

UNIVERSIDADE ESTADUAL DE PONTA GROSSA
SETOR DE CIÊNCIAS AGRÁRIAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

MODELOS MATEMÁTICOS E COMPUTACIONAIS PARA AVALIAÇÃO DO ESTADO
NUTRICIONAL DA SOJA POR MEIO DE DIAGNOSE EM FOLHAS E GRÃOS

RAFAEL POLTRONIERI

PONTA GROSSA
2015

RAFAEL POLTRONIERI

MODELOS MATEMÁTICOS E COMPUTACIONAIS PARA AVALIAÇÃO DO ESTADO
NUTRICIONAL DA SOJA POR MEIO DE DIAGNOSE EM FOLHAS E GRÃOS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação Aplicada da Universidade Estadual de Ponta Grossa, como parte dos requisitos para obtenção do título de Mestre em Computação Aplicada, Área de Computação para Tecnologias em Agricultura.

Orientador: Prof^o. Dr^o. Eduardo Fávero Caires
Coorientador: Prof^a. Dr^a. Alaine M. Guimarães

PONTA GROSSA
2015

Ficha Catalográfica
Elaborada pelo Setor de Tratamento da Informação BICEN/UEPG

Poltronieri, Rafael

P779 Modelos matemáticos e computacionais para avaliação do estado nutricional da soja por meio de diagnose em folhas e grãos/ Rafael Poltronieri. Ponta Grossa, 2015.
84f.

Dissertação (Mestrado em Computação Aplicada - Área de Concentração: Computação para Tecnologias em Agricultura), Universidade Estadual de Ponta Grossa.

Orientador: Prof. Dr. Eduardo Fávero Caires.

Coorientadora: Profª Drª Elaine M. Guimarães.

1. Glycine max. L. Merrill. 2. Análise foliar. 3. Composição mineral nos grãos. I. Caires, Eduardo Fávero. II. Guimarães, Elaine M.. III. Universidade Estadual de Ponta Grossa. Mestrado em Computação Aplicada. IV. T.

CDD: 635.652

TERMO DE APROVAÇÃO


Rafael Poltronieri


“MODELOS MATEMÁTICOS E COMPUTACIONAIS PARA AVALIAÇÃO DO ESTADO NUTRICIONAL DA SOJA POR MEIO DE DIAGNOSE EM FOLHAS E GRÃOS”.

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. José Carlos Ferreira da Rocha
UEPG


Dr. Helio Antonio Wood Joris
UEPG

Ponta Grossa, 23 de dezembro de 2015.

Dedico este trabalho a minha família, em especial a minha esposa Tinessa e minha filha Maria Luiza por estarem ao meu lado dando forças e apoiando independente das circunstâncias.

AGRADECIMENTOS

Agradeço à Deus por ter me dado sabedoria, saúde e me protegido a cada viagem realizada para a realização desse mestrado.

À Tinessa, minha esposa, que esteve ao meu lado em todos os momentos, me motivando para que tudo isso pudesse ser realizado.

À Maria Luiza, minha filha, que em todos os momentos de angústia, era a fonte inspiradora para a conclusão desse trabalho.

Agradeço a minha família por ter me ajudado, dando o suporte necessário em momentos em que não estava presente em Telêmaco.

Ao meu orientador Eduardo Fávero Caires e a minha Coorientadora Alaine M. Guimarães, pelo apoio e ensinamentos passados durante esse período.

Agradeço aos meus amigos Ademir, Leandro e Elvis pela ajuda na coleta das amostras, Berssa e Nasa pela parceria nas viagens realizadas e em especial a Marcos, Guilherme e Ricardo Baran por muitas vezes me cederem um colchão “velho” para dormir. Valeu Galerinha!!

Agradeço também ao pessoal do Laboratório de Solos da UEPG, Shively, Angelo e Dirce, pela ajuda na coleta e determinação dos teores dos nutrientes das amostras.

“Ninguém baterá tão forte quanto a vida. Porém, não se trata de quão forte pode bater, se trata de quão forte pode ser atingido e continuar seguindo em frente. É assim que a vitória é conquistada”.
(Filme Rocky Balboa)

RESUMO

Os modelos baseados nos métodos de Chance Matemática (ChM), Sistema Integrado de Diagnose e Recomendação (DRIS) e Diagnose da Composição Nutricional (CND) têm sido utilizados para avaliar o estado nutricional das plantas por meio da diagnose foliar. Porém, alguns fatores podem interferir na composição mineral das folhas, como a variedade da espécie ou cultivar, a idade das plantas, o tipo e o manejo do solo, as condições climáticas e o ataque de pragas e doenças. Considerando a hipótese que a avaliação do estado nutricional da cultura da soja pode ser realizada por meio de diagnose tanto nas folhas como nos grãos, o presente trabalho foi realizado com os objetivos de (i) avaliar a eficiência dos modelos ChM, DRIS e CND na avaliação do estado nutricional da soja por meio de diagnose em folhas e grãos, e (ii) utilizar os métodos computacionais de Máquina de Vetor de Suporte (SVM) e Redes Neurais Artificiais (RNA) como alternativa para avaliação do estado nutricional da soja. O trabalho foi realizado a partir de um banco de dados formado com 212 amostras de folhas e 216 amostras de grãos de soja coletadas em 2013–2014 de cinco experimentos de campo instalados em sistema plantio direto na região Centro-Sul do Paraná. As amostras de folhas foram coletadas por ocasião do florescimento e as de grãos após a colheita. Determinaram-se os teores de N, P, K, Ca, Mg, S, Cu, Fe, Mn e Zn nas folhas e nos grãos, e avaliou-se a produtividade de grãos. Os métodos de ChM, DRIS e CND apresentaram resultados satisfatórios quando aplicados aos teores de nutrientes nas folhas e nos grãos de soja, mas o DRIS apresentou maior consistência, especialmente quando aplicado aos teores de nutrientes nos grãos. Os métodos computacionais SVM e RNA apresentaram valores próximos dos extraídos pelo DRIS e CND. Os resultados sugerem que o método DRIS pode ser utilizado na avaliação do estado nutricional da cultura da soja por meio de diagnose nos grãos, e que os métodos computacionais SVM e RNA podem ser usados como alternativa aos modelos do DRIS e CND na avaliação do estado nutricional da soja por meio de diagnose em folhas e grãos.

Palavras-chave: *Glycine max.* L. Merrill, Análise Foliar, Composição Mineral nos Grãos

ABSTRACT

The models based on the method of Chance Mathematics (ChM), Diagnosis and Recommendation Integrated System (DRIS) and Compositional Nutrient Diagnosis (CND) have been used to assess the nutritional status of plants through foliar diagnosis. However, some factors may interfere on the leaves mineral composition, as the variety of species or cultivar, plant age, soil type and management, climate conditions, and the attack of pests and diseases. We hypothesized that the assessment of soybean nutritional status can be performed through diagnosis both on leaves and grains. The objectives were (i) to evaluate the efficiency of the ChM, DRIS, and CND models in assessing the soybean nutritional status through diagnosis in leaves and grains, and (ii) using the computational methods Support Vector Machine (SVM) and Artificial Neural Networks (ANN) as an alternative to evaluating the soybean nutritional status. The study was carried out from a database consisting of 212 leaf samples and 216 grain samples of soybean collected in 2013–2014 from five field experiments under no-till systems installed in the Central-South region of Paraná State, Brazil. The leaf samples were collected at flowering period and the grain samples were collected after harvest. The levels of N, P, K, Ca, Mg, S, Cu, Fe, Mn, and Zn in leaves and grains were determined, and grain yields were evaluated. The ChM, DRIS, and CND methods were satisfactory when applied to the nutrient content in leaves and grains. However, the DRIS model showed greater consistency, especially when applied to the nutrient content in grains. Computational methods SVM and ANN showed values close to those extracted by DRIS and CND. The results suggest that the DRIS method could be used to assess the soybean nutritional status through diagnosis in grains, and the computational methods SVM and ANN would be an alternative to DRIS and CND models in evaluating the soybean nutritional status through diagnosis in leaves and grains.

Keywords: *Glycine max.* L. Merrill, foliar analysis, mineral composition in grains

LISTA DE FIGURAS

Figura 1 - Pontos em um sistema cartesiano são separados com base em suas características e são atribuídos a duas classes diferentes: (a) possíveis hiperplanos de separação que não maximizam a margem entre as duas classes; (b) hiperplano de separação encontrado pela SVM, proporcionando a margem máxima.	25
Figura 2 – Pontos representando um problema não separável linearmente: (a) conjunto de dados não linear; (b) conjunto não linear no espaço de entrada; (c) conjunto linear no espaço transformado.....	26
Figura 3 – Representação de Redes Neurais Artificiais: (a) RNA Perceptron com uma camada de entrada e uma de saída; (b) RNA Multilayer Perceptron, onde além das camadas de entrada e saída existe a camada oculta.	29

LISTA DE QUADROS

Quadro 1 - Programação da Função DRIS.	33
Quadro 2 - Programação do Cálculo CND.	34
Quadro 3 - Modelo de arquivo arff para implementação da técnica SVM na ferramenta computacional.	35
Quadro 4 - Função de treinamento e extração dos resultados da SVM.	36
Quadro 5 - Configurações de número de camadas, taxa e tempo de aprendizagem das RNAs por nutriente, modelo (DRIS e CND), e tecido vegetal (folhas e grãos).	37
Quadro 6 - Função de treinamento e extração dos resultados da RNA.	37
Quadro 7 - Regressão SVM para N-DRIS com função de núcleo Polykernel.	61
Quadro 8 - Regressão SVM para N-DRIS com função de núcleo NormalizedPolyKernel. ...	61

LISTA DE TABELAS

Tabela 1 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de N em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	39
Tabela 2 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de P em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	40
Tabela 3 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de K em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	41
Tabela 4 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Ca em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	42
Tabela 5 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mg em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	42
Tabela 6 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de S em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	43
Tabela 7 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de B em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	43
Tabela 8 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Cu em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	44
Tabela 9 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Fe em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	45
Tabela 10 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mn em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	45
Tabela 11 -Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Zn em amostras de terceiro trifólio sem pecíolo, na cultura da soja ¹	46
Tabela 12 - Níveis de suficiência de nutrientes no terceiro trifólio sem pecíolo de soja e limites estabelecidos pelo método da Chance Matemática (ChM).....	47
Tabela 13 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de N em amostras de grãos de soja ¹	47
Tabela 14 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de P em amostras de grãos de soja ¹	48
Tabela 15 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de K em amostras de grãos de soja ¹	49
Tabela 16 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Ca em amostras de grãos de soja ¹	49
Tabela 17 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mg em amostras de grãos de soja ¹	50
Tabela 18 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de S em amostras de grãos de soja ¹	51

Tabela 19 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de B em amostras de grãos de soja ¹	51
Tabela 20 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Cu em amostras de grãos de soja ¹	52
Tabela 21 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Fe em amostras de grãos de soja ¹	53
Tabela 22 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mn em amostras de grãos de soja ¹	53
Tabela 23 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Zn em amostras de grãos de soja ¹	54
Tabela 24 – Níveis de suficiência de nutrientes nos grãos de soja estabelecidos pelo método da Chance Matemática (ChM).	55
Tabela 25 - Médias e desvios padrão das relações duais de nutrientes no terceiro trifólio sem pecíolo, para a população de alta produtividade de soja.	56
Tabela 26 - Médias e desvios padrão das relações duais de nutrientes nos grãos, para a população de alta produtividade de soja.	57
Tabela 27 - Equações de regressão para os teores de macronutrientes (g kg ⁻¹) e micronutrientes (mg kg ⁻¹) no terceiro trifólio sem pecíolo (F) e nos grãos (G) de soja em função do índice DRIS.	58
Tabela 28 – Faixa de suficiência dos teores de nutrientes no terceiro trifólio sem pecíolo e nos grãos de soja considerando uma amplitude de $\pm 10 \text{ } 2/3 \text{ s}$ para o índice DRIS ($-6,7 \leq I \leq 6,7$).	59
Tabela 29- Equações de regressão para os teores de macronutrientes (g kg ⁻¹) e micronutrientes (mg kg ⁻¹) no terceiro trifólio sem pecíolo (F) e nos grãos (G) de soja em função do índice CND.	59
Tabela 30 – Faixa de suficiência dos teores de nutrientes nas folhas e nos grãos de soja considerando uma amplitude de $\pm 2/3 \text{ s}$ para o índice CND ($-0,6,7 \leq I \leq 0,67$).	60
Tabela 31 – Melhores resultados da SVM para os métodos DRIS e CND em folhas e grãos de soja.	63
Tabela 32 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela SVM para o método DRIS.	64
Tabela 33 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela SVM para o método CND.	64
Tabela 34 - Melhores resultados da RNA para os métodos DRIS e CND em folhas e grãos de soja.	66
Tabela 35 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela RNA para o método DRIS.	67
Tabela 36 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela RNA para o método CND.	67
Tabela 37 – Faixa de suficiência e teor ótimo de nutrientes no terceiro trifólio sem pecíolo da soja estimados pelos métodos de Chance Matemática (ChM), DRIS, CND, SVM-DRIS, SVM-CND, RNA-DRIS e RNA-CND.	70
Tabela 38 – Faixa de suficiência e teor ótimo de nutrientes nos grãos de soja estimados pelos métodos de Chance Matemática (ChM), DRIS, CND, SVM-DRIS, SVM-CND, RNA-DRIS e RNA-CND.	71

SUMÁRIO

1. INTRODUÇÃO	13
1.1. Objetivos	14
1.1.1. Objetivo Geral	14
1.1.2. Objetivos Específicos	14
2. REVISÃO LITERATURA	15
2.1. Diagnóstico Nutricional	15
2.1.1 Chance Matemática (ChM)	17
2.1.2 Sistema Integrado de Diagnose e Recomendação (DRIS).....	19
2.1.3 Diagnose da Composição Nutricional (CND)	22
2.2 TÉCNICAS COMPUTACIONAIS.....	25
2.2.1 Máquina de Vetor de Suporte.....	25
2.2.2 Redes Neurais Artificiais.....	28
3. MATERIAL E MÉTODOS	30
3.1. Coleta e Preparo de Amostras de Tecido Foliar e Grãos de Soja.....	30
3.2. Determinação dos Teores de Nutrientes no Tecido Vegetal da Soja.....	31
3.3. Avaliação da Produtividade de Grãos de Soja	32
3.4. Desenvolvimento da Ferramenta Utilizando os Modelos ChM, DRIS, CND e os Métodos Computacionais.....	32
3.4.1 Chance Matemática (ChM)	32
3.4.2. Sistema Integrado de Diagnose e Recomendação (DRIS).....	33
3.4.3. Diagnose da Composição Nutricional (CND)	34
3.4.4. Máquina de Vetor de Suporte (SVM).....	35
3.4.5 Rede Neural Artificial	36
4. RESULTADOS E DISCUSSÃO	39
4.1. Chance Matemática (ChM)	39
4.2. Sistema Integrado de Diagnose e Recomendação (DRIS)	55
4.3. Diagnose da Composição Nutricional (CND).....	59
4.4. Máquina de Vetor de Suporte (SVM)	60
4.5. Rede Neural Artificial (RNA)	64
4.6. Definição de Teores e Faixa Ótima de Nutrientes nas Folhas e nos Grãos de Soja	67
5. CONCLUSÕES	72
REFERÊNCIAS.....	73
APÊNDICE A – Telas do Sistema.....	80

1. INTRODUÇÃO

Segundo a Organização das Nações Unidas (ONU), o mundo terá que produzir 70% mais alimentos até 2050 do que foi produzido em 2013. O Brasil se destaca como o segundo maior produtor de soja do mundo, com 81,5 milhões de toneladas na safra de 2012/2013 (EMBRAPA, 2013), sendo um dos principais agentes para alcançar a meta de aumento de produção. Para atingir este objetivo será necessário investir em tecnologias e melhor aproveitamento da terra, atingindo assim uma maior produção por área plantada.

Técnicas que visam aumentar a produtividade vêm sendo estudadas, sendo o estado nutricional das plantas um fator importante, pois quando há falta de nutrientes nas plantas a produtividade tende a diminuir e o valor nutricional dos grãos é afetado. A análise nutricional das plantas é realizada por meio de diagnose foliar, tendo como resultado possibilidades de intervenções mais precisas nos sistemas de produção com práticas de manejo e adubação (URANO et al., 2006; DEUS et al., 2012).

Os modelos baseados nos métodos da Chance Matemática (ChM), Sistema Integrado de Diagnose e Recomendação (DRIS) e Diagnose da Composição Nutricional (CND) têm sido utilizados para avaliar o estado nutricional das plantas, cujos resultados possibilitam aumentar o potencial produtivo das culturas. O método da ChM busca determinar a faixa de valores de um dado fator, interno ou externo à planta, em que se espera obter a máxima produtividade, possibilitando a determinação do nível crítico, do valor ótimo e da faixa de suficiência a partir de dados provenientes de monitoramentos nutricionais (WADT, 1996; DEUS et al., 2012). O método do DRIS considera as relações entre os nutrientes e as compara com um padrão de alta produtividade, permitindo identificar os nutrientes mais limitantes e diagnosticar de forma mais precisa o estado nutricional das plantas (HOOGERHEIDE, 2005). Já, o método de CND utiliza a relação entre o teor de um nutriente e a média geométrica dos teores dos demais componentes de matéria seca para obtenção da expressão de equilíbrio nutricional (URANO et al., 2006).

Em outra abordagem, o uso de técnicas de Aprendizado de Máquina, como a Máquina de Vetor de Suporte (SVM, do inglês Support Vector Machine) e a Rede Neural Artificial (RNA), pode fornecer uma classificação próxima às obtidas pelos métodos de ChM, CND e DRIS.

As técnicas SVM e RNA podem ser melhor ajustadas à análise nutricional da soja, demonstrando características não analisadas pelos métodos tradicionais, além de criar

modelos computacionais que podem agilizar os resultados. Essas técnicas foram aplicadas em trabalhos de predição de rendimento de grãos e teor de proteína em arroz (SARUTA et al., 2013), e de deficiência nutricional de nitrogênio em feijoeiro (BAESSO et al., 2012). Tais resultados sugerem a possibilidade de utilização de tais técnicas para a estimativa de faixas de suficiência de nutrientes em folhas e grãos de soja.

