

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
DEPARTAMENTO DE INFORMÁTICA
MESTRADO EM COMPUTAÇÃO APLICADA

CLAUDIO KAPP JUNIOR

SENSORES DE REFLETÂNCIA ESPECTRAL E DESEMPENHO DA CULTURA DO
TRIGO EM RESPOSTA À ADUBAÇÃO NITROGENADA EM PLANTIO DIRETO

PONTA GROSSA
2013

CLAUDIO KAPP JUNIOR

SENSORES DE REFLETÂNCIA ESPECTRAL E DESEMPENHO DA CULTURA DO
TRIGO EM RESPOSTA À ADUBAÇÃO NITROGENADA EM PLANTIO DIRETO

Dissertação apresentada ao Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, como requisito parcial para obtenção do título de Mestre.

Orientador: Eduardo Fávero Caires.

Co-Orientadora: Alaine Margarete Guimarães.

PONTA GROSSA

2013

Ficha Catalográfica
Elaborada pelo Setor Tratamento da Informação Belém/UEPG

K17 Kapp Junior, Cláudio
Sensores de refletância espectral e desempenho da cultura do trigo em resposta à adubação nitrogenada em plantio direto / Cláudio Kapp Junior. Ponta Grossa, 2013.
75f.

Dissertação (Mestrado em Computação Aplicada), Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Eduardo Fávero Caires.

Co-orientadora: Alaine Margarete Guimarães

1. *Triticum aestivum* L. 2. Nitrogênio. 3. Clorofilômetro. 4. Crop Circle. 5. Redes neurais artificiais. I. Caires, Eduardo Fávero. II. Guimarães, Alaine, Margarete. III. Universidade Estadual de Ponta Grossa. Mestrado em Computação Aplicada. IV. T.

CDD: 630.2

TERMO DE APROVAÇÃO

Claudio Kapp Junior

“SENSORES DE REFLETÂNCIA ESPECTRAL E DESEMPENHO DA CULTURA DO TRIGO EM RESPOSTA À ADUBAÇÃO NITROGENADA EM PLANTIO DIRETO”.

Dissertação aprovada como requisito parcial para obtenção do grau de Mestre no Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, pela seguinte banca examinadora:



Orientador:

Dr. Eduardo Fávero Caires
UEPG



Dr. Fabrício Pinheiro Povh
FUNDAÇÃO ABC



Dr. Ivo Mário Mathias
UEPG

Ponta Grossa, 08 de março de 2013.

AGRADECIMENTOS

Gostaria de agradecer a Deus por todas as coisas boas que me proporciona, agora em especial, a realização deste trabalho.

Realizar um mestrado é um grande desafio. Um mestrado interdisciplinar aumenta um pouco este desafio, principalmente quando a interdisciplinaridade está em duas áreas que não são comuns à sua formação. Então, para chegar ao final você precisa de dois elementos básicos: (i) força de vontade, você precisa querer muito isso; (ii) estar cercado por pessoas boas, dispostas a te ajudar, tanto aquelas que você já conhece, quanto aquelas que você passa a conhecer no decorrer de sua caminhada. E são estas pessoas que eu gostaria de lembrar agora.

A minha família: pais Claudio e Sueli, irmãos Guilherme e Camila, e avós Pedro e Cecília, que são meu alicerce e ao mesmo tempo minha bússola que acabam de uma maneira outra ditando meus passos, seja pelos conselhos que ainda me prestam ou pelos ensinamentos de humanismo, ética e responsabilidade que já me deixaram. Agradeço também pelo incentivo e companheirismo que recebi de minha namorada no decorrer do curso.

Agradeço ao meu orientador Professor Dr. Eduardo Fávero Caires e minha Co-Orientadora Professora Dra. Alaine Margarete Guimarães que foram decisivos para meu aprendizado e desenvolvimento desta dissertação. Demonstrando paciência para entender minhas dificuldades, e uma didática com explicações sábias para esclarecer desde os conhecimentos básicos pertinentes às suas áreas, até o desenvolvimento das análises mais apuradas necessárias. Mestres em quais pretendo me espelhar durante a construção de minha carreira.

A todos os colegas com quais tive a oportunidade de freqüentar este curso, principalmente aqueles que em alguns momentos foram prestativos, em especial Anderson, Thalita, Cristian, Alison, Regiane e Karine.

Aos amigos que são a extensão de minha família, por sempre estarem ao lado proporcionando momentos de alegria que são extremamente importantes e necessários ao longo de qualquer jornada.

Ao pessoal do laboratório de solos, a Dirce e os estagiários do Professor Eduardo, estudantes de curso de Agronomia da UEPG, com os quais passei um período do curso, e demonstraram-se sempre prestativos para ensinar e ajudar no desenvolvimento das análises laboratoriais.

Agradecer à Universidade Estadual de Ponta Grossa, a todos aqueles que manteve contato no decorrer do curso, principalmente os professores do Programa de Pós Graduação em Computação Aplicada com os quais tive a oportunidade de ser avaliado nestes dois anos.

RESUMO

O sistema plantio direto com rotação diversificada de culturas tem sido apontado como uma das melhores estratégias para aumentar a sustentabilidade da agricultura em regiões tropicais e subtropicais. Uma das culturas de maior importância nessa rotação durante a estação de outono–inverno é o trigo (*Triticum aestivum* L.). O nitrogênio (N) é um dos nutrientes extraídos em maior quantidade pelas plantas, sendo essencial para a estrutura e funções nas células, para todas as reações enzimáticas e faz parte das moléculas de clorofila. Os fertilizantes nitrogenados representam parte significativa dos custos da produção agrícola e, em razão da dinâmica do N no solo, perdas consideráveis de N podem ocorrer e causar prejuízos econômicos e ambientais. Em uma mesma área agrícola podem existir demandas variáveis por este nutriente. Os atributos da planta mais utilizados como indicadores de N são o teor de NO_3^- no colmo, o teor de clorofila, a intensidade da cor verde e o teor de N na folha bandeira, a produção de matéria seca da parte aérea e a extração de N pelas plantas. Níveis baixos de N podem ocasionar deficiência de clorofila que é reconhecida pela coloração pálida ou mesmo esbranquiçada da folha, e esta variação de coloração da planta pode ser identificada por meio de técnicas de sensoriamento remoto. Este trabalho teve o objetivo de estudar as correlações entre dados de refletância espectral obtidos por sensores terrestres comerciais (Clorofilog 1030, GreenSeeker e Crop Circle ACS-470) e atributos de desempenho da cultura do trigo em resposta à doses de N aplicadas em cobertura no sistema plantio direto. A eficiência dos sensores foi avaliada de duas maneiras: (i) por meio de métodos estatísticos clássicos e (ii) por meio da aplicação de Redes Neurais Artificiais com uso da técnica de aprendizado de máquina, software MatLab. Para a utilização de Redes Neurais Artificiais, este trabalho comparou o desempenho dos algoritmos *Backpropagation* e *Resilient Propagation*. Os resultados mostraram que as leituras do Clorofilog 1030 não foram sensíveis às variações das doses de N aplicadas em cobertura na cultura do trigo, pois as plantas de trigo apresentaram bom estado nutricional, mesmo sem aplicação de N em cobertura. Logo, este sensor também não teve correlação significativa com o teor de N na folha bandeira, a produção de matéria seca da parte aérea e a extração de N pelas plantas de trigo. Os índices obtidos pelos sensores de refletância Crop Circle e GreenSeeker tiveram estreita correlação com as doses de N aplicadas em cobertura, a produção de matéria seca da parte aérea e a extração de N pelas plantas de trigo. Os sensores Crop Circle e GreenSeeker apresentaram correlação mais fraca com o teor de N no tecido foliar e, principalmente, com a produtividade de grãos de trigo. Isso aconteceu porque ficou bem evidenciado que a produtividade de grãos não acompanhou os ganhos de matéria seca da parte aérea do trigo, quando os rendimentos de grãos de trigo foram elevados. Os coeficientes de correlação obtidos pelos algoritmos *Backpropagation* e *Resilient Propagation* foram semelhantes aos encontrados pelas análises estatísticas. A técnica de Redes Neurais Artificiais teve comportamento satisfatório e similar aos métodos estatísticos clássicos.

Palavras-chave: *Triticum aestivum* L., nitrogênio, clorofilômetro, Crop Circle, GreenSeeker, NDVI, SR, Redes Neurais Artificiais.

ABSTRACT

No-till systems with diversified crop rotations have stood out of the most effective strategies to improve the sustainability of farming in tropical and subtropical regions. Wheat (*Triticum aestivum* L.) is one of the most important crops used in this rotation during the autumn-winter season. Nitrogen (N) is uptake in larger amounts by plants, it is essential for the structure and functions in the cell, for all enzymatic reactions and is part of the chlorophyll molecules. Nitrogen fertilizers represent a significant part of the costs of production and due to the dynamics of N in soil, losses of N occur and cause economic and environmental damages. In the same agricultural area may exist changing demands for this nutrient. The attributes of the plant commonly used as indicators of N are NO_3^- content in stem, leaf chlorophyll content, the intensity of the green color and the N foliar content, dry biomass, and the extraction of N by plants. Lower levels of N can cause chlorophyll deficiency that is recognized by whitish or pale foliar coloration, and this changing in plant color can be identified using remote sensing techniques. This study aimed to evaluate the correlations between spectral reflectance data obtained by commercial ground sensors (Clorofilog 1030, GreenSeeker, and Crop Circle ACS-470) and attributes of wheat crop in response to N rates in top dressing under a no-till system. The efficiency of the sensors was evaluated in two ways: (i) by classical statistical methods, and (ii) through the application of Artificial Neural Networks, a machine learning technique. For the use of Artificial Neural Networks, this study compared the performance of the algorithms *Resilient Propagation* and *Backpropagation*. Because wheat plants exhibited adequate nutritional status, even without N application in top dressing, Clorofilog 1030 readings were not sensitive to variations of N rates. Thus, this sensor also did not correlate significantly with the N foliar content, dry biomass, and the extraction of N by wheat plants. The indices obtained by reflectance sensors Crop Circle and GreenSeeker had close correlation with the rates of N in top dressing, dry biomass, and the extraction of N by wheat plants. The Crop Circle and GreenSeeker sensors showed weaker correlation with the N content in leaves, and especially with the wheat grain yield. In this way, it was evident that grain yield has not followed the dry biomass production when high wheat grain yields were obtained. The correlation coefficients obtained by the *Resilient Propagation* and *Backpropagation* algorithms were similar to those found by statistical analysis. The Artificial Neural Networks technique had satisfactory behavior similar to classical statistical methods.

Keywords: *Triticum aestivum* L., nitrogen, chlorophyll meter, Crop Circle, GreenSeeker, NDVI, SR, Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1: Espectro eletromagnético.....	22
Figura 2: Diagrama conceitual ilustrando os espectros de refletância de uma folha saudável.....	24
Figura 3: Modelo matemático de um neurônio, proposto por McCulloch e Pitts.....	34
Figura 4: Modelo Perceptron Multi Camadas, com uma camada oculta.	37
Figura 5: Croqui da área experimental contendo as doses (D) e os fertilizantes (F) à base de N-ureia no delineamento de blocos completos ao acaso em esquema fatorial 4 × 3, com quatro repetições.	41
Figura 6: Precipitação pluvial média mensal ocorrida durante o período de desenvolvimento da cultura do trigo em 2011, e precipitação pluvial média mensal de 48 anos em Ponta Grossa – PR.....	42
Figura 7: Concentração de nitrogênio na folha-bandeira do trigo em função de doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$	45
Figura 8: Produção de matéria seca da parte aérea de plantas de trigo em função de doses de nitrogênio aplicadas em cobertura. *: $P < 0,05$	45
Figura 9: Extração de N pelas plantas de trigo em função de doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$	46
Figura 10: Produtividade de grãos de trigo influenciada pelas doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$	47
Figura 11: Massa de 1000 grãos de trigo influenciada pelas doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$	48
Figura 12: Leitura do Clorofilog 1030 influenciada pelas doses de nitrogênio aplicadas em cobertura na cultura do trigo.	48
Figura 13: Correlação entre as leituras do clorofilômetro e o teor de nitrogênio na folha-bandeira (a), a produção de matéria seca da parte aérea (b) e a extração de nitrogênio pelas plantas de trigo (c).	49
Figura 14: Correlações entre os índices do Crop Circle e as doses de nitrogênio aplicadas em cobertura na cultura do trigo. **: $P < 0,01$	50
Figura 15: Correlações entre os índices do GreenSeeker e as doses de nitrogênio aplicadas em cobertura na cultura do trigo. **: $P < 0,01$	51
Figura 16: Correlações entre as leituras dos sensores Crop Circle e Greenseeker e os teores de nitrogênio na folha bandeira do trigo, considerando todos os valores obtidos (n = 144). **: $P < 0,01$	52
Figura 17: Correlações entre as leituras dos sensores Crop Circle e Greenseeker e os teores de nitrogênio na folha bandeira do trigo, considerando os valores médios de cada parcela (n = 48). **: $P < 0,01$	53
Figura 18: Correlações entre as leituras dos sensores Crop Circle e Greenseeker e a produção de matéria seca da parte aérea das plantas de trigo, considerando todos os valores obtidos (n = 144). **: $P < 0,01$	54

Figura 19: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e a produção de matéria seca da parte aérea das plantas de trigo, considerando os valores médios de cada parcela (n = 48). **: $P < 0.01$.	55
Figura 20: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e a extração de N pelas plantas de trigo, considerando todos os valores obtidos (n = 144). **: $P < 0,01$.	56
Figura 21: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e a extração de N pelas plantas de trigo, considerando os valores médios de cada parcela (n = 48). **: $P < 0.01$.	57
Figura 22: Correlação entre a leitura de NDVI do GreenSeeker e a produtividade de grãos de trigo. **: $P < 0,01$.	58
Figura 23: Correlação entre a leitura de NDVI do Crop Circle e a produtividade de grãos de trigo. **: $P < 0,01$.	58
Figura 24: Correlação entre o INSEY obtido pela leitura de NDVI aos 91 dias após a semeadura do GreenSeeker e a produtividade de grãos de trigo. **: $P < 0,01$.	59
Figura 25: Correlação entre o INSEY obtido pela leitura de NDVI aos 91 dias após a semeadura do Crop Circle e a produtividade de grãos de trigo. **: $P < 0,01$.	59
Figura 26: Correlação entre a produção de matéria seca da parte aérea e a produtividade de grãos de trigo. *: $P < 0,05$.	60

LISTA DE TABELAS

Tabela 1: Divisão do espectro eletromagnético.....	23
Tabela 2: Resultados das análises de correlação entre as leituras dos sensores e os atributos da cultura do trigo	61
Tabela 3: Resultados das Redes Neurais Artificiais para estimativa de N na folha bandeira de acordo com a leitura dos sensores Crop Circle e GreenSeeker.....	62
Tabela 4: Resultados das Redes Neurais Artificiais para estimativa da produção de matéria seca da parte aérea do trigo de acordo com a leitura dos sensores Crop Circle e GreenSeeker	63
Tabela 5: Resultados das Redes Neurais Artificiais para estimativa da extração de N pelas plantas de trigo de acordo com a leitura dos sensores Crop Circle e GreenSeeker.....	64
Tabela 6: Resultados gerais do desempenho dos algoritmos <i>Backpropagation</i> e <i>Resilient Propagation</i>	65

SUMÁRIO

1. INTRODUÇÃO	12
2. OBJETIVOS.....	14
2.1. Objetivo geral	14
2.2. Objetivos específicos	14
3. REVISÃO DE LITERATURA	15
3.1. Cultura do trigo.....	15
3.2. Nitrogênio (N) e Clorofila.....	15
3.2.1. Dinâmica do nitrogênio (N) no solo	16
3.2.2. Nitrogênio (N) nas plantas.....	18
3.2.3. Clorofila	19
3.2.4. Produção de matéria seca e indicadores de nitrogênio (N) nas plantas	20
3.3. Sensoriamento remoto	21
3.3.1. Sensores de refletância espectral e monitoramento de atributos de plantas ..	24
3.3.2. Clorofilômetros	26
3.3.3. GreenSeeker	27
3.3.4. Crop Circle	29
3.3.5. Índices e cálculos	29
3.4. Aprendizado de Máquina (AM).....	32
3.4.1. Redes Neurais Artificiais (RNAs).....	33
4. MATERIAL E MÉTODOS	40
4.1. Descrição do local e do solo.....	40
4.2. Delineamento experimental, tratamentos e condução da cultura do trigo	40
4.3. Avaliações realizadas na cultura do trigo	42
4.4. Análises Estatísticas	43
4.5. Redes Neurais Artificiais	43
5. RESULTADOS E DISCUSSÃO	45
5.1. Doses de nitrogênio (N) e atributos da cultura do trigo	45
5.2. Leitura dos sensores e atributos da cultura do trigo	48
5.2.1. Clorofilog 1030	48
5.2.2. Crop Circle e Greenseeker.....	50
5.2.3. Síntese das análises de correlação entre as leituras dos sensores e os atributos da cultura do trigo	61
5.3. Redes Neurais Artificiais	61

5.3.1. Redes Neurais Artificiais na correlação entre concentração de N na folha bandeira e leituras dos sensores Crop Circle e GreenSeeker.....	61
5.3.2 Redes Neurais Artificiais na correlação entre produção de matéria seca da parte aérea do trigo e leituras dos sensores Crop Circle e GreenSeeker	62
5.3.3. Redes Neurais Artificiais na correlação entre extração de N pelas plantas de trigo e leituras dos sensores Crop Circle e GreenSeeker	63
5.3.4. Resultados gerais de correlação das Redes Neurais Artificiais considerando a leitura dos sensores e os atributos da cultura do trigo	65
6. CONCLUSÕES	67
7. TRABALHOS FUTUROS.....	69
8. REFERÊNCIAS BIBLIOGRÁFICAS	70

1. INTRODUÇÃO

O sistema plantio direto com rotação diversificada de culturas tem sido apontado como uma das melhores estratégias para aumentar a sustentabilidade da agricultura em regiões tropicais e subtropicais, contribuindo para reduzir perdas de solo e de nutrientes por erosão. Nesse sistema de cultivo ocorrem consideráveis aumentos no conteúdo de matéria orgânica, principalmente nas camadas superficiais do solo, em decorrência da deposição de resíduos de plantas e da ausência de revolvimento. O aumento do conteúdo de matéria orgânica resulta em incrementos na capacidade de troca catiônica (CTC) e na atividade biológica. O sistema plantio direto tem apresentado rápido crescimento em área cultivada no Brasil, ocupando atualmente mais de 27 milhões de ha.

