

UNIVERSIDADE ESTADUAL DE GOIÁS
CÂMPUS ANÁPOLIS CIÊNCIAS EXATAS E TECNOLÓGICAS - HENRIQUE SANTILLO
PROGRAMA DE PÓS-GRADUAÇÃO MESTRADO *STRICTO SENSU*
EM ENGENHARIA AGRÍCOLA

**REDES NEURAS ARTIFICIAIS NA ESTIMATIVA DO TEMPO DE
ARMAZENAMENTO DE GRÃOS DE FEIJÃO**

Hiago Felipe Lopes de Farias

ANÁPOLIS - GO
JUNHO 2018

**REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DO TEMPO DE
ARMAZENAMENTO DE GRÃOS DE FEIJÃO**

Hiago Felipe Lopes de Farias

Orientador: Prof. Dr. Ivano Alessandro Devilla

Dissertação apresentada à Universidade Estadual de Goiás - UEG, Campus Anápolis de Ciências Exatas e Tecnológicas - Henrique Santillo, como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola - Sistemas Agroindustriais, para obtenção do título de MESTRE.

ANÁPOLIS - GO
JUNHO 2018

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UEG com os dados fornecidos pelo(a) autor(a).

FF224r Farias, Hiago Felipe Lopes de
REDES NEURAIAS ARTIFICIAIS NA ESTIMATIVA DO TEMPO DE
ARMAZENAMENTO DE GRÃOS DE FEIJÃO / Hiago Felipe Lopes de
Farias; orientador Ivano Alessandro Devilla. -- Anápolis, 2018. 65 p.

Dissertação (Mestrado - Programa de Pós-Graduação Mestrado Acadêmico em
Engenharia Agrícola) -- Câmpus-Anápolis CET, Universidade Estadual de
Goiás, 2018.

1. Ciências Agrárias. 2. RNA. 3. Multilayer Perceptron . I. Devilla, Ivano
Alessandro, orient. II. Título.

**REDES NEURAIS ARTIFICIAIS NA ESTIMATIVA DO TEMPO DE
ARMAZENAMENTO DE GRÃOS DE FEIJÃO**

Por

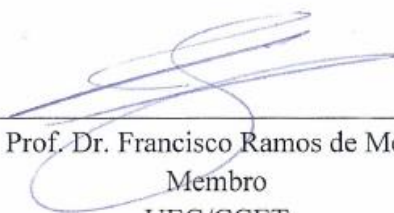
Hiago Felipe Lopes de Farias

Dissertação apresentada como parte das exigências para obtenção do título de
MESTRE EM ENGENHARIA AGRÍCOLA

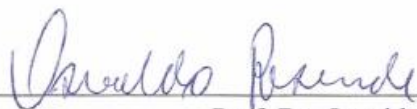
Aprovado em 28/06/2018



Prof. Dr. Ivano Alessandro Devilla
Orientador
UEG/CCET



Prof. Dr. Francisco Ramos de Melo
Membro
UEG/CCET



Prof. Dr. Osvaldo Resende
Membro
IFGOIANO /CÂMPUS RIO VERDE

AGRADECIMENTOS

A Deus, pelas graças recebidas e por sempre iluminar meu caminho.

Aos meus pais que foram os incentivadores para minha formação.

A minha noiva Elaine Freitas, por fazer parte da minha vida, sempre estando ao meu lado e me incentivando em todos os momentos, ao qual tenho grande admiração e amor, obrigado por tudo.

Ao professor MSc. Guiliano Rangel Alves que nunca mediu esforços para me ajudar, pelas horas dedicadas em me auxiliar e por todo ensinamento transmitido, sou muito grato.

Ao meu professor e orientador Dr. Ivano Alessandro Devilla, por toda dedicação e prontidão para me orientar no decorrer do trabalho. Pela confiança e por acreditar que era possível o desenvolvimento de este projeto.

Aos professores e colaboradores da UEG: Francisco Ramos de Melo, Roberta Passini, Sueli Freitas, Eliete Feitosa, Waldeir Costa, pelos ensinamentos.

A Coordenação de Aperfeiçoamento de Pessoas de Nível Superior (CAPES), pela concessão da bolsa de estudos.

Aos amigos (a): Fernando Camargo, Isneider Silva, Luana Lopes, pela amizade, apoio e colaboração na pesquisa.

SUMÁRIO

LISTA DE TABELAS	VIII
LISTA DE FIGURAS	IX
RESUMO	X
ASBTRACT	XI
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	3
2.1 Cultura do feijão	3
2.2 Características das cultivares de feijão.....	4
2.2.1 BRS Estilo	4
2.2.2 BRS Pontal	5
2.2.3 CNFC 10467.....	5
2.2.4 BRSMG Madrepérola.....	6
2.2.5 Linhagem canadense Pinto Beans 1533-15	6
2.3 Armazenamento.....	7
2.4 Cor	8
2.5 Dureza	10
2.6 Redes neurais artificiais.....	11
2.6.1 Neurônio artificial.....	12
2.6.2 Função de ativação	12
2.6.3 Arquitetura de rede neural artificial.....	14
2.6.3.1 Redes alimentadas adiante com camada única	14
2.6.3.2 Redes alimentadas adiante com múltiplas camadas	14
2.6.3.3 Redes Recorrentes	15
2.6.4 Treinamento e aprendizagem das RNAs	16
2.6.5 <i>Multilayer perceptron</i> MLP	17
2.7 Aplicações das RNAs	18
3. MATERIAL E MÉTODOS	19
3.1 Informações e condução experimental	19
3.2 Redes neurais artificiais.....	20
3.2.1 Categorização e normalização dos dados	20
3.2.2 Separação do conjunto de dados.....	22
3.2.3 Desenvolvimento e treinamento da RNA.....	22
3.2.4 Critério de seleção das RNAs	24
4. RESULTADOS E DISCUSSÃO	26
4.1 Treinamento e Seleção da rede neural.....	26

4.2 Validação da rede selecionada.....	32
5. CONCLUSÕES.....	34
6. REFERÊNCIAS BIBLIOGRÁFICAS	35
7. APÊNDICE	44

LISTA DE TABELAS

Tabela 1 - Valores para identificar a temperatura de armazenamento dos grãos de feijão	20
Tabela 2 - Valores utilizados na normalização dos dados para $x_{\text{mín}}$ e $x_{\text{máx}}$ por variável.	21
Tabela 3 - Estatística Descritiva das variáveis e fatores utilizados no treinamento das RNAs..	26
Tabela 4 - Parâmetros utilizados para realizar treinamento da rede MLP.....	27
Tabela 5 - Resultados dos dados após o treinamento das RNAs.....	28
Tabela 6 - Estatística descritiva da rede com 6 neurônios na repetição 204.	32
Tabela 7 - Dados utilizados para o desenvolvimento das RNAs para os conjuntos de treinamento, validação e teste.....	44
Tabela 8 - Dados do experimento realizado em laboratório da variável COR utilizados para o desenvolvimento da RNA.....	51
Tabela 9 - Dados do experimento realizado em laboratório da variável DUREZA utilizados para o desenvolvimento da RNA.....	53

LISTA DE FIGURAS

Figura 1 - Esquema para medição de cores CIELAB 1976, L^* (claro-escuro), a^* (verde-vermelha) e b^* (azul-amarelo).....	9
Figura 2 - Representação do neurônio de McCulloch e Pitts.	12
Figura 3 - Função de ativação binária	13
Figura 4 - Função de ativação bipolar	13
Figura 5 - Função sigmoide com parâmetro de inclinação β variável.....	14
Figura 6 - Rede feedforward (Multilayer).	15
Figura 7 - Representação de uma rede recorrente.	16
Figura 8 - Espaço de cor CIE $L^*a^*b^*$	20
Figura 9 - Esquema da estrutura da Rede Neural Artificial utilizada durante os treinamentos..	23
Figura 10 - Representação gráfica do R linear de treinamento, validação, teste e geral da rede com 6 neurônios treinamento 204.	28
Figura 11 - Comparativo dos dados estimados e observados do conjunto de treinamento na arquitetura com 6 neurônios e repetição 204.....	29
Figura 12 - Comparativo dos dados estimados e observados do conjunto de validação na arquitetura com 6 neurônios e repetição 204.....	29
Figura 13 - Comparativo dos dados estimados e observados do conjunto de teste na arquitetura com 6 neurônios e repetição 204.	30
Figura 14 - Gráfico da performance de treinamento da rede com 6 neurônios na camada intermediária, para a repetição de número 204.....	30
Figura 15 - Gráfico da performance de treinamento da rede com 17 neurônios na camada intermediária, para a repetição de número 747.....	31
Figura 16 - Comparativo dos dados estimados e observados da rede de validação (generalização) na arquitetura com 6 neurônios na camada intermediária.	33

Redes neurais artificiais na estimativa do tempo de armazenamento de grãos de feijão

RESUMO

O feijão é uma cultura amplamente cultivada no Brasil e no mundo. No período da armazenagem dos grãos, ocorre a deterioração do produto, que é gradativa, irreversível e acumulativa. As Redes Neurais Artificiais (RNAs) têm sido utilizadas numa larga gama de aplicações, tais como: classificação padrão, padrão de reconhecimento, otimização, previsão e controle automático. Em alguns casos, as RNAs têm apresentado desempenho superior aos modelos de regressão. Em face ao exposto, objetivou-se com este trabalho avaliar o desempenho das redes neurais artificiais na predição do tempo de armazenamento dos grãos de feijão em função da cor, dureza do tegumento e de diferentes temperaturas. Os grãos foram produzidos e armazenados pela Embrapa Arroz e Feijão, localizada no município de Santo Antônio de Goiás, safra 2013/2014. Foram armazenados 5 grupos de cultivares de feijão carioca com teor de água de 13% b.u. no ano de 2014, as amostras foram armazenadas em câmara tipo Biochemical Oxygen Demand (BOD), com temperaturas (15, 21 e 37 °C). Amostras de grãos foram retiradas aos (36, 72, 108, 144 e 180) dias de armazenamento e foram feitas avaliações de coloração e dureza do tegumento dos grãos. A primeira avaliação foi realizada com os grãos recém-colhidos no ano de 2014, identificados como amostras controle. Os dados foram normalizados entre -1 a 1, as redes treinadas foram do tipo *Multilayer Perceptron* (MLP), após o treinamento foi selecionada a rede que apresentou melhor performance para solução do problema. A melhor RNA teve um índice de acerto de 83,0% com os dados de treinamento e 91,2% com dados de validação, apresentou correlação superior a 0,900 para treinamento, validação e teste. Nas condições em que foi desenvolvido este trabalho pode-se concluir que as RNAs podem ser utilizadas para estimar os dias de armazenamento em função da cor, dureza e temperatura.

Palavras-chave: Escurecimento, dureza, RNA, *multilayer perceptron*.

**Artificial neural networks in the estimation
of the storage time of bean grains**

ASBTRACT

Bean is a widely cultivated crop in Brazil and the world. In the period of storage of grains, deterioration of the product occurs, which is gradual, irreversible and cumulative. Artificial Neural Networks (ANNs) have been used in a wide range of applications, such as: standard classification, recognition pattern, optimization, prediction and automatic control. In some cases, ANNs have performed better than the regression models. In the light of the above, this work aimed to evaluate the performance of artificial neural networks in predicting the storage time of bean grains as a function of color, tegument hardness and different temperatures. The grains were produced and stored by Embrapa Rice e Beans, located in the municipality of Santo Antônio de Goiás, harvest 2013/2014. Five groups of carioca bean cultivars with water content of 13% b.u. in the year 2014, the samples were stored in a Biochemical Oxygen Demand (BOD) type chamber, at temperatures (15, 21 and 37 ° C). Grain samples were collected at (36, 72, 108, 144 and 180) days of storage and staining and hardness evaluations of the tegument of the grains. The first evaluation was performed with the grains freshly harvested in the year 2014, identified as control samples. Data were normalized between -1 to 1, the trained networks were of the Multilayer Perceptron (MLP) type, after the training was selected the network that presented better performance to solve the problem. The best RNA had a success rate of 83.0% with training data and 91.2% with validation data, presented a correlation higher than 0.900 for training, validation and testing. Under the conditions in which this work was developed it can be concluded that RNAs can be used to estimate storage days as a function of color, hardness and temperature.

Key words: dimming, hardness, ANN, multilayer perceptron

1. INTRODUÇÃO

O feijão (*Phaseolus vulgaris* L.) é uma espécie vegetal pertencente à família Fabaceae, de extrema importância na alimentação humana, sendo de fácil acesso e uma importante fonte de proteína, complexos minerais, vitaminas e compostos fenólicos (DÍAZ et al., 2010). É uma cultura amplamente cultivada e consumida nos países em desenvolvimento das Américas e da África (MOTA, 2016).

A cultura apresenta uma ampla diversidade nos tipos de grãos, especialmente no que se refere à forma, ao tamanho e às cores (SILVA et al., 2012a). No Brasil são cultivados feijões dos tipos preto, carioca, roxo, mulatinho, rosinha, vermelho, etc. Embora exista preferência regional por determinado tipo de grão, feijões do grupo carioca são os mais cultivados e consumidos (SIQUEIRA et al., 2014).

O Brasil é um dos principais produtores mundiais desse grão, para a safra de 2017/2018 a estimativa de produção é de 3,30 milhões de toneladas de feijão, enquanto que na safra 2016/2017 obteve-se uma produtividade de 3,32 milhões de toneladas, apresentando uma redução de 0,6% na sua produção, comparado a safra anterior (CONAB, 2018).

Como a produção de grãos é distribuída ao longo do ano, uma forma de evitar a oscilação de preços de feijão no mercado e sua escassez entre as safras de cultivo, após a colheita do feijão, torna-se necessário o seu armazenamento (BRACKMANN et al., 2002). O armazenamento visa preservar as características do produto e é influenciado pela constituição genética, pelos fatores ambientais e pela interação dos genótipos com os ambientes (OLIVEIRA et al., 2011).

Durante o armazenamento dos grãos de feijão, ocorrem algumas alterações químicas e estruturais que levam a depreciação da qualidade geral e do valor nutritivo do produto (ZAMBIASI, 2015). Para que sejam mantidas as qualidades físico-químicas, nutricionais e tecnológicas dos grãos de feijão, condições controladas no armazenamento são essenciais, no qual o teor de água do produto, a umidade relativa do ar e a temperatura de armazenamento são os parâmetros mais críticos (SCHOENINGER et al., 2013; RESENDE et al., 2008).

O armazenamento em ambientes não controlados de temperatura e umidade é um fator que pode prejudicar a qualidade final deste produto, aumentando a deterioração e a perda quantitativa pelo ataque microbiano, de pragas e pelo próprio metabolismo dos grãos. Grãos com maiores teores de água possuem maior taxa respiratória e com isso maior degradação de suas reservas (MOTA, 2016; OLIVEIRA, 2008).

No período da armazenagem dos grãos, ocorre a deterioração do produto, que é gradativa, irreversível e acumulativa. A velocidade de deterioração depende das condições ambientais e dos próprios componentes químicos e físicos dos grãos no momento inicial da estocagem. Essa perda de qualidade caracteriza-se por mudanças no sabor, escurecimento do tegumento dos grãos em algumas cultivares e o aumento no grau de dureza, com elevação do tempo de cocção (RIBEIRO et al., 2007).

O conhecimento da cor e dureza dos grãos de feijão, são características desejáveis pelos consumidores, mas essas características não são suficientes para prever o tempo de prateleira dos grãos. Atualmente não existem modelos matemáticos que consigam solucionar essa variável, mais tal problema pode ser modelado com a utilização da inteligência artificial, as quais são formadas por elementos de processamento simples, os neurônios artificiais (LEAL, 2015).

As redes neurais artificiais (RNAs) tem sua inspiração nas redes neurais biológicas e seu principal componente de processamento, o neurônio. O neurônio artificial nada mais é do que uma modelagem simplificada do funcionamento do neurônio biológico, sendo que esta unidade de processamento se torna fundamental para o funcionamento das redes neurais artificiais (HAYKIN, 2001; SILVA et al., 2012b).

As RNAs são modelos que emulam uma rede de neurônios biológicos, capazes de processar rapidamente uma grande quantidade de dados e de reconhecer padrões com base em sua autoaprendizagem (HAYKIN, 2009). Essas redes são sistemas computacionais paralelos, constituídos por unidades de processamento simples, também denominadas neurônios artificiais, conectadas entre si de maneira específica para desempenhar determinada tarefa (BINOTI et al., 2013).

As RNAs têm sido utilizadas numa larga gama de aplicações, incluindo: classificação padrão, padrão de reconhecimento, otimização, previsão e controle automático (HAQUE e KASHTIBAN, 2007). Um grande destaque das RNAs é a capacidade de aprender a partir da apresentação de um conjunto de amostras que represente o problema a ser trabalhado, sendo que após o treinamento a RNA é capaz de produzir a saída desejada a partir de padrões não apresentados no processo de aprendizagem (SILVA et al., 2012b; HAYKIN, 2005).

Em face ao exposto, objetivou-se com este trabalho avaliar o desempenho das redes neurais artificiais na estimativa do tempo de armazenamento dos grãos de feijão em função da cor, dureza do tegumento e de diferentes temperaturas.

2. REVISÃO DE LITERATURA

2.1 Cultura do feijão

O feijão (*Phaseolus vulgaris* L.) é uma das principais culturas produzidas no Brasil e no mundo. Sua importância supera o aspecto econômico, por sua relevância enquanto fator de segurança alimentar e nutricional e sua importância cultural na culinária de diversos países e culturas (SILVA et al., 2012c).