De acordo com Malavolta et al. (1997), alguns fatores podem interferir na composição mineral das folhas, como a variedade da espécie ou cultivar, a idade das plantas, o tipo e o manejo do solo, as condições climáticas e o ataque de pragas e doenças.

Com o objetivo de minimizar os fatores de interferência na avaliação do estado nutricional da cultura da soja, esse trabalho sugere uma abordagem de análise nutricional utilizando os grãos de soja como referência, considerando que tais análises estariam menos sujeitas à influência de fatores externos, além dos grãos poderem fornecer maior exatidão nos resultados. Com essa abordagem, espera-se evidenciar se os grãos de soja poderiam ser utilizados para análise do estado nutricional da cultura, possibilitando resultados tão ou mais eficientes do que os obtidos pela análise foliar.

1.1. Objetivos

1.1.1. Objetivo Geral

Realizar o diagnóstico nutricional da cultura da soja pelos métodos de ChM, DRIS, CND, RNA-DRIS, RNA-CND, SVN-DRIS, SVM-CND por meio de determinações dos teores de nutrientes em folhas e grãos.

1.1.2. Objetivos Específicos

- a) Analisar os teores de nutrientes em folhas coletadas na época do florescimento e nos grãos de soja com o intuito de estabelecer padrões para a sua interpretação.
- b) Implementar os métodos de ChM, DRIS e CND para a interpretação dos teores de nutrientes nas folhas e nos grãos de soja.
- c) Comparar a utilização das técnicas RNA e SVM através dos métodos DRIS e CND a fim de gerar modelos computacionais que possam ser utilizados para a identificação dos seus índices.

2. REVISÃO LITERATURA

2.1. Diagnóstico Nutricional

O crescimento e a produtividade das culturas são influenciados por fatores relacionados com as condições climáticas, tipo e manejo do solo, qualidade das sementes e disponibilidade de nutrientes para as plantas. A avaliação do estado nutricional das plantas é fundamental para corrigir desequilíbrios nutricionais e dimensionar a adubação. Um dos métodos utilizados para avaliar o estado nutricional das plantas é a diagnose foliar.

A diagnose foliar é definida como um método de avaliação do estado nutricional de culturas agrícolas em que se analisam determinadas folhas em períodos definidos da vida da planta (MALAVOLTA et al., 1997). Segundo Evenhuis e Waard (1980), a utilização da análise foliar para o diagnóstico do estado nutricional das plantas fundamenta-se na premissa de que há uma relação entre o suprimento de nutrientes pelo solo e os teores de nutrientes nas plantas, além das maiores ou menores produtividades relacionarem-se com acréscimos ou decréscimos nas concentrações dos nutrientes.

A recomendação de adubação em plantas normalmente é realizada através de diagnose da fertilidade do solo, associada, eventualmente, à diagnose do estado nutricional das plantas, por meio da interpretação dos resultados da análise química das amostras de solo e de tecido vegetal coletadas na lavoura (KURIHARA et al., 2013a). Segundo Malavolta et al. (1997), alguns fatores podem interferir na composição mineral das folhas, como a variedade da espécie ou cultivar, a idade das plantas, o tipo e o manejo do solo, as condições climáticas e o ataque de pragas e doenças. Nesse sentido, quanto maior for a similaridade das condições edafoclimáticas e da lavoura que se deseja diagnosticar com as condições em que foram estabelecidos os níveis críticos dos nutrientes, maior será a confiabilidade do diagnóstico nutricional (URANO et al., 2007). Isso implica na necessidade de realização de ensaios de calibração em vários locais e ao longo do tempo, a fim de assegurar quais as diferenças nas características de solo, clima e potencial produtivo de espécies vegetais estão sendo consideradas para o estabelecimento dos níveis críticos.

De acordo com Urano et al. (2006) e Castamann et al. (2012), variações no teor de um nutriente nas folhas podem influenciar não só o teor de outro nutriente como também o valor crítico deste. Combinações dos teores críticos foliares de nutrientes são necessárias para a obtenção de produtividades elevadas.

Para a amostragem adequada de folhas visando à diagnose foliar, cada cultura possui regras específicas. Na maioria das culturas, as amostras devem ser retiradas no início da floração, pois as folhas novas apresentam maior diluição de nutrientes, já que estão em fase de

crescimento, e as folhas mais velhas tendem a ter maior concentração de nutrientes, não representando o resultado nutricional adequado (GRASSI FILHO, 2008; OLIVEIRA, 2004).

As amostras foliares para a cultura da soja devem ser colhidas por ocasião florescimento, coletando-se de 30 a 40 folhas recém-maduras por ha⁻¹ com ou sem pecíolo, as quais correspondem às 3ª e 4ª folhas trifolioladas a partir do ápice da haste principal (BORKERT et al., 1994; MALAVOLTA et al., 1997).

Para a interpretação dos resultados da análise foliar são utilizados valores de referência. Esses valores são obtidos por meio de vários modelos, como a ChM, o DRIS e a CND. Urano et al. (2007) utilizaram esses modelos para comparar os teores ótimos de nutrientes na cultura da soja, e concluíram que tais métodos mostraram-se promissores na calibração de teores ótimos de nutrientes a partir de dados provenientes de monitoramentos nutricionais de lavouras comerciais. Kurihara et al. (2013b) utilizaram modelos de regressão entre teores foliares de nutrientes e os respectivos índices DRIS para estabelecer faixas de suficiência de teores de nutrientes em algodoeiro e soja, sendo que tal técnica resultou em uma estimativa da faixa de teores suficientes com amplitude, em geral, menor do que aquela estabelecida na literatura para essas culturas. Wadt et al. (2013) avaliaram os métodos da ChM e da CND para obtenção de valores de referência (faixas de suficiência) para lavouras arrozeiras e verificaram que o método da ChM indicou faixas de suficiência mais amplas do que aquelas obtidas pelo método da CND.

Kurihara et al. (2013a) estabeleceram modelos matemáticos para a estimativa da demanda nutricional por plantas de soja a partir da produção de matéria seca associada a um dado potencial produtivo almejado, e dos teores de nutrientes nos diversos órgãos da planta, ou, então, do Coeficiente de Utilização Biológica (CUB) estabelecido. Deus et al. (2012) avaliaram o estado nutricional do amendoim por meio do método da ChM e verificaram que esse método mostrou-se promissor para determinar a faixa de suficiência e o nível crítico de nutrientes. Harger et al. (2003) avaliaram o comportamento nutricional de quatro cultivares de soja de diferentes ciclos de maturação e concluíram que a avaliação nutricional da planta pelo índice DRIS pode ser utilizada como método diagnóstico a partir dos 27 dias após a emergência das plantas, independentemente do cultivar.

Em uma abordagem diferenciada, utilizando material proveniente de folhas e grãos de soja, Castamann et al. (2012) empregaram o modelo DRIS para diagnosticar o teor de óleo nos grãos de soja, tendo como objetivo estabelecer as normas DRIS e avaliar este método. Os resultados desse trabalho demonstraram a possibilidade de uso do DRIS para avaliar os nutrientes presentes nas folhas com o objetivo de melhorar o teor de óleo nos grãos de soja.

2.1.1 Chance Matemática (ChM)

O método da ChM consiste em estimar faixas de valores de nutrientes para se obter probabilidade de resposta de produtividade. Este método permite a determinação de faixas de suficiência e níveis ótimos, sem a necessidade de instalação e condução de uma rede de experimentos de adubação. Para cada nutriente em estudo, os teores foliares são classificados em ordem crescente e distribuídos em números de classes definidos pela raiz quadrada do número de observações (URANO et al., 2007). Sendo assim, quanto maior o número de observações, maior será a sensibilidade para identificar os diferentes níveis de produtividade considerando os teores nutricionais no tecido foliar. Os intervalos de valores de cada classe são determinados dividindo-se a amplitude dos teores do nutriente pelo número de classes estabelecido, de acordo com Wadt (1996). Em cada classe, calcula-se a chance matemática (ChM_i) conforme a equação 1:

$$\text{ChM}_i = (\text{ChM}(A_i/A) \times \text{ChM}(A_i/C_i))^{0.5} \quad [\text{Eq. 1}]$$

onde:

$$\text{ChM}(A_i/A) = P(A_i/A) \times \text{PROD}_i,$$

$P(A_i/A)$ = Frequência de lavouras de alta produtividade na classe i, em relação ao total geral de talhões de alta produtividade,

PROD_i = Produtividade média dos talhões de alta produtividade na classe i (kg ha⁻¹),

$$\text{ChM}(A_i/C_i) = P(A_i/C_i) \times \text{PROD}_i,$$

$P(A_i/C_i)$ = Frequência de talhões de alta produtividade na classe i, em relação ao total geral de talhões na classe i.

Para cada nutriente é determinado o nível máximo de cada classe considerando os maiores valores de ChM, enquanto o nível crítico é determinado pelo limite inferior, e o valor ótimo sendo a sua mediana (URANO et al., 2007).

O método da ChM foi estudado nas culturas de soja (KURIHARA, 2004; URANO et al., 2007), eucalipto (WADT et al., 1998), cana-de-açúcar (SANTOS et al., 2013) e laranja-pera (CAMACHO et al., 2012) para a determinação de valores de referência.

No caso da cultura da soja, Kurihara (2004) utilizou 257 amostras de folhas coletadas no estádio R₂, sendo 149 (58%) pertencentes à população de baixa produtividade (≤ 3.900 kg ha⁻¹) e 108 (42%) à população de referência, para avaliar os teores de N, P, K, Ca, Mg, S, B, Cu, Fe, Mn e Zn. Para cada nutriente, as amostras foram ordenadas e agrupadas em 15 classes e, posteriormente, calculou-se a ChM. Para os teores foliares de N, observou-se que um pequeno número de talhões de alta produtividade (A_i) prejudicou a ChM, pois quando há

grande quantidade de amostras (Ni), a sua proporção em relação ao total de talhões nas respectivas classes $[P(A_i/Ni)]$ não será necessariamente a mais elevada. Por outro lado, verificou-se também que pode ocorrer grande probabilidade em se encontrar talhões de alta produtividade em classes de teores constituídas de limitado número de amostras (Ni).

Urano et al. (2007) utilizaram 111 amostras foliares de soja, as quais foram coletadas e analisadas da mesma forma que no estudo de Kurihara (2004). Para cada nutriente, as amostras foram ordenadas e agrupadas em 10 classes e, posteriormente, calculou-se a ChM. Os resultados de N, S e Zn apresentaram maiores valores de ChM nas classes que obtiveram, de maneira geral, maior proporção de talhões de alta produtividade em relação ao número total de talhões de alta produtividade $[P(A_i/A)]$. Para Ca e B, a maior proporção entre os talhões de alta produtividade em relação ao número de talhões de cada classe $[P(A_i/C_i)]$ foi o que determinou a maior ChM. Já, para P, K, Mg, Cu, Fe e Mn, tanto $P(A_i/A)$ quanto $P(A_i/C_i)$ foram determinantes na definição das classes de teores com maiores valores de ChM.

Na cultura de eucalipto, Wadt et al. (1998) utilizaram informações de 1213 árvores adultas de híbridos de *Eucalyptus grandis* $\times$ *Eucalyptus urophylla*, tendo como dados a produtividade e a concentração de N, P, K, Ca, Mg e S nas folhas, galhos, casca e lenho. Os resultados indicaram uma amplitude da faixa ótima menor que a variação observada em plantações de *Eucalyptus grandis* na Austrália e na África do Sul. As exceções foram as amplitudes de N e Ca na casca, as quais foram superiores, e de P nos galhos, a qual esteve abaixo dos limites observados na Austrália. Já, P e Ca nas folhas apresentaram índices abaixo dos valores mínimos observados na África do Sul. Constatou-se também que o limite superior da faixa ótima de N, P, S, Ca e Mg mostrou-se inferior aos valores ótimos para a concentração desses nutrientes em folhas, o que evidenciou maior eficiência nutricional dos híbridos de *Eucalyptus grandis* $\times$ *Eucalyptus urophylla* em relação às árvores de *Eucalyptus grandis*.

Para a cana-de-açúcar, Santos et al. (2013) utilizaram 50 amostras de folhas com produção média de 60 Mg ha⁻¹ para análise dos teores de N, P, K, Ca, Mg, S, Cu, Mn e Zn. Os resultados da aplicação do método de ChM apontaram que as faixas normais obtidas apresentaram menor amplitude das classes de teores nutricionais em relação às faixas de suficiência descritas na literatura, concluindo que é possível utilizar o método para realizar o diagnóstico nutricional e a calibração de teores ótimos para a cultura de cana-de-açúcar.

Na laranja-pera, Camacho et al. (2012) utilizaram 50 amostras de folhas com produção média de 40,8 Mg ha⁻¹ para análise da ChM. Os resultados mostraram que a utilização do método foi mais adequada quando houve maior variação nos teores dos

nutrientes. As faixas normais obtiveram menor amplitude em seus valores em comparação aos de faixas de teores suficientes encontradas na literatura.

A análise desses resultados permite inferir que a ChM é um método adequado para a determinação de faixas de suficiência nutricional em diversas culturas. Entretanto, as relações entre as amostras de alta produtividade em cada faixa pelo total geral de amostras e as amostras de alta produtividade em relação ao total de amostras em cada faixa são os fatores que mais influenciaram a ChM. Outro fator importante foi a variação do teor do nutriente, tendo em vista que se a amplitude das classes for muito pequena, a tendência é dispersar as amostras de alta produtividade, fazendo com que a faixa de suficiência abranja a grande maioria das classes.

2.1.2 Sistema Integrado de Diagnose e Recomendação (DRIS)

O método do DRIS foi proposto por Beufls (1973) a partir da técnica chamada Diagnose Fisiológica (BEAUFILS, 1971), utilizada para estudar e identificar a influência de fatores ambientais do manejo sobre a produção de seringueira. A principal premissa foi a utilização de relações duais entre os nutrientes para indicar melhor equilíbrio nutricional nas plantas.

Diversas modificações surgiram a partir do método proposto por Beufls (1973), especialmente no princípio estatístico das fórmulas utilizadas no cálculo das relações dos índices DRIS. O método mais simplificado foi proposto por Jones (1981), o qual considera se a relação da amostra é maior ou menor que a norma DRIS utilizada, ponderando a variação das relações através da reciprocidade do desvio padrão (BATAGLIA & SANTOS, 1990).

O DRIS é uma ferramenta bastante útil para diagnose foliar, pois permite identificar desequilíbrios nutricionais que afetam a produtividade, mesmo quando nenhum nutriente está abaixo de seu nível crítico. Além disso, o método do DRIS hierarquiza nutrientes em ordem de limitação, gera índices de equilíbrio nutricional médio que permitem discriminar nutrientes limitantes e não limitantes, e ainda minimiza os efeitos de diluição ou de concentração de nutrientes nas amostras, resultantes de maior ou menor acúmulo de matéria seca (KURIHARA et al., 2013).

Para a formação das normas ou valores de referência é necessário um aporte considerável de dados básicos, a partir de uma população de referência. A definição da população de referência se dá pela divisão das amostras contidas na base de dados em duas categorias: população de referência, a qual possui produtividades superiores a um nível pré-

estabelecido, e população não-referência, a qual apresenta produtividades menores que o nível estabelecido (BEUFILS, 1973).

A coleta de dados deve ocorrer nas mais variadas condições edafoclimáticas, de modo que todos os fatores que afetam a variabilidade da produção sejam representados, permitindo a aplicação universal das normas ou valores de referência para cada cultura (BEAULFILS, 1973; MAEDA, 2002). Essas normas equivalem aos valores médios das relações entre os nutrientes, dos respectivos desvios padrão e dos coeficientes de variação, os quais correspondem a um determinado padrão de qualidade (MAEDA, 2002).

Para estimar os valores de referência é feito um relacionamento do teor foliar com o respectivo índice do nutriente, sendo que o teor ótimo corresponde ao valor do índice DRIS igual à zero, e a faixa ótima é obtida pela definição de uma amplitude de desvios padrão em torno deste valor ótimo (KURIHARA et al., 2013).

Para estimar o índice DRIS (I_y), para o nutriente y , é utilizada a fórmula da equação 2:

$$I_y = \frac{\sum_{i=1}^m f(Y/X_i) - \sum_{j=1}^n f(X_j/Y)}{m + n} \quad [\text{Eq. 2}]$$

onde:

I_y = Índice DRIS para o nutriente y ,

Y = Nutriente para cálculo do índice,

X = Outro nutriente,

m = Número de funções cujo nutriente Y encontra-se no denominador da função,

n = Número de funções cujo nutriente Y encontra-se no numerador da função,

$F(Y/X_i) = [(Y/X) - (y/x)] \times (c/s)$,

c = Fator de ajuste

s = Desvio padrão da relação dual da população de referência

Y/X e y/x = Relação dual entre os teores de nutrientes (g kg^{-1} e mg kg^{-1} , para macro e micronutrientes, respectivamente) na amostra e na população de referência, respectivamente.

A soma dos valores absolutos dos índices DRIS obtidos para cada nutriente resulta no Índice de Balanço Nutricional (IBN). O quociente entre o valor de IBN e o número de nutrientes analisados (n) define o Índice de Balanço Nutricional médio (IBNm), o qual representa a média dos desvios em relação ao ótimo (KURIHARA et al., 2013).

O DRIS foi utilizado em diferentes culturas para a determinação dos valores de referência, como o algodão (KURIHARA et al., 2008; SERRA et al., 2010), a soja

(KURIHARA et al., 2008; ROMAGNOLI et al., 2008; Urano et al., 2007), o feijão (PARTELLI et al., 2014), a mangueira (WADT et al., 2007) e a videira (TEIXEIRA et al., 2015).