O nitrogênio (N) é um dos nutrientes exigidos em maiores quantidades pela maioria das plantas cultivadas, sendo fundamental para o crescimento vegetativo e para o processo fotossintético. Como a maior parte do N do solo (97-98%) se encontra na forma orgânica, as necessidades de N pelas culturas, especialmente cereais, têm que ser supridas pela adubação nitrogenada.

Os fertilizantes nitrogenados representam parte significativa dos custos da produção agrícola e, em razão da dinâmica do N no solo, perdas consideráveis de N podem ocorrer, podendo causar inclusive prejuízos ambientais. Em uma mesma área agrícola podem existir demandas variáveis por este nutriente. Por este motivo, estuda-se a distribuição do fertilizante nitrogenado seguindo os princípios da agricultura de precisão, que consiste em técnicas que avaliam as variadas características encontradas ao longo de uma mesma área, em todo o ciclo da produção agrícola, permitindo análises, intervenções e correções das culturas em taxa variável.

Para o desenvolvimento da agricultura de precisão, vêm sendo realizados estudos envolvendo equipamentos de tecnologia agregada, como a utilização de sensores de refletância espectral, que consistem em aparelhos capazes de absorver faixas de luz refletidas pelas plantas e mensurá-las para que possam ser interpretadas.

Os valores obtidos pelos sensores podem ser associados aos atributos de desempenho relacionados com a disponibilidade de N em cereais, como o trigo (*Triticum aestivum* L.), cultivado na região dos Campos Gerais do Paraná como

opção durante a estação de outono–inverno para a rotação de culturas no sistema plantio direto.

Os estudos com sensores normalmente utilizam métodos estatísticos para identificar o índice de correlação entre os dados de refletância coletados pelos sensores e os atributos de desempenho das plantas no campo. Visando aumentar a eficiência desse procedimento pode-se adotar o aprendizado de máquina (AM), um ramo da inteligência artificial que visa desenvolver métodos para o computador “aprender” um determinado padrão de comportamento de variáveis a partir de dados obtidos com eventos ocorridos. Uma das técnicas de AM consiste nas Redes Neurais Artificiais (RNAs), a qual tem sido uma boa opção na estimativa de valores de atributos numéricos.

2. OBJETIVOS

2.1. Objetivo geral

Este trabalho teve como objetivo geral estudar as correlações entre dados de refletância espectral obtidos por sensores e atributos de desempenho da cultura do trigo em resposta à adubação nitrogenada em sistema plantio direto, por meio de métodos estatísticos clássicos e de técnicas de AM baseadas em RNAs.

2.2. Objetivos específicos

Os objetivos específicos deste trabalho foram: (i) avaliar o desempenho da cultura do trigo e de sensores de refletância espectral frente a doses de N aplicadas em cobertura, (ii) estudar as correlações entre as leituras dos sensores e os atributos de desempenho da cultura do trigo por meio de métodos estatísticos clássicos, (iii) aplicar técnicas de AM baseadas em RNAs para a obtenção de padrões de comportamento dos dados e (iv) avaliar o desempenho dos sensores de refletância espectral em função das correlações encontradas pelos métodos estatísticos clássicos e pelas técnicas de AM baseadas em RNAs.

3. REVISÃO DE LITERATURA

A seguir são apresentados conceitos e assuntos que abrangem duas áreas da ciência: (i) a agricultura, abordando temas relacionados com a adubação nitrogenada na cultura do trigo em sistema plantio direto e sua relação com o uso de sensores de refletância espectral, e (ii) a computação, abordando temas referentes às técnicas de AM baseadas em RNAs.

3.1. Cultura do trigo

O trigo é um cereal utilizado na composição da alimentação humana e animal. De acordo com Scheren (2006), o trigo está classificado como membro da família *Poaceae* e do gênero *Triticum*. Existem várias espécies desse cereal, sendo a espécie *Triticum aestivum* a mais cultivada no mundo (ARENDT, 2006). Outra espécie cultivada é o *Triticum durum* (trigo duro), utilizado na América do Norte, Europa, Norte da África, Rússia, Índia e alguns países do Oriente Médio. Existem ainda espécies que são fonte de material genético, sem expressividade em cultivo para consumo.

O cultivo de trigo aparece como uma opção para a rotação de culturas no sistema plantio direto, auferindo ganhos para o produtor com a cobertura do solo, podendo trazer também ótimos resultados financeiros ao apresentar produtividade satisfatória.

Na safra 2012, a produção de trigo (*Triticum aestivum*) no Brasil foi de aproximadamente 5,8 milhões de toneladas de grãos, concentrando-se nos estados do Paraná (42%) e Rio Grande do Sul (47%), sendo o restante distribuído em outros estados (BRASIL. Ministério da Agricultura Pecuária e Abastecimento, 2012). A produtividade de trigo prevista para a safra 2013 deve ficar em aproximadamente 2.560 kg ha⁻¹, cerca de 4% menor que a safra passada, que foi de 2.640 kg ha⁻¹ (BRASIL. Ministério da Agricultura Pecuária e Abastecimento, 2012). Fatores como clima, sanidade e nutrientes disponíveis para o desenvolvimento das plantas de trigo podem ser decisivos para a cultura apresentar boa produtividade.

3.2. Nitrogênio (N) e Clorofila

O N exerce efeitos rápidos e pronunciados sobre o desenvolvimento do trigo, e o principal processo bioquímico afetado na planta é a síntese proteica, tendo como função básica estimular o crescimento vegetativo (CRUZ, 2003). Os seus principais

componentes são as proteínas, sendo que o N também controla a absorção de potássio (K), fósforo (P) e outros nutrientes. Em condições de deficiência de N, as folhas são pequenas, e os caules são finos. A produtividade está altamente relacionada com a disponibilidade de N, a qual pode influenciar diretamente o número e o tamanho das espigas; o número, o peso dos grãos e sua qualidade, influenciando o teor de proteína bruta.

Tasca (2009) enfatiza que o N nas plantas participa de processos vitais, sendo essencial para a estrutura e funções das células, para todas as reações enzimáticas, faz parte da molécula de clorofila, é indispensável para a fotossíntese, é componente das vitaminas biotina, tiamina, niacina e riboflavina; das proteínas, e tem função na produção e uso de carboidratos.

Na agricultura, mesmo em áreas consolidadas no sistema plantio direto, a quantidade de N presente no solo pode não ser capaz de atender a necessidade das culturas, sendo necessário o uso de fertilizantes nitrogenados para suprir essa demanda. Em estudo com a cultura do trigo, Benett et al. (2011) verificaram aumento na concentração de clorofila promovido pelo aumento das doses de N empregadas na adubação nitrogenada, e também observaram aumento no número de espiguetas por espiga e na granação pelo maior número de grãos por espiga, quando utilizaram N em cobertura.

A quantidade de energia necessária para a produção de 1 kg de N, de P_2O_5 e de K_2O , respectivamente, é de aproximadamente 16.800 kcal, 3.040 kcal e 2.100 kcal (TASCA, 2009). Portanto, o custo energético para obtenção de 1 kg de N é 5,5 vezes maior em relação à produção de 1 kg de P_2O_5 e 8 vezes maior do que o necessário para produzir 1 kg de K_2O .

Os principais fertilizantes nitrogenados utilizados na agricultura são a ureia (aproximadamente 45% de N), o sulfato de amônio (aproximadamente 20% de N) e o nitrato de amônio (aproximadamente 32% de N). Os fertilizantes nitrogenados demandam um desembolso relativamente alto de recursos financeiros, e seu manejo é de extrema complexidade em razão da dinâmica do N no solo.

3.2.1. Dinâmica do nitrogênio (N) no solo

O maior reservatório de N está na atmosfera, com 78% desse nutriente em sua composição na forma de N_2 . Apesar da abundância de N_2 na atmosfera, a

grande maioria das plantas somente absorve o N em formas minerais, de amônio (NH_4^+) e nitrato (NO_3^-).

A fixação do N_2 atmosférico no solo pode ocorrer por descargas energéticas de relâmpago, as quais separam as moléculas de N. Isso permite a sua ligação com moléculas de oxigênio presentes no ar, formando monóxido de nitrogênio (NO) e, posteriormente, sendo dissolvido na água da chuva e depositado no solo. A fixação do N_2 também pode se dar por processo biológico por meio de bactérias que contém a enzima nitrogenase, de vida livre ou que apresentam relação de simbiose com as plantas e vivem nos nódulos das raízes, realizando a reação de fixação do N_2 caracterizada pela sua redução a NH_3 . Existe ainda a fixação industrial do N_2 por meio da produção de amônia (NH_3), a qual é incorporada a fertilizantes que são, posteriormente, distribuídos no solo.

O N no solo encontra-se predominantemente em compostos orgânicos (97-98%) e apenas 2-3% nas formas minerais, de NH_4^+ e NO_3^- . O N presente no solo pode apresentar uma série de transformações, dentre elas:

a) Mineralização: processo em que o N orgânico é transformado em N mineral por meio da decomposição da matéria orgânica.

b) Nitrificação: processo em que o íon NH_4^+ é transformado no íon NO_3^- . Segundo Ernani (2005), a nitrificação normalmente é indesejável porque em solos brasileiros predominam cargas negativas nos valores de pH utilizados para a produção agrícola e, portanto, não ocorre a retenção do NO_3^- nas partículas coloidais do solo. Com isso, o NO_3^- está sujeito à lixiviação, diferentemente do que ocorre com o NH_4^+ que, por possuir carga positiva, pode ser adsorvido eletrostaticamente às cargas negativas do solo.

c) Desnitrificação: conforme Tasca (2009) este processo representa a redução do N nítrico para formas gasosas que se perdem para a atmosfera (N_2 e N_2O). Esta reação ocorre somente em solos com baixa disponibilidade de O_2 , porque os microrganismos anaeróbios utilizam o oxigênio do nitrato como receptor de elétrons na cadeia respiratória.

d) Imobilização: processo no qual o N mineral é transformado em compostos orgânicos participando da composição de plantas ou microorganismos. Conforme Vargas, Selbach e Sá (2005), se por um lado a biomassa microbiana imobiliza o N mineral, diminuindo a sua disponibilidade para as culturas, por outro lado, pode se constituir em uma fonte de N potencialmente mineralizável. Os nutrientes presentes

na comunidade microbiana podem atingir valores elevados, mas a sua reciclagem e liberação são mais rápidas, se comparadas a outras frações da matéria orgânica do solo. Ocorrendo a morte dos microrganismos, estes são rapidamente mineralizados pelos microrganismos remanescentes, liberando os nutrientes imobilizados no processo conhecido como remineralização.

e) Volatilização: passagem do N do solo para a atmosfera, em que o NH_4^+ passa para a forma de NH_3 (gás). Conforme Scivittaro et al (2010) a ureia apresenta reação inicial alcalina no solo, e isso acarreta em perdas por volatilização de amônia. Quando aplicada em superfície, parte dela geralmente é hidrolisada, por meio da urease, uma enzima extracelular produzida por bactérias, actinomicetos e fungos do solo ou, ainda, originada de restos vegetais. Como resultado da hidrólise, tem-se a formação de carbonato de amônio, sendo que este não é estável e se desdobra em NH_3 , CO_2 e H_2O . Segundo Tasca et al. (2011), recentemente, alguns compostos químicos, entre eles o tiofosfato de N-butiltriamida (NBPT), têm sido misturados à ureia com o objetivo de diminuir a velocidade de hidrólise da ureia, por meio da inibição da atividade da urease, diminuindo assim a quantidade de NH_3 volatilizada.

f) Lixiviação: representa a perda de N-NO_3^- em profundidade no solo. Sangoi (2003) afirma que o NO_3^- é a forma mineral de N predominante nos solos sem restrição de oxigênio. Devido ao predomínio de cargas negativas na camada arável, a sua adsorção eletrostática é insignificante. Desta forma, o NO_3^- permanece na solução do solo favorecendo sua lixiviação no perfil para profundidades inexploradas pelas raízes. A lixiviação de NO_3^- é considerada a principal perda do N disponível às plantas. Fatores como sistemas de preparo do solo, tipo de solo e formas de aplicação dos fertilizantes nitrogenados podem influenciar tanto o fluxo de água quanto a concentração de NO_3^- na solução do solo.

Koch et al. (2004) explicam que podem haver demandas variáveis por N em uma mesma área agrícola, portanto na maioria das situações, é difícil prever a quantidade de N disponível no solo para a absorção pelas plantas.

3.2.2. Nitrogênio (N) nas plantas

O NO_3^- e o NH_4^+ são as principais formas de N absorvidas pelas plantas. O NO_3^- é absorvido pelas raízes e pode ser reduzido ou armazenado nos vacúolos, ou translocado para a parte aérea, onde será reduzido ou armazenado nos vacúolos

foliares. O primeiro passo na redução do NO_3^- ocorre no citosol e envolve a ação da enzima nitrato redutase, produzindo nitrito (NO_2^-), este adentra os plastídeos e cloroplastos em folhas, sendo reduzido a NH_4^+ por ação da enzima nitrito redutase, fixado via GS (Sintetase de Glutamina)/GOGAT (Sintase de Glutamato) em aminoácidos, glutamina e glutamato. Estes servem de substrato para reações de transaminação para a produção de todos os outros aminoácidos necessários para a síntese de proteínas (Taiz e Zeiger 2004, citados por BUSATO, 2007).

Dependendo da espécie de planta, do estágio de desenvolvimento e do órgão, a quantidade de N para o crescimento ótimo varia entre 2 a 5% do peso da matéria seca da planta. Quando o suprimento está abaixo do ótimo, o crescimento é retardado e o N é remobilizado das folhas mais velhas para as mais novas (regiões de crescimento), diminuindo a longevidade das folhas; neste caso, os sintomas típicos de deficiência de N podem ser observados. Um aumento no teor de N não somente decresce a senescência e estimula o crescimento, mas também altera a morfologia da planta de maneira típica, principalmente se a disponibilidade do N for alta na zona radicular durante o início do desenvolvimento (BONATO, et al. 1998).

De acordo com Taiz e Zeiger 2004 citados por Busato (2007), após ser assimilado nas folhas, o excedente de aminoácidos pode ser exportado por meio do floema. Nas raízes, o excesso é translocado para a parte aérea via xilema, estando assim os aminoácidos presentes nestes dois vasos transportadores de seiva, possibilitando adentrar as células adjacentes. Este processo irá depender da concentração externa para servir de suprimento para ápices, tecidos em desenvolvimento e órgãos reprodutivos.

Como o N é facilmente redistribuído na planta via floema, consequentemente as plantas deficientes em N apresentam os sintomas primeiramente nas folhas mais velhas, onde ocorre decréscimo no teor de clorofila (BUSATO, 2007).

3.2.3. Clorofila

Clorofilas são pigmentos naturais abundantes nas plantas. As clorofilas são essenciais para a conversão de energia luminosa em energia química, sendo assim relacionadas com a eficiência fotossintética das plantas e, consequentemente com sua adaptabilidade aos diferentes ambientes de crescimento (JESUS e MARENCO, 2008).

Segundo Streit et al. (2005) os pigmentos de fotossíntese presentes e a sua abundância variam de acordo com a espécie, e sua localização se dá nos cloroplastos. De acordo com Taiz e Zieger 2008 citados por Vieira et al. (2010) as clorofilas possuem N em sua composição e, para fazer parte destes pigmentos, o N deve ser absorvido da rizosfera pelas raízes.

A clorofila “a” (“Chl a”) está presente em todos os organismos que demandam oxigênio para a fotossíntese. As bactérias fotossintetizantes são desprovidas de “Chl a” e possuem em seu lugar a bacterioclorofila como pigmento fotossintético. A “Chl a” é o pigmento utilizado para realizar a fotoquímica (o primeiro estágio do processo fotossintético), enquanto que os demais pigmentos auxiliam na absorção de luz e na transferência da energia radiante para os centros de reação, sendo assim chamados de pigmentos acessórios. Os principais pigmentos acessórios também incluem outros tipos de clorofilas: clorofila “b” (“Chl b”), presente em vegetais superiores, algas verdes e algumas bactérias; clorofila “c” (“Chl c”), em feófitas e diatomáceas; e clorofila “d” (“Chl d”), em algas vermelhas (Taiz e Zieger 2004 citados por STREIT et al. 2005, p.749).

A deficiência de clorofila pode ser reconhecida pela coloração pálida ou mesmo esbranquiçada das folhas (clorose), e ocasiona uma considerável redução na intensidade fotossintética. A deficiência de clorofila muitas vezes ocorre no início do desenvolvimento das folhas, as quais se tornam amareladas. A destruição da clorofila ocorre também devido a uma radiação muito forte ou muito fraca, por uma perda no balanço em relação ao abastecimento mineral, em uma infecção virótica, ou ainda condicionada geneticamente, como em mutantes, com folhas totalmente amareladas (LARCHER, 2004). Essas variações na coloração das folhas das plantas devidas à deficiência de clorofila podem ser identificadas por meio de técnicas de sensoriamento remoto.

3.2.4. Produção de matéria seca e indicadores de nitrogênio (N) nas plantas

A produção de matéria seca de plantas é estudada com o intuito de se fazer associações desta com a concentração de determinados nutrientes nas plantas ou com as condições ambientais que incidiram ao longo do desenvolvimento da cultura.

De acordo com McDonald, Ericson e Larsson (1996), a distribuição de matéria seca entre os órgãos da planta é uma das variáveis chave afetando a sobrevivência, habilidade e desempenho de plantas. É o produto líquido da assimilação de carbono,

a partição de fotoassimiladores entre os órgãos e as perdas via exsudação, respiração e mortalidade dos órgãos. A matéria seca é afetada por muitas variáveis, incluindo a disponibilidade de nutrientes minerais na rizosfera e fluxo de nutrientes na raiz.

