

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS COMPUTACIONAIS
PARA O AGRONEGÓCIO

LEONARDO GOMES GUIDOLIN

**DIAGNÓSTICO DE NÍVEIS DE NITROGÊNIO EM FOLHAS DE FEIJÃO
UTILIZANDO VISÃO COMPUTACIONAL E REDES NEURAIS
ARTIFICIAIS**

DISSERTAÇÃO

Medianeira - PR

2018

LEONARDO GOMES GUIDOLIN

**DIAGNÓSTICO DE NÍVEIS DE NITROGÊNIO EM FOLHAS DE FEIJÃO
UTILIZANDO VISÃO COMPUTACIONAL E REDES NEURAIS
ARTIFICIAIS**

TRABALHO DE DISSERTAÇÃO

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio – PPGTCA – da Universidade Tecnológica Federal do Paraná – UTFPR – Campus Medianeira, como requisito parcial para obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio / Área de Concentração: Tecnologias Computacionais Aplicadas à Produção Agrícola e Agroindústria.

Orientador: Prof. Dr. Augusto Vaghetti Luchese

Co-Orientador: Prof. Dr. Pedro Luiz de Paula Filho

Medianeira - PR

2018

Dados Internacionais de Catalogação na Publicação

G948d

Guidolin, Leonardo Gomes

Diagnóstico de níveis de nitrogênio em folhas de feijão utilizando visão computacional e redes neurais artificiais / Leonardo Gomes Guidolin - 2018

52 f. : il. ; 30 cm.

Orientador: Augusto Vaghetti Luchese.

Coorientador: Pedro Luiz de Paula Filho.

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio. Medianeira, 2018.

Inclui bibliografias.

1. Redes neurais (Computação). 2. Linguagem de programação (Computadores). 3. Feijão-comum. 4. Tecnologias Computacionais - Dissertações. I. Luchese, Augusto Vaghetti, orient. II. Paula Filho, Pedro Luiz de, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio. IV. Título.

CDD: 004

Biblioteca Câmpus Medianeira
Marci Lucia Nicodem Fischborn 9/1219



TERMO DE APROVAÇÃO

DIAGNÓSTICO DE NÍVEIS DE NITROGÊNIO EM FOLHAS DE FEIJÃO UTILIZANDO VISÃO COMPUTACIONAL E REDES NEURAIS ARTIFICIAIS

Por

LEONARDO GOMES GUIDOLIN

Essa dissertação foi apresentada às oito horas, do dia seis de junho de dois mil e dezoito, como requisito parcial para a obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio, Linha de Pesquisa Tecnologias Computacionais Aplicadas à Produção Agrícola, no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio - PPGTCA, da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Prof. Dr. Augusto Vaghetti Luchese (Orientador – PPGTCA)

Prof. Dr. Paulo Lopes de Menezes (Membro Interno – PPGTCA)

Prof. Dr. Mauricio Guy de Andrade (Membro Externo – UFPR)

A via original com as assinaturas encontra-se na secretaria do programa.

AGRADECIMENTOS

A todos os professores do mestrado, meu Orientador e Co-Orientador que auxiliaram e aconselharam na execução do trabalho. Aos meus amigos pela motivação. A minha família pela base que me proporcionou, principalmente meu pai Osmar e minha mãe Cleuza.

"Qualquer tecnologia suficientemente avançada é indistinta de magia"

Arthur C. Clarke.

RESUMO

GUIDOLIN, Leonardo Gomes. **Diagóstico de Níveis de Nitrogênio em Folhas de Feijão utilizando Visão Computacional e Redes Neurais Artificiais**. 2018. Trabalho de Dissertação (Mestrado em Tecnologias Computacionais para o Agronegócio) - Universidade Tecnológica Federal do Paraná, Medianeira, 2018.

A nutrição de nitrogênio na cultura do feijão é importante para garantir uma boa produtividade, porém as formas de detecção desses níveis (análise química e visual) são lentas ou dependem de um profissional experiente, portanto o objetivo deste trabalho consiste diagnosticar os níveis de nitrogênio através de Visão Computacional e Redes Neurais Artificiais (RNA). Foram cultivados feijoeiros em uma casa de vegetação contendo 5 doses diferentes de nitrogênio, 50, 100, 150, 200 e 250 mg L⁻¹. Os dados coletados das plantas foram teores de clorofila por meio de clorofilômetro, teores de nitrogênio em mg L⁻¹ e imagens das folhas, sendo estas realizadas em dois momentos do desenvolvimento da planta 45 e 58 dias após a semeadura, para se realizar o diagnóstico utilizou-se três métodos de extração de características nas imagens das folhas: Grey Level Cooccurrence Matrix (GLCM), Estatístico sem texturização e Local Binary Pattern (LBP). Por fim os dados gerados pelos métodos anteriores foram utilizados para o treinamento e teste de Redes Neurais Artificiais (RNA) Multilayer Perceptron para regressão e posteriormente classificação dos níveis de nitrogênio. Este trabalho demonstrou que os três métodos são promissores dependendo da situação, porém a combinação dos três métodos juntamente com uma seleção de atributos obtém-se resultados melhores na diagnose de nitrogênio.

Palavras-chave: GLCM; LBP; Phaseolus vulgaris; Reconhecimento de padrões; Redes Neurais Artificiais.

ABSTRACT

GUIDOLIN, Leonardo Gomes. **Diagnosis of Nitrogen levels in Bean Leaves Using Computational Vision and Artificial Neural Network**. 2018. Dissertation Work (Masters in Computational Technologies for Agribusiness) - Federal Technological University of Paraná, Medianeira, 2018.

Nitrogen nutrition in the bean crop is important to ensure good productivity, however the ways of detecting these levels (chemical and visual analysis) are slow or depend on an experienced professional, so the objective of this work is to diagnose nitrogen levels through of Computational Vision and Artificial Neural Networks (RNA). Beans were grown in a greenhouse containing 5 different doses of nitrogen, 50, 100, 150, 200 and 250 mg L⁻¹. The data collected from the plants were chlorophyll content by means of chlorophyll meter, nitrogen contents in mg L⁻¹ and leaves images, being these realized in two moments of the development of the plant 45 and 58 days after sowing, to make the diagnosis Gray Level Co-Occurrence Matrix (GLCM), non-texturing Statistic and Local Binary Pattern (LBP) were used. Finally, the data generated by the previous methods were used for the training and testing of Artificial Neural Networks (ANN) Multilayer Perceptron for regression and later classification of the levels of nitrogen. This work demonstrated that the three methods are promising depending on the situation, but the combination of the three methods together with a selection of attributes gives better results in the diagnosis of nitrogen.

Key-words: GLCM; LBP; Phaseolus vulgaris; Pattern Recognition; Artificial neural networks.

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 - Padrão utilizado na nomeação das imagens coletadas..... | 28 |
| Tabela 2 - Dados da Análise química de N e médias de clorofila realizado para as folhas dos feijoeiros da coleta 1 | 32 |
| Tabela 3 - Dados da Análise química de N e médias de clorofila realizado para as folhas dos feijoeiros da coleta 2 | 33 |
| Tabela 4 - Correlações entre os dados coletados das coletas 1 e 2 | 34 |
| Tabela 5 - Correlação dos atributos extraídos das imagens de folha com os dados da análise química de N..... | 35 |
| Tabela 6 - Correlação os método de extração de característica Estatístico sem texturização utilizando Redes Neurais Artificiais | 36 |
| Tabela 7 - Correlação dos atributos extraídos das imagens de folha com os dados da análise química de N..... | 37 |
| Tabela 8 - Correlação dos métodos de extração de característica GLCM utilizando Redes Neurais Artificiais | 39 |
| Tabela 9 - Correlação dos atributos LBP extraídos das imagens de folha com os dados da análise química de N | 41 |
| Tabela 10 - Correlação os método de extração de característica LBP utilizando Redes Neurais Artificiais | 41 |
| Tabela 11 - Correlação dos métodos de extração de característica, GLCM, LBP e Estatístico sem texturização na Rede Neural artificial..... | 43 |
| Tabela 12 - Dados da Análise química de N e médias de clorofila realizado para as folhas dos feijoeiros da coleta 1 e 2 | 44 |
| Tabela 13 - Classificação em 3 classes da análise química utilizando os três métodos de extração de características..... | 45 |
| Tabela 14 - Matriz de confusão da RNA utilizando o GLCM, LBP e Estatístico sem Texturização com 3 classes com seleção de atributos..... | 46 |

LISTA DE SIGLAS

| | |
|------|---------------------------------|
| AQ | Análise Química |
| CA | Clorofila A |
| CB | Clorofila B |
| CT | Clorofila Total |
| GLCM | Gray Level Co-Occurrence Matrix |
| LBP | Local Binary Pattern |
| MLL | Machine Learning Library |
| N | Nitrogênio |
| RGB | Red Green Blue |
| RNA | Redes Neurais Artificiais |

SUMÁRIO

| | |
|--|-----------|
| 1 INTRODUÇÃO | 14 |
| 2 OBJETIVOS | 16 |
| 2.1 OBJETIVO GERAL | 16 |
| 2.2 OBJETIVOS ESPECÍFICOS | 16 |
| 3 REVISÃO DE LITERATURA | 17 |
| 3.1 CULTURA DO FEIJÃO..... | 17 |
| 3.1.1 Importância da Cultura do Feijão no Brasil..... | 17 |
| 3.1.2 Adubação Nitrogenada na Cultura do Feijão..... | 18 |
| 3.1.3 Diagnose Nutricional Visual na Cultura do Feijão..... | 18 |
| 3.1.4 Níveis de clorofila na folha do feijão | 19 |
| 3.2 AVALIAÇÃO COMPUTACIONAL DE IMAGENS..... | 20 |
| 3.2.1 Processamento Digital de Imagens | 20 |
| 3.2.2 Avaliação de Teores de Nitrogênio e Clorofila em Folhas de Feijão por meio de Processamento Digital de Imagens | 21 |
| 3.2.3 Gray Level Co-occurrence Matrix (GLCM) | 22 |
| 3.2.4 Local Binary Pattern (LBP) | 22 |
| 3.2.5 Redes Neurais Artificiais (RNA)..... | 23 |
| 4 MATERIAIS E MÉTODOS | 26 |
| 3.1 PREPARAÇÃO DO EXPERIMENTO | 26 |
| 3.2 COLETA DOS DADOS..... | 27 |
| 4.3 AQUISIÇÃO DE IMAGENS | 28 |
| 4.4 PRÉ-PROCESSAMENTO | 29 |
| 4.5 EXTRAÇÃO DE CARACTERÍSTICAS | 29 |
| 3.6 USO DE REGRESSÃO PARA AVALIAÇÃO DO DIAGNÓSTICO DE NITROGÊNIO | 30 |
| 3.7 AMBIENTE DE DESENVOLVIMENTO | 31 |
| 3.7.1 Biblioteca OpenCV | 31 |
| 3.8 FLUXO GERAL DO SISTEMA PARA DIAGNÓSTICO DE NITROGÊNIO | 31 |
| 5 RESULTADOS E DISCUSSÃO | 33 |
| 4.1 EXTRAÇÃO DE CARACTERÍSTICAS ESTATÍSTICAS SEM TEXTURIZAÇÃO DAS IMAGENS DE FOLHAS DE FEIJÃO | 36 |
| 4.2 EXTRAÇÃO DE CARACTERÍSTICAS DAS IMAGENS DE FOLHAS DE FEIJÃO UTILIZANDO <i>GRAY LEVEL CO-OCCURRENCE MATRIX</i> (GLCM) | 38 |
| 4.3 EXTRAÇÃO DE CARACTERÍSTICAS DAS IMAGENS DE FOLHAS DE FEIJÃO UTILIZANDO <i>LOCAL BINARY PATTERN</i> (LBP) | 41 |
| 4.4 CORRELAÇÃO UTILIZANDO OS TRÊS MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS..... | 43 |
| 4.5 CATEGORIZAÇÃO DA ANÁLISE QUÍMICA UTILIZANDO OS TRÊS MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS E REDES NEURAIS ARTIFICIAIS | 44 |
| 6 CONCLUSÃO | 49 |
| REFERÊNCIAS | 50 |

1 INTRODUÇÃO

O feijão (*Phaseolus vulgaris L.*) é um dos ingredientes mais importantes da dieta do brasileiro, principalmente por ser uma grande fonte de proteínas, carboidratos e ferro. O feijoeiro comum possui muita importância econômica e social, pois é cultivado tanto por grandes quanto por pequenos produtores, em diversificados sistemas de produção e em todas as regiões brasileiras (PENA, 2015).

