

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS

**USO DE REDES NEURAS ARTIFICIAIS NA PREDIÇÃO
DE EFICIÊNCIAS NA COLHEITA SEMIMECANIZADA
DO FEIJÃO**

MARCONDES DE SOUZA PADILHA

DOURADOS
MATO GROSSO DO SUL
2018

**USO DE REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DE
EFICIÊNCIAS NA COLHEITA SEMIMECANIZADA DO
FEIJÃO**

MARCONDES DE SOUZA PADILHA

Orientador: PROF. Dr. CRISTIANO MÁRCIO ALVES DE SOUZA

Trabalho de Conclusão de Curso
apresentado à Universidade Federal da
Grande Dourados, como parte das
exigências para conclusão do curso de
Engenharia Agrícola.

DOURADOS
MATO GROSSO DO SUL
2018

Dados Internacionais de Catalogação na Publicação (CIP).

P123u Padilha, Marcondes De Souza

Uso de redes neurais artificiais na predição de eficiências na colheita semimecanizada do feijão / Marcondes De Souza Padilha -- Dourados: UFGD, 2018.

29f. : il. ; 30 cm.

Orientador: Cristiano Márcio Alves de Souza

TCC (Graduação em Engenharia Agrícola) -Faculdade de Ciências Agrárias, Universidade Federal da Grande Dourados.

Inclui bibliografia

1. Controladores. 2. Perdas na colheita. 3. Modelagem matemática. I. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

**USO DE REDES NEURAS ARTIFICIAIS NA PREDIÇÃO DE EFICIÊNCIAS NA
COLHEITA SEMIMECANIZADA DO FEIJÃO**

Por

Marcondes de Souza Padilha

Trabalho de Conclusão de Curso apresentado como parte dos requisitos exigidos para
obtenção do título de ENGENHEIRO AGRÍCOLA

Aprovado em: 16 de fevereiro de 2018.

Prof. Dr. Cristiano Márcio Alves de Souza
Orientador – UFGD/FCA

Prof. Dr. Roberto Carlos Orlando
Membro da Banca – UFGD/FCA

Prof. Dra. Leidy Zulys Leyva Rafull
Membro da Banca – UFGD/FCA

AGRADECIMENTOS

A Deus, por me permitir chegar até aqui.

Aos meus Pais, que no pouco que tinham, sempre me ajudaram e ensinaram o caminho da educação e conhecimento. E ao meu irmão por sempre me proporcionar alegrias.

A Universidade Federal da Grande Dourados (UFGD) e a Faculdade de Ciências Agrárias (FCA), por me possibilitar cursar Engenharia Agrícola.

Ao professor Dr. Cristiano Márcio Alves de Souza, pela orientação, sugestões, conhecimentos e principalmente pela confiança na realização deste trabalho.

Aos meus amigos, que sempre estiveram ao meu lado e me incentivaram nos bons e maus momentos.

A minha namorada Tatiane Medeiros, pelo apoio, amor e carinho durante os dias difíceis.

A todos os professores do curso de engenharia agrícola, por compartilhar seus conhecimentos, histórias e vida durante todo o tempo de graduação, e por me ajudarem a moldar o conhecimento ao longo desses anos.

A Prof^a Dr. Elaine Reis Pinheiro e ao Prof. Me. Elton Aparecido Siqueira Martins, pelo exemplo como profissionais. Sou grato por toda a amizade e conselhos durante esses anos.

Ao professor Dr. Roberto Carlos Orlando e a professora Dra. Leidy Zulys Leyva Rafull pela avaliação desse trabalho, pelas correções e sugestões para posteriores melhorias do mesmo.

A todos que de alguma forma me ajudaram e me querem bem. Meus sinceros agradecimentos!

SUMÁRIO

	PÁGINA
LISTA DE QUADROS	v
LISTA DE FIGURAS.....	vi
RESUMO.....	vii
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA.....	3
2.1. A Cultura do Feijão	3
2.2. Colheita do Feijão	4
2.3. Eficiência na Colheita	5
2.4. Redes Neurais Artificiais	6
2.4.1. Histórico.....	7
2.4.2. Neurônio Biológico.....	7
2.4.3. Neurônio Artificial.....	8
2.4.4. Treinamento	10
2.4.5. Redes <i>Perceptron</i> Multicamadas (PMC).....	11
2.5. Identidade de Modelo.....	12
3. MATERIAL E MÉTODOS	16
3.1. Local.....	16
3.2. Modelagem.....	16
3.3. Experimento de Campo.....	17
3.4. Validação Estatística do Modelo de Predição	18
4. RESULTADOS E DISCUSSÃO.....	19
4.1. Redes Neurais Artificiais Seleccionadas	19
4.2. Validação Estatística das Redes Neurais Seleccionadas.....	23
5. CONCLUSÕES	26
6. REFERÊNCIAS BIBLIOGRÁFICAS	27

LISTA DE QUADROS

	PÁGINA
QUADRO 1. Regra de decisão para comparação de métodos analíticos para identidade de modelo.....	15
QUADRO 2. Análise de identidade de modelo das RNA avaliadas pelo erro relativo médio (E_r), coeficiente de determinação (R^2), teste de Graybill ($F(H_0)$), teste t do erro médio (t_e) e a relação entre a correlação e o acerto da rede ($R > (1-e)$).....	24

LISTA DE FIGURAS

	PÁGINA
FIGURA 1. Neurônio biológico.	8
FIGURA 2. Neurônio artificial de uma única entrada.	9
FIGURA 3. Representação da rede <i>Perceptron</i> Multicamadas.	11
FIGURA 4. Algumas possíveis situações, quando dois métodos analíticos são comparados pela técnica de regressão linear simples.	14
FIGURA 5. Representação da rede <i>Perceptron</i> de Múltiplas Camadas (PMC) com configuração (2-n1-n2-1).	17
FIGURA 6. Erro quadrático médio (mse) dos dados usados no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência de recolhimento da plataforma.	20
FIGURA 7. Desempenho da RNA na predição de eficiência de recolhimento da plataforma.	20
FIGURA 8. Erro quadrático médio (mse) dos dados usados no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência da separação.	21
FIGURA 9. Desempenho da RNA na predição de eficiência da separação.	21
FIGURA 10. Erro quadrático médio (mse) dos dados usados no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência da limpeza.	22
FIGURA 11. Desempenho da RNA na predição de eficiência da limpeza.	22
FIGURA 12. Erro quadrático médio (mse) dos dados usados no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência total.	23
FIGURA 13. Desempenho da RNA na predição de eficiência total.	23
FIGURA 14. Comparação entre dados de eficiência de recolhimento da plataforma (a), de separação (b), de limpeza (c) e total (d) obtidos experimentalmente e usando a RNA.	25

PADILHA, Marcondes de Souza. **Uso de redes neurais artificiais na predição de eficiências na colheita semimecanizada do feijão**. 2018. 29f. Monografia (Graduação em Engenharia Agrícola) – Universidade Federal da Grande Dourados, Dourados – MS.

RESUMO

A cultura do feijão está entre as mais consumidas e produzidas no Brasil. Aliado a demanda de alimentos, há a crescente busca por tecnologias e controladores para agricultura, que possibilitem ampliar o uso de sistemas mais eficientes no processo de produção. Este trabalho teve como objetivo modelar arquiteturas de redes neurais artificiais (RNA) para prever as eficiências mecânicas na colheita semimecanizada do feijão e realizar a validação das redes obtidas. Foi utilizada uma rede *Perceptron* multicamadas, com três entradas (teor de água de colheita, rotação do cilindro trilhador de fluxo axial e taxa de alimentação da colhedora), duas camadas escondidas de neurônios e uma saída (eficiência). Realizou-se a predição da eficiência no recolhimento da plataforma, na trilha e separação do rotor, na limpeza das peneiras e da eficiência total da máquina. Para realizar os estudos, a RNA foi processada implementando um algoritmo em *script*, a fim de modelar a rede, alternar a quantidades de neurônios das camadas ocultas, selecionar, testar e validar a RNA com melhor desempenho. Para validar as arquiteturas selecionadas pelas redes foi realizada a comparação de seus resultados com dados experimentais. As arquiteturas selecionadas para prever as eficiências foram: 3-8-15-1 para plataforma, 3-9-7-1 para trilha e separação, 3-5-11-1 para limpeza e 3-15-10-1 para total. As RNA preveem resultados satisfatório, tendo todas elas apresentadas erros relativos inferiores a 1%, coeficiente de determinação superior a 0,70 e correlação linear superior ao acerto das redes. Assim, houve validação das RNA selecionadas para prever as eficiências na plataforma de recolhimento, na trilha e separação, na limpeza e a total da máquina.

Palavras-chave: controladores; perdas na colheita; modelagem matemática.

1. INTRODUÇÃO

No atual cenário da economia brasileira o feijão ocupa um grande espaço tornando-se umas das principais culturas alimentícias para consumo humano direto, sendo rico em ferro, proteína e carboidratos (CONAB, 2015). Entre os maiores produtores mundiais de feijão, estão: Brasil, Índia e Birmânia. Ou seja, o fato de haver uma relevante demanda por tal leguminosa, coloca o Brasil como um dos países com maior produção (MANOS et al., 2013). Além da expressiva importância econômica do feijão, tanto para consumo interno quanto para a exportação, o mesmo é um alimento fundamental na dieta alimentar da população e uma das principais fontes de proteínas para grupos sociais menos favorecido economicamente (BORÉM e CARNEIRO, 1998).