Espindula et al. (2010) e De Ros (2003) encontraram aumento da produção de matéria seca da parte aérea com doses crescentes de N na cultura do trigo. De acordo com Schroder et al. (2000), esses resultados são esperados pois o N contribui para o crescimento vegetativo das plantas, atuando nas taxas de iniciação e expansão foliar, no tamanho final das folhas e no alongamento do caule.

Para Scheible et al. (2004), a massa seca da raiz aumenta com o aumento da oferta de NO_3^- . Essa resposta da massa seca da raiz para NO_3^- é vista como um dos vários efeitos específicos desse nutriente, contribuindo para a regulação do metabolismo e arquitetura da planta. Alterações no fotoperíodo e no fornecimento de nutrientes, gás carbônico e água, podem afetar a distribuição de matéria seca entre a parte aérea e as raízes de plantas (RAVEN et al., 2005).

Os atributos da planta mais utilizados como indicadores de N são o teor de NO_3^- no colmo, o teor de clorofila, a intensidade da cor verde e o teor de N nas folhas, a produção de matéria seca da parte aérea e a extração de N pelas plantas (RAMBO et al., 2004).

3.3. Sensoriamento remoto

Todos os objetos do mundo real que estejam a uma temperatura acima de zero absoluto ($-273,15^\circ \text{C}$ ou zero Kelvin) apresentam uma movimentação aleatória das partículas dos átomos e das moléculas. Quando essas partículas se colidem elas mudam o seu estado de energia e emitem radiação eletromagnética (REM). E quanto maior é a temperatura da fonte, maior é a sua potência irradiante de energia (MENEZES e ALMEIDA, 2012).

Conforme informações do Instituto Nacional de Pesquisas Espaciais (INPE), a maior fonte de energia do sistema solar é o sol decorrente de sua temperatura elevada. Essa energia é irradiada para todo o espaço, propaga-se pelo vácuo e atinge a Terra. Galo et. al. (2002) comentam que a REM, dependendo da superfície e do intervalo espectral considerado, pode ser absorvida, transmitida ou refletida quando entra em contato com algum objeto na superfície terrestre.

Toda a informação visual que o ser humano percebe é resultado da refletância da REM no espectro do visível que o objeto refletiu. O espectro do visível é apenas uma parte do espectro eletromagnético, como ilustrado na Figura 1.




Figura 1: Espectro eletromagnético.
Fonte: Teng (2008).

É comum encontrar na literatura intervalos espectrais com limites um pouco diferenciados, de acordo com Menezes e Almeida (2012) a divisão mais aceita no sensoriamento remoto apresenta-se na tabela 1 que descreve os intervalos espectrais, bem como os respectivos comprimentos de onda.

Quando a radiação é transmitida e refletida, sua reflexão pode ser utilizada para observar alvos por meio do sensoriamento remoto, que é uma ciência que visa o desenvolvimento da obtenção de imagens da superfície terrestre por meio da detecção e medição quantitativa das respostas das interações da REM com os materiais terrestres, sem que haja contato físico de qualquer espécie entre o sensor e o objeto (MENEZES e ALMEIDA, 2012).

Para a aquisição e armazenamento de dados de sensoriamento remoto utilizam-se equipamentos que podem ser passivos – aqueles que recebem a REM natural (a principal fonte é o sol) e a transforma em informações – e ativos – que geram a REM de maneira artificial por meio de diodos instalados no próprio equipamento, capturam a refletância e a transformam em informações.

Os sensores ativo e passivo podem ter diferentes resoluções, as quais apresentam três parâmetros (NASCIMENTO e ABREU, 2012):

Tabela 1: Divisão do espectro eletromagnético.

Intervalo Espectral	Comprimento de Onda
Raios Cósmicos	$0,01 \text{ A}^0$
Raios gama	$0,01 - 0,1 \text{ A}^0$
Raios X	$0,1 - 10 \text{ A}^0$
Ultravioleta	$100 \text{ nm} - 0,38 \mu\text{m}$
Visível	$0,38 - 0,76 \mu\text{m}$
Infravermelho próximo	$0,76 - 1,2 \mu\text{m}$
Infravermelho de ondas curtas	$1,2 - 3,0 \mu\text{m}$
Infravermelho médio	$3,0 - 5,0 \mu\text{m}$
Infravermelho termal	$5,0 - 1 \text{ mm}$
Micro-ondas	$1 \text{ mm} - 100 \text{ cm}$
Rádio	$1 \text{ m} - 10 \text{ km}$
Áudio	$10 - 100 \text{ km}$
Corrente alternada	$> 100 \text{ km}$

Obs: $\text{A}^0 = 10^{-10} \text{ m}$; $\text{nm} = 10^{-9} \text{ m}$; $\mu\text{m} = 10^{-6} \text{ m}$

Fonte: Menezes e Almeida (2012).

a) Espacial: medida que dita a menor distância entre dois objetos que um sensor é capaz de identificar como diferentes entre si. Sendo assim, a menor parcela imageada representa o tamanho do pixel. Nesse caso, se existe uma resolução de 30 m, significa que 2 objetos distantes entre si em 30 m poderão ser distinguidos.

b) Espectral: relacionada com a faixa espectral que o sensor é capaz de trabalhar. A resolução espectral será tão maior quanto mais estreitas forem as faixas espectrais que este consegue trabalhar.

c) Temporal: tem relação com a frequência com que o imageamento passa sobre uma mesma área; quanto maior o número de vezes que ele passa, maior será a resolução temporal.

Dependendo das características de resolução, sensores podem ser acoplados em plataformas orbitais, aéreas e terrestres.

No nível orbital os sensores estão a bordo de satélites e estações espaciais, que estão localizados no espaço entre 400 e 36.000 km de altitude. No nível aéreo, são utilizados aviões que carregam os instrumentos sensores a bordo e estão em torno de 7 a 10 km de altitude. No nível terrestre, os instrumentos sensores estão a poucos metros da superfície terrestre, em torno de 50 cm a 30 m de altura. Dependendo do tipo de estudo a ser realizado ou projeto desenvolvido, são utilizados dados de diferentes níveis de coleta separadamente ou de forma combinada (SAUSEN, 2008).

Os sensores remotos representam grande utilidade para a sociedade devido às suas possibilidades de aplicabilidade como auxílio no planejamento urbano, projetos rodoviários, monitoramento de florestas, rios, entre outros. Na agricultura, uma das áreas de aplicação de técnicas de sensoriamento remoto é o monitoramento de atributos de plantas.

3.3.1. Sensores de refletância espectral e monitoramento de atributos de plantas

Com a utilização de sensores capazes de identificar a refletância em faixas isoladas, como no vermelho e infravermelho próximo, podem-se associar tais leituras com os teores de clorofila presentes nas plantas em tempo real, monitorando simultaneamente a nutrição nitrogenada, uma vez que o N encontra-se, em parte, nas moléculas de clorofila.

De acordo com Campbell 2002 citado por Inman e Khosla (2005), as moléculas de clorofila absorvem entre 70 e 90% de toda a luz incidente nas faixas de comprimento de onda do azul e vermelho, enquanto refletem a luz na faixa verde (Figura 2).




Figura 2: Diagrama conceitual ilustrando os espectros de refletância de uma folha saudável.
Fonte: Adaptado de Inman e Khosla (2005).

A quantidade de luz azul e vermelha absorvida pela folha é proporcional à densidade de clorofila da folha (Campbell 2002 citado por INMAN e KHOSLA, 2005).

A refletância da porção do infravermelho próximo do espectro eletromagnético (760-1.200 nm) é influenciada pelas células do mesófilo, que refletem cerca de 60% de toda radiação incidente perto da faixa do infravermelho, enquanto as camadas superiores da folha são quase transparentes a esta.

De acordo com Ramirez (2010), o sensoriamento remoto oferece uma alternativa para aplicação de N a taxa variável. Esta técnica baseia-se na mudança da interceptação de luz e a refletância da vegetação, indicando a cor da folha. Como as clorofilas são os principais contribuintes da cor verde, e seu principal componente é o N, quando ocorre falta da disponibilidade deste, a formação das moléculas de clorofila torna-se limitada e a cor verde das folhas é afetada.

Serrano, Filela e Penuelas (2000) explicam que os maiores níveis de clorofila, associados aos níveis de N, resultam em incremento da área foliar (biomassa). De acordo com Holland (2008), os sensores de refletância se baseiam no fato de que as plantas absorvem a luz visível, e refletem uma porção da luz do infravermelho, devido a propriedades estruturais da planta. A luz refletida é detectada pelo sensor e usada para fazer a mensuração da biomassa vegetativa que é diretamente proporcional à biomassa da planta.

As clorofilas podem ser estimadas pelo uso de medidores portáteis, permitindo medições instantâneas do valor correspondente ao seu teor na folha, podendo também correlacionar-se com o rendimento de grãos (RAMBO et al., 2004). Esses equipamentos têm sido aplicados para prever a necessidade de adubação nitrogenada.

De acordo com Thenkabail, Smith e Pauw (2000) uma das principais tarefas do sensoriamento remoto agrônomo é detectar as bandas espectrais sensíveis de reflexão da luz e seus parâmetros para indicação da situação das culturas, visando determinar a relação quantitativa entre propriedade espectral e característica agrônoma.

Conforme Zhu et al. (2006) as bandas espectrais para o monitoramento de N podem mudar de acordo com as espécies vegetais e as condições experimentais, como a fase em que a cultura se encontra. Xue et al. 2004 citados por Zhu et al. (2006) propuseram que na cultura do trigo, a concentração de N no tecido foliar pode ser refletida pelo índice espectral do dossel com base na reflexão de 660 e 440 nm, enquanto que o acúmulo de N foliar pode ser previsto com índice de vegetação de 1.220 e 660 nm. Stone et al. (1996) relataram que as bandas

espectrais de 671 e 780 nm, quando combinadas, podem estimar o índice espectral e indicar a concentração total de N na cultura do trigo.

Blackmer *et al.* (1996) constataram que a refletância próxima de 550 nm poderia discriminar as diferenças entre os tratamentos de N em milho e, em seguida, determinaram as bandas de 550 e 710 nm para o cálculo do índice espectral, apontando a concentração de N na cultura do milho.

Ao realizar a associação de leituras de refletância com adubação nitrogenada é preciso estar atento a algumas variáveis que podem afetar tal relação. Schepers (2008) comenta que o sintoma de estresse hídrico aparece mais rápido que as outras variáveis, com exceção de alguns herbicidas. As células dentro de uma folha que regulam a turgidez são responsáveis pela refletância da radiação NIR (*Near Infrared* – infravermelho próximo). O estresse hídrico também afeta a fotossíntese e a cor da folha, mas esses sintomas se tornam atrasados em relação ao efeito sobre a turgescência. O estágio da planta deve ser levado em consideração, pois este altera a estrutura da copa das culturas. O horário do dia afeta a evapotranspiração e a temperatura, influenciando principalmente os sensores passivos. A umidade presente nas folhas pode alterar as características de refletância, principalmente na banda do vermelho visível. Áreas agrícolas com diferentes cultivares devem também receber cuidados ao serem comparadas, pois a estrutura foliar e a arquitetura da copa são características definidoras de cultivares.

Dispositivos comerciais com sensores ópticos terrestres como GreenSeeker (NTech Industries, Inc., Ukiah, CA), CropCircle (Holand Scientific Inc., Lincoln, NE) e clorofilômetros (SPAD-502 - Konica Minolta, e Clorofilog 1030 - Falker Agricultural Automation), têm sido desenvolvidos para avaliar o teor de N em tempo real.

3.3.2. Clorofilômetros

De acordo com Malavolta, Vitti e Oliveira (1997), leitores de clorofila podem ser usados para avaliar o teor de N nas folhas, visto que clorofila e N se correlacionam positivamente. Os autores citam algumas vantagens para mensuração de teor de N por meio de medidores de clorofila, tendo em vista que (i) a leitura que indica o teor de N adequado não é afetada pelo consumo de luxo do elemento, pois a planta não produz clorofila além do que necessita, (ii) podem ser feitas leituras em quantas amostras desejar sem que sejam destruídas as folhas, e

(iii) o monitoramento do verde da folha pode sinalizar uma possível deficiência de N, antes mesmo que esta apareça, evitando redução na produção.

Os aparelhos SPAD-502 (Konica Minolta) e Clorofilog 1030 (Falker Agricultural Automation) são medidores portáteis de clorofila com especificações diferentes, mas com resultados semelhantes.

O clorofilômetro SPAD-502 possui diodos que emitem radiação em 650 nm (na faixa do vermelho visível - VIS) e 940 nm (radiação na faixa do infravermelho). Durante a mensuração, a luz passa pelas folhas, é recebida por um fotodiodo de silicone, sendo, então, convertida primeiramente em sinais elétricos analógicos e, depois, em sinais digitais. Esses sinais passam por um microprocessador que calcula os valores adimensionais SPAD (*Soil Plant Analysis Development*) proporcionais ao teor de clorofila presente na região medida (JESUS e MARENCO, 2008).

O medidor de clorofila Clorofilog 1030 opera com medições nas bandas espectrais de 635 nm e 660 nm (na região do VIS) e 850 nm (na região do infravermelho). O aparelho emite as frequências por meio de LEDs e recebe estes sinais para o processamento e mensuração, obtendo um valor em unidade adimensional – ICF (Índice de Clorofila Falker), proporcional ao teor de clorofila presente na região medida (Markwell et al. 1995 citados por BRITO et al., 2011).

A área da folha que é mensurada pelo Clorofilog é maior que a alcançada pelo sensor SPAD, o que pode resultar em menor interferência de algum ponto de outra coloração presente na região da leitura. Mesmo com diferenciais como número de sensores, bandas espectrais utilizadas e tamanho de área auferida, há grande correlação entre as medições feitas pelos sensores SPAD e Clorofilog. Brito et al. (2011) obtiveram um coeficiente de correlação igual a 0,99 entre as leituras dos dois sensores na cultura do algodão.

Com outros sensores óticos terrestres, como Crop Circle e Greenseeker, é possível a utilização de outros índices de leitura espectral, porém, com objetivos semelhantes aos dos clorofilômetros.

3.3.3. GreenSeeker

O GreenSeeker é um sensor desenvolvido pela Universidade de Oklahoma (EUA), na década de 1990 (atualmente produzido pela empresa NTech Industries, Inc., Ukiah, CA). Este sensor existe na versão passiva apenas recebendo radiação

refletida de fontes naturais de luz, e na versão ativa que, de acordo com Erdle, Mistele e Schmidhalter (2011), utiliza diodos emissores de luz (LEDs) como uma fonte de radiação e detecta a reflexão nas regiões espectrais do VIS e NIR. Este sensor tem sido utilizado para a gestão de N em culturas como milho e trigo.

O sensor foi projetado para trabalhar em uma distância de aproximadamente 81 a 121 cm das plantas. Sheiver, Khosla e Westfall (2011) comentam que o GreenSeeker ativo opera emitindo radiação na faixa vermelha VIS (650 ± 10 nm) ou verde VIS (550 ± 10 nm), assim como radiação na faixa do NIR (770 ± 15 nm) no dossel da planta. A quantidade de luz visível e NIR refletida pelo dossel de plantas é medida e, em seguida, é transmitida a um computador portátil adaptado ao sensor. Os arquivos são obtidos em formato “.CSV” para se transformar no formato desejado e, posteriormente, calcular os índices necessários. Com essas medidas, o software do sensor calcula o NDVI (*Normalized Difference Vegetation Index* – diferença normalizada do índice de vegetação) e mais algum outro índice de vegetação escolhido, podendo ser: SR (*Simple Ratio* - índice da razão simples), SAVI (*Soil Adjusted Vegetation Index* – índice de vegetação ajustado com o solo), CI (*Chlorophyll Index* – índice de clorofila), WDR-NDVI (*Wide Dynamic Range Vegetation Index* - ampla faixa dinâmica do índice de vegetação), ISR (*Inverse Simple Ratio* – inverso do índice da razão simples), o que permite comparar o comportamento dos índices ao mesmo tempo com os mesmos dados.

Conforme Schepers (2008) a energia é emitida a partir de diodos separados (VIS e NIR) em rajadas alternadas, emitindo pulso na fonte VIS em 1 ms e, depois, na fonte de NIR em 1 ms em 40.000 Hz. Cada explosão de uma determinada fonte equivale a aproximadamente 40 pulsos antes de uma pausa para o outro diodo emitir sua radiação (outros 40 pulsos). Assim, no final de cada segundo, quando as leituras são compiladas, tanto as faixas de ondas VIS e NIR representam 50 s de 40 pulsos cada um para um total de 2.000 explosões de luz. Durante os 40 pulsos de uma fonte de diodo, o sensor avança 0,07 polegadas (1,788 mm), ou cerca de 3% de sua área em 4 mph.

Isso pode não parecer significativo, mas pode se tornar importante quando se considera que a refletância de uma banda de frequências é apenas 97% da área registrada pelo outro diodo. Em 8 mph, a concordância reduz para 94% e, em 16 mph, para apenas 88%. Os alvos feitos os cálculos subsequentes não são os

mesmos, e os usuários devem esperar uma maior variabilidade nas leituras do sensor em altas velocidades.

3.3.4. Crop Circle

Conforme Samborsky, Tremblay e Fallon (2009), o Crop Circle ACS-210 (Holland Cientific, Lincoln, NE) é um sensor de luz semelhante ao GreenSeeker. Existe também nas versões ativo e passivo, porém com um design óptico e eletrônico diferente, resultando em diferentes características operacionais, como na emissão de radiação, este sensor emite luz através de uma fonte de LED, na faixa do VIS ($590 \pm 5,5 \text{ nm}$) e NIR ($880 \pm 10 \text{ nm}$). É utilizado um sistema duplo de fotodetecção, o que elimina a chance de haver interferência da amostra entre os sinais de refletância VIS e do infravermelho.

O sensor foi projetado para trabalhar em uma distância de aproximadamente 25 a 213 cm das plantas, e fornece um número de índice vegetativo clássico, bem como informações básicas de refletância de dosséis vegetais.