No estudo de Kurihara et al. (2008) utilizaram-se 447 amostras de folhas de algodoeiro e 608 amostras de folhas de soja para calcular as faixas de suficiência dos teores de N, P, K, Ca, Mg, S, B, Cu, Fe, Mn e Zn por meio do método DRIS. Na cultura do algodoeiro, os teores de nutrientes se mantiveram dentro de faixas adequadas, exceto para N, K e B. Para cultura da soja, as amplitudes das faixas de teores se mostraram adequadas em amostras de folhas com pecíolo, com a tendência de serem inferiores às sugeridas na literatura para N, P, K, Ca, S, Cu e Zn, indicando a necessidade de estabelecimento de valores de referência específicos para o tipo de folha índice amostrado.

Serra et. al. (2010) estudaram o método DRIS para a cultura do algodoeiro utilizando 65 amostras de folhas. Os dados foram divididos com base na produtividade de 4250 kg ha⁻¹, sendo 40 amostras de alta produtividade e 25 de baixa produtividade. Os resultados revelaram que entre os talhões diagnosticados, o Mg e o P apresentaram maiores limitações por excesso e K, Ca, Mn, apresentaram maiores limitações por falta que os restante dos nutrientes. Assim sendo, a utilização do método DRIS mostrou-se satisfatória para avaliar o estado nutricional do algodoeiro.

Na cultura da soja, Romagnoli et. al. (2008) utilizaram um banco de dados com 276 amostras de folhas, sendo 136 de cultivares convencionais e 140 de cultivares transgênicos, para avaliar as normas DRIS. Para compor a população de referência foram utilizados três critérios: (i) a produtividade (1000 kg ha⁻¹ para soja convencional e 1500 kg ha⁻¹ para soja transgênica), (ii) os teores de nutrientes próximos aos descritos na literatura e (iii) a eliminação de pontos discrepantes da média da população. Com base nesses critérios, restaram 70 amostras de cultivares convencionais e 65 amostras de cultivares transgênicos. Essas amostras foram utilizadas para formar três grupos de avaliação, sendo o primeiro grupo composto pelos cultivares convencionais e transgênicos, o segundo grupo somente por cultivares convencionais e o terceiro grupo somente por cultivares transgênicos. Para as três populações de referência, os resultados revelaram uma correlação linear negativa entre a produtividade e o IBNm, demonstrando efeito do equilíbrio nutricional para a manutenção do potencial produtivo da soja.

Para a avaliação nutricional do feijão, Partelli et. al. (2015) utilizaram 55 amostras de folhas de lavouras comerciais. Para o estabelecimento da população de referência foi utilizado o critério de produtividade tendo como limite o rendimento de grãos de 2700 kg ha⁻¹,

limitando a população para 20 amostras. Os resultados indicaram que os nutrientes Mn, P e B foram os mais limitantes por deficiência, enquanto K e Ca foram os mais limitantes por excesso.

A utilização do método DRIS na cultura da mangueira (WADT et. al., 2007) mostrou equivalência entre as normas e os resultados obtidos para a cultura da soja (HALLMARK et al., 1990). No caso da mangueira, um pequeno número de plantas sadias e de alta produtividade resultou em normas DRIS equivalentes às informações de uma base com maior número de amostras, tendo-se observado discordância para poucos nutrientes (B, Zn e Mn).

Na cultura da videira, Teixeira et. al. (2015) utilizaram um banco de dados constituído por 116 amostras de folhas com os teores de N, P, K, Ca e Mg, provenientes de experimentos que receberam adubação com doses de N, P e K. O conjunto de dados foi separado em duas populações, tendo como limite a produtividade de 26 Mg ha⁻¹. Os resultados revelaram que a adubação em excesso, ao elevar os teores de N, P e K muito acima dos valores recomendados para videira, provoca diminuição na produtividade dos vinhedos. Observou-se também que as maiores produtividades apresentaram teores foliares de Ca e Mg superiores àqueles de baixa produtividade, reforçando a importância destes cátions para a videira. Portanto, as normas DRIS foram eficientes para discriminar as populações de alta e baixa produtividade de uva.

A partir dos estudos que utilizaram o método DRIS para o diagnóstico nutricional é possível verificar a eficiência do modelo em discriminar faixas de teores de nutrientes para altas produtividades por meio da diagnose foliar. Porém, não foram encontrados estudos que utilizaram os grãos de soja para a determinação de padrões nutricionais.

2.1.3 Diagnose da Composição Nutricional (CND)

O método proposto por Parent e Dafir (1992) definiu o termo composição nutricional como o somatório dos teores de macro e micronutrientes associados ao teor dos demais componentes da matéria seca. Já, o teor dos demais componentes é definido como o valor de complemento (R) representado pela diferença entre a composição total de 1000 g kg⁻¹ e o somatório dos teores de nutrientes na folha índice ($\sum x$).

Tal método, assim como o DRIS, baseia-se nas interações múltiplas que ocorrem entre todos os nutrientes, considerando que o nutriente está em equilíbrio nutricional quando o índice da variável multinutriente (Ivi) tende a zero. Porém, diferencia-se do DRIS ao utilizar o cálculo de média geométrica e uma correção do teor de cada amostra (KURIHARA, 2004).

O calculo é baseado nas equações 3 a 6:

$$R = 100 - \sum x_i \quad [\text{Eq. 3}]$$

$$G = (x_N \cdot x_P \cdot x_K \dots x_{Zn} \cdot R)^{\frac{1}{(n+1)}} \quad [\text{Eq. 4}]$$

$$V_i = \ln (x_i/G) \quad [\text{Eq. 5}]$$

$$I_{vi} = (V_i - v_i)/s_i \quad [\text{Eq. 6}]$$

onde:

x_i = Teores dos nutrientes na folha,

n = Número de nutrientes em avaliação,

R = Valor de complemento,

G = Média geométrica da composição nutricional,

V_i = Variável nutricional,

v_i = Média,

S_i = Desvio padrão,

I_{vi} = Índices das variáveis multinutrientes.

A interpretação dos índices da variável multinutriente é feita considerando o intervalo entre $-2/3s$ e $2/3s$ para o valor nutricional em equilíbrio (KURIHARA, 2004).

Estudos foram realizados em diferentes culturas com o método de CND, como a soja (KURIHARA, 2004; URANO et al., 2007), o arroz (WADT et al., 2013; TOMIO et al., 2015), o algodão (SERRA et al., 2010) e a mangueira (POLOTI et al., 2013).

Na cultura da soja, Kurihara (2004) utilizou 267 amostras de folhas para a construção dos modelos CND e DRIS, e observou que apesar do CND basear-se nas interações múltiplas que ocorrem entre todos os nutrientes, a análise de regressão para o teor de nutriente no terceiro trifólio em função de I_{zi} apresentaram relação linear, com ajuste próximo ao verificado no método DRIS. Verificou ainda que os teores ótimos estimados para I_{zi} igual a zero consistiram na própria média da população de referência. Os resultados revelaram que apesar de se considerar uma faixa de desvio padrão para o CND igual ao adotado para o DRIS, a amplitude de valores estimados pelo CND foi menor em relação aos demais métodos de diagnose avaliados.

Os resultados do estudo Urano et al. (2007) coincidem com os resultados obtidos por Kurihara (2004), pois os ajustes dos modelos estatísticos lineares entre o índice e os teores dos nutrientes nas folhas de soja com o CND foram próximos aos obtidos pelo índice DRIS, além de o teor ótimo estimado também ter correspondido ao teor médio da população de alta produtividade. Os resultados demonstraram que os métodos DRIS e CND foram promissores para a calibração de

teores ótimos para a cultura da soja, a partir de dados provenientes de monitoramento nutricional de lavouras comerciais.

Na cultura do arroz, Wadt et al. (2012) utilizaram 356 amostras de lavouras comerciais do Rio Grande do Sul, tendo como referência de alta produtividade o valor de 7864 kg ha⁻¹. As faixas determinadas pelo método CND para os teores de N, P, K, Ca, S e Cu, estiveram dentro dos intervalos de confiança dos teores médios nas diferentes classes de produtividade. Porém, para Mg, Zn e B, a faixa ótima esteve contida parcialmente em lavouras de baixa produtividade, para Fe em lavouras de alta produtividade e para Mn, parcialmente, em lavouras de alta produtividade. Esse resultados indicaram que não foi possível distinguir as faixas adequadas de produtividade média em relação aos teores de P, Ca, Mg, Cu, Mn e Zn.

Em outra abordagem na cultura do arroz, Tomio et al. (2015) realizaram amostragem com 30, 40 e 65 dias após a semeadura (DAS), com um total de 107 amostras por período. As normas CND variaram de acordo com as épocas de amostragem, principalmente entre as amostras coletadas aos 65 DAS e aquelas coletadas antecipadamente (30 e 40 DAS). Para as amostragens antecipadas (30 e 40 DAS), as normas não conseguiram prever satisfatoriamente a classificação quando utilizada três classes do potencial de adubação (PRA). Com a utilização de duas classes de PRA, os teores de N, P, Ca, Mn, B e Cu aumentaram consideravelmente a concordância entre os diagnósticos, atingindo níveis acima de 75% e possibilitando, assim, a antecipação do período da diagnose foliar para essa cultura.

O estudo realizado por Serral et al. (2010), na cultura do algodoeiro, utilizou 65 amostras de folhas para avaliar o estado nutricional das plantas. Para tanto, foram analisados todos os nutrientes e utilizado o valor de referência para produtividade de 4250 kg ha⁻¹. Após a construção das normas CND, realizou-se o cálculo qui-quadrado, observando a frequência com que os nutrientes ocorreram como mais limitantes no algodoeiro. Os resultados revelaram que o Mg e o P apresentaram maior limitação por excesso, enquanto K, Ca e Mn apresentaram maior frequência de limitação por falta desses nutrientes.

Na cultura da mangueira, Poloti et al. (2013) compararam os métodos DRIS e CND utilizando amostras foliares de 63 pomares. Com base na interpretação dos índices obtidos pelos métodos DRIS e CND, os métodos obtiveram um grau de concordância (GC) entre 90 e 100% das amostras para Zn, 91% para Ca, Mg, Cu e Mn, 73% para N e B, e menor que 73% para K, P e Fe. Os resultados revelaram que os métodos DRIS e CND apresentaram desempenhos semelhantes na avaliação do estado nutricional da mangueira, e que os pomares de manga do semiárido nordestino tiveram maior deficiência de micronutrientes (Zn, Fe e Cu) do que de macronutrientes.

2.2 TÉCNICAS COMPUTACIONAIS


As técnicas computacionais de Aprendizado de Máquina permitem a identificação de padrões de comportamento em um conjunto de dados e possibilitam a determinação de modelos de predição e classificação de dados. Dentre essas técnicas estão a Máquina de Vetor de Suporte e as Redes Neurais Artificiais, as quais têm se mostrado eficientes na realização das tarefas de classificação e regressão.

2.2.1 Máquina de Vetor de Suporte

A SVM é uma técnica de classificação e regressão que utiliza a teoria de aprendizagem estatística e tem demonstrado resultados promissores na análise de diversos tipos de dados, inclusive aqueles que apresentam com alta dimensionalidade (muitas variáveis) (TAN et al., 2009).

A ideia básica por trás desta técnica vem do caso simplificado em que duas classes são linearmente separáveis. Em tal caso, existe um hiperplano que é capaz de separar todas as amostras em duas classes. Na verdade, na maioria dos casos, mais do que um hiperplano satisfaz esta condição (Figura 1a), e um deles é escolhido como classificador com base na margem criada entre as duas classes (Figura 1b). Intuitivamente, o maior hiperplano é a margem e o menor corresponde às possibilidades de erros de classificação (MUCHERINO et al., 2009). Porém, em alguns problemas não é possível separar as classes linearmente. Na realidade, os problemas reais, em sua maioria, não são linearmente separáveis (TAN et al., 2009).

Figura 1 - Pontos em um sistema cartesiano são separados com base em suas características e são atribuídos a duas classes diferentes: (a) possíveis hiperplanos de separação que não maximizam a margem entre as duas classes; (b) hiperplano de separação encontrado pela SVM, proporcionando a margem máxima.




Fonte: MUCHERINO et al. 2009

A abordagem utilizada pela SVM para resolver esse tipo de problema consiste em mapear os dados para um espaço de dimensão maior. Para representar o limite de decisão

utiliza-se um subconjunto de exemplos de treinamento, conhecido como os vetores de suporte (TAN et al. 2009). O espaço de atributos original pode então ser transformado em um espaço de atributos de dimensão maior onde o conjunto de treinamento é linearmente separável. A Figura 2 ilustra essa separação.

Figura 2 – Pontos representando um problema não separável linearmente: (a) conjunto de dados não linear; (b) conjunto não linear no espaço de entrada; (c) conjunto linear no espaço transformado.



Fonte: LORENA e CARVALHO, 2007.

Existem várias implementações de SVM disponíveis para uso não comercial, como o algoritmo SMO (Sequential Minimal Optimization), que é uma implementação para realizar classificação de problemas binários e multiclases. Já para problemas de regressão o algoritmo SMOReg pode ser utilizado. Nesse algoritmo, é possível selecionar diversas funções que medem a similaridade no espaço transformado usando o conjunto de atributos no espaço original. A função de similaridade é conhecida como função do núcleo (kernel), sendo responsável pelos cálculos dos produtos escalares no espaço das características, podendo-se citar como exemplos: PolyKernel, PolyKernel normalizado, Puk e RbfKernel.

Trabalhos relacionados à SVM aplicada a agricultura têm sido publicados desde o início dos anos 2000 em diferentes contextos, como no estudo da influência dos níveis de maturidade de plantas daninhas sobre a classificação das espécies (BURKS et al., 2002) e na classificação de imagens hiperespectrais para detectar infestações de plantas daninhas e de status de nitrogênio na cultura do milho (GOEL et al., 2003).

Kovačević et al. (2010) aplicaram a SVM na estimativa de valores das propriedades do solo e na classificação do tipo de solo. Os resultados demonstraram que a SVM foi a melhor técnica para estimar os valores das propriedades físicas e de pH, comparada com outros modelos de regressão. Já, na tarefa de classificação, o desempenho foi similar às demais técnicas quando aplicadas em grandes conjuntos de dados, enquanto que em conjuntos de dados pequenos a SVM apresentou melhor desempenho.

Guerrero et al. (2012) aplicaram um método baseado em SVM para a identificação de plantas com componentes espectrais verdes mascaradas e não mascaradas. Os resultados demonstram que o método foi capaz de separar regiões em duas classes (mascarada e não mascarada), também foi possível identificar plantas e ervas daninhas, mesmo quando contaminadas pelo solo ou água da chuva.

Para análise nutricional de plantas, Zúñiga (2012) desenvolveu um sistema de visão artificial para verificar a possibilidade de identificação de níveis dos macronutrientes para a cultura do milho. Com utilização da SVM foi possível realizar a análise de textura e textura colorida, permitindo ao sistema ter uma flexibilidade na identificação de novas amostras, treinadas com um conjunto significativo de imagens, sendo que as imagens desconhecidas podem conter algumas variações nas características e assim mesmo serem reconhecidas pelo sistema.

Filgueiras et al. (2012) avaliaram os modelos de calibração PLS (regressão linear de mínimos quadrados parciais) e SVM na determinação de carbono orgânico do solo por espectroscopia na região do infravermelho próximo (NIR). Os resultados apontaram que o modelo de regressão PLS apresentou uma distribuição dos pontos com tendência não linear, indicando não se adequar aos dados. O mesmo não ocorreu com a SVM onde as amostras distribuíram-se de forma aleatória em torno da reta da relação linear, promovendo uma maior exatidão nos resultados.

Um modelo preditivo para o rendimento de grãos e teor de proteína em arroz foi desenvolvido por Saruta et al. (2013). O modelo utilizou a técnica SVM, a qual demonstrou potencial para descrever a relação entre o rendimento de grãos, o teor de proteína e múltiplas variáveis explicativas que refletiam na produtividade de arroz em campos diversificados. Esses resultados podem fornecer conhecimento útil para a tomada de decisão de adubação de cobertura e adubação de base.

Fortin et al. (2015) desenvolveram uma ferramenta para simular a lixiviação de nitrato e de K^+ na cultura da batata. Para tanto, utilizaram o algoritmo LS-SVM para realizar a estimativa dos teores de nitrato e K^+ . Os resultados demonstraram que a ferramenta foi eficiente para simular a lixiviação de nitrato e de K^+ , além de ter a expectativa de melhoria na capacidade de generalização do modelo quando for treinado com dados de outras regiões geográficas.

Para a criação de um modelo de classificação de detecção de hematomas em cultivares de macieira, Araujo et al. (2014) utilizaram imagens espectrais nas regiões do visível e infravermelho próximo (VNIR) e infravermelho de ondas curtas (SWIR) para a aplicações na

SVM. O algoritmo utilizado para a classificação foi o SMO. Os resultados apontaram que a técnica SVM atingiu resultados satisfatórios para a classificação dos grupos, sendo possível identificar regiões do espectro VNIR, referentes às características de absorção de água, óxidos de ferro e minerais de argila que pareciam ser, em grande parte, responsáveis pelas divisões dos grupos.

2.2.2 Redes Neurais Artificiais

As RNAs derivam de estudos das redes neurais biológicas, simulando neurônios através de nodos e as ligações entre eles. Dentre suas aplicações estão a classificação e a regressão, podendo ser utilizadas em diversas áreas de conhecimento.


As RNAs podem ser divididas em dois modelos, o Perceptron (Figura 3a) que é composto por duas camadas, onde a primeira contém os nodos de entrada e a segunda corresponde aos neurônios de saída. Estas camadas são ligadas de modo que sejam transmitidos pesos em cada ligação, os quais se ajustam ao longo do treinamento do modelo até que o mesmo fique consistente. Assim, o nodo de entrada simplesmente transmite o valor que recebe, enquanto o de saída é um dispositivo matemático que calcula o valor da saída. Já o modelo com múltiplas camadas, Multilayer Perceptron, (Figura 3b) possui uma estrutura mais complexa que o modelo Perceptron, podendo ter diversas camadas intermediárias ocultas entre os nodos de entrada e de saída. A propagação dos dados pode ser somente para as camadas da frente ou podem ser conectadas também com as camadas anteriores, sendo esse método denominado alimentação recorrente. A rede também pode usar diferentes tipos de funções de ativação dos neurônios, como lineares, hiperbólicas e sigmóides (logísticas), o que permite que estimem valores de atributos tanto com comportamento linear como não linear (TAN et al., 2009).