Com aumento da demanda por tal alimento, é importante levar em consideração a eficiência durante a colheita mecanizada. Há uma constante busca por tornar os sistemas mecânicos cada vez mais eficazes de forma que possa reduzir perdas e haja menor prejuízo nas lavouras. As perdas oriundas do processo de colheita em vários casos são elevadas e podem decorrer de vários fatores, impactando diretamente quantitativa e qualitativamente no produto (SOUZA et al., 2010), minimizando assim o seu valor final agregado.

A necessidade por produzir mais alimentos de forma que possa suprir a demanda mundial, impulsiona o uso de tecnologias que aumentem a eficiência dos processos de produção e o uso de ferramenta que tornem isso possível. Mediante a tal fato, há a crescente busca por técnicas mais sofisticadas que auxiliem no controle de processos e ajudem a diminuir as perdas. Entre os controladores mais utilizados estão os Proporcional Integrado Derivativo (PID) comumente utilizados, e englobando os sistemas inteligentes que vem crescendo nos últimos anos, estão a Lógica Fuzzy e as Redes Neurais Artificiais (RNA) (FERNANDES JÚNIOR et al., 2005).

Os estudos acerca de redes neurais artificiais tiveram início no ano de 1943 com McCulloch e Pitts (SILVA et al., 2016), e desde então com o aumento da modernização e maior capacidade de processamento dos computadores, vem sendo impulsionada cada vez mais a tentativa de fazer essas máquinas desempenharem atividades que são relativamente fáceis para seres humanos (FAUSETT, 1994). O uso das redes neurais artificiais pode ocorrer de inúmeras formas. De acordo com Silva et al. (2016), elas podem ser aplicadas em: avaliação de imagens digitais obtidas por satélites, classificação de padrões de escrita e fala, reconhecimento de faces em visão

artificial, controle de trens de grande velocidade, previsão de ações do mercado financeiro, entre outros. Na agricultura há trabalhos usando RNA, tais como: estimativa de produtividade da cana-de-açúcar (PICOLI, 2006), recomendação de adubação para cultura da goiabeira (SILVA et al., 2004), predição de perdas de colheita do milho em relação a rotação do cilindro trilhador e da velocidade da colhedora (PISHGAR-KOMLEH et al., 2012), modelagem de redes neurais artificiais para perdas de colheita na plataforma de corte (PEYMAN et al., 2013), entre outros.

Considerando as potencialidades do uso de RNA e a necessidade de buscar formas efetivas que possam explicar e auxiliar no controle do processo de colheita mecânica, o presente trabalho teve como objetivo modelar arquiteturas de RNA para prever as eficiências do recolhimento da plataforma, da trilha e separação dos grãos, da limpeza do produto e total da máquina no decorrer da operação de colheita semimecanizada do feijão, e realizar as suas validações comparando seus resultados com dados obtidos experimentalmente.

2. REVISÃO DE LITERATURA

2.1. A Cultura do Feijão

Com a expansão populacional há crescente busca pelo aumento da produtividade das culturas a fim de elevar a oferta de alimentos. Tendo uma produção estimada para o ano de 2017 de mais de 3 milhões de toneladas e aumento de 31,7% quando comparada a produção do ano anterior (IBGE, 2017), a cultura do feijão (*Phaseolus vulgaris L.*) é um dos principais alimentos na dieta tradicional brasileira, colocando o país como maior consumidor mundial dos grãos (CONAB, 2010).

O feijão é uma leguminosa rica em proteínas e carboidrato, sendo também uma fonte de ferro e vitamina B (SOUZA, 2001). Além disso, ele é fonte de renda para a agricultura familiar, sendo ela responsável por 70% da produção de feijão no Brasil (BORSARI e CAVICHIOLI, 2017). Ou seja, há um grande valor socioeconômico associado a essa cultura.

Internacionalmente, o Brasil possui um expressivo papel na produção, ocupando um dos primeiros lugares entre os países com maior cultivo. Entre os maiores produtores mundiais, estão: Brasil, Índia, Myanmar, China, Estados Unidos e México, esses seis países juntos representam cerca de 61% produção mundial (CONAB, 2015).

Mesmo com uma grande produção, o Brasil não é um dos principais exportadores, tal fato ocorre devido à elevada demanda do alimento na alimentação cotidiana do brasileiro, visto que o alto consumo per capita, cerca de 17 kg ano⁻¹ (WANDER e CHAVES, 2011), retém quase todo o alimento dentro do mercado interno. Havendo em alguns casos, mesmo que pouco, a importação de feijão, limitando-se quase em seu total ao feijão preto (FERREIRA et al., 2002).

Tais fatos, deixa notório a elevada importância da cultura do feijão tanto para o consumo humano quanto para geração de renda ao pequeno, médio e grande agricultor. A agricultura contemporânea demanda estudos que vissem favorecer o cultivo dessa importante cultura bem como o aumento da eficiência durante o processo de colheita mecânica. A partir do momento que houver técnicas, bem como a inserção de tecnologias que possam auxiliar na produção, há grandes possibilidades de que o Brasil se torne referência no cultivo do feijão.

2.2. Colheita do Feijão

A operação de colheita do feijão se evidencia, principalmente, por encontrar como principal obstáculo o seu elevado custo (SOUZA et al., 2010). Além disso, a colheita do feijão é umas das etapas que merece especial atenção, pois quando feita de forma inadequada pode causar danos mecânicos às sementes, perdas de grãos comerciais e escurecimento do produto, interferindo assim de forma direta na qualidade e no valor final agregado ao produto (SOUZA et al., 2003).

A colheita do feijão pode acontecer por meio de três sistemas: manual, semimecanizado e mecanizado (SILVA et al. 1983). A colheita manual é um método secular e até hoje vem sendo utilizado no Brasil. Esse processo é efetuado todo manualmente e, cada vez mais, está sendo limitado a agricultores que tem como finalidade o cultivo de feijão como subsistência (SILVA et al., 2009). Todavia, essa prática tem como um dos principais gargalos o seu alto custo quando há, essencialmente, a escassez de mão de obra.

A colheita semimecanizada é aquela na qual arranca-se e enleira-se as plantas da cultura de forma manual e posteriormente faz o uso de uma máquina recolhadora-trilhadora (SILVA et al., 1983). Esse sistema de colheita ocorre com no mínimo de três operações, a primeira é quando os grãos se encontram com baixo teor de água e quase isentos de folhas, logo após formam-se leiras e o produto fica no campo para que haja naturalmente a secagem e homogeneização natural (CONTO et al., 1980). Por fim, utiliza-se trilhadoras estacionárias ou recolhedoras-trilhadoras para recolher e separar os grãos das plantas (SILVA et al., 1983).

O sistema de colheita mecanizada pode ser realizado por dois processos, direto ou indireto. No processo direto são utilizadas colhedoras combinadas que fazem todo o processo de corte, recolhimento, trilha e separação em uma única operação. A objeção quando ao uso desse sistema é a localização das vagens, que por sua vez podem estar localizadas muito próximas ao solo, ocasionando eventualmente dificuldade no alcance da lâmina de corte da colhedora. Outro empecilho é quanto ao teor de água do produto, que quando muito baixo pode causar debulha precoce no molinete, e quando demasiadamente alto pode não ocorrer a debulha das vagens. Ou seja, esses inconvenientes acabam causando várias perdas durante o processo de colheita inviabilizando por vezes o uso direto. Há no mercado equipamentos que foram desenvolvidos para suprir esses problemas, tais como: substituição do molinete de

barras por dentes metálicos inclinados, barra de corte flutuante que trabalha rente ao solo, entre outros (SILVA et al., 1983). Outra possível solução para tais inconvenientes seria melhorias na botânica da cultura, tais como, porte ereto, boa altura das vagens, maior resistência a deiscência das vagens, entre outros (SILVA et al., 2009). No processo indireto acontece as seguintes etapas, corte por meio de um ceifador enleirador (SILVA et al., 1983), a secagem e homogeneização do produto no campo, e posteriormente o recolhimento, trilha e separação do grão por meio de uma colhedora convencional ou uma recolhedora-trilhadora (SOUZA et al., 2006).

O emprego de máquinas no processo de colheita de feijão vem crescendo cada vez mais, e entre as suas vantagens pode-se ressaltar a diminuição de custos com mão de obra, principalmente onde a mesma tem elevado custo, possibilidade em produzir a cultura em larga escala e maior agilidade na colheita, diminuindo os riscos. No entanto, há problemas como perdas de colheita e danos mecânicos causados nos grãos pela máquina (COSTA e PASQUALETTO, 1999).

2.3. Eficiência na Colheita

O estudo da eficiência durante o processo de colheita é primordial para que seja possível aproveitar ao máximo os recursos e insumos aplicados na lavoura durante todo o ciclo da cultura. Isso visando garantir a rentabilidade ao produtor rural com o resgate ótimo dos grãos do campo.

Uma das principais formas de quantificar a eficiência durante a colheita é relacioná-la com as perdas ocorridas. Souza et al. (2006) apresentam como os principais fatores que podem influenciar diretamente nas perdas da colheita, a altura que está localizada as vagens, havendo a possibilidade de corte das mesmas durante a colheita, a umidade do grão que quando muito baixa, pode causar deiscência das vagens na plataforma e danos mecânicos no sistema de trilha, e quando altas, aumentam a possibilidade de embuchamento da colhedora, perdas pela não debulha das vagens e maior demanda de energia. Ou seja, tais aspectos estão diretamente ligados com a eficiência durante o processo de colheita do feijão.