Uma das principais causas da baixa produtividade da cultura do feijão no Brasil deve-se ao baixo nível técnico empregado pelos produtores e o cultivo de baixa fertilidade, principalmente pobres em Nitrogênio (N). As principais fontes de N para a cultura do feijoeiro são o solo, por meio da decomposição da matéria orgânica, a aplicação de adubos nitrogenados e a fixação biológica de N₂ atmosférico, pela associação do feijoeiro com bactérias do grupo dos rizóbios. Porém, além do alto custo econômico, o uso de adubos nitrogenados em solos tropicais tem ainda um custo ecológico, através das perdas desses adubos ocasionadas principalmente por lixiviação, na forma de nitrato e escoamento superficial, provocado pela água das chuvas ou irrigação. Desta forma o N perdido nesse processo é bastante poluente e, uma vez carregado para o lençol freático, provoca a contaminação dos aquíferos, rios e lagos. Nesse contexto, o manejo adequado da adubação nitrogenada representa uma das principais dificuldades da cultura do feijoeiro, visto que a aplicação de doses excessivas de N, além de aumentar o custo econômico, pode promover sérios riscos ao ambiente, e a sua utilização em quantidade insuficiente diminuir a sua produtividade (PELEGRIN et al., 2009).

Uma maneira prática e rápida de determinar a deficiência de nitrogênio na planta é por meio do diagnóstico visual que consiste em se comparar visualmente o aspecto da amostra com o padrão, ou seja, comparar a coloração, tamanho e forma com o formato padrão da planta. Na maioria das vezes o órgão de comparação é a folha, pois é o que melhor reflete o estado nutricional da planta. Porém, a sua precisão está limitada à experiência do técnico e, também, exige bastante trabalho para gerar um mapa de prescrição para ser utilizado no manejo localizado (BEASSO et al., 2007; FANQUIN, 2002).

Uma forma de automatizar esse processo pode ser através do uso técnicas de processamento digital de imagens, pois apresentam grande potencial para a obtenção de características que expressem a cor verde da planta (KARCHER, 2003).

2 OBJETIVOS

Nesta seção serão apresentados os objetivos gerais e específicos.

2.1 OBJETIVO GERAL

Desenvolver uma metodologia para diagnóstico dos níveis de nitrogênio na folha do feijão, utilizando técnicas de visão computacional e Redes Neurais Artificiais.

2.2 OBJETIVOS ESPECÍFICOS

- a) Estudar técnicas e métodos da detecção visual dos níveis de nitrogênio na folha do feijão;
- b) Aplicar técnicas de visão computacional para fazer a detecção automática dos níveis de nitrogênio;
- c) Realizar testes e avaliações nas técnicas aplicadas;

3 REVISÃO DE LITERATURA

3.1 CULTURA DO FEIJÃO

Nas seções a seguir serão apresentados conceitos sobre a cultura do feijão, como importância da cultura do feijão no Brasil, adubação nitrogenada, diagnose nutricional e níveis de clorofila na folha do feijão.

3.1.1 Importância da Cultura do Feijão no Brasil

O feijão é um dos alimentos mais importantes da dieta dos brasileiros, constituindo a sua principal fonte de proteína vegetal, no qual seu teor proteico pode chegar a 33% com valor energético de 341 cal/100g (SILVA, 2013).

O feijoeiro-comum é considerado uma cultura fora do comum por possuir três safras anuais:

- Safra das águas: plantada nas Regiões Sul, Sudeste, Centro-Oeste, sendo cultivado entre os meses de agosto a novembro;
- Safra da seca: ocorre nas Regiões Sul, Sudeste, Centro-Oeste e em único período de plantio no Norte, onde o feijão-comum é consorciado com o milho. Essa safra é realizada entre os meses de dezembro a abril.
- Safra irrigada: é plantado no Centro-Sul e ocorre entre os meses de abril a julho (AZEVEDO et al.,2008).

A produção do feijão é feita por vários tipos de produtores, e várias regiões do país, utilizando diferentes níveis tecnológicos. Dentre estes produtores, a agricultura familiar é apontada como a grande responsável pela produção desta cultura no Brasil (SILVA, 2013).

Devido a importância da cultura do feijão para o Brasil, uma adubação adequada desta cultura é importante para garantir uma boa produtividade.

3.1.2 Adubação Nitrogenada na Cultura do Feijão

Solos de baixa fertilidade, principalmente pobres em N, resultam em baixa produtividade da cultura do feijoeiro no Brasil. Por ser o N o elemento mais absorvido pelo feijoeiro, a sua carência implica na baixa produtividade de grãos. A maximização do uso de N pelo feijoeiro, por meio de técnicas eficientes de manejo, é importante devido a aspectos econômicos e ambientais pois este nutriente apresenta risco ao ambiente por ser potencialmente contaminante de lençóis freáticos, pois em doses excessivas existe o risco ambiental, e em doses insuficiente pode limitar o potencial produtivo (PELEGRIN, 2009; SANT'ANA, 2010).

Para tanto é necessário que ocorra o diagnóstico preciso de N para garantir uma adubação adequada.

3.1.3 Diagnose Nutricional Visual na Cultura do Feijão

A diagnose visual consiste em se comparar visualmente o aspecto da amostra com o padrão, ou seja, comparar a coloração, tamanho e forma com o formato padrão da planta. Na maioria das vezes o órgão de comparação é a folha, pois é o que melhor reflete o estado nutricional da planta. Como nas folhas ocorrem os principais processos metabólicos do vegetal, as mesmas são os órgãos da planta mais sensíveis às variações nutricionais. Se houver falta ou excesso de um nutriente, isto se manifestará em sintomas visíveis, os quais são típicos para um determinado elemento. O motivo pelo qual o sintoma é típico do elemento, deve-se ao fato de que um dado nutriente exerce sempre as mesmas funções em qualquer espécie de planta (FANQUIN, 2002).

No feijoeiro o sintoma visual da deficiência de N é uma clorose nas folhas (Figura 1), que tem início nas mais velhas, caindo prematuramente. Com a evolução da deficiência a clorose se acentua, podendo permanecer manchas verdes puntiformes, pequenas. Essas características visuais dos níveis possibilitam o uso de visão computacional para a detecção de nutrição de nitrogênio em feijoeiros (BEASSO, 2007).



Figura 1: Folhas de feijoeiro com e sem deficiência de nitrogênio.

Fonte: Autoria própria

3.1.4 Níveis de clorofila na folha do feijão

O N é o nutriente absorvido em quantidades mais elevadas pelo feijoeiro e, conseqüentemente, a sua deficiência é mais freqüente. Plantas com deficiência desse elemento apresentam-se atrofiadas e as folhas revelam coloração entre verde pálido e amarelada, que se inicia pelas folhas mais velhas e relaciona-se com a participação do N na estrutura da molécula de clorofila (Oliveira et al., 1996).

Como o N é constituinte da molécula de clorofila, geralmente existe alta correlação entre o seu teor e a clorofila nas folhas do feijoeiro. Dessa forma, vários autores têm relatado a viabilidade de se utilizar a avaliação indireta de clorofila como indicativo do estado nutricional em relação ao N (SORATTO, 2014; SILVEIRA et al., 2016).

Na cultura do milho, o valor que tem sido usado como Índice de Suficiência de Nitrogênio (ISN) que consiste da média das leituras do clorofilômetro em amostras de uma área a ser adubada com N, dividida pela média das leituras de uma área de referência, sendo este resultado em porcentagem desta forma se o ISN for abaixo de 95% recomenda-se aplicação de N em cobertura. Este índice tem sido usado também para o feijão-comum devido a falta de estudos realizados nesta área (SILVEIRA et al., 2016).

3.2 AVALIAÇÃO COMPUTACIONAL DE IMAGENS

3.2.1 Processamento Digital de Imagens

Uma das primeiras aplicações de técnicas de processamento de imagens ocorreu em 1920 e consistia no melhoramento de imagens de jornal digitalizadas enviadas por um cabo submarino entre Londres e Nova York. Desde então o campo de processamento de imagens cresceu e vem crescendo de forma constante, podem ser citados vários exemplos como o processamento de fotos de telescópios espaciais, na medicina procedimentos computacionais para processamento de imagens são usados para melhorar o contraste ou colorir imagens bio-médicas (GONZALES, 2011).

Segundo Gonzales (2011) Processamento de Imagens Digitais envolve uma série de questões como hardware, software e conhecimento teórico do domínio das informações no qual a imagem se encontra. Para realizar o processamento de imagens algumas fases fundamentais devem ser consideradas, pode-se destacar:

- Aquisição da imagem: A aquisição de imagens é realizada através de algum tipo de sensor de imagens, como câmeras fotográficas;
- Pré-processamento: O pré-processamento consiste em utilizar alguma técnica de melhoramento de imagens específica para uma dada aplicação. Existem várias técnicas de melhoramento de imagem e como exemplo pode-se citar: técnicas de melhoria de contraste, remoção de ruídos, isolamento de regiões similares na imagem, destacamento de bordas, etc;
- Segmentação: A segmentação de imagens consiste em particionar a imagem em partes ou objetos (feições) que a compõem. Na maioria das aplicações a segmentação é a fase mais importante e mais difícil no processamento de imagens digitais. A saída de um procedimento de segmentação geralmente é constituída de pixels da imagem, constituindo os limites de uma região ou todos os pontos na região propriamente dita;
- Representação e Descrição: Escolher uma representação adequada é apenas parte da solução, métodos devem ser especificados para descrever os dados

para que as características importantes sejam destacadas. Descrição ou seleção de características é responsável por extrair características que resultem em informações quantitativas ou características que são base para diferenciação de classes de objetos;

- Reconhecimento e Interpretação: Reconhecimento é o processo que nomeia (identifica) objetos com base nas informações fornecidas pelos seus descritores. Interpretação é a parte que deve dar significado para um conjunto de objetos reconhecidos.

