

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

IDELCIO GONÇALVES DA ROCHA

**ALGORITMOS DE APRENDIZAGEM DE MÁQUINA PARA PREDIÇÃO E
CLASSIFICAÇÃO DE VARIÁVEIS NO DRIP TEST DA INDÚSTRIA DE FRANGO**

FRANCISCO BELTRÃO

2022

IDELCIO GONÇALVES DA ROCHA

**ALGORITMOS DE APRENDIZAGEM DE MÁQUINA PARA PREDIÇÃO E
CLASSIFICAÇÃO DE VARIÁVEIS NO DRIP TEST DA INDÚSTRIA DE FRANGO**

**Machine learning algorithms for prediction and classification of variables in the
drip test of the chicken industry**

Trabalho de Conclusão de Curso de graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Química da Universidade
Tecnológica Federal do Paraná.
Orientador: Claiton Zanini Brusamarello.

FRANCISCO BELTRÃO

2022



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

IDELCIO GONÇALVES DA ROCHA

**ALGORITMOS DE APRENDIZAGEM DE MÁQUINA PARA PREDIÇÃO E
CLASSIFICAÇÃO DE VARIÁVEIS NO DRIP TEST DA INDÚSTRIA DE FRANGO**

Trabalho de Conclusão de Curso de graduação
apresentada como requisito para obtenção do título
de Bacharel em Engenharia Química da Universidade
Tecnológica Federal do Paraná.

Data de aprovação: 24/junho/2022

Claiton Zanini Brusamarello
Doutor
Universidade Tecnológica Federal do Paraná

Frederico Márcio Corrêa Vieira
Doutor
Universidade Tecnológica Federal do Paraná

Suélen Maria de Amorim
Doutora
Universidade Federal do Sul e Sudeste do Pará

FRANCISCO BELTRÃO

2022

Dedico este trabalho ao meus pais Devenir e
Elizandra, por todo apoio.

AGRADECIMENTOS

Primeiramente quero agradecer a Deus por sempre estar ao meu lado, foi uma etapa cheia de obstáculos e de momentos de dificuldades. É difícil lembrar de todos que auxiliaram nessa caminhada, foram muitas pessoas, sempre fui abençoado por ter pessoas maravilhosas comigo. Serei eternamente grato a todos que me apoiaram e deram suporte quando precisei.

Agradeço aos meus pais Devenir e Elizandra que foram fundamentais em todos os momentos da minha vida. Meu pai infelizmente nos deixou durante a caminhada, foi o momento mais difícil, ele sempre foi a base de tudo.

Agradeço ao meu orientador Prof. Dr. Claiton Zanini Brusamarello, por todo apoio e paciência, sem sua ajuda esse trabalho seria impossível.

Agradeço aos professores e colegas, que me auxiliaram muito durante todo o curso, sem vocês eu não teria conseguido.

Agradeço os colegas de trabalho, por toda paciência e apoio, vocês foram os melhores.

Serei eternamente grato a todos que de alguma forma auxiliaram nessa dura batalha.

Obrigado.

O conhecimento torna a alma jovem e diminui a
amargura da velhice. Colhe, pois, a sabedoria.
Armazena suavidade para o amanhã.
Leonardo Da Vinci

RESUMO

Um dos principais problemas na indústria de carne do frango é o controle da quantidade de água que é absorvida pelas carcaças durante o processo produtivo. Os algoritmos de aprendizagem de máquina têm sido aplicados na solução de problemas em diversas áreas. No presente trabalho, foram realizados 907 testes utilizando três algoritmos de aprendizagem de máquina, a rede RBF (*Radial basis function*), a rede *multilayer perceptron* e o SMOReg (Sequential Minimal Optimization), para a previsão do resultado do *drip test* e para a classificação das variáveis mais influentes no processo. A rede RBF obteve o melhor resultado, atingindo 63,68% de acurácia, o *multilayer perceptron* alcançou 55,79% e o SMOReg 52,44%. Buscando otimizar os resultados foi realizada a redução das variáveis de entrada de onze para cinco, nessa etapa o *multilayer perceptron* obteve 58,48% de acurácia e o SMOReg 53,36%. Com a redução das variáveis de entrada houve uma melhora na capacidade de predição dos dois algoritmos, aproximando-se do melhor resultado obtido pela rede RBF com onze variáveis. A utilização de menos variáveis torna mais acessível financeiramente a aplicação industrial. Os algoritmos apontaram a absorção, temperatura do galpão de espera, temperatura ambiente, temperatura no início do pré-*chiller* e a massa média como variáveis mais influentes, tais variáveis estão de acordo com as encontradas na literatura.

Palavras-chave: controle de processos; absorção; algoritmos; redes neurais.

ABSTRACT

One of the main problems in the chicken meat industry is controlling the amount of water absorbed by the carcasses during the production process. Machine learning algorithms have been applied to solve problems in several areas. In the present work, 907 tests were performed using three machine learning algorithms, the RBF (Radial Basis Function) network, the multilayer perceptron network and SMOReg (Sequential Minimal Optimization), were used to predict the result of the drip test and the most influential variables in the process. The RBF network obtained the best result, reaching 63.68% of accuracy, the multilayer perceptron reached 55.79% and the SMOReg 52.44%. Seeking to optimize the results, the input variables were reduced from eleven to five. At this stage the multilayer perceptron obtained 58.48% of accuracy and the SMOReg 53.36%. With the reduction of the input variables, there was an improvement in the prediction capacity of the two algorithms, approaching the best result obtained by the RBF network with eleven variables. The use of fewer variables makes the industrial application more affordable. The algorithms pointed out the absorption, the temperature of the lairage facility, ambient temperature, the temperature at the beginning of the pre-chiller and the average mass as the most influential variables. Such variables agree with the others found in the literature.

Keywords: process control; absorption; algorithms; neural networks.

LISTA DE ILUSTRAÇÕES

Figura 1 - Produção Brasileira de carne de frango (Mil Toneladas)	17
Figura 2 - Valor bruto da produção 2010-2022 (em Bilhões de reais)	18
Figura 3 - Fluxograma de abate	20
Figura 4 - <i>Chiller</i> de resfriamento por imersão em água	22
Figura 5 - Imersão das carcaças	24
Figura 6 - Gotejamento das carcaças	25
Figura 7 - Exemplos de aplicações	26
Figura 8 - Exemplo de transformação realizada em conjunto de dados não lineares	32
Figura 9 - Exemplo de rede MLP aplicada	38
Figura 10 - Melhor resultado rede RBF	43
Figura 11 - Melhor resultado SMOReg com onze variáveis	45
Figura 12 - Melhor resultado SMOReg com cinco variáveis	47
Figura 13 - Melhor resultado MLP com onze variáveis	49
Figura 14 - Melhor resultado MLP com cinco variáveis	51

LISTA DE QUADROS

Quadro 1 - Conjunto de variáveis	34
Quadro 2 - Classificação das variáveis rede RBF	53
Quadro 3 - Classificação das variáveis SMOReg com onze variáveis	54
Quadro 4 - Classificação das variáveis SMOReg com cinco variáveis	55
Quadro 5 - Classificação das variáveis rede MLP com onze variáveis	55
Quadro 6 - Classificação das variáveis rede MLP com cinco variáveis	56

LISTA DE TABELAS

Tabela 1 - Tempo de imersão da carcaça em banho de água em relação ao peso do produto congelado	23
Tabela 2 - Arquiteturas rede RBF	36
Tabela 3 - Configurações testadas SMOReg	37
Tabela 4 - Configurações rede MLP com onze variáveis	38
Tabela 5 - Configurações rede MLP com cinco variáveis	40
Tabela 6 - <i>Ranker</i> variáveis mais importantes	42
Tabela 7 - Resultados RBF	43
Tabela 8 - Função Polinomial com onze variáveis	44
Tabela 9 - Função RBF com onze variáveis	44
Tabela 10 - Função PUK com onze variáveis	45
Tabela 11 - Função Polinomial com cinco variáveis	46
Tabela 12 - Função RBF com cinco variáveis	46
Tabela 13 - Função PUK com cinco variáveis	46
Tabela 14 - Rede MLP com uma camada e onze variáveis	47
Tabela 15 - Rede MLP com duas camadas e onze variáveis	48
Tabela 16 - Rede MLP com três camadas e onze variáveis	48
Tabela 17 - Rede MLP ajuste de <i>Learning Rate</i> e <i>momentum</i>	48
Tabela 18 - Rede MLP com uma camada e cinco variáveis	49
Tabela 19 - Rede MLP com duas camadas e cinco variáveis	50
Tabela 20 - Resultados rede MLP com cinco variáveis após ajustes	50
Tabela 21 - Comparação melhores configurações com onze variáveis	52
Tabela 22 - Comparação melhores configurações com cinco variáveis	52

LISTA DE ABREVIATURAS E SIGLAS

ABPA	Associação Brasileira de Proteína Animal
AM	Aprendizado de máquina
CGD	Conjugate gradient descent
E	Entrada
H	<i>Huanglongbing</i>
IA	<i>Inteligência artificial</i>
LSTM	Long short-term memory
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MLP	<i>MultiLayer Perceptron</i>
PUK	<i>Pearson universal kernel</i>
R	<i>Coeficiente de correlação de Pearson</i>
RBF	<i>Radial Basis Functions</i>
RMSE	<i>Root mean squared error</i>
RNA	<i>Rede neural artificial</i>
SMO	<i>Sequential minimal optimization</i>
SVM	<i>Support vector machine</i>
T	<i>Temperatura</i>
UTFPR	Universidade Tecnológica Federal do Paraná
WEKA	Waikato Environment for Knowledge analysis

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	16
2.1	Objetivo principal	16
2.2	Objetivos específicos	16
3	DESENVOLVIMENTO	17
3.1	Avicultura no Brasil	17
3.2	Processo de abate	18
3.3	Resfriamento	21
3.4	<i>Drip test</i>	22
3.5	Inteligência artificial e aprendizado de máquina	25
3.6	Redes neurais artificiais	26
3.6.1	Funcionamento de uma rede neural.....	28
3.6.2	Multilayer Perceptron.....	30
3.6.3	Redes RBF	31
3.7	Máquina de vetor de suporte	31
4	PROCEDIMENTOS METODOLÓGICOS	34
4.1	Equipamento utilizado	34
4.2	Pré-Processamento dos dados	34
4.3	Testes experimentais	36
4.3.1	RBF (Radial Basis Function)	36
4.3.2	SMOReg.....	36
4.3.3	Rede Neural Artificial.....	37
5	RESULTADOS E DISCUSSÕES	42
5.1	Seleção das variáveis	42
5.2	RBF	42
5.3	SMOReg	44
5.4	MultiLayer Perceptron	47
5.5	Selecionando o melhor algoritmo	51
5.6	Identificando as variáveis mais importantes	52
5.6.1	Rede RBF.....	53
5.6.2	SMOReg.....	54
5.6.3	MultiLayer Perceptron	55
6	CONCLUSÃO	58

SUGESTOES PARA TRABALHOS FUTUROS	59
REFERÊNCIAS.....	60
APÊNDICE A - RESULTADOS DOS TESTES REDE RBF	63
APÊNDICE B - RESULTADOS DOS TESTES COM O ALGORITMO SMOREG COM ONZE VARIÁVEIS E FUNÇÃO POLINOMIAL COMO FUNÇÃO KERNEL..	66
APÊNDICE C - RESULTADOS DOS TESTES COM O ALGORITMO SMOREG COM ONZE VARIÁVEIS E FUNÇÃO RBF COMO FUNÇÃO KERNEL.....	67
APÊNDICE D - RESULTADOS DOS TESTES COM O ALGORITMO SMOREG COM ONZE VARIÁVEIS E FUNÇÃO PUK COMO FUNÇÃO KERNEL	68
APÊNDICE E - RESULTADOS DOS TESTES COM O ALGORITMO SMOREG COM CINCO VARIÁVEIS E FUNÇÃO POLINOMIAL COMO FUNÇÃO KERNEL	69
APÊNDICE F - RESULTADOS DOS TESTES COM O ALGORITMO SMOREG COM CINCO VARIÁVEIS E FUNÇÃO RBF COMO FUNÇÃO KERNEL	70
APÊNDICE G - RESULTADOS DOS TESTES COM O ALGORITMO SMOREG COM CINCO VARIÁVEIS E FUNÇÃO PUK COMO FUNÇÃO KERNEL	71
APÊNDICE H - RESULTADOS DOS TESTES COM A REDE MLP COM ONZE VARIÁVEIS E UMA CAMADA INTERMEDIÁRIA	72
APÊNDICE I - RESULTADOS DOS TESTES COM A REDE MLP COM ONZE VARIÁVEIS E DUAS CAMADAS INTERMEDIÁRIAS	73
APÊNDICE J - RESULTADOS DOS TESTES COM A REDE MLP COM ONZE VARIÁVEIS E TRÊS CAMADAS INTERMEDIÁRIAS	76
APÊNDICE K - RESULTADOS DOS TESTES COM A REDE MLP COM CINCO VARIÁVEIS E UMA CAMADA INTERMEDIÁRIA	85
APÊNDICE L - RESULTADOS DOS TESTES COM A REDE MLP COM CINCO VARIÁVEIS E DUAS CAMADA INTERMEDIÁRIA	86

1 INTRODUÇÃO

A necessidade por alimentos vem crescendo a cada ano e com isso é cada vez mais importante produzir de maneira eficiente. O Brasil é um dos maiores produtores mundiais de alimentos, sendo que em menos de cinco décadas o país passou de importador, para um dos maiores exportadores e isso só foi possível, através de investimentos consistentes na agropecuária (MORETTI, 2020).

A carne de frango é um dos alimentos mais consumidos. Somente no ano de 2021 foram aproximadamente 100 mil toneladas em todo o mundo. O Brasil possui uma das maiores produções de carne de frango, com uma produção de 14,329 mil toneladas em 2021, ficando atrás apenas dos Estados Unidos da América e da China, com produção de 20,378 mil toneladas e 14,700 mil toneladas respectivamente (ABPA, 2022).

Juntamente com a alta na produção e consumo, a exigência por padrões mais elevados de qualidade também cresceu (SILVA *et al.*, 2021). A grande quantidade de água após o descongelamento vem sendo uma das maiores reclamações dos consumidores.

Através da portaria Nº 210 de 1998, o MAPA (Ministério da Agricultura Pecuária e Abastecimento) definiu limites para a quantidade de água que uma carcaça pode absorver, não podendo exceder 8% após o pré resfriamento, e 6% após o descongelamento. O descumprimento causa grande perda financeira para o consumidor e pode caracterizar fraude comercial (SILVA *et al.*, 2021).

Entende-se por absorção o percentual de água adquirido durante o processo de abate e demais operações tecnológicas, principalmente no pré-resfriamento em tanques de imersão, com uma pequena porcentagem nas etapas de escaldagem, depenagem e lavagens na linha de evisceração (BRASIL, 1998).

O resfriamento de frangos é um problema complexo de engenharia, devido a geometria não ser bem definida, possuir alta variabilidade de peso, e características específicas relacionadas ao sexo e a raça (CARCIOFI, 2005). Além de sofrer influência por variáveis ambientais e de projeto, como, temperatura, umidade, correntes de ar, área da lâmina de água, entre outras (KLASSEN, 2008).

O resfriamento logo após a evisceração é uma exigência da legislação nacional e dos importadores da carne de frango. As exigências internacionais são

maiores em relação aos índices de absorção, sendo que para a União Européia o limite do *drip test* é de 5,1% e para a Rússia é de 4,0% (LORENZETTI, 2016).

No Brasil têm-se dois métodos oficiais para o controle dos índices de absorção: o teste de controle interno, efetuado logo após o resfriamento, e o *drip test* (teste do gotejamento), aplicado após o congelamento do frango, sendo ambos desenvolvidos e padronizados pelo MAPA.

A complexidade dos problemas, e o grande volume de dados gerados nos últimos anos evidenciou a necessidade de desenvolver soluções computacionais mais sofisticadas, capazes de adquirir conhecimento, sem a intervenção humana (FACELI *et al.*, 2021).

A aprendizagem de máquina (AM) é um campo da inteligência artificial (IA), que se utiliza do princípio da indução, atingindo resultados genéricos através de um conjunto de dados, possibilitando a resolução de diversos problemas, em diferentes áreas do conhecimento (FACELI *et al.*, 2021).

Redes de aprendizados profundo já provaram sua eficiência na detecção de objetos, reconhecimento de voz, processamento de imagem, entre outros. Nos últimos anos tem sido largamente aplicada na indústria alimentícia, obtendo bons resultados na detecção de alimentos, contaminações, predição de calorias e qualidade, e mostrando-se promissoras na inspeção de segurança e qualidade dos produtos (ZHOU *et al.*, 2019).

Com relação a aplicação de algoritmos para a predição do *drip test*, o tema carece de mais estudos, pois na literatura foi encontrado apenas um trabalho, realizado por Pinto (2021), no qual foi testado o potencial de uma rede neural *multilayer perceptron* para a predição dos testes de absorção e do *drip test*. A pesquisa atingiu um bom resultado para a absorção, porém em relação ao *drip test* o resultado foi insatisfatório.

Com base no exposto, o presente trabalho visa integrar duas grandes áreas de conhecimento, a engenharia de controle de processos e a aprendizagem de máquina, através do estudo da absorção de água no processo de abate de frangos, buscando predizer os resultados do *drip test*, e classificar as variáveis mais influentes no processo, utilizando-se redes neurais artificiais (RNA) e o algoritmo de regressão por suporte de máquinas de vetores *SVM*.

2 OBJETIVOS

2.1 Objetivo principal

O trabalho tem como objetivo a predição do resultado do *drip test* (teste de gotejamento) e a identificação das variáveis mais influentes no processo produtivo utilizando algoritmos de aprendizagem de máquina.

2.2 Objetivos específicos

- Treinar os algoritmos *Multilayer Perceptron* (MLP), *Radial Basis Function* (RBF) e *SMOReg* para a predição do resultado do *drip test*;
- Classificar as variáveis mais influentes do *drip test* utilizando os algoritmos estudados;
- Comparar a classificação obtida pelos algoritmos com dados da literatura;

3 DESENVOLVIMENTO

Neste capítulo serão abordados todos os tópicos importantes para o desenvolvimento deste estudo. Inicialmente é discorrido sobre a avicultura e o processo produtivo, na sequência são apresentados os tópicos referentes ao aprendizado de máquina, desde sua evolução histórica até os algoritmos utilizados para elaboração do estudo.

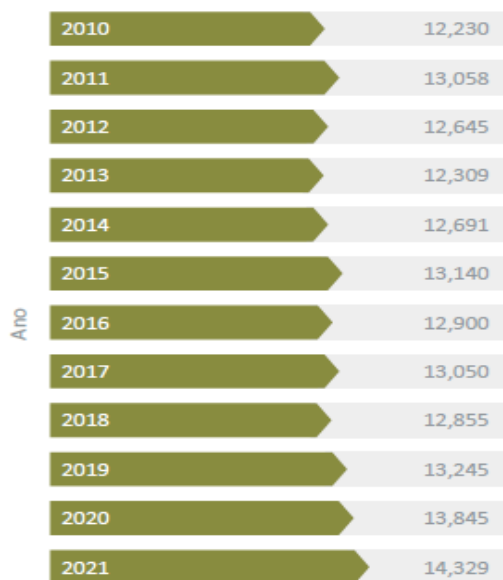
3.1 Avicultura no Brasil

A história da avicultura no Brasil teve sua primeira referência em 1500 com a carta de Pedro Vaz de Caminha, indicando que as primeiras matrizes vieram a bordo das caravelas. Porém a produção de carne de frango em larga escala começou a se desenvolver nos anos 40 e desde então apresenta um bom crescimento, levando o País a um lugar de destaque no cenário mundial (VOGADO *et al.*, 2016).