Souza (2001) estudou as perdas que ocorrem em uma colhedora de fluxo axial para a colheita do feijão. O mesmo identifica que 49,30% das perdas totais ocorridas na colhedora estão na plataforma, para o sistema de trilha e separação 43,61% e limpeza 7,09%. Similarmente é possível relacionar as perdas com a eficiência, ou seja,

é possível pressupor que para plataforma, trilha e separação, e limpeza há uma eficiência de 50,70, 56,39 e 92,91% respectivamente em relação as perdas totais.

Ainda considerando estudos de Souza (2001), é possível afirmar que o local que engloba maior eficiência é o processo de limpeza, enquanto o processo de trilha e separação possuem menores eficiência entre os mecanismos interno da máquina. É necessário precauções com a eficiência do recolhimento da plataforma, ela possui maior ineficiência, e é responsável pelas maiores perdas na colheita do feijão proporcionalmente a perda total. As perdas totais são variáveis, ficando em função das somas das perdas na trilha e separação, plataforma e limpeza.

2.4. Redes Neurais Artificiais

Na área conhecida como sistemas inteligentes ou inteligência computacional estão inseridas as Redes Neurais Artificiais (RNA). Um dos grandes sonhos dos pesquisadores é a ideia de construir uma máquina ou mecanismo que possa agir de forma autônoma (SILVA et al., 2016), e com o advento tecnológico e maior capacidade de processamento de computadores, os estudos nessa área vêm crescendo cada dia mais, devido sua alta capacidade de resolver problemas complexos.

As RNA são modelos computacionais que se baseiam no sistema nervoso central dos seres vivos. Uma das maiores características de uma RNA é a capacidade de aprendizado, ela tem a habilidade de adquirir e reajustar o conhecimento com base em informações recebidas, isso acontece por meio de uma unidade de processamento (neurônios), interligados por um grande número de interconexões (sinapses artificiais), que são constituídas por vetores ou matrizes de pesos sinápticos que são ajustados ponderadamente, conforme a alimentação da RNA (SILVA et al., 2016).

SILVA et al. (2016) apresenta como as principais características de uma rede neural artificial a adaptação por experiência, capacidade de aprendizado, habilidade de generalização, organização de dados, tolerância a falhas, armazenamento distribuído e facilidade de prototipagem. Devido as essas características, as aplicações das RNA são vastas nas mais variadas áreas, tais como: agronomia, engenharias, biologia, geologia, entre outros (SOARES, 2011).

A arquitetura da rede é definida pela forma com que os neurônios estão interligados, isso é bastante variável ficando em função da complexidade do problema. Infelizmente não existe um método ou regra para definir a arquitetura de uma RNA, o

mais usual é testar várias redes e escolher a que mais se enquadra na solução do problema (SOARES, 2011).

2.4.1. Histórico

A origem do estudo sobre RNA começou há mais de 50 anos. O primeiro registro que há acerca de neurocomputação foi escrito por McCulloch & Pitts no ano de 1943. Nesse mesmo trabalho surgiu a primeira ideia de neurônio artificial, visto que os estudos realizados nele visavam criar um modelo matemático inspirado no neurônio biológico (SILVA et al., 2016). Segundo Soares (2011) tratava-se de um processo de decisão lógica (verdadeiro ou falso), onde o neurônio era ativado por uma unidade simples com uma função *Threshold* biestável (0 ou 1) ativada pela soma ponderada entre as entradas e saídas.

Em 1949 surgiu o primeiro modelo de treinamento para as RNA, o mesmo denominado de regra de aprendizado de Hebb, era baseado em observações de hipóteses neurofisiológicas. Um dos principais acontecimentos foi entre os anos de 1957 e 1958 por meio de Rosenblatt que desenvolveu o primeiro neurocomputador chamado de *Mark I – Perceptron*, derivando posteriormente a base do modelo *Perceptron* (SILVA et al., 2016).

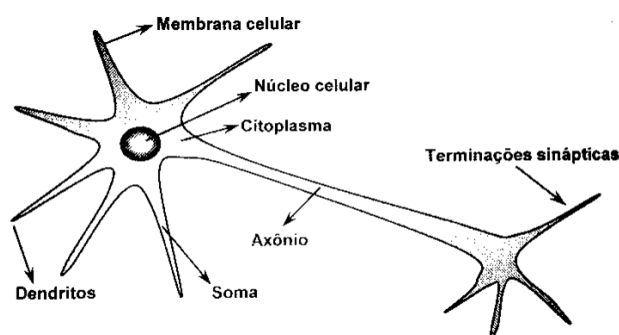
O *Perceptron* tinha como maior característica a sua capacidade de identificação de padrões, isso motivou a vários estudos e a criação de um tipo de rede denominado *Adaline (ADaptive LINear Element)*. Após esses primeiros passos surgiram inúmeros estudos e redes originadas dessas descobertas iniciais, foi a partir de 1980 que realmente houve as maiores descobertas, isso devido ao aumento do poder de processamento dos computadores, novas descobertas acerca do neurônio biológico. A maior motivação de todas foi a descoberta da regra delta generalizada popularmente conhecida como algoritmo *backpropagation*, isso possibilitou trabalhar modelos não lineares, antes mal executados pelas demais redes, e a criação da rede *Perceptron* de múltiplas camadas (PMC) que passou a abranger a solução dos mais variados tipos de problemas.

2.4.2. Neurônio Biológico

Composto por mais de 100 bilhões de neurônios, a rede neural biológica humana é executada com um processamento paralelo com objetivo de conduzir

informação. Esse processamento tem como finalidade desempenhar atividades essenciais para o ser humano, como pensar e memorizar. O elemento principal do cérebro são os neurônios e eles possuem a função de conduzir estímulos sob determinada circunstância. As principais partes que constituem um neurônio são: dendritos, corpo celular (ou soma) e Axônio (SILVA et al., 2016).

Os dendritos são prolongamentos muito finos que formam a árvore dendrital, o mesmo possui como objetivo capturar de forma contínua os diversos estímulos, oriundos dos demais neurônios (conectores) ou também de algum meio externo (neurônios sensitivos) (SILVA et al., 2016).



Fonte: Silva et al. (2016).


FIGURA 1. Neurônio biológico.

O corpo celular tem como objetivo processar todas as informações oriundas dos dendritos, isso com a finalidade de gerar um potencial de ativação que sinaliza ao neurônio se é possível disparar um impulso elétrico ao longo do axônio. No corpo celular se encontra também o núcleo, mitocôndria, centríolo, lisossomo, entre outros. Por fim o axônio é responsável por conduzir os impulsos elétricos ao longo de seu único prolongamento para os demais neurônios (SILVA et al., 2016).

2.4.3. Neurônio Artificial

O primeiro modelo de um neurônio artificial foi proposto por McCulloch & Pitts, sendo o mais simples e mais utilizado até hoje nas mais diversas arquiteturas (SILVA et al., 2016). O neurônio é fundamental na RNA, é ele que recebe uma ou mais entradas e associa a cada uma um peso sináptico, capaz de intensificar ou não cada valor de entrada e gerar uma única saída (SOARES, 2011).

A Figura 2 representa um neurônio artificial de uma única entrada, de acordo com Silva et al. (2016) é necessário fazer algumas ponderações quanto às funções de cada elemento que constitui o neurônio artificial, conforme a seguir:



Fonte: Adaptado de Hagan et al. (2014).

FIGURA 2. Neurônio artificial de uma única entrada.

Sinais de entrada (p): Os sinais de entradas são aquele oriundo do meio externo, eles representam as variáveis adotadas para solução de um determinado problema. Tais entradas são geralmente normalizadas, como o objetivo de aumentar a eficácia computacional do algoritmo de aprendizagem.

Pesos sinápticos (w): Cada entrada tem associada um peso ponderado, o mesmo é utilizado para quantificar a importância do respectivo valor de entrada para ser aplicado ao neurônio.

Combinador linear (Σ): O objetivo do combinador linear é unir todos os valores ponderados pelo sinal de entrada, isso acontece para que seja gerado um valor de potencial de ativação.

Limiar de ativação (b): Se trata de uma variável que determina qual o nível que o efeito gerado pelo combinador linear é adequado para que haja um disparo rumo ao neurônio.

Potencial de ativação (n): É a diferença entre o resultado do combinador linear e o limiar de ativação, se $n \geq b$ há a ativação do neurônio, se acontecer o contrário há a inibição.

Função de Ativação (f): Seu objetivo é restringir o neurônio em um conjunto de valores. As funções de ativação podem ser divididas em parcialmente diferenciáveis e totalmente diferenciáveis. Entre as parcialmente diferenciáveis estão as funções degrau, degrau bipolar (ou função sinal) e rampa simétrica. Enquanto as que fazem parte das totalmente diferenciáveis são as funções logística e tangente hiperbólica, ambas pertencentes a família das funções sigmoidais, e também as funções gaussiana e linear (SILVA et al., 2016).

Sinal de saída (*a*): São o conjunto de resultados gerados em relação aos sinais de entrada da rede, ou seja, é a resposta de cada neurônio após sua ativação.

Em outras palavras, o funcionamento de um neurônio artificial começa com a recepção de um conjunto de dados, o ajuste dos pesos sinápticos correspondente a cada entrada, o alcance de um potencial de ativação, e a união de cada saída utilizando a função de ativação em relação ao potencial de ativação (SILVA et al., 2016).

2.4.4. Treinamento

Como já citado, umas das grandes características das redes neurais artificiais é a capacidade de aprendizagem. Ela tem de certa forma a capacidade de imitar o ser humano e apreender com base em padrões. Uma RNA mapeia todos as entradas e saídas que são apresentadas a ela e com base nisso consegue fazer a generalização de soluções, ou seja, fundamentada no seu aprendizado, ela é capaz de responder a situação externa imposta a ela.