O Crop Circle ACS-470, é um modelo mais recente do sensor, possui seis filtros de banda espectral cada um com um diâmetro de 12,5 milímetros, detectando faixas espectrais entre 440 nm a 800 nm. Nessa versão, trabalha-se simultaneamente com três filtros para fotodetecção, fazendo combinações de cálculo entre os canais 1 e 2, e entre os canais 2 e 3. Recomenda-se que se alocar nos canais 1 e 3 filtros de banda espectral em faixas do VIS, no canal 2 deve-se alocar filtro de banda espectral em faixa do infravermelho, pois os cálculos dos índices tradicionais combinam, faixa do VIS com faixa do infravermelho.

Assim como no ACS-210, na versão ACS-470 todas as faixas de ondas (VIS e NIR) são projetadas simultaneamente, portanto a mesma área é gravada em cada um dos três receptores, diminuindo os riscos de haver interferência nas amostras.

Os dados seriais produzidos pelo sensor podem ser facilmente coletados usando um laptop, GeoSCOUT GLS-400 *datalogger*, PDA ou qualquer outro equipamento de aquisição de dados, sendo os arquivos obtidos em formato “.CSV”.

3.3.5. Índices e cálculos

Sensores como CropCircle e GreenSeeker emitem luz em comprimento de onda na faixa do VIS e do infravermelho próximo, conseguindo captar a refletância

dessa emissão. Esses dados então podem ser trabalhados para a construção de índices como NDVI, SR, SAVI, CI, WDR-NDVI.

Trotter et al. (2008) comentam que o NDVI está relacionado com a biomassa, a área foliar, a cobertura vegetal, a clorofila e o N. O NDVI satura quando o índice de área foliar é maior que 1,5; por isso o SR também tem sido investigado para prever áreas de biomassa com alta vegetação, uma vez que é menos suscetível à saturação.

O SAVI tem sido testado para trabalhar com a introdução de uma variável do solo, a qual pode ser dominante sobre a resposta da vegetação e ajudaria a melhorar a relação entre os índices de vegetação e da biomassa disponível. O CI é um índice que se correlaciona com o teor de clorofila presente nas folhas.

Conforme Ryan (1997), os cálculos dos índices são baseados no princípio de que plantas verdes absorvem fortemente a radiação na região visível do espectro ("PAR", ou "radiação fotossinteticamente ativa"), em decorrência da presença de clorofila, ao mesmo tempo em que refletem fortemente a radiação na região do infravermelho próximo.

O NDVI é calculado pela seguinte equação:

- $NDVI = (NIR - PAR) / (NIR + PAR)$.

onde,

PAR = Valor da radiação fotossinteticamente ativa, na região VIS; e

NIR = Valor da radiação do infravermelho próximo.

Segundo ainda Ryan (1997), essa equação produz um valor que varia de -1 (normalmente água), até +1 (crescimento vegetativo mais forte).

Para o cálculo de SR, utiliza-se a seguinte equação:

- $SR = NIR / PAR$.

O inverso do SR (ISR) é calculado pela equação:

- $ISR = PAR / NIR$.

Para o cálculo de CI, utiliza-se a seguinte equação:

- $CI = (NIR / PAR) - 1$.

Para o cálculo do SAVI, utiliza-se uma constante L, que varia de 0 a 1, dependendo do grau da maior ou menor cobertura do solo, respectivamente, por meio da seguinte equação:

- $SAVI = [(NIR - PAR) / (NIR + PAR + L)] \times (1 + L)$.

De posse dos índices, pode-se também buscar correlações entre estes e alguns atributos de desempenho da cultura, tais como: teor de N nas folhas, teor de N nos grãos, produção de matéria seca da parte aérea, extração de N pela planta, exportação de N pelos grãos e produtividade de grãos.

Grohs et al. (2009) encontraram relação entre NDVI e biomassa acumulada na parte aérea das plantas por ocasião da emissão da sexta folha em cultivares de trigo e cevada, por meio de função quadrática aplicada sobre essa relação. Isso levou à determinação do ponto de saturação do NDVI, ocorrendo quando a curva atingiu seu ponto de inflexão, sem prejuízos na manutenção da resposta do NDVI em função da biomassa.

Portz, Molin e Jasper (2012) detectaram alta correlação entre índices de refletância espectral, biomassa de cana-de-acúcar e absorção de N, apoiando assim o potencial de uso dessa tecnologia para desenvolver algoritmos para gerenciar aplicação em taxa variável de N para a cultura da cana-de-acúcar. Povh et al. (2008) encontraram correlação positiva das leituras de NDVI em resposta ao incremento de doses de N em relação ao tempo de desenvolvimento da cultura do trigo.

Eitel et al. (2011) utilizaram nas bandas 1, 2 e 3 do ACS-470 os respectivos filtros de 659-681 nm, 720-740 nm e > 760 nm para calcular os índices NDVI e CI, e obtiveram fortes correlações com a concentração de N presente nas folhas da cultura do trigo.

Para aumentar a eficiência de tais relações, além do aprimoramento dos métodos estatísticos convencionais, podem-se adotar tecnologias mais apuradas, como técnicas de AM.

3.4. Aprendizado de Máquina (AM)

Aprendizado de Máquina (AM) é o estudo de métodos, dirigidos a dados, capazes de imitar, compreender e auxiliar nas tarefas de processamento de informações humanas e biológicas. Nesse contexto, surgem várias questões relacionadas a forma de compactar, interpretar e processar os dados. Frequentemente, estes métodos não são necessariamente dirigidos a somente imitar o processamento humano, mas sim a melhorá-lo, como na previsão do mercado de ações ou na recuperação rápida de informações. No sentido mais amplo, o AM visa “aprender algo útil” sobre o ambiente em que o agente atua, estando intimamente associado a Inteligência Artificial (IA), sendo que o AM dá mais ênfase na utilização de dados para direcionar e adaptar um modelo (BARBER, 2012).

Silva, et al. (2008) citam que as técnicas de AM, por serem capazes aprender por si próprias, também representam uma alternativa atraente para lidar com problemas de ajuste de funções ou regressões.

Libralão et. al. (2005) comentam que o AM procura extrair conceitos a partir de amostras de dados e, segundo Monard e Baranauskas (2005) os diversos sistemas de AM possuem características particulares e comuns que possibilitam sua classificação quanto à linguagem de descrição, modo, paradigma e forma de aprendizado utilizado. Os autores citam ainda que a indução é a forma de inferência lógica da qual se pode extrair conclusões gerais, da parte para o todo. Pode-se obter assim um conceito por meio de inferência indutiva, podendo ou não representar a verdade, mesmo assim, é um dos principais métodos para derivar conhecimento novo e prever eventos futuros. O aprendizado indutivo é efetuado a partir de raciocínio sobre exemplos fornecidos por um processo externo ao sistema de aprendizado.

Existem diversos algoritmos de AM que, após um período de treinamento, permitem a interpretação de novos dados e sua classificação de maneira apropriada, a partir de uma generalização do que lhe foi apresentado durante o treinamento (Libralão et al., 2005).

O AM pode ser classificado de diferentes maneiras, porém o mais comum é dividir em aprendizado supervisionado e não supervisionado (ARTERO, 2009). No primeiro o foco está na acurácia da predição, enquanto que no segundo o objetivo é encontrar descrições compactas dos dados. Em ambos os casos o interesse está

em métodos que generalizem bem dados inéditos. Neste sentido, distingue-se entre os dados que são usados para formar um modelo e os dados que são usados para testar o desempenho do modelo treinado (BARBER, 2012).

O AM Supervisionado pode ser definido como: Dado um conjunto de dados $D = \{(x^n, y^n), n=1, \dots, N\}$ a tarefa é aprender o relacionamento entre a entrada x e a saída y tal que, quando dado uma nova entrada x^* a saída predita y^* esteja correta. O par (x^*, y^*) não está em D mas assume-se como tendo sido gerado pelo mesmo processo desconhecido que gerou D . Para se especificar explicitamente o que significa acurácia é definida uma função de perda $L(y_{\text{pred}}, y_{\text{verdadeiro}})$ ou, reciprocamente, uma função de utilidade $U = -L$.

O termo supervisionado indica que existe um “supervisor” especificando a saída y para cada entrada x nos dados D disponíveis. Se a saída é um número discreto de possíveis classes, isto é chamado um problema de classificação. Se a saída é um valor contínuo, isso é chamado um problema de regressão (BARBER, 2012).

O AM Não Supervisionado pode ser definido como: Dado um conjunto de dados $D = \{x^n, n=1, \dots, N\}$ no aprendizado não supervisionado o objetivo é encontrar uma descrição compacta plausível dos dados. Um objetivo é usado para quantificar a acurácia da descrição, sendo que nesta forma de aprendizado não existe uma variável especial de predição (BARBER, 2012). Problemas de agrupamento são característicos do aprendizado não supervisionado (KANTARDZIC, 2003).

Pode-se citar como exemplos de técnicas de aprendizado supervisionado indução de árvores de decisão, redes bayesianas e algoritmos de redes neurais artificiais. Como exemplos de aprendizado não supervisionado tem-se uma série de algoritmos de agrupamento como o k-means, além de algoritmos de redes neurais com treinamento não supervisionado como a rede Kohonen (ARTERO, 2009); (BARBER, 2012).

Nesse trabalho será dado ênfase ao aprendizado supervisionado na tarefa de regressão, com o uso de Redes Neurais Artificiais.

3.4.1. Redes Neurais Artificiais (RNAs)

As RNAs consistem em uma metodologia para solucionar problemas de IA, a partir de um sistema que possui circuitos que simulam o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São

técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência, aprendem a partir de seu ambiente e com isso melhoram seu desempenho. Isso é feito por meio de um algoritmo de treinamento, que corresponde a um processo iterativo de ajustes aplicados aos pesos sinápticos em neurônios (MATHIAS, 2006).

Wuerges e Borba (2010) explicam que uma rede precisa “aprender” para tornar-se útil. Aprender em redes neurais está ligado com a atualização dos pesos sinápticos em cada neurônio, de forma que a saída obtida pelos neurônios seja a mais próxima possível da saída desejada para a resolução do problema.

De acordo com Haykin (2001) um neurônio artificial em desenvolvimento é como um cérebro plástico, onde a plasticidade permite que o sistema nervoso em desenvolvimento se adapte ao seu ambiente. A plasticidade pode ser atribuída a novas conexões sinápticas entre neurônios e modificações dos pesos sinápticos existentes, sendo que nestas é que o conhecimento é armazenado.

Na Figura 3 os neurônios de entrada são representados pelos valores de “ X ” e “ β ”, e o neurônio de saída é representado pelo valor de “ y ”. Os valores de “ X ” representam as variáveis de entrada, “ β ” representa a entrada de Bias que segundo Artero (2009) é um valor com limites de 1 positivo ou negativo, com efeito de aplicar uma transformação afim à saída, opcional, e tem se mostrado útil em variadas situações. “ W ” representa os pesos sinápticos, “ Σ ” representa a somatória das multiplicações dos valores de “ X ” pelos valores de “ W ”, somados aos valores Bias quando da existência destes. O resultado da somatória é transferido à função de ativação (função matemática aplicada à combinação linear entre as variáveis de entrada e pesos que chegam a determinado neurônio) que vai definir o neurônio de saída “ y ”.




Figura 3: Modelo matemático de um neurônio, proposto por McCulloch e Pitts.
Fonte: Adaptado de Costa (2009).

A função de ativação realiza a limitação do intervalo do sinal de saída do neurônio geralmente no intervalo normalizado $[0,1]$ ou $[-1,1]$. Artero (2009) cita que existem várias possibilidades para função de ativação, sendo mais comum encontrar: função linear (usada tipicamente para *buffers* de entrada e saída de dados como em redes de Hopfield), função degrau e degrau unitário (usadas em modelos como Perceptron e também redes de Hopfield), função logística e tangente hiperbólica (usadas em redes de alimentação adiante, usando o aprendizado *Backpropagation*). Santos, et. al. (2005) citam que não é possível afirmar se diferentes funções de ativação têm maiores efeitos no desempenho da rede.

A distribuição dos neurônios, bem como sua conectividade e o sentido de fluxo das ligações entre eles definem a topologia das Redes Neurais. Haykin (2001) cita que a maneira com que os neurônios são estruturados está intimamente ligada com o algoritmo de aprendizagem utilizado para treinar a rede, em geral pode-se identificar três classes de arquitetura de redes fundamentalmente diferentes, parcialmente ou completamente conectados:

a) Rede alimentada adiante com uma única camada: existe uma camada de entrada de nós de fonte que se projeta em direção a camada de saída, mas não vice-versa, ou seja é uma camada acíclica.

b) Rede alimentada diretamente com múltiplas camadas: onde existe a presença de uma ou mais camadas ocultas, onde os nós ocultos intervêm entre a camada de entrada e a camada de saída, tornando a rede capaz de extrair estatísticas de ordem elevada, que também é acíclica, onde os neurônios de uma camada podem estar totalmente ou parcialmente conectados aos da outra.

c) Redes Recorrentes: possuem ou não camada oculta, com a diferença que os neurônios da camada de saída realimentam os neurônios da camada de entrada, o que causa um impacto profundo na capacidade de aprendizagem da rede.

Dias et al. (2007) citam que para a aprendizagem da rede, deve observar três conceitos importantes:

a) Treinamento ou aprendizado: conjunto de procedimentos utilizados para ajustar os parâmetros das RNAs para que consigam realizar determinada função.

b) Número de épocas: quantidade de vezes que os padrões de treinamento serão submetidos às RNAs, para atualização dos pesos.

c) Taxa de aprendizado: controla a intensidade das alterações dos pesos. Uma alta taxa de aprendizado acelera o processo, mas pode reduzir a capacidade de generalização da rede neural.

Artero (2009) enfatiza que a construção de um projeto para RNA é uma tarefa de tentativa e erro, e quando não há um bom desempenho, deve-se refazer todo o projeto, alterando número de neurônios, conexões, taxa de aprendizado, funções de propagação, adição de novos parâmetros e número de épocas.

De acordo com Mathias (2006), as tarefas nas quais as RNAs podem ser aplicadas são basicamente: reconhecimento de padrão, associação de padrões, transformação de dados, predição, aproximação de funções, entre outras.

Braga, Carvalho e Ludermir (2002) explicam que na aproximação de funções, os dados são fornecidos dentro de determinados limites, onde a função é definida e o modelo neural é ajustado para dar uma boa aproximação dentro do mesmo; nos problemas de predição o estado seguinte de um determinado problema é previsto com base em seus estados anteriores; para a classificação o objetivo é atribuir um padrão de entrada a uma classe entre um conjunto de classes conhecidas; a categorização envolve a descoberta de características estatisticamente relevantes em um conjunto de dados onde a saída não é conhecida.

Pode-se dizer que é no treinamento que se obtém o sucesso ou fracasso de uma RNA, Artero (2009) explica que o paradigma de treinamento para aprendizado da rede pode ser supervisionado quando a rede recebe com o padrão de entrada a resposta desejada, neste caso as diferenças entre os valores de entrada e saída são utilizadas para alterar os pesos existentes nas entradas dos neurônios até a obtenção do resultado satisfatório. Há também o treinamento não supervisionado, quando a rede altera o valor de seus pesos somente a partir do resultado do seu processamento. Guimaraes et al. (2008) citam ainda o aprendizado reforço que ocorre por meio de tentativa e erro, através de um “crítico”, não havendo valores de saída esperados, assim o crítico não retorna o erro de saída, mas sim um sinal de reforço ou de penalidade, associado à última ação da rede.

Para o treinamento supervisionado, Haykin (2001) comenta que a forma mais simples de uma rede neural é o modelo Perceptron, conhecido como classificador linear. Os padrões utilizados para treinamento deste são retirados de duas classes linearmente separáveis, então o algoritmo do Perceptron converge e posiciona a superfície de decisão na forma de um hiperplano entre duas classes. O modelo

Perceptron é composto de uma única camada que realiza classificação de padrões com duas classes com pesos sinápticos ajustáveis e um *Bias*.

Conforme Guimarães et al. (2008), outro modelo para a realização do treinamento supervisionado é o Perceptron Multi Camadas (PMC), o qual possui uma camada de entrada, uma ou mais ocultas e uma camada de saída, onde qualquer neurônio em qualquer camada pode ou não estar conectado a todos os neurônios das camadas anteriores, conforme ilustra a Figura 4. Artero (2009) cita que este modelo é indicado para um problema de classificação ou reconhecimento de padrões, no qual as soluções não são linearmente separáveis.




Figura 4: Modelo Perceptron Multi Camadas, com uma camada oculta.
Fonte: Elaborado pelo autor (2012).

Para um determinado conjunto de dados, o algoritmo de aprendizado deve ser responsável pela adaptação dos parâmetros da rede, de maneira que, em um número finito de iterações do algoritmo haja convergência para uma solução. O critério de convergência varia de acordo com o algoritmo e com o paradigma de aprendizado (BRAGA, CARVALHO e LUDERMIR, 2002, p. 148).

Um dos algoritmos de treinamento que podem ser usados na arquitetura PMC é o algoritmo *Backpropagation*, um método numérico que já foi usado por diferentes comunidades de pesquisa em diferentes contextos, foi descoberto e redescoberto e tem sido um dos algoritmos para redes neurais artificiais mais usados e estudados (ROJAS, 1996). O treinamento ocorre em duas fases, chamadas de *forward* e *backward*, sendo que em cada fase percorre-se a rede em um sentido. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. A

fase backward utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões até que se obtenha um erro mínimo (BRAGA, CARVALHO e LUDEMIR 2000, p.59).

Outro algoritmo utilizado para o treinamento é o *Resilient Propagation* que, de acordo com Riedmiller 1993 citado por Guimarães et al. (2008), busca tornar mais eficiente o método *Backpropagation*. A principal alteração foi introduzir um valor de atualização individual em cada peso, determinando somente o tamanho da atualização do peso; sendo esse valor adaptável, evoluindo durante o processo de aprendizagem, baseado na visão local da função de erro. Nesta atualização, um parâmetro que interfere no processo de aprendizagem é a taxa de aprendizagem [um índice variando entre 0 (zero) e 1 (um)], buscando determinar quanto do valor atual, da sinapse, será alterado na próxima época.