3.2.2 Avaliação de Teores de Nitrogênio e Clorofila em Folhas de Feijão por meio de Processamento Digital de Imagens

Uma maneira prática e rápida de determinar a existência da deficiência de nitrogênio na planta é por meio do diagnóstico visual. Porém, a sua precisão está limitada à experiência do técnico e, também, exige bastante trabalho para gerar um mapa de prescrição para ser utilizado no manejo localizado (BEASSO, 2007).

Já o clorofilômetro portátil proporciona leituras instantâneas não destrutivas de folhas e é uma alternativa para determinação do índice de clorofila nas folhas (ARGENTA et al., 2002). O clorofilômetro apresenta vantagens como a eliminação do envio de amostras para laboratório e já mostrou-se eficiente como instrumento indicador da necessidade de adubação nitrogenada em cobertura no feijoeiro (SILVEIRA et al., 2003). No entanto, quando absorvido em excesso pelas plantas, o N acumula-se como nitrato e não se associa à molécula de clorofila, o que reduz a precisão do medidor de clorofila na estimação do teor foliar de N.

As técnicas de processamento digital de imagens apresentam grande potencial para a obtenção de características que expressem a cor verde da planta (KARCHER et al., 2003). Assim podendo ser comparado tanto os resultados obtidos pelo clorofilômetro quanto os obtidos utilizando processamento de imagens.

3.2.3 Gray Level Co-occurrence Matrix (GLCM)

O GLCM é um método estatístico para extração de características que usa estatísticas de segunda ordem, pois analisa as co-ocorrências existentes entre pares de pixels, ou seja, ele não analisa cada pixel individualmente mas sim, conjuntos de pixels relacionados através de algum padrão. O GLCM é uma matriz sempre quadrada que mantém informações das intensidades relativas dos pixels em uma dada imagem. Ela calcula as probabilidades de co-ocorrências entre dois níveis de cinza i e j , dada uma certa distância. Os elementos da matriz são calculados através da frequência relativa entre dois pontos separados por uma distância de pixels d . Para evitar dependência de direção na classificação é possível calcular a matriz de coocorrência em 4 diferentes ângulos: $0^\circ, 45^\circ, 90^\circ$ e 135° . Originalmente foi proposto por Haralick em 1973, a extração de 14 descritores texturais desta matriz, porém segundo Parmiggiani em 1995 apenas 6 descritores são necessários, portanto neste trabalho foram utilizados apenas 6: energia, entropia, contraste, variância, correlação e homogeneidade (HARALICK et al, 1973; BARALDI et al.,1995).

3.2.4 Local Binary Pattern (LBP)

Este método consiste em um conjunto de características de textura extraída de imagens em escala de cinza (Imagens com coloração apenas com tons de cinza), do qual os valores são calculados através de um valor binário (0 ou 1), atribuído a cada pixel da imagem, formando uma vizinhança linear de raio R ao redor do pixel principal posicionado em uma região central (GUO et al., 2010; ZHANG et al., 2010). Nota-se no exemplo da Figura 2, no qual é analisado um determinado pixel, então os 8 pixels a sua volta são comparados com ele, os que forem menores atribue-se 0 e os que forem maiores atribue-se 1 à uma outra matriz. Então foi feito a seguinte conta: $1*128+1*64+0*32+1*16+0*8+0*4+0*2+0*1=208$. Então o valor do pixel analisado é substituído por 208. Esse procedimento é feito para todos os pixels da imagem. Após isso, é gerado um histograma com a nova imagem, no qual são extraídos as características da imagem.

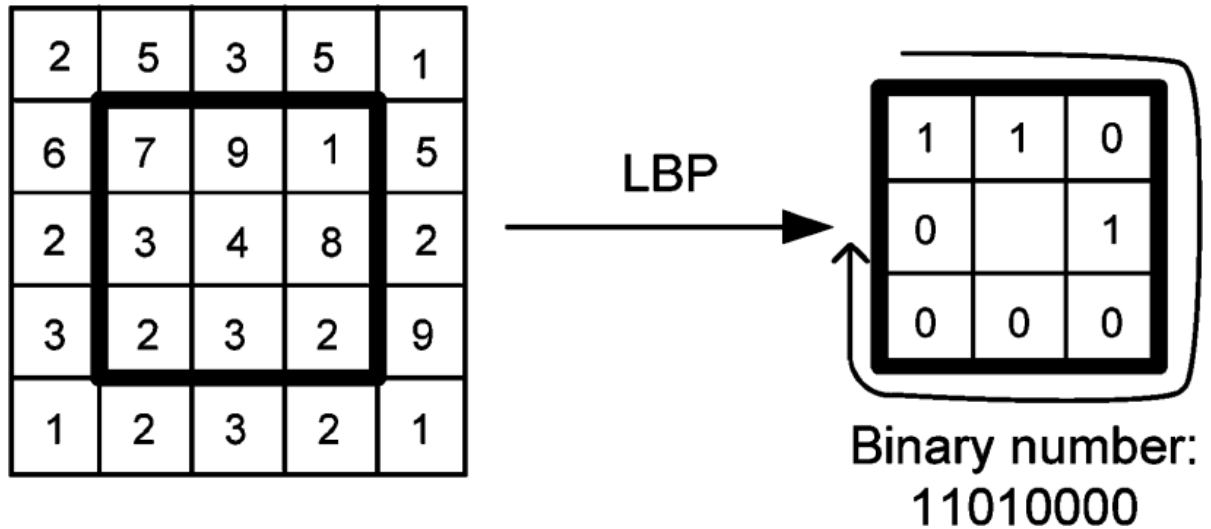


Figura 2: Exemplo do Local Binary Pattern

Fonte: (ZHANG et al., 2010)

3.2.5 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNAs) são modelos inspirados na estrutura do cérebro e tem o objetivo de simular algumas características humanas, tais como aprendizado, associação, generalização e abstração quando submetidas a treinamento. Esses modelos são chamados de neurônios artificiais e calculam funções matemáticas (GUPTA, 2013).

As RNA's foram utilizadas nos últimos anos para realizar tarefas complexas em diferentes áreas e como uma estratégia de modelagem matemática de problemas. Nas RNA's não é necessário propor uma função para o modelo, pois elas são aproximadores universais de funções (CUNHA et al., 2010).




Figura 3: comparação entre neurônio biológico e neurônio artificial

Fonte: (GOLDSCHMIDT, 2010)

A Figura 3 apresenta uma ilustração comparativa entre o modelo biológico e o artificial adotado pelas RNAs. Semelhante ao sistema biológico, uma RNA possui, simplificada, um sistema de neurônios, e conexões ponderadas por valores reais denominados pesos. Numa RNA os neurônios são arrumados em camadas, com conexões entre elas. A Figura 4 ilustra graficamente a arquitetura de uma RNA simples. Os círculos representam os neurônios e as linhas representam os pesos das conexões. Por convenção, a camada que recebe os dados é chamada camada de entrada e a camada que mostra o resultado é chamada de camada de saída. A camada interna, onde ocorre o processamento interno da rede é tradicionalmente chamada de camada escondida. Uma RNA pode conter uma ou várias camadas escondidas, de acordo com a complexidade do problema.

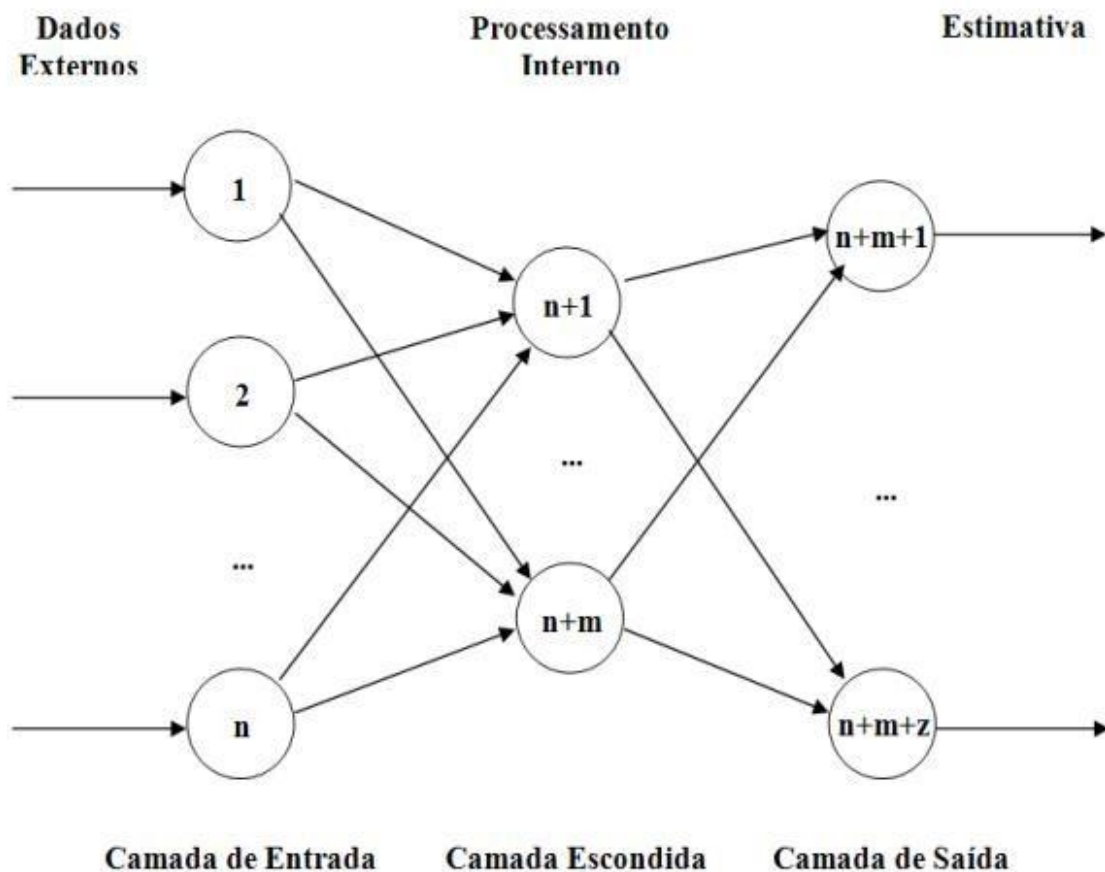


Figura 4: Arquitetura básica de uma RNA.

Fonte: (GOLDSCHMIDT, 2010)

Para a avaliação dos resultados da RNA existem vários métodos, um deles, a validação cruzada, consiste em um método que permite verificar o quão correto é um modelo gerado a partir de análise de dados de treinamento. Esta validação oferece uma estimativa de como o modelo irá se comportar ao analisar um conjunto novo de dados (BAKER et al., 2011).