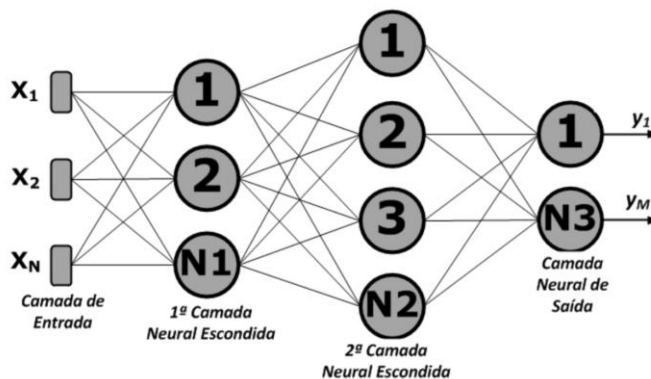
O treinamento é uma etapa que requer especial atenção, visto que é ele que vai definir a aprendizagem da rede. Os principais tipos de treinamento são os supervisionado e não-supervisionado.

O treinamento supervisionado consiste em ter como base uma entrada e uma saída desejada da rede, ou seja, um alvo. Nesse tipo de aprendizado é como se houvesse um “especialista” indicando para a rede quais as repostas desejadas com base nas entradas que ela recebe e saídas que ela fornece. Assim é necessário organizar os dados em uma tabela de atributos/valores. Conforme a rede recebe as informações os pesos sinápticos e limiares vão sendo ajustados, isso ocorre em função da comparação da saída da rede e os valores esperados. É preciso destacar que isso é feito pelo próprio algoritmo de aprendizagem (SILVA et al., 2016). Um dos algoritmos mais conhecidos e usados para esse tipo de treinamento é o algoritmo de retro propagação do erro ou *backpropagation* (LIMA, 1996).

No aprendizado não-supervisionado inexistente uma saída desejada ou alvo. Fica a critério da rede identificar a similaridade de um subconjunto (*clusters*). Os ajustes da rede são feitos com base na representação interna dela e o máximo de *clusters* pode ser especificado a fim de se obter *a priori* (SILVA et al., 2016).

2.4.5. Redes *Perceptron* Multicamadas (PMC)

A redes *Perceptron* Multicamadas (PMC) são as mais utilizadas atualmente. Esse fato é decorrente da sua demasiada aplicabilidade na resolução de vários tipos de problemas nas mais diversas áreas. A grande característica das redes PMC é a presença de no mínimo uma camada escondida, ou seja, essas redes possuem pelo menos duas camadas de neurônios (Figura 3) entre a entrada e saída (GOEDTEL et al., 2013).



Fonte: Goedtel et al. (2013).

FIGURA 3. Representação da rede *Perceptron* Multicamadas.

O advento da rede PMC começou após a descoberta do algoritmo *backpropagation*, que possibilita a aprendizagem dessas redes. Sua arquitetura pertence ao tipo *feedforward* de camadas múltiplas, no qual o aprendizado acontece de forma supervisionada por meio da regra delta generalizada, ou como conhecido popularmente, algoritmo *backpropagation*, como já citado (SILVA et al., 2016).

Observando a Figura 3 é possível entender o funcionamento da rede, a PMC trabalha da seguinte forma, recebe-se o sinal de entrada, ou seja, os valores atribuídos para a resolução do problema, eles passam pela primeira camada de neurônios onde há os ajustes dos pesos sinápticos e limiares, logo após os resultados da primeira camada de neurônios vão para a segunda camada escondida, e por fim o resultado da segunda camada escondida serão os valores apresentados como sinal de saída da rede. Acontece o mesmo processo para redes de n camadas, é necessário apenas salientar que todo o processo ocorrerá sempre da entrada em direção a saída da rede (SILVA et al., 2016).

A quantidade de camadas de uma rede PMC dependem especificadamente da complexibilidade do problema a ser revolvido. Devido à grande possibilidade de aplicações, tais como: aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos (GOEDTEL et al., 2013), otimização de sistemas

(SILVA et al., 2016), previsão de séries temporais (DANTAS et al., 2017), zoneamento ecológico-econômico (SADECK et al., 2017), etc. Esse tipo de rede é comumente utilizado, tornando-se a ferramenta para estudo desse trabalho.

2.5. Identidade de Modelo

Quando se deseja analisar o desempenho de dados obtidos por métodos alternativos comparados com dados padrões ou experimentais, geralmente faz-se o uso de métodos numéricos como o erro relativo (Er) e coeficiente de determinação (R^2), ou métodos estatísticos como os testes F e t.

Leite e Oliveira (2002) propuseram um método estatístico para testar a identidade de modelos, comparando um método padrão com um alternativo. O método proposto, que será denominado aqui por método L&O, é uma combinação do teste F modificado por Graybill (1976), do teste t aplicado ao erro médio, da análise do coeficiente de correlação linear e o acerto do modelo. O método mostra-se eficiente e não subjetivo, podendo ser usado para testar identidade de quaisquer dois vetores ou grupos de dados.

Para entender o método proposto, faça Y_1 e Y_j dois vetores de dados quantitativos obtidos de duas amostras, em que j denota o método alternativo (RNA) e 1 o padrão (experimental), normalmente distribuído com média zero e variância σ^2 , descritos por:

$$Y_1 = \begin{bmatrix} 1 & Y_{11} \\ 1 & Y_{12} \\ \vdots & \vdots \\ 1 & Y_{1n} \end{bmatrix} \quad Y_j = \begin{bmatrix} Y_{j1} \\ Y_{j2} \\ \vdots \\ Y_{jn} \end{bmatrix}$$

A correlação linear entre os dois vetores pode ser escrita na seguinte forma matricial:

$$Y_j = Y_1\beta + \varepsilon \quad (1)$$

sendo que,

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

Pela hipótese de normalidade, tem-se,

$$F(H_0) = \frac{(\beta - 0)'(Y_1'Y_1)(\beta - \theta)}{2QMR} \sim F_\alpha(2, n - 2) \quad (2)$$

onde,

$$\theta = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad Y_1'Y_1 = \begin{bmatrix} n & \sum Y_1 \\ \sum Y_1 & \sum Y_1^2 \end{bmatrix}$$

em que,

QMR - quadrado médio do resíduo da regressão;

F - teste F de Graybill;

H_0 - hipótese nula;

β - vetor de parâmetros;

ε - vetor de erros aleatórios;

θ - esperança matemática.

Assim, com $n - 2$ graus de liberdade e um nível de significância α , o método L&O pode ser utilizado para testar a seguinte hipótese: $H_0: \beta' = [0 \ 1]$. Se $F(H_0) \geq F_\alpha(2, n-2)$, a hipótese é rejeitada, enquanto se $F(H_0) < F_\alpha(2, n-2)$ a hipótese não é rejeitada.

O erro relativo médio é determinado pela Equação 3:

$$\bar{e} = \frac{\sum \left[\frac{Y_{ji} - Y_{li}}{Y_{li}} \right]}{n} \quad (3)$$

Considerando que os erros e_i apresentam distribuição normal, as hipóteses a serem testadas são: $H_0: \bar{e} = 0$, e a, H_a : não H_0 , utilizando para isso o teste t, dado por:

$$t_{\bar{e}} = \frac{\bar{e} - 0}{S_{\bar{e}}}$$

Sendo que, com $n-1$ graus de liberdade o desvio padrão médio da amostra é dado por:

$$S_{\bar{e}} = \frac{S_e}{\sqrt{n}} \quad (4)$$


Se $t_{\bar{e}} \geq t_{\alpha(n-1)}$, a hipótese H_0 é rejeitada, enquanto se $t_{\bar{e}} < t_{\alpha(n-1)}$, a diferença entre os dois métodos pode ser admitida ao acaso, ou seja, a hipótese H_0 não é rejeitada.

Leite e Oliveira (2002) para discutir suas últimas hipóteses, relembra que o denominador do teste F é 2QMR, e considerando que a alta correlação linear entre os

dois métodos resultaria em menor QMR. Consequentemente, o valor de $F(H_0)$ será muito alto e a possibilidade de rejeitar a hipótese H_0 também será alta. Isso leva a acreditar que quando os valores produzidos pelos dois métodos são muito semelhantes, indicando alta precisão de Y_1 em relação a Y_j , qualquer pequena diferença entre estimativas contendo estes dois vetores leva a rejeição de H_0 .

Além disso, é necessário quantificar o grau de associação entre o método padrão e o alternativo, o que pode ser realizado utilizando-se o coeficiente de correlação linear. Essa medida é considerada necessária porque somente o valor de β_1 e a informação que $\beta_1 \neq 1$ não quantifica o grau de associação entre os dois métodos. É possível encontrar pequeno valor de erro médio, $\beta_0 = 0$ e $\beta_1 = 1$ simultâneos, mas com baixo coeficiente de correlação entre os vetores Y_j e Y_1 .

Se a hipótese $H_0: \beta' = [0 \ 1]$ e $H_0: \bar{e} = 0$ não são rejeitadas, o caso pode ser observado na Figura 4a. Todavia, é possível que uma grande dispersão de Y_1 em relação a Y_j ainda aconteça, como pode ser observado na Figura 4g. Então, $H_0: \beta' = [0 \ 1]$ e $H_0: \bar{e} = 0$ não são rejeitadas, junto com a alta correlação entre Y_1 e Y_j , que permite concluir seguramente que os resultados obtidos com os dois métodos não são estatisticamente diferentes. Mas, a alta correlação é muito relativa (Figura 4). Para evitar essa subjetividade na definição da alta correlação, a estimada r_{Y_j, Y_1} deve ser comparada com $(1 - |\bar{e}|)$, desde que $H_0: \bar{e} = 0$ não tenha sido rejeitada.