O gênero *Phaseolus* originou-se nas Américas e possui cerca de 55 espécies, das quais apenas cinco são cultivadas: *P. vulgaris* L. (feijão comum), *P. lunatus* (feijão de lima), *P. coccineus* L. (feijão ayocote), *P. acutifolius* A. Gray (feijão tepari) e *P. polyanthus* Greenman. A espécie de maior relevância econômica é o *Phaseolus vulgaris*, por ser cultivada há mais tempo e a mais consumida (SANTOS e GAVILANES, 2006).

Segundo a espécie a que pertence, o feijão é classificado em dois grupos: grupo I, feijão comum proveniente da espécie *Phaseolus vulgaris* L.; grupo II, feijão-caupi (Feijão-de-corda ou feijão-macassar), quando proveniente da espécie *Vigna unguiculata* (L) Walp, conforme estabelecido pela Instrução Normativa Nº 12/2008, do Ministério da Agricultura Pecuária e Abastecimento (BRASIL, 2008).

O feijão pode ser cultivado em três safras anuais. O feijão das “águas” ou 1ª safra, é plantado nas Regiões Sul, Sudeste, Centro-Oeste e nos Estados do Ceará, Rio Grande do Norte e Bahia, sendo cultivado entre os meses de agosto a novembro. O feijão da “seca” ou 2ª safra, é plantado nas Regiões Sul, Sudeste, Centro-Oeste e em único período de plantio no Norte, onde é consorciado com o milho, essa safra é cultivado entre os meses de dezembro a abril. A safra de “inverno” ou 3ª safra, também designada como safra irrigada, acontece com o feijão cultivado entre os meses de abril a julho, no Centro-Sul do Brasil (EMBRAPA, 2017).

Em termos de produção de grãos de feijão, cerca de 61% da produção mundial deste grão é proveniente de apenas seis países. Myanmar é o maior produtor mundial dessa leguminosa, seguido da Índia, Brasil, China, EUA e México (CONAB, 2017).

O Brasil é considerado o terceiro maior produtor deste grão, para a safra agrícola de 2017/2018 a estimativa de produção é de 3,30 milhões de toneladas de feijão, já em relação à área total de feijão para a mesma safra, será de 3,16 milhões de hectares (CONAB, 2018). Na produção de feijão, o Estado de Goiás apresenta uma estimativa de 365,2 mil toneladas de grão para a safra 2017/2018, apresentando um aumento de 6,5% em relação à safra passada, na qual teve uma produção de 343,0 mil toneladas (CONAB, 2018).

O hábito do consumo de feijão pelas famílias brasileiras, em associação com a ampla adaptação climática dessa cultura, faz com que o feijão esteja distribuído por todo o território. Além disso, sua grande variedade de cores, tamanhos e formas das sementes são consideradas as características que mais influenciam a preferência dos consumidores por determinada variedade (CARNEIRO et al., 2005).

2.2 Características das cultivares de feijão

A cultura do feijão apresenta uma ampla diversidade nos tipos de grãos, especialmente no que se refere à forma, ao tamanho e às cores. No mercado brasileiro, esta diversidade é bem evidente. Contudo, a preferência é predominante sobre o grão tipo Carioca, que possui tegumento de coloração clara e cujo escurecimento e endurecimento dos grãos ocorrem durante o período de armazenamento, fenômeno que causa perda considerável no valor comercial do feijão (SILVA et al., 2012a).

Em relação ao consumo, o feijão é definido conforme os aspectos sensoriais do grão, como cor, tamanho, forma e qualidade culinária como: rápida hidratação, reduzido tempo de cocção, caldo espesso, bom sabor e textura, grãos moderadamente rachados, casca delgada e boa estabilidade de cor (BASSINELLO, 2008).

Além de ser um dos maiores produtores mundiais, o Brasil é considerado o maior consumidor de feijão. No Brasil, a preferência tradicional de consumo tem sido por grãos do tipo comercial carioca, o que justifica a intensidade de esforços no sentido de desenvolver linhagens superiores com esse tipo de grão, que associam o maior número possível de características que expressem o fenótipo desejável (DEL PELOSO et al., 2003).

A adoção de uma nova cultivar pelos produtores é ditada pelas vantagens que esta deverá oferecer em relação às já existentes no mercado (CARNEIRO et al., 2012). Novas cultivares para serem lançadas devem superar as pré-existentes e, para isso, devem associar características agronômicas desejáveis como resistência a doenças, tolerância ao acamamento, arquitetura de plantas ereta e grande potencial produtivo. Com isso devem agregar ainda, grãos de elevada qualidade, especialmente em tamanho e aparência conforme Carbonell et al. (2014) e grãos claros e com reduzido tempo de cocção (JUNK-KNIEVEL et al., 2008).

2.2.1 BRS Estilo

A cultivar BRS Estilo, originou-se a partir do programa de melhoramento genético do feijoeiro comum da Embrapa Arroz e Feijão, sendo uma cultivar de grão tipo comercial carioca,

com arquitetura da planta ereta, associada a alto potencial produtivo, com estabilidade de produção. Possui uniformidade de coloração (bege com listras marrons) e de tamanho dos grãos, com massa média de 1000 grãos de 260 gramas e tempo de cocção de aproximadamente 26 minutos. Apresenta resistência a doenças, como ao mosaico-comum e aos patótipos 23, 55, 71, 89, 89 – AS, 95, 127 e 453 de *Colletotrichum lindemuthianum*, agente causal da antracnose (MELO et al., 2010).

Essa cultivar possui ciclo normal de 85-95 dias, desde a emergência até a maturidade fisiológica) um alto potencial de produtividade de 4.011 kg ha⁻¹, com produção em três safras por ano. Sendo para as safras das “águas” em Goiás, São Paulo, Paraná, Santa Catarina, Pernambuco, Sergipe e Rio Grande do Sul; de “inverno” em Goiás, Mato Grosso e Tocantins; da “seca” em Goiás, Paraná, Santa Catarina, Rondônia, Mato Grosso e Mato Grosso do Sul (MELO et al., 2010).

2.2.2 BRS Pontal

O BRS Pontal é uma cultivar de grão tipo comercial carioca, as plantas apresentam porte semiprostrado na maioria dos sistemas de produção, em diferentes condições de solo e clima, possui baixa resistência ao acamamento. A cultivar possui uniformidade de coloração de grãos, com massa média de 1000 grãos de 261 gramas e excelentes qualidades culinárias, com tempo de cocção 26 minutos, sendo similar a cultivar BRS Estilo. Sob inoculação artificial é resistente ao mosaico-comum e apresenta reações resistente, intermediária e suscetível a respectivamente, 11, 6 e 7 patótipos de *Colletotrichum lindemuthianum*. Apresenta reação intermediária à ferrugem e ao crestamento-bacteriano-comum, é suscetível à mancha angular e ao mosaico dourado (DEL PELOSO, 2003).

Possui um ciclo médio de 87 dias da emergência à maturação fisiológica, com produtividade de aproximadamente 2.747 kg ha⁻¹, a cultivar pode ser cultivada nas três épocas de plantio (águas, seca e inverno). No momento do lançamento, a cultivar BRS Pontal havia sido indicada para plantio nos estados de Distrito Federal, Goiás, Mato Grosso do Sul, Mato Grosso e Minas Gerais. Posteriormente, sua indicação de plantio foi ampliada para Alagoas, Bahia, Sergipe, Tocantins, São Paulo, Paraná e Santa Catarina (SILVA e WANDER, 2009).

2.2.3 CNFC 10467

O CNFC 10467 é uma linhagem do grupo carioca, possui características como escurecimento lento do tegumento dos grãos, plantas de porte semiprostrado e alto nível de

resistência a antracnose, possui massa de 1000 grãos de 242 gramas e uma produtividade média de 3.118 kg ha⁻¹ quando cultivado no período de inverno (SILVA et al., 2011; AGUIAR et al., 2015).

Segundo Siqueira (2013), estudando o fenômeno de escurecimento e endurecimento de feijão carioca, verificou que a linhagem CNFC 10467 apresentou maiores valores de luminosidade e que os grãos se mantiveram visualmente mais claros, comparadas a outros grãos do tipo carioca ao longo do armazenamento. Já no período de armazenamento foi observado um aumento no tempo de cocção, ficando mais susceptível ao fenômeno de endurecimento.

2.2.4 BRSMG Madrepérola

O BRSMG Madrepérola é uma cultivar de grão carioca, cujos grãos permanecem claros por mais tempo em relação as cultivares de grãos tipo carioca existentes no mercado. As plantas dessa cultivar são de porte prostrado, hábito de crescimento indeterminado, tipo III, com baixa tolerância ao acamamento (ABREU et al., 2011).

A cultivar apresenta alto potencial produtivo e bom nível de resistência às principais doenças (mosaico comum e antracnose) que ocorrem no Estado de Minas Gerais, sendo indicada para plantio nesta região nas três safras de cultivo (“águas”, “seca” e inverno). A produtividade média de grãos é de 2.308 kg ha⁻¹, com ciclo entre 83-88 dias, apresenta massa média de 1000 grãos de 245 gramas e com tempo médio de cocção de 29,0 minutos (ABREU et al., 2011; CARNEIRO et al., 2012).

2.2.5 Linhagem canadense Pinto Beans 1533-15

A linhagem de feijão canadense pinto beans 1533-15 é oriunda do Centro de Desenvolvimento de Cultivos (CDC), Universidade de Saskatchewan no Canadá (SINGH et al., 2006).

A qualidade dos grãos pinto beans é avaliada por fatores visuais, como tamanho, cor e forma. Essa cultivar tem o escurecimento do grão lento, enquanto a maioria das outras linhas e cultivares de pinto beans são de escurecimento normal. Em contrapartida essa cultivar tem um menor potencial de produtividade em relação a maioria das cultivares pinto beans (FELICETTI et al., 2012). Os grãos dessa cultivar é de ciclo precoce e apresenta uma produtividade média de 1.609 kg ha⁻¹ (FARIA et al., 2009).

2.3 Armazenamento

A qualidade dos grãos é um importante parâmetro para a comercialização e o processamento, e afeta o valor final do produto. Apesar de toda a tecnologia disponível à agricultura brasileira, as perdas qualitativas e quantitativas, originadas durante o processo de pós-colheita dos grãos, ainda não são bem controladas durante o armazenamento, a massa de grãos é constantemente submetida a fatores externos (FARONI et al., 2009).

E se tratando de armazenamento é importante aliar conhecimentos sobre as condições do grão, o teor de água e a natureza, além das condições ambientais como a temperatura, a umidade relativa e a luminosidade, a fim de manter a qualidade do produto armazenado (POHNDORF, 2012).

Após a colheita, a respiração e outros processos metabólicos de grãos continuam ocasionando perdas expressivas de qualidade. Além disso, um longo período de armazenamento pode ocasionar o escurecimento do tegumento do feijão tipo carioca, depreciando seu valor comercial (BRACKMANN et al., 2002).

A velocidade da deterioração durante o armazenamento vai depender das condições às quais o produto está submetido e também das condições iniciais do próprio produto. No caso do feijão, a queda de qualidade está ligada ao aumento do tempo de cocção e aumento da dureza, mudanças do sabor, redução do valor nutricional e da capacidade de absorção de água, e para algumas cultivares ocorre ainda o escurecimento do tegumento (SARTORI, 1996).

A utilização adequada de técnicas de armazenamento pode contribuir para prolongar a conservação da qualidade dos grãos. Neste sentido, os programas de melhoramento que visam à introdução de novos genótipos devem considerar na seleção, grãos com características culinárias adequadas aos consumidores, incluindo a preservação da cor e a cocção rápida (MORAIS et al., 2010).

O feijão passa por modificações fisiológicas e bioquímicas que alteram a sua qualidade durante o período de armazenamento tanto para o uso como semente quanto para consumo como alimento. Santos et al. (2005) estudaram essas alterações em sementes de feijoeiro armazenadas em condições ambientais não controladas de temperatura e umidade relativa do ar e concluíram que existem cultivares com diferentes aptidões para a manutenção da qualidade fisiológica durante o armazenamento.

A temperatura é um dos fatores físicos mais importante na conservação dos grãos armazenados, pois a maioria das reações químicas é acelerada com o aumento da temperatura. Quando a temperatura de é mais baixa, pode-se armazenar com segurança, inclusive se o teor de

água dos grãos estiver um pouco mais elevado, pois a baixa temperatura reduz a atividade de água e inibe o desenvolvimento de microrganismos e de insetos-praga (BRAGANTINI, 2005; RIGUEIRA et al., 2009).

O teor de água dos grãos juntamente com a temperatura, são fatores primordiais na conservação dos grãos e sementes. Quando o teor de água está em torno de 11 a 13% (b.u.), a atividade de respiratória é diminuída e o metabolismo é reduzido. A combinação de baixa temperatura e baixo teor de água dos grãos é ideal para a manutenção da qualidade de grãos e sementes (BRAGANTINI, 2005).

A manutenção da temperatura em níveis inferiores a 20 °C, apresenta-se como uma ótima ferramenta na conservação da qualidade dos grãos de feijão, uma vez que mesmo com teores de água elevado essa temperatura não permitirá o desenvolvimento de fungos, bactérias e ainda desacelerará a respiração e degradação dos nutrientes. Temperaturas elevadas no armazenamento, acima dos 25 °C, podem promover além do desenvolvimento de fungos e bactérias, o aumento das reações químicas (BRAGANTINI, 2005).

2.4 Cor

O escurecimento pós-colheita do tegumento do grão de feijão tem sido relacionado a mudanças bioquímicas durante o armazenamento. Ao longo do tempo, compostos presentes no tegumento podem sofrer oxidação ou outras mudanças químicas que levam a novos compostos, alterando a cor dos grãos armazenados (SIQUEIRA, 2013).

A cor, o aroma, a textura e o valor nutritivo dos alimentos determinam a aquisição e consumo de alimentos, pois influenciam a preferência do consumidor (SILOCHI, 2015). As características tecnológicas que se destacam no momento de adquirir o produto são o tamanho dos grãos, a cor do tegumento e o brilho. Portanto, a cor do tegumento é uma característica decisiva para o sucesso de um cultivar (ALMEIDA, 2016).

Em várias classes comerciais de feijão, incluindo carioca, pinto e *cranberry*, a cor creme do tegumento muda lentamente para marrom escuro após a semente estar fisiologicamente madura. Estudos demonstraram que este escurecimento pós-colheita do tegumento ocorre mais rapidamente em ambientes com alta temperatura e umidade relativa do ar e presença de luz e oxigênio (BRACKMANN et al., 2002; JUNK-KNIEVEL et al., 2007).

A cor do feijão é uma das atribuições da qualidade tecnológica, que influencia o consumidor no momento da compra. O escurecimento do grão ocorre de acordo com as condições de armazenamento e o consumidor associa o grão escurecido com seu envelhecimento e

consequente, endurecimento, depreciando assim seu valor comercial (BASSINELLO et al., 2005).

Tendo em vista a grande perda econômica que grãos de tegumento escuro representam no mercado de feijão, devido a estes serem preteridos pelos consumidores no ato da compra, os programas de melhoramento genético do feijoeiro comum têm se concentrado em grãos com o fundo mais claro e também, na manutenção da cor clara pelo maior tempo possível (SILVA et al., 2008).

O tegumento do grão apresenta ampla variabilidade de cores, pode ser de cor uniforme ou possuir mais de uma cor, distribuídas em forma de estrias, pontuações ou manchas. As diferenças, das características externas apresentadas pelos grãos são usadas para classificar os grãos em tipos comerciais: como carioca, preto, mulatinho, roxo entre outros (NUNES et al., 2017).

A medida de cor é um parâmetro usado como índice de qualidade de alimentos crus ou processados, bem como para avaliar as mudanças de qualidade em consequência de processamento, armazenamento ou outros fatores (ABEROUMAND, 2011). Alguns métodos foram desenvolvidos para a análise da cor, dentre estes tem-se: Cie, Hunter, Munsell e Cielab, em que o sistema CIELAB 1976 (Comissão Internacional de Iluminantes) (Figura 1), é considerado um dos mais práticos e com maior aceitação por pesquisadores sendo o mais indicativo da percepção sensorial (GRANATTO e MASSON, 2010).




Figura 1 - Esquema para medição de cores CIELAB 1976, L^* (claro-escuro), a^* (verde-vermelha) e b^* (azul-amarelo).

Fonte: Handprint (2018)

O sistema CIELAB 1976 mede o grau de luminosidade (L^*), que é a relação entre a luz refletida e absorvida, é expressa em uma escala de 0 a 100, em que 0 representa o preto absoluto e 100 o branco absoluto; a cromaticidade ($\pm a^*$) assume valores positivos para cores avermelhadas e valores negativos para as tonalidades esverdeadas (-60 a 60); enquanto a cromaticidade ($\pm b^*$)

assume valores positivos para cores em tom amarelo e negativos para tons de azul (-60 a 60). A cor representada no sistema de coordenadas retangulares (L^* , a^* , b^*), mostra variáveis dependentes e de difícil interpretação, quando avaliadas separadamente (GRANATTO e MASSON, 2010).

Assim, as prioridades dos programas de melhoramento genético são desenvolver cultivares produtivas, resistentes às pragas e doenças, que apresentem cocção rápida (LEMOS et al., 2004) e principalmente, cor clara e menor suscetibilidade ao escurecimento para aumentar a probabilidade de aceitação por produtores e consumidores.

Para grãos do tipo carioca, o tegumento claro é associada com grãos recém-colhidos e de rápido cozimento e cultivares com luminosidade (L^*) superior a 55 têm maior aceitação no mercado (OLIVEIRA et al., 2011).