4 MATERIAIS E MÉTODOS

3.1 PREPARAÇÃO DO EXPERIMENTO

Durante a execução deste trabalho foi realizado um experimento com o intuito de obter dados e imagens a respeito de teores de clorofila e Nitrogênio referentes a cultura do feijão. Este experimento foi conduzido em uma casa de vegetação na UFPR, localizada da cidade de Palotina – PR. Neste experimento foi cultivado feijoeiros em vasos com areia e recebeu tratamentos de soluções nutritivas com diferentes doses de Nitrogênio. O experimento foi feito em casas de vegetação por necessitar de um ambiente controlado onde a cultura fica protegida de pragas e do clima externo.

O experimento constou de um delineamento em blocos inteiramente casualizado com 5 doses de N (dose 1: 50 mg L⁻¹, dose 2: 100 mg L⁻¹, dose 3: 150 mg L⁻¹, dose 4: 200 mg L⁻¹ e dose 5: 250 mg L⁻¹) conforme a Figura 5.

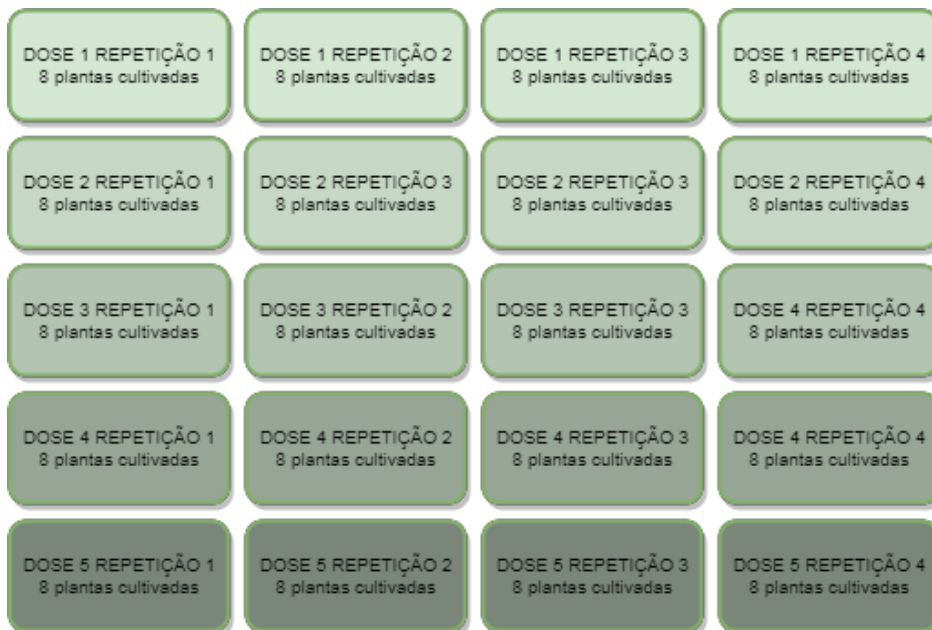


Figura 5: Esquema de doses e repetições do experimento.

Fonte: Autoria Própria.

Ocorreram duas coletas de dados e imagens do experimento, o primeiro realizando avaliações em plantas e o segundo coletando as plantas restantes. Após a coleta, ocorreu a análise química para determinar o N presente em cada dosagem

testada no experimento, utilizando-se a metodologia para determinação de Nitrogênio Total descrita por Soares (2013).

3.2 COLETA DOS DADOS

A coleta dos dados de clorofila consistiu primeiramente no corte da planta, onde foram selecionadas e retiradas as 4 folhas em melhor estado. Em seguida foi feito a medição de clorofila de cada uma das folhas. A medição foi feita utilizando o clorofilômetro cujo modelo é ClorofiLOG CFL1030, conforme a Figura 6.



Figura 6: Clorofilômetro

Fonte: Autoria propria

4.3 AQUISIÇÃO DE IMAGENS

A aquisição das imagens foi feita utilizando a câmera fotográfica digital da marca Nikon cujo modelo é Coolpix L820. Esta câmera é de propriedade da UTFPR de Medianeira.

As fotos foram tiradas em um ambiente controlado com o intuito de reduzir ruídos e padronizar as imagens. O ambiente controlado consistiu em uma caixa com iluminação artificial feita de pranchas de madeira e painéis de LED nas laterais. As folhas foram posicionadas no fundo da caixa ao lado de uma escala de cores, conforme a Figura 7 e Figura 8. Foram coletadas um total de 499 fotos, 247 na primeira coleta e 252 na segunda.



Figura 7: Caixa utilizado para aquisição de imagens.

Fonte: Autoria própria.




Figura 8: Fotos coletadas nas coletas 1 e 2.

Fonte: Autoria própria.

4.4 PRÉ-PROCESSAMENTO

O pré-processamento consiste em aplicar métodos para minimizar ruídos nas imagens coletadas, preparando-as para as etapas seguintes. As imagens coletadas são nomeadas de forma sequencial pela câmera utilizada, porém notou-se a necessidade de organizar as imagens por tratamento, repetição, planta e folha, assim foi definido um padrão para nomeá-las. Na Tabela 1 são apresentados exemplos das imagens que foram renomeadas utilizando o padrão definido.

Tabela 1: padrão utilizado na nomeação das imagens coletadas

| Nome | Tratamento | Repetição | Planta | Folha |
|--------------|------------|-----------|--------|-------|
| t1r1p1f1.jpg | 1 | 1 | 1 | 1 |
| t2r2p1f2.jpg | 2 | 2 | 1 | 2 |
| t3r2p2f4.jpg | 3 | 2 | 2 | 4 |
| T4r4p1f2.jpg | 4 | 4 | 1 | 2 |

Fonte: Autoria Própria.

4.5 EXTRAÇÃO DE CARACTERÍSTICAS

Esta etapa consistiu em extrair características, ou seja, foram extraídos dados das imagens através de métodos de extração de características para posteriormente utiliza-los como entrada em um algoritmo de aprendizado de máquina para classificação de níveis de nitrogênio. Os métodos de extração de características utilizados neste trabalho foram: Gray-Level Co-Occurrence Matrix (GLCM), Estatístico sem texturização e Local Binary Patterns (LBP). Esses métodos serão descritos no decorrer desta seção.

O primeiro método para extração de características foi o método Estatístico sem texturização. Neste método foram calculadas a média aritmética, moda, variância e curtose para RGB (vermelho, verde e azul) porém diretamente dos pixels da imagem, totalizando 12 descritores.

O segundo método utilizado foi o GLCM, no qua, originalmente foi proposto por Haralick (1973), a extração de 14 descritores texturais desta matriz, porém segundo Parmiggiani em 1995 apenas 6 descritores são necessários, portanto neste

trabalho foram utilizados apenas 6: energia, entropia, contraste, variância, correlação e homogeneidade (HARALICK et al, 1973; BARALDI et al.,1995).

Foram calculados esses descritores para cada um dos 4 ângulos, todos com distância d de 1 pixel. Normalmente no GLCM utilizam-se imagens em escala de cinza, porém a cor verde é muito relevante para detectar níveis de nitrogênio, portanto também foram calculados esses descritores para o sistema RGB, totalizando 72 descritores.

O terceiro método de extração de características utilizado foi o LBP. Para a criação dos descritores LBP deste trabalho foi utilizado primeiro um vetor com 10 valores que descreve a imagem obtido o LBP implementado pelo software Matlab. Também foi implementado o LBP na linguagem java onde foram extraídos valores adicionais do vetor de característica gerado no LBP, sendo eles: variância, maior valor e entropia. Os 3 valores anteriores foram calculados para RGB, totalizando mais 9 descritores, desta forma este método obteve 19 descritores para cada imagem (GUO et al., 2010; ZHANG et al., 2010).

Os descritores de ambos os métodos de extração foram retirados de 247 fotos da primeira coleta e de 252 fotos da segunda coleta, onde ambos foram utilizados separadamente como atributos para treinamento e teste de uma Rede Neural Artificial *Multilayer Perceptron* utilizando o software Weka. O Weka consiste em uma coleção de algoritmos de aprendizado de máquina e ferramentas de processamento de dados, no qual é possível todos esses recursos utilizando linha de comando ou uma interface visual (FRANK et al., 2009).

3.6 USO DE REGRESSÃO PARA AVALIAÇÃO DO DIAGNÓSTICO DE NITROGÊNIO

Neste trabalho foi utilizado a RNA *Multilayer Perceptron* já implementada pelo software Weka, onde ele cria a RNA com base na quantidade de descritores. Já para teste da RNA foi utilizado o método de validação cruzada. Para avaliação da RNA foi calculado a correlação de Pearson dos valores preditos por ela com os valores de treinamento. Este método de correlação consiste em uma medida de associação do grau de relacionamento entre duas variáveis (FILHO et al., 2009).

3.7 AMBIENTE DE DESENVOLVIMENTO

Neste trabalho os métodos extração de características foram desenvolvidos utilizando a linguagens de programação Java com a biblioteca OpenCV e o Matlab, no qual foram criados os arquivos .arff que são necessários para treinamento das RNA's utilizando o Weka.

3.7.1 Biblioteca OpenCV

O OpenCV consiste em uma biblioteca *open source* de visão computacional. Ela foi desenvolvida utilizando a linguagem C e C++, e pode ser executada em múltiplas plataformas, como Linux, Windows e Mac OS.

No seu desenvolvimento foi considerado a eficiência computacional e grande foco em aplicações em tempo real. Um dos principais objetivos do OpenCV é facilitar o uso de visão computacional, ou seja, essa biblioteca fornece diversas funções prontas. Atualmente ela possui mais de 2500 funções relacionadas a visão computacional, como filtros, calibração de câmera e robótica.

Como o aprendizado de máquina e a visão computacional são duas área que muitas vezes de correlacionam, o OpenCV fornece o *Machine Learning Library* (MLL), que consiste em uma sub-biblioteca focada em padrões estatísticos de reconhecimento e *clustering*. Este recurso é muito útil para resolver problemas de aprendizado de máquina (KEAHLER et al., 2008; SOBRAL, 2013).

3.8 FLUXO GERAL DO SISTEMA PARA DIAGNÓSTICO DE NITROGÊNIO

A ideia geral deste trabalho consistiu em criar uma metodologia para diagnóstico de nitrogênio em folhas de feijão utilizando técnicas de extração de característica de imagens e Redes Neurais Artificiais. Na Figura 9 é apresentado o fluxo geral deste trabalho, no qual primeiramente são extraídos características das imagens coletadas. Essas características são utilizadas como dados para treinamento de RNAs utilizando o Weka. Assim que o treinamento é concluído a RNA esta pronta para realizar predições de N em novas imagens.