Atualmente o Brasil é o terceiro maior produtor de carne de frango, sendo o líder em exportações, apenas em 2021 o país exportou 4,61 mil toneladas para 151 países. A região sul é responsável por mais de 64,08% da produção nacional, sendo a produção do Paraná de 35,54%, enquanto Santa Catarina e Rio Grande do Sul, produzem 14,89% e 13,65% respectivamente (ABPA, 2022).

Na Figura 1, é possível visualizar a evolução da produção brasileira entre os anos de 2010 e 2021.

Figura 1 - Produção Brasileira de carne de frango (Mil Toneladas)




Fonte: ABPA (2022)

Segundo ABPA (2022), o consumo de carne de frango no Brasil, cresceu atingindo em 2021 o índice de 45,56 kg/habitante, contra 45,27 kg/habitante em 2020. Quando comparado com o consumo de 2019 (42,84 kg/habitante) esse crescimento é ainda mais significativo, representando um aumento de 2,72 kg/habitante no período 2019-2021. O relatório também aponta que 67,83% da produção nacional é direcionada ao mercado consumidor interno, e 32,17% para exportações.

Em relação à economia, a produção de 2021 foi recorde, superando a marca de 100 bilhões de reais de valor bruto de produção, sendo a primeira vez na história que essa marca foi atingida. Em relação ao ano de 2020, houve uma alta de 15,487 bilhões de reais, o que representa um crescimento de 14,2%.

A Figura 2 ilustra o valor bruto da produção brasileira no período que corresponde aos anos de 2010 a 2021. É possível observar que houve uma alta significativa durante o período.

Figura 2 - Valor bruto da produção 2010-2022 (em Bilhões de reais)



Fonte: ABPA (2022)

3.2 Processo de abate

A organização do procedimento operacional para o abate de aves é muito semelhante em todos os frigoríficos, podendo sofrer pequenas modificações ou adaptações relacionadas a estrutura física da planta industrial. O processo aqui descrito, Figura 3, foi baseado nos trabalhos de Carciofi (2005), Klassen (2008), Sant'anna (2008), Lorenzetti (2016) e Vieira *et al.* (2016).

O processo de abate de frangos envolve diversas etapas iniciando pela recepção das aves, as quais devem ser direcionadas para um galpão de espera, onde permanecem entre uma e três horas, sob ventilação controlada, com o intuito de proporcionar o relaxamento das aves e a recuperação do estresse causado pelo transporte.

Em seguida as caixas plásticas são descarregadas em uma esteira, que direciona para a linha de pendura. De forma manual, os colaboradores da empresa retiram os frangos das gaiolas e as penduram em ganchos de aço inox conectados a nória transportadora. Nessa etapa o manejo adequado é fundamental para a redução de hematomas, lesões e fraturas.

Após serem pendurados, os frangos passam pela cuba de insensibilização, onde são mergulhados em água eletrificada, o tempo submerso deve ser proporcional a espécie, o tamanho e peso das aves, a insensibilização não deve provocar a morte da ave, a sangria deve ocorrer no prazo máximo de 12 segundos, o objetivo é reduzir o sofrimento causado pela etapa posterior, a sangria.

A sangria pode ser feita de forma manual ou mecânica, o frango sofre um corte no pescoço, e em seguida é encaminhado a um túnel, onde permanece por aproximadamente três minutos, tempo necessário para que o sangue escorra.

A etapa seguinte visa remover as penas. As aves são imersas em um tanque de escaldagem, com temperatura entre 50 °C e 70 °C, por aproximadamente dois minutos, tempo médio para que ocorra a abertura do folículo, facilitando a remoção das penas. A depenagem ocorre de forma mecânica, através da passagem por várias paletas rotativas de borracha.

A evisceração pode ocorrer de forma manual, semiautomática ou automática. Nesta etapa, o frango sofre um corte abdominal, e em seguida as vísceras são separadas da carcaça. A maior preocupação é não rasgar o pacote de vísceras durante a remoção, evitando possíveis contaminações. Após evisceradas, as aves são inspecionadas.

A etapa de inspeção é realizada por funcionários do MAPA, ou por colaboradores da empresa, que foram devidamente treinados pelos auditores fiscais. É uma etapa muito importante, além de proporcionar a certificação de qualidade necessária para as exportações, ela garante a qualidade do produto, pois é nesse estágio onde ocorre o descarte de aves acometidas por alguma doença, tais como, artrite, dermatose, miopatia, colibacilose, onfalite, salpingite, entre outras.

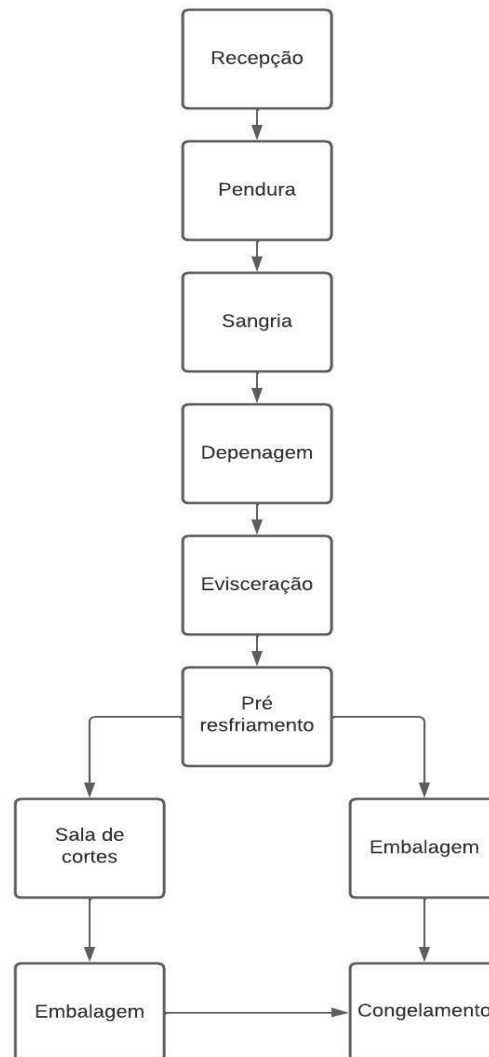
Na sequência as aves são destinadas para ao resfriamento. Esta etapa pode ocorrer a seco ou por imersão. No processo a seco, os frangos percorrem um túnel e a troca térmica ocorre pela passagem de uma corrente de ar, não é utilizado no Brasil, pois ocorre uma perda de 3% a 4% de massa. A imersão é amplamente utilizada, além de proporcionar a troca térmica, atua na hidratação e recuperação dos tecidos.

Após resfriadas, as carcaças são separadas. As carcaças que serão embaladas inteiras, seguem para o setor de embalagem, e as carcaças que serão desossadas, são direcionadas para a sala de cortes.

Após embalados, os produtos seguem para os túneis de congelamento, e posteriormente para a embalagem final e estocagem. A estocagem é feita em câmaras frias com temperatura inferior a $-18\text{ }^{\circ}\text{C}$ (BRASIL, 2008).

O fluxograma do procedimento de abate é apresentado a seguir, na Figura 3.

Figura 3 - Fluxograma de abate



Fonte: Autoria Própria (2022)

3.3 Resfriamento

A etapa de resfriamento, também chamada de pré-resfriamento, é uma etapa crucial, pois a redução da temperatura auxilia no controle microbiano e influencia a qualidade da carne, reduzindo a degradação da carne causada pela atividade enzimática (KLASSEN, 2008). Em temperaturas baixas, ocorre a redução na velocidade das reações bioquímicas e microbiológicas, aumentando a vida útil dos produtos (CARCIOFI; LAURINDO, 2007).

No Brasil e nos Estados Unidos o método utilizado para resfriamento é por imersão em água (*chillers*), enquanto na Europa é amplamente utilizado o sistema com ar frio (*air chillers*) (LORENZETTI, 2016).

A legislação exige que ao final do processo de resfriamento, a temperatura no centro do peito atinja 7 °C, porém alguns mercados internacionais exigem 4 °C. No centro do peito a velocidade de resfriamento é mais lenta, portanto, possui temperatura mais elevada (LORENZETTI, 2016).

O resfriamento por imersão permite a recuperação da água perdida durante o abate (ROSA, 2014). O processo ocorre em tanques cilíndricos deitados, com um helicóide que se move lentamente, proporcionando o deslocamento das carcaças. É dividido em duas etapas, pré *chiller* e *chiller*. A renovação de água deve ser constante, no pré-*chiller* é necessário a adição de 1,5 litros de água por carcaça, e a temperatura não deve ultrapassar 16 °C. No *chiller* é necessário 1 litro de água por carcaça e a temperatura final do frango deve ser 4 °C (KLASSEN, 2008).

Klassen (2008), ainda cita que para acelerar a troca térmica utilizam-se camisas de circulação de uma solução de 30% de propilenoglicol, em uma temperatura abaixo de 0 °C, e adiciona-se gelo em diversos pontos. O propilenoglicol é amplamente utilizado por ser um anticongelante barato, seguro e inerte.

A Figura 4 apresenta um *chiller* de resfriamento por imersão, modelo mais utilizado nos frigoríficos brasileiros.

Figura 4 - Chiller de resfriamento por imersão em água



Fonte: Klassen (2008)

3.4 Drip test

O *drip test* é regulamentado pela Instrução Normativa nº 20 de 21 de julho de 1999 (BRASIL, 1999) e segue os padrões definidos pela Portaria nº 210 de 10 de novembro de 1998 (BRASIL, 1998), atualizadas pela Portaria nº 74 de 7 de março de 2019 (BRASIL, 2019).

O teste é efetuado com o produto pronto para ser enviado para o consumidor, ocorre o descongelamento sob condições controladas, a fim de calcular a massa de água perdida, o resultado em base percentual não deve ultrapassar 6% do valor da carcaça (PINTO, 2021).

Os equipamentos necessários para efetuar o teste estão listados abaixo.

- Balança com capacidade de 5 kg \pm 1 g;
- Papel absorvente;
- Sacos plásticos com fechamento seguro;
- Termômetro;
- Tesoura;

- Caneta para identificação das carcaças;
- Equipamento com banho de água controlado termostaticamente, com volume oito vezes maior do que a carcaça a ser testada, e temperatura de $42\text{ °C} \pm 2\text{°C}$.

Deve-se coletar amostras de seis frangos, mantendo-se a temperatura de -12 °C até o início da análise. Antes de efetuar a pesagem a parte externa deve ser enxuta, para remoção do gelo. O peso da carcaça embalada é marcado como medida M0, a embalagem é removida, secada e pesada, obtendo-se a medida M1. Em seguida a carcaça juntamente com os miúdos, são colocados dentro de um saco plástico, com a cavidade abdominal virada para o fundo da embalagem. O saco plástico contendo a carcaça e os miúdos deve permanecer imersa em banho de água à temperatura de 42 °C , até que a temperatura do centro da ave atinja 4 °C . O tempo necessário de imersão é apresentado na Tabela 1 (BRASIL, 1998).

Tabela 1 - Tempo de imersão da carcaça em banho de água em relação ao peso do produto congelado

Peso do frango com vísceras (gramas)	Tempo de imersão (minutos)
Até 800	65
801 a 900	72
901 a 1000	78
1001 a 1100	85
1101 a 1200	91
1201 a 1300	98
1301 a 1400	105
1401 a 1500	112
1501 a 1600	119
1601 a 1700	126
1701 a 1800	133
1801 a 1900	140
1901 a 2000	147
2001 a 2100	154
2101 a 2200	161
2201 a 2300	168

Fonte: BRASIL (1998)

Acima de 2300 gramas somar 7 minutos a cada 100g adicionais.

A Figura 5 exibe a etapa de imersão das carcaças, na qual ocorre o descongelamento controlado.

Figura 5 - Imersão das carcaças



Fonte: Fries (2017)

Após a imersão, o saco plástico é perfurado, para que a água proveniente do descongelamento esorra. As embalagens devem permanecer penduradas, à temperatura ambiente entre 18 °C e 25 °C, durante uma hora para que ocorra o gotejamento completo das carcaças, o procedimento é apresentado na Figura 6. Em seguida o frango e as vísceras são retirados da embalagem, ambos são secados e pesados, obtendo-se as medidas M2 e M3 respectivamente.

Figura 6 - Gotejamento das carcaças



Fonte: Fries (2017)

De posse de todas as medidas, é possível efetuar o cálculo da quantidade de água proveniente do descongelamento da carcaça, utilizando-se a seguinte equação.

$$Drip\ test = \frac{M0 - M1 - M2}{M0 - M1 - M3} * 100 \quad (1)$$

3.5 Inteligência artificial e aprendizado de máquina

Em aplicações de algoritmos de aprendizagem de máquina, é definido um atributo de saída, e a partir do conjunto de dados para treinamento (atributos de entrada), busca-se aprender um modelo ou hipótese capaz de associar os dados de entrada com o atributo de saída (FACELI *et al.*, 2021).

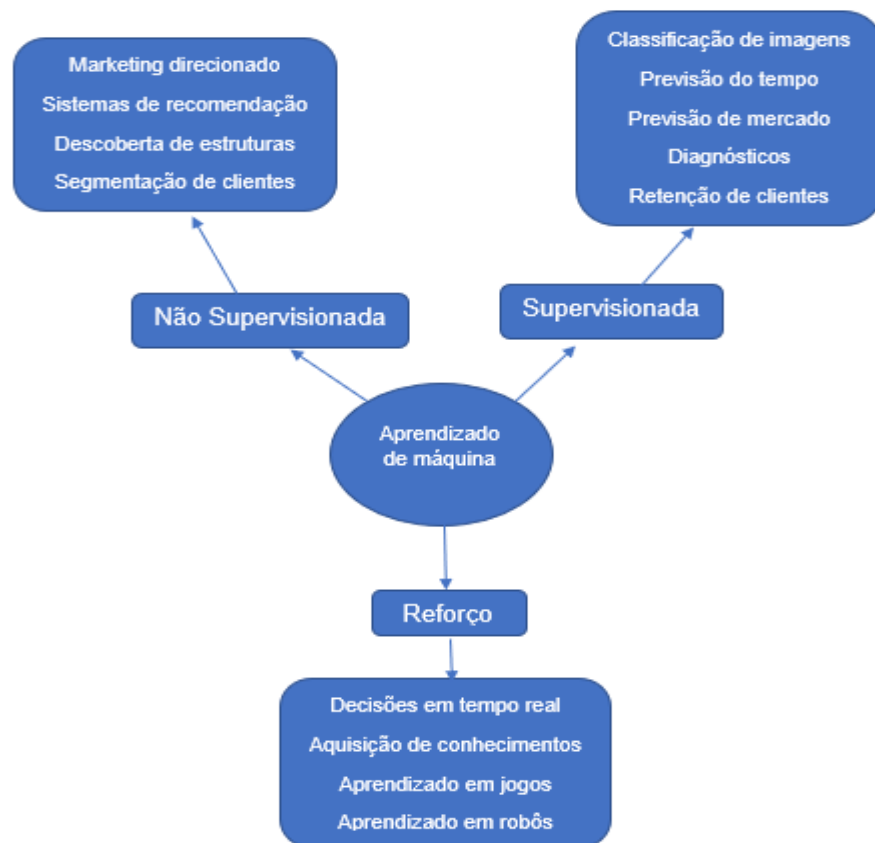
O aprendizado de máquina pode ser dividido em aprendizado supervisionado, não supervisionado e aprendizado por reforço.

Na aprendizagem supervisionada, um supervisor externo fornece os dados, e ensina o algoritmo a identificar padrões na relação de pares de entrada e saída. No aprendizado não supervisionado o agente tenta identificar padrões nos dados de entrada, esses algoritmos não geram resultados explícitos, geralmente são aplicados

em tarefas de agrupamento. O aprendizado por reforço é baseado em um sistema de recompensas para acertos e punições para falhas (RUSSEL; NORVIG, 2013).

A escolha do tipo de aprendizado é um fator importante para o sucesso da tarefa desejada. Cada aprendizado possui diferentes algoritmos, que se ajustam melhor a determinados problemas, na Figura 7 é possível observar algumas aplicações para cada tipo de aprendizado.

Figura 7 - Exemplos de aplicações



Fonte: Autoria própria (2022)

3.6 Redes neurais artificiais

As redes neurais artificiais são algoritmos robustos e eficientes, capazes de manipular base de dados volumosas, são hábeis em aprender com os dados, e aplicar o aprendizado para novos dados. Sua operação é inspirada no sistema nervoso, e busca reproduzir o funcionamento do cérebro humano.

Segundo Faceli *et al* (2021), o primeiro estudo relacionado a rede neural artificial foi elaborado em 1943 por McCulloch e Pitts, em que os autores propuseram

uma rede simples capaz de resolver funções lógicas e aritméticas. O trabalho serviu de base para muitos outros pesquisadores.

Com o avanço da capacidade de processamento, na década de 80 vários eventos renovaram o interesse pela área. Em 1985, cerca de 1800 pessoas participaram da primeira Conferência Internacional sobre redes neurais, no *Institute of Electrical and Electronic Engineer's* (MÜLLER, 2019).

O desenvolvimento da computação nos anos 2000, proporcionaram um grande avanço na utilização das RNA's, possibilitando sua aplicação em várias áreas e em diversos estudos.

Na avicultura, Reali (2004), utilizou as redes no gerenciamento da produção de frangos de cortes, tendo atingido o objetivo, a rede conseguiu explicar os fenômenos envolvidos na produção do frango de corte. Nestas situações todos os ensaios apresentaram resultados satisfatórios, com coeficiente de correlação próximo de 1.

Klassen (2008), aplicou as RNA's na modelagem da temperatura e da retenção de água no resfriamento de carcaças de frangos por imersão. A rede apresentou bons resultados na predição da absorção de água, porém foram ineficientes na determinação da temperatura final das carcaças.

Spohr (2011), analisou as RNA's no gerenciamento dos fenômenos envolvidos na produção de aves reprodutoras pesadas e do frango de corte em um incubatório e em um frigorífico. Foram desenvolvidas várias redes, com o objetivo de prever a eclosão total, eclosão vendável, fertilidade, mortalidade, perda de peso de ovo, peso após cinco semanas, tipo de pinto e condenações parciais e totais. As redes neurais foram capazes de modelar os fenômenos envolvidos, demonstrando ser uma importante ferramenta de apoio na área.

Sevegnani *et al.* (2017), estudaram a influência de fatores ambientais em variáveis fisiológicas de frango de cortes. O algoritmo conseguiu correlacionar as variáveis de entrada com o peso corporal dos frangos, apontando as variáveis climáticas como o principal fator de influência, o que também foi possível prever o estresse ao qual o frango foi submetido.

Ott (2018), aplicou redes neurais LSTM (*Long-Short Term Memory*) na predição do peso do frango de corte. Para tanto, foram utilizadas como variáveis de entrada, a idade, a temperatura e a umidade relativa. O modelo conseguiu prever os

resultados, com um erro quadrático médio de 2,5 gramas, demonstrando potencial para aplicação no controle e gerenciamento das granjas.

Pinheiro (2020), usou redes neurais e regressão linear na análise e previsão de variáveis produtivas de frango de corte, e a aplicabilidade de redes neurais recorrentes na predição do preço do quilo do frango congelado e resfriado. As previsões foram precisas, apresentando coeficiente de correlação de 0,9989 para o índice de eficiência produtiva e 0,9991 para o peso médio. Os resultados da rede recorrente também se mostraram promissores na previsão do preço do quilo do frango em um cenário de curto prazo. O resultado foi superior ao atingido neste estudo.