O ajustamento de cada peso é aumentado por um fator todas as vezes que o desempenho da derivada da função, com respeito aos pesos, tem o mesmo sinal para duas iterações sucessivas. O valor do ajustamento do peso é diminuído por um fator, todas as vezes que a derivada, com respeito aos pesos, muda de sinal na iteração seguinte. Se a derivada é zero, então valor do gradiente permanece o mesmo. Todas as vezes que os pesos estão oscilando, a mudança dos mesmos será reduzida. Se os pesos continuam a mudar na mesma direção por várias iterações, então a magnitude do ajuste deles será aumentada (Riedmiller e Braun 1993, citados por SCHOENINGER et al. 2008).

Quando uma rede neural está treinada e chega-se a um erro considerado satisfatório, ela é capaz de dar respostas a novas entradas ligadas com a mesma situação do treinamento, para auxiliar nas mais diversas situações.

Existem muitos estudos que utilizam as RNAs na agricultura, como Oliveira et al. (2010) que as aplicam para previsão da produção de álcool no Brasil, a partir de dados de produção anteriores, comparando os resultados com os obtidos utilizando técnicas de séries temporais, sendo que a Rede Neural obteve melhor desempenho. Mathias (2006) obteve com as RNAs um novo modo para definir relações entre variáveis meteorológicas e o molhamento foliar por orvalho, com resultados considerados satisfatórios.

França et al. (2009) utilizaram RNAs para a quantificação das classes de uso do solo, obtida pela classificação de imagens de satélite. Foi comparado o algoritmo

de aprendizado *Backpropagation* com o algoritmo de Máxima Verossimilhança (*Maxver*), tendo-se obtido resultados estatisticamente superiores para as RNAs.

De Wolf e Franci (2000) utilizaram as RNAs para prever a ocorrência da mancha amarela e da mancha de *Stagonospora* na cultura do trigo. Para isso, utilizaram dados de períodos de infecção dos patógenos em plantas suscetíveis com informações de graus dias acumulados duração do molhamento foliar, temperatura, umidade relativa e precipitação pluviométrica.

Noh et al. (2006) construíram uma rede neural artificial para prever níveis de estresse de N na cultura do milho, na camada de saída (em unidade SPAD), por meio dos dados de leitura espectral nas bandas do vermelho, infravermelho e verde, utilizados na camada de entrada.

Em outro trabalho, Liu et al. (2010) obtiveram resultados satisfatórios utilizando RNAs para relacionar índices de refletância espectral, na camada de entrada da rede, com o teor de clorofila, na camada de saída, na cultura de arroz, por meio do algoritmo de aprendizado *Backpropagation*.

A análise dos trabalhos da literatura envolvendo técnicas de AM baseadas em RNAs permite inferir que esta tecnologia pode ser amplamente explorada para sua utilização na agricultura. Uma das vertentes que se pode pesquisar para adoção dessas técnicas é na correlação entre índices obtidos por meio de leitura de sensores de refletância espectral e atributos de desempenho da cultura do trigo relacionados à concentração de N nas plantas. O que se espera é um aumento na capacidade de predição desses atributos devido à potencialidade que as RNAs possuem de aprender a partir de um padrão de comportamento de uma base de dados.

4. MATERIAL E MÉTODOS

4.1. Descrição do local e do solo

O experimento foi realizado em um Latossolo Vermelho sob plantio direto da região dos Campos Gerais do Paraná, na Fazenda Escola “Capão da Onça” da Universidade Estadual de Ponta Grossa. O clima da região, segundo classificação de Köppen, é do tipo Cfb, com verões amenos e geadas frequentes durante o inverno. A altitude média é de 970 m. A precipitação pluvial média anual é de cerca de 1.550 mm. Análises químicas do solo, na camada de 0–20 cm, realizadas antes da instalação do experimento, revelaram os seguintes resultados: pH (CaCl_2) de 5,2; acidez potencial ($\text{H} + \text{Al}$) de $49,6 \text{ mmol}_c \text{ dm}^{-3}$; teores de Ca, Mg e K trocáveis de 41, 22 e $3,7 \text{ mmol}_c \text{ dm}^{-3}$, respectivamente; P (Mehlich-1) de $4,0 \text{ mg dm}^{-3}$; carbono orgânico de 25 g dm^{-3} ; capacidade de troca de cátions (CTC) a pH 7,0 de $116,3 \text{ mmol}_c \text{ dm}^{-3}$; e saturação por bases (V) de 57%.

4.2. Delineamento experimental, tratamentos e condução da cultura do trigo

O delineamento experimental utilizado foi o de blocos completos ao acaso em esquema fatorial 4×3 , com quatro repetições. Em parcelas de 56 m^2 ($7 \times 8 \text{ m}$), foram empregadas quatro doses de N em cobertura (0, 50, 100 e 150 kg ha^{-1}) e três fertilizantes à base de N-ureia, sem e com inibidor da urease (ureia, ureia com o inibidor NBPT e ureia com o inibidor da Bunge—Fertilizantes) (Figura 5).

O trigo (*Triticum aestivum* L.), cv. Quartzo, foi semeado no dia 13 de junho de 2011, após o cultivo de milho (*Zea mays* L.), utilizando-se 170 kg ha^{-1} de sementes e espaçamento de 0,17 m entre as linhas. O cv. Quartzo é classificado como Trigo Pão, possui elevado potencial de rendimento de grãos, apresenta bom nível de resistência às manchas foliares e boa tolerância às chuvas na pré-colheita; é de hábito de crescimento intermediário a semi-ereto, moderadamente resistente ao acamamento e à geada, e moderadamente tolerante à debulha natural e ao alumínio. Na adubação de semeadura foram aplicados 300 kg ha^{-1} da fórmula 4–14–8 ($\text{N-P}_2\text{O}_5\text{-K}_2\text{O}$). A adubação nitrogenada de cobertura com as diferentes doses e fertilizantes à base de N-ureia foi realizada por ocasião do perfilhamento da cultura do trigo, entre a emissão da 4ª e da 7ª folha. O controle de pragas, doenças e plantas daninhas foi rigorosamente realizado de acordo com as necessidades da




Figura 5: Croqui da área experimental contendo as doses (D) e os fertilizantes (F) à base de N-ureia no delineamento de blocos completos ao acaso em esquema fatorial 4×3 , com quatro repetições.

cultura, de modo a permitir o adequado desenvolvimento das plantas para alcançar o máximo potencial produtivo.

Os dados de precipitação pluvial média mensal ocorrida durante o período de desenvolvimento da cultura do trigo em 2011 e de precipitação pluvial média histórica mensal (48 anos) de Ponta Grossa – PR são mostrados na Figura 6. A adubação nitrogenada foi realizada em solo com boa umidade e não houve chuvas durante dois dias após a aplicação das fontes de N-ureia. Entretanto, as chuvas ocorridas depois desse período superaram a média histórica para o mês de agosto (Figura 6). A temperatura média do ar variou 14 a 19°C.




Figura 6: Precipitação pluvial média mensal ocorrida durante o período de desenvolvimento da cultura do trigo em 2011, e precipitação pluvial média mensal de 48 anos em Ponta Grossa – PR.

4.3. Avaliações realizadas na cultura do trigo

Em cada parcela escolheu-se aleatoriamente três pontos representados por linhas de plantas de trigo. Amostras de folhas foram coletadas no início do florescimento da cultura do trigo, retirando-se a folha-bandeira, em 45 plantas de cada parcela, sendo 15 plantas em cada linha, para fins de análise foliar. Em cada folha-bandeira coletada foi realizada uma leitura de clorofila por meio de aparelho Clorofilog 1030, em unidades “ICF” próprias do aparelho. Nessa ocasião, nas mesmas linhas de plantas de trigo escolhidas, realizaram-se leituras por meio dos sensores GreenSeeker, utilizando as bandas espectrais de 650 ± 10 nm e 770 ± 15 nm, e Crop Circle ACS-470, utilizando as bandas espectrais 730 nm no canal 1, 760 nm no canal 2 e 670 nm no canal 3, a uma distância de 0,90 m do dossel das plantas, em um total de três leituras por parcela. Nessa mesma época, foram também retiradas, em cada ponto da parcela, duas linhas de 1,5 m de plantas ($0,51 \text{ m}^2$), somente a parte aérea, em um total de três pontos por parcela, para avaliação da produção de matéria seca. Todas essas amostragens foram realizadas no dia 12 de setembro de 2011.

As amostras de folhas e de plantas foram lavadas com água deionizada e colocadas para secar em estufa com circulação forçada de ar à temperatura de 60°C

até a obtenção de massa constante. Depois da avaliação da produção de matéria seca da parte aérea, as amostras de folhas e plantas foram moídas, e os teores de N foram analisados por meio de digestão sulfúrica e determinação pelo método Kjeldahl (Malavolta et al., 1997). A extração de N pelas plantas de trigo foi calculada por meio do produto da produção de matéria seca e da concentração de N na parte aérea.

A produção de grãos de trigo foi avaliada após a maturação fisiológica da cultura, por meio de colheita manual e trilhagem em máquina debulhadora estacionária. Foram colhidas as 20 linhas centrais por 4 m de comprimento de cada parcela (13,6 m²), tendo-se desprezado 2,0 m de cada extremidade. A produtividade de grãos foi calculada em kg ha⁻¹, corrigindo-se o teor de água nos grãos para 130 g kg⁻¹. Após a colheita, avaliou-se a massa de 1000 grãos em cada parcela.

4.4. Análises Estatísticas

Os resultados obtidos foram submetidos às análises de variância e de regressão. Como não houve influência significativa dos fertilizantes à base de N-ureia e também da interação doses × fertilizantes nitrogenados sobre os parâmetros avaliados, os fertilizantes à base de N-ureia empregados foram considerados como repetições. Assim, os efeitos das doses de N foram comparados por meio de análises de regressão, considerando o delineamento de blocos completos ao acaso, com quatro doses de N em cobertura e 12 repetições. Adotou-se como critério para escolha do modelo da regressão a magnitude dos coeficientes de determinação significativos a 5%.

4.5. Redes Neurais Artificiais

As técnicas de AM supervisionado adotadas foram as RNAs, aplicando-se os algoritmos *Backpropagation* e *Resilient Propagation*, por meio do software MatLab® (The MathWorks Inc).

A definição da arquitetura de rede mais adequada foi obtida pelo método construtivo que, de acordo com Castro et. al. (1999), começa com uma arquitetura mínima de rede e adicionam-se neurônios até que uma solução adequada seja encontrada. A grande vantagem é que este método busca sempre uma arquitetura reduzida, afetando os passos *forward* e *backward*, resultando em menor esforço computacional. Além disso, o papel individual de cada neurônio torna-se mais

evidente. Neste estudo, independentemente da base de entrada e do número de instâncias, a melhor arquitetura encontrada foi uma camada escondida, com 10 neurônios. Dividiu-se as bases em 5 folds, com 100 épocas para o treinamento.

Na camada de saída utilizou-se a função de ativação sigmoide tangencial (valor de saída compreendido no espaço -1 e 1). Haykin (2001) comenta que o fato de permitir que uma função do tipo sigmoide assumia valores negativos traz benefícios analíticos; e a função logarítmica sigmoideal (valor de saída compreendido no espaço 0 e 1) na camada oculta.

Para este estudo, a base de dados foi subdividida em quatro, sendo duas para cada sensor. Para encontrar a melhor combinação de atributos a serem considerados como neurônios de entrada utilizou-se técnicas de pré-processamento de dados para seleção de atributos, utilizando-se o software WEKA[®] (The University of Waikato). As bases bem como os dados utilizados como neurônios de entrada estão descritos a seguir:

BD-C1 (Base Crop Circle 1): composta pelo atributos NDVI (bandas 670 e 760 nm) e NDVI (bandas 730 e 760 nm).

BD-C2 (Base Crop Circle 2): composta pelos atributos NDVI (bandas 670 e 760 nm), NDVI (bandas 730 e 760 nm), SR(bandas 670 e 760 nm), SR(bandas 730 e 760 nm); banda 730 nm, banda 760 nm, banda 670 nm e doses de N.

BD-G1 (Base GreenSeeker 1): composta pelos atributos NDVI e doses de N.

BD-G2 (Base GreenSeeker 2): composta pelo atributo NDVI.

Pretendeu-se, assim, estimar os resultados obtidos em laboratório, ou seja, N na folha bandeira, extração de N e matéria seca da parte aérea das plantas de trigo.

Para cada base de dados utilizou-se ainda três números distintos de instâncias:

- Para se estimar o teor de N na folha bandeira, a extração de N e a matéria seca da parte aérea do trigo, o total de instâncias na base de dados contendo o total de leituras do sensor Crop Circle foi de 7.237 e do GreenSeeker foi de 5.271; para a base que continha as médias das leituras de cada amostra, o número de instâncias foi de 144 para ambos os sensores; e para a base que continha as médias das leituras de cada parcela, o número de instâncias foi de 48 para ambos os sensores. A base de 144 instâncias representa uma média do total de instâncias de cada amostra, e a base de 48 instâncias representa uma média dos valores das amostras de cada parcela.

5. RESULTADOS E DISCUSSÃO

5.1. Doses de nitrogênio (N) e atributos da cultura do trigo

A concentração de N na folha-bandeira foi aumentada linearmente ($P < 0,01$) com as doses de N aplicadas em cobertura na cultura do trigo (Figura 7). Dessa forma, a maior concentração de N na folha-bandeira foi alcançada com a maior dose de N (150 kg ha^{-1}) aplicada em cobertura.




Figura 7: Concentração de nitrogênio na folha-bandeira do trigo em função de doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$.

As doses de N aplicadas em cobertura aumentaram ($P < 0,05$) a produção de matéria seca da parte aérea de plantas de trigo, conforme o modelo quadrático (Figura 8). De acordo com a equação de regressão ajustada, a máxima produção de matéria seca da parte aérea seria obtida com a aplicação de 138 kg ha^{-1} de N em cobertura.




Figura 8: Produção de matéria seca da parte aérea de plantas de trigo em função de doses de nitrogênio aplicadas em cobertura. *: $P < 0,05$.

A extração de N pelas plantas de trigo foi aumentada linearmente ($P < 0,01$) com as doses de N aplicadas em cobertura na cultura do trigo, mostrando que a maior extração de N pelas plantas ocorreu com a aplicação da dose de 150 kg ha^{-1} de N em cobertura (Figura 9).




Figura 9: Extração de N pelas plantas de trigo em função de doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$.

A influência positiva da adubação nitrogenada em cobertura no teor de N nas folhas (Figura 7), na produção de matéria seca da parte aérea (Figura 8) e na extração de N pelas plantas de trigo (Figura 9) era esperada, pois a maior parte do N do solo encontra-se na forma orgânica e, em vários trabalhos realizados com a cultura do trigo, foram encontradas respostas positivas da adubação nitrogenada no acúmulo de matéria seca e na nutrição de N da cultura (VIANA e KIEHL, 2010; ESPINDULA, et al. 2010; NUNES, SOUZA e MERCANTE, 2011).

A produtividade de grãos de trigo foi aumentada com as doses de N aplicadas em cobertura ($P < 0,01$), conforme o modelo quadrático (Figura 10). De acordo com a equação de regressão ajustada, a máxima produtividade de grãos de trigo ($\sim 5000 \text{ kg ha}^{-1}$) seria obtida com a aplicação de cerca de 90 kg ha^{-1} de N em cobertura. Em diversos estudos também foram observadas respostas positivas da adubação nitrogenada na produtividade de grãos de trigo (ZAGONEL et al., 2002; TRINDADE et al., 2006; HEINEMANN et al., 2006; BOSCHINI et al., 2011). Destaca-se que a produtividade de grãos de trigo obtida no presente estudo foi elevada, inclusive na ausência de adubação nitrogenada em cobertura ($\sim 4500 \text{ kg ha}^{-1}$). Isso pode ser consequência do estoque relativamente alto de N lábil no solo sob plantio direto,

considerando que o trigo foi cultivado após milho e com o emprego de somente 12 kg ha⁻¹ de N na semeadura. Esse comportamento pode ter influenciado os resultados de leitura dos sensores na comparação dos atributos avaliados na cultura do trigo.




Figura 10: Produtividade de grãos de trigo influenciada pelas doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$.

A massa de 1.000 grãos de trigo foi linearmente reduzida com o aumento das doses de N aplicadas em cobertura (Figura 11). Resultado semelhante foi encontrado por Teixeira Filho et al. (2010) com trigo irrigado em sistema plantio direto. Isso certamente ocorreu devido ao enchimento incompleto dos grãos decorrente do maior número de perfilhos ou de grãos por panícula em níveis mais elevados de adubação nitrogenada. Assim, a adubação nitrogenada aumentou a produtividade de grãos de trigo conforme o modelo quadrático (Figura 10), mas a massa dos grãos produzidos foi linearmente menor com o aumento das doses de N aplicadas em cobertura porque provavelmente não houve adequado enchimento dos grãos com o aumento do número de perfilhos ou de grãos por panícula.




Figura 11: Massa de 1000 grãos de trigo influenciada pelas doses de nitrogênio aplicadas em cobertura. **: $P < 0,01$.

5.2. Leitura dos sensores e atributos da cultura do trigo

5.2.1. Clorofilog 1030

As leituras do clorofilômetro não foram sensíveis às variações de doses de N aplicadas em cobertura na cultura do trigo (Figura 12). Consequentemente, as leituras do clorofilômetro também não se correlacionaram significativamente com o teor de N na folha bandeira, a produção de matéria seca da parte aérea e a extração de N pelas plantas de trigo (Figura 13).




Figura 12: Leitura do Clorofilog 1030 influenciada pelas doses de nitrogênio aplicadas em cobertura na cultura do trigo.




Figura 13: Correlação entre as leituras do clorofilômetro e o teor de nitrogênio na folha-bandeira (a), a produção de matéria seca da parte aérea (b) e a extração de nitrogênio pelas plantas de trigo (c).