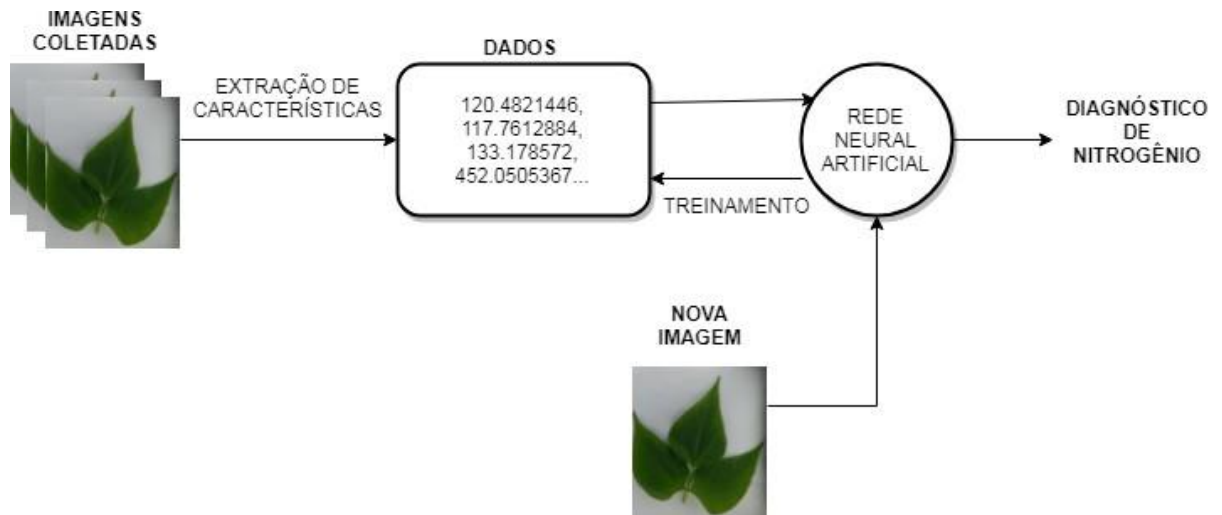


Figura 9: Diagrama apresentando o fluxo geral do método de diagnóstico de N.

Fonte: Autoria própria.

5 RESULTADOS E DISCUSSÃO

Diversos trabalhos científicos como Soratto et al. (2005), Silveira et al. (2016) e Sant'Ana et al. (2010) propoem o diagnóstico de nitrogênio no feijoeiro através de leitura de clorofila na folha da planta. Nesta dissertação é proposta o uso de diagnóstico por imagem além dos dados de clorofila A, B, Total para diagnosticar a nutrição do feijoeiro em relação ao nitrogênio como padrão de nutrição. Os valores de clorofila e N no tecido do feijoeiro realizados em dois períodos diferentes do desenvolvimento do feijoeiro são apresentados nas Tabelas 2 e 3 sendo a Tabela 2 referente aos dados da coleta 1 (45 dias após a semeadura) e a Tabela 3 da coleta 2 (58 dias após a semeadura).

Tabela 2: Dados da Análise química de N e médias de clorofila realizado para as folhas dos feijoeiros da coleta 1

| Tratamento (mg L ⁻¹) | Repetição | Análise química (g kg ⁻¹) | Clorofila Total | Clorofila A | Clorofila B |
|-------------------------------------|-----------|---|--------------------|----------------|-------------|
| 50 | 1 | 42,93 | 35,59 | 27,55 | 7,79 |
| 50 | 2 | 38,56 | 35,82 | 27,54 | 7,90 |
| 50 | 3 | 39,98 | 36,11 | 28,86 | 8,04 |
| 50 | 4 | 39,52 | 37,77 | 29,76 | 7,52 |
| 100 | 1 | 39,55 | 36,17 | 30,06 | 7,54 |
| 100 | 2 | 42,64 | 37,38 | 29,97 | 7,67 |
| 100 | 3 | 39,73 | 35,88 | 29,30 | 7,24 |
| 100 | 4 | 41,10 | 36,01 | 29,75 | 7,19 |
| 150 | 1 | 39,84 | 38,74 | 30,47 | 7,88 |
| 150 | 2 | 38,73 | 37,29 | 29,22 | 6,74 |
| 150 | 3 | 40,23 | 33,71 | 28,52 | 7,07 |
| 150 | 4 | 44,04 | 36,30 | 28,77 | 7,3 |
| 200 | 1 | 39,99 | 38,26 | 29,98 | 7,75 |
| 200 | 2 | 43,73 | 35,87 | 29,37 | 7,45 |
| 200 | 3 | 43,52 | 38,15 | 28,36 | 7,78 |
| 200 | 4 | 43,43 | 54,61 | 29,19 | 8,76 |
| 250 | 1 | 47,25 | 38,73 | 29,18 | 8,77 |
| 250 | 2 | 45,50 | 39,68 | 31,42 | 9,82 |
| 250 | 3 | 49,86 | 40,93 | 30,54 | 8,26 |
| 250 | 4 | 49,25 | 38,10 | 30,57 | 8,12 |

Fonte: Autoria Própria

Tabela 3: Dados da Análise química de N e médias de clorofila realizado para as folhas dos feijoeiros da coleta 2

| Tratamento (mg L ⁻¹) | Repetição | Análise química (g kg ⁻¹) | Clorofila Total | Clorofila A | Clorofila B |
|-------------------------------------|-----------|---|--------------------|-------------|-------------|
| 50 | 1 | 32,45 | 34,25 | 26,87 | 7,37 |
| 50 | 2 | 35,58 | 34,40 | 27,15 | 7,60 |
| 50 | 3 | 36,92 | 35,18 | 27,63 | 7,77 |
| 50 | 4 | 32,08 | 36,22 | 27,71 | 7,78 |
| 100 | 1 | 28,56 | 31,42 | 24,91 | 6,79 |
| 100 | 2 | 34,17 | 34,16 | 26,60 | 7,43 |
| 100 | 3 | 33,35 | 34,59 | 27,03 | 7,64 |
| 100 | 4 | 36,22 | 32,43 | 29,19 | 9,12 |
| 150 | 1 | 35,39 | 34,54 | 26,70 | 7,56 |
| 150 | 2 | 38,92 | 35,06 | 27,42 | 7,70 |
| 150 | 3 | 32,27 | 34,93 | 27,45 | 7,57 |
| 150 | 4 | 33,67 | 34,23 | 26,81 | 7,67 |
| 200 | 1 | 39,95 | 37,92 | 28,75 | 8,79 |
| 200 | 2 | 35,24 | 38,17 | 29,49 | 9,33 |
| 200 | 3 | 39,79 | 38,95 | 29,54 | 9,08 |
| 200 | 4 | 39,59 | 38,24 | 29,61 | 9,16 |
| 250 | 1 | 38,41 | 44,36 | 32,37 | 11,62 |
| 250 | 2 | 38,34 | 41,69 | 31,00 | 10,57 |
| 250 | 3 | 37,61 | 41,08 | 31,68 | 11,18 |
| 250 | 4 | 42,01 | 41,43 | 29,85 | 9,57 |

Fonte: Autoria Própria.

Observa-se pelas Tabela 2 e Tabela 3, que os teores de N variaram de 28,56 até 49,86 g kg⁻¹, nos quais são próximos de 30 à 50 g kg⁻¹ que são considerados ideais segundo Silva (2009). Na Coleta 1 as doses obtiveram as seguintes médias de N na análise química:

- Dose 50 mg L⁻¹: 40,24 g kg⁻¹;
- Dose 100 mg L⁻¹: 40,75 g kg⁻¹
- Dose 150 mg L⁻¹: 40,71 g kg⁻¹
- Dose 200 mg L⁻¹: 42,66 g kg⁻¹
- Dose 250 mg L⁻¹: 47,96 g kg⁻¹

Já a Coleta 2 obteve as seguintes médias de N:

- Dose 50 mg L⁻¹: 34,25 g kg⁻¹;
- Dose 100 mg L⁻¹: 33,07 g kg⁻¹
- Dose 150 mg L⁻¹: 35,06 g kg⁻¹
- Dose 200 mg L⁻¹: 38,64 g kg⁻¹
- Dose 250 mg L⁻¹: 39,09 g kg⁻¹

Nota-se que em ambas as coletas ocorreu um aumento na média de N conforme a dose aumenta. Também percebe-se que as médias da Coleta 2 são inferiores às da coleta 1, isso ocorre pois a falta de N fica mais nítida conforme o tempo passa.

As correlações encontradas entre os teores de clorofila e os teores de Nitrogênio determinado pela análise química apresentaram correlações significativas, principalmente quando se avalia os teores de clorofila A com as concentrações de N, apresentando uma correlação moderada (Tabela 4), demonstrando a possibilidade da previsão de N através de um clorofilômetro (Soratto et al., 2005; Silveira et al., 2016; Sant'Ana et al., 2010).

Ainda pode-se verificar que a clorofila A, em virtude desta compor juntamente com a clorofila B os valores da clorofila Total. A clorofila Total apresentou correlação fraca com os teores de N, esta piora na correlação quando se avalia clorofila Total é entendida quando se verifica que a correlação entre os teores de N e a clorofila B não apresentam correlação, como a clorofila B é componente dos valores da clorofila total o uso destes valores acaba por diminuir a correlação nas avaliações (Tabela 4).

Tabela 4: Correlações entre os dados coletados das coletas 1 e 2

| | AQ X CT | AQ X CA | AQ X CB | CT X CA | CT X CB | CA X CB |
|-------------------|----------------|----------------|----------------|----------------|----------------|----------------|
| Correlação | 0,489885 | 0,598921 | 0,156906 | 0,827656 | 0,740046 | 0,655197 |
| | Fraca | Moderada | Desprezível | Forte | Forte | Moderada |

Obs: AQ = Análise Química; CT = Clorofila Total; CA = Clorofila A; CB = Clorofila B.

Fonte: Autoria Própria.

4.1 EXTRAÇÃO DE CARACTERÍSTICAS ESTATÍSTICAS SEM TEXTURIZAÇÃO DAS IMAGENS DE FOLHAS DE FEIJÃO

Segundo Kawashima et al. (1998), é possível prever a clorofila presente em folhas através de características estatísticas de uma imagem digital, sabendo que existe uma relação direta entre a clorofila e o nível de nitrogênio da planta (SILVEIRA et al., 2016), o presente trabalho utilizou a extração de diversos atributos estatísticos de imagens de folhas de feijão cultivadas com teores distintos de Nitrogênio para gerar variabilidade. Assim, as características avaliadas com o intuito de verificar a possibilidade de uso para determinação não destrutiva de teor de N em tecido foliar de feijão foram: MédiaR, ModaR, VariânciaR, CurtoseR, MédiaG, ModaG, VariânciaG, CurtoseG, MédiaB, ModaB, VariânciaB, CurtoseB.

Estas características consistem em média aritmética, moda, variância e curtose para os níveis de R, G e B, consistindo em vermelho, verde e azul respectivamente. Em cada imagem foram extraídos um total de 12 atributos estatísticos, tanto para a coleta 1 quanto para a coleta 2.

Para determinar a possibilidade de uso destes atributos para a determinação de N estes foram submetidos como entrada em uma Rede Neural Artificial (RNA) com o intuito de fazer a diagnose de N, a RNA pode ser utilizada para realizar previsões de N em diversas culturas, como por exemplo no trabalho de Silva et al. (2009) que prevê a deficiência de N em mamoeiras.