Pinto (2021) aplicou RNA's na predição dos resultados do teste interno de absorção e do *drip test*. Para o teste de absorção a rede obteve um resultado satisfatório, com coeficiente de correlação de 0,95. Para o *drip test* a rede não obteve bons resultados, foram aplicados dois métodos de treinamento e validação, os coeficientes de correlação apresentados foram 0,3902 e 0,4207, resultado abaixo do aceitável, demonstrando que o modelo não conseguiu correlacionar as variáveis de maneira adequada.

Bortoleti (2021) atingiu 99,09% de correlação, em seu estudo utilizando redes neurais para a predição do resultado do teste de absorção. No mesmo trabalho o autor fez uso do algoritmo SMOreg, obtendo 99,87% de correlação.

3.6.1 Funcionamento de uma rede neural

O neurônio artificial é uma estrutura que busca simular o comportamento do neurônio biológico, sendo que, as entradas representam os dendritos. Suas conexões são realizadas pelos pesos, simulando as sinapses. O processamento das entradas ocorre na função soma, e a função de transferência representa o limiar de disparo do neurônio biológico (KLASSEN, 2008).

Segundo Braga (2007), as RNA's necessitam dos seguintes elementos básicos para sua operação.

- Conjunto de sinapses: conexões entre os neurônios;
- Integrador: responsável para somar os sinais de entrada, ponderados pelos pesos;
- Função de ativação: responsável por restringir a amplitude do sinal de saída;

- Bias: valor aplicado externamente a cada neurônio e tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação.

Os pesos são similares as sinapses do cérebro humano, sua função é ampliar ou reduzir os valores das entradas. O conhecimento de uma RNA está relacionado com os pesos, os valores são atualizados a cada iteração. A equação abaixo descreve uma maneira genérica de atualizar o erro.

$$Peso(n+1) = Peso(n) + (TA * E * Erro) \quad (2)$$

Onde:

Peso (n) = peso atual;

TA = Taxa de aprendizado;

E = valor da entrada;

Erro = Diferença entre o valor real e o valor calculado.

Em relação a função de ativação, segundo Haykin (2007), existem diversos tipos, sendo as mais populares:

- Função de Limiar

$$f(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases} \quad (3)$$

- Função Linear por partes

$$f(x) = \begin{cases} 1 & \text{se } x \geq +1/2 \\ x & \text{se } +\frac{1}{2} < x < -1/2 \\ 0 & \text{se } x \leq -1/2 \end{cases} \quad (4)$$

- Função Sigmóide

$$f(x) = \frac{1}{1 + \exp(-ax)} \quad (5)$$

Onde a representa o parâmetro de inclinação, quanto maior o valor de a , maior será a inclinação.

- Função Tangente Hiperbólica

$$f(x) = \tanh(x) \quad (6)$$

Segundo Braga (2007), para a definição da arquitetura de uma rede, é necessário analisar os seguintes parâmetros: número de camadas da rede, número de neurônios por camada, tipo de conexão entre os neurônios e topologia da rede.

Em relação ao número de camadas, uma rede pode ser classificada em camada única ou múltiplas camadas. As conexões podem ocorrer de forma *feedforward* (acíclica) ou *feedback* (cíclica), e a rede pode ser parcialmente conectada ou totalmente conectada.

3.6.2 Multilayer Perceptron

É uma das arquiteturas mais versáteis caracterizada pela presença de pelo menos uma camada intermediária. Dentre as áreas de aplicação, destacam-se, otimização de sistemas, identificação e controle de processos, reconhecimento de padrões, aproximação universal de funções e previsão de séries temporais (SILVA; SPATTI; FLAUZINO, 2019).

O processo de treinamento geralmente ocorre através da utilização do algoritmo *back-propagation*, também conhecido por Delta generalizado ou gradiente descendente. O algoritmo opera em duas etapas, primeiramente ocorre a propagação adiante (*forward*), onde as informações percorrem a rede, gerando um valor de saída. O valor obtido é comparado com o valor desejado, obtendo-se o valor do erro. A segunda etapa é a propagação reversa (*backward*), ela é aplicada em função do erro calculado, é nessa etapa onde ocorrem os ajustes dos pesos.

Para a aplicação de uma rede de múltiplas camadas é importante a definição de dois atributos, o número de camadas intermediárias e o número de neurônios por camada.

Para Braga (2007), deve-se evitar a utilização de um grande número de camadas intermediárias, pois o erro medido é propagado para a camada anterior, perdendo a precisão. A camada final é a única que possui o valor real do erro, a camada anterior recebe uma estimativa, e as camadas anteriores a ela, recebem estimativas das estimativas. Em relação ao número de neurônios, deve-se analisar a quantidade de dados para treinamento, o ruído presente nos dados, a complexidade da função a ser aprendida e a distribuição estatística dos dados para treinamento.

3.6.3 Redes RBF

Uma rede RBF básica envolve três camadas com papéis diferentes. A camada de entrada conecta a rede ao ambiente. A única camada intermediária é responsável por transformar os dados não linearmente separáveis, em dados linearmente separáveis. A camada de saída fornece a resposta do padrão relacionado a entrada (HAYKIN, 2007).

As principais funções radiais utilizadas são:

- Função Gaussiana

$$f(u) = \exp\left(-\frac{v^2}{2\theta^2}\right) \quad (7)$$

- Função multiquadrática

$$f(u) = \sqrt{v^2 + \theta^2} \quad (8)$$

Onde $v = \|x - \mu\|$, que é uma distância euclidiana, x é o vetor de entrada, μ é o centro da função e θ representa a largura da função.

3.7 Máquina de vetor de suporte

As máquinas de vetores de suporte, do inglês (*support vector machine - SVM*), se baseiam na teoria de aprendizado estatístico, desenvolvida por Vapnik (1995). A teoria estabelece condições matemáticas que contribuem na escolha de um classificador a partir de um grupo de dados de treinamento, baseado no desempenho do treinamento e na complexidade dos dados, objetivando o melhor desempenho para novos dados.

São ótimos algoritmos para classificação e regressão, tem um excelente poder de generalização, podem ser aplicados em aprendizado não supervisionado, como por exemplo em tarefas de agrupamento.

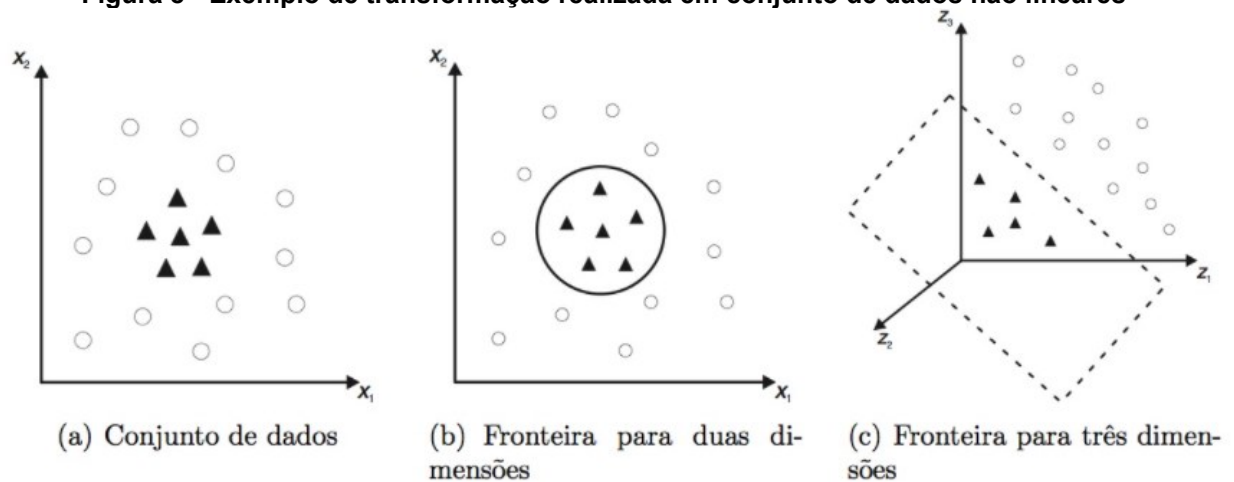
Os SVM's constroem um separador de margem máxima como forma de reduzir a complexidade da solução (AYAT *et al.*, 2005). O algoritmo cria uma separação por hiperplanos, com capacidade de inserção de dados em dimensões superiores, através de funções *Kernel*.

O algoritmo encontra um plano de separação e define as margens máximas, os pontos mais próximos das margens são definidos como vetores de suporte, e servem de sustentação para o hiperplano.

Sempre se busca hiperplanos de separação lineares, mesmo para conjunto de dados explicitamente não lineares, isso é possível mapeando esse conjunto de dados em dimensões superiores, para dimensões suficientemente altas, todos os dados serão quase sempre linearmente separáveis.

As funções *Kernel* são aplicadas a pares de dados de entrada, para avaliar o produto escalar em algum espaço característico. Pelo teorema de Mercer (1909), qualquer função *Kernel* corresponde a algum espaço característico, esses espaços podem ser muito grandes, e até mesmo infinitos. Por exemplo na função *Kernel* polinomial o número de dimensões é representado pelo expoente d . A Figura 8 exemplifica como o algoritmo consegue realizar essa separação.

Figura 8 - Exemplo de transformação realizada em conjunto de dados não lineares



Fonte: Faceli et al. (2021)

Um dos principais fatores a se observar na utilização de SVM's, é a função Kernel capaz de representar a melhor separação e generalização, para o conjunto de dados de entrada. Segundo *Hsu et al. (2003)*, as principais funções Kernel são expressas como função linear, polinomial e RBF.

Além de possuir grande poder de generalização, os SVM's são bons para conjuntos de dados robustos ou com grandes dimensões, conseguindo um bom ajuste em situações em que outros algoritmos apresentam dificuldades. O SVM consegue determinar funções de classificação e regressão utilizando pequenas amostras, o que facilita a solução de problemas com banco de dados volumosos (*MOGUERZA; MUÑOZ, 2006*).

A principal desvantagem é alta sensibilidade a variações nos parâmetros, pequenas modificações podem apresentar grandes mudanças na definição do hiperplano.

Michelon *et al.* (2017), utilizaram SVM's para a predição da produtividade de soja. Os autores aplicaram dados dos macros nutrientes presentes na folha da soja para identificar os pontos de baixa produtividade. A intenção foi usar os resultados para ajustar a adubação nos pontos mais críticos. O modelo com melhor ajuste conseguiu prever 58% dos resultados.

Lima *et al.* (2017), analisaram o comportamento das máquinas de vetores, aliadas com a espectrometria de infravermelho médio no controle do processo de hidrogenação do óleo de soja. Foram desenvolvidos modelos para a predição da quantidade de ácidos graxos saturados, insaturados, monossaturados, trans, poli-insaturados e índice de iodo. Os modelos obtiveram coeficientes de correlação acima de 0,96.

Prestes (2020), testou o algoritmo na predição de produtividade de trigo. Para tal, foram utilizados valores digitais de bandas espectrais e valores estimados de altura das plantas, os dados foram obtidos com o auxílio de uma aeronave remotamente pilotada. As máquinas de vetores conseguiram desenvolver um modelo com 0,97 de coeficiente de correlação.

4 PROCEDIMENTOS METODOLÓGICOS

Neste capítulo será apresentada a metodologia utilizada, inicialmente será abordado o pré-processamento dos dados, e na sequência será discorrido sobre os parâmetros modificados em cada um dos algoritmos.

4.1 Equipamento utilizado

Os testes foram realizados em um notebook, Acer Aspire A315-41, com processador AMD Ryzen 5 2500U, 8 GB de memória RAM e placa de vídeo Radeon Vega mobile Gfx 2,00 Ghz.

4.2 Pré-Processamento dos dados

Para o presente trabalho, foram utilizados os dados obtidos experimentalmente por Pinto (2021). O conjunto de dados possui 36 variáveis, as quais são listadas no Quadro 1.

Quadro 1 - Conjunto de variáveis

Variáveis		
Distância do aviário	Regulagem da depenadeira 2	Temperatura no final do <i>pré-chiller</i>
Tempo de Jejum	Temperatura de escaldagem 1	Temperatura no início do <i>chiller</i> intermediário
Sexo	Temperatura de escaldagem 2	Temperatura no final do <i>chiller</i> intermediário
Idade	Condenação por dermatose	Temperatura no início do <i>chiller</i>
Massa média	Temperatura da depenadeira	Temperatura no final do <i>chiller</i>
Temperatura do galpão de espera	Massa inicial da carcaça	Borbulho
Umidade do galpão de espera	Massa final da carcaça	Temperatura das carcaças no <i>chiller</i>
Tempo de espera no galpão	Absorção	Peito com bolsão de ar
Temperatura do ambiente externo	Temperatura de congelamento	Costela ou coluna fraturada
Linha de produção	Dripping test	Falta de pele no pescoço
Velocidade da linha de produção	Tempo de retenção no <i>chiller</i>	Perna deslocada

Regulagem da depenadeira 1	Temperatura no início do <i>pré-chiller</i>	Acidez/Alcalinidade (pH)
----------------------------	---	--------------------------

Fonte: Autoria Própria (2022)

O banco de dados utilizado, possui 312 amostras, totalizando 11232 dados. As informações referentes as coletas 311 e 312 foram excluídas antes do início dos testes, devido a inconsistência de alguns dados.

Foram excluídas as variáveis que possuíam apenas dados de sim ou não, foram elas, perna deslocada, falta de pele no pescoço, costela ou coluna fraturada, peito com bolsão de ar e borbulho. A variável relacionada com a distância do aviário também foi excluída.

Antes da realização dos testes os dados foram normalizados, tal procedimento é necessário devido a não linearidade dos dados. A normalização aumenta o desempenho do algoritmo, pois trabalha com dados dentro do intervalo entre 0 e 1. Isso é realizado para evitar que um atributo seja predominante sobre outro (FACELI *et al.*, 2021).

Após a normalização, com o intuito de otimizar o processamento dos algoritmos, foi necessário a redução do número de variáveis do banco de dados, para tal, o WEKA disponibiliza um classificador de atributos, o *Ranker*, que classifica as variáveis de acordo com a sua influência sobre o resultado do atributo de saída, para isso o WEKA utiliza o coeficiente de correlação de Pearson.

O WEKA disponibiliza quatro formas de divisão dos dados para a realização do treinamento e dos testes, as duas principais são o *Cross-Validation* e o *Percentage split*, na primeira os dados são divididos em dez grupos, sendo que nove são utilizados para treinamento e um para a validação do modelo. Já o *Percentage split* realiza a divisão dos dados com base em uma porcentagem escolhida pelo usuário, o valor inserido é utilizado para o treinamento do algoritmo e a porcentagem restante é destinada para a validação do modelo.

Para a realização dos testes, os dados foram divididos em 70% para treinamento e 30% para validação. A separação foi baseada na literatura, principalmente no trabalho elaborado por Bortoleti (2021).

4.3 Testes experimentais

4.3.1 RBF (Radial Basis Function)

O primeiro algoritmo testado foi o *RBFRegressor*, foi desenvolvido por Frank (2014), e está presente como pacote adicional do WEKA. O algoritmo permite o ajuste de diversos parâmetros, tais como o *ridge*, que penaliza os pesos na camada de saída, o *NumFunctions*, que corresponde a quantidade de neurônios presentes na camada intermediária e o *seed* que representa o valor randômico inicial, que é o valor inicial utilizado pelo algoritmo.

Outras opções são o ajuste se o valor de sigma será usado de maneira global ou por unidade, a primeira apresenta maior rapidez no processamento, o *useAttributeWeights*, responsável por aprender pesos diferentes para a função distância, a utilização do gradiente descendente conjugado para a otimização do erro através da opção *useCGD*.

Para o presente trabalho, foi fixado o valor do *ridge*, utilizado o ajuste global de sigma, ativado o *useAttributeWeights* e o *useCGD*, essa combinação de parâmetros foi obtida através da tentativa e erro. Foram testadas diferentes configurações variando-se os parâmetros *numFunctions* e o *seed*.

Todas as configurações testadas são representadas na Tabela 2.

Tabela 2 - Arquiteturas rede RBF

Seed	numFunctions																			
1	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
2	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
3	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
4	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
5	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20

Fonte: Autoria própria (2022)

4.3.2 SMOReg

Para o *SMOReg* foram realizadas duas etapas de testes, a primeira contendo as onze variáveis principais, e a segunda com as cinco variáveis mais influentes de acordo com o *Ranker*.

Os parâmetros alterados variam de acordo com a função *Kernel*. O parâmetro de complexidade C foi alterado em todas as funções, para a função polinomial, foi alterado o expoente n. Para a função RBF foi alterado o parâmetro gama e para a função PUK, foram alterados os parâmetros $\hat{\Omega}$ e sigma. As configurações

utilizadas são apresentadas na Tabela 3 e foram baseadas no trabalho realizado por Bortoleti (2021).

Tabela 3 - Configurações testadas SMOReg


Parâmetro	Valores									
Função Polinomial										
C	1	10	100	1000						
Expoente	1	2	3	4						
Função RBF										
C	1	10	100	1000						
Gama	0.001	0.01	0.02	0.05	0.1	0.2	0.5	0.7	1	
Função PUK										
C	1	10	100	1000						
Ômega	0.1	0.5	1	2	5	10	20	30		
Sigma	0.5	1	2	5	10	20	30			

Fonte: Autoria própria (2022)

4.3.3 Rede Neural Artificial

O algoritmo utilizado foi o *multilayer perceptron* (MLP), cujo treinamento ocorre por um algoritmo *backpropagation*. O algoritmo utiliza uma função sigmoide nas camadas ocultas como padrão de ativação, e uma função linear na camada de saída, ambas são padrão do algoritmo utilizado pelo *software* e não podem ser alteradas. Um esquema representado a rede neural utilizada é apresentado na Figura 9.

Figura 9 - Exemplo de rede MLP aplicada



Fonte: WEKA (2022)

Os parâmetros alterados foram o número de épocas, o número de camadas ocultas e o número de neurônios por camada.

Nesta etapa foram realizados diversos testes, com diferentes combinações de variáveis. No primeiro teste (Tabela 4) foram utilizadas as onze variáveis principais, e as cinco principais para o segundo.

