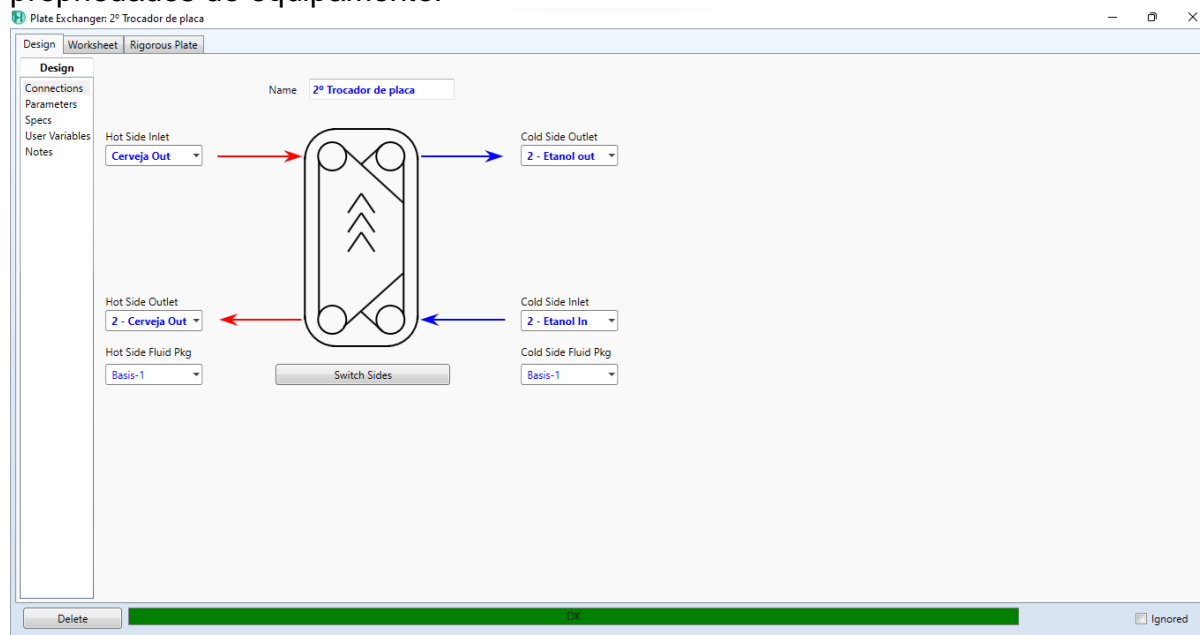
posicionado na aba Design, no interior da opção *Connections*. A aba exibirá logo uma ilustração do equipamento, apontando as entradas e saídas de massa. O usuário pode assim relacionar qualquer uma destas a uma corrente existente no *Flowsheet*. Verifica-se que na janela *Connections* o usuário pode simplesmente definir as correntes materiais que percorrem no lado quente e lado frio (Figura 21 e 22).

**Figura 21** - Conectando correntes do 1º Trocador de calor de placas pela janela de propriedades do equipamento.



Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

**Figura 22** – Conectando correntes 2º Trocador de calor de placas pela janela de propriedades do equipamento.



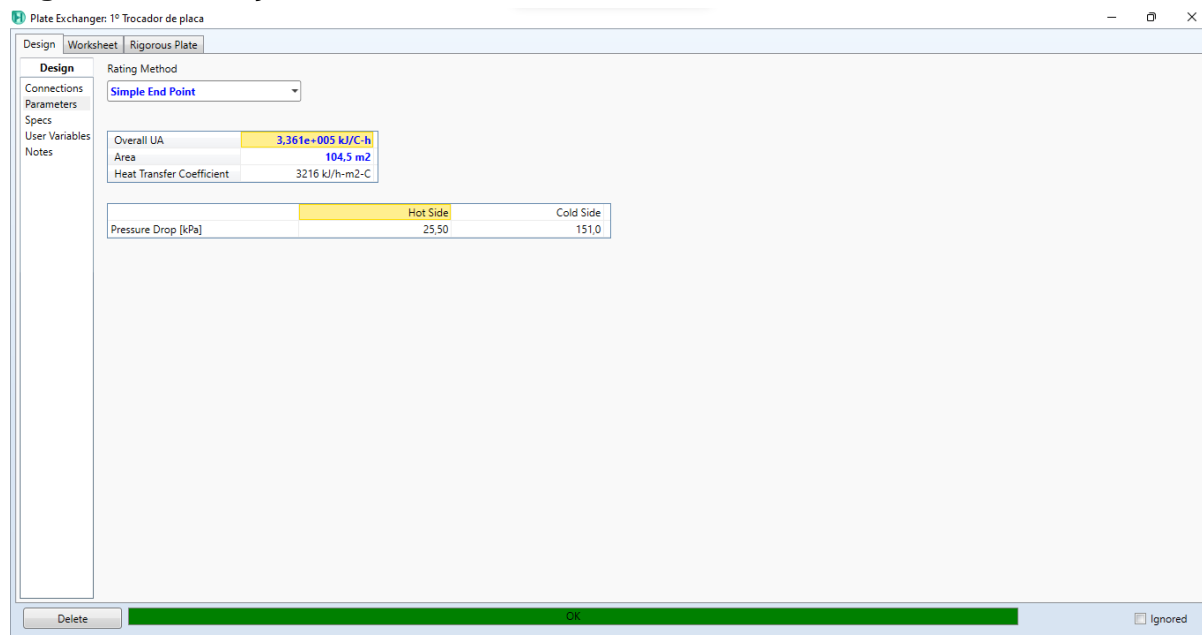
Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

A representação será similar ao da Figura 09 (o ícone do bloco pode ser adaptado para uma melhor ilustração do sistema, podendo ser criado clicando sobre o bloco com o botão direito do mouse na opção *Change Icon*).