2.5 Dureza

O armazenamento dos grãos de feijão por um tempo prolongado, reflete no grau de dureza em decorrência do decréscimo da qualidade fisiológica, causando mudanças do sabor, endurecimento do tegumento, aumento na dureza do grão e resistência à cocção (MORAIS et al., 2010). Desta forma recomenda-se que seja oferecido ao consumidor, grãos colhidos recentemente.

Durante os longos períodos de armazenamento, frequentemente sob condições inadequadas, ocorre o desenvolvimento de defeitos (*hardshell* e *hard-to-cook*) na textura do grão que causa inúmeros prejuízos econômicos e nutricionais (BRACKMANN et al., 2002). Devido as condições inapropriadas de armazenamento os grãos de feijões, torna-se endurecido e resistente ao cozimento (OLIVEIRA et al., 2011).

Quando os grãos são submetidos à temperatura e umidade elevadas, adquirem o defeito conhecido como *hard-to-cook* (difícil de cozinhar) são caracterizados por necessitarem de um tempo de cozimento prolongado para amolecerem, ou não amolecem, mesmo depois de um cozimento prolongado em água fervente (JOÃO, 2016). Esse defeito nos grãos faz com que a qualidade e aceitabilidade pelos consumidores caiam drasticamente, sendo assim, fatores como tempo de cozimento e absorção de água se tornam um dos principais parâmetros de qualidade de grãos de feijão (COELHO et al., 2009).

O desenvolvimento do fenômeno *hardshell* ou casca dura, impede a reidratação dos grãos, este fenômeno é favorecido pelas condições de baixa umidade relativa na atmosfera de armazenamento e pelo alto teor de água nos grãos (RESENDE et al., 2008).

A perda de qualidade durante o armazenamento manifesta-se pelo aumento no grau de dureza do feijão, aumentando o tempo necessário para o cozimento, além de alterar o sabor e provocar o escurecimento do tegumento (RIOS et al., 2002).

A qualidade de grãos pode ser determinada pela aceitabilidade ao consumo, a qual está relacionada principalmente a suas características tecnológicas de absorção de água antes e após o cozimento, tempo de cozimento, porcentagem de sólidos solúveis no caldo, cor do tegumento e do caldo. Essas características podem ser alteradas durante o armazenamento em condições inadequadas ou mesmo pela presença de inseto-praga (RESENDE et al., 2008; COELHO et al., 2009).

Balamaze et al. (2008), ao avaliarem a susceptibilidade ao defeito *hard-to-cook* de grãos de quatro cultivares de feijão em função do local de plantio, utilizaram diferentes embalagens para o armazenamento, em condições de temperatura e umidade relativa do local de armazenamento ambiente, durante seis meses, verificaram que a embalagem de sisal permitiu o equilíbrio de temperatura de 25 °C e 74% de umidade relativa e proporcionou maior desenvolvimento do *hard-to-cook* em relação às outras embalagens (polipropileno, recipientes de plástico e pote).

2.6 Redes neurais artificiais

Em sua forma mais geral, uma rede neural é um sistema projetado para modelar a maneira como o cérebro realiza uma tarefa particular, podendo ser implementada utilizando-se componentes eletrônicos ou simulada por software em um computador digital. Para alcançarem bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples, denominadas de “neurônios” ou unidades de processamento (HAYKIN, 2001).

As redes neurais também possuem características importantes, das quais podem se destacar três, de acordo com Silva et al. (2010) são elas: a) habilidade de adaptação por experiência; objetivando aperfeiçoar seu desempenho e possibilitando a aquisição de conhecimento; b) experimentação; capacidade de aprendizado e por intermédio de um algoritmo de treinamento; c) habilidade de generalização, isto é, após o treinamento da rede, essa é capaz de generalizar o conhecimento, podendo estimar soluções até então desconhecidas.

O surgimento das RNAs ocorreu com o modelo matemático do neurônio biológico proposto por Warren McCulloch e Walter Pitts em 1943 (McCULLOCH e PITTS, 1943). O modelo, denominado neurônio MCP (McCulloch-Pitts), é descrito por um conjunto de n entradas,

as quais são multiplicadas por um determinado peso e em seguida, os resultados são somados e comparados a um limiar (NIED, 2007).

2.6.1 Neurônio artificial

Os neurônios artificiais imitam o comportamento dos neurônios biológicos que recebem informações por meio dos dendritos (no neurônio artificial equivalem à camada de entrada). Se a intensidade de sinais recebidos for suficientemente alta (no neurônio artificial é indicado pela somatória das informações ponderadas recebidas e é feita na camada de processamento) será disparado uma resposta para as células seguintes chamadas neurônios pós-sinápticos (no neurônio artificial a resposta ocorre de qualquer maneira e é feita pela camada de saída). É pela sinapse que os neurônios se unem funcionalmente e uma das funções básicas executadas por um neurônio é a combinação de sinais recebidos de neurônios anteriores (BRAGA et al., 2012).

A descrição matemática de neurônio artificial, proposto por McCulloch e Pitts (1943), segue um modelo composto por n entradas (terminais, equivalente aos dendritos) que são responsáveis por receber os valores x_1, x_2, \dots, x_n e apenas um terminal de saída y (equivalente ao axônio). O comportamento das sinapses é simulado pela aplicação de pesos (w_1, w_2, \dots, w_n) na qual as entradas que podem assumir valores positivos ou negativos, dependendo das sinapses correspondentes serem inibitórias ou excitatórias. A saída só é acionada quando a soma dos impulsos recebidos (Σ) ultrapassa o limiar de excitação $g(u)$ (Figura 2).




Figura 2 - Representação do neurônio de McCulloch e Pitts.
Fonte: Braga et al. (2012)

2.6.2 Função de ativação

Um dos componentes mais importantes do neurônio artificial é a sua função de ativação, que gera a saída y do neurônio a partir da soma ponderada dos valores dos pesos $w = (w_1, w_2, \dots, w_n)$ e de entrada $x = (x_1, x_2, \dots, x_n)$, podendo assumir valores do tipo: binários (0 ou 1); bipolares (-1 ou 1) e reais (HAYKIN, 2005). Segundo Haykin (2001) existem diversos tipos de funções de ativação, sendo as mais populares: função limiar (degrau), função linear por partes, função logística ou sigmoideal.

A função limiar, utilizada no modelo McCulloch e Pitts, limita a saída do neurônio a apenas dois valores (binária: 0 ou 1, ou bipolar: -1 ou 1). A função binária Equação 1, acontece quando nível de atividade interna do neurônio for negativo a saída do neurônio assume valor 0, e 1 caso contrário, é representado conforme (Figura 3) (McCULLOCH e PITTS, 1943).

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (1)$$




Figura 3 - Função de ativação binária

A função bipolar Equação 2, acontece quando nível de atividade interna do neurônio for negativo a saída do neurônio assumirá valor -1 e 1 caso contrário, é representado conforme (Figura 4) (McCULLOCH e PITTS, 1943).

$$g(u) = \begin{cases} +1, & \text{se } u \geq 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (2)$$




Figura 4 - Função de ativação bipolar

A função sigmoideal é definida como uma função crescente com balanceamento adequado entre o comportamento linear e não linear e assume um intervalo de variação entre 0 e 1 (Figura 5) (McCULLOCH e PITTS, 1943). Um exemplo de função sigmoide é a função logística, definida por:

$$g(u) = \frac{1}{1 + e^{(-\beta u)}} \quad (3)$$




Figura 5 - Função sigmoide com parâmetro de inclinação β variável.

2.6.3 Arquitetura de rede neural artificial

Uma das maiores dificuldades encontradas no uso das redes neurais é a escolha da melhor arquitetura, uma vez que esse processo é experimental e demanda um grande tempo de execução. Na prática, o processo deve ser aplicado com o intuito de testar vários métodos de aprendizado e as diferentes configurações que uma rede possa ter para a resolução de um problema em específico (MIRANDA et al., 2009). Em geral, pode-se identificar três classes de arquiteturas de rede fundamentalmente diferentes: redes alimentadas adiante com camada única, redes alimentadas diretamente com múltiplas camadas e redes recorrentes.

2.6.3.1 Redes alimentadas adiante com camada única

Redes neurais de camada única são constituídas por uma camada de entrada seguida de uma camada de saída sem retorno, ou seja, a camada de saída não retorna qualquer informação para a entrada, pode-se dizer que isso é alimentação adiante ou *feedforward*. Podem resolver problemas linearmente separáveis, por exemplo, separar em domínios diferentes retângulos de círculos (HAYKIN, 2001).

2.6.3.2 Redes alimentadas adiante com múltiplas camadas

Diferentemente da arquitetura anterior, essas redes apresentam duas ou mais camadas ocultas (Figura 6). A camada intermediária (camada oculta), tem como função de processar os sinais de entrada antes de enviá-los aos neurônios de saída, possui uma maior capacidade computacional e possibilitam aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos dentre outras. Um dos principais tipos de rede que utiliza esta arquitetura é o *Multilayer Perceptron* (BRAGA et al., 2012; SILVA et al., 2010).




Figura 6 - Rede *feedforward* (Multilayer).
 Fonte: Silva et al. (2010)

2.6.3.3 Redes Recorrentes

Redes recorrentes possuem conexões de realimentação que proporcionam comportamento dinâmico. A realimentação gera um impacto significativo na capacidade de aprendizagem da rede e na sua performance (MATSUNAGA, 2012). Há dois tipos de redes recorrentes: aquelas em que o padrão de entrada é fixo e a saída caminha, dinamicamente, para um estado estável e aquelas em que ambas, entrada e saída, variam com o tempo, sendo estas últimas mais gerais e utilizadas com maior frequência (SEGATTO e COURY, 2006). As conexões de realimentação se originam dos neurônios da camada de saída e possuem uma memória de atraso que operam sobre todas as entradas $x(n)$ produzindo uma versão atrasada (Figura 7).

Há muitas variações de arquiteturas de redes recorrentes, sendo que algumas delas permitem o uso de algoritmos de treinamento mais simples ou adaptados a uma tarefa particular. Duas maneiras que podem ser usadas para treinar uma rede recorrente, e que não envolvem o uso de aproximações na computação dos gradientes são *Backpropagation Through Time* e redes recorrentes de tempo real (SEGATTO e COURY, 2006).




Figura 7 - Representação de uma rede recorrente.
Fonte: Silva et al. (2010)

2.6.4 Treinamento e aprendizagem das RNAs

O principal destaque das RNAs é a capacidade de aprendizado por meio do processamento das amostras que exprimem o comportamento do sistema como um todo. O processo de aprendizagem consiste na etapa por meio da qual os parâmetros livres de uma rede são adaptados por meio dos estímulos fornecidos pelo ambiente de treinamento e se torna capaz de fornecer uma solução generalizada para uma classe de problemas (HAYKIN, 2009).

O aprendizado de uma RNA é realizado por meio de processos iterativos de ajustes aplicados aos pesos sinápticos, o chamado treinamento. O aprendizado só ocorre quando a rede neural atinge uma solução generalizada para um determinado problema. Em síntese, treinar uma rede é ajustar a sua matriz de pesos sinápticos de forma que o vetor de saída coincida com um valor desejado para cada vetor de entrada (MIRANDA et al., 2009).

O aprendizado em RNAs pode ser classificado, de acordo com a ausência ou a presença de realimentação explícita do mundo exterior, em não supervisionado e em supervisionado, respectivamente (BARRETO, 2004).

A aprendizagem supervisionada baseia-se no erro entre a resposta esperada e a calculada pela rede, que é utilizado para ajustar os pesos. Se o resultado gerado pela rede for diferente da saída esperada, o algoritmo de treinamento ajusta os pesos, utilizando alguns critérios e procura reduzir o erro a um valor aceitável (BRAGA et al., 2012).

O processo de aprendizagem não supervisionado não utiliza o uso dos sinais de saída desejados do conjunto de amostras de treinamento, dessa forma o algoritmo conduz a rede a se auto organizar de forma que consiga identificar subconjuntos das amostras que tenham

similaridade. Os pesos e limiares dos neurônios são ajustados de forma a refletir essas similaridades (SILVA et al., 2010).

2.6.5 *Multilayer perceptron* MLP

As redes *Multilayer Perceptron* ou de retropropagação do erro possuem como característica principal ter no mínimo uma camada oculta de neurônios. Este tipo de rede se destaca por ser amplamente utilizada em diversas áreas do conhecimento, sendo considerada uma das mais versáteis quanto à aplicabilidade (BRAGA et al., 2012).

O algoritmo de *backpropagation*, também conhecido como retropropagação é o mais utilizado em redes do tipo *Multilayer Perceptron*. Baseado na estratégia de aprendizado supervisionado ele é dividido em duas fases bem definidas chamadas de propagação (*forward*) e retropropagação (*backward*) (FAVAN, 2015).

Na fase de propagação, um padrão de ativação é aplicado aos nós da camada de entrada da rede e seu efeito se propaga através da rede, camada por camada. Na última camada, um conjunto de saídas é produzido, configurando-se como resposta real da rede. Já na segunda fase denominada de retropropagação, todos os pesos sinápticos são ajustados de acordo com uma regra de correção de erro. O sinal de erro é propagado da saída para a entrada da rede, contra a direção das conexões sinápticas, sendo os pesos sinápticos ajustados para fazer com que a resposta real da rede se aproxime da resposta desejada, num sentido estatístico (NIED, 2007).

Este processo de ajustar os pesos de cada neurônio é realizado a cada iteração o que leva a rede a convergir muito lentamente, demandando assim, um grande esforço computacional. Buscando contornar esse inconveniente, várias técnicas têm sido incorporadas ao algoritmo *backpropagation* na busca por melhorar o seu tempo de convergência e diminuir o custo computacional requerido. Entre as técnicas de otimização mais utilizadas destacam-se: método de inserção do termo *momentum*, método *Resilient-Propagation* e o método Levenberg-Marquardt (HAGAN e MENHAJ, 1994).

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. O critério de parada do algoritmo *backpropagation* não é bem definido e geralmente é utilizado um número máximo de iterações. Porém, devem ser considerados a taxa de erro médio por ciclo e a capacidade de generalização da rede, observada na etapa de validação, já que pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de over-training ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de

generalização (LIMA et al., 2016). Quando treina-se uma RNA, geralmente deseja-se obter uma rede com a melhor capacidade de generalização possível, ou seja, a maior capacidade de responder corretamente a dados que não foram utilizados no processo de treinamento (SANTOS, 2015).

2.7 Aplicações das RNAs

Nos últimos anos, publicações de trabalhos envolvendo redes neurais artificiais (RNA) tem crescido gradativamente no Brasil (BISI et al., 2015).

Curi et al. (2014), utilizaram redes neurais artificiais na predição da vazão ideal de exaustores em aviários de frango de corte com diferentes tipologias, neste estudo as RNAs foram capazes de auxiliar a tomada de decisão quanto da vazão de ar dos exaustores necessária para renovação e resfriamento do ar nas instalações de frango de corte, em função das condições climáticas internas e externas.

Soares et al. (2014), estudando diferentes arquiteturas de redes neurais artificiais, obtiveram bons resultados na predição da produtividade da cultura do feijão, no qual as RNAs tiveram uma elevada capacidade preditiva e um ótimo coeficiente de desempenho.

Vendruscolo et al. (2015), avaliaram aplicabilidade das redes neurais artificiais para estimar altura de eucalipto, onde os resultados encontrados foram melhores que a modelagem por regressão, sendo que as RNAs apresentaram alto potencial para tal utilização e uma de suas vantagens é a inserção de variáveis categóricas no treino.

Leal et al. (2015) estudando os atributos do solo, matéria orgânica, capacidade de troca de cátions, saturação de bases e teor de argila por meio de adoção de redes neurais artificiais, permitiu a predição da produtividade do milho cultivado em “segunda safra” em região de cerrado.

Bonini Neto et al. (2017) desenvolveram um programa baseado em RNAs para classificação e análise de solos degradados, em que após seu treinamento, a rede foi capaz de fazer predições a partir dos atributos do solo, permitindo a identificando de seus níveis de recuperação.

Alves et al. (2018), utilizaram RNAs do tipo MLP, a rede selecionada teve alto índice de assertividade, sendo 98% para os dados de treinamento e 72% para os dados de validação, demonstrando que é viável a aplicação das redes neurais para estimar a produtividade da soja.

3. MATERIAL E MÉTODOS

3.1 Informações e condução experimental

Os grãos foram produzidos e armazenados pela Embrapa Arroz e Feijão, localizada no município de Santo Antônio de Goiás, safra 2013/2014. O armazenamento do feijão iniciou-se logo após a colheita e secagem do material com teor de água inicial de 13% b.u., no ano de 2014. Foram utilizados grãos de feijão das cultivares do grupo comercial carioca: BRS Estilo, BRS Pontal, Madrepérola, CNFC 10467 e uma linhagem do grupo Pinto Beans (1533-15).

As amostras foram armazenadas em câmara do tipo “BOD” (Biochemical Oxygen Demand), nas temperaturas de 15, 21 e 37°C, sendo a temperatura de 15°C simulando ambiente refrigerado, a de 21°C simulando temperatura ambiente e a de 37°C temperatura extrema para o armazenamento na Embrapa Arroz e Feijão.

Amostras com aproximadamente 0,4 kg de grãos, foram retiradas aos 36, 72, 108, 144 e 180 dias de armazenamento e colocadas em sacos plásticos previamente identificados com etiquetas. Em seguida, as amostras foram transportadas da Embrapa Arroz e Feijão para o laboratório de Secagem e Armazenamento de Produtos Vegetais do Câmpus de Ciências e Exatas e Tecnológicas - Henrique Santillo, da Universidade Estadual de Goiás. A primeira avaliação foi realizada com os grãos recém-colhidos no ano de 2014, identificados como amostra controle.