No presente trabalho a RNA foi utilizada para realizar a previsão de N utilizando o método estatístico sem texturização para extração de características. Observou-se por meio desta forma de trabalhar os dados que o uso de todos os atributos separados por época de coleta de dados, coleta 1 e coleta 2, apresentaram correlações moderadas com os teores de N, com valores de correlação de 0,4958 e 0,4262 para a coleta 1 e 2 respectivamente. Quando se trabalha no treinamento da RNA com um universo amostral maior, o que ocorre com o uso dos dados das duas épocas juntas obtêm-se uma melhoria nas correlações, saltando para 0,7062, mostrando que a época de coleta gera maior variabilidade nos dados o que acaba por enriquecer o universo amostral e assim favorecer a previsão dos teores de N.

Por meio da análise conjunta de todos os valores extraídos verificou-se que é possível utilizar a RNA no processo de determinação de N. Contudo, a avaliação separada dos atributos extraídos da imagem pode auxiliar a melhorar a qualidade de determinação. Para verificar esta possibilidade realizou-se uma análise dos atributos coletados do método Estatístico, como intuito de identificar e excluir os atributos menos relevantes. Esta análise foi feita utilizando correlação de Pearson entre os atributos e a análise química. Desta forma, utilizando no treinamento da RNA apenas com os atributos (Tabela 5) que obtiveram uma correlação superior a 0,3 ou inferior a - 0,3, obtendo com estes atributos uma correlação da RNA de 0,7151, ou seja, a correlação foi levemente superior ao treinamento da RNA sem seleção de atributos. Outra seleção de atributos que foi testada foi a separação dos atributos com correlação negativa dos atributos com correlação positiva, nos quais obtiveram correlação da RNA de 0,5874 e 0,6456 respectivamente, notando-se que utilizando ambos, a correlação é superior. Por fim utilizou-se apenas o atributo com a melhor correlação, no qual obteve uma correlação com a RNA de 0,583, notando-se que a RNA obtém melhores resultados utilizando uma maior quantidade de atributos, porém com uma alta relevância.

Tabela 5: Correlação dos atributos extraídos das imagens de folha com os dados da análise química de N.

| Atributos avaliados | Correlação |
|----------------------------|-------------------|
| MediaR | -0,6369 |
| ModaR | 0,6559 |
| VariânciaR | -0,6511 |
| CurtoseR | 0,6604 |
| MediaG | 0,6482 |
| ModaG | -0,6494 |
| VariânciaG | 0,2874 |
| CurtoseG | 0,2492 |
| MediaB | -0,2363 |
| ModaB | -0,6524 |
| VariânciaB | 0,4534 |
| CurtoseB | 0,4581 |

Fonte: Autoria Própria.

Na Tabela 6 é apresentado as correlações do método Estatístico utilizando RNA com dados de teor de N no tecido foliar, Clorofila Total, Clorofila A e Clorofila B aplicando seleção de atributos com os dados das duas coletas. No qual nota-se que os resultados da análise química foram superiores aos de clorofila, obtendo correlação de 0,7151 com seleção de atributos, este resultado sendo semelhante aos obtidos por Baesso et al. (2012) na diagnose de N em feijoeiros, no qual obteve uma porcentagem de acerto de 74% de classificação, utilizando RNA treinada com atributos estatísticos.

Tabela 6: Correlação os método de extração de característica Estatístico sem texturização utilizando Redes Neurais Artificiais

| Dados avaliados | Correlação sem seleção de atributos | Correlação com seleção de atributos |
|------------------------|--|--|
| Análise química | 0,7062 | 0,7151 |
| Clorofila Total | 0,1015 | 0,0844 |
| Clorofila A | 0,2974 | 0,3054 |
| Clorofila B | 0,4055 | 0,4055 |

Fonte: Autoria Própria.

4.2 EXTRAÇÃO DE CARACTERÍSTICAS DAS IMAGENS DE FOLHAS DE FEIJÃO UTILIZANDO *GRAY LEVEL CO-OCURRENCE MATRIX* (GLCM)

Além dos atributos Estatísticos sem texturização, buscou-se abordagens mais sofisticadas para extração de características em imagens digitais. Segundo Vakilian et al. (2012) a utilização do método de extração de características GLCM é eficaz na detecção de N no pepino. Desta forma, nesta dissertação utilizou-se o GLCM para extração de características das imagens das folhas de feijão. No GLCM foram calculados 6 atributos da imagem: energia, entropia, contraste, heterogeneidade, correlação e variância. Porém pode-se variar o ângulo em que é montada a matriz de co-ocorrência, sendo 0°, 45°, 90° e 135°, cada um deles sendo calculado os 6 atributos anteriores. Neste trabalho esses cálculos foram feitos para imagens em escala de cinza totalizando 24 atributos e obtendo uma correlação de 0,5020 de acerto. Posteriormente esses testes foram repetidos para R,G e B, totalizando 72 atributos coletados em cada imagem da coleta 1 e 2. Esses atributos podem ser

vistos na Tabela 7 em conjunto com a correlação de Pearson para a análise química foliar de N.

Tabela 7: Correlação dos atributos extraídos das imagens de folha com os dados da análise química de N.

| Atributos Avaliados | Correlação |
|----------------------------|-------------------|
| EnergiaR0 | -0,3253 |
| EntropiaR0 | 0,1509 |
| ContrasteR0 | -0,3214 |
| HeterogeneidadeR0 | 0,4098 |
| CorrelaçãoR0 | 0,0128 |
| VariânciaR0 | -0,01266 |
| EnergiaR45 | -0,4221 |
| EntropiaR45 | 0,1876 |
| ContrasteR45 | 0,3936 |
| HeterogeneidadeR45 | 0,3745 |
| CorrelaçãoR45 | 0,0600 |
| VariânciaR45 | -0,0599 |
| EnergiaR90 | -0,3287 |
| EntropiaR90 | 0,1169 |
| ContrasteR90 | -0,3786 |
| HeterogeneidadeR90 | 0,3683 |
| CorrelaçãoR90 | 0,0987 |
| VariânciaR90 | -0,1030 |
| EnergiaR135 | -0,3440 |
| EntropiaR135 | 0,1772 |
| ContrasteR135 | -0,1855 |
| HeterogeneidadeR135 | -0,3349 |
| CorrelaçãoR135 | 0,0138 |
| VariânciaR135 | -0,0128 |
| EnergiaG0 | -0,4412 |
| EntropiaG0 | 0,2165 |
| ContrasteG0 | -0,2980 |
| HeterogeneidadeG0 | 0,2689 |
| CorrelaçãoG0 | 0,0614 |
| VariânciaG0 | -0,0601 |
| EnergiaG45 | -0,3614 |
| EntropiaG45 | 0,1602 |
| ContrasteG45 | -0,2793 |
| HeterogeneidadeG45 | -0,2583 |
| CorrelaçãoG45 | 0,0999 |
| VariânciaG45 | -0,1031 |
| EnergiaG90 | -0,2821 |
| EntropiaG90 | 0,0718 |
| ContrasteG90 | -0,2759 |

| | |
|---------------------|---------|
| HeterogeneidadeG90 | 0,4299 |
| CorrelaçãoG90 | 0,0138 |
| VariânciaG90 | -0,0133 |
| EnergiaG135 | -0,3958 |
| EntropiaG135 | 0,1381 |
| ContrasteG135 | -0,3848 |
| HeterogeneidadeG135 | 0,3731 |
| CorrelaçãoG135 | 0,0621 |
| VariânciaG135 | -0,0629 |
| EnergiaB0 | -0,2988 |
| EntropiaB0 | 0,0775 |
| ContrasteB0 | -0,3673 |
| HeterogeneidadeB0 | 0,3693 |
| CorrelaçãoB0 | 0,1008 |
| VariânciaB0 | -0,1057 |
| EnergiaB45 | -0,3287 |
| EntropiaB45 | 0,1422 |
| ContrasteB45 | -0,3825 |
| HeterogeneidadeB45 | 0,3220 |
| CorrelaçãoB45 | 0,0145 |
| VariânciaB45 | -0,0143 |
| EnergiaB90 | -0,4322 |
| EntropiaB90 | 0,1757 |
| ContrasteB90 | -0,4819 |
| HeterogeneidadeB90 | 0,2616 |
| CorrelaçãoB90 | 0,0627 |
| VariânciaB90 | -0,0634 |
| EnergiaB135 | -0,3468 |
| EntropiaB135 | 0,1149 |
| ContrasteB135 | -0,4590 |
| HeterogeneidadeB135 | 0,2549 |
| CorrelaçãoB135 | 0,1012 |
| VariânciaB135 | -0,1058 |

Fonte:Autoria Própria.

Semelhante ao que foi feito para os atributos Estatísticos sem texturização, os atributos do GLCM também foram submetidos como entrada à uma RNA *Multilayer Perceptron* com o intuito de avaliar a sua qualidade na diagnose de nitrogênio. Foram criadas duas RNA's para a análise química, a primeira tendo como entrada todos os atributos extraídos das imagens utilizando o GLCM, já a segunda RNA tendo como entrada apenas os atributos com correlação de Pearson superior a 0,3 ou inferior a -0,3, ou seja, foram excluídos 43 atributos. Esse procedimento foi repetido para os dados de clorofila A, B e Total. Pelas análises de correlação

realizadas observa-se que novamente a análise química se sobressai em comparação aos resultados de clorofila, melhorando significativamente quando é feita a seleção de atributos (Tabela 8).

Vakilian et al. (2012) utilizaram em seu trabalho o GLCM apenas para diagnosticar se havia deficiência de nitrogênio ou não comparando com dados coletados de folhas de pepino sem a utilização de tratamento nitrogenado (controle) com dados de folhas com tratamento deficiente de nitrogênio, no qual obteve uma confiabilidade de acerto de 92 a 95 %. Já no presente trabalho foram realizadas medições de clorofila e nitrogênio, submetendo-as em uma RNA correlacionando os resultados desta, com as medições feitas chegando a uma correlação máxima de 0,7454 para o GLCM com seleção de atributos.

Tabela 8: Correlação dos métodos de extração de característica GLCM utilizando Redes Neurais Artificiais

| Dados avaliados | Correlação sem seleção de atributos | Correlação com seleção de atributos |
|------------------------|--|--|
| Análise química | 0,2391 | 0,7454 |
| Clorofila Total | 0,0226 | 0,0962 |
| Clorofila A | -0,0439 | 0,5354 |
| Clorofila B | 0,0256 | 0,5472 |

Fonte:Autoria Própria.

4.3 EXTRAÇÃO DE CARACTERÍSTICAS DAS IMAGENS DE FOLHAS DE FEIJÃO UTILIZANDO *LOCAL BINARY PATTERN* (LBP)

Segundo Dubey et. al (2012) o LBP pode atingir bons resultados extraindo características texturais para a classificação de doenças na cultura de milho através de fotos de folhas desta cultura. Já neste trabalho também utilizou-se o LBP para extrair características texturais, porém em folhas de feijão, com o intuito de diagnosticar a nutrição de N no feijoeiro.

O LBP foi implementado de duas formas neste trabalho, a primeira delas foi utilizando o Matlab no qual utilizou-se a função `extractLBPFeatures(imagem, 'Upright', false)` que retorna um vetor com 10

características (bins) da imagem extraídas do histograma que o LBP constroi. Esses atributos submetidos como entrada de RNA obtiveram correlação de 0,6754 comparando com os dados da análise química de N.