## SIMULAÇÃO DO TROCADOR DE PLACAS

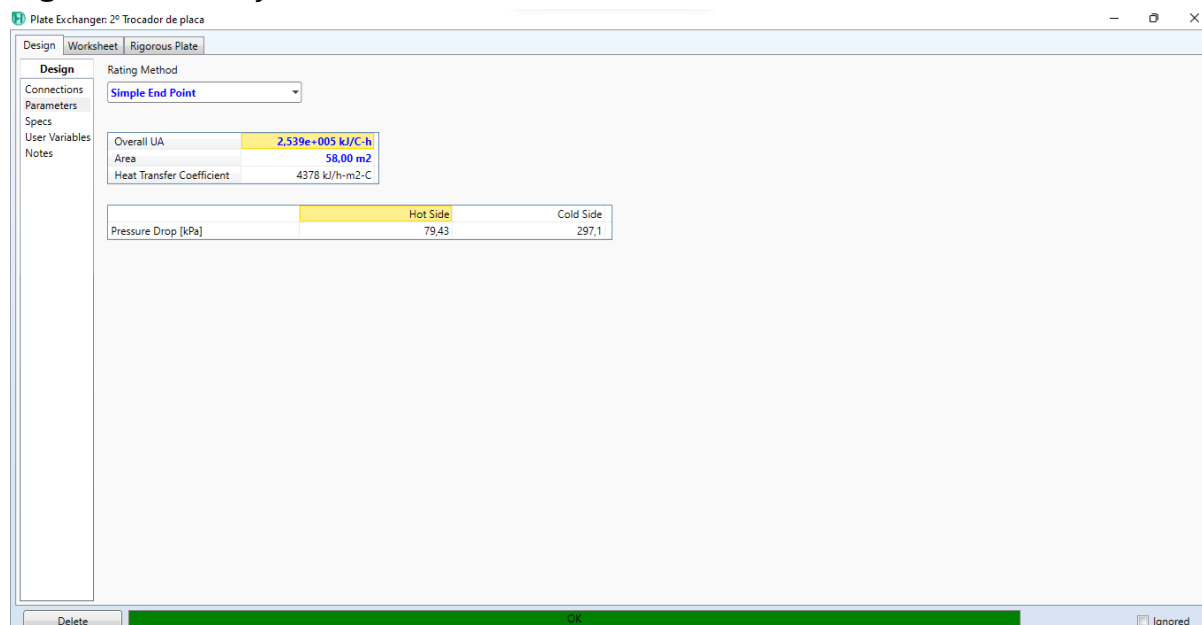
As primordiais informações a serem inseridas nos trocadores de calor serão o modelo (*Simple End Point*) e a área de troca. Isto pode ser definido conectando-se as configurações do trocador, sob a guia *Parameters* (Figura 23 e 24).

**Figura 23** - Inserção dos Parâmetros do 1º Trocador de Calor.



Fonte: Elaborado pelo autor no Aspen HYSYS, n.d.

**Figura 24** - Inserção dos Parâmetros do 2º Trocador de Calor.

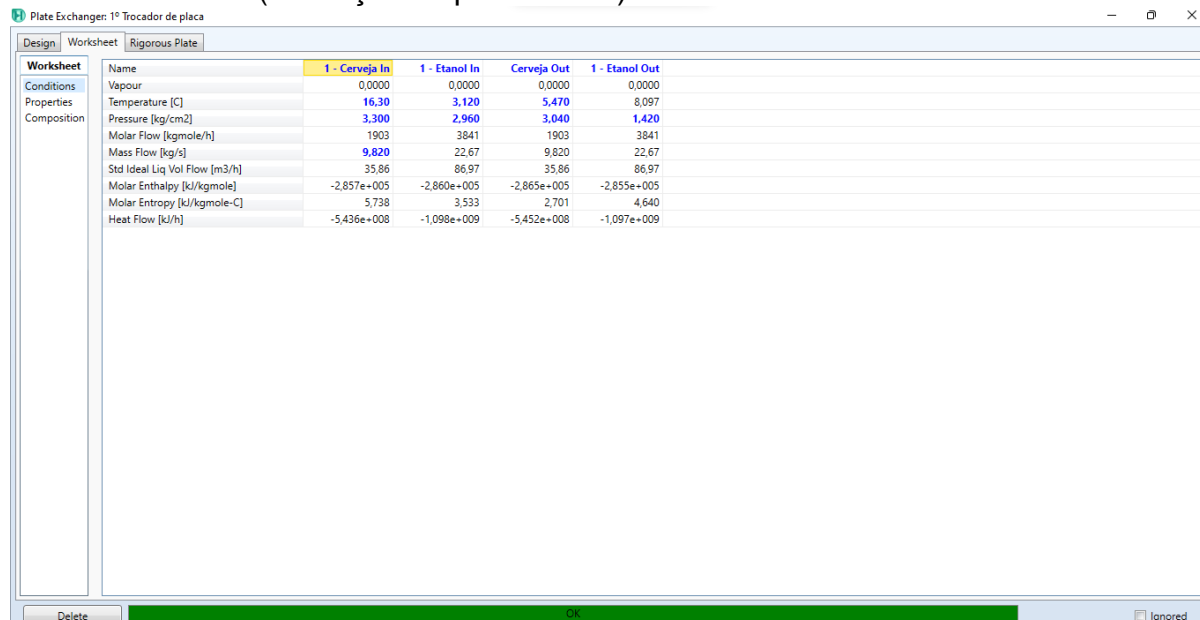


Fonte: Elaborado pelo autor no Aspen HYSYS, n.d.

A próxima etapa é caracterizar o fluxo com os dados proveniente da tabela 01. Em vez de configurá-lo alterando-se os dados de corrente, é mais adequado implementá-lo pelo meio dos segmentos *Conditions* e *Composition* posicionadas na guia *Worksheet* de configuração do trocador de calor. É interessante observar que

espaços sem informações são estimados automaticamente com base nos valores inseridos para as condições de operação do trocador de calor. As Figuras 25,26,27 e 28 mostram essa prática.

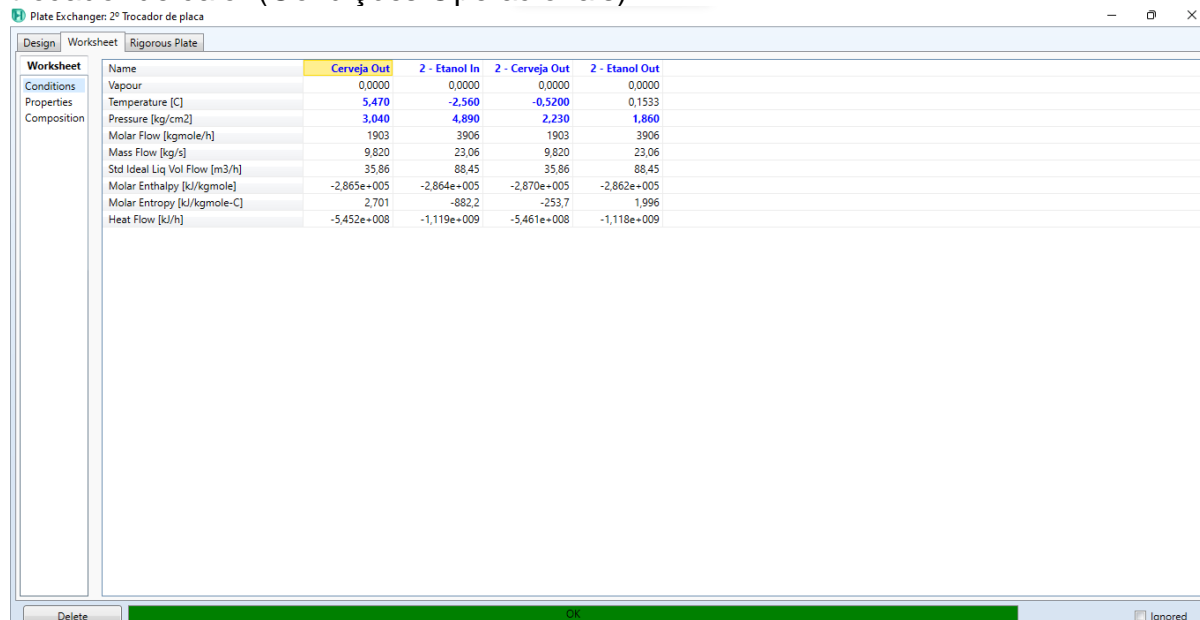
**Figura 25** – Caracterização das correntes materiais de entrada e saída do 1º trocador de calor (Condições Operacionais).