Fonte: Leite e Oliveira (2002).

FIGURA 4. Algumas possíveis situações, quando dois métodos analíticos são comparados pela técnica de regressão linear simples.

Um resumo do procedimento estatístico até aqui discutido está apresentado no Quadro 1, mostrando as situações que podem ocorrer quando aplicado o método proposto. Pode-se observar que a significância do erro médio já indica que há diferença entre os dois métodos comparados. Por outro lado, quando o erro médio não é significativo, ele também é necessário para testar se o coeficiente de correlação linear é maior que $(1 - |\bar{e}|)$ e que o $F(H_0)$ não seja significativo. A situação 5 pode ser aceitável em alguns casos, principalmente quando o QMR é muito pequeno. Nesse caso, o valor de $F(H_0)$ tende a ser muito alto, resultando em significância. Isso ocorre quando os resultados dos dois métodos são muito próximos.

QUADRO 1. Regra de decisão para comparação de métodos analíticos para identidade de modelo

Situação	$F(H_0)$	$t\bar{e}$	r_{Y_j, Y_1}	Decisão
1	ns	ns	$r_{Y_j, Y_1} \geq (1 - \bar{e})$	$Y_j = Y_1$
2	ns	ns	$r_{Y_j, Y_1} \leq (1 - \bar{e})$	$Y_j \neq Y_1$
3	ns	*	$r_{Y_j, Y_1} \geq (1 - \bar{e})$	$Y_j \neq Y_1$
4	ns	*	$r_{Y_j, Y_1} \leq (1 - \bar{e})$	$Y_j \neq Y_1$
5	*	ns	$r_{Y_j, Y_1} \geq (1 - \bar{e})$	$Y_j \neq Y_1$
6	*	ns	$r_{Y_j, Y_1} \leq (1 - \bar{e})$	$Y_j \neq Y_1$
7	*	*	$r_{Y_j, Y_1} \geq (1 - \bar{e})$	$Y_j \neq Y_1$
8	*	*	$r_{Y_j, Y_1} \leq (1 - \bar{e})$	$Y_j \neq Y_1$

Fonte: Leite e Oliveira (2002).

3. MATERIAL E MÉTODOS

3.1. Local

A execução do trabalho aconteceu no Laboratório de Projetos de Máquinas da Faculdade de Ciências Agrárias da Universidade Federal da Grande Dourados, localizada no município de Dourados-MS.

3.2. Modelagem

O presente trabalho foi desenvolvido com base nos estudos realizado por Pishgar-Komleh et al. (2012), que analisou qual a melhor arquitetura de RNA para predição de perdas de colheita para cultura do milho, levando em consideração as velocidades do cilindro trilhador e da colhedora.

O processamento dos dados ocorreu por meio de uma rede *Perceptron* de Múltiplas Camadas (PMC) com arquitetura *feedforward* de camadas múltiplas, isso por se tratar de uma rede com grandes possibilidades de aplicação e por ter uma ampla versatilidade quanto ao seu uso (SILVA et al., 2016).

Na fase de aprendizado a rede utilizou 70% do conjunto de dados para aprendizado, cujo o treinamento ocorreu de forma supervisionada com algoritmo *backpropagation*, outros 15% dos dados foram usados para teste e 15% para validação numérica, que visa avaliar o desempenho da rede.

A fim de buscar uma arquitetura que possa representar adequadamente a eficiência durante a colheita, utilizou-se uma rede PMC com configuração $2-n_1-n_2-1$, com três variáveis no vetor de entrada (teor de água de colheita, rotação do cilindro trilhador de fluxo axial e taxa de alimentação da colhedora), n neurônios na primeira camada e na segunda camada oculta (n_1 e n_2), sendo a quantidade de neurônios variada, com o objetivo de encontrar a arquitetura com melhor desempenho, e um vetor na camada de saída (eficiência).

As funções de ativação adotadas foram a tangente hiperbólica e logística para primeira e segunda camada de neurônios respectivamente, e para camada de saída a função linear. As mesmas foram escolhidas por serem as mais recomendadas para a rede PMC e por apresentarem melhores resultados para a solução do problema estudado. Na Figura 5 está a representação da rede com a configuração adotada no trabalho.

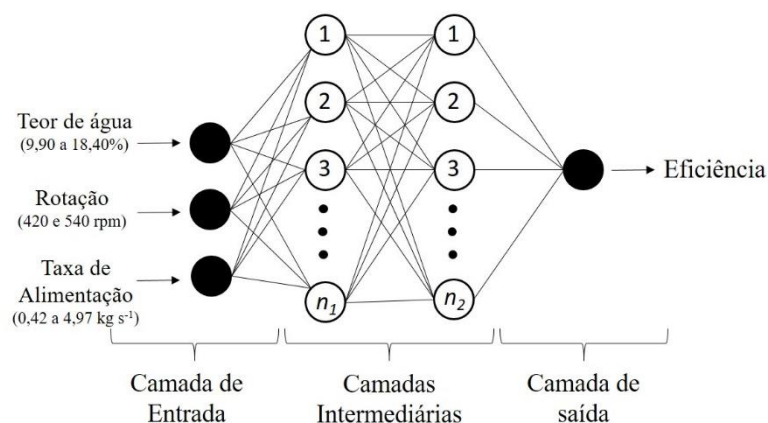


FIGURA 5. Representação da rede Perceptron de Múltiplas Camadas (PMC) com configuração (2- n_1 - n_2 -1).

Para escolher a RNA foi desenvolvido um algoritmo em *script*, que visava sortear automaticamente os dados para treinamento, teste e validação numérica, incrementar a quantidade de neurônios nas duas camadas ocultas, de um a 20 neurônios cada uma como recomendado na literatura e encontrado nos demais trabalhos científicos que utilizam redes PMC, treinar cada rede 15 vezes com os dados sorteados e por fim selecionar como a melhor RNA aquela que possuísse o menor erro quadrático médio. Para o desenvolvimento do *script*, foram utilizados os programas de computador Matlab versão 9, que possui um módulo específico de RNA (Toolbox Neural Network), e o MS Office Excel para organização os dados. O algoritmo implementado empregou como critérios de parada durante o processamento: a quantidade de iterações estabelecida como 1000, a performance da rede levando em consideração o menor Erro Quadrático Médio (EQM), o gradiente da função, e a quantidade de 1000 verificações de validação da rede

3.3. Experimento de Campo

Para treinar, testar e validar a rede foram utilizados dados de eficiência de colheita coletados por Souza (2001), que realizou um experimento de campo composto por variação dos teores de água dos grãos [9,9 a 18,4%], das taxas de alimentação da colhedora [0,4 a 4,97 kg s⁻¹] e velocidades do cilindro trilhador [420 e 540 rpm]. O experimento foi conduzido segundo delineamento inteiramente casualizado, com duas repetições, totalizando 72 dados observados. A abertura entre o cilindro e o côncavo da máquina usado durante o teste foi regulada em 20 mm. Nos ensaios, utilizou-se o feijão (*Phaseolus vulgaris* L.), cultivar Carioca, sendo a máquina avaliada uma colhedora-

trilhadora de arrasto modelo “Double Master”, com sistema de trilha em fluxo axial (rotor). A máxima capacidade de colheita da máquina foi de 6,56 t h⁻¹.

Para o vetor de entrada que realizou a alimentação da rede, foram adotados três fatores principais: a rotação do cilindro trilhador, o teor de água de colheita e a taxa de alimentação da colhedora. A escolha da taxa de alimentação (Equação 5) se deve pelo motivo dela representar melhor o efeito de três elementos envolvidos no processo de colheita, tais como, a largura equivalente ao número de linhas enleiradas, a produtividade do feijoeiro, além da velocidade de deslocamento da máquina.

$$T_x = \frac{L_c \cdot V \cdot P_d}{36000} \quad (5)$$

m que,

T_x - taxa de alimentação da máquina, kg s⁻¹;

L_c - largura equivalente da plataforma de recolhimento, m;

V - velocidade da recolhadora-trilhadora, km h⁻¹;

P_d - produtividade do feijoeiro, kg ha⁻¹.

3.4. Validação Estatística do Modelo de Predição

Com a finalidade de realizar a validação estatística dos modelos de redes neurais artificiais foram realizadas comparação com o objetivo de verificar a igualdade entre os dados experimentais e aqueles obtidos pela rede neural.

Submeteu-se os dados do trabalho ao teste estatístico proposto por Leite e Oliveira (2002). Tendo o procedimento estatístico derivado da metodologia descrita por Graybill (1976) para realizar o teste de F. O teste considera Y_j com um método alternativo e Y_1 como um método padrão. Onde a relação entre os dois é expressa matricialmente como $Y_j = Y_1\beta + \varepsilon$.

Para uma hipótese $H_0: \beta_0=0$ e $\beta_1=1$ foi aplicado o teste F, ao nível de 5% de probabilidade. Levando em consideração parâmetros como $F(H_0)$, erro médio ($t\bar{e}$) somados ao critério $r_{Y_jY_1} \geq (1 - |\bar{e}|)$, possibilitou analisar a validação do modelo. Assim, podendo confirmar como alternativa a modelagem com a RNA para a predição da eficiência no recolhimento da plataforma, na trilha e separação dos grãos, e na limpeza do produto, e da eficiência total da máquina durante a colheita do feijão.