Tabela 4 - Configurações rede MLP com onze variáveis

(contínua)

Número de camadas ocultas	Neurônios por camada	Épocas					
1	5	500	1000	1500	2000	2500	3000
1	10	500	1000	1500	2000	2500	3000
1	15	500	1000	1500	2000	2500	3000
1	20	500	1000	1500	2000	2500	3000
2	5/5	500	1000	1500	2000	2500	3000
2	5/10	500	1000	1500	2000	2500	3000
2	5/15	500	1000	1500	2000	2500	3000
2	5/20	500	1000	1500	2000	2500	3000
2	10/5	500	1000	1500	2000	2500	3000
2	10/10	500	1000	1500	2000	2500	3000
2	10/15	500	1000	1500	2000	2500	3000
2	10/20	500	1000	1500	2000	2500	3000
2	15/5	500	1000	1500	2000	2500	3000
2	15/10	500	1000	1500	2000	2500	3000
2	15/15	500	1000	1500	2000	2500	3000
2	15/20	500	1000	1500	2000	2500	3000
2	20/5	500	1000	1500	2000	2500	3000
2	20/10	500	1000	1500	2000	2500	3000
2	20/15	500	1000	1500	2000	2500	3000
2	20/20	500	1000	1500	2000	2500	3000

Tabela 4 - Configurações rede MLP com onze variáveis

(contínua)

Número de camadas ocultas	Neurônios por camada	Épocas					
		500	1000	1500	2000	2500	3000
3	5/5/5	500	1000	1500	2000	2500	3000
3	5/5/10	500	1000	1500	2000	2500	3000
3	5/5/15	500	1000	1500	2000	2500	3000
3	5/5/20	500	1000	1500	2000	2500	3000
3	5/10/5	500	1000	1500	2000	2500	3000
3	5/10/10	500	1000	1500	2000	2500	3000
3	5/10/15	500	1000	1500	2000	2500	3000
3	5/10/20	500	1000	1500	2000	2500	3000
3	5/15/5	500	1000	1500	2000	2500	3000
3	5/15/10	500	1000	1500	2000	2500	3000
3	5/15/15	500	1000	1500	2000	2500	3000
3	5/15/20	500	1000	1500	2000	2500	3000
3	5/20/5	500	1000	1500	2000	2500	3000
3	5/20/10	500	1000	1500	2000	2500	3000
3	5/20/15	500	1000	1500	2000	2500	3000
3	5/20/20	500	1000	1500	2000	2500	3000
3	10/5/5	500	1000	1500	2000	2500	3000
3	10/5/10	500	1000	1500	2000	2500	3000
3	10/5/15	500	1000	1500	2000	2500	3000
3	10/5/20	500	1000	1500	2000	2500	3000
3	10/10/5	500	1000	1500	2000	2500	3000
3	10/10/10	500	1000	1500	2000	2500	3000
3	10/10/15	500	1000	1500	2000	2500	3000
3	10/10/20	500	1000	1500	2000	2500	3000
3	10/15/5	500	1000	1500	2000	2500	3000
3	10/15/10	500	1000	1500	2000	2500	3000
3	10/15/15	500	1000	1500	2000	2500	3000
3	10/15/20	500	1000	1500	2000	2500	3000
3	10/20/5	500	1000	1500	2000	2500	3000
3	10/20/10	500	1000	1500	2000	2500	3000
3	10/20/15	500	1000	1500	2000	2500	3000
3	10/20/20	500	1000	1500	2000	2500	3000
3	15/5/5	500	1000	1500	2000	2500	3000
3	15/5/10	500	1000	1500	2000	2500	3000
3	15/5/15	500	1000	1500	2000	2500	3000
3	15/5/20	500	1000	1500	2000	2500	3000
3	15/10/5	500	1000	1500	2000	2500	3000
3	15/10/10	500	1000	1500	2000	2500	3000
3	15/10/15	500	1000	1500	2000	2500	3000
3	15/10/20	500	1000	1500	2000	2500	3000
3	15/15/5	500	1000	1500	2000	2500	3000
3	15/15/10	500	1000	1500	2000	2500	3000
3	15/15/15	500	1000	1500	2000	2500	3000
3	15/15/20	500	1000	1500	2000	2500	3000
3	15/20/5	500	1000	1500	2000	2500	3000

Tabela 4 - Configurações rede MLP com onze variáveis

(conclusão)

Número de camadas ocultas	Neurônios por camada	Épocas					
		500	1000	1500	2000	2500	3000
3	15/20/10	500	1000	1500	2000	2500	3000
3	15/20/15	500	1000	1500	2000	2500	3000
3	15/20/20	500	1000	1500	2000	2500	3000
3	20/5/5	500	1000	1500	2000	2500	3000
3	20/5/10	500	1000	1500	2000	2500	3000
3	20/5/15	500	1000	1500	2000	2500	3000
3	20/5/20	500	1000	1500	2000	2500	3000
3	20/10/5	500	1000	1500	2000	2500	3000
3	20/10/10	500	1000	1500	2000	2500	3000
3	20/10/15	500	1000	1500	2000	2500	3000
3	20/10/20	500	1000	1500	2000	2500	3000
3	20/15/5	500	1000	1500	2000	2500	3000
3	20/15/10	500	1000	1500	2000	2500	3000
3	20/15/15	500	1000	1500	2000	2500	3000
3	20/15/20	500	1000	1500	2000	2500	3000
3	20/20/5	500	1000	1500	2000	2500	3000
3	20/20/10	500	1000	1500	2000	2500	3000
3	20/20/15	500	1000	1500	2000	2500	3000
3	20/20/20	500	1000	1500	2000	2500	3000

Fonte: Autoria Própria (2022)

Após os testes, todas as configurações que obtiveram R superior a 0,5 foram submetidas a novos testes, nos quais foram alterados outros dois parâmetros da rede, a taxa de aprendizado (*Learning Rate*) e o termo responsável por aumentar a velocidade de aprendizado da rede (*momentum*).

Para o segundo grupo de testes foram testadas arquiteturas contendo 5, 10, 15 e (a) neurônios nas camadas ocultas, o número de neurônios (a) que é um padrão utilizado pelo algoritmo, onde ele efetua um cálculo baseado no número de atributos de entrada e de saída, o cálculo é apresentado na Equação 9.

$$a = \frac{(\text{atributos de entrada} + \text{atributos de saída})}{2} \quad (9)$$

Todas as configurações testadas são listadas na Tabela 5.

Tabela 5 - Configurações rede MLP com cinco variáveis

(contínua)

Número de camadas ocultas	Neurônios por camada	Épocas					
		500	1000	1500	2000	2500	3000
1	5	500	1000	1500	2000	2500	3000
1	10	500	1000	1500	2000	2500	3000
1	15	500	1000	1500	2000	2500	3000
1	20	500	1000	1500	2000	2500	3000

Tabela 5 - Configurações rede MLP com cinco variáveis

(conclusão)

Número de camadas ocultas	Neurônios por camada	Épocas					
		500	1000	1500	2000	2500	3000
2	5/5	500	1000	1500	2000	2500	3000
2	5/10	500	1000	1500	2000	2500	3000
2	5/15	500	1000	1500	2000	2500	3000
2	5/a	500	1000	1500	2000	2500	3000
2	10/5	500	1000	1500	2000	2500	3000
2	10/10	500	1000	1500	2000	2500	3000
2	10/15	500	1000	1500	2000	2500	3000
2	10/a	500	1000	1500	2000	2500	3000
2	15/5	500	1000	1500	2000	2500	3000
2	15/10	500	1000	1500	2000	2500	3000
2	15/15	500	1000	1500	2000	2500	3000
2	15/a	500	1000	1500	2000	2500	3000
2	a/5	500	1000	1500	2000	2500	3000
2	a/10	500	1000	1500	2000	2500	3000
2	a/15	500	1000	1500	2000	2500	3000
2	a/a	500	1000	1500	2000	2500	3000

Fonte: Autoria Própria (2022)

5 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados obtidos pelos testes, bem como uma análise em comparação com trabalhos encontrados na literatura, em que foram utilizados os mesmos algoritmos de aprendizado de máquina. Ao todo foram realizados 907 testes a fim de encontrar as arquiteturas que melhor se adaptavam ao conjunto de dados utilizados.

5.1 Seleção das variáveis

Após a seleção do *Ranker*, foram escolhidas as onze variáveis mais influentes, que são listadas por ordem de influência, o coeficiente de correlação de Pearson de corte utilizado foi 0,14045. Para os algoritmos *SMOReg* e *multilayer perceptron* foram realizados testes com as onze variáveis e com as cinco mais influentes. O *Ranker* completo é apresentado na Tabela 6.

Tabela 6 - *Ranker* variáveis mais importantes

Variável	Coeficiente de correlação de Pearson
Absorção	0,4826
T ambiente externo	0,2879
T do galpão de espera	0,2555
T no início do pré- <i>chiller</i>	0,2302
T no final do pré- <i>chiller</i>	0,1970
Massa média	0,1719
T no final do <i>chiller</i> intermediário	0,1576
T no final do <i>chiller</i>	0,1560
T no início do <i>chiller</i>	0,1536
T no início do <i>chiller</i> intermediário	0,1532
T de congelamento	0,1404

Fonte: Autoria Própria (2022)

5.2 RBF

Para a rede RBF foram realizados 100 testes utilizando as onze variáveis principais apontadas pelo *Ranker*. Também foram realizados testes com apenas cinco variáveis de entrada, porém os resultados foram inferiores aos obtidos com os demais algoritmos, e, portanto, não foram considerados relevantes para o trabalho. Os testes foram divididos em cinco etapas, variando-se o número randômico inicial (*Seed*) e o número de neurônios da camada intermediária (*NumFunctions*). A Tabela 7 apresenta os dois melhores e os dois piores resultados, ela contém as informações do número de neurônios da camada intermediária (*NumFunctions*), número randômico inicial

(*Seed*), coeficiente de correlação de Pearson (R), raiz quadrada do erro médio (RMSE) do inglês *root mean squarer error* e o tempo de processamento. Os resultados completos encontram-se no Apêndice A.


Tabela 7 - Resultados RBF

Teste	NumFunctions	Seed	R	RMSE	Tempo (s)
3	3	1	0,6368	0,0977	0,93
2	2	1	0,5743	0,1054	0,65
49	9	3	0,4025	0,1278	2,72
19	19	1	0,3980	0,1257	9,70

Fonte: Autoria Própria (2022)

O teste que apresentou o melhor resultado foi o teste 3, Tabela 7, onde a rede possui três neurônios na camada intermediária e o *seed* utilizado foi 1. A Figura 10 apresenta o gráfico de dispersão entre os valores reais (eixo x) e os valores preditos (eixo y), com base nele é possível observar a baixa correlação entre os dados.

Figura 10 - Melhor resultado rede RBF



Fonte: Autoria Própria (2022)

Sousa (2019) fez uso da rede RBF como mecanismo no diagnóstico da doença HLB (*Huanglongbing*), uma doença de origem chinesa que é considerada a pior doença em frutas cítricas. O trabalho foi realizado com dados coletados em um pomar de tangerina poncã, na ocasião o algoritmo conseguiu prever 93,1% do resultado.

Souza *et al* (2021) utilizou uma rede RBF como ferramenta de apoio ao setor agropecuário, o estudo objetivou a predição da maturação do amendoim com imagens obtidas por um veículo aéreo não tripulado, a rede atingiu 88% de precisão no resultado.

Ambos os trabalhos atingiram uma acurácia maior do que o deste trabalho.

O resultado abaixo do esperado pode ter ocorrido devido aos dados ou ao algoritmo. Em relação aos dados, estes podem conter ruídos que interferem no aprendizado. No tocante ao algoritmo, a rede utilizada é um algoritmo otimizado pelo *software*, alguns parâmetros importantes não podem ser alterados, o principal deles é referente aos centros das funções de base radial.

Haykin (2008) aponta três estratégias que podem ser aplicadas no projeto de uma rede RBF. A primeira é a seleção ao acaso dos centros, no qual os centros são escolhidos aleatoriamente. A segunda é a seleção auto-organizada dos centros, um dos algoritmos mais utilizados para este método é o *k-means*, este é o método utilizado na rede aplicada neste trabalho. A terceira é a seleção supervisionada de centros, o principal procedimento utilizado é a descida do gradiente.

No presente trabalho foi utilizada apenas uma das estratégias, com a aplicação do *k-means*, porém no nosso caso não foi permitido a alteração do valor inicial, limitando-se a exploração do algoritmo.

5.3 SMOReg

Os testes do SMOReg foram divididos em duas etapas, contendo as onze e as cinco variáveis principais, respectivamente, segundo o *Ranker* realizado.

Na primeira etapa foram realizados 80 testes, sendo 8 com a função de ativação polinomial, 36 com a função RBF e 36 com a função PUK. A Tabela 8 apresenta os dois melhores e os dois piores resultados para a função polinomial como função Kernel.

Tabela 8 - Função Polinomial com onze variáveis

Teste	C	Grau	R	RMSE	Tempo (s)
102	1	2	0,4997	0,1146	0,18
101	1	1	0,4868	0,1120	0,06
104	10	2	0,4279	0,1227	1,33
106	100	2	0,3866	0,1318	11,26

Fonte: Autoria Própria (2022)

A Tabela 9 apresenta os dois melhores e os dois piores resultados para a função de base radial (RBF) como função Kernel.

Tabela 9 - Função RBF com onze variáveis

Teste	C	Gama	R	RMSE	Tempo (s)
115	1	0,5	0,5191	0,1128	0,05
123	10	0,2	0,5178	0,1141	0,09

(continua)

Tabela 9 - Função RBF com onze variáveis

Teste	C	Gama	R	RMSE	(conclusão)
					Tempo (s)
144	1000	1	0,3657	0,1786	11,02
109	1	0,001	0,2939	0,1241	0,07

Fonte: Autoria Própria (2022)

A Tabela 10 apresenta os dois melhores e os dois piores resultados para a função PUK como função Kernel.


Tabela 10 - Função PUK com onze variáveis

Teste	C	Ômega	Sigma	R	RMSE	Tempo
178	1000	10	10	0,5244	0,1145	0,55
149	1	2	2	0,5149	0,1139	0,04
174	1000	0,5	1	0,2527	0,3430	17,71
173	1000	0,5	0,5	-0,0370	0,5000	25,12

Fonte: Autoria Própria (2022)

Após a realização de todos os testes com as onze variáveis mais influentes, obtivemos o melhor resultado com o teste 178, no qual foi utilizado a função PUK como função Kernel. A Figura 11 apresenta o gráfico de dispersão do melhor resultado.

Figura 11 - Melhor resultado SMOReg com onze variáveis



Fonte: Autoria própria (2022)

Para a segunda etapa de testes, foram mantidas apenas as cinco variáveis mais influentes apontadas pelo *Ranker*, e a metodologia anterior foi repetida.

A Tabela 11 apresenta os dois melhores e os dois piores resultados dos testes com o *SMOReg*, com a função polinomial como função Kernel.

Tabela 11 - Função Polinomial com cinco variáveis

Teste	C	Grau	R	RMSE	Tempo (s)
182	1	2	0,5228	0,1111	0,09
184	10	2	0,5225	0,1107	0,23
185	100	1	0,4918	0,1118	0,44
181	1	1	0,4902	0,1119	0,10

Fonte: Autoria Própria (2022)

A Tabela 12 apresenta os dois melhores e os dois piores resultados dos testes com o *SMOReg*, com a função RBF como função Kernel.

Tabela 12 - Função RBF com cinco variáveis

Teste	C	Gama	R	RMSE	Tempo (s)
197	1	1	0,5239	0,1091	0,06
196	1	0,7	0,5199	0,1107	0,06
221	1000	0,2	0,4105	0,1210	2,52
189	1	0,001	0,3457	0,1263	0,19

Fonte: Autoria Própria (2022)

A Tabela 13 apresenta os dois melhores e os dois piores resultados dos testes com o *SMOReg*, com a função PUK como função Kernel.


Tabela 13 - Função PUK com cinco variáveis

Teste	C	Ômega	Sigma	R	RMSE	Tempo (s)
225	1	0,1	1	0,5336	0,1112	0,08
230	1	5	5	0,5151	0,1116	0,05
254	1000	0,5	1	0,2210	0,2729	19,77
253	1000	0,5	0,5	-0,0567	0,4404	27,01

Fonte: Autoria Própria (2022)

Após essa etapa de testes, a configuração que apresentou o melhor desempenho foi a do teste 225, novamente utilizando uma função PUK, o algoritmo conseguiu prever 53,36% dos resultados, valor um pouco maior quando comparado com o teste usando as onze variáveis. A Figura 12 apresenta o gráfico de dispersão entre os valores reais e os valores preditos pelo algoritmo.

Figura 12 - Melhor resultado SMOReg com cinco variáveis



Fonte: Autoria Própria (2022)

Para *Gomes et al.* (2010), apesar do alto poder de generalização, os algoritmos SVM dependem diretamente da escolha adequada dos parâmetros e da regularização desses parâmetros, o algoritmo é muito sensível a pequenas modificações. Essa sensibilidade pode ter influenciado nos resultados obtidos neste estudo.

5.4 MultiLayer Perceptron

Para a rede MLP foram realizados 647 testes, divididos em duas etapas. Na primeira foram 504 testes utilizando as onze variáveis principais. Na segunda etapa foram realizados 143 testes utilizando as cinco variáveis principais apontadas pelo *Ranker*.

As tabelas de resultados contêm o número do teste, quantidade de neurônios por camada intermediária, número de épocas de treinamento, o coeficiente de correlação de Pearson, a raiz quadrada do erro médio e o tempo computacional.

A Tabela 14 aponta as duas melhores e as duas piores configurações para a rede com uma camada intermediária.

Tabela 14 - Rede MLP com uma camada e onze variáveis

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
278	15	3000	0,4323	0,1668	5,10
272	10	3000	0,4289	0,1711	3,56
261	5	500	0,2789	0,1822	0,21
274	15	1000	0,2720	0,1808	1,78

Fonte: Autoria Própria (2022)

A Tabela 15 mostra os dois melhores e os dois piores resultados para a rede com duas camadas intermediárias.

Tabela 15 - Rede MLP com duas camadas e onze variáveis

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
310	10/5	1000	0,5248	0,1621	1,30
365	20/10	1500	0,5228	0,1658	8,94
325	10/15	2500	0,1683	0,2095	5,29
326	10/15	3000	0,1096	0,2267	6,00

Fonte: Autoria Própria (2022)

A Tabela 16 exhibe as duas melhores e as duas piores configurações para a rede com três camadas intermediárias.

Tabela 16 - Rede MLP com três camadas e onze variáveis

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
646	15/20/5	1000	0,5276	0,1655	3,95
645	15/20/5	500	0,5261	0,1846	2,39
674	20/5/5	3000	0,4265	0,1605	8,01
673	20/5/5	2500	0,4447	0,1569	5,65

Fonte: Autoria Própria (2022)

A configuração que apresentou o melhor resultado foi o teste 646, uma rede com três camadas ocultas, que conseguiu prever 52,76% dos resultados.

Na sequência todos os resultados com R superior a 0,5000 foram submetidos a novos testes, alterando-se os parâmetros *Learning Rate* e *momentum*. Os resultados são exibidos na Tabela 17.

Tabela 17 - Rede MLP ajuste de *Learning Rate* e *momentum*

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)	LR	Momentum
765	10/5	1000	0,5308	0,1608	1,23	0,3	0,1
766	20/10	1000	0,5294	0,1685	2,73	0,4	0,1
767	20/10	1500	0,5228	0,1658	8,94	0,3	0,2
768	5/10/5	500	0,5460	0,1368	0,50	0,1	0,6
769	5/15/5	500	0,5517	0,1412	0,72	0,1	0,7
770	5/20/5	500	0,5546	0,1477	0,84	0,1	0,8
771	5/20/15	1000	0,5308	0,1437	3,65	0,1	0,8
772	10/5/15	1000	0,5091	0,1525	2,45	0,2	0,2
773	10/10/10	500	0,5441	0,1374	1,18	0,1	0,6
774	10/15/5	500	0,5544	0,1431	1,07	0,1	0,7
775	10/20/5	500	0,5579	0,1436	1,36	0,1	0,7
776	10/20/10	500	0,5407	0,1397	1,78	0,1	0,6
777	15/5/5	500	0,5287	0,1604	0,77	0,2	0,2
778	15/10/15	500	0,5359	0,1382	0,92	0,1	0,5
779	15/15/10	500	0,5248	0,1587	2,20	0,2	0,2
780	15/15/20	500	0,5424	0,1389	1,73	0,1	0,6
781	15/20/5	500	0,5475	0,1701	1,98	0,1	0,9

(continua)


Tabela 17 - Rede MLP ajuste de *Learning Rate* e *momentum*

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)	(conclusão)	
						LR	Momentum
782	15/20/5	1000	0,5516	0,1548	3,51	0,2	0,4
783	15/20/10	500	0,5437	0,1390	2,09	0,1	0,6
784	15/20/20	500	0,5415	0,1378	3,27	0,1	0,6

Fonte: Autoria Própria (2022)

Após os ajustes apenas o teste 767 não apresentou melhora nos resultados, os demais tiveram uma pequena melhora, com isso o teste 775 foi o melhor, atingindo 55,79% de acerto na previsão dos resultados. A baixa correlação pode ser observada na Figura 13.

Figura 13 - Melhor resultado MLP com onze variáveis



Fonte: Autoria Própria (2022)

Para a segunda etapa, o número de variáveis foi reduzido, sendo utilizadas as cinco principais apontadas pelo *Ranker*.