Name	1 - Cerveja In	1 - Etanol In	Cerveja Out	1 - Etanol Out
Vapour	0,0000	0,0000	0,0000	0,0000
Temperature [C]	16,30	3,120	5,470	8,097
Pressure [kg/cm2]	3,300	2,960	3,040	1,420
Molar Flow [kgmole/h]	1903	3841	1903	3841
Mass Flow [kg/s]	9,820	22,67	9,820	22,67
Std Ideal Liq Vol Flow [m3/h]	35,86	86,97	35,86	86,97
Molar Enthalpy [kJ/kgmole]	-2,857e+005	-2,860e+005	-2,865e+005	-2,855e+005
Molar Entropy [kJ/kgmole-C]	5,738	3,533	2,701	4,640
Heat Flow [kJ/h]	-5,436e+008	-1,098e+009	-5,452e+008	-1,097e+009

Fonte: Elaborado pelo autor no Aspen HYSYS, n.d.

**Figura 26** – Caracterização das correntes materiais de entrada e saída do 2º trocador de calor (Condições Operacionais).



Name	Cerveja Out	2 - Etanol In	2 - Cerveja Out	2 - Etanol Out
Vapour	0,0000	0,0000	0,0000	0,0000
Temperature [C]	5,470	-2,560	-0,5200	0,1533
Pressure [kg/cm2]	3,040	4,890	2,230	1,860
Molar Flow [kgmole/h]	1903	3906	1903	3906
Mass Flow [kg/s]	9,820	23,06	9,820	23,06
Std Ideal Liq Vol Flow [m3/h]	35,86	88,45	35,86	88,45
Molar Enthalpy [kJ/kgmole]	-2,865e+005	-2,864e+005	-2,870e+005	-2,862e+005
Molar Entropy [kJ/kgmole-C]	2,701	-882,2	-253,7	1,996
Heat Flow [kJ/h]	-5,452e+008	-1,119e+009	-5,461e+008	-1,118e+009

Fonte: Elaborado pelo autor no Aspen HYSYS.

**Figura 27** – Caracterização das correntes do 1º trocador de calor (Fração molar).

Plate Exchanger: 1º Trocador de placa

		1 - Cerveja In	1 - Etanol In	Cerveja Out	1 - Etanol Out
Conditions	H2O	0,9797	0,8847	0,9797	0,8847
Properties	Ethanol	0,0181	0,1153	0,0181	0,1153
Composition	CO2	0,0021	0,0000	0,0021	0,0000

Delete OK Ignored

Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

**Figura 28** – Caracterização das correntes do 2º trocador de calor (Fração molar).

Plate Exchanger: 2º Trocador de placa

		Cerveja Out	2 - Etanol In	2 - Cerveja Out	2 - Etanol out
Conditions	H2O	0,9797	0,8847	0,9797	0,8847
Properties	Ethanol	0,0181	0,1153	0,0181	0,1153
Composition	CO2	0,0021	0,0000	0,0021	0,0000

Delete OK Ignored

Fonte: Elaborado pelo autor no *Aspen HYSYS*, n.d.

## APÊNDICES B – Código-fonte

```

#Bibliotecas Base
import pandas as pd
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt

#Modelos de busca por melhores parâmetros de modelos
from time import time#contagem de tempo para execução de tarefas
fonte = pd.read_csv('/content/Resultado3.csv',encoding='ISO-8859-1') #Importando
os dados gerados no Aspen HYSYS
dados = fonte #Renomeando as informações para dados
dados=dados.drop(labels=0) # Excluido a primeira linha dos dados, pois não
interessa.
dadosX = dados.drop(['State','1 - Etanol Out - Mass Flow','2 - Etanol Out - Mass
Flow',
                    '2º Trocador de placa - Heat Transfer Coefficient','1 - Etanol Out -
Temperature',
                    '1º Trocador de placa - Heat Transfer Coefficient',
                    '2 - Etanol Out - Temperature',
                    '1 - Cerveja In - Mass Heat Capacity',
                    'Cerveja Out - Mass Heat Capacity',
                    '1 - Etanol In - Mass Heat Capacity',
                    '1 - Etanol Out - Mass Heat Capacity','2 - Etanol In - Mass Heat
Capacity',
                    '2 - Etanol Out - Mass Heat Capacity','2 - Cerveja Out - Mass Heat
Capacity'],
                    axis = 1) # Retirando as features target e features sem qualquer relação
com o calculo.
dados_y1=dados # Transformando os dados em resposta do primeiro trocador.
dados_y2=dados # Transformando os dados em resposta do segundo trocador.
# Transformando os dados target em float: 1.º e 2.º Trocador de calor.