O uso de RNAs na agricultura tem sido visto já desde a década de 1990 em trabalhos voltados para a classificação de frutas (BEN-HANAN et al., 1992), bem como para verificar a segurança e confiabilidade de herbicidas residuais (FERRIS et al., 1992). Mais recentemente, Aitkenhead et al. (2012) produziram um modelo de rede neural para prever propriedades físicas e químicas do solo com diferentes níveis de precisão. Os resultados indicaram que a abordagem de RNAs pode ser um importante instrumento adicional na atividade do agrimensor de campo, pois é um método rápido e de baixo custo que pode fornecer informações indicativas sobre as características do solo.

Yu et al. (2012) propuseram um modelo de fertilização que é constituído de um conjunto de redes neurais, um método de agrupamento (k-means) e um multiplicador de

Lagrange. Os resultados indicaram que o modelo pode simular com precisão a relação não linear entre a produtividade e o teor de nutrientes do solo.

Figura 3 – Representação de Redes Neurais Artificiais: (a) RNA Perceptron com uma camada de entrada e uma de saída; (b) RNA Multilayer Perceptron, onde além das camadas de entrada e saída existe a camada oculta.



Fonte: (a) Adaptado de <http://www.codeproject.com/Articles/821348/Multilayer-Perceptron-in-Python>
 (b) Adaptado de http://dms.irb.hr/tutorial/tut_nnets_short.php

Baesso et al. (2012) identificaram a deficiência nutricional de nitrogênio no feijoeiro utilizando índices espectrais e técnicas de processamento de imagens. Para a análise, foram utilizadas RNAs com diferentes números de neurônios. Os resultados apontaram que é possível identificar a deficiência de nitrogênio aos 30 dias após a emergência (DAE) com a mesma exatidão que aos 40 DAE, viabilizando a realização de uma adubação em tempo hábil para a colheita.

Gago et al. (2010) compararam as tecnologias de RNAs com métodos estatísticos clássicos. Para a realização da comparação foi analisado um experimento de proliferação em vidro utilizando um explante de uma variedade do kiwi. O objetivo foi avaliar os efeitos da intensidade de luz e concentração de sacarose e otimizar o processo, tendo em conta todos os fatores que o influenciam. Os resultados indicam que a RNA, em particular, é capaz de modelar e otimizar o processo de estimar as melhores condições de proliferação, sem a necessidade de um conhecimento extremamente especializado em estatística.

O uso de RNA em visão computacional foi proposto no trabalho de Tan et al. (2014) para identificar doenças em sementes de soja. Trinta e nove parâmetros de características de cor, textura e forma foram computados depois do processamento das imagens de soja adquiridas. A dimensionalidade dos parâmetros característicos foi reduzida de 39 para 12 atributos utilizando o método de análise de componentes principais (PCA). O modelo de previsão foi construído utilizando algoritmos de RNA implementados no software MALAB.

A precisão de estimativa de doenças variou entre 92% e 96%. A precisão para sementes de soja heterogêneas com diversas doenças foi de 90%. Os resultados mostraram que o modelo de previsão construído pela rede neural foi satisfatório para a identificação de doenças em sementes de soja.

Não foram encontrados na literatura trabalhos relacionados ao diagnóstico nutricional da cultura da soja utilizando as técnicas computacionais SVM e RNA. Porém, considerando as características de estimativa de modelos de regressão dessas técnicas, bem como os demais trabalhos identificados, as mesmas podem se mostrar adequadas para essa finalidade.

3. MATERIAL E MÉTODOS

3.1. Coleta e Preparo de Amostras de Tecido Foliar e Grãos de Soja

As amostras de folhas e grãos de soja foram coletadas no ano agrícola de 2013–2014 de cinco experimentos instalados em lavouras comerciais da região Centro-Sul do Paraná, compreendendo um total de 212 amostras de folhas e 216 amostras de grãos. Essa diferença no número de amostras de folhas e grãos ocorreu porque em um total de quatro amostras de folhas houve falta de material vegetal para a realização das análises de B. A seguir, é realizada a descrição dos experimentos que deram origem às amostras utilizadas no presente estudo.

Experimento 1. O experimento foi realizado em um Latossolo Vermelho textura média. O delineamento utilizado foi em blocos ao acaso no esquema de parcelas subdivididas com três repetições, totalizando 60 unidades experimentais. Nas parcelas, foram aplicadas quatro doses de calcário na superfície (0, 4, 8 e 12 Mg ha⁻¹) em 2004 e, nas subparcelas, foram empregadas, anualmente, quatro doses de N (0, 60, 120 e 180 kg ha⁻¹ de N), na forma de nitrato de amônio, em cobertura nas culturas de inverno (aveia preta ou trigo), mais um tratamento sem N e sem cultura de inverno. O cultivar de soja empregado no ano agrícola de 2013–2014 foi o BMX Ativa RR.

Experimento 2. O experimento foi realizado em um Latossolo Bruno textura franco-arenosa. O delineamento utilizado foi em blocos ao acaso no esquema de parcelas subdivididas com três repetições, totalizando 48 unidades experimentais. Nas parcelas, foram aplicadas quatro doses de P₂O₅ (0, 30, 60 e 90 kg ha⁻¹) no sulco de semeadura da soja, na forma de superfosfato triplo e, nas subparcelas, foram empregadas quatro doses de gesso

agrícola (0, 2, 4 e 6 Mg ha⁻¹) na superfície, antes da semeadura em 2013. O cultivar de soja empregado no ano agrícola de 2013–2014 foi o NA 5909 RR.

Experimento 3. O experimento foi realizado em um Latossolo Vermelho textura argilosa, no mesmo delineamento e com os mesmos tratamentos e cultivar de soja descritos no experimento 2, totalizando 48 unidades experimentais.

Experimento 4. O experimento foi realizado experimento em um Latossolo Vermelho textura argilosa. O delineamento utilizado foi em blocos ao acaso no esquema de parcelas subdivididas com três repetições, totalizando 36 unidades experimentais. Nas parcelas, foram aplicados os seguintes tratamentos: (i) sem calcário, (ii) 4,5 Mg ha⁻¹ de calcário na superfície em 1998 + 4,0 Mg ha⁻¹ de calcário na superfície em 2013, e (iii) 4,5 Mg ha⁻¹ de calcário incorporado com aração e gradagem em 1998 + 4,0 Mg ha⁻¹ de calcário na superfície em 2013. Nas subparcelas, foram empregados os seguintes tratamentos: sem gesso, 3 Mg ha⁻¹ de gesso em 1998 + 3 Mg ha⁻¹ de gesso em 2013, 6 Mg ha⁻¹ de gesso em 1998 + 6 Mg ha⁻¹ de gesso em 2013 e 9 Mg ha⁻¹ de gesso em 1998 + 9 Mg ha⁻¹ de gesso em 2013. O cultivar de soja empregado no ano agrícola de 2013–2014 foi o BMX Energia RR.

Experimento 5. O experimento foi realizado em um Latossolo Vermelho textura argilosa. O delineamento utilizado foi em blocos ao acaso com seis tratamentos e quatro repetições, totalizando 24 unidades experimentais. Os tratamentos envolveram a aplicação da formulação 0–20–10 (N–P₂O₅–K₂O) em doses variando de 280 a 400 kg ha⁻¹ no sulco de semeadura. O cultivar de soja empregado no ano agrícola de 2013–2014 foi o NA 5909 RR.

As folhas de soja foram coletadas na época do florescimento da cultura da soja, retirando-se o terceiro trifólio sem pecíolo, a partir do ápice das plantas, em 30 plantas de cada unidade experimental. As amostras de grãos de soja, constituídas de aproximadamente 400 g de grãos de cada unidade experimental, foram tomadas logo após a colheita da soja nos experimentos.

3.2. Determinação dos Teores de Nutrientes no Tecido Vegetal da Soja

As análises químicas dos teores de nutrientes nas folhas e nos grãos de soja foram realizadas no Laboratório de Fertilidade do Solo da Universidade Estadual de Ponta Grossa (UEPG), conforme os métodos descritos em Malavolta et al. (1997). O N foi extraído por meio de digestão sulfúrica e determinado pelo método semi-micro-Kjeldahl. As análises de P, K, Ca, Mg, S, Cu, Fe, Mn e Zn foram realizadas por meio de digestão nítrico-perclórica e determinação por espectrofotometria de absorção molecular para P, fotometria de chama para

K, turbidimetria do sulfato de bário para S e espectrofotometria de absorção atômica para Ca, Mg, Cu, Fe, Mn e Zn. O B foi extraído por incineração e determinado por espectrofotometria de absorção molecular, pelo método da azometina H.

3.3. Avaliação da Produtividade de Grãos de Soja

A produtividade de grãos de soja, em cada unidade experimental, foi avaliada após a maturidade fisiológica da cultura, por meio de colheita manual e trilhagem em máquina debulhadora estacionária, corrigindo-se a umidade dos grãos para 130 g kg⁻¹.

3.4. Desenvolvimento da Ferramenta Utilizando os Modelos ChM, DRIS, CND e os Métodos Computacionais

Desenvolveu-se uma ferramenta computacional na linguagem de programação JAVA com o ambiente de desenvolvimento Netbeans 7.2 incluindo a biblioteca Ireport 4.7.1 para realização dos relatórios. A ferramenta tem como entrada os dados de teores de nutrientes no tecido vegetal (folhas e grãos) e de produtividade de grãos de soja de cada unidade experimental, sendo armazenados no banco de dados PostgreSQL versão 8.4. Para a comunicação entre a ferramenta e o banco de dados foi utilizada a biblioteca jdbc postgresql.8.4-703.

Em seguida, foram desenvolvidos os métodos para os modelos ChM, CND, DRIS, SVM e RNA para avaliar o estado nutricional das plantas.

3.4.1 Chance Matemática (ChM)

O desenvolvimento do módulo de ChM seguiu os passos descritos por Wadt (1996), tendo-se calculado a amplitude, por meio da diferença entre o maior e o menor teor do nutriente nas amostras, o número de classes através da raiz quadrada do número de amostras respeitando o máximo de 15 e o mínimo de 5 classes, e o intervalo entre as classes pela divisão da amplitude pelo número de classes.

Após a identificação das classes e seus limites inferiores e superiores, determinou-se o número total de amostras e o número de amostras de alta produtividade contidas em cada classe através de consultas SQL.

As probabilidades $P(A_i/A)$ e $P(A_i/N_i)$ foram calculadas por meio da divisão entre o número de amostras de alta produtividade na classe e o total de amostras de alta produtividade, e do número de amostras de alta produtividade pelo número de amostras da classe, respectivamente. A $PROD_i$ foi a produtividade média das amostras de alta produtividade da classe.

Depois de todas as variáveis terem sido calculadas, a ChM para cada classe foi calculada pela raiz quadrada da multiplicação entre $P(A_i/A) \times \text{PRODi}$ e $P(A_i/N_i) \times \text{PRODi}$.

Para cada nutriente, a faixa ótima consistiu das classes de valores que apresentaram maiores valores de ChM, sendo o seu limite inferior considerado o nível crítico e a sua mediana o valor ótimo do fator de produção (URANO et al., 2007).

Para a sistematização do método da ChM visando a definição da faixa ótima, foram considerados os valores de ChM maiores que 1, aceitando-se valores superiores a 0,7 nesse intervalo.

3.4.2. Sistema Integrado de Diagnóstico e Recomendação (DRIS)

Para a realização dos cálculos do DRIS foram desenvolvidas as funções `getmediadrispar`, `getmediadris` e `getdesviadris`, responsáveis pelos cálculos da relação dual entre os nutrientes de uma determinada amostra, da média da relação dual da população de referência e do desvio padrão da relação dual da população de referência, respectivamente.

Para cada amostra foram calculadas as funções $F(Y/X_i)$ e $F(X_j/Y)$ por meio da subtração entre a relação dual da amostra (`getmediadrispar`) e a média da relação dual da população de referência (`getmediadris`) dividida pela divisão entre o fator de correção $c = 10$ e o desvio padrão da relação dual (`getdesviadris`).

A obtenção do índice DRIS foi realizada de acordo com a fórmula descrita na equação 2 e apresentada através do Quadro 1:

Quadro 1 - Programação da Função DRIS.

```

indicei(Parcela, Valor de Referência, Tipo, Experimento){
    real f_y_x, f_x_y;
    for (int i=0; i<=10; i++){
        for(int j=0; j<=10; j++){
            if(i!=j){
                f_y_x=((db.getmediadrispar(nutrientes.get(i), nutrientes.get(j), parcela, tipo, exp_id)-
                db.getmediadris(nutrientes.get(i), nutrientes.get(j), valor, tipo))*10/db.getdesviadris(nutrientes.get(i), n
                utrientes.get(j), valor, tipo));
                f_x_y=((db.getmediadrispar(nutrientes.get(j), nutrientes.get(i), parcela, tipo, exp_id)-
                db.getmediadris(nutrientes.get(j), nutrientes.get(i), valor, tipo))*10/db.getdesviadris(nutrientes.get(j), n
                utrientes.get(i), valor, tipo));
                valores_i[i]=getValores_i()[i]+ f_y_x - f_x_y;
            }
        }
        valores_i[i]=getValores_i()[i]/(2*(11-1));
    }
}

```

Nessa função calculou-se o índice DRIS para todos os nutrientes de uma determinada amostra através da variação do índice i de 0 a 10, representando os teores de N, P, K, Ca, Mg, S, B, Cu, Fe, Zn e Mn, respectivamente. Para cada nutriente do índice i foi calculada a somatória da relação com os demais nutrientes representados pelo índice j e os dados foram armazenados no vetor `valores_i` para, posteriormente, ser calculado o índice dividindo o valor somado pelo número de nutrientes menos 1 (um) multiplicado por 2 (dois).

Para a obtenção das faixas de referência realizou-se uma regressão linear dos índices DRIS com os valores dos nutrientes, tendo-se atribuído os valores de $\pm 2/3$ do desvio padrão para o valor DRIS para a obtenção dos limites inferior e superior da faixa ótima. O valor ótimo foi obtido através da aplicação do índice 0 (zero) na regressão.

3.4.3. Diagnóstico da Composição Nutricional (CND)

O método CND foi desenvolvido utilizando as expressões apresentadas nas equações 3 a 6. Para os cálculos do índice CND foram construídas as funções `cndvi`, `cndmediavi` e `cnddesviovi`, e aplicadas nas funções apresentadas no Quadro 2:

Quadro 2 - Programação do Cálculo CND.

```
public void calcula(String par,String tipo,float valor){
    for(int i=0;i<=10;i++){
        valores_i[i]=(db.cndvi(par, nutrientes.get(i),tipo)- db.cndmediavi(valor, nutrientes.get(i),tipo))
        /db.cnddesviovi(valor, nutrientes.get(i),tipo);
        iem= getIem()+Math.abs(getValores_i()[i]);
    }
    iemm=getIem()/11;
}
```

A função `cndvi` foi calculada pelo logaritmo natural do nutriente dividido pela média geométrica da composição nutricional, a qual é o produto de todos os nutrientes multiplicado pelo valor de complemento R e elevado por 0,08333. O valor de complemento R foi calculado pela subtração de 1000 pela somatória de todos os elementos.

A média da variável nutricional foi calculada na função `cndmediavi`, sendo feita a média do cálculo do `cndvi` para toda a base de referência. A função `cnddesviovi` seguiu o mesmo preceito, mas ao invés da média foi feito o desvio padrão do cálculo de `vi`.

Para a obtenção do índice CND calculou-se a função $(cndvi - cndmediavi) / db.cnddesviovi$, para cada nutriente através do índice i variando de 0 a 10. As faixas de referência e os valores ótimos seguiram os mesmos cálculos usados para o método do DRIS.

3.4.4. Máquina de Vetor de Suporte (SVM)

Para a implementação da SVM foi construído um arquivo.arff para cada nutriente. O arquivo é composto de todos os valores nutricionais e o índice DRIS ou CND do respectivo nutriente meta conforme apresentado no Quadro 3.

Após a construção do arquivo arff foi implementado o método SVM incorporando a biblioteca WEKA.jar (HALL et al., 2009) a ferramenta desenvolvida.

Para a execução dos métodos de classificação do WEKA é necessário criar uma instância (Instances) do arquivo arff e definir o atributo meta através da função setClassIndex(). Após definida a instância de treinamento, foram definidas as configurações do algoritmo SMOreg, sendo elas a função do núcleo (kernel) e o valor da variável de complexidade, , conforme apresentado no Quadro 4.

Quadro 3 - Modelo de arquivo arff para implementação da técnica SVM na ferramenta computacional.

```
@relation parcelas
@attribute N numeric
@attribute P numeric
@attribute K numeric
@attribute Ca numeric
@attribute Mg numeric
@attribute S numeric
@attribute B numeric
@attribute Cu numeric
@attribute Fe numeric
@attribute Zn numeric
@attribute Mn numeric
@attribute Producao numeric
@attribute indice numeric
@data
52.1,3.2,28.6,7.8,4.2,2.2,37.3,12.4,340.3,27.9,106.0,3966.5,0.86417168
51.8,4.1,27.1,8.5,4.9,2.0,42.4,11.6,311.6,25.4,66.7,3712.8,0.58428442
44.2,3.2,25.6,7.3,5.1,2.0,40.7,11.6,345.7,27.5,94.7,3886.9,-4.1019888
35.8,3.3,24.1,6.8,5.6,1.6,41.3,5.9,259.9,21.8,84.8,3677.9,-7.3037863
```

A configuração do SMOreg foi obtida através de testes utilizando o software Weka 3.7.12. Esses testes consistiram em analisar qual função do núcleo e que valor da variável de complexidade se ajustavam melhor aos dados. Foi configurado para execução no sistema, a função do núcleo NormalizedPolyKernel e a variável de complexidade igual a 3,0. Os demais parâmetros não foram testados, permanecendo para os mesmos os valores default.