A Tabela 18 contém os dois melhores e dois piores resultados para a rede com uma camada intermediária.

Tabela 18 - Rede MLP com uma camada e cinco variáveis

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
791	10	500	0,5057	0,1667	0,25
797	15	500	0,4966	0,1672	0,37
787	5	1500	0,3969	0,1704	0,54
796	10	3000	0,3816	0,1701	1,22

Fonte: Autoria Própria (2022)

A Tabela 19 contém os dois melhores e os dois piores resultados para a rede com duas camadas intermediárias.

Tabela 19 - Rede MLP com duas camadas e cinco variáveis

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
832	5/a	3000	0,5552	0,1769	1,22
856	10/a	3000	0,5441	0,1740	2,87
897	a/15	2500	0,4114	0,1757	1,74
898	a/15	3000	0,4079	0,1761	2,86

Fonte: Autoria Própria (2022)

Nesta etapa a configuração que apresentou melhor resultado foi o teste 832, na qual a rede é composta por duas camadas e foram aplicadas 3000 épocas de treinamento, a rede atingiu 55,52% de acerto.

As três melhores configurações foram submetidas a mais uma bateria de testes, onde foram testadas diferentes combinações de taxa de aprendizado (*Learning Rate*) e o *Momentum* e o resultado é apresentado na Tabela 20.

Tabela 20 - Resultados rede MLP com cinco variáveis após ajustes

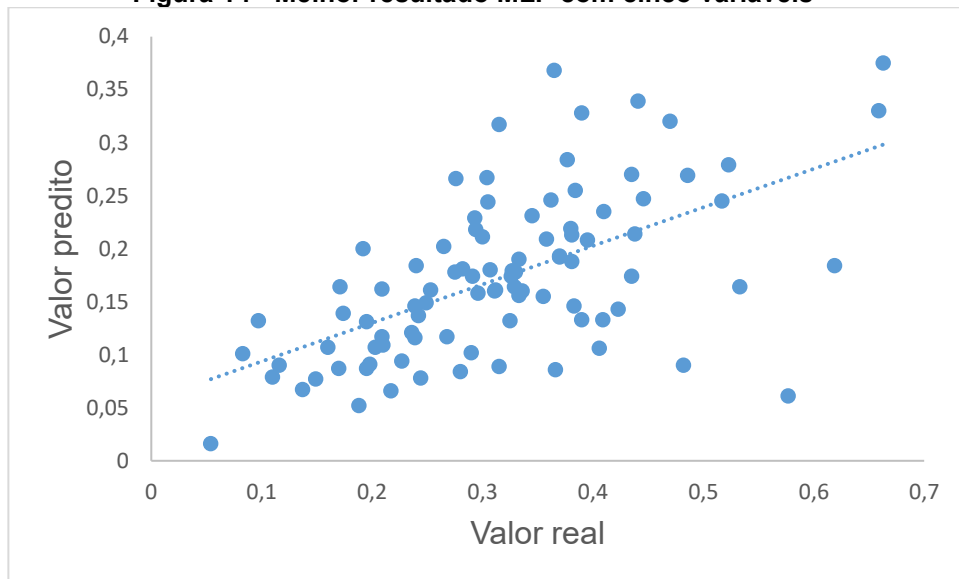
Teste	Neurônios	Épocas	R	RMSE	Tempo (s)	LR	Momentum
905	5/a	3000	0,5848	0,1754	1,08	0,3	0,5
906	10/a	3000	0,5524	0,1757	1,78	0,3	0,4
907	5/a	2500	0,5656	0,1932	0,77	0,3	0,5

Fonte: Autoria Própria (2022)

A configuração que obteve o melhor desempenho foi a do teste 905, onde foram otimizados a taxa de aprendizado e o termo referente a velocidade do aprendizado, o resultado foi superior ao obtido na etapa contendo onze variáveis. Esse resultado é muito interessante para a indústria, com menos variáveis para serem controladas, necessita-se uma quantidade menor de controladores para o processo, proporcionando uma economia financeira para a implementação do sistema, além de o algoritmo obter um ganho computacional significativo. Com onze variáveis o tempo computacional foi de 3,95 segundos, contra 1,08 segundos para a melhor configuração com cinco variáveis.

Pela Figura 14 é possível observar que a correlação entre os valores reais e os valores previstos foi baixa.

Figura 14 - Melhor resultado MLP com cinco variáveis



Fonte: Autoria Própria (2022)

Porém, os resultados foram abaixo do obtido em outros trabalhos com algoritmos de aprendizado de máquina.

Como apontado por Pinto (2021), uma das hipóteses para o resultado abaixo do esperado é a falta de dados relacionados ao congelamento, sendo que no banco de dados utilizados, esta variável não foi mensurada. Passarelli (2018) realizou um estudo sobre túneis de congelamento onde foi concluído que as variáveis presentes nessa etapa são responsáveis pela formação de cristais de gelo. É comprovado bioquimicamente que os cristais de gelo causam ruptura das células, causando exsudação no descongelamento com perda de nutrientes e interferindo no *drip test* (PINTO, 2021).

5.5 Selecionando o melhor algoritmo

Para a validação dos resultados, foram utilizados o coeficiente de correlação de Pearson (R) e a raiz quadrada do erro médio (RMSE).

Além da correlação e do erro, outro fator importante observado foi o tempo computacional, tempos muito altos podem inviabilizar uma aplicação industrial, ou uma aplicação onde é necessária uma resposta rápida, como em sistemas de monitoramento em tempo real.

O melhor resultado para cada um dos algoritmos testados com onze variáveis é apresentado na Tabela 21.

Tabela 21 - Comparação melhores configurações com onze variáveis

Teste	Algoritmo	R	RMSE	Tempo (s)
3	Rede RBF	0,6368	0,0977	0,93
178	SMOreg	0,5244	0,1145	0,55
775	MLP	0,5579	0,1436	1,36

Fonte: Autoria Própria (2022)

A Tabela 22 exibe os melhores resultados com algoritmos testados utilizando cinco variáveis.

Tabela 22 - Comparação melhores configurações com cinco variáveis

Teste	Algoritmo	R	RMSE	Tempo (s)
225	SMOreg	0,5336	0,1112	0,08
905	MLP	0,5848	0,1754	1,08

Fonte: Autoria Própria

Com base nos resultados apresentados, o algoritmo com melhor acurácia foi a rede RBF, conseguindo prever 63,68% dos resultados, o valor é baixo para fins de aplicação industrial, mas é bastante promissor, conseguindo uma melhora considerável em relação ao estudo realizado por Pinto (2021), que foi o único encontrado na literatura que aborda o mesmo tema.

Com relação ao SMOReg e ao MLP, houve uma melhora quando os testes foram realizados com apenas cinco variáveis. O resultado tem grande relevância para a indústria, a utilização de um algoritmo que consiga obter bons resultados com menos variáveis, alcança um ganho econômico, sendo necessário a implantação de menos equipamentos para o controle do processo. Além do ganho computacional, que otimiza sistemas que necessitam de respostas rápidas, principalmente sistemas de monitoramento em tempo real.

5.6 Identificando as variáveis mais importantes

Não foram encontrados dados referentes as variáveis mais influentes no resultado do *drip test*. A literatura é concentrada no processo de absorção, por tanto neste trabalho iremos nos basear nos trabalhos referentes as variáveis mais influentes na absorção de água nas carcaças das aves.

Os principais trabalhos relacionados a absorção de água são o de Klassen (2008), Carciofi (2005), Carciofi e Laurindo (2007), Martins *et al.*, (2011), Sant'anna (2008) e Vieira *et al.* (2016). As principais variáveis apontadas pelos estudos foram a massa inicial, temperatura inicial do pré *chiller*, vazão de borbulhamento, temperatura inicial do *chiller*, temperatura final do *chiller*, massa, tempo de resfriamento, pressão

da coluna d'água, temperatura ambiente, quantidade de gelo nos tanques, tempo de permanência no *chiller* e a absorção.

Para o presente estudo, não foi possível obter valores referentes a vazão de borbulhamento, pressão da coluna d'água e quantidade de gelo nos tanques. Tais informações não estavam presentes no conjunto de dados utilizados para os testes.

A obtenção das variáveis mais influentes em cada um dos resultados é possível através do *Ranker*, para este estudo foi utilizada a opção *ClassifierAttributeEval*. O procedimento é similar ao utilizado no pré-processamento dos dados, sendo necessário apenas o ajuste dos dados da arquitetura do algoritmo e a indicação do coeficiente de correlação de Pearson na guia *evaluationMeasure*.

O coeficiente de correlação de Pearson indica a importância da variável para o resultado, seu valor varia entre -1 e 1, e quanto mais próximo de 1 maior é sua influência. Valores próximos a 0 indicam pouca correlação e valores próximos a -1 indicam que existe correlação, porém em direções opostas, ou seja, quando uma variável aumenta, a outra diminui.

Foram analisadas a melhor e a pior configuração de cada um dos algoritmos testados e verificado se as variáveis indicadas pelo software coincidem com as encontradas na literatura.

5.6.1 Rede RBF

Para a rede RBF foram utilizados os testes 3 e 19, melhor e pior respectivamente. A classificação das variáveis é apresentada no Quadro 2.

Quadro 2 - Classificação das variáveis rede RBF

Melhor			Pior	
Coeficiente	Variável		Coeficiente	Variável
0,6100	Absorção		0,5480	Absorção
0,4770	Temperatura ambiente		0,4910	Massa média
0,4220	Temperatura do galpão de espera		0,4790	Temperatura do galpão de espera
0,4150	T no início do pré <i>chiller</i>		0,4590	Temperatura ambiente
0,3750	T no final do pré <i>chiller</i>		0,4480	T no início do pré <i>chiller</i>
0,3500	Massa média		0,4400	T no final do pré <i>chiller</i>
0,3000	T no final do <i>chiller</i>		0,4300	T no final do <i>chiller</i>

0,2950	T no final do <i>chiller</i> intermediário		0,4240	T no final do <i>chiller</i> intermediário
0,2430	T no início do <i>chiller</i>		0,4200	T no início do <i>chiller</i>
0,2370	T de congelamento		0,4170	T no início do <i>chiller</i> intermediário
0,2370	T no início do <i>chiller</i> intermediário		0,2500	T de congelamento

Fonte: Autoria Própria (2022)

A classificação obtida pela melhor configuração apresenta a absorção, temperatura ambiente, temperatura do galpão de espera e temperatura no início do pré *chiller* como as quatro principais, todas condizentes com as variáveis apontadas pela literatura.

Em relação a pior configuração as quatro principais foram: absorção, massa média, temperatura do galpão de espera e a temperatura ambiente, todas de acordo com a literatura.

Dessa forma, é possível observar que o algoritmo conseguiu correlacionar bem as variáveis de acordo com a literatura, o que demonstra a eficiência das redes RBF para mineração de dados.

5.6.2 SMOReg

Para o SMOReg com onze variáveis foram utilizados os testes 178 e 173, melhor e pior, respectivamente. A classificação das variáveis é apresentada no Quadro 3.

Quadro 3 - Classificação das variáveis SMOReg com onze variáveis

Melhor			Pior	
Coefficiente	Variável		Coefficiente	Variável
0,4830	Absorção		0,4171	Absorção
0,3000	T do galpão de espera		0,3353	T do galpão de espera
0,3000	T ambiente		0,3144	T no início do pré <i>chiller</i>
0,2350	T no início do pré <i>chiller</i>		0,2937	T ambiente
0,1830	T no final do pré <i>chiller</i>		0,2884	Massa média
0,1420	T no final do <i>chiller</i>		0,2774	T no final do <i>chiller</i>

0,1350	T no final do <i>chiller</i> intermediário		0,2736	T no final do pré <i>chiller</i>
0,1320	Massa média		0,2719	T no final do <i>chiller</i> intermediário
0,1280	T no início do <i>chiller</i>		0,1289	T de congelamento
0,1280	T no início do <i>chiller</i> intermediário		0,0838	T no início do <i>chiller</i> intermediário
0,1060	T de congelamento		0,0822	T no início do <i>chiller</i>

Fonte: Autoria Própria (2022)

Para o SMOReg com cinco variáveis foram utilizados os testes 225 e 253, a classificação das variáveis é apresentada no Quadro 4.

Quadro 4 - Classificação das variáveis SMOReg com cinco variáveis

Melhor			Pior	
Coeficiente	Variável		Coeficiente	Variável
0,4330	Absorção		0,4170	Absorção
0,3430	T do galpão de espera		0,3360	T do galpão de espera
0,3300	T no início do pré <i>chiller</i>		0,3140	T no início do pré <i>chiller</i>
0,2930	T ambiente		0,2940	T ambiente
0,2670	T no final do pré <i>chiller</i>		0,2730	T no final do pré <i>chiller</i>

Fonte: Autoria Própria (2022)

As classificações obtidas pelo SMOReg, com onze e cinco variáveis, apresentaram as mesmas variáveis entre as quatro principais. Todas são corroboradas pela literatura.

O resultado é promissor, além de conseguir identificar as variáveis de acordo com a literatura, o algoritmo mostrou-se consistente, obtendo as mesmas variáveis nos testes com a melhor e com a pior configuração.

5.6.3 MultiLayer Perceptron

Para o MLP com onze variáveis foram utilizados os testes 775 e 326, melhor e pior, respectivamente. A classificação é apresentada no Quadro 5.

Quadro 5 - Classificação das variáveis rede MLP com onze variáveis

Melhor			Pior	
Coeficiente	Variável		Coeficiente	Variável
0,5060	Absorção		0,4171	Absorção

0,3750	T ambiente		0,3353	T do galpão de espera
0,2350	T no início do pré <i>chiller</i>		0,3144	T no início do pré <i>chiller</i>
0,2300	T do galpão de espera		0,2937	T ambiente
0,2100	T no final do pré <i>chiller</i>		0,2884	Massa média
0,2100	T no início do <i>chiller</i>		0,2774	T no final do <i>chiller</i>
0,2100	T no início do <i>chiller</i> intermediário		0,2736	T no final do pré <i>chiller</i>
0,2100	T de congelamento		0,2719	T no final do <i>chiller</i> intermediário
0,2070	Massa média		0,1289	T de congelamento
0,2050	T no final do <i>chiller</i> intermediário		0,0838	T no início do <i>chiller</i> intermediário
0,2050	T no final do <i>chiller</i>		0,0822	T no início do <i>chiller</i>

Fonte: Autoria Própria (2022)

Para a rede MLP com cinco variáveis foram utilizados os testes 832 e 796, melhor e pior, respectivamente. A classificação é apresentada no Quadro 6.

Quadro 6 - Classificação das variáveis rede MLP com cinco variáveis

Melhor			Pior	
Coeficiente	Variável		Coeficiente	Variável
0,5550	Absorção		0,5460	Absorção
0,4450	T do galpão de espera		0,4360	T do galpão de espera
0,4200	T ambiente		0,3810	T ambiente
0,3520	T no início do pré <i>chiller</i>		0,2950	T no início do pré <i>chiller</i>
0,3220	T no final do pré <i>chiller</i>		0,2600	T no final do pré <i>chiller</i>

Fonte: Autoria Própria (2022)

Assim como nas classificações obtidas pelo SMOReg, a rede MLP obteve as mesmas variáveis como as quatro principais, são elas absorção, temperatura ambiente, temperatura do galpão de espera e temperatura no início do pré *chiller*.

Os resultados foram satisfatórios, os algoritmos conseguiram realizar a classificação das variáveis em concordância com a literatura.

A semelhança das classificações dos diferentes algoritmos já era esperada, isso ocorre devido ao pré-processamento dos dados, onde as variáveis para estudo já haviam sido escolhidas de acordo com o *Ranker* do WEKA.

6 CONCLUSÃO

Os algoritmos realizaram uma predição razoável. A rede RBF obteve o melhor resultado, atingindo um valor de 0.6368 de coeficiente de correlação, a rede MLP para os testes com onze e com cinco variáveis de entrada foram próximos, atingiu 0,5579 e 0,5848 de coeficiente de correlação e o SMOReg também obteve resultados similares para os testes com onze e com cinco variáveis de entrada, ambos resultados foram utilizando a função PUK como função Kernel, com onze variáveis o algoritmo atingiu 0,5244 de coeficiente de correlação e 0,5336 de coeficiente de correlação para cinco variáveis.

Os resultados foram abaixo do atingido em outros trabalhos, porém foram promissores, podendo evoluir em trabalhos futuros. O SMOReg e a rede MLP melhoraram a capacidade de predição através da redução das variáveis de entrada, esse resultado é interessante para uma aplicação industrial, sendo necessário o controle de menos variáveis o que torna a implantação mais atraente financeiramente.

Com relação a previsão das variáveis mais influentes, os algoritmos apontaram a absorção, temperatura do galpão de espera, temperatura ambiente, temperatura no início do pré-*chiller* e a massa média como as mais influentes no resultado. Destas cinco variáveis, quatro estão de acordo com as informações encontradas na literatura, apenas a temperatura do galpão de espera não foi citada em outros estudos, porém seu resultado era esperado, devido ao valor da temperatura do galpão de espera ser muito próximo ao da temperatura ambiente. Portanto podemos afirmar que os algoritmos conseguiram realizar a previsão das variáveis mais influentes.

SUGESTOES PARA TRABALHOS FUTUROS

- Utilizar outro software para a realização dos testes;
- Testar outras arquiteturas, principalmente com a rede RBF;
- Utilizar outro banco de dados;
- Realizar uma coleta de dados onde inclua os dados referentes ao congelamento.

REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL - ABPA. **RELATÓRIO ANUAL, 2022.**
- AYAT, Nedjem Eddine, Mohamed Cheriet e Ching Y Suen: **Automatic model selection for the optimization of svm kernels.** *Pattern Recognition*, 38(10):1733–1745, 2005.
- BRAGA, A. DE P. **Redes neurais artificiais: teoria e aplicações.** 2ª ed. Rio de Janeiro: LTC, 2007.
- BRASIL. **Portaria Nº 210 de 10 de novembro de 1998. Regulamento técnico de inspeção tecnológica e higiênico sanitária de carne de aves.** Diário Oficial da União, n. 9, p. 1689–1699, 1998.
- BRASIL. **INSTRUÇÃO NORMATIVA Nº 20, DE 21 DE JULHO DE 1999.** Diário Oficial da União, 1999.
- BRASIL. **Portaria Nº 74 de 7 de maio de 2019.** Diário Oficial da União, 2019.
- BORTOLETI, G. B. **USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA PARA PREDIÇÃO E CLASSIFICAÇÃO DE VARIÁVEIS DE INTERESSE EM PROCESSO INDUSTRIAL DE ABATE DE FRANGO,** 2021.
- CARCIOFI, B. A. M. **ESTUDO DO RESFRIAMENTO DE CARÇAÇAS DE FRANGO EM CHILLER DE IMERSÃO EM ÁGUA,** 2005.
- CARCIOFI, B. A. M.; LAURINDO, J. B. Water uptake by poultry carcasses during cooling by water immersion. **Chemical Engineering and Processing: Process Intensification**, v. 46, n. 5, p. 444–450, 1 maio 2007.
- FACELI, K. et al. **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina.** 2ª ed. Porto Alegre: Grupo GEN, 2021.
- FRANK, E. **Fully supervised training of Gaussian radial basis function networks in WEKA.** Hamilton, NZ: Department of Computer Science, The University of Waikato, 2014.
- FRIES, G. **AVALIAÇÃO DA PERDA DE ÁGUA EM CARÇAÇAS DE FRANGO POR DRIPPING TESTE EM UM FRIGORÍFICO DO VALE DO TAQUARI,** 2017.
- GOMES, T. A. F. *et al.* **Combining meta-learning and search techniques to svm parameter selection.** Em Neural Networks (SBRN), 2010 Eleventh Brazilian Symposium on, páginas 7984. IEEE, 2010.
- HAYKIN, S. **Redes Neurais: Princípios e Prática.** 2ª ed. Ontário: Bookman, 2007.
- HSU, Chih Wei, Chih Chung Chang, Chih Jen Lin et al.: **A practical guide to support vector classification.** 2003.