```

```
dados_y1['1 - Etanol Out - Mass Flow']=dados_y1['1 - Etanol Out - Mass
Flow'].astype('float')
dados_y2['2 - Etanol Out - Mass Flow']=dados_y2['2 - Etanol Out - Mass
Flow'].astype('float')
# Quando as informações da feature target para treino.
dados_y1 = dados_y1['1 - Etanol Out - Mass Flow']
dados_y2 = dados_y2['2 - Etanol Out - Mass Flow']
# Transformando as variavel do Coeficiente global de transferência de calor em float
de cada um dos trocadores de calor.
dados_U= dados
dados_U['1º Trocador de placa - Heat Transfer Coefficient']=dados_U['1º Trocador
de placa - Heat Transfer Coefficient'].astype('float')
dados_U['2º Trocador de placa - Heat Transfer Coefficient']=dados_U['2º Trocador
de placa - Heat Transfer Coefficient'].astype('float')
dados_U['1 - Etanol Out - Temperature']=dados_U['1 - Etanol Out -
Temperature'].astype('float')
dados_U['2 - Etanol Out - Temperature']=dados_U['2 - Etanol Out -
Temperature'].astype('float')
dados_U['1 - Cerveja In - Mass Heat Capacity']=dados_U['1 - Cerveja In - Mass Heat
Capacity'].astype('float')
dados_U['Cerveja Out - Mass Heat Capacity']=dados_U['Cerveja Out - Mass Heat
Capacity'].astype('float')
dados_U['1 - Etanol In - Mass Heat Capacity']=dados_U['1 - Etanol In - Mass Heat
Capacity'].astype('float')
dados_U['1 - Etanol Out - Mass Heat Capacity']=dados_U['1 - Etanol Out - Mass
Heat Capacity'].astype('float')
dados_U['2 - Etanol In - Mass Heat Capacity']=dados_U['2 - Etanol In - Mass Heat
Capacity'].astype('float')
dados_U['2 - Etanol Out - Mass Heat Capacity']=dados_U['2 - Etanol Out - Mass
Heat Capacity'].astype('float')
dados_U['2 - Cerveja Out - Mass Heat Capacity']=dados_U['2 - Cerveja Out - Mass
Heat Capacity'].astype('float')
# Selecionando as váriaveis principais para análise do coeficiente global de
transferência de calor.
```

```

dados_U = dados_U[['State','1 - Cerveja In - Mass Flow','1 - Cerveja In -
Temperature',
                    '1 - Cerveja In - Pressure','1 - Etanol In - Pressure','1 - Etanol In -
Temperature',
                    '2 - Etanol In - Pressure','2 - Etanol In - Temperature',
                    '1º Trocador de placa - Heat Transfer Coefficient',
                    '2º Trocador de placa - Heat Transfer Coefficient',
                    '1 - Etanol Out - Temperature',
                    '2 - Etanol Out - Temperature',
                    '1 - Cerveja In - Mass Heat Capacity',
                    'Cerveja Out - Mass Heat Capacity',
                    '1 - Etanol In - Mass Heat Capacity',
                    '1 - Etanol Out - Mass Heat Capacity','2 - Etanol In - Mass Heat
Capacity',
                    '2 - Etanol Out - Mass Heat Capacity','2 - Cerveja Out - Mass Heat
Capacity',
                    '1 - Etanol Out - Mass Flow','2 - Etanol Out - Mass Flow']]
# Transformando os dados da análise do U em float: 1.º e 2.º Trocador de calor.
dados_U['1 - Cerveja In - Mass Flow'] = dados_U['1 - Cerveja In - Mass
Flow'].astype('float')
dados_U['1 - Etanol Out - Mass Flow'] = dados_U['1 - Etanol Out - Mass
Flow'].astype('float')
dados_U['2 - Etanol Out - Mass Flow'] = dados_U['2 - Etanol Out - Mass
Flow'].astype('float')
dados_U['1 - Cerveja In - Temperature'] = dados_U['1 - Cerveja In -
Temperature'].astype('float')
dados_U['1 - Cerveja In - Pressure'] = dados_U['1 - Cerveja In -
Pressure'].astype('float')
dados_U['1 - Etanol In - Pressure'] = dados_U['1 - Etanol In -
Pressure'].astype('float')
dados_U['1 - Etanol In - Temperature'] = dados_U['1 - Etanol In -
Temperature'].astype('float')
dados_U['2 - Etanol In - Temperature'] = dados_U['2 - Etanol In -
Temperature'].astype('float')

```



```

dados_U['2 - Etanol In - Pressure'] = dados_U['2 - Etanol In -
Pressure'].astype('float')
# Verificando a quantidade de linha e colunas da variável dadosX:
dadosX.shape
# Fazendo leitura das informações dos dadosX
dadosX.head()
# Averiguando o tipo ou falta de informações das váriaveis das variveis dadoX:
print("Valores do Conjunto:\n")
print(dadosX.info())
# Transformando as variáveis de entrada em float do 1.º e 2.º Trocador de calor.
dadosX['1 - Cerveja In - Mass Flow'] = dadosX['1 - Cerveja In - Mass
Flow'].astype('float')
dadosX['1 - Cerveja In - Temperature'] = dadosX['1 - Cerveja In -
Temperature'].astype('float')
dadosX['1 - Cerveja In - Pressure'] = dadosX['1 - Cerveja In -
Pressure'].astype('float')
dadosX['1 - Etanol In - Pressure'] = dadosX['1 - Etanol In - Pressure'].astype('float')
dadosX['1 - Etanol In - Temperature'] = dadosX['1 - Etanol In -
Temperature'].astype('float')
dadosX['2 - Etanol In - Temperature'] = dadosX['2 - Etanol In -
Temperature'].astype('float')
dadosX['2 - Etanol In - Pressure'] = dadosX['2 - Etanol In - Pressure'].astype('float')
# Verificando os tipos das variveis novamente:
dadosX.info()
# Importando da biblioteca o train_test_split para separar os dados em treino e
teste.

from sklearn.model_selection import train_test_split
# No qual separou-se 33% para teste e 67% para treino:
X_train, X_test, y_train, y_test = train_test_split( dadosX, dados_y1, test_size=0.33,
random_state=42)
# Verificando a quantidade de linha e colunas das variáveis treino:
X_train.shape, y_train.shape
# Verificando a quantidade de linha e colunas das variáveis teste:

```

```
X_test.shape,y_test.shape
# ignorando warnings da MLP
import warnings
warnings.filterwarnings("ignore")
# Importando os modelos de Regressão Linear, Perceptron Múltiplas Camadas e
Árvore de Decisão.
from sklearn.linear_model import LinearRegression
from sklearn.neural_network import MLPRegressor
from sklearn.tree import DecisionTreeRegressor
# Importando os cálculos para fazer validação cruzada.
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import KFold
# Definindo o número de divisões da validação cruzada.
kfold = KFold(n_splits=4, shuffle=True, random_state=42)
# Importando o Erro Quadrático médio
from sklearn.metrics import mean_squared_error
# conjunto de modelos
models = [LinearRegression(), MLPRegressor(),DecisionTreeRegressor()]
# Lista dos nomes das variáveis importantes.
nome_features = []
# Lista dos valores das variáveis importantes.
import time
features = []
for model in models: # Aplicando em cada modelo as regras.
    inicio = time.time()
    val_scores = cross_val_score(model,X_train, y_train, cv=kfold) # Aplicando ao
modelo uma validação cruzada nos dados de treino.
    nome_modelo = type(model).__name__ # somente para exibição.
    model.fit(X_train, y_train) # Ajustando o modelo de treino.
    Y_pred = model.predict(X_test) # Predizendo a variável target utilizando o dado
de teste.

    if models[0]==model: # Se o modelo é de regressão linear aplica-se essas regras.
```

```

print('Modelo: {} |Valores do Score: {}| Valores dos coeficientes: {} | Intercept: {} |
Média: {} | Desvio: {} | Mean squared error (MSE): {}'.format(nome_modelo,
        val_scores,model.coef_,model.intercept_,np.mean(val_scores),
np.std(val_scores),mean_squared_error(y_test,Y_pred)))

print("Training set score: {}".format(model.score(X_train, y_train))) # Coeficiente
de determinação do treino.

print("Test set score: {}".format(model.score(X_test, y_test))) # Coeficiente de
determinação do test.

media_scores1=np.mean(val_scores) # Média do coeficiente de determinação
dos valores da validação cruzada.

print(sns.scatterplot(y_test,Y_pred,color='blue',
        marker='o',legend='full',alpha=1,
        label= r" Linear Regression -  $R^2$ :
{:.3f}").format(media_scores1)).legend(loc="best"))
        # Plotando o modelo Regressão Linear.

fim = time.time()
tempoRL= fim-inicio

print('\nTempo do modelo de regressão linear: {} seg'.format(tempoRL))

if models[1]==model: # Se o modelo é de Perceptron Múltiplas Camadas aplica-se
essas regras.

print('Modelo: {} |Valores do Score: {} | Média: {} | Desvio: {} | Mean squared error
(MSE): {}'.format(nome_modelo,val_scores,
        np.mean(val_scores),
np.std(val_scores),mean_squared_error(y_test,Y_pred)))

print("Training set score: {}".format(model.score(X_train, y_train))) # Coeficiente
de determinação do treino.

print("Test set score: {}".format(model.score(X_test, y_test))) # Coeficiente de
determinação do test.

media_scores2=np.mean(val_scores) # Média do coeficiente de determinação
dos valores da validação cruzada.

print(sns.scatterplot(y_test,Y_pred,color='green',
        marker='o',legend='full',alpha=1,