Para a extração dos resultados preditivos da SVM foi utilizado a função classifyInstance, onde é passado por parâmetro a instância a qual se deseja obter o valor que foi predito, para posteriormente ser armazenado o valor em um vetor de resultados.

A validação dos resultados foi realizada através do método de validação cruzada (CrossValidation), com 10 classes, tendo sido analisados o fator de correlação, erro médio absoluto, erro médio quadrático, erro relativo absoluto e raiz quadrada do erro relativo.

Quadro 4 - Função de treinamento e extração dos resultados da SVM.

```
BufferedReader bufferedReader = null;
bufferedReader = new BufferedReader(new FileReader(arquivo));
Instances train = new Instances(bufferedReader);
train.setClassIndex(train.numAttributes()-1);
Valores_i = new float[train.numInstances()];
bufferedReader.close();
SMOreg smo= new SMOreg();
String options = "-C 3.0 -N 0 -I \"weka.classifiers.functions.supportVector.RegSMOImproved -T 0.001 -V -P 1.0E-12 -L 0.001 -W 1\" -K \"weka.classifiers.functions.supportVector.NormalizedPolyKernel -E 2.0 -C 250007\"";
smo.setOptions(weka.core.Utils.splitOptions(options));
smo.buildClassifier(train);
//===== Extração dos valores de Predição =====
for(int k=0;k<train.numInstances();k++){
    Valores_i[k]=(float) smo.classifyInstance(train.instance(k));
}
//=====Teste de Precisão da SVM=====
Evaluation evaluation = new Evaluation(train);
evaluation.crossValidateModel(smo, train, 10, new Random(1));
System.out.println(evaluation.toSummaryString("Resultado\n=====\n", true));
```

3.4.5 Rede Neural Artificial

O processo de criação da RNA seguiu o mesmo princípio da SVM utilizando a biblioteca Weka, e a mesma estrutura de arquivos.arff apresentada no Quadro 3.

Diferentemente da SVM em que uma única configuração foi executada para todos os nutrientes e modelos, na RNA cada modelo e nutriente obteve uma configuração diferente para o método MultiLayerPerceptron conforme apresentado no Quadro 5.

Para identificar qual a melhor configuração da RNA para cada modelo e nutriente, foram realizados testes no software WEKA 3.7.12 para diferentes combinações de números de camadas e taxa de aprendizagem, com o tempo de aprendizagem de 500 épocas. O número de camadas ocultas variou de 5 a 12 e a taxa de aprendizagem entre 0.3 e 0.4. Após obter a

melhor configuração em relação ao número de camadas e taxa de aprendizagem testados, foi variado o tempo de aprendizagem entre 2000, 2500, 3000 e 3500 épocas, obtendo-se assim, a melhor configuração para cada modelo e nutriente.

O Quadro 6 apresenta a função programada para a execução da RNA, onde os parâmetros de configuração são passados em uma variável denominada options. A extração dos valores preditos e os resultados utilizam as mesmas funções utilizadas pela SVM.

Quadro 5 - Configurações de número de camadas, taxa e tempo de aprendizagem das RNAs por nutriente, modelo (DRIS e CND), e tecido vegetal (folhas e grãos)

DRIS						
Nutriente	Camadas	Folhas Taxa	Tempo	Camadas	Grãos Taxa	Tempo
N	10	0.4	2000	6	0.4	3500
P	5	0.4	3500	11	0.4	2500
K	11	0.3	3500	9	0.3	3500
Ca	5	0.3	3500	5	0.4	3500
Mg	5	0.4	3500	10	0.4	2000
S	9	0.4	3000	11	0.3	2500
B	6	0.3	3500	12	0.4	3000
Cu	8	0.3	3500	9	0.4	3500
Fe	9	0.4	3500	8	0.4	3500
Zn	11	0.3	2500	11	0.4	3500
Mn	6	0.4	3500	7	0.3	3000
CND						
N	6	0.3	3500	6	0.3	3500
P	7	0.4	3500	8	0.4	3500
K	7	0.3	3500	6	0.3	2000
Ca	11	0.3	3500	5	0.3	3500
Mg	5	0.4	2000	8	0.4	3500
S	9	0.4	3000	7	0.4	3500
B	10	0.4	2500	11	0.4	3500
Cu	5	0.4	3500	9	0.4	3500
Fe	9	0.3	3500	12	0.4	2000
Zn	11	0.4	3000	6	0.4	3500
Mn	6	0.4	3500	6	0.3	3000

Quadro 6 - Função de treinamento e extração dos resultados da RNA

```

BufferedReader bufferedReader = null;
bufferedReader = new BufferedReader(new FileReader(arquivo));
Instances train = new Instances(bufferedReader);
train.setClassIndex(train.numAttributes()-1);
Valores_i = new float[train.numInstances()];
bufferedReader.close();
MultilayerPerceptron rede= new MultilayerPerceptron();
rede.setOptions( Utils.splitOptions(options));
rede.buildClassifier(train);
//===================================================== Extração dos valores de Predição =====
for(int k=0;k<train.numInstances();k++){

```

```
        Valores_i[k]=(float) rede.classifyInstance(train.instance(k));
    }
//=====Teste de Precisão da RNA=====
Evaluation evaluation = new Evaluation(train);
evaluation.crossValidateModel(rede, train, 10, new Random(1));
System.out.println(evaluation.toSummaryString("Results\n=====\\n", true));
```


4. RESULTADOS E DISCUSSÃO

Para a realização das análises dos algoritmos ChM, DRIS e CND foi utilizado o valor de produtividade de referência de $3,6 \text{ t ha}^{-1}$. Esse valor é aproximadamente 15% maior que a produtividade média de soja alcançada nos últimos dois anos no Estado do Paraná, a qual foi de $2,95$ e $3,28 \text{ t ha}^{-1}$, respectivamente em 2013–2014 e 2014–2015 (COMPANHIA NACIONAL DE ABASTECIMENTO, 2015).

4.1. Chance Matemática (ChM)

4.1.1. Concentração de Nutrientes nas Folhas de Soja

Os valores de ChM para diferentes classes de frequência de distribuição de teores de N nas folhas de soja estão apresentados na Tabela 1. Nota-se que as classes 1, 4, 5 e 6, apesar de terem apresentado alta probabilidade de ocorrência em unidades experimentais de alta produtividade [$P(A_i/N_i)$], suas frequências em relação ao total de unidades experimentais de alta produtividade [$P(A_i/A)$] foram baixas, o que resultou em baixos valores de ChM. Por outro lado, verifica-se que o intervalo entre as classes 7 e 13 apresentaram elevados valores de ChM, entre 0,988 e 1,290, revelando que o limite inferior e o superior do nível de suficiência de N nas folhas de soja foram de $39,8$ e $58,7 \text{ g kg}^{-1}$, respectivamente, enquanto o teor ótimo foi a mediana desse intervalo, ou seja, $50,8 \text{ g kg}^{-1}$.

Tabela 1 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de N em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de N ----						----- t ha ⁻¹ -----	
1	23,6	26,3	2	2	0,011	1,000	4,057	0,435
2	26,3	29,0	4	3	0,017	0,750	4,081	0,464
3	29,0	31,7	3	1	0,006	0,333	3,611	0,158
4	31,7	34,4	6	5	0,029	0,833	3,916	0,606
5	34,4	37,1	8	7	0,040	0,875	3,933	0,738
6	37,1	39,8	11	9	0,052	0,818	4,119	0,847
7	39,8	42,5	13	11	0,063	0,846	4,339	1,004
8	42,5	45,2	24	20	0,115	0,833	4,464	1,382
9	45,2	47,9	16	10	0,057	0,625	4,325	0,820
10	47,9	50,6	32	27	0,155	0,843	4,464	1,615
11	50,6	53,3	37	34	0,195	0,919	4,345	1,841
12	53,3	56,0	34	26	0,149	0,765	4,298	1,453
13	56,0	58,7	18	16	0,092	0,889	4,563	1,305
14	58,7	61,4	4	3	0,017	0,750	4,720	0,537
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades

experimentais de alta produtividade em relação ao total de unidades experimentais da classe i ; $PROD_i$ = produtividade média das unidades experimentais de alta produtividade.

Para o teor foliar de P, as classes 1, 11, 12 e 13 (Tabela 2) apresentaram alta relação de unidades experimentais de alta produtividade na classe, porém não foram representativas em relação ao total de unidades experimentais de alta produtividade. Entre as classes 2 e 7, os valores de ChM foram maiores que os encontrados nas classes 8 a 10. Dessa forma, o intervalo entre as classes 2 e 8 foi definido como nível de suficiência para P, sendo $1,4 \text{ g kg}^{-1}$ o limite inferior e $5,6 \text{ g kg}^{-1}$ o limite superior, enquanto o teor ótimo foi de $3,3 \text{ g kg}^{-1}$.

Tabela 2 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de P em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N_i	A_i	$P(A_i/A)$	$P(A_i/N_i)$	$PROD_i$	ChM _i
	---- g kg^{-1} de P ----						----- t ha^{-1} -----	
1	0,8	1,4	1	1	0,006	1,000	3,970	0,301
2	1,4	2,0	27	20	0,115	0,741	4,257	1,242
3	2,0	2,6	24	21	0,121	0,875	4,205	1,367
4	2,6	3,2	34	28	0,161	0,824	3,995	1,455
5	3,2	3,8	50	35	0,201	0,700	4,130	1,550
6	3,8	4,4	27	23	0,132	0,852	4,391	1,474
7	4,4	5,0	19	17	0,098	0,895	4,911	1,452
8	5,0	5,6	8	8	0,046	1,000	4,690	1,006
9	5,6	6,2	5	5	0,029	1,000	4,576	0,776
10	6,2	6,8	9	8	0,046	0,889	4,541	0,918
11	6,8	7,4	3	3	0,017	1,000	4,939	0,649
12	7,4	8,0	2	2	0,012	1,000	4,968	0,533
13	8,0	8,6	3	3	0,017	1,000	5,260	0,691
14	8,6	9,2	0	0	0,000	0,000	0,000	0,000
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; $P(A_i/A)$ = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); $P(A_i/N_i)$ = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i ; $PROD_i$ = produtividade média das unidades experimentais de alta produtividade.

O nível de suficiência de K foi determinado pelo intervalo entre as classes 3 e 10 (Tabela 3), obtendo-se o limite inferior de $18,3 \text{ g kg}^{-1}$, o limite superior de $33,5 \text{ g kg}^{-1}$ e o teor ótimo de $27,4 \text{ g kg}^{-1}$. Nota-se que as classes 1 e 2 tiveram índices de ChM superiores à classe 5, porém as classes que antecederam e sucederam a classe 5 apresentaram altos valores de ChM, determinando assim o intervalo do nível de suficiência.

Tabela 3 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de K em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de K ----						----- t ha ⁻¹ -----	
1	14,5	16,4	8	7	0,040	0,875	4,692	0,88
2	16,4	18,3	6	6	0,034	1,000	4,468	0,83
3	18,3	20,2	18	17	0,098	0,944	4,657	1,415
4	20,2	22,1	8	8	0,046	1,000	4,690	1,006
5	22,1	24	11	8	0,046	0,727	4,359	0,797
6	24	25,9	26	20	0,115	0,769	4,066	1,209
7	25,9	27,8	42	30	0,172	0,714	4,066	1,427
8	27,8	29,7	35	30	0,172	0,857	4,210	1,619
9	29,7	31,6	31	27	0,155	0,871	4,533	1,667
10	31,6	33,5	20	16	0,092	0,800	4,291	1,164
11	33,5	35,4	5	3	0,017	0,600	5,105	0,519
12	35,4	37,3	1	1	0,006	1,000	4,379	0,332
13	37,3	39,2	0	0	0,000	0,000	0,000	0,000
14	39,2	41,1	1	1	0,006	1,000	4,076	0,309
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

No caso do teor foliar de Ca, as classes 1, 2, 3, 4 e 5 apresentaram baixos índices de ChM (Tabela 4), tendo como principal motivo a baixa frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade, além de não terem sido muito representativas em relação ao total de unidades experimentais. O nível de suficiência foi determinado pelo intervalo entre as classes 6 e 10, tendo-se definido os valores de referência de 6,1g kg⁻¹ como limite inferior, de 9,1 g kg⁻¹ como limite superior e o teor ótimo de 7,7g kg⁻¹.

Para o teor Mg nas folhas, uma unidade experimental apresentou concentração muita alta do nutriente e o agrupamento da maioria das unidades experimentais entre as classes 3 e 7 definiram o nível de suficiência (Tabela 5). Assim, o limite inferior e o superior do nível de suficiência de Mg nas folhas de soja foram de 2,3 e 4,3 g kg⁻¹, respectivamente, enquanto o teor ótimo foi de 3,4 g kg⁻¹.

O nível de suficiência de S foi gerado pelas classes 1, 2, 3, 4, 5, 6, 7, 8 e 9 (Tabela 6) indicando como limite inferior 0,9 g kg⁻¹ e superior de 4,9 g kg⁻¹. Nesse limite de classes estão relacionadas aproximadamente 97% das unidades experimentais, indicando uma baixa concentração de unidades experimentais com teores mais elevados de S. O teor ótimo de S foi de 2,2 g kg⁻¹.

Tabela 4 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Ca em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de Ca ----						----- t ha ⁻¹ -----	
1	3,1	3,7	2	0	0,000	0,000	0,000	0,000
2	3,7	4,3	3	1	0,006	0,333	4,190	0,183
3	4,3	4,9	2	1	0,006	0,500	3,894	0,209
4	4,9	5,5	1	0	0,000	0,000	0,000	0,000
5	5,5	6,1	8	6	0,034	0,750	4,385	0,705
6	6,1	6,7	19	15	0,086	0,789	4,003	1,044
7	6,7	7,3	31	26	0,149	0,839	4,375	1,549
8	7,3	7,9	51	46	0,264	0,902	4,503	2,199
9	7,9	8,5	44	37	0,213	0,841	4,444	1,879
10	8,5	9,1	19	15	0,086	0,789	4,337	1,131
11	9,1	9,7	12	10	0,057	0,833	3,944	0,863
12	9,7	10,3	14	11	0,063	0,786	4,171	0,930
13	10,3	10,9	4	4	0,023	1,000	4,244	0,643
14	10,9	11,5	2	2	0,011	1,000	4,264	0,457
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 5 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mg em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de Mg ----						----- t ha ⁻¹ -----	
1	1,3	1,8	2	0	0,000	0,000	0,000	0,000
2	1,8	2,3	8	4	0,023	0,500	3,802	0,408
3	2,3	2,8	28	22	0,126	0,786	4,169	1,314
4	2,8	3,3	49	42	0,241	0,857	4,252	1,934
5	3,3	3,8	66	60	0,345	0,909	4,584	2,567
6	3,8	4,3	39	31	0,178	0,795	4,289	1,614
7	4,3	4,8	15	10	0,057	0,667	4,290	0,840
8	4,8	5,3	3	3	0,017	1,000	3,943	0,518
9	5,3	5,8	1	1	0,006	1,000	3,678	0,279
10	5,8	6,3	0	0	0,000	0,000	0,000	0,000
11	6,3	6,8	0	0	0,000	0,000	0,000	0,000
12	6,8	7,3	0	0	0,000	0,000	0,000	0,000
13	7,3	7,8	0	0	0,000	0,000	0,000	0,000
14	7,8	8,3	1	1	0,006	1,000	3,759	0,285
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 6 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de S em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de S ----						----- t ha ⁻¹ -----	
1	0,9	1,4	15	13	0,075	0,867	4,151	1,056
2	1,4	1,9	49	39	0,224	0,796	4,176	1,764
3	1,9	2,4	57	43	0,247	0,754	4,246	1,833
4	2,4	2,9	22	18	0,103	0,818	4,197	1,221
5	2,9	3,4	15	11	0,063	0,733	4,175	0,899
6	3,4	3,9	16	12	0,069	0,750	4,258	0,968
7	3,9	4,4	11	11	0,063	1,000	4,475	1,125
8	4,4	4,9	14	14	0,080	1,000	4,967	1,409
9	4,9	5,4	6	6	0,034	1,000	5,136	0,954
10	5,4	5,9	2	2	0,011	1,000	4,667	0,500
11	5,9	6,4	3	3	0,017	1,000	5,329	0,700
12	6,4	6,9	0	0	0,000	0,000	0,000	0,000
13	6,9	7,4	0	0	0,000	0,000	0,000	0,000
14	7,4	7,9	2	2	0,011	1,000	4,401	0,472
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade (A = Σ A_i); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

No caso do teor foliar de B, o nível de suficiência foi determinado pelo intervalo entre as classes 3 e 10 (Tabela 7), tendo-se definido os valores de referência de 40,1 mg kg⁻¹ como limite inferior, de 67mg kg⁻¹ como limite superior e o teor ótimo de 52 mg kg⁻¹. As classes

Tabela 7 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de B em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de B ----						----- t ha ⁻¹ -----	
1	33,5	36,8	8	6	0,034	0,750	4,047	0,651
2	36,8	40,1	19	12	0,069	0,632	3,940	0,822
3	40,1	43,4	22	18	0,103	0,818	3,942	1,147
4	43,4	46,7	34	30	0,172	0,882	4,468	1,743
5	46,7	50,0	21	17	0,098	0,810	4,459	1,254
6	50,0	53,3	15	11	0,063	0,733	4,382	0,943
7	53,3	56,6	19	16	0,092	0,842	4,378	1,218
8	56,6	59,9	34	32	0,184	0,941	4,400	1,831
9	59,9	63,2	21	16	0,092	0,762	4,428	1,172
10	63,2	66,5	10	9	0,052	0,900	4,635	1,000
11	66,5	69,8	3	1	0,006	0,333	3,978	0,174
12	69,8	73,1	2	2	0,011	1,000	4,281	0,459
13	73,1	76,4	1	1	0,006	1,000	4,998	0,379
14	76,4	79,7	3	3	0,017	1,000	4,726	0,620
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade (A = Σ A_i); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

superiores a 10 não apresentaram altos índices de ChM pois tiveram baixa quantidade de amostras contidas nelas, apesar de altos valores de $[P(A_i/N_i)]$.