KLASSEN, T. Uso De Redes Neurais Artificiais Para a Modelagem Da Temperatura E Da Retenção De Água No Processo De Resfriamento De Carcaças De Frangos Por Imersão, 2008.

KLASSEN, T. *et al.* Modelagem do sistema de resfriamento por imersão de carcaças de frangos utilizando redes neurais artificiais. **Acta Scientiarum - Technology**, v. 31, n. 2, p. 201–205, jul. 2009.

LIMA, P. C. DE *et al.* Espectroscopia de Infravermelho Médio e Máquinas de Vetor Suporte Aplicados ao Controle do Processo de Hidrogenação do Óleo de Soja. **Seminário de Iniciação Científica e Tecnológica**, 2017.

LORENA, A. C.; CARVALHO, A. C. P. L. F. DE. Uma Introdução às Support Vector Machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 20 dez. 2007.

LORENZETTI, E. **Estudo das variáveis que interferem na absorção de água em carcaças e cortes de frango durante e atapa de pré-resfriamento**, 2016.

MARTINS, T. D. *et al.* **Modeling the water uptake by chicken carcasses during cooling by immersion.**, vol.31 no.3 Campinas, julho/setembro 2011.

MICHELON, G. K. *et al.* MÁQUINA DE VETORES DE SUPORTE PARA ESTIMAR A PRODUTIVIDADE DA SOJA. **periodicos.ufv.br**, 2017.

MOGUERZA, J. M.; MUÑOZ, A. **Support vector machines with applications.** Statistical Science, páginas 322–336, 2006. pg 14

MORETTI, C. LUIZ. **Investir em pesquisa agropecuária traz retorno para a sociedade brasileira.** seer.sede.embrapa.br, 2020.

MÜLLER, T. B. **Aplicação De Redes Neurais Artificiais Na Avicultura Comercial**, 2019.

OTT, E.; SARTORI, A. **PREDIÇÃO DE PESO NA CRIAÇÃO DE FRANGO DE CORTE UTILIZANDO REDES NEURAS ARTIFICIAIS.** dsc.inf.furb.br, 2018.

PASSARELLI, G. L. **Utilização do túnel de retenção variável (TRV) para congelamento.** Cascavel: Revista Agricultura Industria, 2018.

PINHEIRO, T. C. **Gestão da produção de frangos de corte por meio de redes neurais artificiais** Universidade Tecnológica Federal do Paraná, , 27 mar. 2020. Disponível em: <<http://repositorio.utfpr.edu.br:8080/jspui/handle/1/25458>>. Acesso em: 11 jul. 2021

PINTO, M. C. L. **Utilização de algoritmos de aprendizagem de máquina para predição de absorção de água nas carcaças de frango: aplicação de redes neurais artificiais.** 24 fev. 2021.

PRESTES, C. **Predição de produtividade de trigo por meio de dados espectrais e altura estimada da planta obtidos por meio de aeronave remotamente pilotada**, 2020. Disponível em: <<https://tede2.uepg.br/jspui/handle/prefix/3276>>. Acesso em: 25 jul. 2021

REALI, E. **Utilização de inteligência artificial-(Redes Neurais Artificiais) no gerenciamento da produção de frangos de corte**, 2004. Disponível em: <<https://www.lume.ufrgs.br/handle/10183/6339>>. Acesso em: 25 jul. 2021

ROSA, K. R. **Fatores Que Interferem Na Absorção De Água Em Carcaças De Frango**, 2014.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3ª ed. Rio de Janeiro: Grupo GEN, 2013.

SANT'ANNA, V. **ANÁLISE DOS FATORES QUE AFETAM A TEMPERATURA E ABSORÇÃO DE ÁGUA DE CARCAÇAS DE FRANGO EM CHILLER INDUSTRIAL**, 2008.

SEVEGNANI, K. B. *et al.* ESTUDO DA INFLUÊNCIA DE FATORES AMBIENTAIS EM VARIÁVEIS FISIOLÓGICAS DE FRANGOS DE CORTE COM REDES NEURAIS ARTIFICIAIS. **researchgate.net**, 2017.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais PARA ENGENHARIA E CIÊNCIAS APLICADAS**. 2ª ed. São Paulo: Artliber, 2019.

SILVA, T. F. *et al.* Impacto Dos Fatores Pré-Abate No Dripping Test De Carcaças De Frango: Uso De Redes Neurais. In: **Ensino e Pesquisa no Campo da Engenharia e da Tecnologia de Alimentos**. [s.l.] Atena Editora, 2021. p. 120–129.

SOUSA, Roney Nogueira de. *et al.* **Aplicação da Rede Neural RBF Como Mecanismo Auxiliador no Diagnóstico da Doença HLB em Espécies Cítricas**. Em: ESCOLA REGIONAL DE COMPUTAÇÃO APLICADA À SAÚDE (ERCAS), 7. , 2019, Teresina. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2019 . p. 55-60.

SOUZA, J. B. C. *et al.* **Uso de redes neurais para predição da maturação do amendoim com imagens de UAV**. South American Sciences, v. 2, n. edesp2, p. e21129–e21129, 30 set. 2021.

SPOHR, A. **Gerenciamento através de redes neurais artificiais das atividades de produção de reprodutoras pesadas e do frango de corte, de um incubatório e de um abatedouro**, 2011. Disponível em: <<https://www.lume.ufrgs.br/handle/10183/36860>>. Acesso em: 25 jul. 2021

VAPNIK, Vladimir: **The nature of statistical learning theory**. Springer science & business media, 2013.

VIEIRA, F.M.C. *et al.* **Influência das condições térmicas do galpão de espera climatizado na mortalidade pré-abate de frangos de corte**. Arquivo Brasileiro de Medicina Veterinária e Zootecnia [online]. 2016, v. 68, n. 2 [Acessado 29 Junho 2022] , pp. 475-482. Disponível em: <<https://doi.org/10.1590/1678-4162-7872>>

VOGADO, G. M. S. *et al.* Evolução da avicultura brasileira. **Nucleus Animalium, ISSN-e 2175-1463, Vol. 8, Nº. 1, 2016, págs. 49-58**, v. 8, n. 1, p. 49–58, 2016.

ZHOU, L. *et al.* **Application of Deep Learning in Food: A Review** **Comprehensive Reviews in Food Science and Food Safety** John Wiley & Sons, Ltd, , 1 nov. 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/1541-4337.12492>>. Acesso em: 14 jul. 2021

APÊNDICE A - RESULTADOS DOS TESTES REDE RBF

Teste	NumFunctions	Seed	R	RMSE	Tempo (s)
1	1	1	0.5299	0.1095	0.27
2	2	1	0.5743	0.1054	0.65
3	3	1	0.6368	0.0977	0.93
4	4	1	0.5434	0.1085	2.11
5	5	1	0.5249	0.1115	0.10
6	6	1	0.5021	0.1143	0.11
7	7	1	0.4495	0.1208	4.77
8	8	1	0.4610	0.1204	1.24
9	9	1	0.4451	0.1244	5.90
10	10	1	0.4382	0.1221	7.43
11	11	1	0.4348	0.1324	8.60
12	12	1	0.4102	0.1287	6.29
13	13	1	0.5134	0.1195	8.54
14	14	1	0.4680	0.1309	12.41
15	15	1	0.5059	0.1201	12.09
16	16	1	0.5319	0.1169	6.48
17	17	1	0.5175	0.1198	8.65
18	18	1	0.4821	0.1293	9.49
19	19	1	0.3980	0.1257	9.70
20	20	1	0.472	0.1169	8.12
21	1	2	0.5299	0.1095	0.20
22	2	2	0.5576	0.1085	0.36
23	3	2	0.5337	0.1078	0.94
24	4	2	0.5384	0.1102	1.57
25	5	2	0.5172	0.1120	1.95
26	6	2	0.5021	0.1143	1.06
27	7	2	0.4422	0.1237	4.02
28	8	2	0.4610	0.1204	5.46
29	9	2	0.4641	0.1216	5.81
30	10	2	0.4128	0.1250	2.60
31	11	2	0.4809	0.1197	4.73
32	12	2	0.5016	0.1203	9.06
33	13	2	0.5062	0.1204	4.60
34	14	2	0.4807	0.1217	8.79
35	15	2	0.4901	0.1235	10.97
36	16	2	0.4849	0.1206	11.08
37	17	2	0.4536	0.1309	8.01
38	18	2	0.4788	0.1304	5.67
39	19	2	0.4830	0.1267	11.30
40	20	2	0.4524	0.1212	10.12
41	1	3	0.5299	0.1095	0.27
42	2	3	0.4968	0.1116	0.59

43	3	3	0.5709	0.1059	0.62
44	4	3	0.5108	0.1143	1.22
45	5	3	0.5135	0.1112	2.39
46	6	3	0.4777	0.1163	2.12
47	7	3	0.4663	0.1183	3.76
48	8	3	0.4457	0.1213	5.41
49	9	3	0.4025	0.1278	2.72
50	10	3	0.4862	0.1217	4.46
51	11	3	0.4469	0.1249	5.21
52	12	3	0.5190	0.1171	5.63
53	13	3	0.4819	0.1225	14.70
54	14	3	0.5130	0.1178	7.97
55	15	3	0.5214	0.1187	9.09
56	16	3	0.4743	0.1254	5.70
57	17	3	0.4870	0.1246	5.32
58	18	3	0.4833	0.1260	7.57
59	19	3	0.4592	0.1330	11.68
60	20	3	0.4177	0.1343	16.03
61	1	4	0.5299	0.1095	0.18
62	2	4	0.5743	0.1054	0.59
63	3	4	0.4723	0.1175	0.85
64	4	4	0.4988	0.1164	2.03
65	5	4	0.4565	0.1194	1.79
66	6	4	0.4489	0.1209	3.17
67	7	4	0.4519	0.1217	2.30
68	8	4	0.4556	0.1215	2.46
69	9	4	0.4641	0.1216	6.40
70	10	4	0.4618	0.1218	5.21
71	11	4	0.4711	0.1218	3.33
72	12	4	0.4823	0.1222	5.51
73	13	4	0.4553	0.1259	7.19
74	14	4	0.5202	0.1199	8.22
75	15	4	0.5140	0.1206	10.32
76	16	4	0.4337	0.1363	5.59
77	17	4	0.4362	0.1325	7.89
78	18	4	0.4662	0.1330	12.23
79	19	4	0.4869	0.1265	10.73
80	20	4	0.4300	0.1371	10.14
81	1	5	0.5299	0.1095	0.24
82	2	5	0.4972	0.1117	0.62
83	3	5	0.5349	0.1076	2.06
84	4	5	0.5434	0.1085	1.45
85	5	5	0.5241	0.1116	1.66
86	6	5	0.5000	0.1150	4.08
87	7	5	0.4661	0.1184	1.19

88	8	5	0.4494	0.1217	3.73
89	9	5	0.4632	0.1213	6.20
90	10	5	0.4272	0.1253	6.65
91	11	5	0.4390	0.1247	4.55
92	12	5	0.4753	0.1232	5.85
93	13	5	0.5017	0.1209	5.50
94	14	5	0.4991	0.1216	6.03
95	15	5	0.4772	0.1267	5.24
96	16	5	0.4299	0.1277	7.46
97	17	5	0.4847	0.1296	7.83
98	18	5	0.5236	0.1223	16.87
99	19	5	0.4535	0.1196	11.32
100	20	5	0.5080	0.1218	7.40

APÊNDICE B - RESULTADOS DOS TESTES COM O ALGORITMO SMOReg COM ONZE VARIÁVEIS E FUNÇÃO POLINOMIAL COMO FUNÇÃO KERNEL

Teste	C	Grau	R	RMSE	Tempo (s)
101	1	1	0.4868	0.1120	0.06
102	1	2	0.4997	0.1146	0.18
103	10	1	0.4851	0.1123	0.20
104	10	2	0.4279	0.1227	1.33
105	100	1	0.4855	0.1123	1.35
106	100	2	0.3866	0.1318	11.26
107	1000	1	0.4842	0.1126	11.88
108	1000	2	0.4308	0.1266	92.29

**APÊNDICE C - RESULTADOS DOS TESTES COM O ALGORITMO SMOReg COM
ONZE VARIÁVEIS E FUNÇÃO RBF COMO FUNÇÃO KERNEL**

Teste	C	Gama	R	RMSE	Tempo (s)
109	1	0.001	0.2939	0.1241	0.07
110	1	0.01	0.4320	0.1172	0.04
111	1	0.02	0.4734	0.1146	0.01
112	1	0.05	0.4701	0.1141	0.05
113	1	0.1	0.4695	0.1150	0.01
114	1	0.2	0.4892	0.1135	0.04
115	1	0.5	0.5191	0.1128	0.05
116	1	0.7	0.5153	0.1139	0.05
117	1	1	0.5160	0.1144	0.06
118	10	0.001	0.4318	0.1173	0.02
119	10	0.01	0.4834	0.1122	0.03
120	10	0.02	0.4590	0.1160	0.02
121	10	0.05	0.4881	0.1142	0.03
122	10	0.1	0.5016	0.1135	0.04
123	10	0.2	0.5178	0.1141	0.09
124	10	0.5	0.4478	0.1214	0.12
125	10	0.7	0.3861	0.1308	0.15
126	10	1	0.3697	0.1354	0.18
127	100	0.001	0.4953	0.1112	0.02
128	100	0.01	0.4671	0.1163	0.04
129	100	0.02	0.4939	0.1138	0.09
130	100	0.05	0.5124	0.1147	0.12
131	100	0.1	0.5135	0.1150	0.24
132	100	0.2	0.4103	0.1258	0.43
133	100	0.5	0.3786	0.1387	0.71
134	100	0.7	0.4126	0.1387	0.82
135	100	1	0.4288	0.1429	1.03
136	1000	0.001	0.4759	0.1144	0.04
137	1000	0.01	0.5008	0.1141	0.25
138	1000	0.02	0.5153	0.1146	0.37
139	1000	0.05	0.5010	0.1159	1.02
140	1000	0.1	0.3713	0.1342	1.47
141	1000	0.2	0.3672	0.1392	3.06
142	1000	0.5	0.4379	0.1513	5.36
143	1000	0.7	0.4055	0.1675	9.15
144	1000	1	0.3657	0.1786	11.02

**APÊNDICE D - RESULTADOS DOS TESTES COM O ALGORITMO SMOReg COM
ONZE VARIÁVEIS E FUNÇÃO PUK COMO FUNÇÃO KERNEL**

Teste	C	Ômega	Sigma	R	RMSE	Tempo
145	1	0.1	1	0.4973	0.1148	0.16
146	1	0.5	0.5	0.4278	0.1297	0.05
147	1	0.5	1	0.4112	0.1245	0.05
148	1	1	1	0.4192	0.1239	0.04
149	1	2	2	0.5149	0.1139	0.04
150	1	5	5	0.4755	0.1146	0.02
151	1	10	10	0.4715	0.1135	0.02
152	1	20	20	0.4057	0.1185	0.02
153	1	30	30	0.3484	0.1226	0.03
154	10	0.1	1	0.4545	0.1197	0.22
155	10	0.5	0.5	0.3920	0.1511	0.28
156	10	0.5	1	0.3924	0.1516	0.22
157	10	1	1	0.3700	0.1524	0.18
158	10	2	2	0.3820	0.1337	0.12
159	10	5	5	0.5085	0.1145	0.05
160	10	10	10	0.4693	0.1150	0.03
161	10	20	20	0.4849	0.1122	0.03
162	10	30	30	0.4756	0.1127	0.02
163	100	0.1	1	0.4475	0.1205	1.05
164	100	0.5	0.5	0.2722	0.2535	2.29
165	100	0.5	1	0.3583	0.1853	1.80
166	100	1	1	0.3929	0.1736	1.95
167	100	2	2	0.4266	0.1439	0.76
168	100	5	5	0.4935	0.1164	0.23
169	100	10	10	0.4969	0.1141	0.08
170	100	20	20	0.4561	0.1172	0.03
171	100	30	30	0.4661	0.1144	0.03
172	1000	0.1	1	0.4483	0.0877	5.50
173	1000	0.5	0.5	-0.0370	0.5000	25.12
174	1000	0.5	1	0.2527	0.3430	17.71
175	1000	1	1	0.2829	0.2685	21.57
176	1000	2	2	0.3422	0.1714	6.74
177	1000	5	5	0.3641	0.1370	2.19
178	1000	10	10	0.5244	0.1145	0.55
179	1000	20	20	0.4924	0.1142	0.17
180	1000	30	30	0.4681	0.1161	0.10

APÊNDICE E - RESULTADOS DOS TESTES COM O ALGORITMO SMOReg COM CINCO VARIÁVEIS E FUNÇÃO POLINOMIAL COMO FUNÇÃO KERNEL

Teste	C	Grau	R	RMSE	Tempo (s)
181	1	1	0.4902	0.1119	0.10
182	1	2	0.5228	0.1111	0.09
183	10	1	0.4944	0.1116	0.09
184	10	2	0.5225	0.1107	0.23
185	100	1	0.4918	0.1118	0.44
186	100	2	0.5186	0.1112	1.26
187	1000	1	0.4925	0.1117	2.95
188	1000	2	0.5222	0.1107	12.48

APÊNDICE F - RESULTADOS DOS TESTES COM O ALGORITMO SMOReg COM CINCO VARIÁVEIS E FUNÇÃO RBF COMO FUNÇÃO KERNEL

Teste	C	Gama	R	RMSE	Tempo (s)
189	1	0.001	0.3457	0.1263	0.19
190	1	0.01	0.4283	0.1199	0.06
191	1	0.02	0.4622	0.1165	0.05
192	1	0.05	0.5001	0.1131	0.04
193	1	0.1	0.5120	0.1115	0.07
194	1	0.2	0.5061	0.1124	0.04
195	1	0.5	0.5097	0.1119	0.05
196	1	0.7	0.5199	0.1107	0.06
197	1	1	0.5239	0.1091	0.06
198	10	0.001	0.4285	0.1195	0.04
199	10	0.01	0.4982	0.1117	0.03
200	10	0.02	0.5010	0.1120	0.03
201	10	0.05	0.4920	0.1131	0.03
202	10	0.1	0.4807	0.1139	0.06
203	10	0.2	0.5104	0.1110	0.06
204	10	0.5	0.5058	0.1101	0.09
205	10	0.7	0.4739	0.1129	0.12
206	10	1	0.4297	0.1186	0.20
207	100	0.001	0.4924	0.1115	0.02
208	100	0.01	0.4968	0.1123	0.05
209	100	0.02	0.4766	0.1141	0.07
210	100	0.05	0.4961	0.1126	0.08
211	100	0.1	0.5060	0.1108	0.26
212	100	0.2	0.5062	0.1103	0.43
213	100	0.5	0.4182	0.1207	0.67
214	100	0.7	0.4252	0.1207	0.80
215	100	1	0.4109	0.1222	0.76
216	1000	0.001	0.4942	0.1117	0.03
217	1000	0.01	0.4752	0.1142	0.14
218	1000	0.02	0.5010	0.1118	0.31
219	1000	0.05	0.5065	0.1103	0.66
220	1000	0.1	0.4999	0.1109	1.22
221	1000	0.2	0.4105	0.1210	2.52
222	1000	0.5	0.4205	0.1219	4.97
223	1000	0.7	0.4513	0.1202	6.11
224	1000	1	0.4570	0.1221	10.91