4. RESULTADOS E DISCUSSÃO

De forma geral, evidencia-se que o uso das redes neurais artificiais se mostra como uma ferramenta viável para estudos de predição oriundos do meio agrícola, a fim de, gerar estudos e inovações para a agricultura moderna.

O tempo computacional médio gasto para o treinamento e seleção da rede neural artificial para cada eficiência, foi de aproximadamente 5 horas, usando um notebook com processador Intel Core i5-3337U, CPU de 1,80 GHz, com 6 GB de memória RAM e tamanho de máquina de 64 bits. O número de iterações foi variável para cada resolução dos modelos matemáticos, uma vez que em cada fase de aprendizagem da RNA, há uma nova adaptação dos pesos sinápticos.

4.1. Redes Neurais Artificiais Seleccionadas

Para a predição da eficiência de recolhimento da plataforma de uma recolhadora-trilhadora de feijão, obteve-se como melhor arquitetura uma rede neural com configuração 3-8-15-1, contendo 3 entradas (teor de água, rotação do cilindro trilhador e taxa de alimentação) 8 neurônios na primeira camada oculta, 15 neurônios na segunda camada oculta e uma saída (eficiência).

O erro quadrático médio ótimo (Best) entre os dados observados e preditos pela rede neural seleccionada o foi de 1,04. A quantidade de iterações (Epochs) necessárias para determinar o modelo matemático, foi de 23, sendo esse mesmo valor, o local onde o treinamento, teste e validação mais se aproximam do erro quadrático médio ótimo. Os dados do erro quadrático médio da rede podem ser observados na Figura 6.

A comparação entre os dados observados e aqueles obtidos com uso da rede neural artificial seleccionadas durante o treinamento, o teste e a sua validação podem ser analisados na Figura 7. O treinamento e a validação tiveram correlação linear superior a 0,86, enquanto no teste obteve-se 0,62. Assim, pode-se considerar que a rede neural seleccionada foi eficaz no processamento, com a validação correspondendo a 86% dos dados observados.

Na predição de eficiência de trilha e separação dos grãos, realizada pela recolhadora-trilhadora, obteve-se como melhor arquitetura uma rede com configuração 3-9-7-1, contendo 3 entradas (teor de água, rotação do cilindro trilhador e taxa de alimentação), 9 neurônios na primeira camada oculta, 7 neurônios na segunda camada oculta e uma saída (eficiência).




FIGURA 6. Erro quadrático médio (mse) obtidos no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência de recolhimento da plataforma.

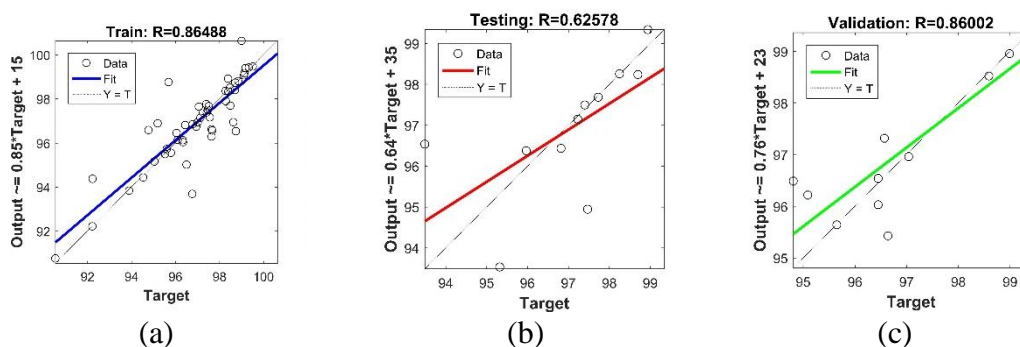


FIGURA 7. Desempenho da RNA na predição de eficiência de recolhimento da plataforma no treinamento (a), testes (b) e validação numérica (c).

O erro quadrático médio ótimo (Best), entre os dados observados e a RNA durante a predição da eficiência da separação, foi de 0,42. Para elaborar o modelo matemático, foram necessárias 74 iterações (Epochs) durante o processamento da rede, os valores obtidos podem ser analisados na Figura 8.

Quando analisados os valores observados em comparação com os calculados pela RNA, é possível notar um desempenho considerável, uma vez que os valores de correlação linear da validação e teste, estão acima de 86% e o de treinamento da rede é superior a 93%. Observando a Figura 9, é possível afirmar que a RNA teve desempenho superior as demais redes no seu processamento, pois a validação corresponde a 89% dos dados observados.




FIGURA 8. Erro quadrático médio (mse) obtido no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência da separação.

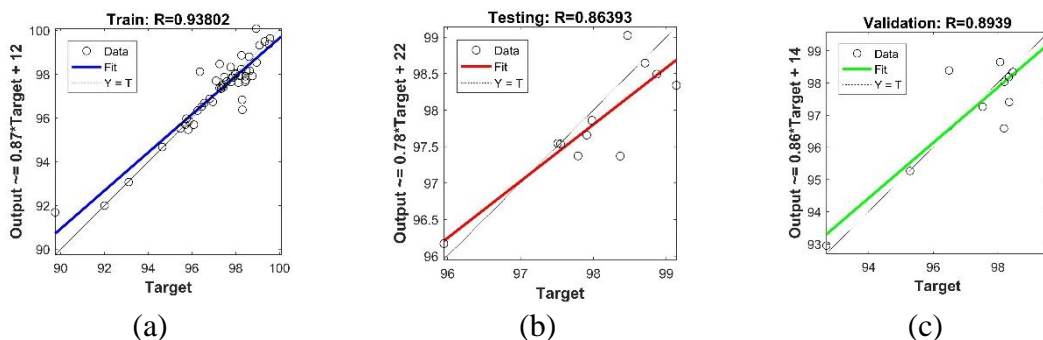


FIGURA 9. Desempenho da RNA na predição de eficiência de trilha e separação no treinamento (a), testes (b) e validação numérica (c).

Para a predição de eficiência da limpeza dos grãos durante a colheita do feijão, executada por uma recolhedora-trilhadora, obteve-se como melhor arquitetura uma rede com configuração 3-5-11-1, possuindo 3 entradas (teor de água, rotação do cilindro trilhador e taxa de alimentação), 5 neurônios na primeira camada oculta, 11 neurônios na segunda camada oculta e uma saída (eficiência).

O erro quadrático médio ótimo (Best), em comparação aos dados observados e os resultados oriundos da rede neural, foi de 0,02. Para a determinação do modelo matemático foram necessárias 35 iterações (Epochs), durante o processo de aprendizagem da rede. O desempenho no processamento, bem como, os valores calculados de erro quadrático médio da RNA, podem ser observados na Figura 10.

Assim como aconteceu com as redes selecionadas para a eficiência no recolhimento da plataforma e na separação dos grãos, a rede selecionada para prever a eficiência na limpeza, tem uma qualidade muito significativa, analisando os dados observados e os da RNA, nota-se uma correlação linear do treinamento e dos testes

acima de 83%. Entretanto, a validação obteve um coeficiente de correlação linear de 0,88, ou seja, 88% da validação corresponde aos dados observados (Figura 11).




FIGURA 10. Erro quadrático médio (mse) obtidos no treinamento (Train), validação (Validation) e teste (Test) da RNA para predição de eficiência da limpeza.

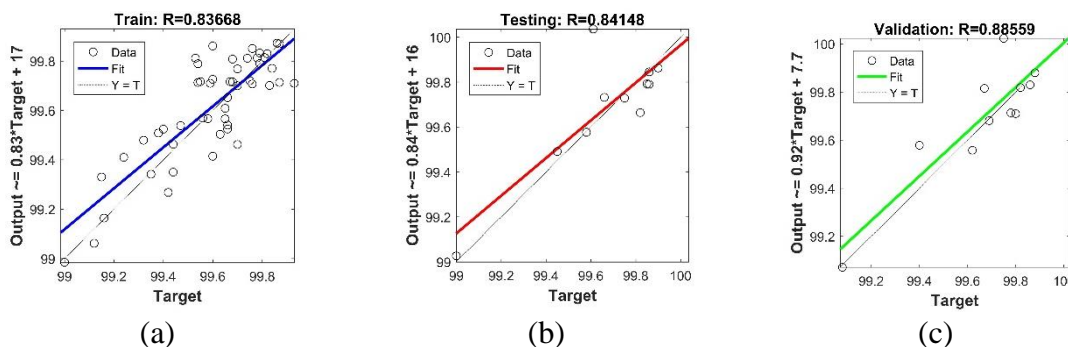


FIGURA 11. Desempenho da RNA na predição de eficiência da limpeza no treinamento (a), testes (b) e validação numérica (c).

A predição de eficiência total para a colheita do feijão com uma recolhedora-trilhadora, obteve como melhor arquitetura uma rede com configuração 3-15-10-1, contendo 3 entradas (teor de água, rotação do cilindro trilhador e taxa de alimentação), 15 neurônios na primeira camada oculta, 10 neurônios na segunda camada oculta e uma saída (eficiência).

O erro quadrático médio ótimo (Best) entre os valores observados e preditos, foi de 1,84. Foram necessárias 37 iterações (Epochs) para determinar o modelo matemático para prever a eficiência total. O desempenho da rede durante o processamento e os valores calculados, podem ser observados na Figura 12.

Analisando os parâmetros para a eficiência total (Figura 13), observa-se um leve declínio da correlação linear, havendo o treinamento com correlação superior a 88%, teste com valor superior a 76%, porém, com uma correlação menor, correspondente a um pouco mais que 60% para validação. Mesmo havendo uma

diminuição, considera-se a qualidade da RNA como significativa, uma vez que os valores apresentam baixo erro relativo médio, e ocorreu a validação da mesma pelo teste estatístico.