```

```

        label= r" MLPRegressor - $R^2:
{:.3f}$".format(media_scores2)).legend(loc="best")
        # Plotando o modelo MLPRegressor.

        fim = time.time()
        tempoMLP= fim-inicio
        print("\nTempo do modelo MLPRegressor: {} seg'.format(tempoMLP))
        if models[2]==model: # Se o modelo é de Árvore de Decisão aplica-se essas
regras.
            print('Modelo: {} |Valores do Score: {}| Valores dos coeficientes: {} | Média: {} |
Desvio: {} | Mean squared error (MSE): {}
'.format(nome_modelo,val_scores,model.feature_importances_,
            np.mean(val_scores),
np.std(val_scores),mean_squared_error(y_test,Y_pred)))
            print("Training set score: {}".format(model.score(X_train, y_train))) # Coeficiente
de determinação do treino.
            print("Test set score: {}".format(model.score(X_test, y_test))) # Coeficiente de
determinação do test.

        for importance, name in sorted(zip(model.feature_importances_,
X_train.columns),reverse=True):
            print (name, importance) # Printando o nome e valores das variáveis
importantes.
            nome_features.append(name) # Guardando na lista dos nomes das variáveis
importantes.
            features.append(importance) # Guardando na lista dos valores das variáveis
importantes.
            media_scores3=np.mean(val_scores) # Média do coeficiente de determinação
dos valores da validação cruzada.
            print(sns.scatterplot(y_test,Y_pred,color='red',
            marker='o',legend='full',alpha=1,
            label= r" Decision Tree Regressor - $R^2:
{:.3f}$".format(media_scores3)).legend(loc="best"))
            # Plotando o modelo árvore de decisão.

        fim = time.time()

```

```

tempoDTR= fim-inicio
print("\nTempo do modelo da arvore de decisao: {} seg'.format(tempoDTR))
plt.xlabel(r'1 - Etanol Out - Mass Flow (Teste/Real) $\frac{\text{kg}}{\text{s}}$') # Nome do eixo
abscissa (x).
plt.ylabel(r'1 - Etanol Out - Mass Flow (Predito) $\frac{\text{kg}}{\text{s}}$') # Nome do eixo
ordenada (y).
plt.savefig('1- Etanol Out - Mass Flow.pdf',
           transparent=True) # Salvando a figura em pdf.
# Transformando os valores das variáveis de grau de importancia do modelo árvore
de decisao em float.
variaveis=[]
for i in list(features):
    v = float('{:.2f}'.format(i*100))
    variaveis.append(v)
variaveis
# Platando o gráfico das variveis importante
fake = pd.DataFrame({'f': variaveis,'g': nome_features}) # Transformando os dados
em DataFrame.
plt.figure(figsize=(8,5)) # Definindo o tamanho da figura.
fig = sns.barplot(x = 'f', y = 'g',data=fake,palette="Set1") # Inserindo os dados do
gráfico em barra.
for py,px in enumerate(variaveis): # Colocando o rótulo no gráfico.
    if px!=0:
        fig.annotate(str(px)+'%',xy=(px,py))
fig.spines['top'].set_visible(False) # Retirando a linha superior da figura.
fig.spines['right'].set_visible(False) # Retirando a linha à direita da figura.
plt.xlabel("Feature_importance [ % ]") # Nome do eixo abscissa (x).
plt.ylabel("Feature") # Nome do eixo ordenada (y).
plt.show(fig)
plt.savefig('1 - Feature_importance.pdf',
           transparent=True) # Salvando a figura em pdf.
# Calculando o cdpMédio do lado quente e do lado frio, para cada um dos
trocadores.

```

```

dados_U['1 - CpmedioQuente'] = (dados_U['1 - Cerveja In - Mass Heat
Capacity']+dados_U['Cerveja Out - Mass Heat Capacity'])/2
dados_U['1 - CpmedioFrio'] = (dados_U['1 - Etanol In - Mass Heat
Capacity']+dados_U['1 - Etanol Out - Mass Heat Capacity'])/2
dados_U['2 - CpmedioQuente'] = (dados_U['Cerveja Out - Mass Heat
Capacity']+dados_U['2 - Cerveja Out - Mass Heat Capacity'])/2
dados_U['2 - CpmedioFrio'] = (dados_U['2 - Etanol In - Mass Heat
Capacity']+dados_U['2 - Etanol Out - Mass Heat Capacity'])/2
dados_U[['1 - CpmedioQuente','1 - CpmedioFrio','2 - CpmedioQuente','2 -
CpmedioFrio']]
# Predizendo a corrente Etanol a partir do modelo árvore de decisão, no primeiro
trocaador de calor.
dados_U['1 - Etanol Out - Mass Flow'] = model.predict(dadosX)
# Calculando do produto minimo da vazão mássica e capacidade calorifica, no
primeiro trocaador de calor.
dados_U['1 - m.CpmedioQuente']=dados_U['1 - CpmedioQuente']*dados_U['1 -
Cerveja In - Mass Flow']
dados_U['1 - m.CpmedioFrio']=dados_U['1 - CpmedioFrio']*dados_U['1 - Etanol Out -
Mass Flow']
dados_U[['1 - m.CpmedioQuente','1 - m.CpmedioFrio']]
# Calculando a taxa de calor trocada (Q) para o primeiro trocaador de calor, no lado
quente e frio.
dados_U['1 - Qquente']=dados_U['1 - m.CpmedioQuente']*(dados_U['1 - Cerveja In -
Temperature']-5.47)
dados_U['1 - Qfrio']=dados_U['1 - m.CpmedioFrio']*(dados_U['1 - Etanol Out -
Temperature']-dados_U['1 - Etanol In - Temperature'])
dados_U[['1 - Qquente','1 - Qfrio']]
# cálculo o delta máximo da temperatura entre as correntes(Tq,e-Tf,e). Para ambos
os trocaadores.
dados_U['1 - deltaTmax']=dados_U['1 - Cerveja In - Temperature']-dados_U['1 -
Etanol In - Temperature']
dados_U['2 - deltaTmax']=5.47-dados_U['2 - Etanol In - Temperature']
dados_U[['1 - deltaTmax','2 - deltaTmax']]
# Calculando a taxa máxima de calor de troca (Qmáx)