A dureza dos grãos de feijão foi avaliada por meio do teste de punção “*puncturetest*” em um texturômetro TA CT-3 *Texture Analyser*, com célula de carga de 50 kg. Cada grão foi avaliado quanto à resistência oferecida à penetração por geometria cilíndrica de ponta plana de 2 mm (P2), a uma velocidade constante de 1 mm s⁻¹ até 90% da sua altura inicial. Foram perfurados 30 grãos de feijão cru, para cada amostra e os resultados expressos em cN (centinewton) (SILOCHI, 2015).

A coloração do tegumento dos grãos de feijão foi determinada em um Colorímetro ColorQuest XE (Hunter Lab) com iluminação difusa (iluminante D65, ângulo de visão 10°), previamente calibrado com a placa branca padrão de configuração, utilizando-se o sistema CIELAB (L*, a*, b*), (CIE, 1978). Este sistema de coordenadas define a cor em termos de luminosidade (L*), vermelho versus verde (a*) e amarelo versus azul (b*), (Figura 8).




Figura 8 - Espaço de cor CIE $L^*a^*b^*$
 Fonte: Handprint (2018)

3.2 Redes neurais artificiais

As redes neurais artificiais foram treinadas com auxílio do software Matlab® 2017, utilizando pacote *Neural Network Toolbox*. As redes treinadas foram do tipo *Multilayer Perceptron* (MLP) com aprendizado supervisionado, sendo dividido em duas fases de treinamento, na primeira fase alimentada para frente (*feedforward*) e na segunda fase com retropropagação do (*erro backpropagation*), seguindo metodologia proposta por (BRAGA et al., 2012; RUSSEL e NORVIG, 2013).

3.2.1 Categorização e normalização dos dados

Os dados de temperatura foram tratados como categóricas, ou seja, variável independente, com a finalidade de encontrar a combinação linear da variável independente que forneça máxima correlação com as variáveis dependentes. Assim é recomendado seguir o mesmo tratamento dado as variáveis tipo *dummy* da Análise de Regressão Múltipla (BOHL et al., 2015; SHARMA et al., 2007). Dessa forma, a variável T1 e T2 podem assumir valores de 0 ou 1 (indicando a sua presença e indicando ausência de um atributo).

Na Tabela 1 observa-se como identificar a temperatura utilizando as variáveis T1 e T2, em que as duas variáveis assumem o valor 0 quando a temperatura de armazenamento considerado é de 15°C.

Tabela 1 - Valores para identificar a temperatura de armazenamento dos grãos de feijão

Temperaturas de Armazenamento	T1	T2
Temperatura 15 °C	0	0
Temperatura 21 °C	1	0
Temperatura 37 °C	1	1

Para o ajuste das RNAs, foi realizada a normalização dos dados com o objetivo de nivelar a ordem de grandeza proporcional para uso (LEAL, 2015), buscando-se assim equalizar o peso inicial que a variável possa assumir no início do treinamento. Para isso foi utilizada a transformação linear descrita na Equação 4 (SRINIVASAN et al., 1994). Os dados foram normalizados para faixa de valor entre -1 a 1.

$$y = \frac{(x - x_{\text{mín}})(d_2 - d_1)}{x_{\text{máx}} - x_{\text{mín}}} + d_1 \quad (4)$$

Em que:

y = resultado normalizado;

x = valor a ser normalizado;

$x_{\text{mín}}$ = valor mínimo de x;

$x_{\text{máx}}$ = valor máximo de x;

d_1 = limite inferior do resultado da normalização (-1); e

d_2 = limite superior do resultado da normalização (1).

Os valores de $x_{\text{máx}}$ e $x_{\text{mín}}$ utilizados na transformação das variáveis luminosidade (L^*), vermelho versus verde (a^*), amarelo versus azul (b^*), dias de armazenamento e dureza são mostrados na (Tabela 2).

Tabela 2 - Valores utilizados na normalização dos dados para $x_{\text{mín}}$ e $x_{\text{máx}}$ por variável.

Variável	Unidade	$x_{\text{mín}}$	$x_{\text{máx}}$	Autores
L^*	Un	35,00	65,00	BRACKMANN et al. (2002)
a^*	Un	5,00	15,00	BRACKMANN et al. (2002)
b^*	Un	13,00	25,00	BRACKMANN et al. (2002)
Dias de armazenamento	Un	0	200	
Dureza	cN	6.000,00	30.000,00	(SILOCHI, 2015)

Fonte: Adaptado (BRACKMANN et al. 2002); (SILOCHI, 2015).

Luminosidade (L); vermelho versus verde (a); e amarelo versus azul (b).

Após o treinamento e validação das redes, os resultados estimados pela RNA foram desnormalizados retornando a sua grandeza original. Para realizar essa transformação foi utilizado a Equação 5, sendo obtida isolando-se a variável “x” da Equação 4.

$$x = \frac{(x_{\text{máx}} - x_{\text{mín}})(y - d_1)}{d_2 - d_1} + x_{\text{máx}} \quad (5)$$

Em que:

x = resultado desnormalizado;

y = valor normalizado;

$x_{\text{mín}}$ = valor mínimo de x ;

$x_{\text{máx}}$ = valor máximo de x ;

d_1 = limite inferior do resultado da normalização (-1); e

d_2 = limite superior do resultado da normalização (1).

3.2.2 Separação do conjunto de dados

Os dados experimentais já normalizados, foram separados em três conjuntos de dados aleatoriamente, sendo: 70% para treinamento, 20% para validação e 10% para teste, para cada arquitetura de RNAs. A quantidade de amostras de cada um desses conjuntos foi escolhida mediante adaptação da proporção indicada por Braga et al. (2012) e Russel e Norvig (2013). O conjunto de dados foi composto por 300 amostras, sendo utilizados 270 para treinamento, validação e teste e as 30 amostras restantes foram utilizadas para testar a generalização da rede neural selecionada.

3.2.3 Desenvolvimento e treinamento da RNA

No início do desenvolvimento da RNA foi definida a camada de entrada, que utilizou um neurônio para cada uma das variáveis de entrada e a camada de saída contendo um neurônio, que corresponde os dias de armazenamento dos grãos de feijão.

Com o auxílio de uma planilha eletrônica os dados foram organizados em colunas, sendo as 7 primeiras colunas correspondente aos neurônios da camada de entrada (Dureza, L , a^* , b^* , T_1 , T_2 e Dias de armazenamento) e a última coluna o neurônio da camada de saída (Dias de armazenamento), o arquivo foi exportado no formato *Common Separated Values* - CSV e posteriormente foram feitas adequações em um editor de texto Notepad++ substituindo “ ” (espaço) por “;” (ponto e vírgula), para o formato esperado pelo software do programa de treinamento.

Para importação do arquivo para o treinamento de RNAs no software Matlab®, foram separadas duas matrizes de dados: uma matriz de entrada contendo as variáveis (Dureza, L , a^* , b^* , T_1 , T_2 e Dias de armazenamento) e outra matriz com a variável (Dias de armazenamento), que é o resultado esperado pela rede.

Antes de iniciar o treinamento, foram definidos alguns critérios para elaboração da programação, a saber:

- os dados foram divididos de forma aleatória em três conjuntos, sendo eles treinamento (70%), validação (20%) e teste (10%);
- foi selecionado o algoritmo de treinamento Levenberg-Marquardt, por ser um dos mais eficientes do tipo *Backpropagation* (LO SCHIAVO et al., 2015);
- número máximo de falhas de validação igual a 200.

A arquitetura da RNA foi composta por uma camada de entrada, uma camada intermediária e uma camada de saída. A Figura 9 mostra o esquema da arquitetura utilizada durante o treinamento das RNAs.

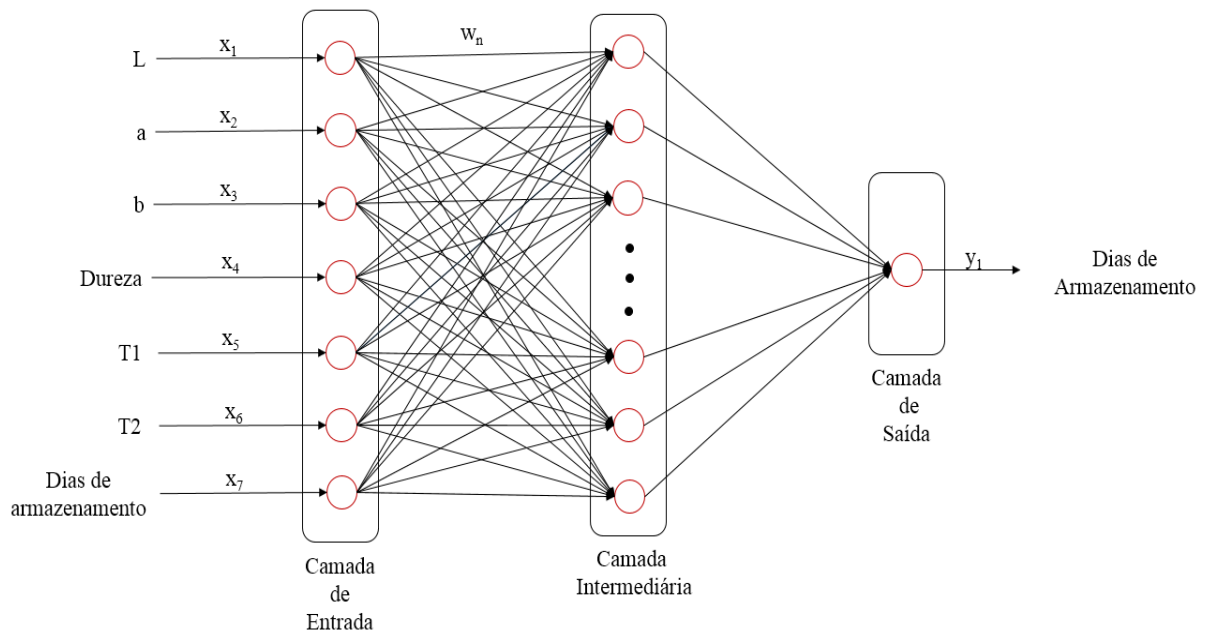


Figura 9 - Esquema da estrutura da Rede Neural Artificial utilizada durante os treinamentos.
Fonte: Autor

Após a elaboração do programa foram treinadas mil redes para cada arquitetura, variando-se o número de neurônio na camada intermediária entre 1 e 20, totalizando 20.000 redes treinadas do tipo MLP.

Como critério de parada desse algoritmo de treinamento foi utilizado o número total de ciclos igual a 1.000 ou Erro Quadrado Médio (*Mean Squared Error*, MSE) menor ou igual a 0,001, Equação 6. O treinamento foi finalizado quando um dos critérios foi atingido.

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - \alpha_i)^2 \quad (6)$$

Em que:

N = número de dados apresentados para treinamento;

e = diferença entre o valor esperado e o valor estimado pela rede;

t = valor estimado pela rede; e

α = valor esperado.

3.2.4 Critério de seleção das RNAs

Após concluído o treinamento das redes neurais foi gerado um arquivo no formato CSV, este arquivo foi editado no editor de texto Notepad++ substituindo as “,” (vírgulas) por “;” (ponto e vírgula) e em seguida os “.” (pontos) por “,” (vírgulas), concluído esses ajustes o arquivo foi aberto no Microsoft Excel e salvo no formato nativo do XLS.

O arquivo resultante possui 20.000 redes, sendo uma linha para cada rede treinada e 284 colunas, onde as colunas de 1 a 270 corresponde aos valores estimados pela rede neural e as demais colunas são as seguintes: Performance geral da rede; Performance no conjunto treinamento; Performance no conjunto de validação; Performance no conjunto de teste; R linear do conjunto de treinamento; R linear do conjunto de validação; R linear do conjunto de teste; R linear do conjunto geral; Correlação de Pearson do conjunto de treinamento; Correlação de Pearson do conjunto de validação; Correlação de Pearson do conjunto de teste; Época que ocorreu a parada do treinamento (convergência); Número de neurônios na camada oculta do treinamento; Número do treinamento realizado na arquitetura.

As melhores RNAs foram selecionadas com base nos seguintes critérios: Erro Quadrático Médio (Mean Squared Error, MSE), coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2), conforme as Equações 6, 7 e 8.

Coeficiente de correlação (r), Equação 7, pode variar de -1 a 1 e quanto maior o seu valor absoluto, maior o grau de associação entre os valores observados e estimados (SCHNEIDER, 1998). Este parâmetro permite quantificar o grau de associação entre os valores observados e os estimados pela RNA.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{[\sum_{i=1}^n (x_i - \bar{x})^2][\sum_{i=1}^n (y_i - \bar{y})^2]}} \quad (7)$$

Em que:

r = coeficiente de correlação de Pearson;

x_i = valores estimados;

y_i = valores observados;

\bar{x} = média dos valores estimados;

\bar{y} = média dos valores observados; e
 n = quantidade de padrões de teste.

Coefficiente de determinação (R^2) varia entre 0 e 1, indicando em percentagem o quanto o modelo consegue explicar os valores observados e estimados pela RNA. Quanto mais próximo da unidade for o coeficiente de determinação, melhor ele se ajusta à amostra, sendo descrita conforme a Equação 8:

$$R^2 = r^2 \quad (8)$$

Em que:

R^2 = coeficiente de determinação; e

r = coeficiente de correlação de Pearson.

Na seleção da melhor rede após o treinamento, os dados estimados pelas redes foram ordenados crescentemente pelo Erro Quadrático Médio do inglês (MSE), quanto menor esse valor, melhor será a performance da rede. Já para o coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2), a ordenação foi realizada de forma decrescentemente, em que quanto maior o valor da correlação de Pearson mais próximo o valor estimado está do valor observado. Já o R^2 indica correlação entre os dados observados e os estimados pela RNA treinada.

Na seleção mais criteriosa da melhor rede, os resultados de correlação de Pearson de treinamento, validação e teste foram ordenados decrescentemente e foi selecionada a rede que apresentou correlação de Pearson (r) superior a 0,900 em todos os parâmetros avaliados pois, a rede que apresenta boa generalização, tem capacidade de produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem).

Neste estudo foi desenvolvida 1 rede neural em função da média de todas as cultivares (Madrepérola, BRS Estilo, BRS Pontal, CNFC 10467 e a linhagem do grupo Pinto Beans), e das variáveis (Luminosidade (L^*), vermelho versus verde (a^*), amarelo versus azul (b^*) e dureza).

O delineamento experimental foi inteiramente ao acaso, em esquema fatorial triplo 3x5x6, com 3 repetições. Sendo três temperaturas de armazenamento (15, 21 e 37°C), cinco cultivares de feijão (BRS Estilo, BRS Pontal, Madrepérola, CNFC 10467 e uma linhagem do grupo Pinto Beans (1533-15)) e seis períodos de armazenamento (0, 36, 72, 108, 144 e 180 dias).

4. RESULTADOS E DISCUSSÃO

A estatística descritiva das variáveis utilizadas para o treinamento, teste e validação da rede Multilayer Perceptron (MLP) são mostradas na Tabela 3.

Tabela 3 - Estatística Descritiva das variáveis e fatores utilizados no treinamento das RNAs.

Variáveis/Fatores	Média	Mín	Máx	Var	DP	CV (%)
Dureza (cN)	14.283,39	9.795,00	19.010,00	4.505.057,43	2.122,51	14,86
L*	48,77	39,21	59,67	13,49	3,67	7,53
a*	8,77	6,15	12,66	2,61	1,62	18,42
b*	16,83	13,73	21,72	1,23	1,11	6,58
Temperatura °C	24,33	15,00	37,00	86,51	9,30	38,22
Dias de Armazenamento	108,00	36,00	180,00	2.600,67	51,00	47,22

Luminosidade (L); vermelho versus verde (a); e amarelo versus azul (b); Mín: valor mínimo; Máx: valor máximo; Var: variância; DP: Desvio Padrão; CV: Coeficiente de Variação.

Observa-se na Tabela 03, que o coeficiente de variação das características Dureza, Cromaticidade a*, Temperatura e Dias de Armazenamento foram superiores a 10% o que contribuiu para o treinamento, pois esta variação nos valores permite o melhor ajuste dos pesos das sinapses das conexões na rede. O alto coeficiente de variação, pode representar *outliers* nos dados. No entanto, segundo Reed (1993) a utilização de redes do tipo MLP utilizando validação cruzada, consegue lidar com esses *outliers*, que evita a influência desses no ajuste dos pesos das sinapses. Assim garante-se que a rede não modelasse os ruídos presentes nas amostras, e apresente melhor capacidade de generalização dos dados.

4.1 Treinamento e Seleção da rede neural

Para o treinamento da rede neural artificial, foram realizados testes preliminares para determinar a melhor configuração de entrada dos dados. A primeira configuração de rede foi composta de seis variáveis de entrada com todos os dados normalizados entre -1 e 1. Com essa configuração foi observado que a variável temperatura sendo testada com os dados normalizados influenciaria na variável de saída (Dias de armazenamento). A maior temperatura de 37 °C teria maior peso (influência) sobre a menor temperatura de 15 °C de armazenamento, isso não é confirmado pois, a temperatura de armazenagem não influencia na identificação dos dias de armazenamento de grãos de feijão.

Uma segunda configuração de rede foi testada com a normalização das variáveis de entrada, definindo a temperatura como variável binária (assume um ou zero), ou seja, variável categórica (independente). A arquitetura dessa rede foi composta de sete variáveis de entrada e uma variável de saída.

Esta última configuração foi a que apresentou os melhores resultados de performance, coeficiente de determinação (R^2) e correlação de Pearson (r) dos dados observados e os estimados pela rede neural artificial.