A segunda forma que o LBP foi implementado, foi utilizando a linguagem de programação Java com a biblioteca OpenCV, no qual, foram gerados mais 9 características extraídas também do histograma que o LBP gera. Esses 9 atributos obtiveram correlação na RNA de 0,6384 também comparando com os dados de N da análise química.

Já utilizando os 19 atributos em conjunto obteve-se uma correlação de 0,7061, obtendo resultado superior aos atributos separados, sendo assim utilizados desta forma na sequência deste trabalho.

Semelhante ao que foi feito com o Estatístico e ao GLCM, o LBP também foi submetido a seleção de atributos utilizando correlação de Pearson, nos quais podem ser visto na Tabela 9.

Tabela 9: Correlação dos atributos LBP extraídos das imagens de folha com os dados da análise química de N.

| Atributos avaliados | Correlação |
|---------------------|------------|
| MatlabBin1 | -0,7102 |
| MatlabBin2 | -0,6967 |
| MatlabBin3 | -0,6963 |
| MatlabBin4 | 0,6515 |
| MatlabBin5 | -0,2047 |
| MatlabBin6 | 0,7107 |
| MatlabBin7 | -0,6234 |
| MatlabBin8 | -0,6889 |
| MatlabBin9 | -0,0323 |
| MatlabBin10 | -0,7038 |
| VariânciaR | 0,4472 |
| MáximoR | 0,3395 |
| EntropiaR | -0,0110 |
| VariânciaG | 0,4344 |
| MáximoG | 0,3366 |
| EntropiaG | 0,0420 |
| VariânciaB | 0,4170 |
| MáximoB | 0,3148 |

EntropiaB

0,0903

 Fonte:Autoria Própria.

Os atributos selecionados para a criação das novas RNA's foram os que obtiveram correlação de Pearson superiores a 0,3 ou inferiores a -0,3 ,ou seja, 5 atributos foram excluídos. Os resultados das RNA's criadas com esses atributos selecionados podem ser conferidos na Tabela 10. Percebe-se que a RNA utilizando dados da análise química foliar de N novamente obteve resultados superiores aos de clorofila. Já a utilização de seleção de atributos também obteve resultados superiores aos atributos sem seleção (Tabela 10).

Tabela 10: Correlação os método de extração de característica LBP utilizando Redes Neurais Artificiais

| Dados avaliados | Correlação sem seleção de atributos | Correlação com seleção de atributos |
|------------------------|--|--|
| Análise química | 0,7061 | 0,7308 |
| Clorofila Total | 0,3069 | 0,3852 |
| Clorofila A | 0,2740 | 0,3612 |
| Clorofila B | 0,3628 | 0,4055 |

 Fonte:Autoria Própria.

Neste trabalho o melhor resultado obtido utilizando o LBP foi de 0,7308 para correlação da análise química foliar de N, com seleção de atributos, sendo submetidos a uma RNA *Multilayer Perceptron*. já no trabalho de Dubey et. al (2012) foi obtido um resultado de 93% de acerto de classificação, porém no trabalho dele foi utilizado como classificador o *Support Vector Machine*.

4.4 CORRELAÇÃO UTILIZANDO OS TRÊS MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS

No artigo de Sardar et. al (2016) foi proposto a combinação do método GLCM e LBP para extração de características, com o intuito fazer o reconhecimento de diferentes frutas e a sua quantidade calórica. Já no presente trabalho foi testado a extração de característica utilizando o método Estatístico sem texturização, GLCM e LBP. Segundo Sardar et. al (2016) a combinação de diferentes métodos de

extração de características é promissora. Assim com o intuito de verificar se o uso combinado dos três métodos melhora a eficiência, realizou-se a combinação dos três métodos estudados para a criação de uma RNA para classificação de N. Para esta RNA também foram testados os resultados com a análise química, Clorofila A, B e Total utilizando todos os atributos e com seleção de atributos com os atributos com correlação maior que 0,3 ou menor que -0,3.

Nota-se na Tabela 11 que todos os dados testados promoveram uma melhora nos resultados, com exceção da clorofila total que a seleção de atributos piorou os resultados. Porém na análise química obteve-se um resultado superior à todos os métodos de extração de característica testados separadamente.

Tabela 11: Correlação dos métodos de extração de característica, GLCM, LBP e Estatístico sem texturização na Rede Neural artificial

| Dados avaliados | Correlação sem seleção de atributos | Correlação com seleção de atributos |
|------------------------|--|--|
| Análise química | 0,7081 | 0,7635 |
| Clorofila Total | 0,3158 | -0,0278 |
| Clorofila A | 0,5346 | 0,5376 |
| Clorofila B | 0,5455 | 0,675 |

Fonte:Autoria Própria.

No artigo de Sardar et. al (2016) obteve-se resultados da classificação de algumas frutas superiores a 90% utilizando o SVM como classificador, porém notou-se que o autor utilizou no máximo 25 imagens para cada fruta classificada e algumas frutas apenas 1 imagem, desta forma comprometendo a significância estatística dos resultados.

4.5 CATEGORIZAÇÃO DA ANÁLISE QUÍMICA UTILIZANDO OS TRÊS MÉTODOS DE EXTRAÇÃO DE CARACTERÍSTICAS E REDES NEURAS ARTIFICIAIS

Considerando que é rotineiro o uso de faixas para determinar os níveis adequados de nutrientes nas culturas, ocorrendo faixas consideradas adequadas,

insuficientes ou mesmo excessivas. A determinação de faixas nutricionais ao invés de teores pontuais em substituição da análise pode ser extremamente útil para o presente estudo, isto se esta forma de avaliação apresentar ganhos significativos.

Para Romualdo (2013) o uso de técnicas de visão computacional na categorização de nutrição de nitrogênio na cultura do milho é promissora, quando se utiliza descritores de Gabor Wavelets multiespectrais e fractais (GWF), e o método de aprendizado de máquina (SVM) para classificação. O GWF é uma função matemática que depois de aplicada em uma imagem gera uma representação que ressalta os pontos mais importantes dela. Já o SVM consiste em um conjunto de métodos de aprendizado supervisionado que analisam os dados e reconhece padrões, usado para classificação e análise de regressão.

Utilizando-se uma classificação como uma forma de analisar os resultados e comparar com os resultados anteriores utilizando regressão. Para classificar entre níveis de N, foi necessário a divisão dos dados da análise química de N em em 3 classes. As imagens que possuíam menos de $36,67 \text{ g kg}^{-1}$ de N se tornaram da classe 1, as que tinha N de $36,67$ à $43,32 \text{ g kg}^{-1}$ de N ficaram na classe 2 e por fim acima de $43,32$ ficaram na classe 3 (Tabela 12).

Tabela 12: Dados da Análise química de N e médias de clorofila realizado para as folhas dos feijoeiros da coleta 1 e 2

| Coleta | Tratamento (mg L^{-1}) | Repetição | Análise química (g kg^{-1}) | Classe |
|--------|--------------------------------------|-----------|--|--------|
| 1 | 50 | 1 | 42,93 | 2 |
| 1 | 50 | 2 | 38,56 | 2 |
| 1 | 50 | 3 | 39,98 | 2 |
| 1 | 50 | 4 | 39,52 | 2 |
| 1 | 100 | 1 | 39,55 | 2 |
| 1 | 100 | 2 | 42,64 | 2 |
| 1 | 100 | 3 | 39,73 | 2 |
| 1 | 100 | 4 | 41,10 | 2 |
| 1 | 150 | 1 | 39,84 | 2 |
| 1 | 150 | 2 | 38,73 | 2 |
| 1 | 150 | 3 | 40,23 | 2 |
| 1 | 150 | 4 | 44,04 | 3 |
| 1 | 200 | 1 | 39,99 | 2 |
| 1 | 200 | 2 | 43,73 | 3 |

| | | | | |
|---|-----|---|-------|---|
| 1 | 200 | 3 | 43,52 | 3 |
| 1 | 200 | 4 | 43,43 | 3 |
| 1 | 250 | 1 | 47,25 | 3 |
| 1 | 250 | 2 | 45,50 | 3 |
| 1 | 250 | 3 | 49,86 | 3 |
| 1 | 250 | 4 | 49,25 | 3 |
| 2 | 50 | 1 | 32,45 | 1 |
| 2 | 50 | 2 | 35,58 | 2 |
| 2 | 50 | 3 | 36,92 | 2 |
| 2 | 50 | 4 | 32,08 | 1 |
| 2 | 100 | 1 | 28,56 | 1 |
| 2 | 100 | 2 | 34,17 | 1 |
| 2 | 100 | 3 | 33,35 | 1 |
| 2 | 100 | 4 | 36,22 | 1 |
| 2 | 150 | 1 | 35,39 | 1 |
| 2 | 150 | 2 | 38,92 | 2 |
| 2 | 150 | 3 | 32,27 | 1 |
| 2 | 150 | 4 | 33,67 | 1 |
| 2 | 200 | 1 | 39,95 | 2 |
| 2 | 200 | 2 | 35,24 | 1 |
| 2 | 200 | 3 | 39,79 | 2 |
| 2 | 200 | 4 | 39,59 | 2 |
| 2 | 250 | 1 | 38,41 | 2 |
| 2 | 250 | 2 | 38,34 | 2 |
| 2 | 250 | 3 | 37,61 | 2 |
| 2 | 250 | 4 | 42,01 | 2 |

Fonte: Autoria Própria.

Para os testes de classificação foi realizado os mesmos procedimentos anteriores, sendo testados os 3 métodos de extração de características: Estatístico de texturização, GLCM e LBP, nos quais foram realizados seleção dos seus atributos através de correlação de Pearson e submetidos como entrada em uma RNA *Multilayer Perceptron* para predição de N.

Tabela 13: Classificação em 3 classes da análise química utilizando os três métodos de extração de características

| Dados de treinamento | Taxa de acerto sem seleção de atributos (%) | Taxa de acerto com seleção de atributos (%) |
|------------------------------|--|--|
| GLCM | 66,93 | 67,73 |
| LBP | 68,53 | 71,14 |
| Estatístico sem Texturização | 71,54 | 71,74 |
| Todos os métodos | 77,71 | 81,12 |

Fonte: Autoria Própria.

Nota-se na Tabela 13 que todos os métodos tiveram uma porcentagem de acerto na classificação acima de 66%, estes resultados sendo mais consistentes que os resultados utilizando regressão. A utilização de seleção de atributos também aumentou o acerto de todos os métodos, sendo o melhor resultado utilizando os 3 métodos de extração de características juntos e com seleção de atributos, chegando a uma porcentagem de acerto 81,12% sendo o melhor resultado deste trabalho. Para Romualdo (2013), o melhor resultado obtido foi de uma porcentagem de acerto de aproximadamente 83%, sendo muito próximo ao obtido neste trabalho, apesar da utilização de diferentes métodos de extração de características e classificação.