APÊNDICE G - RESULTADOS DOS TESTES COM O ALGORITMO SMOReg COM CINCO VARIÁVEIS E FUNÇÃO PUK COMO FUNÇÃO KERNEL

Teste	C	Omega	Sigma	R	RMSE	Tempo (s)
225	1	0.1	1	0.5336	0.1112	0.08
226	1	0.5	0.5	0.4568	0.1209	0.07
227	1	0.5	1	0.4491	0.1173	0.05
228	1	1	1	0.4606	0.1160	0.08
229	1	2	2	0.5136	0.1102	0.05
230	1	5	5	0.5151	0.1116	0.05
231	1	10	10	0.4824	0.1149	0.06
232	1	20	20	0.4148	0.1211	0.04
233	1	30	30	0.3878	0.1235	0.04
234	10	0.1	1	0.4913	0.1159	0.27
235	10	0.5	0.5	0.4066	0.1467	0.36
236	10	0.5	1	0.3843	0.1403	0.41
237	10	1	1	0.3648	0.1318	0.33
238	10	2	2	0.4321	0.1191	0.15
239	10	5	5	0.4934	0.1129	0.08
240	10	10	10	0.5003	0.1122	0.04
241	10	20	20	0.4910	0.1123	0.06
242	10	30	30	0.4832	0.1141	0.04
243	100	0.1	1	0.4839	0.1168	1.42
244	100	0.5	0.5	0.2938	0.2169	3.58
245	100	0.5	1	0.3335	0.1791	2.14
246	100	1	1	0.3363	0.1709	2.25
247	100	2	2	0.4347	0.1200	0.82
248	100	5	5	0.5091	0.1097	0.19
249	100	10	10	0.4747	0.1143	0.05
250	100	20	20	0.4972	0.1121	0.06
251	100	30	30	0.4944	0.1118	0.03
252	1000	0.1	1	0.4855	0.1164	8.69
253	1000	0.5	0.5	-0.0567	0.4404	27.01
254	1000	0.5	1	0.2210	0.2729	19.77
255	1000	1	1	0.2316	0.2441	21.25
256	1000	2	2	0.4467	0.1241	9.36
257	1000	5	5	0.4561	0.1150	1.41
258	1000	10	10	0.5059	0.1109	0.41
259	1000	20	20	0.4668	0.1153	0.15
260	1000	30	30	0.5004	0.1113	0.08

**APÊNDICE H - RESULTADOS DOS TESTES COM A REDE MLP COM ONZE
VARIÁVEIS E UMA CAMADA INTERMEDIÁRIA**

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
261	5	500	0.2789	0.1822	0.21
262	5	1000	0.2981	0.1811	0.34
263	5	1500	0.3148	0.1795	0.53
264	5	2000	0.3218	0.1786	0.76
265	5	2500	0.3266	0.1779	0.91
266	5	3000	0.3298	0.1773	1.10
267	10	500	0.3504	0.1711	0.63
268	10	1000	0.3016	0.1812	1.19
269	10	1500	0.3262	0.1792	1.80
270	10	2000	0.3453	0.1780	2.40
271	10	2500	0.4099	0.1713	2.93
272	10	3000	0.4289	0.1711	3.56
273	15	500	0.3915	0.1685	0.89
274	15	1000	0.2720	0.1808	1.78
275	15	1500	0.3244	0.1782	2.59
276	15	2000	0.3553	0.1761	3.46
277	15	2500	0.3965	0.1712	4.32
278	15	3000	0.4323	0.1668	5.10
279	20	500	0.3922	0.1688	1.13
280	20	1000	0.4286	0.1600	2.26
281	20	1500	0.4257	0.1596	3.44
282	20	2000	0.2861	0.1930	4.53
283	20	2500	0.2997	0.1970	5.60
284	20	3000	0.2999	0.2011	7.01

**APÊNDICE I - RESULTADOS DOS TESTES COM A REDE MLP COM ONZE
VARIÁVEIS E DUAS CAMADAS INTERMEDIÁRIAS**

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
285	5/5	500	0.4562	0.1764	0.37
286	5/5	1000	0.4786	0.1627	1.15
287	5/5	1500	0.4572	0.1686	1.56
288	5/5	2000	0.4325	0.1745	1.93
289	5/5	2500	0.3911	0.1748	2.53
290	5/5	3000	0.3843	0.1722	2.51
291	5/10	500	0.3547	0.1754	0.45
292	5/10	1000	0.3107	0.1776	0.99
293	5/10	1500	0.3301	0.1704	2.11
294	5/10	2000	0.3303	0.1687	2.70
295	5/10	2500	0.3005	0.1705	3.00
296	5/10	3000	0.2501	0.1770	3.64
297	5/15	500	0.4556	0.1646	0.61
298	5/15	1000	0.4155	0.1625	1.16
299	5/15	1500	0.4033	0.1574	1.71
300	5/15	2000	0.3985	0.1574	2.33
301	5/15	2500	0.3709	0.1610	2.73
302	5/15	3000	0.3516	0.1610	3.34
303	5/20	500	0.4049	0.1621	1.06
304	5/20	1000	0.4432	0.1647	2.04
305	5/20	1500	0.4543	0.1647	1.99
306	5/20	2000	0.4484	0.1670	2.64
307	5/20	2500	0.4441	0.1683	3.39
308	5/20	3000	0.4474	0.1680	3.89
309	10/5	500	0.4641	0.1822	0.71
310	10/5	1000	0.5248	0.1621	1.30
311	10/5	1500	0.4514	0.1666	1.98
312	10/5	2000	0.4223	0.1619	2.51
313	10/5	2500	0.3848	0.1644	3.18
314	10/5	3000	0.3598	0.1702	3.77
315	10/10	500	0.4238	0.1748	0.86
316	10/10	1000	0.4144	0.1639	1.65
317	10/10	1500	0.4074	0.1634	2.44
318	10/10	2000	0.4084	0.1676	3.56
319	10/10	2500	0.4448	0.1617	4.17
320	10/10	3000	0.4562	0.1565	4.88
321	10/15	500	0.3995	0.1796	1.04
322	10/15	1000	0.3553	0.1658	2.3
323	10/15	1500	0.2343	0.1931	3.03
324	10/15	2000	0.1937	0.2009	4.06
325	10/15	2500	0.1683	0.2095	5.29

326	10/15	3000	0.1096	0.2267	6.00
327	10/20	500	0.3980	0.1679	1.35
328	10/20	1000	0.3471	0.1700	2.43
329	10/20	1500	0.2924	0.1767	3.73
330	10/20	2000	0.2986	0.1730	4.76
331	10/20	2500	0.2815	0.1766	5.92
332	10/20	3000	0.2040	0.1941	7.76
333	15/5	500	0.4698	0.1847	0.98
334	15/5	1000	0.4703	0.1669	1.71
335	15/5	1500	0.4569	0.1550	2.25
336	15/5	2000	0.3649	0.1699	3.34
337	15/5	2500	0.3645	0.1761	4.36
338	15/5	3000	0.3694	0.1765	10.05
339	15/10	500	0.4627	0.1811	2.31
340	15/10	1000	0.4172	0.1616	4.58
341	15/10	1500	0.4048	0.1625	7.50
342	15/10	2000	0.3568	0.1749	9.09
343	15/10	2500	0.3915	0.1740	11.63
344	15/10	3000	0.3778	0.1684	13.96
345	15/15	500	0.4553	0.1835	2.89
346	15/15	1000	0.3745	0.1652	5.80
347	15/15	1500	0.3452	0.1706	8.87
348	15/15	2000	0.3016	0.1827	11.58
349	15/15	2500	0.2539	0.1945	14.84
350	15/15	3000	0.2331	0.1997	19.11
351	15/20	500	0.4448	0.1731	3.73
352	15/20	1000	0.3509	0.1749	7.16
353	15/20	1500	0.3426	0.1774	10.70
354	15/20	2000	0.3258	0.1788	14.07
355	15/20	2500	0.3085	0.1804	20.46
356	15/20	3000	0.3012	0.1826	21.52
357	20/5	500	0.4708	0.1815	2.24
358	20/5	1000	0.4816	0.1696	4.45
359	20/5	1500	0.4445	0.1527	6.55
360	20/5	2000	0.3699	0.1557	8.93
361	20/5	2500	0.3439	0.1619	11.09
362	20/5	3000	0.3605	0.1650	13.38
363	20/10	500	0.4628	0.1815	3.00
364	20/10	1000	0.5183	0.1692	5.95
365	20/10	1500	0.5228	0.1658	8.94
366	20/10	2000	0.4656	0.1566	12.36
367	20/10	2500	0.4119	0.1612	15.18
368	20/10	3000	0.3892	0.1655	17.79
369	20/15	500	0.4603	0.1855	3.78
370	20/15	1000	0.4117	0.1637	7.19

371	20/15	1500	0.3883	0.1620	11.35
372	20/15	2000	0.3607	0.1688	14.96
373	20/15	2500	0.3497	0.1744	18.81
374	20/15	3000	0.3387	0.1784	22.90
375	20/20	500	0.4563	0.1874	4.55
376	20/20	1000	0.4454	0.1634	9.17
377	20/20	1500	0.3897	0.1627	13.58
378	20/20	2000	0.3535	0.1696	18.29
379	20/20	2500	0.3479	0.1700	23.15
380	20/20	3000	0.3832	0.1641	27.92

**APÊNDICE J - RESULTADOS DOS TESTES COM A REDE MLP COM ONZE
VARIÁVEIS E TRÊS CAMADAS INTERMEDIÁRIAS**

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
381	5/5/5	500	0.4913	0.1814	0.72
382	5/5/5	1000	0.4751	0.1671	1.26
383	5/5/5	1500	0.4622	0.1621	2.02
384	5/5/5	2000	0.4582	0.1572	1.96
385	5/5/5	2500	0.4566	0.1523	3.23
386	5/5/5	3000	0.4318	0.1501	4.60
387	5/5/10	500	0.4832	0.1800	0.97
388	5/5/10	1000	0.4693	0.1640	1.48
389	5/5/10	1500	0.4627	0.1584	2.31
390	5/5/10	2000	0.4448	0.1574	3.33
391	5/5/10	2500	0.4213	0.1566	3.63
392	5/5/10	3000	0.3824	0.1575	4.70
393	5/5/15	500	0.4760	0.1806	0.99
394	5/5/15	1000	0.4630	0.1657	1.67
395	5/5/15	1500	0.4636	0.1589	2.40
396	5/5/15	2000	0.4505	0.1607	3.15
397	5/5/15	2500	0.4485	0.1609	4.67
398	5/5/15	3000	0.4200	0.1663	4.45
399	5/5/20	500	0.4695	0.1803	1.26
400	5/5/20	1000	0.4346	0.1765	2.16
401	5/5/20	1500	0.4662	0.1621	3.78
402	5/5/20	2000	0.4141	0.1701	4.15
403	5/5/20	2500	0.3539	0.1734	4.88
404	5/5/20	3000	0.3054	0.1727	7.47
405	5/10/5	500	0.5009	0.1850	0.63
406	5/10/5	1000	0.4729	0.1674	1.28
407	5/10/5	1500	0.4663	0.1639	1.85
408	5/10/5	2000	0.4649	0.1641	2.44
409	5/10/5	2500	0.4593	0.1649	4.21
410	5/10/5	3000	0.4575	0.1687	4.63
411	5/10/10	500	0.4831	0.1815	1.05
412	5/10/10	1000	0.4738	0.1669	2.04
413	5/10/10	1500	0.4549	0.1629	3.65
414	5/10/10	2000	0.4584	0.1619	4.52
415	5/10/10	2500	0.4618	0.1606	5.72
416	5/10/10	3000	0.4602	0.1602	5.06
417	5/10/15	500	0.4804	0.1746	1.13
418	5/10/15	1000	0.4775	0.1670	2.67
419	5/10/15	1500	0.4649	0.1644	3.33
420	5/10/15	2000	0.4619	0.1651	4.50
421	5/10/15	2500	0.4660	0.1659	5.37

422	5/10/15	3000	0.4698	0.1670	6.94
423	5/10/20	500	0.4864	0.1756	1.75
424	5/10/20	1000	0.4892	0.1702	3.48
425	5/10/20	1500	0.4557	0.1739	4.89
426	5/10/20	2000	0.4045	0.1760	6.49
427	5/10/20	2500	0.3819	0.1775	7.96
428	5/10/20	3000	0.3862	0.1762	8.62
429	5/15/5	500	0.5194	0.1863	1.57
430	5/15/5	1000	0.4852	0.1769	3.15
431	5/15/5	1500	0.4829	0.1635	4.79
432	5/15/5	2000	0.4643	0.1606	6.50
433	5/15/5	2500	0.4515	0.1606	9.96
434	5/15/5	3000	0.4552	0.1594	8.49
435	5/15/10	500	0.4900	0.1798	1.87
436	5/15/10	1000	0.4969	0.1620	4.03
437	5/15/10	1500	0.4911	0.1650	5.60
438	5/15/10	2000	0.4948	0.1665	7.80
439	5/15/10	2500	0.4941	0.1667	9.32
440	5/15/10	3000	0.4734	0.1691	11.22
441	5/15/15	500	0.4836	0.1788	2.67
442	5/15/15	1000	0.4632	0.1682	4.97
443	5/15/15	1500	0.4650	0.1662	7.40
444	5/15/15	2000	0.4627	0.1668	9.88
445	5/15/15	2500	0.4576	0.1677	12.37
446	5/15/15	3000	0.4506	0.1689	14.96
447	5/15/20	500	0.4814	0.1784	3.07
448	5/15/20	1000	0.4690	0.1691	6.19
449	5/15/20	1500	0.4546	0.1676	9.14
450	5/15/20	2000	0.4584	0.1651	12.12
451	5/15/20	2500	0.4571	0.1649	15.54
452	5/15/20	3000	0.4543	0.1615	18.35
453	5/20/5	500	0.5104	0.1930	0.98
454	5/20/5	1000	0.4552	0.1782	1.99
455	5/20/5	1500	0.4672	0.1657	2.93
456	5/20/5	2000	0.4642	0.1666	3.93
457	5/20/5	2500	0.4833	0.1688	4.86
458	5/20/5	3000	0.4831	0.1708	5.94
459	5/20/10	500	0.4948	0.1826	2.70
460	5/20/10	1000	0.4552	0.1677	3.48
461	5/20/10	1500	0.4394	0.1717	5.10
462	5/20/10	2000	0.4244	0.1716	8.19
463	5/20/10	2500	0.4245	0.1617	13.70
464	5/20/10	3000	0.4353	0.1581	9.58
465	5/20/15	500	0.4960	0.1803	2.14
466	5/20/15	1000	0.5068	0.1628	4.64

467	5/20/15	1500	0.4949	0.1720	6.24
468	5/20/15	2000	0.4838	0.1718	9.33
469	5/20/15	2500	0.4796	0.1706	10.27
470	5/20/15	3000	0.4971	0.1695	11.64
471	5/20/20	500	0.4769	0.1801	2.95
472	5/20/20	1000	0.4556	0.1684	4.93
473	5/20/20	1500	0.4431	0.1621	7.63
474	5/20/20	2000	0.4365	0.1590	9.82
475	5/20/20	2500	0.4386	0.1556	14.65
476	5/20/20	3000	0.4449	0.1523	16.05
477	10/5/5	500	0.4971	0.1812	1.09
478	10/5/5	1000	0.4844	0.1693	1.65
479	10/5/5	1500	0.4219	0.1724	2.73
480	10/5/5	2000	0.4010	0.1723	2.89
481	10/5/5	2500	0.3928	0.1665	4.63
482	10/5/5	3000	0.3936	0.1630	4.31
483	10/5/10	500	0.4963	0.1809	1.08
484	10/5/10	1000	0.4987	0.1613	2.20
485	10/5/10	1500	0.4571	0.1549	2.80
486	10/5/10	2000	0.3633	0.1646	5.46
487	10/5/10	2500	0.3441	0.1718	5.10
488	10/5/10	3000	0.3254	0.1761	5.60
489	10/5/15	500	0.4865	0.1822	0.92
490	10/5/15	1000	0.5058	0.1629	2.19
491	10/5/15	1500	0.4978	0.1644	2.86
492	10/5/15	2000	0.4473	0.1660	3.86
493	10/5/15	2500	0.3997	0.1604	4.75
494	10/5/15	3000	0.3332	0.1731	6.86
495	10/5/20	500	0.4792	0.1846	1.20
496	10/5/20	1000	0.4843	0.1665	2.37
497	10/5/20	1500	0.4187	0.1714	3.45
498	10/5/20	2000	0.3518	0.1741	4.47
499	10/5/20	2500	0.3302	0.1805	6.23
500	10/5/20	3000	0.3076	0.1907	6.78
501	10/10/5	500	0.4553	0.1890	0.91
502	10/10/5	1000	0.3589	0.1749	1.52
503	10/10/5	1500	0.3834	0.1674	2.24
504	10/10/5	2000	0.4175	0.1647	3.06
505	10/10/5	2500	0.4345	0.1628	3.64
506	10/10/5	3000	0.4410	0.1613	4.71
507	10/10/10	500	0.5014	0.1827	1.03
508	10/10/10	1000	0.4880	0.1709	2.07
509	10/10/10	1500	0.4660	0.1615	3.01
510	10/10/10	2000	0.4068	0.1612	3.74
511	10/10/10	2500	0.3859	0.1651	4.83

512	10/10/10	3000	0.3806	0.1676	5.67
513	10/10/15	500	0.4891	0.1810	1.23
514	10/10/15	1000	0.4586	0.1733	2.52
515	10/10/15	1500	0.4159	0.1651	3.58
516	10/10/15	2000	0.4115	0.1634	4.76
517	10/10/15	2500	0.4084	0.1719	6.16
518	10/10/15	3000	0.4116	0.1745	7.30
519	10/10/20	500	0.4856	0.1801	1.54
520	10/10/20	1000	0.4792	0.1670	2.98
521	10/10/20	1500	0.4448	0.1699	4.39
522	10/10/20	2000	0.4288	0.1690	5.52
523	10/10/20	2500	0.4275	0.1677	8.34
524	10/10/20	3000	0.4189	0.1687	8.50
525	10/15/5	500	0.5136	0.1864	0.98
526	10/15/5	1000	0.4754	0.1772	1.99
527	10/15/5	1500	0.4649	0.1651	2.94
528	10/15/5	2000	0.4047	0.1616	3.98
529	10/15/5	2500	0.3969	0.1624	4.78
530	10/15/5	3000	0.3886	0.1645	5.82
531	10/15/10	500	0.5009	0.1844	1.32
532	10/15/10	1000	0.4529	0.1772	2.66
533	10/15/10	1500	0.4185	0.1595	3.80
534	10/15/10	2000	0.3961	0.1511	5.17
535	10/15/10	2500	0.3897	0.1503	6.47
536	10/15/10	3000	0.3867	0.1505	7.45
537	10/15/15	500	0.4902	0.1850	1.78
538	10/15/15	1000	0.4585	0.1738	3.33
539	10/15/15	1500	0.4519	0.1649	4.79
540	10/15/15	2000	0.3898	0.1750	6.38
541	10/15/15	2500	0.4030	0.1690	8.05
542	10/15/15	3000	0.4057	0.1639	9.85
543	10/15/20	500	0.4893	0.1796	1.97
544	10/15/20	1000	0.4955	0.1641	4.13
545	10/15/20	1500	0.4600	0.1628	5.75
546	10/15/20	2000	0.4020	0.1697	7.47
547	10/15/20	2500	0.3899	0.1698	9.33
548	10/15/20	3000	0.4067	0.1661	11.52
549	10/20/5	500	0.5114	0.1861	1.17
550	10/20/5	1000	0.4522	0.1820	2.29
551	10/20/5	1500	0.4110	0.1761	3.51
552	10/20/5	2000	0.4432	0.1614	4.88
553	10/20/5	2500	0.4222	0.1546	6.13
554	10/20/5	3000	0.4275	0.1558	6.90
555	10/20/10	500	0.5077	0.1824	1.49
556	10/20/10	1000	0.4768	0.1765	3.14