O treinamento das RNAs do tipo MLP foi realizado utilizando um script desenvolvido por Alves (2016) chamado “TREINAR_V6”, em que os valores de cada parâmetro utilizado para o treinamento estão os descritos na Tabela 4.

Tabela 4 - Parâmetros utilizados para realizar treinamento da rede MLP

Valor utilizado	Descrição dos parâmetros
1000	Número de ciclos – número máximo de vezes que os dados de treinamento serão apresentados para cada treinamento
1000	Número de treinamentos – número de treinamentos que devem ser realizados em cada arquitetura (número de neurônio na camada intermediária)
1	Quantidade de neurônios iniciais na camada intermediária
20	Quantidade final de neurônios na camada intermediária
1	Passos - é o incremento que será realizado na quantidade de neurônios na camada intermediária cada vez que o número de treinamentos especificado for atingido

Foi realizado o treinamento de vinte mil redes alterando-se o número de neurônios na camada intermediária de um a vinte. Com a utilização do script foi possível de forma simples variar o número de neurônios na camada intermediária permitindo assim a avaliação da performance em diferentes arquiteturas e configurações de rede.

Durante o treinamento outro recurso utilizado foi a repetição do treinamento em cada arquitetura mil vezes. A cada novo treinamento, realizava novo sorteio dos conjuntos de treinamento, validação e teste assim como a inicialização dos pesos das sinapses. Sendo assim possível superar um problema comum no treinamento de redes MLP que utilizam algoritmo do tipo backpropagation, que pode consumir várias tentativas devido à propensão para ficar preso em mínimos locais (ARNOLD et al., 2011; ZWEIRI et al., 2005).

Na Tabela 5 estão apresentados os resultados dos dados após o treinamento das RNAs. Pode-se verificar que a melhor rede durante o treinamento possui arquitetura com 6 neurônios na camada intermediária sendo encontrada após 204 repetições, com boa performance $R^2 = 83,0\%$ no treinamento e $R^2 = 91,2\%$ na validação. A rede com arquitetura de 19 neurônios na camada intermediária, apresentou performance semelhante a rede com 6 neurônios, mas redes com maior número de neurônios na camada intermediária aumenta o custo computacional e com isso não se torna viável sua utilização.

Tabela 5 - Resultados dos dados após o treinamento das RNAs

Treinamento			Performance				R ² (%)				Correlação de Pearson			
NN	NT	C	Ger	Tre	Val	Tes	Ger	Tre	Val	Tes	Ger	Tre	Val	Tes
1	938	35	0,215	0,210	0,260	0,157	17,5	18,1	06,0	40,5	0,418	0,426	0,245	0,636
6	204	287	0,039	0,041	0,029	0,045	84,9	83,0	91,2	82,7	0,922	0,911	0,955	0,909
9	116	220	0,050	0,058	0,019	0,057	80,7	77,9	92,8	74,4	0,898	0,883	0,963	0,863
17	747	622	0,054	0,004	0,183	0,145	81,1	98,4	46,6	49,8	0,901	0,992	0,683	0,705
19	948	221	0,043	0,046	0,029	0,047	83,5	82,1	89,4	83,5	0,914	0,906	0,945	0,914
19	694	213	0,049	0,050	0,064	0,010	81,2	80,6	72,9	96,0	0,901	0,898	0,854	0,980

NN: Número de neurônios na camada intermediária; NT: número do treinamento realizado na arquitetura de NN; C: ciclos (época) que o treinamento foi finalizado; Ger: Geral; Tre: Treinamento; Val: Validação; Tes: Teste; Performance: Erro Quadrático Médio (EQM); R²: Coeficiente de determinação.

A rede com arquitetura de 6 neurônios foi selecionada por apresentar melhor solução e performance geral (Tabela 5). Foi observado também, um (r) muito forte em cada parâmetro avaliado (geral, treinamento, validação e teste), sendo todos superiores a 0,900. Na Figura 10 são apresentados os valores de R² obtidos pela rede.

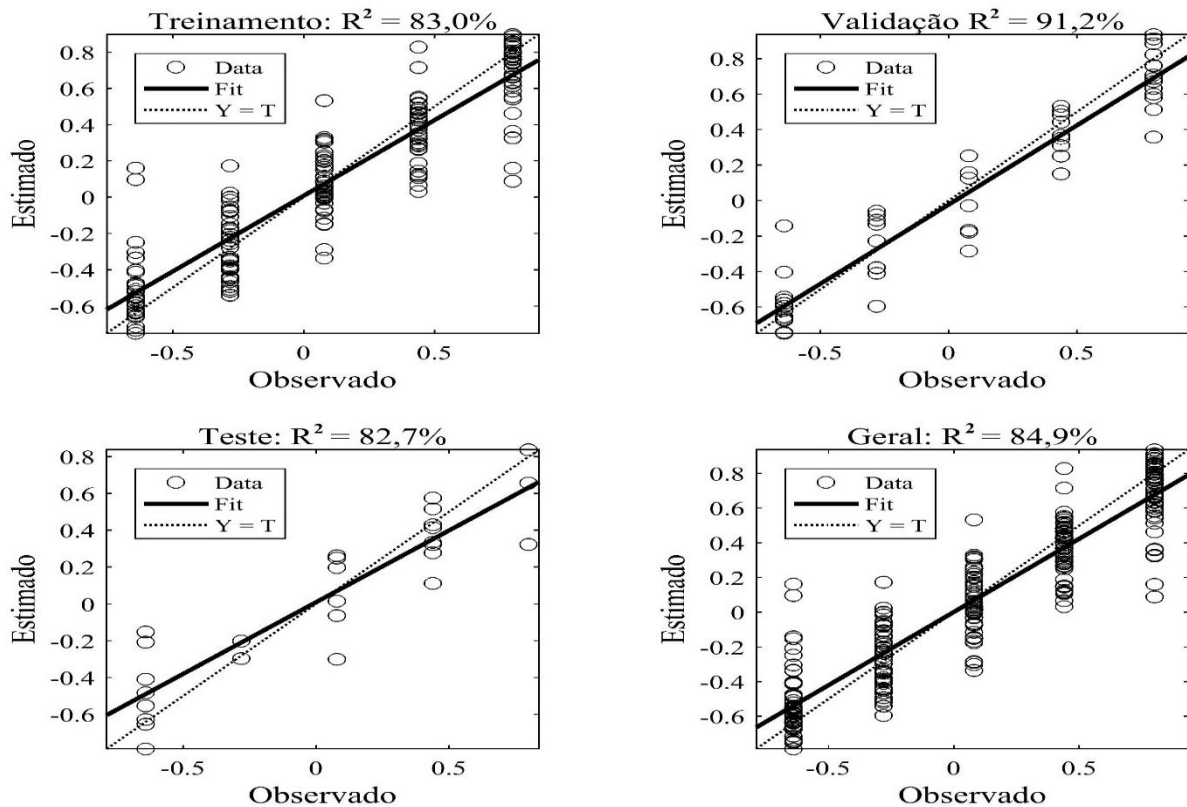


Figura 10 - Representação gráfica do R linear de treinamento, validação, teste e geral da rede com 6 neurônios treinamento 204.

No conjunto de treinamento (Figura 11), pode-se verificar que os valores de treinamento estimados pela rede ficaram próximos do que era esperado, demonstrando que a rede do tipo MLP foi capaz de aprender com os dados apresentados. Por outro lado, notou-se alguns pontos mais distantes do valor esperado. Por exemplo, as amostras 26, 29, 60, 109 e 125 foram superestimadas para o armazenamento, já as amostras 140, 145, 155, 159, 161 e 163 foram subestimadas para os

dias de armazenamento. Estas amostras foram identificadas sendo observado nos dados originais sendo aquelas armazenadas a temperatura de 15 °C.




Figura 11 - Comparativo dos dados estimados e observados do conjunto de treinamento na arquitetura com 6 neurônios e repetição 204.

No conjunto de validação (Figura 12), a rede apresentou boa performance $R^2 = 91,2\%$ e alta $r = 0,955$. Entretanto, identificou-se um ponto mais distantes (amostra 13) nos primeiros 36 dias de armazenamento, superestimando o tempo de armazenamento dos grãos de feijão. Já na faixa de 180 dias de armazenamento é possível observar a amostra 46 subestimando o tempo de armazenamento.




Figura 12 - Comparativo dos dados estimados e observados do conjunto de validação na arquitetura com 6 neurônios e repetição 204.

No conjunto de teste (Figura 13), mesmo apresentando alguns pontos mais distantes do que era esperado aos 36 dias de armazenamento amostras 1 e 5, a rede apresentou alta $r = 0,909$

dos dados e uma performance $R^2 = 82,7\%$, demonstrando boa capacidade de generalização dos dados.




Figura 13 - Comparativo dos dados estimados e observados do conjunto de teste na arquitetura com 6 neurônios e repetição 204.

O número de neurônios na camada intermediária é responsável pela extração de características de não linearidade dos dados, neste caso a configuração com 6 neurônios na camada intermediária, demonstrou que a rede com poucos neurônios nessa camada é capaz de extrair a relação entre as variáveis consideradas e os dias de armazenamento dos grãos de feijão. Na figura 14 é mostrado o gráfico de performance de treinamento da rede com 6 neurônios na camada intermediária, observa-se que a melhor performance de validação foi encontrada na época 87.




Figura 14 - Gráfico da performance de treinamento da rede com 6 neurônios na camada intermediária, para a repetição de número 204.

Ainda analisando a Tabela 5, verifica-se na linha 4 a rede neural que apresentou melhor performance de treinamento com uma arquitetura com 17 neurônios na camada intermediária, onde após 747 repetições apresentou no treinamento $R^2 = 98,4\%$ e uma $r = 0,992$. Observou-se na Figura 15, após a época 100 que a linha de treinamento teve uma queda acentuada, esse comportamento pode ser indicativo de que a rede começou a se especializar no conjunto de treinamento e perdeu a capacidade de generalização. Este fato pode-se atribuir ao maior número de neurônios na camada intermediária, corroborando com os resultados encontrados por Alves et al. (2018), que ao realizar um novo sorteio de cada conjunto de treinamento, obtiveram conjuntos com baixa representação amostral, ocasionando problemas para a convergência e generalização das redes.




Figura 15 - Gráfico da performance de treinamento da rede com 17 neurônios na camada intermediária, para a repetição de número 747.

Na Tabela 5 nota-se ainda que o conjunto de validação e teste não conseguiram acompanhar a performance do conjunto de treinamento, apresentando $R^2 = 46,6\%$ e $49,8\%$, respectivamente. De acordo com Braga et al. (2007), a escolha da arquitetura de uma rede deve ser feita com atenção pois uma rede com muitos neurônios na camada intermediária pode fornecer excelentes resultados para os dados de treinamento, porém, para os dados de validação, os resultados podem ser totalmente imprecisos, conforme pode ser visto na Figura 14.

Maciel et al. (2012) testaram diferentes arquiteturas de RNA, variando o número de neurônios na camada intermediária de um até quinze. Os autores observaram que a rede composta por seis neurônios na camada intermediária apresentou os melhores resultados, verificaram também que a complexidade da rede aumentava com o acréscimo do número de neurônios na

camada intermediária, mas seu desempenho declinava. Este fato corrobora com o presente estudo, em que a melhor rede foi encontrada com 6 neurônios e a medida que aumentou a quantidade de neurônios na camada intermediária a rede perdeu a capacidade de generalização.

4.2 Validação da rede selecionada

Após a escolha da rede com melhor performance durante o treinamento com arquitetura de 6 neurônios na camada intermediária, foi realizada a validação da rede utilizando o conjunto de dados que não foram apresentados durante o treinamento, ou seja, dados desconhecidos pela rede. Esse conjunto foi composto por 30 amostras, que serviram para avaliar a capacidade da rede em fornecer resultados precisos para dados desconhecidos.

Os pesos sinápticos armazenaram o conhecimento adquirido pela rede durante a etapa de treinamento, ajustando os valores dos seis neurônios da camada intermediária e os valores dos *bias* de cada um. Posteriormente, foi apresentado a esta rede o conjunto de dados desconhecidos, cuja estatística descritiva está apresentada na Tabela 6.

Tabela 6 - Estatística descritiva da rede com 6 neurônios na repetição 204.

	Número de Amostras	Mín	Máx	Média	EMA	DP
Geral	300	19,92	193,64	107,2	15	47,11
Treinamento	189	24,88	189,82	108,38	15	45,12
Validação	54	25,2	193,64	103,66	13	53,47
Teste	27	21,32	183,84	102,98	16	44,22
Generalização	30	19,92	183,3	109,87	21	51,46

Mín: Mínimo; Máx: Máximo; EMA: Erro Médio Absoluto (Média calculada a partir dos valores absolutos do erro); DP: Desvio Padrão; Valores expressos em dias.

Observa-se que a diferença entre os dias de armazenamento observado e o estimado pela rede no conjunto de validação apresentou uma diferença de 13 dias do valor esperado, já para o conjunto utilizado para a generalização da rede apresentou uma diferença de 21 dias.

A validação dessa rede apresentou performance $R^2 = 77,9\%$ e $r = 0,883$, mesmo com boa performance é possível observar que nem todos os valores estimados pela rede conseguiram acompanhar os valores observados, apresentando alguns pontos mais distantes para os dias de armazenamento (Figura 16). O desempenho moderado pode ser relacionado a ocorrência de sobre-treinamento (*over training*), ou seja, a rede começou a memorizar os dados de treinamento, ocorrendo um decréscimo na capacidade de generalização da rede, corroborando com os resultados encontrados por Binoti et al. (2015) que encontraram valores aproximados de correlação para o conjunto de treinamento e generalização.




Figura 16 - Comparativo dos dados estimados e observados da rede de validação (generalização) na arquitetura com 6 neurônios na camada intermediária.

5. CONCLUSÕES

Nas condições em que foi desenvolvido este trabalho pode-se concluir que:

- O uso das redes neurais artificiais na estimativa do tempo de armazenamento dos grãos de feijão teve um bom desempenho, apresentando baixo EQM (Erro Quadrático Médio), alta correlação de Pearson e coeficiente de determinação R^2 com resultados satisfatórios;
- As redes neurais artificiais podem ser utilizadas para estimar os dias de armazenamento em função da cor, dureza e temperatura; e
- A rede de melhor desempenho possui arquitetura (7-6-1), sendo 7 neurônios na camada de entrada, 6 na camada intermediária e 1 neurônio na camada de saída.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ABEROUMAND, A. A review on edible pigments properties and sources as natural biocolorants in foodstuff and food industry. **World Journal of Dairy & Food Science**, Punjab, v.6, n.1, p.71-78, 2011.

ABREU, A.F.B; CARNEIRO, J.E.S.; RAMALHO, A.P.; MELO, L.C.; JÚNIOR, T.J.P.; PEREIRA FILHO, I.A.; MARTINS, M.; PEREIRA, H.S.; CARNEIRO, P.C.S.; DEL GIÚDICE, M.P.; VIEIRA, R.F. TEIXEIRA, H.; DEL PELOSO, M.J.; FARIA, L.C.; SANTOS, J.B.; COSTA, J.G.C.; MOREIRA, J.A.A.; WENDLAND, A. BRSMG Madrepérola: Cultivar de Feijão Tipo Carioca com Escurecimento Tardio dos Grãos. Santo Antônio de Goiás, Embrapa Arroz e Feijão, 2011, 4 p. (Embrapa Arroz e Feijão. Comunicado técnico, 200).

AGUIAR, M.S.; GOMES, D.R.; CABRERA DIAZ, J.L.; WENDLAND, A.; FARIA, L.C.; SOUZA, T.L.P.O.; PEREIRA, H.S.; MELO, L.C. Caracterização para reação às doenças em cultivares e linhagens elite de feijoeiro-comum. In: CONGRESSO BRASILEIRO DE MELHORAMENTO DE PLANTAS, 8., 2015, Goiânia. O melhoramento de plantas, o futuro da agricultura e a soberania nacional: **Anais...** Goiânia: UFG: SBMP, 2015.

ALMEIDA, A.J.B. **Alterações tecnológicas e químicas de grãos de feijão carioca durante o armazenamento em condições controladas**. 65 p. 2016. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Estadual do Oeste do Paraná, Cascavel.

ALVES, G.R.; TEIXEIRA, I.R.; MELO, F.R.; SOUZA, R.T.G.; SILVA, A.G. Estimating soybean yields with artificial neural networks. **Acta Scientiarum Agronomy**, Maringá, v.40, p.1-9, 2018. <http://dx.doi.org/10.4025/actasciagron.v40i1.35250>

ALVES, G.R. **Estimativa da produtividade da soja com redes neurais artificiais**. 76 p. 2016. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Goiás, Anápolis.

ARNOLD, L.; REBECCHI, S.; CHEVALLIER, S.; PAUGAM-MOISY, H. An introduction to deep-learning. In: European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN), p.477-488, 2011. **Anais...** Bruges, Belgium. Proceedings of the European Symposium on Artificial Neural Networks. 2011.

BALAMAZE, J.; MUYONGA, J.H.; KYAMUHANGIRE, W.M.; KIKAFUNDA, J.K.; NAKIMBUGWE, D.; UGEN, M. Influence of variety, growth location and storage conditions on development of hard-to-cook defect in common bean (*Phaseolus vulgaris*. L). **African Journal of Food Agriculture Nutrition and Development**, Kenya, v.8, n.3, p.333-348, 2008.

BARRETO, J.M. **Introdução às Redes Neurais Artificiais**. Laboratório de Conexão e Ciências Cognitivas (Universidade Estadual de Santa Catarina - UFSC), Departamento de Informática e de Estatística. Florianópolis, Santa Catarina, 2004.