Nota-se que a classificação utilizando os 3 métodos de extração de característica juntos obtém uma precisão superior em relação à classificação com cada método separado, isso ocorre pois cada método extrai informações diferentes de cada folha, dando visões diferentes para a RNA, desta forma quando essas diferentes visões são combinadas em uma única RNA, é coerente que obtenha-se um resultado melhor. Nota-se também (Tabela 14) que todas as categorias obtiveram uma precisão na classificação superior a 0,77, não ocorrendo uma categoria que apresente uma precisão ruim, nem ocorrendo erros entre as classes 1 e 3, fatos que podem corroborar que a separação das categorias foi realizada de forma adequada.

Tabela 14 – Matriz de confusão da RNA utilizando o GLCM, LBP e Estatístico sem Texturização com 3 classes com seleção de atributos

| | Classificado como | | | Precisão |
|---|-------------------|----------|----------|----------|
| | Classe 1 | Classe 2 | Classe 3 | |
| 1 | 116 | 26 | 0 | 0,779 |
| 2 | 33 | 202 | 15 | 0,815 |
| 3 | 0 | 20 | 86 | 0,851 |

Obs: 0 até 36,66 = Classe 1; 36,67 até 43,32 = Classe 2; 43,33 até 50,00 = Classe 3

Fonte: Autoria Própria.

6 CONCLUSÃO

Com os estudos realizados neste trabalho obteve-se as seguintes conclusões:

- Os três métodos de extração de características obtiveram correlação superiores a 0,7 utilizando a análise química e seleção de atributos, porém o GLCM se sobressaiu aos outros dois obtendo uma correlação de 0,7454. Utilizando os dados de clorofila todos os métodos obtiveram resultados muito inferiores em relação aos resultados utilizando a análise química, portanto a utilização dos dados da análise química e a seleção de atributos é mais interessante, melhorando a precisão da diagnose de N na folha do feijoeiro.
- A junção dos três métodos de extração de características obteve uma melhora na diagnose de N, obtendo correlação 0,7635 também utilizando dados da análise química e fazendo seleção de atributos.
- Utilizando categorização em 3 classes para diagnosticar níveis de N na folhagem do feijoeiro obteve-se uma porcentagem de acerto de 81,12%, sendo superior à utilização de regressão, porém com esta categorização o sistema perde a capacidade de determinar valores pontuais de N.
- O desenvolvimento de um sistema automático para diagnóstico de N é bastante viável e sem a necessidade de um investimento podendo ser de grande ajuda para agricultores e profissionais do agronegócio. Porém com os resultados atuais existe um fator limitante, no qual consiste na necessidade de coleta de imagens no mesmo padrão de iluminação utilizado nos experimentos apresentados, para obtenção de resultados semelhantes aos vistos neste trabalho.

REFERÊNCIAS

ARGENTA, G.; SILVA, P.R.F. da; MIELNICZUK, J.; BORTOLINI, C.G. **Parâmetros de planta como indicadores do nível de nitrogênio na cultura do milho.** Pesquisa Agropecuária Brasileira, v.37, p.519-527, 2002.

AZEVEDO, J. A.; SILVA, E. M.; RODRIGUES, G. C.; GOMES, A. C. **Produtividade do feijão de inverno influenciada por irrigação, densidade de plantio e adubação em solo de Cerrado.** Planaltina, DF: Embrapa Cerrados, 2008. 3 p. (Embrapa Cerrados. Comunicado técnico, 145).

BAKER, R.; ISOTANI, S.; CARVALHO, A . **Mineração de dados educacionais: oportunidades para o brasil.** Revista brasileira de informática na educação, Cidade, v. 19, n. 2, 2011.

BARALDI, A.; PARMIGGIANI, F. **An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters.** Geoscience and Remote Sensing, IEEE Transactions on, v. 33, n. 2, p. 293–304, 1995. ISSN 0196-2892.

BAESSO, M.; PINTO, F. A. C; QUEIROZ, D. M.; VIEIRA, L. B.; ALVES, E. A.. **Determinação do "status" nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas.** Engenharia Agrícola, Jaboticabal, v. 8, n. 2, p.520-528, 1 mai. 2007.

BAESSO, M.; PINTO, F. A. C; QUEIROZ, D. M.; JUNIOR, D. G. S; JUNIOR, J. K. K.. **Determinação do Nível de Deficiência Nutricional de Nitrogênio Utilizando Redes neurais Artificiais.** Engenharia na Agricultura, Viçosa – MG. V.20, n.6, p. 512-518, 2012

CUNHA, G. B.; LUITGARDS-MOURA, J. F.; NAVES, E. L. M.; ANDRADE, A. O.; PEREIRA, A. A.; MILAGRE, S. T.. **A utilização de uma rede neural artificial para previsão da incidência da malária no município de cantá, estado de roraima.** sociedade brasileira de medicina tropical, set./out. 2010.

DUBEY, S. R.; Jalal, A. S., **Detection and Classification of Apple Fruit Diseases Using Complete Local Binary Patterns,** Conf. Comput. Commun. Technol., p. 346-351, 2012.

DWYER, L.M.; ANDERSON, A.M.; MA, B.L. **Quantifying the nonlinearity in chlorophyll meter response to corn leaf nitrogen concentration.** Canadian Journal of Plant Science, v.75, p.179-182, 1995.

FANQUIN, V. **Diagnose do Estado Nutricional das Plantas.** Universidade Federal de Lavras – UFLA,2002, Disponível em:

<Fonte:http://www.dcs.ufla.br/site/_adm/upload/file/pdf/Prof_Faquin/Diagnose%20do%20Estado%20Nutricional%20das%20Plantas.pdf > . Acesso em: 16 abr. 2017.

FILHO, D. B. F.; JÚNIOR, J. A. S. **Desvendando os Mistérios do Moeficiente de Correlação de Pearson** . Política hoje, Cidade, v. 18, n. 1, 2009.

FRANK, E. HALL, M.; HOLMES, G.; KIRKBY, R.; PFAHRINGER, B.; WITTEN, I. H.; TRIGG, L.. **Weka-a machine learning workbench for data mining**. Data mining and knowledge discovery handbook, p. 1269-1277, 2009.

GOLDSCHMIDT, R. G., **Uma Introdução à Inteligência Computacional**. 1 ed, Instituto Superior de Tecnologia do Rio de Janeiro, 2010.

GONZALES, R.C. and WOODS, R. E.. **Digital Image Processing**. 2 ed. Addison-Wesley Publishing Company, Reading, 2011.

GUO, Z.; ZHANG, L.; ZHANG, D. **A completed modeling of local binary pattern operator for texture classification**. iee transactions on image processing, Cidade, v. 19, n. 6, p. 1657-1663, jun. 2010.

GUPTA, N.. **Artificial neural network**. Network and complex systems, v. 3, n. 1, 2013.

HARALICK, R.M., K. SHANMUGAN, I. DINSTEIN, **Textural Fetures for Image**
SILVEIRA, P.M. BRAZ, A.J.B.P.; **Uso do Clorofilômetro como Indicador da Necessidade de Adubação Nitrogenada em Cobertura no Feijoeiro**. Pesquisa Agropecuária Brasileira, V.38, P.1083-1087,2003.

KAEHLER, A; BRADISKI, G. **Learning OpenCV: Computer Vision with the OpenCV Library**. Sebastopol, CA. O'Reilly. 2008.

KARCHER, D.E.; RICHARDSON, M.D. **Quantifying turfgrass color using digital image analysis**. Crop Science, v.43, p.943-951, 2003.

KAWASHIMA S, NAKATANI M. **An algorithm for estimating chlorophyll content in leaves using a video camera**. Annals of Botany 81: 49-54, 1998.

PELEGRIN, R.; MERCANTE, F.M.; OTSUBO, I.M.N. & OTSUBO, A.A. **Resposta da cultura do feijoeiro à adubação nitrogenada e à inoculação com rizóbio**. R Bras Ci Solo, 33:219-226, 2009.

PENA, C. **Cultura do feijão**. 2015. Disponível em:
<<https://plantarcrecercolher.blogspot.com.br/2015/09/cultura-do-feijao-resumo.html>>. ACESSA em: 16 abr. 2017.

ROMUALDO, L. M. **Utilização de Visão Artificial para diagnóstico nutricionar de nitrogênio, fósforo, potássio e manganês em milho**. Universidade de São Paulo, 2013.

SARDAR, M. B.; AJIJ, S. **Fruit Recognition and its Calorie Measurement: An Image Processing Approach**. v. 98, n. 38, p. 18675-18678. 2016

SANT'ANA, E. V. P.; SANTOS, A. B.; SILVEIRA, P. M. **Adubação nitrogenada na produtividade, leitura spad e teor de nitrogênio em folhas de feijoeiro**. Pesquisa agropecuária tropical, Cidade, v. 40, n. 4, p. 491-496, out./dez. 2010.

SILVA, O. F. ; WANDER, A. E.. **O Feijão-Comum no Brasil Passado, Presente e Futuro**. Embrapa, 2013. Disponível em:
<https://www.researchgate.net/profile/Osmira_Silva/publication/257385091_O_feijao-comum_no_Brasil_passado_presente_e_futuro/links/00b495252bae080446000000/O-feijao-comum-no-Brasil-passado-presente-e-futuro.pdf>. Acesso em: 01 fev. 2018.

SILVA, W. A. da; COSTA, F. B.; BELTRÃO, N. E. M.; DANTAS, J. P.; JÚNIOR, F. F. A.; JÚNIOR, G. S. C. **Utilização de Redes neurais Artificiais na Identificação de Mamoeiras com Deficiência de Nitrogênio**. IV Encontro de Produção Científica da Embrapa Algodão, 2009.

SILVA, F. C.. **Manual de análises químicas de solos, plantas e fertilizantes**. 2 ed. Embrapa, 2009.

SILVEIRA, P. M.; FERREIRA, E. P. B.. **Índice de suficiência de nitrogênio determinado pelo clorofilômetro em feijão inoculado com rizóbio e sob adubação nitrogenada**. Embrapa arroz e feijão, Santo Antônio de Goiás, GO, 2016.

SOARES, H. R.; NETO, E. B.; BARRETO, L. P.; LIRA, R. M.; LUCENA, E. H. L.; LIMA, N. S.; SILVA, M. A.. **Comparação de Metodologias para Determinação N-Total em Tecido Vegetal**. Jornada de Ensino, Pesquisa e Extensão – JEPEX, UFRPE, 2013.

SOBRAL, A. **Bgslibrary: An OpenCV c++ Background Subtraction Library**. IX Workshop de Visão Computacional, 2013.

SORATTO, R. P.; ARF, M. A. C. C. **Teor de clorofila e produtividade do feijoeiro em razão da adubação nitrogenada**. Pesquisa Agropecuária Brasileira, Brasília, v. 39, n. 9, p. 895-901, set. 2014.

VAKILIAN, K.A.; MASSAH, J.. **Design, Development and Performance Evaluation of a Robot to Early Detection of Nitrogen Deficiency in Greenhouse Cucumber (Cucumis Sativus) with Machine Vision**. International Journal of Agriculture: Research and Review. V.2, N.4, p. 448-454, 2012

ZHANG, B.; GAO, Y.; ZHAO, S.; LIU, J.. **Local derivative pattern versus local binary pattern: face recognition with high-order local pattern descriptor**. IEEE transactions on image processing, Cidade, v. 19, n. 2, p. 533-544, 2010.