Durante a mensuração do clorofilômetro, o aparelho emite radiação que passa pelas folhas e o sinal é recebido para formação do índice (ICF), que é associado ao teor de clorofila presente das folhas. Como a produtividade do trigo foi alta ($\sim 4500 \text{ kg ha}^{-1}$) na ausência de adubação nitrogenada em cobertura (Figura 10), as plantas de trigo apresentaram bom estado nutricional e, conseqüentemente, boa estruturação e coloração das folhas, mesmo sem aplicação de N em cobertura. Logo, os incrementos nas leituras de clorofila com o aumento das doses de N aplicadas em cobertura foram pequenos e não significativos (Figura 12). Pelo

mesmo motivo houve baixa correlação entre as leituras do clorofilômetro e os atributos avaliados nas plantas de trigo (Figura 13).

5.2.2. Croop Circle e Greenseeker

Os índices obtidos pelo sensor Crop Circle ACS-470 aumentaram linearmente ($P < 0,01$) com as doses de N aplicadas em cobertura na cultura do trigo (Figura 14).




Figura 14: Correlações entre os índices do Crop Circle e as doses de nitrogênio aplicadas em cobertura na cultura do trigo. **: $P < 0,01$.

Os coeficientes de determinação (R^2) obtidos foram de 0,97 para a refletância de 760 nm; 0,96 para o SR (670 e 760 nm); e 0,91 para o NDVI (670 e 760 nm).

Para o sensor Greenseeker, o NDVI aumentou e o VI diminuiu significativamente ($P < 0,01$), conforme modelo quadrático, com as doses de N aplicadas em cobertura na cultura do trigo (Figura 15). O coeficiente de determinação (R^2) obtido para ambos os índices, NDVI e VI, foi de 0,96.




Figura 15: Correlações entre os índices do GreenSeeker e as doses de nitrogênio aplicadas em cobertura na cultura do trigo. **: $P < 0,01$.

Os resultados obtidos no presente estudo corroboram com os obtidos por Amaral e Molin (2011) na cultura da cana-de-açúcar utilizando o sensor Crop Circle ACS-210, Rossato et al. (2012) na cultura do algodão com o sensor Crop Circle ACS-470 e Povh et al. (2008) nas culturas de trigo e triticale utilizando o sensor GreenSeeker.

Motomiya, Molin e Chiavegato (2009) explicam que menores aportes de N resultam em decréscimo de clorofila e da taxa de expansão foliar, além de diminuição no desenvolvimento das plantas. Como a refletância na região do visível do espectro eletromagnético varia em função da concentração de clorofila no tecido foliar, quanto menor o suprimento de N para as plantas, menor também será o nível de clorofila e, conseqüentemente, menor será a absorção da radiação na região do visível, o que causa redução do NDVI e aumento do VI.

Para o estudo das correlações entre as leituras dos sensores e os teores de N na folha bandeira, a produção de matéria seca da parte aérea e a extração de N pelas plantas de trigo, realizaram-se duas análises, sendo uma com todos os valores obtidos em cada amostra de cada parcela e outra com a média dos valores das amostras em cada parcela.

Os índices dos dois sensores obtidos em cada amostra de cada parcela correlacionaram-se linearmente com os teores de N na folha bandeira ($P < 0,01$). Nesse caso, foram utilizadas 144 leituras dos sensores e 144 determinações de teor de N na folha bandeira. Apesar de as correlações terem sido significativas, os coeficientes de determinação (R^2) foram baixos: 0,13 para o NDVI do GreenSeeker; 0,13 para o VI do GreenSeeker; 0,15 para o NDVI (bandas 670 e 760 nm) do Crop Circle; e 0,16 para o SR (bandas 670 e 760 nm) do Crop Circle (Figura 16).




Figura 16: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e os teores de nitrogênio na folha bandeira do trigo, considerando todos os valores obtidos ($n = 144$). **: $P < 0,01$.

Quando foram utilizados os valores médios das amostras de cada parcela, ou seja, 48 leituras médias dos sensores e 48 determinações do teor de N na folha bandeira, as correlações mantiveram comportamento linear ($P < 0,01$), mas os coeficientes de determinação (R^2) foram mais elevados: 0,34 para o NDVI do GreenSeeker; 0,38 para o VI do GreenSeeker; 0,38 para o NDVI (bandas 670 e 760 nm) do Crop Circle; e 0,40 para o SR (bandas 670 e 760 nm) do Crop Circle (Figura

17). Isso certamente aconteceu porque quando se utilizou um número menor de observações houve menor variabilidade e melhor ajuste das correlações. Mesmo assim, o maior coeficiente de determinação (R^2) obtido foi de 0,40 para o SR (bandas 670 e 760 nm) do Crop Circle.




Figura 17: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e os teores de nitrogênio na folha bandeira do trigo, considerando os valores médios de cada parcela ($n = 48$).
 ** : $P < 0.01$.

Os dois sensores demonstraram comportamento semelhante quanto ao teor de N na folha bandeira do trigo, tanto quando se considerou todos os valores obtidos nas parcelas como também para os valores médios das amostras de cada parcela. Os resultados mostraram que os índices dos dois sensores identificaram variações no teor de N nas folhas de trigo, mas as correlações não foram muito estreitas. Melhores correlações foram obtidas por Rissini (2011) e Freeman et al. (2003) para o mesmo estágio fenológico da cultura de trigo. Cabe destacar, no entanto, que no presente estudo houve alta produtividade de grãos de trigo e, portanto, bom estado nutricional das plantas, mesmo na ausência de adubação nitrogenada em cobertura.

Para a produção de matéria seca pela parte aérea das plantas de trigo, nas análises realizadas com todos os valores obtidos em cada amostra de cada parcela (144 observações) e com a média dos valores das amostras em cada parcela (48 observações), houve correlações lineares significativas ($P < 0,01$) com os índices obtidos pelos sensores (Figuras 18 e 19).

Considerando todos os valores obtidos em cada amostra de cada parcela (144 observações), os coeficientes de determinação (R^2) dos ajustes entre as leituras dos sensores e a produção de matéria seca da parte aérea do trigo de trigo

foram de 0,44 para o NDVI do GreenSeeker; 0,43 para o VI do GreenSeeker; 0,41 para o NDVI (bandas 670 e 760 nm) do Crop Circle; e 0,38 para o SR (bandas 670 e 760 nm) do Crop Circle (Figura 18).




Figura 18: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e a produção de matéria seca da parte aérea das plantas de trigo, considerando todos os valores obtidos (n = 144).
**: $P < 0,01$.

Com os valores médios das amostras de cada parcela (48 observações), os coeficientes de determinação (R^2) dos ajustes entre as leituras dos sensores e a produção de matéria seca da parte aérea das plantas de trigo de trigo foram de 0,60 para o NDVI do GreenSeeker; 0,59 para o VI do GreenSeeker; 0,61 para o NDVI (bandas 670 e 760 nm) do Crop Circle; e 0,59 para o SR (bandas 670 e 760 nm) do Crop Circle (Figura 19).

Os coeficientes de correlação (R^2) entre as leituras dos sensores Croop Circle e Greenseeker e a produção de matéria seca da parte aérea das plantas de trigo foram maiores quando se utilizaram os valores médios das parcelas do que todos obtidos em cada amostra de cada parcela porque com a utilização de um número menor de observações houve menor variabilidade e melhor ajuste das correlações.




Figura 19: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e a produção de matéria seca da parte aérea das plantas de trigo, considerando os valores médios de cada parcela (n = 48). **: $P < 0.01$.

A produção de matéria seca da parte aérea das plantas de trigo esteve estreitamente correlacionada com os índices obtidos pelos sensores Croop Circle e Greenseeker, os quais mostraram um desempenho semelhante para essa finalidade. Esses resultados estão em concordância com os obtidos por Rissini (2011) no mesmo estágio fonológico da cultura de trigo com o sensor Crop Circle ACS 210 e por Gohrs et al. (2009) em cultivares de trigo e cevada utilizando o sensor GreenSeeker.

A extração de N pelas plantas de milho também se correlacionou linearmente ($P < 0,01$) com os índices obtidos pelos sensores Croop Circle e Greenseeker, tanto quando se utilizaram todos os valores obtidos em cada amostra de cada parcela (n = 144) (Figura 20), como também quando foram usadas somente as médias das parcelas (n = 48) (Figura 21).

Para n = 144, os coeficientes de determinação (R^2) dos ajustes entre as leituras dos sensores e a extração de N pelas plantas de trigo foram de 0,49 para o NDVI do GreenSeeker; 0,47 para o VI do GreenSeeker; 0,44 para o NDVI (bandas 670 e 760 nm) do Crop Circle; e 0,43 para o SR(bandas 670 e 760 nm) do Crop Circle (Figura 20).




Figura 20: Correlações entre as leituras dos sensores Croop Circle e Greenseeker e a extração de N pelas plantas de trigo, considerando todos os valores obtidos ($n = 144$). **: $P < 0,01$.

Para $n = 48$, os coeficientes de determinação (R^2) dos ajustes entre as leituras dos sensores e a extração de N pelas plantas de trigo foram de 0,64 para o NDVI do GreenSeeker; 0,62 para o VI do GreenSeeker; 0,61 para o NDVI (bandas 670 e 760 nm) do Crop Circle; e 0,61 para o SR (bandas 670 e 760 nm) do Crop Circle (Figura 21).

Os maiores coeficientes de determinação (R^2) obtidos entre as leituras dos sensores e a extração de N pelas plantas de trigo para $n = 48$ em relação à $n = 144$ foram decorrentes de menor variabilidade causada pelo número menor de observações.




Figura 21: Correlações entre as leituras dos sensores Crop Circle e Greenseeker e a extração de N pelas plantas de trigo, considerando os valores médios de cada parcela ($n = 48$). **: $P < 0.01$.

As correlações obtidas entre os sensores e a extração de N pelas plantas de trigo foram bem mais estreitas do que as encontradas por Grohs (2008), que obteve um coeficiente de determinação (R^2) de 0,23 para o ajuste entre NDVI e acúmulo de N na parte aérea da planta do trigo. As análises de correlação dos sensores com a extração de N pelas plantas de trigo mostraram que o desempenho do sensor Greenseeker foi ligeiramente superior ao do sensor Crop Circle.

As leituras de NDVI obtidas pelos sensores GreenSeeker (Figura 22) e Crop Circle (Figura 23) estiveram linearmente ($P < 0,01$) correlacionadas com a produtividade de grãos de trigo, mas os coeficientes de determinação (R^2) foram muito baixos.




Figura 22: Correlação entre a leitura de NDVI do GreenSeeker e a produtividade de grãos de trigo.
**: $P < 0,01$.




Figura 23: Correlação entre a leitura de NDVI do Crop Circle e a produtividade de grãos de trigo.
**: $P < 0,01$.

Para gerar o INSEY (“in-season estimate of yield”- “rendimento esperado de grãos”), o NDVI é dividido pelo número de dias da semeadura até a leitura do índice (RAUN et al., 1999; 2001; 2002; POVH et al., 2008). No presente estudo, este período correspondeu a 91 dias após a semeadura (DAS). Obedecendo esta metodologia, o INSEY obtido pela leitura de NDVI aos 91 DAS por meio do Greenseeker apresentou relação linear ($P < 0,01$) com a produtividade de grãos de trigo (Figura 24), mas o coeficiente de determinação (R^2) foi de apenas 0,24.




Figura 24: Correlação entre o INSEY obtido pela leitura de NDVI aos 91 dias após a semeadura do GreenSeeker e a produtividade de grãos de trigo. **: $P < 0,01$.

O INSEY obtido pela leitura de NDVI aos 91 DAS por meio do Crop Circle também esteve linearmente ($P < 0,01$) relacionado com a produtividade de grãos de trigo (Figura 25), mas o coeficiente de determinação (R^2) também foi muito baixo (0,19).




Figura 25: Correlação entre o INSEY obtido pela leitura de NDVI aos 91 dias após a semeadura do Crop Circle e a produtividade de grãos de trigo. **: $P < 0,01$.

A produção de matéria seca da parte aérea, aos 91 DAS, teve uma correlação muito fraca com a produtividade de grãos de trigo (Figura 26). Os sensores GreenSeeker e CropCircle apresentaram grande sensibilidade para a mensuração da produção de matéria seca da parte aérea, porém a matéria seca produzida não apresentou boa correlação com a produtividade de grãos de trigo.




Figura 26: Correlação entre a produção de matéria seca da parte aérea e a produtividade de grãos de trigo. *: $P < 0,05$.

Na literatura, existem resultados bem melhores, como os obtidos por Rissini (2011) e Povh (2008), com coeficientes de correlação (R^2) superiores a 0,90. Acontece, porém, que no presente estudo a produtividade de grãos foi alta ($\sim 4500 \text{ kg ha}^{-1}$) na ausência de aplicação de N em cobertura (Figura 10). Com a adubação nitrogenada em cobertura houve aumento na produção de matéria seca da parte aérea (Figura 8) e, provavelmente, no número de perfilhos ou de grãos por panícula, mas a produtividade de grãos não acompanhou essa resposta porque não houve enchimento completo dos grãos nas maiores doses de N empregadas, que culminou em menor massa de 1000 grãos (Figura 11). Assim, quando os rendimentos de grãos de trigo são mais baixos na ausência de cobertura nitrogenada, é possível que a correlação entre a produção de matéria seca da parte aérea e a produtividade de grãos da cultura, em resposta à aplicação de N em cobertura, seja mais estreita. Consequentemente, baseando-se em outros resultados da literatura, é possível estimar a produtividade de grãos pela leitura dos sensores, uma vez que os sensores conseguem diferenciar bem a produção de matéria seca ao longo do ciclo da cultura. Entretanto, o presente estudo mostrou que para mais altos tetos de produtividade de trigo isso não é possível porque a produtividade de grãos não acompanha diretamente os ganhos na produção de matéria seca da parte aérea.

5.2.3. Síntese das análises de correlação entre as leituras dos sensores e os atributos da cultura do trigo

A incidência da radiação emitida pelos sensores ocorre no dossel das plantas. Logo, quanto maior a produção de massa, maior será a área verde refletida, que irá incidir principalmente na região verde visível e infravermelho. Isso explica a obtenção de índices distintos entre diferentes estádios de desenvolvimento e cultivares, como os encontrados por Rissini (2011) em uma mesma área e na mesma época de cultivo, pois cada uma possuía particularidades em coloração e formação do dossel.

No presente estudo, observou-se que os índices obtidos pelos sensores de refletância Crop Circle e GreenSeeker tiveram estreita correlação com as doses de N aplicadas em cobertura na cultura do trigo, a produção de matéria seca da parte aérea e a extração de N pelas plantas (Tabela 2). Os sensores Crop Circle e GreenSeeker apresentaram correlação fraca com o teor de N nas folhas e, principalmente, com a produtividade de grãos de trigo. Isso porque ficou bem evidenciado que a produtividade de grãos não acompanhou a produção de matéria seca da parte aérea do trigo quando os rendimentos de trigo foram elevados.

Tabela 2: Resultados das análises de correlação entre as leituras dos sensores e os atributos da cultura do trigo

Atributos	Coeficiente de correlação (r)	
	Crop Circle	GreenSeeker
Doses de N em cobertura	0,98	0,95
Matéria seca da parte aérea do trigo	0,78	0,78
Extração de N pelas plantas de trigo	0,78	0,80
Teor de N na folha bandeira	0,61	0,58
Produtividade de grãos de trigo	0,43	0,49

5.3. Redes Neurais Artificiais

5.3.1. Redes Neurais Artificiais na correlação entre concentração de N na folha bandeira e leituras dos sensores Crop Circle e GreenSeeker

O primeiro atributo da cultura do trigo correlacionado por meio das RNAs com as leituras dos sensores e doses do fertilizante nitrogenado foi o N na folha bandeira. Os resultados de coeficiente de correlação e erro médio absoluto estão apresentados na Tabela 3.

Tabela 3: Resultados das Redes Neurais Artificiais para estimativa de N na folha bandeira de acordo com a leitura dos sensores Crop Circle e GreenSeeker

Algoritmo	Total de instâncias				144 instâncias				48 instâncias			
	Backprop.		Resilient P.		Backprop.		Resilient P.		Backprop.		Resilient P.	
Resultado	r	Erro	r	Erro	r	Erro	r	Erro	r	Erro	r	Erro
BD-C1	0,34	1,74	0,33	1,74	0,40	1,77	0,37	1,88	0,42	1,24	0,40	1,77
BD-C2	0,45	1,62	0,42	1,67	0,38	1,78	0,38	1,80	0,42	1,54	0,39	1,28
BD-G1	0,41	1,76	0,41	1,70	0,36	1,65	0,39	1,82	0,42	1,54	0,37	1,94
BD-G2	0,20	2,67	0,22	2,50	0,30	1,84	0,30	1,84	0,36	1,67	0,38	1,56

Os coeficientes de correlação obtidos mostraram desempenho baixo, com comportamento semelhante dos sensores e algoritmos, independentemente do número de instâncias utilizado. Mesmo quando se adicionaram as doses de N como atributo de entrada (BD-C2 e BD-G1), a rede não conseguiu melhorar o desempenho ao ponto de se chegar a um resultado satisfatório.

Em linhas gerais, as melhores correlações (com uma diferença pequena) foram obtidas utilizando-se a base BD-C2 e o algoritmo *Backpropagation*. Os melhores coeficientes de correlação encontrados foram 0,45 para a base BD-C2 com o algoritmo *Backpropagation* quando se utilizou o total de instâncias e se obteve um erro de 1,62; 0,40 para a base BD-C1 com o algoritmo *Backpropagation* quando se utilizaram 144 instâncias e se obteve um erro de 1,77; e 0,42 para a base BD-C1, com um erro de 1,24 e utilizando o algoritmo *Backpropagation*.

Ressalta-se também que para o total de instâncias, as bases que continham o atributo de entrada “doses de N” (BD-C2 e BD-G1) apresentaram desempenho bastante superior em relação àquelas que não o possuíam. Quando se diminuiu o número de instâncias, a base do sensor Crop Circle – BD-C1 corrigiu mais essa diferença do que a base do sensor Greenseeker – BD-G2.

5.3.2 Redes Neurais Artificiais na correlação entre produção de matéria seca da parte aérea do trigo e leituras dos sensores Crop Circle e GreenSeeker

As leituras dos sensores e as doses do fertilizante nitrogenado foram, em seguida, correlacionadas com os valores de matéria seca da parte aérea do trigo por meio das RNAs. Os resultados de coeficiente de correlação e erro médio absoluto estão apresentados na Tabela 4.