FIGURA 12. Erro quadrático médio (mse) dos dados usados no treinamento (Train), na validação (Validation) e no teste (Test) da RNA para predição de eficiência total.

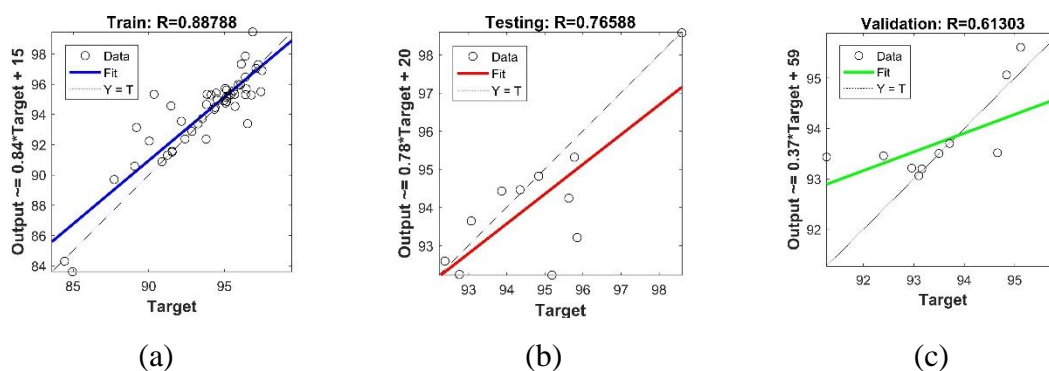


FIGURA 13. Desempenho da RNA na predição de eficiência total no treinamento (a), testes (b) e validação numérica (c).

4.2. Validação Estatística das Redes Neurais Selecionadas

No Quadro 2 está apresentada a análise de identidade de modelo entre os dados preditos pelas redes neurais e aqueles obtidos experimentalmente. Observa-se que os erros relativos médios foram inferiores a 1%, os coeficientes de determinações superiores a 70%, os erros médios foram considerados nulos pelo teste t e todas as redes neurais apresentaram maior correlação entre os dados de validação que o próprio acerto das RNA.

A rede neural selecionada para prever a eficiência total da colheita semimecanizada de feijão foi considerada igual estatisticamente aos dados observados por não apresentar significância pelo teste de Graybill e os demais parâmetros

analisados. Entretanto, as demais eficiências devem ser verificadas durante o processo de colheita para constatar a qualidade continua das predições da RNA. Entretanto, Leite e Oliveira (2002) relatam que pode ser aceitável em alguns casos, principalmente quando o quadrado médio do resíduo é muito pequeno. Nesse caso, o valor de $F(H_0)$ tende a ser muito alto, resultando em significância. Isso ocorre quando os resultados dos dois métodos são muito próximos. Dessa forma, pode-se considerar as redes obtidas para prever as eficiências do recolhimento da plataforma, da trilha e separação e da limpeza também como válidas.

Os resultados obtidos com a rede neural quando se analisou o erro relativo médio foi inferior ao conseguido por SOUZA et al. (2003), que modelaram matematicamente a eficiência de trilha e separação na colheita de feijão com erro relativo médio de 1,78%. Com esse valor de erro, o modelo de simulação implementado pode ser considerado válido por apresentar pequeno erro relativo médio na simulação da eficiência de trilha e separação mecânica do feijão.

QUADRO 2. Análise de identidade de modelo das RNA avaliadas pelo erro relativo médio (Er), coeficiente de determinação (R^2), teste F de Graybill ($F(H_0)$), teste t do erro médio (t_e) e a relação entre a correlação e o acerto da rede ($R > (1-e)$)

Eficiência	Er (%)	R^2	$F(H_0)$	t_e	$R > (1-e)$
Plataforma	0,63	0,70	8,73*	0,02 ns	Sim
Separação	0,42	0,86	31,59*	0,45 ns	Sim
Limpeza	0,09	0,72	51*	1,30 ns	Sim
Total	0,94	0,74	2,04 ns	0,98 ns	Sim

* Significativo a 5%, pelo teste F. ns - não significativo.

O coeficiente de determinação médio das redes neurais selecionadas foi de 0,76, valor esse equivalente ao coeficiente médio de SOUZA et al. (2001), que modelaram as perdas na colheita semimecanizada de feijão usando modelos lineares.

O coeficiente de determinação obtido para a eficiência de colheita na plataforma é inferior ao encontrado por Peyman et al. (2013), que modelou as perdas na plataforma de corte e encontrou coeficiente de determinação de 0,837.

Pishgar-Komleh et al. (2012) fez o uso de redes neurais artificiais para prever as perdas de colheita em relação a velocidade do cilindro trilhador e a velocidade de deslocamento da colhedora para a cultura do milho. Os autores validaram a rede por meio do maior coeficiente de determinação, que foi de 0,93, para uma arquitetura de rede com configuração 2-7-10-1, todavia com um erro relativo de

15,48%, enquanto os erros relativos apresentados para predição da eficiência da plataforma, limpeza, separação e total, foram abaixo de 1%.

Os gráficos de comparação entre as eficiências de recolhimento, de separação do rotor trilhador, de limpeza das peneiras e totais da máquina obtidas experimentalmente e aquelas previstas pela RNA estão apresentadas na Figura 14.

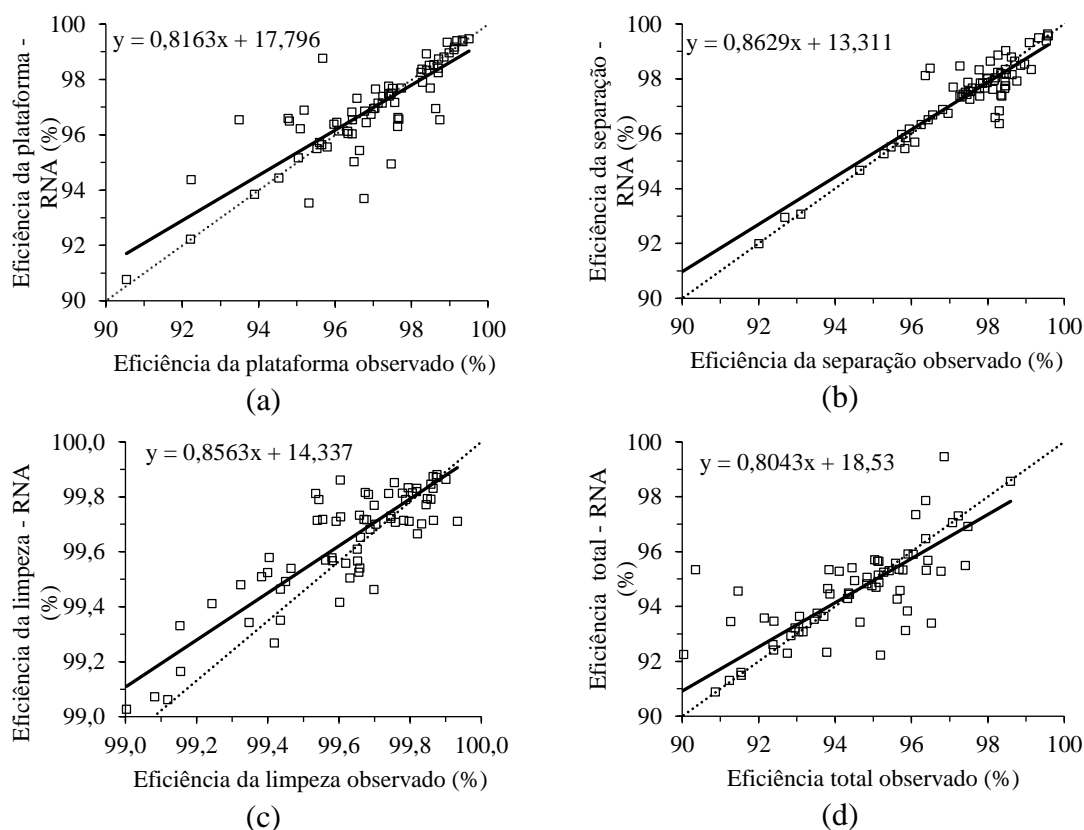


FIGURA 14. Comparação entre dados de eficiência de recolhimento (a), de separação (b), de limpeza (c) e total (d) obtidos experimentalmente e pela RNA.

Observa-se que houve tendência da rede selecionada para prever a eficiência de recolhimento (Figura 14a) de superestimar ligeiramente (0,64%) seus valores até 96,7% da eficiência experimental, enquanto a partir daí a tendência foi de subestimar (0,23%) os dados. Na predição da eficiência da trilha (Figura 14b) houve tendência de superestimar (0,52%) seus valores até 97,4% daquela observada, ao passar desse valor a tendência é de subestimar (0,20%). Verificou-se também uma tendência de superestimar (1,20%) a predição da eficiência total (Figura 14d) até 93,9%, sendo que a partir desse valor a rede neural é ligeiramente subestimada (0,32%). Enquanto na predição da eficiência na limpeza dos grãos (Figura 14c), foi onde se observou menor variação dos valores previstos pela RNA em relação aos valores da eficiência experimental, havendo uma tendência nula até 99,62%, enquanto a partir disso a tendência foi de superestimar ligeiramente (0,07%) os dados.