557	10/20/10	1500	0.4751	0.1660	4.64
558	10/20/10	2000	0.4058	0.1737	6.12
559	10/20/10	2500	0.4013	0.1741	8.58
560	10/20/10	3000	0.3747	0.1748	9.74
561	10/20/15	500	0.4935	0.1865	1.99
562	10/20/15	1000	0.4853	0.1674	3.94
563	10/20/15	1500	0.4770	0.1675	6.03
564	10/20/15	2000	0.4361	0.1708	7.93
565	10/20/15	2500	0.4236	0.1693	9.84
566	10/20/15	3000	0.4211	0.1674	11.82
567	10/20/20	500	0.4906	0.1838	2.38
568	10/20/20	1000	0.4593	0.1712	4.67
569	10/20/20	1500	0.4431	0.1589	7.14
570	10/20/20	2000	0.3964	0.1717	9.29
571	10/20/20	2500	0.3855	0.1720	11.51
572	10/20/20	3000	0.3772	0.1723	14.14
573	15/5/5	500	0.5076	0.1838	0.79
574	15/5/5	1000	0.4754	0.1658	1.59
575	15/5/5	1500	0.4297	0.1721	2.19
576	15/5/5	2000	0.3920	0.1755	2.95
577	15/5/5	2500	0.3916	0.1734	3.53
578	15/5/5	3000	0.3818	0.1721	4.29
579	15/5/10	500	0.4987	0.1760	0.81
580	15/5/10	1000	0.4839	0.1679	1.62
581	15/5/10	1500	0.4426	0.1685	2.52
582	15/5/10	2000	0.4101	0.1712	3.27
583	15/5/10	2500	0.4055	0.1689	4.04
584	15/5/10	3000	0.3882	0.1686	4.95
585	15/5/15	500	0.4986	0.1738	1.05
586	15/5/15	1000	0.4543	0.1689	1.94
587	15/5/15	1500	0.4445	0.1643	3.04
588	15/5/15	2000	0.4241	0.1628	3.72
589	15/5/15	2500	0.3916	0.1683	4.85
590	15/5/15	3000	0.3687	0.1687	5.52
591	15/5/20	500	0.4955	0.1744	1.14
592	15/5/20	1000	0.4888	0.1684	2.50
593	15/5/20	1500	0.4424	0.1706	3.34
594	15/5/20	2000	0.3968	0.1777	4.73
595	15/5/20	2500	0.3638	0.1898	5.51
596	15/5/20	3000	0.3113	0.1924	6.88
597	15/10/5	500	0.4711	0.1917	1.02
598	15/10/5	1000	0.3712	0.1772	2.03
599	15/10/5	1500	0.4094	0.1591	2.90
600	15/10/5	2000	0.4303	0.1563	3.90
601	15/10/5	2500	0.4486	0.1616	4.86

602	15/10/5	3000	0.4537	0.1631	5.62
603	15/10/10	500	0.4408	0.1923	1.25
604	15/10/10	1000	0.4379	0.1730	2.37
605	15/10/10	1500	0.4188	0.1695	3.55
606	15/10/10	2000	0.4038	0.1684	4.67
607	15/10/10	2500	0.4194	0.1626	5.77
608	15/10/10	3000	0.4280	0.1562	7.07
609	15/10/15	500	0.5068	0.1775	1.43
610	15/10/15	1000	0.4777	0.1712	2.85
611	15/10/15	1500	0.4425	0.1709	4.19
612	15/10/15	2000	0.3849	0.1732	5.46
613	15/10/15	2500	0.3621	0.1759	6.98
614	15/10/15	3000	0.3576	0.1766	8.04
615	15/10/20	500	0.4904	0.1853	1.64
616	15/10/20	1000	0.4688	0.1734	3.28
617	15/10/20	1500	0.4390	0.1689	4.73
618	15/10/20	2000	0.4157	0.1662	6.52
619	15/10/20	2500	0.4201	0.1610	8.07
620	15/10/20	3000	0.4204	0.1571	9.61
621	15/15/5	500	0.4912	0.1913	1.27
622	15/15/5	1000	0.3584	0.1814	2.48
623	15/15/5	1500	0.3877	0.1674	3.61
624	15/15/5	2000	0.4189	0.1637	4.68
625	15/15/5	2500	0.4160	0.1652	5.90
626	15/15/5	3000	0.4033	0.1710	7.35
627	15/15/10	500	0.5177	0.1843	1.53
628	15/15/10	1000	0.4626	0.1751	3.05
629	15/15/10	1500	0.4220	0.1706	4.56
630	15/15/10	2000	0.3669	0.1774	5.96
631	15/15/10	2500	0.3827	0.1741	7.67
632	15/15/10	3000	0.3749	0.1763	8.78
633	15/15/15	500	0.4384	0.1886	1.99
634	15/15/15	1000	0.3657	0.1818	3.68
635	15/15/15	1500	0.3823	0.1746	5.64
636	15/15/15	2000	0.3973	0.1728	8.11
637	15/15/15	2500	0.4253	0.1679	9.86
638	15/15/15	3000	0.4405	0.1629	11.78
639	15/15/20	500	0.5019	0.1813	3.05
640	15/15/20	1000	0.4862	0.1686	5.51
641	15/15/20	1500	0.4050	0.1758	8.26
642	15/15/20	2000	0.3689	0.1715	9.26
643	15/15/20	2500	0.3331	0.1727	11.56
644	15/15/20	3000	0.2999	0.1782	14.53
645	15/20/5	500	0.5261	0.1846	2.39
646	15/20/5	1000	0.5276	0.1655	3.95

647	15/20/5	1500	0.4738	0.1563	6.31
648	15/20/5	2000	0.4603	0.1601	5.96
649	15/20/5	2500	0.4448	0.1663	8.81
650	15/20/5	3000	0.4386	0.1682	8.88
651	15/20/10	500	0.5119	0.1862	2.03
652	15/20/10	1000	0.4603	0.1756	3.70
653	15/20/10	1500	0.4713	0.1608	5.80
654	15/20/10	2000	0.4470	0.1587	7.61
655	15/20/10	2500	0.4433	0.1593	9.49
656	15/20/10	3000	0.4310	0.1618	11.31
657	15/20/15	500	0.4756	0.1858	2.23
658	15/20/15	1000	0.3885	0.1734	4.66
659	15/20/15	1500	0.3834	0.1650	6.99
660	15/20/15	2000	0.4024	0.1577	9.03
661	15/20/15	2500	0.4061	0.1551	11.72
662	15/20/15	3000	0.4133	0.1592	13.53
663	15/20/20	500	0.5016	0.1831	2.68
664	15/20/20	1000	0.4954	0.1656	5.45
665	15/20/20	1500	0.4675	0.1705	8.15
666	15/20/20	2000	0.3987	0.1814	10.67
667	15/20/20	2500	0.3576	0.1871	14.18
668	15/20/20	3000	0.3363	0.1907	15.90
669	20/5/5	500	0.4996	0.1915	1.12
670	20/5/5	1000	0.4223	0.1682	2.62
671	20/5/5	1500	0.4625	0.1532	4.19
672	20/5/5	2000	0.4565	0.1545	4.35
673	20/5/5	2500	0.4447	0.1569	5.65
674	20/5/5	3000	0.4265	0.1605	8.01
675	20/5/10	500	0.4666	0.1890	1.30
676	20/5/10	1000	0.4779	0.1648	2.85
677	20/5/10	1500	0.4513	0.1663	4.74
678	20/5/10	2000	0.3828	0.1690	5.72
679	20/5/10	2500	0.3298	0.1759	6.31
680	20/5/10	3000	0.3143	0.1755	6.86
681	20/5/15	500	0.4683	0.1877	1.69
682	20/5/15	1000	0.4761	0.1670	3.46
683	20/5/15	1500	0.4496	0.1688	5.23
684	20/5/15	2000	0.4027	0.1825	6.14
685	20/5/15	2500	0.3863	0.1867	7.44
686	20/5/15	3000	0.3643	0.1890	8.18
687	20/5/20	500	0.4555	0.1910	1.77
688	20/5/20	1000	0.4736	0.1641	3.67
689	20/5/20	1500	0.4073	0.1784	4.48
690	20/5/20	2000	0.2764	0.1978	6.22
691	20/5/20	2500	0.2587	0.1941	7.93

692	20/5/20	3000	0.2635	0.1985	9.05
693	20/10/5	500	0.4763	0.1937	1.42
694	20/10/5	1000	0.3953	0.1707	2.58
695	20/10/5	1500	0.4122	0.1626	3.81
696	20/10/5	2000	0.4136	0.1632	5.16
697	20/10/5	2500	0.4150	0.1637	6.15
698	20/10/5	3000	0.4121	0.1641	7.97
699	20/10/10	500	0.4558	0.1950	1.67
700	20/10/10	1000	0.4232	0.1681	2.98
701	20/10/10	1500	0.4051	0.1606	4.59
702	20/10/10	2000	0.4007	0.1591	6.02
703	20/10/10	2500	0.4123	0.1548	7.76
704	20/10/10	3000	0.4198	0.1545	8.82
705	20/10/15	500	0.4513	0.1916	1.82
706	20/10/15	1000	0.4374	0.1683	3.50
707	20/10/15	1500	0.3864	0.1615	5.46
708	20/10/15	2000	0.3335	0.1702	7.02
709	20/10/15	2500	0.3202	0.1689	9.11
710	20/10/15	3000	0.2967	0.1704	10.49
711	20/10/20	500	0.4701	0.1880	2.07
712	20/10/20	1000	0.4654	0.1656	4.06
713	20/10/20	1500	0.4073	0.1734	5.92
714	20/10/20	2000	0.3681	0.1715	8.15
715	20/10/20	2500	0.3746	0.1679	9.95
716	20/10/20	3000	0.3602	0.1708	12.58
717	20/15/5	500	0.4879	0.1798	1.77
718	20/15/5	1000	0.4470	0.1670	3.37
719	20/15/5	1500	0.4338	0.1655	4.93
720	20/15/5	2000	0.4310	0.1644	6.34
721	20/15/5	2500	0.4132	0.1680	7.61
722	20/15/5	3000	0.4099	0.1682	9.83
723	20/15/10	500	0.4356	0.1839	1.91
724	20/15/10	1000	0.3865	0.1710	3.80
725	20/15/10	1500	0.4230	0.1599	5.82
726	20/15/10	2000	0.4248	0.1588	7.63
727	20/15/10	2500	0.4229	0.1640	9.53
728	20/15/10	3000	0.4249	0.1670	11.61
729	20/15/15	500	0.4615	0.1928	2.40
730	20/15/15	1000	0.4001	0.1812	4.56
731	20/15/15	1500	0.4118	0.1711	6.61
732	20/15/15	2000	0.3854	0.1712	9.22
733	20/15/15	2500	0.3873	0.1677	11.43
734	20/15/15	3000	0.3935	0.1643	13.54
735	20/15/20	500	0.4673	0.1901	2.68
736	20/15/20	1000	0.4639	0.1691	5.05

737	20/15/20	1500	0.4491	0.1652	7.80
738	20/15/20	2000	0.4352	0.1641	10.71
739	20/15/20	2500	0.4081	0.1657	12.40
740	20/15/10	3000	0.4019	0.1668	15.55
741	20/20/5	500	0.4860	0.1924	1.99
742	20/20/5	1000	0.4165	0.1800	3.77
743	20/20/5	1500	0.3942	0.1719	5.80
744	20/20/5	2000	0.3522	0.1753	7.52
745	20/20/5	2500	0.3351	0.1755	9.28
746	20/20/5	3000	0.3400	0.1741	11.06
747	20/20/10	500	0.4966	0.1891	2.36
748	20/20/10	1000	0.4767	0.1650	4.73
749	20/20/10	1500	0.4364	0.1704	6.86
750	20/20/10	2000	0.4208	0.1680	9.26
751	20/20/10	2500	0.4266	0.1672	11.50
752	20/20/10	3000	0.4374	0.1662	14.03
753	20/20/15	500	0.5116	0.1846	2.96
754	20/20/15	1000	0.4846	0.1698	5.54
755	20/20/15	1500	0.4778	0.1697	8.41
756	20/20/15	2000	0.4587	0.1720	10.82
757	20/20/15	2500	0.4553	0.1717	13.71
758	20/20/15	3000	0.4448	0.1741	16.37
759	20/20/20	500	0.4833	0.1892	3.13
760	20/20/20	1000	0.4002	0.1736	6.32
761	20/20/20	1500	0.3976	0.1608	9.78
762	20/20/20	2000	0.3968	0.1612	12.69
763	20/20/20	2500	0.4148	0.1588	15.3
764	20/20/20	3000	0.4347	0.1559	19.25

**APÊNDICE K - RESULTADOS DOS TESTES COM A REDE MLP COM CINCO
VARIÁVEIS E UMA CAMADA INTERMEDIÁRIA**

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
785	5	500	0.4257	0.1739	0.27
786	5	1000	0.4059	0.1714	0.37
787	5	1500	0.3969	0.1704	0.54
788	5	2000	0.4273	0.1676	0.62
789	5	2500	0.4265	0.1679	0.63
790	5	3000	0.4207	0.1682	1.06
791	10	500	0.5057	0.1667	0.25
792	10	1000	0.4095	0.1725	0.44
793	10	1500	0.4308	0.1671	0.59
794	10	2000	0.4230	0.1655	0.85
795	10	2500	0.4068	0.1668	1.02
796	10	3000	0.3816	0.1701	1.22
797	15	500	0.4966	0.1672	0.37
798	15	1000	0.4459	0.1668	0.84
799	15	1500	0.4109	0.1681	1.16
800	15	2000	0.4309	0.1623	1.33
801	15	2500	0.4303	0.1596	1.65
802	15	3000	0.4164	0.1603	2.42
803	a	500	0.4087	0.1778	0.12
804	a	1000	0.4080	0.1741	0.22
805	a	1500	0.4148	0.1722	0.32
806	a	2000	0.4190	0.1705	0.48
807	a	2500	0.4214	0.1691	0.52
808	a	3000	0.4233	0.1680	0.70

**APÊNDICE L - RESULTADOS DOS TESTES COM A REDE MLP COM CINCO
VARIÁVEIS E DUAS CAMADA INTERMEDIÁRIA**

Teste	Neurônios	Épocas	R	RMSE	Tempo (s)
809	5/5	500	0.5196	0.1795	0.55
810	5/5	1000	0.5296	0.1776	0.58
811	5/5	1500	0.5310	0.1757	0.84
812	5/5	2000	0.5301	0.1780	1.44
813	5/5	2500	0.5264	0.1802	1.62
814	5/5	3000	0.5292	0.1837	2.08
815	5/10	500	0.5176	0.1803	0.45
816	5/10	1000	0.4856	0.1813	1.05
817	5/10	1500	0.5112	0.1680	1.53
818	5/10	2000	0.4947	0.1552	2.10
819	5/10	2500	0.4857	0.1504	2.41
820	5/10	3000	0.4623	0.1493	3.39
821	5/15	500	0.4626	0.1850	0.52
822	5/15	1000	0.4633	0.1777	0.91
823	5/15	1500	0.4431	0.1703	1.38
824	5/15	2000	0.4472	0.1648	1.81
825	5/15	2500	0.4435	0.1642	2.28
826	5/15	3000	0.4175	0.1680	2.75
827	5/a	500	0.5206	0.1795	0.20
828	5/a	1000	0.5298	0.1778	0.45
829	5/a	1500	0.5367	0.1758	0.63
830	5/a	2000	0.5401	0.1749	0.73
831	5/a	2500	0.5422	0.1771	1.01
832	5/a	3000	0.5552	0.1769	1.22
833	10/5	500	0.5148	0.1807	0.44
834	10/5	1000	0.5223	0.1786	0.75
835	10/5	1500	0.5280	0.1761	1.20
836	10/5	2000	0.4672	0.1820	1.74
837	10/5	2500	0.4834	0.1781	2.11
838	10/5	3000	0.4844	0.1575	2.91
839	10/10	500	0.5113	0.1830	0.93
840	10/10	1000	0.4833	0.1834	1.58
841	10/10	1500	0.5489	0.1671	2.76
842	10/10	2000	0.5069	0.1581	3.19
843	10/10	2500	0.4736	0.1568	4.39
844	10/10	3000	0.4426	0.1589	4.61
845	10/15	500	0.4989	0.1862	1.19
846	10/15	1000	0.5159	0.1782	2.27
847	10/15	1500	0.5308	0.1644	3.38
848	10/15	2000	0.4920	0.1578	4.43
849	10/15	2500	0.4785	0.1539	5.12

850	10/15	3000	0.4576	0.1532	7.36
851	10/a	500	0.5191	0.1800	0.49
852	10/a	1000	0.5230	0.1788	0.86
853	10/a	1500	0.5242	0.1779	1.49
854	10/a	2000	0.5258	0.1774	1.90
855	10/a	2500	0.5300	0.1765	2.36
856	10/a	3000	0.5441	0.1740	2.87
857	15/5	500	0.5137	0.1812	0.67
858	15/5	1000	0.5194	0.1795	1.33
859	15/5	1500	0.5216	0.1777	2.54
860	15/5	2000	0.5236	0.1764	3.15
861	15/5	2500	0.5277	0.1750	4.11
862	15/5	3000	0.5351	0.1734	4.86
863	15/10	500	0.5081	0.1832	1.41
864	15/10	1000	0.5163	0.1808	2.35
865	15/10	1500	0.5194	0.1785	3.80
866	15/10	2000	0.5224	0.1771	4.99
867	15/10	2500	0.5258	0.1761	6.67
868	15/10	3000	0.5280	0.1758	7.01
869	15/15	500	0.4995	0.1841	1.97
870	15/15	1000	0.5085	0.1824	3.36
871	15/15	1500	0.4786	0.1827	5.11
872	15/15	2000	0.4673	0.1808	6.13
873	15/15	2500	0.4837	0.1732	7.44
874	15/15	3000	0.4784	0.1624	8.52
875	15/a	500	0.5191	0.1808	0.64
876	15/a	1000	0.5220	0.1793	1.57
877	15/a	1500	0.5287	0.1776	2.37
878	15/a	2000	0.4501	0.1857	2.42
879	15/a	2500	0.4259	0.1862	3.24
880	15/a	3000	0.4288	0.1832	3.87
881	a/5	500	0.5244	0.1783	0.29
882	a/5	1000	0.5333	0.1755	0.42
883	a/5	1500	0.5338	0.1758	0.90
884	a/5	2000	0.5322	0.1782	1.10
885	a/5	2500	0.5266	0.1788	1.23
886	a/5	3000	0.5266	0.1783	1.62
887	a/10	500	0.5181	0.1788	0.38
888	a/10	1000	0.4644	0.1821	0.74
889	a/10	1500	0.4812	0.1743	0.94
890	a/10	2000	0.4562	0.1715	1.45
891	a/10	2500	0.4511	0.1695	1.80
892	a/10	3000	0.4487	0.1676	2.57
893	a/15	500	0.5000	0.1763	0.51
894	a/15	1000	0.4452	0.1797	1.14

895	a/15	1500	0.4465	0.1729	1.00
896	a/15	2000	0.4146	0.1761	2.08
897	a/15	2500	0.4114	0.1757	1.74
898	a/15	3000	0.4079	0.1761	2.86
899	a/a	500	0.5249	0.1793	0.23
900	a/a	1000	0.5273	0.1780	0.32
901	a/a	1500	0.5293	0.1772	0.45
902	a/a	2000	0.5338	0.1765	0.85
903	a/a	2500	0.5382	0.1784	0.88
904	a/a	3000	0.5280	0.1790	1.09