```

```

dados_U['1 - dadosQmaxquente'] = dados_U['1 - m.CpmedioQuente']*dados_U['1 -
deltaTmax']
# Calculando a Eficiência(%) do primeiro trocador de calor: E = Q / Qmáx
dados_U['1 - EficiênciaQuente'] = 100*dados_U['1 - Qquente']/dados_U['1 -
dadosQmaxquente']
dados_U['1 - EficiênciaQuente']
# A eficiência com a variação da temperatura do etanol na entrada.
dados_Ue=dados_U.drop_duplicates(subset=['1 - Etanol In - Temperature']) #
Retirando linhas duplicadas da temperatura de etanol.
print(sns.scatterplot('1 - Etanol In - Temperature','1 -
EficiênciaQuente',data=dados_Ue,
                    color='green',marker='o',legend='full',alpha=1))
plt.xlabel(r'Temperature $[^\circ\text{C}]$') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).
plt.savefig('1 - Etanol In - Temperature EFIC.pdf',
            transparent=True) # Salvando a figura em pdf.
# A eficiência com a variação da temperatura da cerveja na entrada.
dados_Ue1=dados_U.drop_duplicates(subset=['1 - Cerveja In - Temperature']) #
Retirando linhas duplicadas da temperatura da cerveja.
print(sns.scatterplot('1 - Cerveja In - Temperature','1 -
EficiênciaQuente',data=dados_Ue1,
                    color='green',marker='o',legend='full',alpha=1))
plt.xlabel(r'Temperature $[^\circ\text{C}]$') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).
plt.savefig('1 - Cerveja In - Temperature EFIC.pdf',
            transparent=True) # Salvando a figura em pdf.
# A eficiência com a variação da vazão mássica do etanol na saída.
dados_Ue2=dados_U.drop_duplicates(subset=['1 - Etanol Out - Mass Flow']) #
Retirando linhas duplicadas da vazão mássica do etanol na saída.
print(sns.scatterplot('1 - Etanol Out - Mass Flow','1 -
EficiênciaQuente',data=dados_Ue2,
                    color='green',marker='o',legend='full',alpha=1))
plt.xlabel(r'Mass Flow $[\frac{\text{kg}}{\text{s}}]$') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).

```

```

plt.savefig('1 - Etanol Out - Mass Flow EFIC.pdf',
           transparent=True) # Salvando a figura em pdf.
# Melhores valores da vazão mássica de etanol no primeiro trocador de calor
combinada com a eficiência.
p=0
mass=[]
efi =[]
for j,k in enumerate(dados_U['1 - EficiênciaQuente']):
    if k>p:
        p=k
        b=dados_Ue2['1 - Etanol Out - Mass Flow'][(1+j)]
        mass.append(b)
        efi.append(k)
        print(b,k,1+j)
# Plotando o gráfico de melhor eficiencia combinado com a vazão mássica de
etanol.
from matplotlib.patches import Circle
from matplotlib.lines import Line2D
print(sns.scatterplot(x=mass,y=efi,
                     color='green',marker='o',legend='full',alpha=1))
plt.xlabel(r'Mass Flow  $[\frac{\text{kg}}{\text{s}}]$ ') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).
plt.gca().margins(0.1)
cir = Circle((22.82, 85.7419444060296),0.3,color='red',lw=1,fill=False,zorder=10)
red_circle = Line2D([], [], marker='o', color='r',
                   markerfacecolor='w',lw=0, markersize=7),
plt.gca().add_patch(cir)
plt.legend([red_circle],[r'Melhor Ponto'],loc='right')
plt.savefig('1 - Etanol Out - Mass Flow EFIC.pdf',
           transparent=True) # Salvando a figura em pdf.
# Descrição das correntes no melhor ponto de eficiência, no primeiro trocador de
calor.
dados_Ue2[['1 - Cerveja In - Mass Flow','1 - Cerveja In - Temperature','1 - Cerveja In
- Pressure','1 - Etanol In - Temperature',

```



```

'1 - Etanol In - Pressure','1º Trocador de placa - Heat Transfer Coefficient',
'1 - Etanol Out - Temperature','1 - Etanol Out - Mass Flow','1 -
EficiênciaQuente']].loc[8083:8083]
# Separando os dados em treino e teste, no qual separou-se 33% para teste e 67%
para treino:
x_train, x_test, Y_train, Y_test = train_test_split( dadosX, dados_y2, test_size=0.33,
random_state=42)
# conjunto de modelos
models1 = [LinearRegression(), MLPRegressor(),DecisionTreeRegressor()]
kfold = KFold(n_splits=4, shuffle=True, random_state=42)
# Lista dos nomes das variáveis importantes.
nome_features2 = []
# Lista dos valores das variáveis importantes.
features2 = []
for model2 in models1: # Aplicando em cada modelo as regras.
    inicio = time.time()
    val_scores = cross_val_score(model2,x_train, Y_train, cv=kfold) # Aplicando ao
modelo uma validação cruzada nos dados de treino.
    nome_modelo = type(model2).__name__ # Somente para exibição.
    model2.fit(x_train, Y_train) # Ajustando o modelo de treino.
    y_pred = model2.predict(x_test) # Predizendo a variável target utilizando o dado
de teste.
    if models1[0]==model2: # Se o modelo é de regressão linear aplica-se essas
regras.
        print('Modelo: {} |Valores do Score: {}|Valores dos coeficientes: {} |Intercept: {} |
Média: {} | Desvio: {} | Mean squared error (MSE): {}
'.format(nome_modelo,val_scores,model2.coef_,model2.intercept_,
np.mean(val_scores),
np.std(val_scores),mean_squared_error(Y_test,y_pred)))
        print("Training set score: {}".format(model2.score(x_train, Y_train))) # Coeficiente
de determinação do treino.
        print("Test set score: {}".format(model2.score(x_test, Y_test))) # Coeficiente de
determinação do test.