BASSINELLO, P.Z. Qualidade na escolha de variedades de feijão para o mercado consumidor. **Atualidades em micotoxinas e armazenagem qualitativas de grãos II**. 1. ed. Florianópolis: Imprensa Universitária, 2008.

BASSINELLO, P.Z.; CASTRO, M.G.; OLIVEIRA, L.L.R.; SOARES, D.M.; PELOSO, M.J.; SILVA C.C.; THUNG, M. Decoada e outros químicos para reduzir o tempo de cocção e seus efeitos na qualidade culinária de feijão. In: Congresso nacional de pesquisa de feijão, 8., 2005, Goiânia. **Anais...** Santo Antônio de Goiás: Embrapa Arroz e Feijão, v.2, p.691-694, 2005.

BINOTI, M.L.M.S.; LEITE, H.G.; BINOTI, D.H.B.; GLERIANI, J.M. Prognose em nível de povoamento de clones de eucalipto empregando redes neurais artificiais. **Cerne**, Lavras, v.21 n.1, p.97-105, 2015.

BINOTI, D.H.B.; BINOTI, M.L.M.S.; LEITE, H.G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa, v.37, n.4, p.639-645, 2013.

BISI, B.S.; NETO, A.B.; BONINI, C.S.B. Redes neurais artificiais: utilização do algoritmo retropropagação para classificação de grupos em biosistemas, parte 1: Introdução teórica. **Fórum Ambiental da Alta Paulista**, São Paulo, v.11, n.2, p.345-354, 2015.

BOHL, M.T.; DIESTELDORF, J.; SALM, C.A.; WILFLING, B. Spot market volatility and futures trading: the pitfalls of using a dummy variable approach. **Journal of Futures Markets**. v. 36, n.1, p.30-45, 2015.

BONINI NETO, A.; BONINI, C.S.B.; BISI, B.S.; COLETTA, L.F.S.; REIS, A.R. Artificial Neural Network for Classification and Analysis of Degraded Soils. **Ieee Latin América Transactions**, v.15, n.3, p.503-509, 2017.

BRACKMANN, A.; NEUWALD, D.A.; RIBEIRO, N.D.; FREITAS, S.T. Conservação de três genótipos de feijão (*Phaseolus vulgaris* L.) do grupo carioca em armazenamento refrigerado e em atmosfera controlada. **Ciência Rural**, Santa Maria, v.32, n.6, p.911-915, 2002.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Redes Neurais Artificiais - Teoria e Aplicações**. 2º ed. Rio de Janeiro: LTC, 2012. 226p.

BRAGA, A.P.; CARVALHO; A.P.L.F.; LUDERMIR, T.B. **Redes neurais artificiais - Teoria e aplicações**. 2.ed. Rio de Janeiro: LTC, 2007. 248p.

BRAGANTINI, C. **Alguns aspectos do armazenamento de sementes e grãos de feijão**. Santo Antônio de Goiás, Embrapa Arroz e Feijão, 2005. 28 p. (Documento, 187).

BRASIL. Ministério da Agricultura Pecuária e Abastecimento - MAPA. **Instrução Normativa Nº 12, 28 de março de 2008**: Regulamento Técnico do Feijão, 2008. Disponível em: <<http://sistemasweb.agricultura.gov.br/sislegis/action/detalhaAto.do?method=visualizarAtoPort alMapa&chave=294660055>>. Acesso em 25 fev. 2018.

CARBONELL, S.A.M.; CHIORATO, A.F.; BOLONHEZI, D.; BARROS, V.L.N.P.; BORGES, V.L.B.; TICELLI, M.; GALLO, P.B.; FINOTO, E.L.; SANTOS, N.C.B. IAC Milênio – common bean cultivar with high grain quality. **Crop Breeding and Applied Biotechnology**, Viçosa, v.14, n.4, p.273-276, 2014.

CARNEIRO, J.E.S.; ABREU, A.F.B.; RAMALHO, M.A.P.; PAULA JÚNIOR, J.; DEL PELOSO, M.J.; MELO, L.C.; PEREIRA, H.S.; PEREIRA FILHO, I.A. MARTINS, M.; VIEIRA, R.F.; MARTINS, F.A.D.; COELHO, M.A.O.; CARNEIRO, P.C.S.; MOREIRA, J.A.A.; SANTOS, J.B.; FARIA, L.C.; COSTA, J.G.C.; TEIXEIRA, H. Cultivar release - BRSMG madrepérola: common bean cultivar with late-darkening Carioca grain. **Crop Breeding and Applied Biotechnology**, Santo Antônio de Goiás, v. 12, p. 281-284, maio 2012.

CARNEIRO, J.C.S.; MINIM, V.P.R.; SOUZA JÚNIOR, M.M.; CARNEIRO, J.E.S.; ARAÚJO, G.A.A. Perfil sensorial e aceitabilidade de cultivares de feijão (*Phaseolus vulgaris* L.). **Ciência e Tecnologia de Alimentos**, Campinas, v.25, n.1, p.18-24, 2005.

CIE. Commission International De L'Eclairage. Recommendations on Uniform Color Spaces, Color Difference Equations, Psychometric Color Terms, Colorimetry. **Bureau Central de la CIE**, Paris, 1978. Supplement nº 2, to CIE Publication Nº 15.

COELHO, S.R.M.; PRUDÊNCIO, S.H.; NÓBREGA, L.H.P.; LEITE, C.F.R. Alterações no tempo de cozimento e textura dos grãos de feijão comum durante o armazenamento. **Ciência e Agrotecnologia**, Lavras, v.33, n.2, p.539-544, 2009.

CONAB - Companhia Nacional de Abastecimento. **Acompanhamento da safra brasileira de grãos**, v. 5 Safra 2017/18 - Quinto levantamento, Brasília, p.1-140 fev. 2018. Disponível em: < http://www.conab.gov.br/OlalaCMS/uploads/arquivos/18_02_08_09_00_09_fevereiro_2018.pdf > Acesso em: 25 fev. 2018.

CONAB - Companhia Nacional de Abastecimento. **Perspectiva para a agropecuária**, v. 5 Safra 2017/18 Produtos de verão. Brasília, p.1-122 agosto 2017. Disponível em: < https://www.conab.gov.br/OlalaCMS/uploads/arquivos/17_09_06_09_30_08_perspectivas_da_agropecuaria_bx.pdf >. Acesso em: 25 fev. 2018.

CURI, T.M.R.C.; MOURA, D.J.; MASSARI, J.M.; VERCELLINO, R.A.; SABINO, L.A. Redes Neurais na predição da vazão ideal de exaustores em aviários de frango de corte com diferentes topologias. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 43, 2014. Campo Grande, **Anais...** Campo Grande, CONBEA, 2014.

DEL PELOSO, M.J.; MELO, L.C.; FARIA, L.C. de; COSTA, J.G.C. da; RAVA, C.A.; CARNEIRO, G.E.S.; SOARES, D.M.; CABRERA DÍAZ, J.L.; ABREU, A.F.B.; FARIA, J.C.; SARTORATO, A.; SILVA, H.T.; BASSINELLO, P.Z.; ZIMMERMANN, F.J.P. **BRS Pontal: nova cultivar de feijoeiro comum de tipo de grão carioca com alto potencial produtivo**. Santo Antônio de Goiás: Embrapa Arroz e Feijão, 2003. 2 p. (Embrapa Arroz e Feijão. Comunicado técnico, 64).

DÍAZ, A.M.; CALDAS, G.V.; BLAIR, M.W. Concentrations of condensed tannins and anthocyanin in common bean seed coats. **Food Research International**, Canadian, v.43, n.2, p.595-601, 2010.

ELSADR, H.T.; WRIGHT, L.C.; PAULS, K.P.; BETT, K.E. Characterization of seed coat postharvest darkening in common bean (*Phaseolus vulgaris* L.). **Theoretical Applied Genetics**, Maryland, v.123, n.8, p.1467-1472, 2011.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Dados conjunturais da produção de feijão-comum (*Phaseolus vulgaris* L.) e caupi (*Vigna unguiculata* (L.) Walp) no Brasil (1985 a 2016): área, produção e rendimento**. Santo Antônio de Goiás: Embrapa Arroz e Feijão, 2017. Disponível em: <<http://www.cnpaf.embrapa.br/socioeconomia/index.htm>>. Acesso em: 24 fev. 2018.

FARIA, A.P.; MODA-CIRINO, V.; BURATTO, J.S.; SILVA, C.F.B.; DESTRO, D. Interação genótipo x ambiente na produção de grãos de linhagens e cultivares de feijão. **Acta Scientiarum Agronomia**, Maringá, v.31, n.4, p.579-585, 2009.

FARONI, L.R.A.; ALENCAR, E.R.; PAES, J.L.; COSTA, A.R.; ROMA, R.C.C. Qualidade dos grãos de soja armazenados em diferentes condições. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.5, p.606-613, 2009.

FAVAN, J.R. **Utilização de redes neurais artificiais aplicadas na discriminação de padrões de doenças florestais**. 2015. 74 p. Dissertação (Mestrado em Ciência Florestal) - Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu.

FELICETTI, E.; SONG, Q.; JIA, G.; CREGAN, P.; BETT, K.E.; MIKLAS, P.N. Simple Sequence Repeats Linked with Slow Darkening Trait in Pinto Bean Discovered by Single Nucleotide Polymorphism Assay and Whole Genome Sequencing. **Crop Science**, Madison, v.52, n. 4, p.1600-1608, 2012. doi: 10.2135/cropsci2011.12.0655

GRANATTO, D.; MASSON, M.L. Instrumental color and sensory acceptance of soy-based emulsions: a response surface approach. **Ciência e Tecnologia de Alimentos**, Campinas, v.30, n.4, p.1090-1096, 2010.

HAGAN, M.T.; MENHAJ, M.B. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, v.5, n.6, p.989–993, 1994.

HAQUE, M.T.; KASHTIBAN, A.M. Application of Neural Networks in Power Systems; a review. **International Journal Innovative Research in Science & Engineering**, Mangalyaan, v.1, n.6, p.885-889, 2007.

HAYKIN, S. **Neural networks and learning machines**. 3rd ed. New York: Prentice Hall, 2009. 936p.

HAYKIN, S. **Neural network: A Comprehensive Foundation**. 2 ed. Ontario: Pearson Prentice Hall, 2005. 823p.

HAYKIN, S. **Redes neurais: princípios e prática**. 2 nd ed. Bookman: Porto Alegre, 2001. 900p.

HANDPRINT. **Modern color models.** Disponível em: <<http://www.handprint.com/HP/WCL/color7.html#CIELAB>>. Acesso em 07 mar. 2018.

HILL, P.S.M.; WELLS, P.H.; WELLS, H. Spontaneous flower constancy and learning in honey bees as a function of colour. **Anim. Behav.** v. 54, p. 615-627, 1997.

JUNK-KNIEVEL, D.C.; VANDERBERG, A.; BETT, K.E. Slow darkening in pinto bean (*Phaseolus vulgaris* L.) seed coats is controlled by a single major gene. **Crop Science**, Madison, v. 48, n. 1, p. 189-193, 2008.

JUNK-KNIEVEL, D.C.; VANDENBERG, A.; BETT, K.E. An accelerated postharvest seedcoat darkening protocol for pinto beans grown across different environments. **Crop Science**, Madison, v.47, n.2, p.694-700, 2007. doi:10.2135 / crops2006.05.0325

LEAL, A.J.F.; MIGUEL, E.P.; BAIO, F.H.R.; NEVES, D.C.; LEAL, U.A.S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, Campinas, v.74, n 4, p.436-444, 2015.

LEMOS, L.B.; OLIVEIRA, R.S.; PALOMINO, E.C.; SILVA, T.R.B. Características agronômicas e tecnológicas de genótipos de feijão do grupo comercial Carioca. **Pesquisa Agropecuária Brasileira**, Brasília, v.39, n.4, p.319-326, 2004.

LIMA, I.; PINHEIRO, C. A. M.; SANTOS, F. A. O. **Inteligência Artificial.** ed. Elsevier Brasil: Rio de Janeiro, 2016. 184p.

LIMA, R.A.Z. Armazenamento de feijão: uso da embalagem à vácuo na manutenção da qualidade. 2013. 105 p. Tese (Doutorado em Agroquímica) - Universidade Federal de Lavras, Lavras, MG.

LO SCHIAVO, M.; PRINARI, B.; GRONSKI, J.A.; SERIO, A.V. An artificial neural network approach for modeling the ward atmosphere in a medical unit. **Mathematics and Computers in Simulation**, v. 116, p. 44–58. 2015.

MACIEL, L.S.; BALLINI, R.; SILVEIRA, R.L.F. Apreçamento de opções sobre taxa de câmbio R\$/US\$ negociadas no Brasil: uma comparação entre os modelos Black e redes neurais artificiais. **Revista de Administração**, São Paulo, v.47, n.1, p.96-111, 2012.

McCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v.5, p.115-133, 1943.

MELO, L.C.; DEL PELOSO, M.J.; PEREIRA, H.S.; FARIA, L.C.; COSTA, J.G.C.; CABRERA DIAZ, J.L.; RAVAL, C.A.; WENDLAND, A.; ABREU, A.F.B.; BRS Estilo - Common bean cultivar with Carioca grain, upright growth and high yield potential. **Crop Breeding and Applied Biotechnology**, Viçosa, v.10, n.4, p.377-379, 2010.
<http://dx.doi.org/10.1590/S1984-70332010000400015>

MIRANDA, F.A.; FREITAS, S.R.C.; FAGGION, P.L. Integração e interpolação de dados de anomalias ar livre utilizando-se a técnica de RNA e krigagem. **Boletim de Ciências Geodésicas**, v.15, n.3, p.428-443, 2009.

MORAIS, P.P.P.; VALENTINI, G.; GUIDOLIN, A.F.; BALDISSERA, J.N.C.; COIMBRA, J.L.M. Influência do período e das condições de armazenamento de feijão no tempo de cocção. **Revista Ciência Agrônômica**, Fortaleza, v.41, n.4, p.593-598, 2010.

MOTA, D.H. **Propriedades físicas durante a secagem e qualidade tecnológica em cultivares de feijão carioca em diferentes condições de armazenamento**. 2016. 163 p. Dissertação (Mestrado em Agronomia), Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, Brasília.

NIED, A. **Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com taxa de aprendizado adaptativa**. 2007. 128 p. Tese (Doutorado em Engenharia Elétrica), Universidade Federal de Minas Gerais.

NUNES, C.S.; KURS, V.; FIGUEIREDO, A.M.B. TRAVI, M.R.L. Métodos de controle e pragas nas lavouras de feijão. **Revista Tecnológica**, Chapecó, v.6, n.1, p.128-146, 2017.

OLIVEIRA, V.R.; RIBEIRO, N.D.; MAZIERO, S.M.; FILHO, A.C.; JOST, E. Qualidade para o cozimento e composição nutricional de genótipos de feijão com e sem armazenamento sob refrigeração. **Ciência Rural**, Santa Maria, v.41, n.5, p.746-752, 2011.

OLIVEIRA, M. **Temperatura de secagem e condições de armazenamento sobre propriedades da soja para consumo e produção de biodiesel**. 2008. 140 p. Dissertação (Mestrado em Ciência e Tecnologia Agroindustrial), Faculdade de Agronomia Eliseu Maciel, Universidade Federal de Pelotas, Pelotas.

POHNDORF, R.S. **Efeitos da umidade e do resfriamento no armazenamento sobre a qualidade de grãos e do óleo de soja para fins comestíveis e de produção de biodiesel**. 2012. 84 p. Dissertação (Mestrado em Ciência e Tecnologia Agroindustrial) - Universidade Federal de Pelotas, Pelotas, RS.

REED, R. Pruning algorithms - a survey. **IEEE Transactions on Neural Networks**. v.4, n.5, p.740-747. 1993.

RESENDE, O.; CORRÊA, P.C.; FARONI, L.R.A.; CECON, P.R. Avaliação da qualidade tecnológica do feijão durante o armazenamento. **Ciência e Agrotecnologia**, Lavras, v.32, n.2, p.517-524, 2008.

RIBEIRO, N.D.; RODRIGUES, J.A.; CARGNELUTTI FILHO, A.; POERSCH, N.L.; TRENTIN, M.; DA ROSA, S. S.; Efeito de períodos de semeadura e das condições de armazenamento sobre a qualidade de grãos de feijão para cozimento. **Bragantia**, Campinas, v.66 n.1, p.157-163, 2007.