Para o teor Cu nas folhas, duas unidades experimentais apresentaram concentração muita alta do nutriente e o agrupamento da maioria das unidades experimentais entre as classes 2 e 4 definiram o nível de suficiência (Tabela 8). Assim, o limite inferior e o superior do nível de suficiência de Cu nas folhas de soja foram de 6 e 14 mg kg⁻¹, respectivamente, enquanto o teor ótimo foi de 11 mg kg⁻¹.

Os valores de ChM para diferentes classes de frequência de distribuição de teores de Fe nas folhas de soja estão apresentados na Tabela 9. Verifica-se que o intervalo entre as classes 1 e 5 apresentaram elevados valores de ChM, entre 1,194 e 1,286, revelando que o limite inferior e o superior do nível de suficiência de Fe nas folhas de soja foram de 80 e 189 mg kg⁻¹, respectivamente, enquanto o teor ótimo foi a mediana desse intervalo, ou seja, 140 mg kg⁻¹.

Os resultados para o teor foliar de Mn também revelaram maiores concentrações do nutriente em algumas classes (Tabela 10). As concentrações mais elevadas de Mn nas folhas de soja devem ter sido consequência da maior acidificação do solo ocasionada pela adubação nitrogenada nas culturas de inverno, especialmente nas unidades experimentais sem calcário do experimento 1. O nível de referência de Mn nas folhas de soja ficou determinado pelo

Tabela 8 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Cu em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Cu ----						----- t ha ⁻¹ -----	
1	2,6	5,5	6	2	0,011	0,333	4,129	0,256
2	5,5	8,4	22	15	0,086	0,682	4,466	1,083
3	8,4	11,3	64	57	0,328	0,891	4,689	2,533
4	11,3	14,2	51	41	0,236	0,804	4,023	1,751
5	14,2	17,1	11	11	0,063	1,000	3,918	0,985
6	17,1	20	0	0	0,000	0,000	0,000	0,000
7	20	22,9	1	1	0,006	1,000	4,288	0,325
8	22,9	25,8	5	5	0,029	1,000	4,651	0,788
9	25,8	28,7	7	6	0,034	0,857	4,062	0,698
10	28,7	31,6	14	14	0,080	1,000	4,311	1,223
11	31,6	34,5	15	12	0,069	0,800	4,149	0,975
12	34,5	37,4	10	8	0,046	0,800	4,393	0,842
13	37,4	40,3	4	2	0,011	0,500	5,018	0,380
14	40,3	43,2	2	0	0,000	0,000	3,913	0,000
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 9 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Fe em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Fe ----						----- t ha ⁻¹ -----	
1	79,8	101,6	11	11	0,063	1,000	4,749	1,194
2	101,6	123,4	32	26	0,149	0,813	4,502	1,569
3	123,4	145,2	52	46	0,264	0,885	4,269	2,065
4	145,2	167,0	52	46	0,264	0,885	4,405	2,130
5	167,0	188,8	18	16	0,092	0,889	4,500	1,286
6	188,8	210,6	4	2	0,011	0,500	4,460	0,338
7	210,6	232,4	0	0	0,000	0,000	0,000	0,000
8	232,4	254,2	4	2	0,011	0,500	4,039	0,306
9	254,2	276,0	3	2	0,011	0,667	3,846	0,337
10	276,0	297,8	8	4	0,023	0,500	4,016	0,431
11	297,8	319,6	8	5	0,029	0,625	3,783	0,507
12	319,6	341,4	13	9	0,052	0,692	4,009	0,759
13	341,4	363,2	5	4	0,023	0,800	3,965	0,538
14	363,2	385	2	1	0,006	0,500	3,759	0,202
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

intervalo entre as classes 1 e 4, obtendo-se como limite inferior e superior as concentrações de 23 e 98 mg kg⁻¹, respectivamente, e teor ótimo de 54 mg kg⁻¹.

Tabela 10 – Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mn em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Mn ----						----- t ha ⁻¹ -----	
1	22,7	41,4	30	29	0,167	0,967	4,645	1,865
2	41,4	60,1	95	82	0,471	0,863	4,385	2,797
3	60,1	78,8	38	32	0,184	0,842	4,231	1,665
4	78,8	97,5	28	18	0,103	0,643	3,968	1,023
5	97,5	116,2	4	3	0,017	0,750	4,151	0,472
6	116,2	134,9	3	2	0,011	0,667	4,056	0,355
7	134,9	153,6	1	1	0,006	1,000	4,767	0,361
8	153,6	172,3	4	4	0,023	1,000	4,067	0,617
9	172,3	191,0	1	1	0,006	1,000	4,441	0,337
10	191,0	209,7	2	1	0,006	0,500	4,346	0,233
11	209,7	228,4	2	0	0,000	0,000	0,000	0,000
12	228,4	247,1	1	0	0,000	0,000	0,000	0,000
13	247,1	265,8	1	0	0,000	0,000	0,000	0,000
14	265,8	284,5	1	0	0,000	0,000	0,000	0,000
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Para o teor Zn nas folhas, o intervalo que representou o nível de suficiência ficou entre as classes 2 e 7 (Tabela 11). Assim, o limite inferior e o superior do nível de suficiência de Cu nas folhas de soja foram de 20 e 37 mg kg⁻¹, respectivamente, enquanto o teor ótimo foi de 29 mg kg⁻¹.

Tabela 11 -Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Zn em amostras de terceiro trifólio sem pecíolo, na cultura da soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Zn ----						----- t ha ⁻¹ -----	
1	17	19,8	7	6	0,034	0,857	4,843	0,833
2	19,8	22,6	12	12	0,069	1,000	4,421	1,161
3	22,6	25,4	21	13	0,075	0,619	4,597	0,989
4	25,4	28,2	27	23	0,132	0,852	4,417	1,482
5	28,2	31,0	27	23	0,132	0,852	4,410	1,480
6	31,0	33,8	32	26	0,149	0,813	4,347	1,515
7	33,8	36,6	26	24	0,138	0,923	4,506	1,608
8	36,6	39,4	14	9	0,052	0,643	4,343	0,792
9	39,4	42,2	14	9	0,052	0,643	3,836	0,699
10	42,2	45,0	12	10	0,057	0,833	3,994	0,874
11	45,0	47,8	11	10	0,057	0,909	3,969	0,907
12	47,8	50,6	5	5	0,029	1,000	4,017	0,681
13	50,6	53,4	1	1	0,006	1,000	4,041	0,306
14	53,4	56,2	2	2	0,011	1,000	3,838	0,411
Total			212	174				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade (A = Σ A_i); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Os níveis de suficiência de nutrientes no tecido foliar da soja encontrados pelo método da ChM no presente estudo não diferiram muito daqueles preconizados por Malavolta et al. (1997). No presente estudo, foram consideradas produtividades de soja acima de 3,6 t ha⁻¹ e pequenas diferenças nos níveis de suficiência dos teores foliares de nutrientes eram esperadas. Destaca-se que amplitude de variação dos níveis de suficiência foi maior para P e S, e menor para Ca, Mg, Cu e Fe nas folhas de soja com o método da ChM, nesse estudo, em comparação àqueles preconizados por Malavolta et al. (1997). Os resultados obtidos com o método da ChM para a definição de níveis de suficiência de nutrientes nas folhas de soja foram relativamente satisfatórios, uma vez que os teores ótimos de nutrientes estimados pelo método da ChM estiveram dentro dos níveis considerados adequados para a cultura da soja (MALAVOLTA et al., 1997).

Tabela 12 - Níveis de suficiência de nutrientes no terceiro trifólio sem pecíolo de soja e limites estabelecidos pelo método da Chance Matemática (ChM).

Nutriente	Nível de Suficiência ¹	ChM Inferior	ChM Superior	ChM Ótimo
----- g kg ⁻¹ -----				
N	45,0–55,0	39,8	58,7	50,8
P	2,6–5,0	1,4	5,6	3,3
K	17,0–25,0	18,3	33,5	27,4
Ca	4,0–20,0	6,1	9,1	7,7
Mg	3,0–10,0	2,3	4,3	3,4
S	2,5	0,9	4,9	2,2
----- mg kg ⁻¹ -----				
B	21–55	40	67	52
Cu	10–30	6	14	11
Fe	51–350	80	189	140
Mn	21–100	23	98	54
Zn	21–50	20	37	29

¹ Malavolta et al. (1997).

4.1.2. Concentração de Nutrientes nos Grãos de Soja

Os valores de ChM para diferentes classes de frequência de distribuição de teores de N nos grãos de soja estão apresentados na Tabela 13. As classes 1, 2, 3, 4 e 13 apresentaram alta probabilidade de ocorrência em unidades experimentais de alta produtividade [$P(A_i/N_i)$], porém suas frequências em relação ao total de unidades experimentais de alta produtividade [$P(A_i/A)$] foram baixas. Os maiores valores de ChM foram obtidos no intervalo entre as classes 5 e 10, definindo-se o nível de suficiência entre 46,7 e 71,9 g kg⁻¹ e o teor ótimo de 56,4 g kg⁻¹.

Tabela 13 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de N em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
----- g kg ⁻¹ de N -----								
							----- t ha ⁻¹ -----	
1	29,9	34,1	1	1	0,006	1,000	4,031	0,303
2	34,1	38,3	1	1	0,006	1,000	3,713	0,279
3	38,3	42,5	2	1	0,006	0,500	5,121	0,272
4	42,5	46,7	4	4	0,023	1,000	5,203	0,782
5	46,7	50,9	26	23	0,130	0,885	4,765	1,616
6	50,9	55,1	57	39	0,220	0,684	3,969	1,541
7	55,1	59,3	59	46	0,260	0,780	4,213	1,896
8	59,3	63,5	21	20	0,113	0,952	4,339	1,423
9	63,5	67,7	24	24	0,136	1,000	4,576	1,685
10	67,7	71,9	16	14	0,079	0,875	4,483	1,179
11	71,9	76,1	3	3	0,017	1,000	4,035	0,525
12	76,1	80,3	0	0	0,000	0,000	0,000	0,000
13	80,3	84,5	1	1	0,006	1,000	4,429	0,333
14	84,5	88,7	1	0	0,000	0,000	0,000	0,000
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades

experimentais de alta produtividade em relação ao total de unidades experimentais da classe i ; $PROD_i$ = produtividade média das unidades experimentais de alta produtividade.

Para o teor de P nos grãos, os resultados revelaram distribuição nas classes (Tabela 14) semelhante à encontrada para o teor foliar de P (Tabela 2). O nível de suficiência para o teor de P nos grãos de soja ficou entre as classes 4 e 10, variando de $3,6 \text{ g kg}^{-1}$ (limite inferior) a $6,4 \text{ g kg}^{-1}$ (limite superior), e o teor ótimo foi de $5,1 \text{ g kg}^{-1}$.

Tabela 14 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de P em amostras de grãos de soja¹.

Classe (i)	L I	L S	N_i	A_i	$P(A_i/A)$	$P(A_i/N_i)$	$PROD_i$	ChM_i
	---- g kg^{-1} de P ----						----- t ha^{-1} -----	
1	2,4	2,8	2	1	0,006	0,500	3,858	0,205
2	2,8	3,2	9	7	0,040	0,778	4,342	0,761
3	3,2	3,6	17	12	0,068	0,706	4,274	0,935
4	3,6	4,0	22	19	0,107	0,864	4,341	1,322
5	4,0	4,4	23	21	0,119	0,913	4,519	1,487
6	4,4	4,8	26	19	0,107	0,731	4,552	1,275
7	4,8	5,2	20	18	0,102	0,900	4,315	1,305
8	5,2	5,6	38	29	0,164	0,763	4,483	1,585
9	5,6	6,0	23	21	0,119	0,913	4,359	1,435
10	6,0	6,4	19	16	0,090	0,842	3,831	1,057
11	6,4	6,8	10	10	0,056	1,000	3,992	0,949
12	6,8	7,2	5	4	0,023	0,800	4,219	0,567
13	7,2	7,6	2	0	0,000	0,000	0,000	0,000
14	7,6	8,0	0	0	0,000	0,000	0,000	0,000
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; $P(A_i/A)$ = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); $P(A_i/N_i)$ = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i ; $PROD_i$ = produtividade média das unidades experimentais de alta produtividade.

O intervalo entre as classes 4 e 8 determinaram os níveis de suficiência para o teor de K nos grãos (Tabela 15). Assim, o limite inferior e o superior do nível de suficiência de K nos grãos de soja foram de $19,8$ e $25,8 \text{ g kg}^{-1}$, respectivamente, enquanto o teor ótimo foi de $23,2 \text{ g kg}^{-1}$. As classes 2 e 3 apresentaram valores de ChM superiores a 0,8, porém abaixo dos valores limites para serem considerados no intervalo. As demais classes não foram representativas, pois os valores de ChM foram baixos.

No caso do teor de Ca nos grãos, o nível de suficiência foi determinado pelo intervalo entre as classes 3 e 8 (Tabela 16), tendo-se definido os valores de referência de $1,2 \text{ g kg}^{-1}$ como limite inferior, de $3,0 \text{ g kg}^{-1}$ como limite superior e o teor ótimo de $2,2 \text{ g kg}^{-1}$.

Tabela 15 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de K em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de K ----						----- t ha ⁻¹ -----	
1	16,2	17,4	2	2	0,011	1,000	4,477	0,476
2	17,4	18,6	6	6	0,034	1,000	4,655	0,857
3	18,6	19,8	10	8	0,045	0,800	4,372	0,831
4	19,8	21,0	19	16	0,090	0,842	4,358	1,202
5	21,0	22,2	34	25	0,141	0,735	4,337	1,398
6	22,2	23,4	52	45	0,254	0,865	4,309	2,021
7	23,4	24,6	68	58	0,328	0,853	4,376	2,313
8	24,6	25,8	16	12	0,068	0,750	4,227	0,953
9	25,8	27,0	4	1	0,006	0,250	4,167	0,157
10	27,0	28,2	3	2	0,011	0,667	4,251	0,369
11	28,2	29,4	0	0	0,000	0,000	0,000	0,000
12	29,4	30,6	0	0	0,000	0,000	0,000	0,000
13	30,6	31,8	1	1	0,006	1,000	4,220	0,317
14	31,8	33,0	1	1	0,006	1,000	4,648	0,349
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade (A = Σ A_i); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 16 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Ca em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de Ca ----						----- t ha ⁻¹ -----	
1	0,6	0,9	2	2	0,011	1,000	4,194	0,446
2	0,9	1,2	1	1	0,006	1,000	4,167	0,313
3	1,2	1,5	11	10	0,056	0,909	4,555	1,032
4	1,5	1,8	25	24	0,136	0,960	4,634	1,672
5	1,8	2,1	37	29	0,164	0,784	4,276	1,532
6	2,1	2,4	48	44	0,249	0,917	4,146	1,979
7	2,4	2,7	45	34	0,192	0,756	4,101	1,562
8	2,7	3,0	22	14	0,079	0,636	4,739	1,063
9	3,0	3,3	8	6	0,034	0,750	5,071	0,809
10	3,3	3,6	5	4	0,023	0,800	5,192	0,698
11	3,6	3,9	4	3	0,017	0,750	4,195	0,473
12	3,9	4,2	3	2	0,011	0,667	3,694	0,321
13	4,2	4,5	5	4	0,023	0,800	3,770	0,507
14	4,5	4,8	0	0	0,000	0,000	0,000	0,000
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade (A = Σ A_i); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Para o teor Mg nos grãos, assim como a distribuição do teor foliar (Tabela 5), uma unidade experimental apresentou concentração muito alta do nutriente e o agrupamento da maioria das unidades experimentais entre as classes 4 e 7 definiram o nível de suficiência

(Tabela 17). Assim, o limite inferior e o superior do nível de suficiência de Mg nos grãos de soja foram de 2,1 e 3,7 g kg⁻¹, respectivamente, enquanto o teor ótimo foi de 2,7 g kg⁻¹.

Tabela 17 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mg em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de Mg ----						----- t ha ⁻¹ -----	
1	0,9	1,3	3	3	0,017	1,000	4,122	0,537
2	1,3	1,7	2	2	0,011	1,000	3,982	0,423
3	1,7	2,1	11	6	0,034	0,545	4,267	0,580
4	2,1	2,5	51	39	0,220	0,765	4,200	1,724
5	2,5	2,9	94	82	0,463	0,872	4,323	2,748
6	2,9	3,3	26	22	0,124	0,846	4,434	1,438
7	3,3	3,7	10	9	0,051	0,900	4,993	1,068
8	3,7	4,1	7	6	0,034	0,857	5,107	0,870
9	4,1	4,5	4	2	0,011	0,500	3,841	0,289
10	4,5	4,9	1	0	0,000	0,000	0,000	0,000
11	4,9	5,3	2	2	0,011	1,000	3,689	0,392
12	5,3	5,7	2	2	0,011	1,000	3,738	0,397
13	5,7	6,1	3	2	0,011	0,667	3,876	0,336
14	6,1	6,5	0	0	0,000	0,000	0,000	0,000
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade (A = Σ A_i); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

O nível de suficiência de S foi gerado pelo intervalo das classes 2 e 6 (Tabela 18) tendo-se definido os valores de referência de 1,2 g kg⁻¹ como limite inferior, de 4,2 g kg⁻¹ como limite superior e o teor ótimo de 2,6 g kg⁻¹. Nota-se que a distribuição de classes nos grãos ocorreu de forma diferente à apresentada pelos teores foliares (Tabela 6). Enquanto nas folhas houve distribuição em nove classes, nos grãos as unidades experimentais se concentraram em cinco classes.