5. CONCLUSÕES

A metodologia adotada para selecionar e validar as redes neurais artificiais demonstrou-se eficaz para modelar as eficiências de recolhimento, da trilha e separação do cilindro trilhador de fluxo axial, da limpeza das peneiras com fluxo de ar e da operação total de colheita de feijão.

As RNA predizem as eficiências de colheita semimecanizada do feijão com acurácia e foram consideradas válidas, tendo todas elas apresentadas erros relativos médios inferiores a 1%, coeficiente de determinação superior a 0,70 e correlação linear superior ao acerto da RNA.

As arquiteturas selecionadas para prever as eficiências foram: 3-8-15-1 para plataforma de recolhimento, 3-9-7-1 para trilha e separação, 3-5-11-1 para limpeza e 3-15-10-1 para a total.

Os modelos de RNA podem ser fonte de estudo para demais trabalhos de predição de eficiência na colheita de feijão, bem como a avaliação de melhores teores de água, rotações do rotor trilhador e taxas de alimentação da colhedora, que possam vir a aumentar a eficiência e o controle da operação mecanizada.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- BORÉM, A.; CARNEIRO, J.E.S. A Cultura. In: VIEIRA, C.; PAULA JÚNIOR, T.J.; BORÉM, A. **Feijão: aspectos gerais e cultura no Estado de Minas Gerais**. Viçosa, MG: UFV, 1998. p.13-17.
- BORSARI, B.; CAVICHIOLI, F.A. A importância da agricultura familiar. In: Simpósio nacional de tecnologia em agronegócio (Sintagro), 9, 2017, Botucatu. **Anais...** Botucatu: IX Sintagro – Simpósio Nacional de Tecnologia em Agronegócio, junho de 2017.
- CONAB – Companhia Nacional de Abastecimento. (2010). **Conjuntura agropecuária do feijão**. Disponível em: < <http://www.agricultura.gov.br/assuntos/camaras-setoriais-tematicas/documentos/camaras-setoriais/feijao/anos-anteriores/consumo-de-feijao-no-brasil-15.pdf>>.
- CONAB – Companhia Nacional de Abastecimento. (2015). **Conjuntura agropecuária do feijão**. Disponível em: <http://www.conab.gov.br/OlalaCMS/uploads/arquivos/15_07_09_16_20_14_conjuntura_agropecuaria_do_feijao_-_junho_2015.pdf>.
- CONTO A.J.; VIEIRA, E.H.N.; OLIVEIRA, E.T.; CASTRO, T.A.P. **Aspectos técnicos e econômicos da colheita mecânica e manual do feijão (*Phaseolus vulgaris* L.)**. Goiânia: EMBRAPA Arroz e Feijão, agosto 1980, 14 p., (Circular Técnica nº 02).
- COSTA, L.R.M.; PASQUALETTO, A. Comparação de sistemas de colheita mecanizada e semimecanizada na perda, dano mecânico e impureza de grãos na cultura do feijoeiro (*Phaseolus vulgaris* L.). **Pesquisa Agropecuária Tropical**, v. 29, n. 1, p. 35-38, 1999.
- DANTAS, D.; LUZ, T.M.O.; SOUZA, M.J.H.; BARBOSA, G.P.; CUNHA, E.G.S. Uso de redes neurais artificiais na previsão da precipitação de períodos chuvosos. **Revista Espinhaço**, v.5, n.1, p.11-18, 2017.
- FAUSETT, L. **Fundamentals of neural networks: Architectures, algorithms and applications**. 1 ed. Prentice-Hall, 1994. 461p.
- FERNANDES JÚNIOR, F.D.; LOPES, J.S.B.; MAITELLI, A.L; ARAÚJO, F.M.U.; OLIVEIRA, L.A.H.G. Implementação de controladores PID utilizando lógica fuzzy e instrumentação industrial. 2005. **Anais...** In: Simpósio Brasileiro de Automação Inteligente, 7, São Luís, 2005, 7p.
- FERREIRA, C.M.; PELOSO, M.J.D.; FARIA, L.C. **Feijão na economia nacional**. Santo Antônio de Goiás: EMBRAPA Arroz e Feijão, agosto 2002, 47 p., (Documentos 135).
- GOEDEL, A.; SILVA, I.N.; SERNI, P.J.A.; SUETAKE, M.; NASCIMENTO, C.F.; SILVA, S.A.O. Speed estimation for induction motor using neural networks method. **IEEE Latin America Transactions**, v.11, n.2, p.768-778, 2013.
- GRAYBILL, F.A. **Theory and application of the linear model**. Belmont: Duxbury Press, 1976. 704p.
- HAGAN, M.T.; DEMUTH, H.B.; BEALE, M.H.; JESÚS, O. **Neural Network Design**. 2 ed., Oklahoma: Martin Hagan, 2014. 800 p.
- IBGE – Instituto Brasileiro de Geografia e Estatística. **Levantamento sistemático da produção agrícola**. Rio de Janeiro: v.30, n.1, p.1-81, janeiro, 2017.

LEITE, H.G.; OLIVEIRA, F.H.T. Statistical Procedure to Test the Identity of Analytical Methods. **Communications in Soil Science Plant Analysis**, v.33, n.7/8, p.1105-1118, 2002.

LIMA, W.S. **Previsão de carga no período de demanda de ponta utilizando redes neurais artificiais**. 1996. 140p. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de Campinas – UNICAMP, Campinas.

MANOS, M.G.L; OLIVEIRA, M.G.C; MARTINS, C.R. **Informações Técnicas para o Cultivo do Feijoeiro Comum na Região Nordeste Brasileira 2013-2014**. Aracaju: EMBRAPA Tabuleiros, dezembro 2013, 184 p., (Documentos 181).

PEYMAN, L.; MAHMOUDI, A.; JALALI, A. Artificial neural network modeling (ANNs) for combine harvester header losses. **International Journal of Agriculture and Crop Sciences**, v. 5, n.5, p. 553-558, 2013.

PICOLI, M.C.A. **Estimativa da produtividade agrícola da cana-de-açúcar utilizando agregados de redes neurais artificiais: Estudo de caso Usina Catanduva**. 2016. 90p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos.

PISHGAR-KOMLEH, S.H.; KEYHANI, A.; MOSTOFI-SARKARI, M. R.; JAFARI, A. Predicting the relationship between grain-combine travel, cylinder speed and harvesting losses by applying artificial neural networks. **International Journal of Applied Sciences and Engineering Research**, v.1, n.3, p. 405-414, 2012.

SADECK, L.W.R.; LIMA, A.M.M.; ADAMI, M. Artificial neural network for ecological-economic zoning as a tool for spatial planning. **Pesquisa Agropecuária Brasileira**, v.52, n.11, p.1050-1062, 2017.

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes neurais artificiais para engenharia e ciências aplicadas: Fundamentos teóricos e aspectos práticos**. 2. ed. São Paulo: Artliber, 2016. 431p.

SILVA, J.G.; AIDAR, H.; KLUTHCOUSKI, J. Colheita direta de feijão com colhedora automotriz axial. **Pesquisa Agropecuária Tropical**. v. 39, n. 4, p. 371-379, 2009.

SILVA, J.G.; FONSECA, J.R.; CONTO, A.J.A colheita mecanizada do feijão no Brasil. **Informativo agropecuário**, v.9, n.103, p.40-42, 1983.

SILVA, S.H.M.G.; CARVALHO, A.C.P.L.F.; ROMERO, R.A.F.; CRUVINEL, P.E.; NATALE, W. Redes neurais artificiais e agricultura de precisão para recomendação de adubação da cultura da goiabeira. **Revista Brasileira de Agrocomputação**, v.2, n.1, p. 37-42, 2004.

SOARES, J.D.R. **Modelagem matemática na previsão de colheita de bananeira: regressão linear múltipla x redes neurais artificiais**. 2011. 115p. Tese (Doutorado em Produção Vegetal) – Universidade Federal de Lavras – UFLA, Lavras.

SOUZA, C.M.A. **Avaliação e simulação de desempenho de uma colhedora de fluxo axial para feijão**. 2001. 113p. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa - UFV, Viçosa.

SOUZA, C.M.A.; BOTTEGA, E.L.; VILELA, F.V.; RAFULL, L.Z.L.; QUEIROZ, D.M. Espacialização de perdas e da qualidade do feijão em colheita semimecanizada. **Acta Scientiarum. Agronomy**. v. 32, n. 2, p. 201-208, 2010.

SOUZA, C.M.A.; QUEIROZ, D. M.; CECOM, P.R.; MANTOVANI, E.C. Avaliação de perdas em uma colhedora de fluxo axial para feijão. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 5, n.3, p. 530-537, 2001.

SOUZA, C.M.A.; QUEIROZ, D.M.; PINTO, F.A.C.; DIAS, G.P. Modelo de simulação do processo de trilha e separação mecânica em uma recolhadora-trilhadora de fluxo axial para feijão. **Engenharia Agrícola**, Jaboticabal, v. 23, n.1, p. 96-105, 2003.

SOUZA, C.M.A.; QUEIROZ, D.M.; PINTO, F.A.C. Colheita de Feijão. In: VIEIRA, C.; PAULA JÚNIOR, T.J.; BORÉM, A. **Feijão**. 2ed. Viçosa: Editora UFV, 2006, v. 1, p. 529-571.

WANDER, A.E.; CHAVES, M.O. Consumo per capita de feijão no Brasil de 1998 a 2010: uma comparação entre consumo aparente e consumo domiciliar. In: CONGRESSO NACIONAL DE PESQUISA DE FEIJÃO, 10., 2011, Goiânia. **Anais...** Goiânia: EMBRAPA Arroz e Feijão, 2011. 1 CD-ROM.