- RIGUEIRA, R.J.A.; LACERDA FILHO, A.F.; VOLK, M.B.S. Avaliação da qualidade do feijão armazenado em ambiente refrigerado. **Alimentos e Nutrição**, Araraquara, v.20, n.4, p. 649-655, 2009.
- RIOS, A.O.; ABREU, C.M.P.; CORREA, A.D. Efeitos da época de colheita e do tempo de armazenamento no escurecimento do tegumento do feijão (*Phaseolus vulgaris* L.). **Ciência e Agrotecnologia**, Lavras, v.26, n.3, p.550-558, 2002.
- RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3. ed. Rio de Janeiro: Campus, 2013. 1016p.
- SANTOS, H.C. **Classificação de sinais EGG combinado Análise em Componentes Independentes, Redes Neurais e Modelo Oculto de Markov**. 2015. 116 p. Dissertação (Mestrado em Ciência da Computação), Universidade Federal de Sergipe, Sergipe.
- SANTOS, J.B.; GAVILANES, M.L. Botânica. IN: VIEIRA, C.; PAULA JÚNIOR, T.J.; BORÉM, A. (Ed.). **Feijão**. 2.ed. Viçosa: UFV, 2006. p.41-66.
- SANTOS, C.M.R.; MENEZES, N.L.; VILLELA, F.A. Modificações fisiológicas e bioquímicas em sementes de feijão no armazenamento. **Revista Brasileira de Sementes**, Brasília, v. 27, n. 1, p. 104-114, 2005.
- SARTORI, M.R. Armazenamento. In: ARAUJO, R. S.; RAVA, C. A.; STONE, L. F.; ZIMMERMANN, M. J. de O. (Coords.). **Cultura do feijoeiro comum no Brasil**. Piracicaba: POTAFOS, 1996. p. 543-558.
- SCHNEIDER, P.R. **Análise de regressão aplicada à Engenharia Florestal**. 2. Ed. Santa Maria. UFSM/CEPEF, 1998. 236p.
- SHARMA, A.K.; SHARMA, R.K.; KASANA, H.S. Prediction of first lactation 305-day milk yield in karan fries dairy cattle using ann modeling. **Applied Soft Computing Journal**. v.7, n.3, p.1112–1120. 2007.
- SCHOENINGER, V.; COELHO, S.R.M.; PALOSCHI, C.L.; PRADO, N.V. Qualidade físico-química e tempo de cozimento de grãos de feijão novos e envelhecidos em condições de armazenamento refrigerado. **Revista Varia Scientia Agrárias**, Oeste do Paraná, v.03, n.02, p.55-65, 2013.
- SEGATTO, Ê.C.; COURRY, D.V. Redes neurais artificiais recorrentes aplicadas na correção de sinais distorcidos pela saturação de transformadores de corrente. **Revista Controle e Automação**, Campinas, v.17, n.4, p.424-436, 2006.
- SILOCHI, R.M.H.Q. **Caracterização tecnológica nutricional e metabólitos secundários em cultivares de feijão carioca armazenados**. 2015. 147 p. Tese (Doutorado em Engenharia Agrícola), Universidade Estadual do Oeste do Paraná, Cascavel.
- SILVA, C.A.; ABREU, A.F.B.; RAMALHO, M.A.P.; MAIA, L.G.S. Chemical composition as related to seed color of common bean. **Crop Breeding and Applied Biotechnology**, Viçosa, v.12, n.2, p.132-137, 2012a. <http://dx.doi.org/10.1590/S1984-70332012000200006>.

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. Sociedade Brasileira de Automática Controle e Automação, **Campinas**, v.23, n.5, p.649-652, 2012b.

SILVA, A.G.; WANDER, A.E.; BARBOSA, F.R.; GONZAGA, A.C.O.; SILVA, J.G. Análise econômica da produção de feijão comum em sistema de produção convencional e de produção integrada, em cristalina, estado de Goiás, e Unaí, estado de Minas Gerais, maio de 2009 a abril de 2010. **Informações Econômicas**, São Paulo, v.42, n.5, p.55-64, 2012c.

SILVA, F.C.; PEREIRA, H.S.; MELO, P.G.S.; MELO, L.C.; WENDLAND, A.; CABRERA DIAZ, J.L. Seleção de populações segregantes de feijoeiro-comum tipo carioca para produtividade de grãos. In: CONGRESSO BRASILEIRO DE MELHORAMENTO DE PLANTAS, 6, 2011, Búzios. **Anais...** Panorama atual e perspectivas do melhoramento de plantas no Brasil. Búzios, 2011. <http://ainfo.cnptia.embrapa.br/digital/bitstream/item/41019/1/3636.pdf>

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: curso prático**. Artliber, São Paulo, 2010. 399p.

SILVA, O.F.; WANDER, A.E. **Impacto econômico da cultivar de feijão tipo carioca BRS pontal**. Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), Embrapa Arroz e Feijão. San Antônio de Goiás, 2009.

SILVA, G.S.; RAMALHO, M.A.P.; ABREU, A.F.B.; SILVA, F.B. Genetic control of early darkening of carioca common bean. **Crop breeding and applied biotechnology**, Londrina, v.8, p.299-304, 2008.

SINGH, S.P.; TERÁN, H.; LEMA, M.; DENNIS, M.F.; HAYES, R. Registration of slow darkening pinto bean germplasm line SDIP-1. **Crop Science**, Madison, v.46, n.6, p.2726-2727, 2006. doi:10.2135/cropsci2006.04.0247

SIQUEIRA, B.S.; PEREIRA, W.J.; BATISTA, K.A.; OOMAH, D.B.; FERNANDES, K.F.; BASSINELLO, P.Z. Influence of storage on darkening and hardening of slow-and regular-darkening carioca bean (*Phaseolus vulgaris L.*) genotypes. **Journal of Agricultural Studies**, Cambridge, v.2, n.2, p.87-104, 2014.

SIQUEIRA, B.S. **Desenvolvimento dos fenômenos de escurecimento e endurecimento em feijão carioca: aspectos bioquímicos e tecnológicos**. 2013. 126 p. Dissertação (Mestrado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Goiás, Goiânia.

SOARES, F.C.; RUSSI, J.L.; ROBAINA, A.D.; PEITER, M.X.; PARIZI, A.R.C. Uso de Rede Neural Artificial para predição da produção na cultura do feijoeiro. In: CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA, 43, 2014. Campo Grande, **Anais...** Campo Grande, CONBEA, 2014.

SRINIVASAN, D.; LIEW, A.C.; CHANG, C.S. A neural network short-term load forecaster. **Electric Power Systems Research**, Holanda, v.28, n.3, p.227-234, 1994.

VENDRUSCOLO, D.G.S; DRESCHER, R.; SOUZA, H.S.; MOURA, J.P.V.M.; MAMORÉ, F.M.D.; SIQUEIRA, T.A.S. Estimativa da altura de eucalipto por meio de regressão não linear e redes neurais artificiais. **Revista Brasileira de Biometria**, São Paulo, v.33, n.4, p.556-569, 2015 doi: 10.13140/RG.2.1.1742.5684

ZAMBIASI, C.A. **Qualidade de grãos de feijão armazenados em diferentes condições de temperatura**. 2015. 77 p. Tese (Doutorado em Engenharia Agrícola), Universidade Federal de Viçosa, Viçosa.

ZWEIRI, Y.H.; SENEVIRATNE, L.D.; ALTHOEFER, K. Stability analysis of a three-term backpropagation algorithm. **Neural Networks**, v.18, n.10, p.1341-1347, 2005.

7. APÊNDICE

Tabela 7 - Dados utilizados para o desenvolvimento das RNAs para os conjuntos de treinamento, validação e teste.

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de Armazenamento
1	11601	54,41	7,06	17,13	15	36
2	11957	53,93	7,27	17,63	21	36
3	13389	53,1	7,54	18,01	37	36
4	11806	53,26	6,86	17,76	15	36
5	12259	52,92	7,14	17,38	21	36
6	13686	52,25	7,42	17,59	37	36
7	12106	52,94	7,26	17,78	15	36
8	12433	50,36	7,07	17,76	21	36
9	14013	51,90	7,63	17,47	37	36
10	12280	53,34	7,06	17,68	15	36
11	12605	51,03	7,08	18,14	21	36
12	14216	51,53	7,62	17,67	37	36
13	12365	54,04	7,16	17,81	15	36
14	12938	53,77	7,17	17,91	21	36
15	14216	51,95	7,59	17,95	37	36
16	12488	53,18	7,06	17,99	15	36
17	13163	53,17	7,63	18,03	21	36
18	14398	53,17	7,63	18,03	37	36
19	12656	53,39	6,88	18,04	15	36
20	13334	51,74	7,51	17,94	21	36
21	14549	52,92	7,81	18,26	37	36
22	12721	52,10	7,07	17,34	15	36
23	13454	51,80	6,97	17,66	21	36
24	14862	51,59	7,93	18,28	37	36
25	12890	52,64	6,93	18,07	15	36
26	13585	51,84	7,04	17,57	21	36
27	15026	50,71	7,57	17,79	37	36
28	12962	51,61	7,11	17,09	15	36
29	13754	51,28	7,45	18,05	21	36
30	15109	50,41	7,52	18,31	37	36
31	13128	52,71	7,01	17,27	15	36
32	13903	52,23	7,14	17,95	21	36
33	15149	50,87	7,63	18,11	37	36
34	13170	52,74	7,16	17,62	15	36
35	13988	52,29	7,54	17,35	21	36
36	15260	50,90	7,97	18,37	37	36
37	13307	52,93	7,33	17,89	15	36
38	14065	52,46	7,12	17,94	21	36
39	15363	52,41	7,45	18,09	37	36
40	13380	53,14	7,07	18,09	15	36
41	14221	53,58	7,28	18,00	21	36

Cont...

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de Armazenamento
42	15493	52,17	7,41	18,23	37	36
43	13495	53,10	7,09	17,90	15	36
44	14340	52,41	7,22	17,60	21	36
45	15601	51,28	7,51	18,17	37	36
46	13605	52,45	7,12	17,59	15	36
47	14432	52,23	7,00	17,46	21	36
48	15738	51,92	7,67	17,65	37	36
49	13687	52,53	7,56	17,63	15	36
50	14508	52,03	7,17	18,16	21	36
51	15822	51,27	7,52	17,77	37	36
52	13763	53,54	6,92	17,54	15	36
53	14548	52,34	7,20	17,62	21	36
54	16018	51,99	7,47	18,08	37	36
55	13852	53,19	7,12	17,99	15	36
56	14633	52,60	7,11	18,17	21	36
57	16141	51,45	7,33	17,81	37	36
58	14100	52,93	7,08	16,96	15	36
59	14793	52,55	7,22	17,86	21	36
60	16284	52,46	7,83	17,75	37	36
61	12484	50,40	6,98	17,59	15	72
62	12787	50,03	7,50	17,95	21	72
63	13407	50,89	8,51	17,93	37	72
64	12695	54,37	6,98	17,61	15	72
65	13084	54,37	6,98	17,61	21	72
66	13949	50,60	8,53	18,22	37	72
67	13102	53,66	7,00	17,61	15	72
68	13248	52,91	7,28	17,57	21	72
69	14155	47,90	8,53	18,04	37	72
70	13182	52,55	7,00	17,82	15	72
71	13419	53,00	7,41	17,73	21	72
72	14375	49,54	8,60	18,26	37	72
73	13241	52,39	6,88	17,76	15	72
74	13510	52,68	7,65	18,05	21	72
75	14521	48,98	8,59	18,24	37	72
76	13444	52,63	6,95	17,92	15	72
77	13918	53,02	7,65	18,49	21	72
78	14659	49,86	8,85	18,32	37	72
79	13558	52,29	7,12	17,94	15	72
80	14106	52,48	7,60	18,37	21	72
81	14904	49,62	8,90	18,43	37	72
82	13618	52,68	7,02	18,29	15	72
83	14188	52,28	7,35	17,54	21	72
84	14979	49,35	8,83	18,73	37	72
85	13693	52,63	7,11	17,42	15	72

Cont...

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de armazenamento
86	14259	51,44	7,55	17,79	21	72
87	15156	49,05	8,82	18,90	37	72
88	13841	52,73	7,29	17,69	15	72
89	14419	52,00	8,08	18,17	21	72
90	15303	48,37	8,98	19,11	37	72
91	13893	51,97	7,03	18,37	15	72
92	14510	52,85	7,64	18,65	21	72
93	15465	48,24	9,19	19,25	37	72
94	14011	53,21	7,15	17,56	15	72
95	14653	52,67	7,57	18,39	21	72
96	15789	48,69	8,94	18,53	37	72
97	14162	53,43	6,85	17,75	15	72
98	14736	52,82	7,62	18,35	21	72
99	15874	52,82	7,62	18,35	37	72
100	14223	53,67	7,13	17,64	15	72
101	14793	52,27	7,63	17,97	21	72
102	16044	49,64	8,84	18,15	37	72
103	14439	51,78	7,73	17,55	15	72
104	14912	52,92	7,34	17,53	21	72
105	16122	49,68	8,79	18,60	37	72
106	14533	53,50	6,69	17,68	15	72
107	15045	52,76	7,56	18,00	21	72
108	16258	50,10	8,73	18,37	37	72
109	14614	52,15	6,81	17,84	15	72
110	15097	52,80	7,40	17,20	21	72
111	16485	49,21	8,79	17,72	37	72
112	14785	52,82	7,15	17,54	15	72
113	15279	52,21	7,68	17,93	21	72
114	16681	49,39	8,29	18,35	37	72
115	14884	53,59	6,68	17,83	15	72
116	15480	53,32	7,39	17,67	21	72
117	16770	53,32	7,39	17,67	37	72
118	14994	52,81	7,09	17,98	15	72
119	15599	53,57	7,70	17,31	21	72
120	16962	49,80	8,39	18,71	37	72
121	12468	53,56	7,04	17,47	15	108
122	11559	53,13	7,87	18,10	21	108
123	14018	50,33	8,79	19,03	37	108
124	12727	53,72	7,21	17,65	15	108
125	11879	52,30	7,96	18,20	21	108
126	14812	51,03	8,27	18,50	37	108
127	13062	50,90	7,02	17,01	15	108
128	12018	51,12	7,92	18,63	21	108
129	14968	48,63	8,79	18,55	37	108

Cont...

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de armazenamento
130	13218	51,51	7,18	17,67	15	108
131	12177	49,98	8,30	18,25	21	108
132	15057	48,99	8,82	18,72	37	108
133	13367	53,18	7,68	18,71	15	108
134	12297	50,70	8,18	18,24	21	108
135	15168	50,45	8,61	18,79	37	108
136	13509	53,52	7,47	18,02	15	108
137	12378	51,85	8,10	18,44	21	108
138	15450	49,25	9,21	18,40	37	108
139	13666	51,18	7,31	17,48	15	108
140	12566	50,17	8,25	18,49	21	108
141	15568	50,07	8,93	18,78	37	108
142	13746	52,01	7,42	17,92	15	108
143	12649	48,95	8,24	18,49	21	108
144	15760	49,42	8,52	18,49	37	108
145	13803	52,41	7,51	17,78	15	108
146	12774	49,77	8,17	18,52	21	108
147	15930	49,45	8,57	18,30	37	108
148	13933	52,72	7,30	17,78	15	108
149	12933	50,50	7,88	18,38	21	108
150	16071	50,11	8,89	17,99	37	108
151	14035	52,00	7,78	17,83	15	108
152	13082	50,72	8,02	18,29	21	108
153	16188	49,54	8,77	18,25	37	108
154	14143	52,98	7,15	17,80	15	108
155	13143	50,51	8,01	18,16	21	108
156	16292	49,69	8,77	18,19	37	108
157	14296	52,40	7,52	17,98	15	108
158	13263	51,72	8,00	18,32	21	108
159	16551	49,64	8,78	18,43	37	108
160	14404	52,02	7,07	17,49	15	108
161	13431	51,05	8,09	18,39	21	108
162	16645	49,04	8,47	18,31	37	108
163	14517	52,74	7,33	17,65	15	108
164	13595	50,83	7,87	18,18	21	108
165	16771	50,06	8,39	18,74	37	108
166	14587	52,37	7,16	17,62	15	108
167	13748	51,28	8,29	18,18	21	108
168	16840	49,21	8,80	17,97	37	108
169	14717	51,78	7,19	17,76	15	108
170	13897	49,90	8,08	18,23	21	108
171	17021	49,71	8,85	18,57	37	108
172	14828	51,76	7,43	17,41	15	108
173	13990	51,03	8,07	18,00	21	108

Cont...

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de armazenamento
174	17157	50,24	9,01	18,81	37	108
175	15001	52,66	7,77	17,30	15	108
176	14130	50,90	8,11	18,85	21	108
177	17324	50,86	8,50	18,66	37	108
178	15076	52,39	6,95	18,50	15	108
179	14331	51,32	8,18	18,77	21	108
180	17478	50,28	8,89	18,86	37	108
181	12939	54,20	7,43	17,38	15	144
182	13408	51,85	8,44	17,90	21	144
183	15043	49,85	9,10	18,78	37	144
184	13477	53,42	7,36	17,24	15	144
185	13756	52,04	8,36	17,98	21	144
186	15557	49,52	9,16	18,67	37	144
187	13655	52,67	6,94	16,54	15	144
188	13958	48,96	8,09	17,69	21	144
189	15816	48,36	9,32	18,39	37	144
190	13722	51,47	7,19	16,52	15	144
191	14118	49,86	8,19	17,85	21	144
192	16239	47,23	9,34	18,52	37	144
193	13841	53,45	7,30	17,08	15	144
194	14231	52,29	8,74	17,99	21	144
195	16405	49,57	9,27	19,07	37	144
196	14098	54,09	7,47	17,35	15	144
197	14322	52,02	8,52	17,98	21	144
198	16546	49,56	9,21	18,15	37	144
199	14211	53,39	7,60	17,74	15	144
200	14358	52,62	8,31	18,48	21	144
201	16814	49,76	9,24	18,43	37	144
202	14244	51,53	7,13	16,90	15	144
203	14522	51,24	8,36	18,07	21	144
204	16937	47,24	9,33	19,34	37	144
205	14338	51,94	7,06	16,93	15	144
206	14605	49,78	8,45	17,65	21	144
207	17079	46,43	9,55	18,92	37	144
208	14396	52,38	7,14	17,03	15	144
209	14652	51,47	8,37	18,36	21	144
210	17187	46,97	9,36	18,84	37	144
211	14415	53,04	7,28	17,37	15	144
212	14749	51,03	8,49	18,22	21	144
213	17262	49,30	9,21	18,59	37	144
214	14505	53,11	7,51	16,51	15	144
215	14856	51,70	8,56	18,63	21	144
216	17333	48,86	9,48	18,51	37	144
217	14568	53,70	7,46	16,83	15	144

Cont...