Tabela 4: Resultados das Redes Neurais Artificiais para estimativa da produção de matéria seca da parte aérea do trigo de acordo com a leitura dos sensores Crop Circle e GreenSeeker

Algoritmo	Total de instâncias				144 instâncias				48 instâncias			
	Backprop.		Resilient P.		Backprop.		Resilient P.		Backprop.		Resilient P.	
Resultado	r	Erro	r	Erro	r	Erro	r	Erro	r	Erro	r	Erro
BD-C1	0,52	543	0,52	541	0,60	496	0,58	536	0,64	487	0,74	363
BD-C2	0,58	524	0,59	520	0,57	533	0,58	535	0,67	406	0,68	408
BD-G1	0,55	531	0,57	518	0,63	596	0,60	513	0,64	428	0,67	403
BD-G2	0,53	532	0,54	534	0,62	515	0,63	494	0,73	386	0,66	441

A correlação nas bases de dados com o atributo produção de matéria seca da parte aérea do trigo (Tabela 4) apresentou melhor desempenho em relação ao atributo N na folha bandeira (Tabela 3). Nota-se que ao diminuir o número de instâncias não prejudicou o aprendizado da rede (Tabela 4) e que o comportamento linear dos dados observados nas análises estatísticas pode explicar tais resultados.

Os melhores coeficientes de correlação foram sempre obtidos com o algoritmo *Resilient Propagation*, os quais foram 0,59 para a base BD-C2 quando se utilizou o total de instâncias e se obteve um erro médio de 520; 0,63 para a base BD-G2 quando se utilizaram 144 instâncias e se obteve um erro de 494; e 0,74 para a base BD-C1, com um erro de 363. Observa-se também que para o total de instâncias, as bases BD-C2 e BD-G1, que continham o atributo de entrada doses de N, apresentaram desempenho mais satisfatório para ambos os algoritmos. Já com o número de 144 e 48 instâncias, essa relação alternou-se, mostrando que não se pode atribuir ganho de aprendizado com a utilização ou não do atributo de entrada doses de N.

5.3.3. Redes Neurais Artificiais na correlação entre extração de N pelas plantas de trigo e leituras dos sensores Crop Circle e GreenSeeker

Por fim, correlacionaram-se por meio das RNAs, as leituras dos sensores e doses do fertilizante nitrogenado com os valores de extração de N pela parte aérea das plantas de trigo. Os resultados de coeficiente de correlação e erro médio absoluto estão apresentados na Tabela 5.

Tabela 5: Resultados das Redes Neurais Artificiais para estimativa da extração de N pelas plantas de trigo de acordo com a leitura dos sensores Crop Circle e GreenSeeker

Algoritmo	Total de instâncias				144 instâncias				48 instâncias			
	Backprop.		Resilient P.		Backprop.		Resilient P.		Backprop.		Resilient P.	
Resultado	r	Erro	r	Erro	r	Erro	r	Erro	r	Erro	r	Erro
BD-C1	0,59	16,19	0,55	16,14	0,62	15,54	0,63	15,19	0,71	12,00	0,70	11,63
BD-C2	0,64	14,82	0,65	14,80	0,64	15,10	0,67	13,56	0,67	11,65	0,74	11,15
BD-G1	0,65	15,27	0,66	14,82	0,58	15,27	0,65	15,52	0,69	12,61	0,64	13,40
BD-G2	0,59	15,60	0,57	15,08	0,67	15,06	0,66	15,59	0,71	14,80	0,76	12,50

Assim como nos resultados de produção de matéria seca da parte aérea (Tabela 4), na extração de N pelas plantas de trigo os melhores coeficientes de correlação encontrados foram para o número de 48 instâncias (Tabela 5). Nota-se ainda que os melhores valores de erro médio absoluto foram também obtidos com um número de 48 instâncias. Isso significa que a diminuição no número de instâncias não prejudicou o aprendizado da rede, e isso pode ser explicado pelo comportamento linear dos dados observado nas análises estatísticas.

Os melhores coeficientes de correlação foram sempre obtidos com o algoritmo *Resilient Propagation*, os quais foram 0,66 para a base BD-G1 quando se utilizou o total de instâncias e se obteve um erro médio de 14,82; 0,67 para a base BD-C2 quando se utilizaram 144 instâncias e se obteve um erro de 13,56; e 0,76 para a base BD-G2, com um erro de 12,50 com 48 instâncias. Observa-se que, para o total de instâncias, as bases BD-C2 e BD-G1, que possuíam o atributo de entrada doses de N, apresentaram desempenho melhor para ambos os algoritmos. Já, com o número de 144 e 48 instâncias, essa relação inverteu-se com a base do sensor GreenSeeker, apresentando coeficientes de correlações maiores quando não foram utilizadas as doses de N como neurônio de entrada. O comportamento de todas as instâncias manteve-se parecido para as bases do sensor Crop Circle, com exceção de 48 instâncias com o algoritmo *Backpropagation* que teve melhor desempenho quando não se utilizou as doses de N como neurônio de entrada. Cabe destacar que os melhores coeficientes obtidos pelo atributo meta produção de matéria seca da parte aérea do trigo (Tabela 4) foram menores, em todos os números de instâncias, do que aqueles obtidos pelo atributo meta extração de N pelas plantas de trigo (Tabela 5).

5.3.4. Resultados gerais de correlação das Redes Neurais Artificiais considerando a leitura dos sensores e os atributos da cultura do trigo

A análise geral dos resultados, apresentada na Tabela 6, foi feita utilizando-se os melhores resultados obtidos com 48 instâncias para N na folha bandeira, produção de matéria seca da parte aérea das plantas e extração de N pelas plantas de trigo.

Tabela 6: Resultados gerais do desempenho dos algoritmos *Backpropagation* e *Resilient Propagation*

Atributo	CROP CIRCLE				GREENSEEKER			
	<i>Backpropagation</i>		<i>Resilient Propagation</i>		<i>Backpropagation</i>		<i>Resilient Propagation</i>	
	r	Erro	r	Erro	r	Erro	r	Erro
N na folha bandeira	0,42	1,54	0,40	1,77	0,42	1,54	0,38	1,56
Produção de matéria seca	0,67	406,00	0,74	363,00	0,73	386,00	0,67	403,00
Extração de N pelas plantas	0,71	12,00	0,74	11,15	0,71	14,80	0,76	12,50

Assim como observado nas análises estatísticas, os sensores demonstraram desempenho similar, mesmo com neurônios de entrada diferentes. Considerando que os sensores trabalham de forma parecida com o mesmo objetivo, esses resultados já eram esperados. Ressalta-se aqui uma diferença com relação ao comportamento dos algoritmos em relação ao atributo meta produção de matéria seca da parte aérea do trigo. Percebe-se que o algoritmo *Backpropagation* apresentou desempenho melhor para o sensor GreenSeeker com um coeficiente de correlação de 0,73 contra 0,67 para o *Resilient Propagation*. Já, para o sensor Crop Circle, o comportamento foi inverso, com o algoritmo *Backpropagation* apresentando coeficiente de correlação de 0,67 e o *Resilient Propagation* de 0,74.

Assim como nos resultados de correlação estatística (Tabela 2), os maiores coeficientes de correlação foram obtidos para a produção de matéria seca da parte aérea e a extração de N pelas plantas de trigo (Tabela 6), demonstrando que os sensores Crop Circle e GreenSeeker têm sensibilidade para acusar variação na produção de matéria seca da parte aérea das plantas e, indiretamente, em outros atributos da cultura do trigo.

Os coeficientes de correlação obtidos pelas redes neurais estabelecidas (Tabela 6) foram relativamente semelhantes aos obtidos pelas análises estatísticas (Tabela 2). O maior coeficiente de correlação foi de 0,80 nas análises estatísticas para a extração de N pelas plantas de trigo com as leituras do sensor GreenSeeker (Tabela 2) e o melhor coeficiente de correlação encontrado para as RNAs foi de 0,76 para a extração de N pelas plantas de trigo e também com as leituras do sensor GreenSeeker, demonstrando certo limite de aprendizagem para as redes neurais.

Com relação aos erros, obteve-se, em média, cerca de 4,00% do atributo meta N na folha bandeira para o algoritmo *Backpropagation* e 4,50% para o algoritmo *Resilient Propagation*; 11,00 % do atributo meta produção de matéria seca da parte aérea do trigo para o algoritmo *Backpropagation* e 10,50% para o algoritmo *Resilient Propagation*; e 15,50% do atributo meta extração de N pelas plantas de trigo para o algoritmo *Backpropagation* e 14,00% para o algoritmo *Resilient Propagation*. Nota-se que o desempenho dos algoritmos em relação aos erros apresentou uma pequena diferença em porcentagem. Atribui-se esse fato ao comportamento linear dos atributos de entrada em relação aos atributos meta. Embora o modelo *Perceptron* seja indicado para problemas em que os dados dos atributos meta e de entrada sejam linearmente separáveis, nesse trabalho, ao utilizar esse modelo a rede neural não apresentou aprendizado satisfatório. Já, quando se empregou o modelo *Perceptron Multi Camadas*, adicionando-se uma camada oculta, a rede pôde abstrair aprendizado dos dados apresentados.

6. CONCLUSÕES

As doses de N aplicadas em cobertura na cultura do trigo exerceram influência positiva no acúmulo de matéria seca e na nutrição de N da cultura. Porém, o aumento na produção de matéria seca não resultou diretamente em aumento na produtividade de grãos de trigo.

As leituras do sensor Clorofilog 1030 não se correlacionaram significativamente com o teor de N na folha bandeira, a produção de matéria seca da parte aérea e a extração de N pelas plantas de trigo. A cultura do trigo apresentou estado nutricional satisfatório, mesmo na ausência de adubação nitrogenada em cobertura.

Os índices obtidos pelos sensores Crop Circle e GreenSeeker demonstraram estreita correlação com as doses de N aplicadas em cobertura na cultura do trigo, a produção de matéria seca da parte aérea e a extração de N pelas plantas. Os sensores Crop Circle e GreenSeeker apresentaram correlação mais fraca com o teor de N nas folhas e, principalmente, com a produtividade de grãos de trigo.

As diferenças no desempenho do Clorofilog 1030 em relação aos sensores Crop Circle e GreenSeeker observadas no presente estudo se devem ao fato de o sensor Clorofilog 1030 ser mais eficiente na mensuração do teor de N nas folhas, os quais não apresentaram alterações significativas pela nutrição satisfatória das plantas, mesmo na ausência de adubação nitrogenada em cobertura.

Com a utilização de Redes Neurais Artificiais, o uso do modelo *Perceptron* não se mostrou eficiente, apesar de ser indicado para dados com comportamento linear, como era o caso desse estudo. Ao se empregar o modelo *Perceptron Multi Camadas*, com uma camada oculta, foi possível abstrair aprendizado da rede, porém, sem vantagens numéricas em relação às análises estatísticas. Também, o uso das doses de N como atributo de entrada para a rede neural não resultou em ganho de aprendizado, não contribuindo, portanto, para a melhora da correlação entre os dados estudados.

Os algoritmos de aprendizagem *Backpropagation* e *Resilient Propagation* não apresentaram ganhos efetivos de desempenho. O algoritmo *Backpropagation* apresentou desempenho melhor para os índices obtidos pelo sensor GreenSeeker com os atributos N na folha bandeira e produção de matéria seca do trigo, enquanto o desempenho do algoritmo *Resilient Propagation* foi melhor para os índices do

sensor Crop Circle com os atributos produção matéria seca e extração de N pelas plantas de trigo.

Considerando que ambos os métodos empregados atingiram resultados de correlação semelhantes, a rede neural treinada pode ser considerada uma alternativa para análise e interpretação desse tipo de dado, por tornar essa análise mais rápida, sem a necessidade de ajuste constante do modelo estabelecido.

7. TRABALHOS FUTUROS

Em continuidade aos conhecimentos adquiridos no presente trabalho, seria interessante realizar aprofundamento dos seguintes estudos:

- Realizar leitura dos sensores em diferentes estádios de desenvolvimento de culturas cereais visando elaborar técnicas para o diagnóstico de doses de fertilizante nitrogenado a serem aplicadas em taxa variável.

- Utilizar Redes Neurais Artificiais para estudar a correlação entre os atributos de desempenho de culturas cereais e os índices de refletância espectral calculados a partir de imagens obtidas por câmeras instaladas em veículos aéreos não tripulados.

- Avaliar a correlação entre os atributos de desempenho de culturas cereais e os índices de refletância espectral com a utilização de outras técnicas de aprendizado de máquina, como indução de regras e máquinas de vetores de suporte.

8. REFERÊNCIAS BIBLIOGRÁFICAS

- AGRICON. Disponível em: < <http://www.agricon.de/en/products/yara-n-sensor/basic-technical-information>>. Acesso em: 25 set, 2011.
- AMARAL, L. R.; MOLIN, J. P. Sensor óptico no auxílio à recomendação de adubação nitrogenada em cana-de-açúcar. **Pesquisa Agropecuária Brasileira**, v.46, n.12, p.1633-1642, 2011.
- ARENDT, P. F. **Resistência de genótipos de trigo a brusone**. 75 f. Dissertação (Mestrado em Agronomia). Universidade de Passo Fundo, Passo Fundo, 2006.
- ARTERO, A. O. **Inteligência Artificial Teórica e Prática**. 1 ed. São Paulo: Livraria da Física. 2009. 230 p.
- BARBER, D. **Bayesian Reasoning and Machine Learning**. 1 ed. Cambridge: Cambridge University Press. 2012. 646p.
- BASTOS, E. **Trigo: da lavoura ao pão**. 1 ed. São Paulo: Ícone. 1987. 95p.
- BENETT, C. G. S.; BUZZETTI, S.; SILVA, K. S.; TEIXEIRA FILHO, M. C. M.; ANDREOTTI, M.; ARF, O. Aplicação foliar e em cobertura de nitrogênio na cultura do trigo no cerrado. **Semina: Ciências Agrárias**, v. 32, n. 3, p. 829-838, 2011.
- BLACKMER, T. M.; SCHEPERS, J. M.; VARVEL, G. E.; WALTER-SHEA, E. A. Nitrogen deficiency detection using reflected shortwave radiation from irrigated corn canopies. **Agronomy Journal**, v.88, p.1-5, 1996.
- BONATO, C. M.; RUBIN FILHO, C. J.; MELGES, E.; SANTOS, V. D. **Nutrição mineral de plantas**. Universidade Estadual de Maringá, 1998. Disponível em: <<http://www.dbi.uem.br/apost2.pdf>>. Acesso em: 28 set. 2011.
- BOSCHINI, A. P. M.; SILVA, C. L.; OLIVEIRA, C. A. S.; OLIVEIRA JUNIOR, M. P.; MIRANDA, M. Z.; FAGIOLI, M. Aspectos quantitativos e qualitativos do grão de trigo influenciados por nitrogênio e lâminas de água. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.15, n.5, p. 450-457, 2011.
- BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. **Redes Neurais artificiais: Teoria e aplicações**. 2 ed. Rio de Janeiro: LTC, 2000. 238 p.
- BRAGA, A. P.; CARVALHO, A. P. L.; LUDERMIR, T. B. **Redes Neurais Artificiais**. In: _____. Sistemas Inteligentes: Fundamentos e aplicações. 1 ed. Barueri: Manole, 2005. p. 141-168.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Brasil projeções do agronegócio 2011/2012 a 2021/2022**. Brasília, 2012.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Acompanhamento da Safra Brasileira de Grãos 2011/12 – Oitavo Levantamento – Maio/2012**. Brasília: Conab, 2012.
- BRITO, G. G.; SOFIATTI, V.; BRANDÃO, Z. N.; SILVA, V. B.; SILVA, F. G.; SILVA, D. A. Non-destructive analysis of photosynthetic pigments in cotton plants. **Acta Scientiarum Agronomy**, v.33., n.4., p. 671-678, 2011.
- BUSATO, C. **Características da planta, teores de nitrogênio na folha e produtividade de tubérculos de cultivares de batata em função de doses de nitrogênio**. 129 f. Dissertação (Mestrado em Fitotecnia). Universidade Federal de Viçosa, Viçosa, 2007.
- CASTRO, L. N.; et. al. Redes Neurais Construtivas: Uma Abordagem Comparativa. In: IV Congresso Brasileiro de Redes Neurais, 1999, São José dos Campos. **ANAIS...**São José dos Campos: ITA, 1999, p.102-107.

COSTA, E. J. X.; IYODA E. M.; PINHEIRO, E.; ZUBEN, F. V. Inteligência artificial aplicada à Zootecnia. **Revista Brasileira de Zootecnia**, v. 38, p. 390-396, 2009.

CRUZ, R. S. **Crescimento do capim Xaraes e Cameroon estabelecidos em duas classes de solos d submetidos a doses crescentes de Nitrogênio no Norte Tocantinense**. Dissertação (Mestrado em Ciência Animal Tropical), Universidade Federal de Tocantins, 2008.

DE ROS, C. O. Disponibilidade de nitrogênio e produtividade de milho e trigo com diferentes métodos de adubação nitrogenada no sistema plantio direto. **Ciência Rural**, v. 33, n. 5, p. 799-804, 2003.

DIAS, A. H.; MATHIAS, I. M.; VIRGENS FILHO, J. S.; RICKLI, L. I. Aplicação de redes neurais artificias de topologia MLP em simulação de dados radiométricos. **Revista Brasileira de Agrocomputação**, v.2, n.2, p.5-11, 2007.

EITEL, J. U. H.; VIERLING, L. A.; LONG, D. S.; HUNT, R. E. Early season remote sensing of wheat nitrogen status using a green scanning laser. **Agricultural and Forest Meteorology**, v. 151, n. 10, p. 1338-1345, 2011.

ERDLE, K.; MISTELE, B.; SCHIMIDHALTER, U. Comparison of active and passive spectral sensors in discriminating biomass parameters and nitrogen status in wheat cultivars. **Field Crops Research**, v.124, p.74-84, 2011.