A distribuição do teor de B nos grãos foi similar à encontrada para os teores foliares (Tabela 7). O nível de suficiência de B nos grãos foi determinado pelo intervalo entre as classes 2 e 7 (Tabela 19), tendo-se definido os valores de referência de 36 mg kg⁻¹ como limite inferior, de 50 mg kg⁻¹ como limite superior e o teor ótimo de 43 mg kg⁻¹.

Para o teor Cu nos grãos, as classes 7 e 9 definiram o nível de suficiência (Tabela 20). Assim, o limite inferior e o superior do nível de suficiência de Cu nos grãos de soja foram de 10 e 13 mg kg⁻¹, respectivamente, enquanto o teor ótimo foi de 12 mg kg⁻¹. Nota-se que as classes 12 e 13 apresentaram altos valores de ChM, porém não foram considerados no nível de suficiência porque as classes 10 e 11 apresentaram índices ChM mais baixos.

Tabela 18 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de S em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- g kg ⁻¹ de S ----						----- t ha ⁻¹ -----	
1	0,6	1,2	1	1	0,006	1,000	4,190	0,315
2	1,2	1,8	20	19	0,107	0,950	4,669	1,491
3	1,8	2,4	61	51	0,288	0,836	4,162	2,043
4	2,4	3,0	45	28	0,158	0,622	3,941	1,236
5	3,0	3,6	37	29	0,164	0,784	4,281	1,534
6	3,6	4,2	25	22	0,124	0,880	4,268	1,412
7	4,2	4,8	3	3	0,017	1,000	4,302	0,560
8	4,8	5,4	0	0	0,000	0,000	0,000	0,000
9	5,4	6,0	2	2	0,011	1,000	5,392	0,573
10	6,0	6,6	6	6	0,034	1,000	4,967	0,914
11	6,6	7,2	10	10	0,056	1,000	5,148	1,224
12	7,2	7,8	1	1	0,006	1,000	4,792	0,360
13	7,8	8,4	3	3	0,017	1,000	4,785	0,623
14	8,4	9,0	2	2	0,011	1,000	5,041	0,536
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 19 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de B em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de B ----						----- t ha ⁻¹ -----	
1	34,1	36,4	3	3	0,017	1,000	4,212	0,548
2	36,4	38,7	16	16	0,090	1,000	4,395	1,321
3	38,7	41,0	34	29	0,164	0,853	4,315	1,613
4	41,0	43,3	44	27	0,153	0,614	4,162	1,273
5	43,3	45,6	50	40	0,226	0,800	4,320	1,837
6	45,6	47,9	28	28	0,158	1,000	4,338	1,725
7	47,9	50,2	20	17	0,096	0,850	4,640	1,326
8	50,2	52,5	10	7	0,040	0,700	4,275	0,711
9	52,5	54,8	5	5	0,028	1,000	4,717	0,793
10	54,8	57,1	3	2	0,011	0,667	4,170	0,362
11	57,1	59,4	1	1	0,006	1,000	4,511	0,339
12	59,4	61,7	0	0	0,000	0,000	0,000	0,000
13	61,7	64,0	0	0	0,000	0,000	0,000	0,000
14	64,0	66,3	2	2	0,011	1,000	3,892	0,414
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 20 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Cu em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Cu ----						----- t ha ⁻¹ -----	
1	4,1	5,1	8	6	0,034	0,750	4,091	0,652
2	5,1	6,1	12	9	0,051	0,750	3,890	0,760
3	6,1	7,1	2	1	0,006	0,500	3,960	0,210
4	7,1	8,1	6	4	0,023	0,667	3,885	0,477
5	8,1	9,1	4	3	0,017	0,750	3,941	0,444
6	9,1	10,1	14	6	0,034	0,429	4,156	0,501
7	10,1	11,1	26	20	0,113	0,769	4,462	1,315
8	11,1	12,1	35	33	0,186	0,943	4,453	1,867
9	12,1	13,1	43	41	0,232	0,953	4,758	2,236
10	13,1	14,1	9	7	0,040	0,778	4,355	0,764
11	14,1	15,1	7	3	0,017	0,429	4,723	0,402
12	15,1	16,1	26	25	0,141	0,962	4,003	1,475
13	16,1	17,1	19	14	0,079	0,737	4,012	0,969
14	17,1	18,1	5	5	0,028	1,000	3,960	0,665
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

O teor de Fe nos grãos se aglomerou nas amostras das classes 1, 2, 3 e 4 (Tabela 21), pois duas amostras, nas classes 11 e 14, apresentaram teores de Fe muito acima dos obtidos nas demais unidades experimentais, causando um intervalo grande entre as classes. Como a disponibilidade de Fe no solo é maior quando o pH do solo é mais baixo (maior acidez), os mais altos teores de Fe encontrados nos grãos de soja certamente foram decorrentes da maior acidez dos solos nos tratamentos sem calagem dos experimentos 1 e 4. O nível de suficiência de Fe nos grãos de soja variou de 39 g kg⁻¹ (limite inferior) a 270 g kg⁻¹ (limite superior), e o teor ótimo foi de 107 g kg⁻¹.

Os resultados para o teor dos grãos de Mn, assim como nas folhas, também revelaram maiores concentrações do nutriente em algumas classes (Tabela 22). O nível de referência de Mn nas folhas de soja ficou determinado pelo intervalo entre as classes 4 e 8, obtendo-se como limite inferior e superior as concentrações de 21 e 35 mg kg⁻¹, respectivamente, e teor ótimo de 27 mg kg⁻¹.

Tabela 21 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Fe em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Fe ----						----- t ha ⁻¹ -----	
1	38,8	96,5	87	74	0,418	0,851	4,375	2,609
2	96,5	154,2	76	59	0,333	0,776	4,254	2,164
3	154,2	211,9	27	22	0,124	0,815	4,397	1,399
4	211,9	269,6	12	11	0,062	0,917	4,308	1,028
5	269,6	327,3	4	2	0,011	0,500	3,756	0,282
6	327,3	385,0	2	2	0,011	1,000	4,553	0,484
7	385,0	442,7	3	2	0,011	0,667	4,525	0,393
8	442,7	500,4	3	3	0,017	1,000	4,398	0,573
9	500,4	558,1	0	0	0,000	0,000	0,000	0,000
10	558,1	615,8	0	0	0,000	0,000	0,000	0,000
11	615,8	673,5	1	1	0,006	1,000	6,308	0,474
12	673,5	731,2	0	0	0,000	0,000	0,000	0,000
13	731,2	788,9	0	0	0,000	0,000	0,000	0,000
14	788,9	846,6	1	1	0,006	1,000	3,764	0,283
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Tabela 22 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Mn em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Mn ----						----- t ha ⁻¹ -----	
1	12,2	15,0	2	2	0,011	1,000	3,787	0,403
2	15,0	17,8	2	2	0,011	1,000	3,911	0,416
3	17,8	20,6	4	4	0,023	1,000	4,072	0,612
4	20,6	23,4	28	20	0,113	0,714	4,410	1,253
5	23,4	26,2	60	55	0,311	0,917	4,537	2,421
6	26,2	29,0	37	36	0,203	0,973	4,463	1,985
7	29,0	31,8	33	26	0,147	0,788	4,055	1,380
8	31,8	34,6	31	23	0,130	0,742	4,143	1,286
9	34,6	37,4	12	6	0,034	0,500	4,167	0,543
10	37,4	40,2	3	2	0,011	0,667	4,040	0,351
11	40,2	43,0	3	0	0,000	0,000	0,000	0,000
12	43,0	45,8	0	0	0,000	0,000	0,000	0,000
13	45,8	48,6	0	0	0,000	0,000	0,000	0,000
14	48,6	51,4	1	1	0,006	1,000	3,877	0,291
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Para o teor Zn nos grãos, o intervalo que representou o nível de suficiência ficou entre as classes 5 e 9 (Tabela 23). Assim, o limite inferior e o superior do nível de suficiência de Zn nos grãos de soja foram de 27 e 45 mg kg⁻¹, respectivamente, enquanto o teor ótimo foi de 36 mg kg⁻¹.

Tabela 23 - Valores de chance matemática (CHMi) estabelecidos para as diferentes classes de frequência “i” de distribuição de teores de Zn em amostras de grãos de soja¹.

Classe (i)	L I	L S	N _i	A _i	P(A _i /A)	P(A _i /N _i)	PROD _i	ChM _i
	---- mg kg ⁻¹ de Zn ----						----- t ha ⁻¹ -----	
1	12,6	16,2	11	8	0,045	0,727	3,890	0,705
2	16,2	19,8	20	14	0,079	0,700	3,985	0,938
3	19,8	23,4	2	1	0,006	0,500	3,713	0,197
4	23,4	27,0	2	2	0,011	1,000	4,284	0,455
5	27,0	30,6	16	13	0,073	0,813	4,515	1,103
6	30,6	34,2	37	33	0,186	0,892	4,562	1,860
7	34,2	37,8	57	47	0,266	0,825	4,570	2,138
8	37,8	41,4	26	23	0,130	0,885	4,319	1,464
9	41,4	45,0	30	24	0,136	0,800	3,973	1,309
10	45,0	48,6	12	9	0,051	0,750	4,044	0,790
11	48,6	52,2	1	1	0,006	1,000	3,778	0,284
12	52,2	55,8	0	0	0,000	0,000	0,000	0,000
13	55,8	59,4	0	0	0,000	0,000	0,000	0,000
14	59,4	63,0	2	2	0,011	1,000	4,825	0,513
Total			216	177				

¹ Em cada classe de frequência, LI = limite inferior; LS = limite superior; N_i = número de amostras; A_i = número de amostras de alta produtividade; P(A_i/A) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais de alta produtividade ($A = \sum A_i$); P(A_i/N_i) = frequência de unidades experimentais de alta produtividade em relação ao total de unidades experimentais da classe i; PROD_i = produtividade média das unidades experimentais de alta produtividade.

Os teores de suficiência, delimitados pelos níveis inferior e superior, e o teor ótimo de nutrientes nos grãos de soja estabelecidos pelo método da ChM estão apresentados na Tabela 24. Nota-se que a amplitude de variação dos níveis de suficiência para P, K, S, Cu e Mn foi menor nos grãos (Tabela 24) do que nas folhas (Tabela 12). O Fe foi o único nutriente que apresentou amplitude de variação dos níveis de suficiência ainda maior nos grãos do que nas folhas. Para os demais nutrientes não se observaram grandes alterações na amplitude de variação dos níveis estabelecidos em folhas ou grãos de soja. Porque os nutrientes apresentam mobilidade diferenciada nas plantas, as concentrações de nutrientes nos grãos em relação aos seus teores nas folhas foram também diferentes, dependendo da mobilidade do nutriente. Como o N e o P apresentam alta mobilidade nas plantas, os teores ótimos de N e P foram maiores nos grãos do que nas folhas. Efeito contrário foi observado para os teores ótimos de Ca, Fe e Mn, cujos valores foram maiores nas folhas do que nos grãos em decorrência da baixa mobilidade que esses nutrientes apresentam nas plantas. Os resultados mostraram que o estabelecimento de níveis de suficiência de nutrientes nos grãos pelo método da ChM é uma técnica promissora para a avaliação do estado nutricional da cultura da soja.

Tabela 24 – Níveis de suficiência de nutrientes nos grãos de soja estabelecidos pelo método da Chance Matemática (ChM).

Nutriente	ChM Inferior	ChM Superior	ChM Ótimo
	----- g kg ⁻¹ -----		
N	46,7	71,9	56,4
P	36	6,4	5,0
K	19,8	25,8	23,2
Ca	1,2	3,0	2,2
Mg	2,1	3,7	2,7
S	1,2	4,2	2,6
	----- mg kg ⁻¹ -----		
B	36	50	43
Cu	10	13	12
Fe	39	270	107
Mn	21	35	27
Zn	27	45	36

4.2. Sistema Integrado de Diagnose e Recomendação (DRIS)

Nas Tabelas 25 e 26 são apresentadas as médias e os desvios padrão (normas) das relações duais entre os nutrientes nas folhas e nos grãos, respectivamente, para a população de alta produtividade. A aplicação do teste de Kolmogorov-Smirnov com a finalidade de verificar a normalidade da distribuição das relações duais indicou que 34% das relações obtidas com as análises foliares e 27% das relações obtidas com as análises nos grãos apresentaram rejeição à hipótese de normalidade de distribuição. Nota-se que as relações com Fe e Mn foram as que apresentaram maior rejeição na normalidade da distribuição nas folhas, enquanto nos grãos somente o Fe apresentou alto índice de rejeição. Essa rejeição pode ter ocasionada pelo tratamento sem calcário nos experimentos 1 e 4. Nesses experimentos, os solos apresentavam alta acidez (baixo valor pH). Como a disponibilidade de Fe e Mn no solo aumenta em condições de maior acidez, o mais baixo pH do solo no tratamento sem calcário deve ter favorecido a absorção de Fe e Mn pelas plantas, elevando o teor desses nutrientes em relação aos demais. O fato de nos grãos somente o Fe ter apresentado alto índice de rejeição é indicativo de que houve maior mobilidade de Fe do que de Mn para os grãos de soja.

Tabela 25 - Médias e desvios padrão das relações duais de nutrientes no terceiro trifólio sem pecíolo, para a população de alta produtividade de soja.

Relação	Média	Desvio padrão	Relação	Média	Desvio padrão	Relação	Média	Desvio padrão
N/P*	14,79822	6,627224	Ca/Fe	0,0537876	0,0172814	Cu/Mg*	4,9688482	3,2977465
N/K*	1,925968	0,647719	Ca/Mn	0,1488743	0,0550041	Cu/S	6,3192987	2,8298002
N/Ca	6,220573	1,486881	Ca/Zn	0,2542714	0,063171	Cu/B	0,3114118	0,1469309
N/Mg	14,07564	3,223344	Mg/N	0,0750853	0,0197952	Cu/Fe**	0,1121794	0,0724623
N/S	20,49034	9,154416	Mg/P	1,0652498	0,3965181	Cu/Mn*	0,2880619	0,1815584
N/B	0,94986	0,193025	Mg/K	0,1392726	0,0422554	Cu/Zn*	0,5201859	0,3045482
N/Cu**	3,871553	2,220066	Mg/Ca	0,4518672	0,1141392	Fe/N*	3,5680902	1,4924012
N/Fe	0,326441	0,123341	Mg/S	1,5049651	0,7165518	Fe/P	51,66009	25,130871
N/Mn	0,88896	0,324738	Mg/B	0,0705202	0,0205079	Fe/K*	6,3874965	2,4545676
N/Zn	1,576079	0,499335	Mg/Cu	0,287816	0,1781052	Fe/Ca*	21,885491	11,581445
P/N	0,078667	0,028024	Mg/Fe	0,0231597	0,006864	Fe/Mg*	47,579456	16,828569
P/K*	0,155901	0,097745	Mg/Mn	0,0653263	0,0231383	Fe/S*	72,265127	46,587782
P/Ca	0,483919	0,20693	Mg/Zn	0,1162558	0,0439913	Fe/B*	3,4766375	2,0157075
P/Mg	1,079581	0,424768	S/N	0,0605074	0,0305982	Fe/Cu*	13,746147	10,129434
P/S*	1,660833	1,099997	S/P*	0,8995137	0,5696912	Fe/Mn*	2,916405	0,9179001
P/B	0,074604	0,028899	S/K	0,1070681	0,0429214	Fe/Zn*	5,592255	3,1998215
P/Cu	0,331693	0,234678	S/Ca	0,3627587	0,1792086	Mn/N*	1,3085118	0,5920347
P/Fe*	0,026349	0,0171	S/Mg	0,8281251	0,3968386	Mn/P*	21,185066	19,623691
P/Mn	0,073924	0,046419	S/B**	0,0558561	0,0281589	Mn/K*	2,4023041	1,1402508
P/Zn	0,122814	0,057958	S/Cu*	0,2158583	0,1559557	Mn/Ca*	8,096579	4,4720922
K/N	0,573237	0,172536	S/Fe*	0,0188979	0,0093483	Mn/Mg*	18,526324	11,487109
K/P**	8,403483	3,853073	S/Mn**	0,0531174	0,0342264	Mn/S	25,762316	12,955965
K/Ca	3,399013	0,840299	S/Zn**	0,0969334	0,065091	Mn/B*	1,2331882	0,5847289
K/Mg	7,801198	2,178629	B/N*	1,0974487	0,2390129	Mn/Cu*	4,5903338	2,4804225
K/S*	10,93615	4,405609	B/P*	16,327175	8,4800833	Mn/Fe*	0,4032236	0,2286965
K/B	0,534873	0,161951	B/K**	2,0773517	0,728808	Mn/Zn*	2,0088726	1,0699288
K/Cu	2,06118	1,022338	B/Ca	6,6370827	1,4555596	Zn/N*	0,7181981	0,2893428
K/Fe	0,173353	0,046441	B/Mg	15,272411	4,1686586	Zn/P*	10,327522	5,0533525
K/Mn	0,486586	0,180839	B/S	21,779853	9,2051171	Zn/K	1,2958809	0,417554
K/Zn	0,860064	0,293469	B/Cu**	3,9837598	1,9130702	Zn/Ca	4,1770181	1,0433616
Ca/N	0,171378	0,047628	B/Fe	0,3585785	0,1416562	Zn/Mg	9,8427672	3,6075222
Ca/P	2,470499	1,055843	B/Mn	0,9661538	0,3796317	Zn/S	14,533463	7,6864919
Ca/K	0,31255	0,078512	B/Zn	1,6730382	0,4806379	Zn/B*	0,6568473	0,2181776
Ca/Mg	2,325067	0,486279	Cu/N	0,3506671	0,1998381	Zn/Cu*	2,5299719	1,1158655
Ca/S	3,369915	1,435536	Cu/P*	6,0046779	5,682709	Zn/Fe	0,2254836	0,0895828
Ca/B	0,15792	0,034942	Cu/K*	0,6282496	0,3375898	Zn/Mn	0,6108448	0,2476532
Ca/Cu	0,619467	0,271722	Cu/Ca*	2,0913125	1,2295076			

* e ** indicam relação dual em que houve rejeição da hipótese de normalidade de distribuição pelo teste de Kolmogorov-Smirnov, a 1 e 5 % de probabilidade, respectivamente.