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de Armazenamento
218	14996	52,27	8,71	18,08	21	144
219	17420	49,60	9,33	18,89	37	144
220	14645	52,11	7,11	17,81	15	144
221	15091	50,23	8,62	17,91	21	144
222	17487	48,22	9,25	18,99	37	144
223	14685	53,35	7,19	17,46	15	144
224	15223	51,29	8,85	17,78	21	144
225	17620	47,81	9,19	18,31	37	144
226	14762	53,51	7,25	16,93	15	144
227	15250	51,21	8,19	18,40	21	144
228	17636	48,61	9,21	19,05	37	144
229	14898	52,78	7,30	17,68	15	144
230	15284	50,66	8,26	17,26	21	144
231	17697	48,21	9,67	19,52	37	144
232	15023	52,26	7,26	16,81	15	144
233	15326	50,65	7,65	18,06	21	144
234	17830	48,47	9,12	19,08	37	144
235	15190	52,35	7,02	16,89	15	144
236	14417	50,97	7,98	17,93	21	144
237	18033	46,94	9,16	18,97	37	144
238	15217	52,32	7,04	17,10	15	144
239	15524	51,95	7,96	18,04	21	144
240	18093	48,20	9,15	19,17	37	144
241	13293	52,55	7,59	17,45	15	180
242	11071	51,75	8,54	17,84	21	180
243	16170	47,37	9,68	17,66	37	180
244	13703	53,31	7,11	17,32	15	180
245	11158	51,23	8,58	18,10	21	180
246	16571	46,80	9,78	17,99	37	180
247	13805	51,10	7,45	17,28	15	180
248	11250	48,90	8,67	17,34	21	180
249	16789	47,16	9,51	18,67	37	180
250	13993	51,51	7,57	17,43	15	180
251	11361	48,77	8,54	17,22	21	180
252	17069	45,62	9,99	18,82	37	180
253	14080	52,81	7,49	17,68	15	180
254	11509	51,07	8,44	16,87	21	180
255	17206	46,83	9,88	17,97	37	180
256	14278	53,72	7,24	17,43	15	180
257	11569	51,24	8,76	17,23	21	180
258	17309	47,93	9,81	18,90	37	180
259	14398	50,67	7,46	16,88	15	180
260	11610	48,85	9,01	17,74	21	180
261	17472	46,31	9,49	18,40	37	180

Cont...

Amostras	Dureza (cN)	L	a*	b*	Temperatura °C	Dias de Armazenamento
262	14472	49,57	7,40	16,98	15	180
263	11723	49,88	8,50	16,79	21	180
264	17567	45,92	9,36	17,60	37	180
265	14526	53,50	7,47	16,90	15	180
266	11836	50,38	8,52	16,90	21	180
267	17654	47,91	9,27	18,15	37	180
268	14570	51,14	7,48	16,66	15	180
269	11888	49,14	8,34	16,68	21	180
270	17678	47,18	9,40	18,28	37	180
271	14707	53,01	7,45	17,30	15	180
272	11945	50,66	8,56	17,02	21	180
273	17946	47,36	9,30	18,37	37	180
274	14794	51,99	7,16	17,07	15	180
275	11991	49,72	8,74	17,26	21	180
276	17998	48,25	10,10	18,60	37	180
277	14899	52,22	7,68	17,13	15	180
278	12022	50,92	8,33	17,00	21	180
279	18124	47,50	10,05	18,39	37	180
280	14980	52,31	7,17	17,50	15	180
281	12062	50,40	8,44	17,34	21	180
282	18343	46,58	9,94	18,51	37	180
283	15051	53,47	7,85	17,22	15	180
284	12098	50,05	8,64	17,72	21	180
285	18498	46,84	9,53	18,42	37	180
286	15135	50,50	7,67	17,84	15	180
287	12125	49,51	8,17	17,31	21	180
288	18619	47,09	9,68	18,56	37	180
289	15192	51,46	7,15	17,55	15	180
290	12163	49,86	8,73	17,44	21	180
291	18779	47,84	9,74	18,32	37	180
292	15250	51,76	7,44	17,55	15	180
293	12199	49,70	8,33	16,97	21	180
294	18842	46,71	9,14	18,50	37	180
295	15357	51,19	7,28	16,88	15	180
296	12298	50,58	8,55	17,03	21	180
297	18954	47,02	9,46	18,18	37	180
298	15422	51,90	7,40	16,87	15	180
299	12319	50,40	8,69	17,55	21	180
300	19122	46,40	9,16	17,83	37	180

Centinewton (cN); Luminosidade (L); vermelho versus verde (a); e amarelo versus azul (b).

Tabela 8 - Dados do experimento realizado em laboratório da variável COR utilizados para o desenvolvimento da RNA.

Dias de armazenamento (36)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
1	54,41	7,06	17,13	53,93	7,27	17,63	53,10	7,54	18,01
2	53,26	6,86	17,76	52,92	7,14	17,38	52,25	7,42	17,59
3	52,94	7,26	17,78	50,36	7,07	17,76	51,90	7,63	17,47
4	53,34	7,06	17,68	51,03	7,08	18,14	51,53	7,62	17,67
5	54,04	7,16	17,81	53,77	7,17	17,91	51,95	7,59	17,95
6	53,18	7,06	17,99	53,17	7,63	18,03	51,14	7,55	17,95
7	53,39	6,88	18,04	51,74	7,51	17,94	52,92	7,81	18,26
8	52,10	7,07	17,34	51,80	6,97	17,66	51,59	7,93	18,28
9	52,64	6,93	18,07	51,84	7,04	17,57	50,71	7,57	17,79
10	51,61	7,11	17,09	51,28	7,45	18,05	50,41	7,52	18,31
11	52,71	7,01	17,27	52,23	7,14	17,95	50,87	7,63	18,11
12	52,74	7,16	17,62	52,29	7,54	17,35	50,90	7,97	18,37
13	52,93	7,33	17,89	52,46	7,12	17,94	52,41	7,45	18,09
14	53,14	7,07	18,09	53,58	7,28	18,00	52,17	7,41	18,23
15	53,10	7,09	17,90	52,41	7,22	17,60	51,28	7,51	18,17
16	52,45	7,12	17,59	52,23	7,00	17,46	51,92	7,67	17,65
17	52,53	7,56	17,63	52,03	7,17	18,16	51,27	7,52	17,77
18	53,54	6,92	17,54	52,34	7,20	17,62	51,99	7,47	18,08
19	53,19	7,12	17,99	52,60	7,11	18,17	51,45	7,33	17,81
20	52,93	7,08	16,96	52,55	7,22	17,86	52,46	7,83	17,75
Dias de armazenamento (72)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
1	54,40	6,99	17,59	54,03	7,50	17,96	50,89	8,52	17,93
2	54,37	6,98	17,61	52,76	7,38	17,57	50,67	8,53	18,21
3	53,66	7,00	17,61	52,91	7,28	17,57	47,90	8,53	18,04
4	52,55	7,00	17,82	53,00	7,41	17,73	49,54	8,60	18,26
5	52,39	6,88	17,76	52,68	7,65	18,05	48,98	8,59	18,24
6	52,63	6,95	17,92	53,02	7,65	18,49	49,86	8,85	18,32
7	52,29	7,12	17,94	52,48	7,60	18,37	49,62	8,90	18,43
8	52,68	7,02	18,29	52,28	7,35	17,54	49,35	8,83	18,73
9	52,63	7,11	17,42	51,44	7,55	17,79	49,05	8,82	18,90
10	52,73	7,29	17,69	52,00	8,08	18,17	48,37	8,98	19,11
11	51,97	7,03	18,37	52,85	7,64	18,65	48,24	9,19	19,25
12	53,21	7,15	17,56	52,67	7,57	18,39	48,69	8,94	18,53
13	53,43	6,85	17,75	52,82	7,62	18,35	49,82	8,78	18,30
14	53,67	7,13	17,64	52,27	7,63	17,97	49,64	8,84	18,15
15	51,78	7,73	17,55	52,92	7,34	17,53	49,68	8,79	18,60
16	53,50	6,69	17,68	52,76	7,56	18,00	50,10	8,73	18,37
17	52,15	6,81	17,84	52,80	7,40	17,20	49,21	8,79	17,72
18	52,82	7,15	17,54	52,21	7,68	17,93	49,39	8,29	18,35

Cont...

Dias de armazenamento (72)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
19	53,59	6,68	17,83	53,32	7,39	17,67	49,14	8,90	18,02
20	52,81	7,09	17,98	53,57	7,70	17,31	49,80	8,39	18,71

Dias de armazenamento (108)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
1	53,57	7,04	17,47	53,13	7,88	18,11	50,34	8,79	19,03
2	53,72	7,21	17,65	52,30	7,96	18,20	51,03	8,27	18,51
3	50,90	7,02	17,01	51,12	7,92	18,63	48,63	8,79	18,55
4	51,51	7,18	17,67	49,98	8,30	18,25	48,99	8,82	18,72
5	53,18	7,68	18,71	50,70	8,18	18,24	50,45	8,61	18,79
6	53,52	7,47	18,02	51,85	8,10	18,44	49,25	9,21	18,40
7	51,18	7,31	17,48	50,17	8,25	18,49	50,07	8,93	18,78
8	52,01	7,42	17,92	48,95	8,24	18,49	49,42	8,52	18,49
9	52,41	7,51	17,78	49,77	8,17	18,52	49,45	8,57	18,30
10	52,72	7,30	17,78	50,50	7,88	18,38	50,11	8,89	17,99
11	52,00	7,78	17,83	50,72	8,02	18,29	49,54	8,77	18,25
12	52,98	7,15	17,80	50,51	8,01	18,16	49,69	8,77	18,19
13	52,40	7,52	17,98	51,72	8,00	18,32	49,64	8,78	18,43
14	52,02	7,07	17,49	51,05	8,09	18,39	49,04	8,47	18,31
15	52,74	7,33	17,65	50,83	7,87	18,18	50,06	8,39	18,74
16	52,37	7,16	17,62	51,28	8,29	18,18	49,21	8,80	17,97
17	51,78	7,19	17,76	49,90	8,08	18,23	49,71	8,85	18,57
18	51,76	7,43	17,41	51,03	8,07	18,00	50,24	9,01	18,81
19	52,66	7,77	17,30	50,90	8,11	18,85	50,86	8,50	18,66
20	52,39	6,95	18,50	51,32	8,18	18,77	50,28	8,89	18,86

Dias de armazenamento (144)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
1	54,20	7,43	17,38	51,85	8,44	17,90	49,85	9,10	18,78
2	53,42	7,36	17,24	52,04	8,36	17,98	49,52	9,16	18,67
3	52,67	6,94	16,54	48,96	8,09	17,69	48,36	9,32	18,39
4	51,47	7,19	16,52	49,86	8,19	17,85	47,23	9,34	18,52
5	53,45	7,30	17,08	52,29	8,74	17,99	49,57	9,27	19,07
6	54,09	7,47	17,35	52,02	8,52	17,98	49,56	9,21	18,15
7	53,39	7,60	17,74	52,62	8,31	18,48	49,76	9,24	18,43
8	51,53	7,13	16,90	51,24	8,36	18,07	47,24	9,33	19,34
9	51,94	7,06	16,93	49,78	8,45	17,65	46,43	9,55	18,92
10	52,38	7,14	17,03	51,47	8,37	18,36	46,97	9,36	18,84
11	53,04	7,28	17,37	51,03	8,49	18,22	49,30	9,21	18,59
12	53,11	7,51	16,51	51,70	8,56	18,63	48,86	9,48	18,51
13	53,70	7,46	16,83	52,27	8,71	18,08	49,60	9,33	18,89
14	52,11	7,11	17,81	50,23	8,62	17,91	48,22	9,25	18,99
15	53,35	7,19	17,46	51,29	8,85	17,78	47,81	9,19	18,31

Cont...

Dias de armazenamento (144)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
16	53,51	7,25	16,93	51,21	8,19	18,40	48,61	9,21	19,05
17	52,78	7,30	17,68	50,66	8,26	17,26	48,21	9,67	19,52
18	52,26	7,26	16,81	50,65	7,65	18,06	48,47	9,12	19,08
19	52,35	7,02	16,89	50,97	7,98	17,93	46,94	9,16	18,97
20	52,32	7,04	17,10	51,95	7,96	18,04	48,20	9,15	19,17

Dias de armazenamento (180)									
Repetição	Temperatura 15 °C			Temperatura 21 °C			Temperatura 37 °C		
	L	a*	b*	L	a*	b*	L	a*	b*
1	52,56	7,59	17,46	51,75	8,54	17,84	47,37	9,68	17,66
2	53,31	7,11	17,32	51,23	8,58	18,10	46,80	9,78	18,00
3	51,10	7,45	17,28	48,90	8,67	17,34	47,16	9,51	18,67
4	51,51	7,57	17,43	48,77	8,54	17,22	45,62	9,99	18,82
5	52,81	7,49	17,68	51,07	8,44	16,87	46,83	9,88	17,97
6	53,72	7,24	17,43	51,24	8,76	17,23	47,93	9,81	18,90
7	50,67	7,46	16,88	48,85	9,01	17,74	46,31	9,49	18,40
8	49,57	7,40	16,98	49,88	8,50	16,79	45,92	9,36	17,60
9	53,50	7,47	16,90	50,38	8,52	16,90	47,91	9,27	18,15
10	51,14	7,48	16,66	49,14	8,34	16,68	47,18	9,40	18,28
11	53,01	7,45	17,30	50,66	8,56	17,02	47,36	9,30	18,37
12	51,99	7,16	17,07	49,72	8,74	17,26	48,25	10,10	18,60
13	52,22	7,68	17,13	50,92	8,33	17,00	47,50	10,05	18,39
14	52,31	7,17	17,50	50,40	8,44	17,34	46,58	9,94	18,51
15	53,47	7,85	17,22	50,05	8,64	17,72	46,84	9,53	18,42
16	50,50	7,67	17,84	49,51	8,17	17,31	47,09	9,68	18,56
17	51,46	7,15	17,55	49,86	8,73	17,44	47,84	9,74	18,32
18	51,76	7,44	17,55	49,70	8,33	16,97	46,71	9,14	18,50
19	51,19	7,28	16,88	50,58	8,55	17,03	47,02	9,46	18,18
20	51,90	7,40	16,87	50,40	8,69	17,55	46,40	9,16	17,83

Luminosidade (L); vermelho versus verde (a); e amarelo versus azul (b).

Tabela 9 - Dados do experimento realizado em laboratório da variável DUREZA utilizados para o desenvolvimento da RNA.

Repetição	Dias de Armazenamento								
	36			72			108		
	Temperatura (°C)								
	15	21	37	15	21	37	15	21	37
	Dureza (cN)								
1	11601	11957	13389	12484	12787	13407	12468	11559	14018
2	11806	12259	13686	12695	13084	13949	12727	11879	14812
3	12106	12433	14013	13102	13248	14155	13062	12018	14968
4	12280	12605	14216	13182	13419	14375	13218	12177	15057
5	12365	12938	14307	13241	13510	14521	13367	12297	15168
6	12488	13163	14398	13444	13918	14659	13509	12378	15450

Cont...

Repetição	Dias de Armazenamento								
	36			72			108		
	Temperatura (°C)								
	15	21	37	15	21	37	15	21	37
Dureza (cN)									
7	12656	13334	14549	13558	14106	14904	13666	12566	15568
8	12721	13454	14862	13618	14188	14979	13746	12649	15760
9	12890	13585	15026	13693	14259	15156	13803	12774	15930
10	12962	13754	15109	13841	14419	15303	13933	12933	16071
11	13128	13903	15149	13893	14510	15465	14035	13082	16188
12	13170	13988	15260	14011	14653	15789	14143	13143	16292
13	13307	14065	15363	14162	14736	15874	14296	13263	16551
14	13380	14221	15493	14223	14793	16044	14404	13431	16645
15	13495	14340	15601	14439	14912	16122	14517	13595	16771
16	13605	14432	15738	14533	15045	16258	14587	13748	16840
17	13687	14508	15822	14614	15097	16485	14717	13897	17021
18	13763	14548	16018	14785	15279	16681	14828	13990	17157
19	13852	14633	16141	14884	15480	16770	15001	14130	17324
20	14100	14793	16284	14994	15599	16962	15076	14331	17478

Repetição	Dias de Armazenamento					
	144			180		
	Temperatura (°C)					
	15	21	37	15	21	37
Dureza (cN)						
1	12939	13408	15043	13293	11071	16170
2	13477	13756	15557	13703	11158	16571
3	13655	13958	15816	13805	11250	16789
4	13722	14118	16239	13993	11361	17069
5	13841	14231	16405	14080	11509	17206
6	14098	14322	16546	14278	11569	17309
7	14211	14358	16814	14398	11610	17472
8	14244	14522	16937	14472	11723	17567
9	14338	14605	17079	14526	11836	17654
10	14396	14652	17187	14570	11888	17678
11	14415	14749	17262	14707	11945	17946
12	14505	14856	17333	14794	11991	17998
13	14568	14996	17420	14899	12022	18124
14	14645	15091	17487	14980	12062	18343
15	14685	15223	17620	15051	12098	18498
16	14762	15250	17636	15135	12125	18619
17	14898	15284	17697	15192	12163	18779
18	15023	15326	17830	15250	12199	18842
19	15109	15417	18033	15357	12298	18954
20	15217	15524	18093	15422	12319	19122

Cont...

Centinewton (cN); Luminosidade (L); vermelho versus verde (a); e amarelo versus azul (b).