ERNANI, P.R.; SANGOI, L.; LECH, V. A.; RAMPAZZO, C. A forma de aplicação da uréia e dos resíduos vegetais afeta a disponibilidade de nitrogênio. **Ciência Rural**, v.35, n.2, p. 360-365, 2005.

ESPINDULA, M. C. Doses e formas de aplicação de nitrogênio no desenvolvimento e produção da cultura do trigo. **Ciência e Agrotecnologia**, v. 34, n. 6, p. 1404-1411, 2010.

FRANÇA, M. M. Análise do uso da terra no município de Viçosa-MG mediado por classificações supervisionadas com redes neurais artificiais e Maxver. **Revista Brasileira de Geografia Física**, v.2, n.3, p.92-101, 2010.

GALO, M. L. B. T.; VELINI, E. D.; TRINDADE, M. L. B.; SANTOS, S. C. A. Uso do sensoriamento remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do complexo Tietê. **Planta Daninha**, v.20, n.spe, p. 7-20, 2002.

GROHS, D. S. **Modelo para estimativa do potencial produtivo em trigo e cevada pelo índice de vegetação por diferença normalizada**. 2008. 124 f. Dissertação (Mestrado em Fitotecnia), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

GROHS, D. S.; BREDEMEIER, C.; MUNDSTOCK, C. M.; POLETO, N. Modelo para estimativa do potencial produtivo em trigo e cevada por meio do sensor GreenSeeker. **Engenharia Agrícola**, v.29, n.1, p.101-112, 2009.

GUIMARAES, A. M.; MATHIAS, I. M.; DIAS, A. H.; FERRARI, J. W.; CAZELATTO JUNIOR, C. R. Módulo de validação cruzada para treinamento de redes neurais artificais com algoritmos *Backpropagation* e *Resilient Propagation*. **Publicatio UEPG**. Ciências Exatas e da Terra, Ciências Agrárias e Engenharias (Impresso), v. 1, p. 17-24, 2008.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v. 11, n. 1, p. 10-18, 2009.

HAYKIN, S. **Redes Neurais: princípios e práticas**. 2 ed. Porto Alegre: Bookman, 2001. 900 p.

HEINEMANN, A. B.; STONE, L. F.; DIDONET, A. D.; TRINDADE, M. G.; SOARES, B. B.; MOREIRA, J. A. A; CÂNOVAS, A. D. Eficiência de uso da radiação solar na produtividade do trigo decorrente da adubação nitrogenada. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.10, p.352-356, 2006.

HOLLAND SCIENTIFIC. Disponível em: < <http://hollandscientific.com/> > . Acesso em: 29 jun, 2011.

HURTADO, S. M. C.; RESENDE, A. V.; SILVA, C. A.; CORAZZA, E. J.; SHIRATSUCHI, L. S. Agricultura de precisão: possibilidades de manejo da adubação nitrogenada para o milho no Cerrado. **Embrapa Cerrados**. Planaltina: documento 214, 2008.

INMAN, D.; KHOSLA, R. On-the-go active remote sensing for efficient crop nitrogen management. **Sensor Review**, v.25, n.3, p. 209-214, 2005.

INPE. **Introdução ao sensoriamento remoto**. Divisão de sensoriamento remoto. Disponível em: < <http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm> > . Acesso em: 09 nov, 2012.

JESUS, S. V.; MARENCO, R. A. O SPAD-502 como alternativa para a determinação dos teores de clorofila em espécies frutíferas. **Acta Amazonica**, v. 38, n.4, p. 815-818, 2008.

KANTARDZIC, M. **DATA MINING: Concepts, Models, Methods, and Algorithms**. IEEE. Press. 2003. 345p.

KOCH, B., KHOSLA, R.; FRASIER, M.; WESTFALL, D. G. Economic feasibility of variable rate nitrogen application utilizing site-specific management zones. **Agronomy Journal**, v.96,p.1572-1580, 2004.

LARCHER, W. **Ecofisiologia Vegetal**. 1 ed. São Carlos: Rima, 2004. 531 p.

LIBRALÃO, G. L.; NETTO, A. V.; CARVALHO, A. P. L .F.; OLIVEIRA, M. C. F. Determinação de vícios refrativos oculares utilizando support vector machine. **Revista Controle e Automação**. v.16, n.2, p.146-158, 2005.

LIU, M. et al. Neural-network model for estimating leaf chlorophyll concentration in rice under stress from heavy metals using four spectral indices. **Biosystems Engineering**. v. 06, n.1, p. 223-233, 2010.

MALAVOLTA, E.; VITTI, G. C.; OLIVEIRA, S. A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. 2 ed. Piracicaba: Potafos, 1997. 319 p.

MARKWELL, J.; OSTERMAN, J. C.; MITCHELL, J. L. Calibration of the Minolta SPAD-502 leaf chlorophyll meter. **Photosynthesis Research**, v. 46, n. 3, p. 467-472, 1995.

MATHIAS, I.M. **Aplicação de redes neurais artificiais na análise de dados de molhamento foliar por orvalho**. 120 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrônomicas. Universidade Estadual Paulista “Julio de Mesquita Filho”, Botucatu, 2006.

MCDONALD, A. J. S.; ERICSSON, T.; LARSSON, C. Plant nutrition, dry matter gain and partitioning at the whole-plant level. **Journal of Experimental Botany**, v. 47, Special Issue, p. 1245-1253, 1996.

MENEZES, P. B.; ALMEIDA, T (Org). **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: CNPq/UnB, 2012.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizado de Máquina. In: _____. **Sistemas Inteligentes: Fundamentos e aplicações**. 1 ed. Barueri: Manole, 2005. 527 p.

MOTOMIYA, A.V. A; MOLIN, J. P.; CHIAVEGATO, E. J. Utilização de sensor óptico ativo para detectar deficiência foliar de nitrogênio em algodoeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.13, n.2, p.137–145, 2009.

NASCIMENTO, H. R.; ABREU, Y. V. **Geotecnologias e planejamento da agricultura de energia**. 1 ed. Málaga, Espanha: Eumed.Net, 2012, 145 p.

NOH, H. et al. A Neural Network Model of Maize Crop Nitrogen Stress Assessment for a Multi-spectral Imaging Sensor. **Byosistemas Engineering**, v. 94, n. 4, p. 477-485, 2006.

NUNES, A. S.; SOUZA, L. C. F.; MERCANTE, F. M. Adubos verdes e adubação mineral nitrogenada em cobertura na cultura do trigo em plantio direto. **Bragantia**, v. 70, n.2, p.432-438, 2011.

OLIVEIRA, A. C. S. et al. Aplicação de redes neurais artificiais na previsão da produção de álcool. **Ciência e Agrotecnologia**, v.34, n.2, p.279-284, 2010.

PORTZ, G.; MOLIN, J. P.; JASPER, J. Active crop sensor to detect variability of nitrogen supply and biomass on sugarcane fields. **Precision Agriculture**, v. 1, p. 1-12, 2012.

POVH, F. P.; MOLIN, J. P.; GIMENEZ, L. M.; PAULETTI, V.; MOLIN, R.; SALVI, J. V. Comportamento do NDVI obtido por sensor ótico ativo em cereais. **Pesquisa Agropecuária Brasileira**, v.43, n.8, p. 1075-1083, 2008.

RAMBO, L.; SILVA, P.R.F.; ARGENTA, G.; SANGOI, L. Parâmetros de planta para aprimorar o manejo da adubação nitrogenada de cobertura em milho. **Ciência Rural**, v.34, p.1637-1645, 2004.

RAMIREZ, M.B. **Monitoring Nitrogen Levels in the Cotton Canopy using Real-Time Active-Illumination Spectral Sensing**. 2010.126 f. Dissertação. Master of Science Degree. The University of Tennessee, Knoxville. 2010.

RAVEN, J.A., ANDREWS, M., QUIGG, A. The evolution of oligotrophy: implications for the breeding of crop plants for low input agricultural systems. **Annals of Applied Biology**, v. 146, p.261–280, 2005.

RAUN, W.R.; JOHNSON, G. V.; STONE, M. L.; SOLIE, J. B.; LUKINA, E. V.; THOMASON, W. E. In-Season Prediction of Yield Potential in Winter Wheat. **Better Crops**, v. 83, n. 2, p. 24-25, 1999.

RAUN, W.R.; SOLIE, J. B.; JOHNSON, G. V.; STONE, M. L.; LUKINA, E. V.; THOMASON, W. E.; SCHEPERS, J. S. In-season prediction of potential grain yield in winter wheat using canopy reflectance. **Agronomy Journal**, v.93, p.131-138, 2001.

RAUN, W.R.; SOLIE, J. B.; JOHNSON, G. V.; STONE, M. L.; MULLEN, R. W.; FREEMAN, K. W.; THOMASON, W. E.; LUKINA, E. V. Improving nitrogen use efficiency in cereal grain production with optical sensing and variable rate application. **Agronomy Journal**, v.94, p.815-820, 2002.

RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster *Backpropagation* learning: the RPROP algorithm. In: **International Conference on Neural Network (ICNN)**, 1993. San Francisco: Proceedings. San Francisco, p.586 – 591, 1993.

RISSINI, A. L. D. **NDVI, crescimento e produtividade de cultivares de trigo submetidas a doses de nitrogênio**. 2011. 53 f. Dissertação (Mestrado em Agronomia), Universidade Estadual do Centro-Oeste, Guarapuava, 2011.

ROJAS, R. *Neural Networks: A Systematic Introduction*. Springer-Verlag. 1996. 453p.

ROSSATO, O. B.; ANDRADE-SANCHEZ, P.; GUERRA, S. P. S.; CRUSCIOL, C. A. C. Sensores de refletância e fluorescência na avaliação de teores de nitrogênio, produção de biomassa e produtividade do algodoeiro. **Pesquisa Agropecuária Brasileira**, v.47, n.8, p. 1133-1141, 2012.

RYAN, L. Creating a “Normalized Difference Vegetation Index” (NDVI) image Using MultiSpec. **The Global Program**. University of New Hampshire. Disponível em: <<http://www.globe.unh.edu/MultiSpec/NDVI.pdf>>. Acesso em: 05 out, 2011.

SAGRILO, E.; VIDIGAL FILHO, P.S.; PEQUENO, M. G.; VIDIGAL, M. C. G.; SCAPIM, C. A.; KVITSCHAL, M. V.; MAIA, R. R.; RIMOLDI, F. Effect of harvest period on foliage production and dry matter distribution in five cassava cultivars during the second plant cycle. **Brazilian Archives of Biology and Technology**, v.49, n.6, p.1007-1018, 2006.

SAMBORSKI, S. M.; TREMBLAY, N.; FALLON, E. Strategies to Make Use of Plant Sensors-Based Diagnostic Information for nitrogen recommendations. **Agronomy journal**, v. 101, n.4, p.800-816, 2009.

SANGOI, L.; ERNANI, P. R.; LECH, V. A.; RAMPAZZO, C. Lixiviação de nitrogênio afetada pela forma de aplicação da ureia e manejo dos restos culturais de aveia em dois solos com texturas contrastante. **Ciência Rural**, v.33, n.1, p. 65-70, 2003.

SANTOS, A. M.; SEIXAS, J. M.; PEREIRA, B. B.; MEDRONHO, R. A. Usando Redes Neurais Artificiais e Regressão Logística na Predição da Hepatite A. **Revista Brasileira de Epidemiologia**, v.8, n.2, p. 117-126, 2005.

SAUSEN, T. M. **Desastres naturais e geotecnologia: sensoriamento remoto**. São José dos Campos: INPE. 2008, 40 p.

SCHEIBLE, W. R.; MORCUENDE, R.; CZECHOWSKI, T.; FRITZ, C.; OSUNA, D.; PALACIOS-ROJAS, N.; SCHINDELASCH, D.; THIMM, O.; UDVARDI, M. K.; STITT, M. Genome-wide reprogramming of primary and secondary metabolism, protein synthesis, cellular growth processes, and the regulatory infrastructure of Arabidopsis in response to nitrogen. **Plant Physiology**, v.136, p. 2483-2499, 2004.

SCHEPERS, J. **Active Sensor Tidbits**. Revisão, 2008. Disponível em: <http://www.isafarmnet.com/08OFNConfPresent/Nitrogen/Nitrogen_Sensors_Handout.pdf>. Acesso em: 01 dez, 2011.

SCHEREN, P. L. **Informação sobre o trigo** (Triticum sp). Passo Fundo: Embrapa – CNTP, 1986.

SCHOENINGER, E. R.; KOEHLER, H. S.; BOTELHO, M. F.; WATZLAWICK, L. F.; OLIVEIRA, P. C. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. **Ambiência**, v. 4, n.3, p.529-549, 2008.

SCHRÖDER, J.J.; NEETESON, J.J.; OENEMA, O.; STRUIK, P.C. Does the crop or the soil indicate how to save nitrogen in maize production?: Reviewing the state of the art. **Field Crops Research**, v.66, p.151-164, 2000.

SCHIVITTARO, W. B.; GONÇALVES, D. R. N.; VALE, M. L. C.; RICORDI, V. G. Perdas de nitrogênio por volatilização de amônia e resposta do arroz irrigado à aplicação de ureia tratada com o inibidor de urease NBPT. **Ciência Rural**, v.40, n.6, p.1283-1289, 2010.

SERRANO, L.; FILELA, I.; PENUELAS, J. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. **Crop Science**, v.40, n.3, p.723-731, 2000.

SHEIVER, T. M.; KHOSLA, R.; WESTFALL, D. G. Evaluation of two crop canopy sensors for nitrogen variability determination in irrigated maize. **Precision Agriculture**, v.12, p. 892-904, 2011.

SILVA, D. B. Efeito do nitrogênio em cobertura. **Pesquisa Agropecuária Brasileira**, v.26, p.1387-1392, 1991.

SILVA, S. H. M.; LIMA, J. D.; BENDINI, H. N.; NOMURA, E. S.; MORAES, W. S. Estimativa da área foliar do antúrio com o uso de funções de regressão. **Ciência Rural**, v.38, n.1, p.243-246, 2008.

STREIT, N. M.; CANTERLE, L. P.; CANTO, M. W.; HECKTHEUER, L. H. H. As Clorofilas. **Ciência Rural**, v.35, n.3, p. 748-755, 2005.

TAIZ, L.; ZEIGER, E. **Fisiologia Vegetal**. 3. ed. Porto Alegre: Artmed, 2004. 719 p.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. 4. ed. Porto Alegre: Artmed, 2008. p.819.

TASCA, F. A. **Volatilização de amônia a partir da aplicação de duas fontes de nitrogênio, em laboratório**. Dissertação (Mestrado em Ciência Agroveterinárias), Universidade do Estado de Santa Catarina. 2009.

TASCA, F. A.; ERNANI, P. R.; ROGERI, D. A.; GATIBONI, L. C.; CASSOL, P. C. Volatilização de amônia do solo após a aplicação de uréia convencional ou com inibidor de uréase. **Revista Brasileira de Ciência do Solo**, v.35, p. 493-502, 2011.

TEIXEIRA FILHO, M. C. M. Doses, fontes e épocas de aplicação de nitrogênio em trigo irrigado em plantio direto. **Pesquisa Agropecuária Brasileira**, v.45, n.8, p.797-804, 2010.

TENG, T. K. **Introdução à Cromoterapia**. Disponível em: <<http://somostodosum.ig.com.br/conteudo/conteudo.asp?id=01283>>. Acesso em: 15 nov, 2012.

THENKABAIL, P.S.; SMITH R.B.; PAUW, E. Hyperspectral vegetation indices for determining agricultural crop characteristics, **Remote Sensing of Environment**, v. 71, p.158-182, 2000.

TRINDADE, M. G.; STONE, L. F.; HEINEMANN, A. B.; CÁNOVAS, A. D.; MOREIRA, J. A. A. Nitrogênio e água como fatores de produtividade do trigo no Cerrado. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.10, p.24-29, 2006.

TROTTER, T. F.; FRAZIER, P. F.; TROTTER, M. G.; LAMB, D. W. Objective biomass assessment using an active plant sensor (CROP CIRCLE) preliminary experiences on a variety of agricultural landscapes. **ANAIS...** 9th International Conference on Precision Agriculture. Colorado State University, Denver, Colorado, 2008.

VARGAS, L.K.; SELBACH, P.A.; SÁ, E. L. S. Imobilização de nitrogênio em solo cultivado com milho em sucessão à aveia preta nos sistemas plantio direto e convencional. **Ciência Rural**, v.35, n.1, p. 76-83, 2005.

VIANA, E.M.; KIEHL, J.C. Doses de nitrogênio e potássio no crescimento do trigo. **Bragantia**, v. 69, n. 4, p. 975-982, 2010.

VIEIRA, D. A. P.; PORTES, T. A.; STACCIARINI-SERAPHIN, E.; TEIXEIRA, J. B. Fluorescência e teores de clorofilas em abacaxizeiro cv. pérola submetido a diferentes concentrações de sulfato de amônio. **Revista Brasileira de Fruticultura**, v.32, n.2, p. 360-368, 2010.

WOLF, E. D.; FRANCI, L. J. Neural Network Classification of Tan Spot and Stagonospora Blotch Infection Periods in a Wheat Field Environment. **Phytopathology**, v. 90, n.2, p.108-113, 2000.

WUERGES, A. F. E.; BORBA, J. A. Redes neurais, lógica nebulosa e algoritmos genéticos: aplicações e possibilidades em finanças e contabilidade. **Journal of Information Systems and Technology Management**, v.7, n.1, p. 163-182, 2010.

XUE, L. H.; CAO, W.; LUO, W.; ZHANG, X. Correlation between leaf nitrogen status and canopy spectral characteristics in wheat. **Acta Phytoecol. Sinica**. v. 28, p. 172–177, 2004.

ZAGONEL, J.; VENÂNCIO, W. S.; KUNZ, R. P.; TANAMATI, H. Doses de nitrogênio e densidades de plantas com e sem regulador de crescimento afetando o trigo, cultivar OR-1. **Ciência Rural**, v.32, p.25-29, 2002.

ZHU, Y.; LI, Y.; FENG, W.; TIAN, Y.; YAO, X.; CAO, W. Monitoring leaf nitrogen in wheat using canopy reflectance spectra. **Canadian Journal of Plant Science**, v. 86, p.1037–1046, 2006.