```

```

media_scores4=np.mean(val_scores) # Média do coeficiente de determinação
dos valores da validação cruzada.
print(sns.scatterplot(Y_test,y_pred,color='blue',
                    marker='o',legend='full',alpha=1,
                    label= r"Linear Regression - $R^2:
{:.3f}$".format(media_scores4)).legend(loc="best"))
# Plotando o modelo Regressão Linear.
fim = time.time()
tempoRL= fim-inicio
print("\nTempo do modelo de regressão linear: {} seg'.format(tempoRL))
elif models1[1]==model2: # Se o modelo é de Perceptron Múltiplas Camadas
aplica-se essas regras.
print('Modelo: {} |Valores do Score: {} | Média: {} | Desvio: {} | Mean squared error
(MSE): {}'.format(nome_modelo,val_scores,
                    np.mean(val_scores),
np.std(val_scores),mean_squared_error(Y_test,y_pred)))
print("Training set score: {}".format(model2.score(x_train, Y_train))) # Coeficiente
de determinação do treino.
print("Test set score: {}".format(model2.score(x_test, Y_test)))
media_scores5=np.mean(val_scores) # Média do coeficiente de determinação
dos valores da validação cruzada.
print(sns.scatterplot(Y_test,y_pred,color='green',
                    marker='o',legend='full',alpha=1,
                    label= r"MLPRegressor - $R^2:
{:.3f}$".format(media_scores5)).legend(loc="best"))
# Plotando o modelo MLPRegressor.
fim = time.time()
tempoMLP= fim-inicio
print("\nTempo do modelo MLPRegressor: {} seg'.format(tempoMLP))
elif models1[2]==model2: # Se o modelo é de Árvore de Decisão aplica-se essas
regras.
print('Modelo: {} |Valores do Score: {}|Valores dos coeficientes: {} | Média: {} |
Desvio: {} | Mean squared error (MSE): {}
'.format(nome_modelo,val_scores,model2.feature_importances_,

```

```

        np.mean(val_scores),
np.std(val_scores),mean_squared_error(Y_test,y_pred)))
    print("Training set score: {}".format(model2.score(x_train, Y_train))) # Coeficiente
de determinação do treino.
    print("Test set score: {}".format(model2.score(x_test, Y_test))) # Coeficiente de
determinação do test.
    for importances, names in sorted(zip(model2.feature_importances_,
x_train.columns),reverse=True):
        print (names, importances) # Printando o nome e valores das variáveis
importantes.
        nome_features2.append(names) # Guardando na lista dos nomes das variáveis
importantes.
        features2.append(importances) # Guardando na lista dos valores das variáveis
importantes.
        media_scores6=np.mean(val_scores) # Média do coeficiente de determinação
dos valores da validação cruzada.
        print(sns.scatterplot(Y_test,y_pred,color='red',
            marker='o',legend='full',alpha=1,
            label= r"Decision Tree Regressor -  $R^2$ :
{:.3f}" .format(media_scores6)).legend(loc="best"))
            # Plotando o modelo Árvore de Decisão.
        fim = time.time()
        tempoDTR= fim-inicio
        print("\nTempo do modelo da arvore de decisão: {} seg'.format(tempoDTR))
plt.xlabel(r' $2$  - Etanol Out - Mass Flow (Teste/Real)  $\frac{\text{kg}}{\text{s}}$ ') # Nome do eixo
abscissa (x).
plt.ylabel(r' $2$  - Etanol Out - Mass Flow (Predito)  $\frac{\text{kg}}{\text{s}}$ ') # Nome do eixo
ordenada (y).
plt.savefig('2- Etanol Out - Mass Flow.pdf',
        transparent=True) # Salvando a figura em pdf.
# Transformando os valores das variáveis de grau de importancia do modelo árvore
de decisão em float.
variaveis1=[]
for i in list(features2):

```

```

v = float('{:.2f}'.format(i*100))
variaveis1.append(v)
variaveis1
# Platanando o gráfico das variveis importante
fake2 = pd.DataFrame({'f': variaveis1,'g': nome_features2}) # Transformando os
dados em DataFrame.
plt.figure(figsize=(8,5)) # Definindo o tamanho da figura.
fig = sns.barplot(x = 'f', y = 'g',data=fake2,palette="Set1") # Inserindo os dados do
gráfico em barra.
for pY,pX in enumerate(variaveis1): # Colocando o rótulo no gráfico.
    if pX!=0:
        fig.annotate(str(pX)+'%',xy=(pX,pY))
fig.spines['top'].set_visible(False) # Retirando a linha superior da figura.
fig.spines['right'].set_visible(False) # Retirando a linha à direita da figura.
plt.xlabel("Feature_importance [ % ]") # Nome do eixo abscissa (x).
plt.ylabel("Feature") # Nome do eixo ordenada (y).
plt.show(fig) # Plotando somente a Figura.
plt.savefig('2 - Feature_importance.png',dpi=300,
           transparent=True) # Salvando a figura em png.
# Predizendo a corrente Etanol a partir do modelo árvore de decisão, no segundo
trocador de calor.
dados_U['2 - Etanol Out - Mass Flow'] = model2.predict(dadosX)
# Calculando do produto minimo da vazão mássica e capacidade calorifica, no
segundo trocador de calor.
dados_U['2 - m.CpmedioQuente']=dados_U['2 - CpmedioQuente']*dados_U['1 -
Cerveja In - Mass Flow']
dados_U['2 - m.CpmedioFrio']=dados_U['2 - CpmedioFrio']*dados_U['2 - Etanol Out -
Mass Flow']
#Calculando a taxa de calor trocada (Q) para o segundo trocador de calor, no lado
quente e frio.
dados_U['2 - Qquente']=dados_U['2 - m.CpmedioQuente']*(5.47 - (-0.52))
dados_U['2 - Qfrio']=dados_U['2 - m.CpmedioFrio']*(dados_U['2 - Etanol Out -
Temperature']-dados_U['2 - Etanol In - Temperature'])
# Calculando a taxa máxima de calor de troca (Qmáx)

```

```

dados_U['2 - dadosQmaxquente'] = dados_U['2 - m.CpmedioQuente']*dados_U['2 -
deltaTmax']
# Calculando a Eficiência (%) do segundo trocador de calor: E = Q / Qmáx
dados_U['2 - EficiênciaQuente'] = 100*dados_U['2 - Qquente']/dados_U['2 -
dadosQmaxquente']
dados_U['2 - EficiênciaQuente']
# A eficiência com a variação da temperatura do etanol na entrada.
dados_Ue6=dados_U.drop_duplicates(subset=['2 - Etanol In - Temperature']) #
Retirando linhas duplicadas da temperatura do etanol.
print(sns.scatterplot('2 - Etanol In - Temperature','2 -
EficiênciaQuente',data=dados_Ue6,
                    color='green',marker='o',legend='full',alpha=1))
plt.xlabel(r'Temperature $[^\circ\text{C}]$') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).
plt.savefig('2 - Etanol In - Temperature EFIC.pdf',
            transparent=True) # Salvando a figura em pdf.
# A eficiência com a variação da vazão mássica do etanol na saída.
dados_Ue7=dados_U.drop_duplicates(subset=['2 - Etanol Out - Mass Flow']) #
Retirando linhas duplicadas da vazão mássica do etanol na saída.
print(sns.scatterplot('2 - Etanol Out - Mass Flow','2 -
EficiênciaQuente',data=dados_Ue7,
                    color='green',marker='o',legend='full',alpha=1))
plt.xlabel(r'Mass Flow $\frac{\text{kg}}{\text{s}}$') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).
plt.savefig('2 - Etanol Out - Mass Flow EFIC.pdf',
            transparent=True) # Salvando a figura em pdf.
# Melhores valores da vazão mássica de etanol no primeiro trocador de calor
combinada com a eficiência.
w=0
mass1=[]
efi1 =[]
for r,y in enumerate(dados_U['2 - EficiênciaQuente']):
    if y>w:
        w=y

```

```

b1=dados_Ue7['2 - Etanol Out - Mass Flow'][(1+r)
mass1.append(b1)
efi1.append(w)
print(b1,w,1+r)
# Plotando o gráfico de melhor eficiencia combinado com a vazão mássica de
etanol.
from matplotlib.patches import Circle
fig= sns.scatterplot(x=mass1,y=efi1,
                    color='green',marker='o',legend='full',alpha=1)
#fig.spines['top'].set_visible(False)
plt.xlabel(r'Mass Flow  $[\frac{\text{kg}}{\text{s}}]$ ') # Nome do eixo abscissa (x).
plt.ylabel(r'Eficiência [%]') # Nome do eixo ordenada (y).
plt.gca().margins(0.03)
cir1 =
Circle((17.430000000000206,75.95739284808522),0.15,color='red',lw=1,fill=False,z
order=10)
red_circle1 = Line2D([], [], marker='o', color='r',label='Circle',
                    markerfacecolor='w',lw=0, markersize=7),
plt.gca().add_patch(cir1)
plt.legend([red_circle1],[r'Melhor Ponto'],loc='right')
plt.savefig('2 - Etanol Out - Mass Flow EFIC.pdf',
          transparent=True) # Salvando a figura em pdf.
# Descrição das correntes no melhor ponto de eficiência, no segundo trocador de
calor.
dados_Ue7[['1 - Cerveja In - Mass Flow','2 - Etanol In - Temperature','2 - Etanol In -
Pressure',
          '2º Trocador de placa - Heat Transfer Coefficient','2 - Etanol Out -
Temperature',
          '2 - Etanol Out - Mass Flow','2 - EficiênciaQuente']].loc[5:5]

```

## ANEXO A – Melhor Design: 1° Trocador De Calor


Optimization Path Plate

Optimization Path

Current selected case 2

Item	Passes		Channels		Area ratio	Risk of maldistribution	Total area	Plate Details					Hot Side DP		Cold Side DP		
	Hot side	Cold side	Hot side	Cold side				Chevron angle	Plate area	Port diameter	Horz. port distance	Vert. port distance	Plate	Port	Plate	Port	
1	1	1	1	111	111	1,01	Yes	88,4	30	0,4	100	260	1052,63	0,02723	0,01353	0,13776	0,0795
2	2	1	1	101	101	1,25	No	104,5	30	0,52	100	260	1368,42	0,04191	0,01289	0,21224	0,07573
3	3	1	1	263	263	1,01	Yes	210	45	0,4	100	260	1052,63	0,00142	0,02327	0,0065	0,13677
4	4	2	2	288	288	1,52	Yes	230	45	0,4	100	260	1052,63	0,0077	0,04975	0,038	0,29237
5	5	1	1	151	151	1,01	Yes	156,5	45	0,52	100	260	1368,42	0,00461	0,01609	0,02268	0,09457
6	6	1	1	89	89	1,02	Yes	119,7	45	0,676	100	260	1778,95	0,0151	0,01212	0,07609	0,07121
7	7	2	2	56	56	1,14	No	132,4	60	1,193	150	325	2409,18	0,04834	0,00351	0,24528	0,02065
8	8	2	2	136	136	1,02	Yes	191,2	60	0,706	150	325	1425,55	0,006	0,00532	0,02956	0,03125
9	9	3	3	90	90	1,05	No	126,3	60	0,706	150	325	1425,55	0,03793	0,00642	0,19231	0,03773
10	10	1	1	161	161	1	Yes	294,5	60	0,917	150	325	1853,22	0,001	0,00294	0,00424	0,01728
11	11	2	2	76	76	1,01	No	138,5	60	0,917	150	325	1853,22	0,02157	0,00397	0,10899	0,0233
12	12	1	1	95	95	1,01	Yes	225,4	60	1,193	150	325	2409,18	0,0029	0,0022	0,0138	0,01291
13																	
14	2	1	1	101	101	1,25	No	104,5	30	0,52	100	260	1368,42	0,04191	0,01289	0,21224	0,07573

## ANEXO B – Dimensões: 1° Trocador De Calor



**ANEXO C – Custo/Peso: 1° Trocador De Calor**

<b>Weights</b>	<b>kg</b>	<b>Cost</b>	<b>Dollar(US)</b>
Plate pack weight - empty (1 PHE)	558	Total cost (1 PHE)	10013
Plate pack weight - with water (1 PHE)	872,5	Total cost (all PHEs)	10013



## ANEXO D – Melhor Design: 2° Trocador De Calor


Optimization Path Plate

Optimization Path

Current selected case 1

Item	Passes		Channels		Area ratio	Risk of maldistribution	Total area m <sup>2</sup>	Plate Details				Hot Side DP		Cold Side DP		
	Hot side	Cold side	Hot side	Cold side				Chevron angle Degrees	Plate area m <sup>2</sup>	Port diameter mm	Horz. port distance mm	Vert. port distance mm	Plate bar	Port bar	Plate bar	Port bar
1	1	1	1	73	73	1 No	58	30	0,4	100	260	1052,63	0,05981	0,011	0,28217	0,06013
2	2	1	1	68	68	1,25 No	70,2	30	0,52	100	260	1368,42	0,08827	0,01068	0,41679	0,05839
3	3	1	1	166	166	1 Yes	132,4	45	0,4	100	260	1052,63	0,0032	0,01692	0,01424	0,09245
4	4	2	1	300	300	1 Yes	239,6	45	0,4	100	260	1052,63	0,00758	0,05088	0,00507	0,13903
5	5	2	2	84	84	1,03 No	66,8	45	0,4	100	260	1052,63	0,07088	0,0234	0,33483	0,12791
6	6	1	1	299	299	0,86 Yes	238,8	60	0,4	100	260	1052,63	0,00041	0,02537	0,00137	0,13868
7	7	2	1	300	300	0,63 Yes	239,6	60	0,4	100	260	1052,63	0,00205	0,05088	0,00136	0,13903
8	8	2	2	208	208	1,01 Yes	166	60	0,4	100	260	1052,63	0,00361	0,03917	0,01591	0,21411
9	9	3	3	135	135	1,02 Yes	107,6	60	0,4	100	260	1052,63	0,02268	0,04483	0,10627	0,24504
10																
11	1	1	1	73	73	1 No	58	30	0,4	100	260	1052,63	0,05981	0,011	0,28217	0,06013

## ANEXO E – Dimensões: 2° Trocador De Calor



**ANEXO F – Custo/Peso: 2° Trocador De Calor**

<b>Weights</b>	<b>kg</b>	<b>Cost</b>	<b>Dollar(US)</b>
Plate pack weight - empty (1 PHE)	315,6	Total cost (1 PHE)	6218
Plate pack weight - with water (1 PHE)	494,3	Total cost (all PHEs)	6218