Tabela 26 - Médias e desvios padrão das relações duais de nutrientes nos grãos, para a população de alta produtividade de soja.

Relação	Média	Desvio padrão	Relação	Média	Desvio padrão	Relação	Média	Desvio padrão
N/P*	12,27001	3,879877	Ca/Fe	0,0218994	0,0105717	Cu/Mg	4,618261	1,7079632
N/K	2,558923	0,480386	Ca/Mn	0,0892399	0,0384842	Cu/S*	4,722525	2,4324265
N/Ca**	27,11011	10,43483	Ca/Zn**	0,0775959	0,0511068	Cu/B	0,281131	0,0865141
N/Mg	21,61691	6,151965	Mg/N**	0,0504097	0,0163132	Cu/Fe	0,113136	0,0511424
N/S	22,70835	11,19356	Mg/P	0,5847609	0,1579518	Cu/Mn	0,452596	0,105108
N/B	1,305537	0,184245	Mg/K	0,1245115	0,0307589	Cu/Zn	0,358857	0,0687053
N/Cu*	5,171545	2,049565	Mg/Ca	1,2424037	0,2563205	Fe/N*	2,47817	1,8535167
N/Fe	0,570693	0,301549	Mg/S	1,0673762	0,4943041	Fe/P*	28,20744	22,685233
N/Mn	2,180015	0,495936	Mg/B	0,0641534	0,016354	Fe/K*	6,149604	4,9190523
N/Zn*	1,816504	0,671956	Mg/Cu**	0,2583598	0,1311438	Fe/Ca*	61,92402	53,048671
P/N	0,089201	0,025878	Mg/Fe	0,0272485	0,0142709	Fe/Mg*	51,27154	40,137105
P/K	0,220715	0,05109	Mg/Mn	0,108595	0,0463728	Fe/S*	51,32671	45,056548
P/Ca	2,23818	0,604152	Mg/Zn*	0,0937314	0,0628279	Fe/B*	3,179974	2,3877627
P/Mg**	1,83473	0,495266	S/N**	0,0584881	0,03752	Fe/Cu*	11,62904	8,4342472
P/S*	1,92082	0,873452	S/P*	0,6684133	0,3481851	Fe/Mn*	5,045719	3,7267347
P/B	0,11438	0,030779	S/K	0,1394262	0,0698718	Fe/Zn*	4,120916	2,8658572
P/Cu*	0,442476	0,191525	S/Ca	1,3863779	0,6296681	Mn/N	0,483474	0,1175765
P/Fe	0,046373	0,019248	S/Mg**	1,1531541	0,5416304	Mn/P*	5,699233	1,6083462
P/Mn	0,186996	0,047039	S/B*	0,0736407	0,042048	Mn/K	1,205328	0,2299317
P/Zn	0,157519	0,069604	S/Cu**	0,2807251	0,1513941	Mn/Ca	12,48003	3,6012693
K/N	0,404629	0,077529	S/Fe	0,0289393	0,0154109	Mn/Mg	10,23257	3,0573741
K/P	4,79563	1,205579	S/Mn**	0,1209095	0,0668053	Mn/S	10,47462	4,5107824
K/Ca	10,43169	2,969165	S/Zn	0,0992319	0,0539781	Mn/B	0,624461	0,1415957
K/Mg*	8,467142	1,994588	B/N	0,7822307	0,1201976	Mn/Cu*	2,396062	0,8487337
K/S	8,657923	3,422208	B/P	9,3991643	2,5422349	Mn/Fe	0,256101	0,1112732
K/B	0,519532	0,075715	B/K	1,9690603	0,3122984	Mn/Zn*	0,835391	0,2355266
K/Cu*	2,062724	0,8716	B/Ca**	20,64398	7,2693456	Zn/N	0,610823	0,1828872
K/Fe	0,219998	0,099834	B/Mg**	16,534128	4,1902575	Zn/P	7,210558	2,2154895
K/Mn	0,860554	0,171566	B/S	17,24867	7,8074345	Zn/K*	1,537992	0,4504936
K/Zn*	0,726091	0,289837	B/Cu*	4,0381306	1,7821451	Zn/Ca	16,17712	6,3149444
Ca/N**	0,042315	0,015839	B/Fe	0,4361532	0,2156757	Zn/Mg	13,11991	4,7476458
Ca/P	0,480162	0,132028	B/Mn	1,6911937	0,4290907	Zn/S*	13,34116	6,8336091
Ca/K	0,103005	0,027983	B/Zn*	1,4265906	0,6313764	Zn/B	0,793797	0,2345466
Ca/Mg	0,834585	0,152235	Cu/N	0,2170007	0,0690456	Zn/Cu**	2,868705	0,473866
Ca/S**	0,858688	0,346927	Cu/P	2,5247469	0,6782116	Zn/Fe	0,325345	0,1699912
Ca/B	0,053628	0,016428	Cu/K	0,5441115	0,1563608	Zn/Mn*	1,271025	0,2754589
Ca/Cu**	0,214828	0,115859	Cu/Ca	5,690611	2,2449433			

* e ** indicam relação dual em que houve rejeição da hipótese de normalidade de distribuição, pelo teste de Kolmogorov-Smirnov, a 1 e 5 % de probabilidade, respectivamente.

Para a determinação do teor ótimo de nutrientes e dos limites inferiores e superiores, os teores na folha índice e nos grãos de soja foram relacionados aos respectivos índices DRIS apresentados na Tabela 27, conforme Wadt et al. (1998). Este relacionamento também foi utilizado por Silva (2001) e Kurihara (2004) na folha índice e baseia-se no fato de que o teor associado a um índice DRIS igual a zero pode ser considerado como um valor ótimo. As amostras com teores e inferiores e superiores a este nível ótimo teriam índices DRIS negativos e positivos respectivamente, indicando possível limitação de produtividade por deficiência ou excesso nutricional (KURIHARA, 2004).

Tabela 27 - Equações de regressão para os teores de macronutrientes (g kg^{-1}) e micronutrientes (mg kg^{-1}) no terceiro trifólio sem pecíolo (F) e nos grãos (G) de soja em função do índice DRIS.

Equação – Folhas			R ²	Equação – Grãos			R ²
$N_F = 48,0 + 1,200 \times I_N$	$-24,0 \leq I_N \leq 12,6$	0,80		$N_G = 57,48 + 1,01 \times I_N$	$-27,3 \leq I_N \leq 14,0$	0,81	
$P_F = 3,75 + 0,170 \times I_P$	$-21,0 \leq I_P \leq 20,9$	0,92		$P_G = 4,98 + 0,14 \times I_P$	$-21,7 \leq I_P \leq 10,9$	0,77	
$K_F = 26,4 + 0,792 \times I_K$	$-14,1 \leq I_K \leq 11,6$	0,82		$K_G = 22,76 + 0,32 \times I_K$	$-14,2 \leq I_K \leq 13,2$	0,51	
$Ca_F = 7,9 + 0,205 \times I_{Ca}$	$-21,1 \leq I_{Ca} \leq 14,6$	0,73		$Ca_G = 2,34 + 0,08 \times I_{Ca}$	$-23,5 \leq I_{Ca} \leq 25,0$	0,86	
$Mg_F = 3,5 + 0,111 \times I_{Mg}$	$-19,6 \leq I_{Mg} \leq 22,0$	0,80		$Mg_G = 2,82 + 0,09 \times I_{Mg}$	$-22,5 \leq I_{Mg} \leq 27,9$	0,79	
$S_F = 2,8 + 0,162 \times I_S$	$-16,7 \leq I_S \leq 25,0$	0,95		$S_G = 3,19 + 0,18 \times I_S$	$-22,5 \leq I_S \leq 19,9$	0,87	
$B_F = 51,7 + 1,473 \times I_B$	$-14,3 \leq I_B \leq 16,0$	0,79		$B_G = 44,34 + 0,69 \times I_B$	$-13,6 \leq I_B \leq 15,9$	0,73	
$Cu_F = 16,5 + 1,078 \times I_{Cu}$	$-30,4 \leq I_{Cu} \leq 18,6$	0,91		$Cu_G = 12,22 + 0,40 \times I_{Cu}$	$-24,1 \leq I_{Cu} \leq 11,1$	0,84	
$Fe_F = 166,58 + 8,463 \times I_{Fe}$	$-16,3 \leq I_{Fe} \leq 20,2$	0,92		$Fe_G = 137,86 + 11,54 \times I_{Fe}$	$-19,4 \leq I_{Fe} \leq 41,3$	0,89	
$Mn_F = 61,8 + 3,576 \times I_{Mn}$	$-24,0 \leq I_{Mn} \leq 29,7$	0,95		$Mn_G = 27,22 + 0,70 \times I_{Mn}$	$-25,2 \leq I_{Mn} \leq 23,1$	0,91	
$Zn_F = 32,8 + 1,073 \times I_{Zn}$	$-15,1 \leq I_{Zn} \leq 14,9$	0,99		$Zn_G = 34,53 + 1,09 \times I_{Zn}$	$-26,0 \leq I_{Zn} \leq 21,8$	0,91	

Os coeficientes de determinação apresentados pela regressão tanto nas folhas como nos grãos de soja estão coerentes com os encontrados nos trabalhos de Kurihara (2004), Camacho et al. (2012) e Urano et al. (2006). De maneira geral, as regressões apresentaram grande representatividade dos dados. Somente o K nos grãos apresentou coeficiente de determinação (R^2) relativamente mais baixo.

A partir dos modelos lineares ajustados para os teores de nutrientes nas folhas e nos grãos em função do índice DRIS (Tabela 27), calculou-se a faixa ótima de teores considerando uma amplitude de ± 10 2/3 s para o índice DRIS ($-6,7 \leq I \leq 6,7$), incluindo mais de 50% da população ao redor da média.

As faixas de suficiência para os teores de nutrientes nas folhas e nos grãos de soja estão apresentadas na Tabela 28. Os valores obtidos para as folhas estão coerentes com os observados em outros estudos (KURIHARA, 2004; URANO et al., 2006; URANO et al., 2007; KURIHARA et al., 2008; ROMAGNOLI et al., 2008).

Tabela 28 – Faixa de suficiência dos teores de nutrientes no terceiro trifólio sem pecíolo e nos grãos de soja considerando uma amplitude de $\pm 10 \text{ 2/3 s}$ para o índice DRIS ($-6,7 \leq I \leq 6,7$).

Nutriente	Folhas			Grãos		
	DRIS Inferior	DRIS Superior	DRIS Ótimo	DRIS Inferior	DRIS Superior	DRIS Ótimo
	----- g kg ⁻¹ -----					
N	40,0	56,1	48,0	50,8	64,2	57,5
P	2,6	4,9	3,8	4,0	5,9	5,0
K	21,1	31,7	26,4	20,6	24,9	22,8
Ca	6,6	9,3	7,9	1,8	2,9	2,3
Mg	2,8	4,3	3,5	2,2	3,4	2,8
S	1,8	3,9	2,8	2,0	4,4	3,2
	----- mg kg ⁻¹ -----					
B	42	62	52	40	49	44
Cu	9	24	16	10	15	12
Fe	110	223	167	60	215	138
Mn	38	86	62	22	32	27
Zn	26	40	33	27	42	34

4.3. Diagnóstico da Composição Nutricional (CND)

O método CND, apesar de basear-se nas interações múltiplas que ocorrem entre todos os nutrientes sob diagnóstico, diferentemente do método DRIS considera que o nutriente está em equilíbrio nutricional quando o índice da variável multinutriente (Ivi) tende a zero (KHIARI et al., 2001a,b).

Na Tabela 29 estão apresentadas as regressões e os índices gerados para os teores de nutrientes nas folhas e nos grãos de soja a partir da aplicação do método CND na população de alta produtividade. Os teores de nutrientes nas folhas e nos grãos apresentaram relações lineares, com ajustes relativamente próximos aos verificados pelo método DRIS. O coeficiente de determinação para o teor de K nos grãos, assim como no DRIS, foi o menos representativo.

Tabela 29- Equações de regressão para os teores de macronutrientes (g kg⁻¹) e micronutrientes (mg kg⁻¹) no terceiro trifólio sem pecíolo (F) e nos grãos (G) de soja em função do índice CND.

Equação - Folhas			R ²	Equação - Grãos			R ²
$N_F = 48,01 + 6,52 \times I_N$	$-3,78 \leq I_N \leq 2,21$	0,75		$N_G = 57,48 + 6,47 \times I_N$	$-3,20 \leq I_N \leq 1,83$	0,73	
$P_F = 3,75 + 1,43 \times I_P$	$-2,25 \leq I_P \leq 2,24$	0,91		$P_G = 4,98 + 0,83 \times I_P$	$-3,44 \leq I_P \leq 1,82$	0,63	
$K_F = 26,41 + 4,51 \times I_K$	$-2,39 \leq I_K \leq 2,01$	0,80		$K_G = 22,76 + 1,16 \times I_K$	$-3,04 \leq I_K \leq 2,39$	0,29	
$Ca_F = 7,93 + 0,95 \times I_{Ca}$	$-3,97 \leq I_{Ca} \leq 2,79$	0,64		$Ca_G = 2,34 + 0,58 \times I_{Ca}$	$-2,96 \leq I_{Ca} \leq 3,36$	0,79	
$Mg_F = 3,57 + 0,59 \times I_{Mg}$	$-3,29 \leq I_{Mg} \leq 3,30$	0,71		$Mg_G = 2,82 + 0,59 \times I_{Mg}$	$-2,81 \leq I_{Mg} \leq 3,81$	0,71	
$S_F = 2,83 + 1,31 \times I_S$	$-1,84 \leq I_S \leq 2,76$	0,95		$S_G = 3,19 + 1,54 \times I_S$	$-2,27 \leq I_S \leq 2,23$	0,84	
$B_F = 51,71 + 8,07 \times I_B$	$-2,53 \leq I_B \leq 2,44$	0,73		$B_G = 44,34 + 3,79 \times I_B$	$-1,95 \leq I_B \leq 2,32$	0,60	
$Cu_F = 16,48 + 9,20 \times I_{Cu}$	$-2,77 \leq I_{Cu} \leq 2,03$	0,92		$Cu_G = 12,22 + 2,78 \times I_{Cu}$	$-3,04 \leq I_{Cu} \leq 1,41$	0,78	
$Fe_F = 166,58 + 65,01 \times I_{Fe}$	$-1,96 \leq I_{Fe} \leq 2,43$	0,91		$Fe_G = 137,86 + 94,90 \times I_{Fe}$	$-2,06 \leq I_{Fe} \leq 3,86$	0,84	
$Mn_F = 61,75 + 27,09 \times I_{Mn}$	$-2,70 \leq I_{Mn} \leq 3,54$	0,94		$Mn_G = 27,22 + 3,34 \times I_{Mn}$	$-3,83 \leq I_{Mn} \leq 3,51$	0,85	
$Zn_F = 32,80 + 7,69 \times I_{Zn}$	$-1,96 \leq I_{Zn} \leq 1,92$	0,99		$Zn_G = 34,53 + 7,82 \times I_{Zn}$	$-3,08 \leq I_{Zn} \leq 2,57$	0,88	

Os teores ótimos estimados para I_{zi} igual a zero consistiram-se também na própria média da população de referência (Tabela 30), assim com os apresentados pelos trabalhos de KURIHARA, 2004 e URANO et al. (2007). Para estimar a faixa ótima considerou-se uma amplitude de $\pm 2/3$ desvios padrão para o índice CND ($-0,67 \leq I \leq 0,67$).

Tabela 30 – Faixa de suficiência dos teores de nutrientes nas folhas e nos grãos de soja considerando uma amplitude de $\pm 2/3$ s para o índice CND ($-0,67 \leq I \leq 0,67$).

Nutriente	Folhas			Grãos		
	CND Inferior	CND Superior	CND Ótimo	CND Inferior	CND Superior	CND Ótimo
	----- g kg ⁻¹ -----					
N	43,6	52,4	48,0	53,2	61,8	57,5
P	2,8	4,7	3,8	4,4	5,5	5,0
K	23,4	29,4	26,4	22,0	23,5	22,8
Ca	7,3	8,6	7,9	2,0	2,7	2,3
Mg	3,1	3,9	3,5	2,4	3,2	2,8
S	2,0	3,7	2,8	2,2	4,2	3,2
	----- mg kg ⁻¹ -----					
B	46	57	52	42	47	44
Cu	10	23	16	10	14	12
Fe	123	210	167	74	201	138
Mn	44	80	62	25	29	27
Zn	28	38	33	29	40	35

4.4. Máquina de Vetor de Suporte (SVM)

A SVM foi aplicada utilizando os teores de todos os nutrientes e a produtividade da soja, a fim de estimar os índices DRIS e CND. Para tanto, foram testadas diversas configurações para a SVM. As configurações que obtiveram melhores resultados foram as que utilizaram as funções do núcleo NormalizedPolyKernel e PolyKernel com a variável de complexidade igual a 3,0.

A configuração utilizando PolyKernel e variável de complexidade igual a 3,0 apresentou uma menor efetividade em relação aos erros relativos absolutos do que a configuração utilizando NormalizedPolyKernel. Porém, as regressões resultantes da primeira configuração, como a apresentada no Quadro 7, demonstram um maior grau de simplicidade ao apresentar os pesos atribuídos a cada nutriente, possibilitando a identificação de quais nutrientes afetam mais a relação do índice DRIS ou CND.

Por sua vez, a configuração utilizando a função do núcleo NormalizedPolyKernel apresentou resultados mais precisos. Porém, sua regressão (Quadro 8) é de mais difícil compreensão e uso.

Quadro 7 - Regressão SVM para N-DRIS com função de núcleo Polykernel.

$$N_DRIS = 0,6547 \times N^1 - 0,1141 \times P^1 - 0,0745 \times K^1 - 0,1059 \times Ca^1 - 0,1855 \times Mg^1 - 0,12 \times S^1 - 0,1043 \times B^1 - 0,1061 \times Cu^1 - 0,1235 \times Fe^1 - 0,1035 \times Zn^1 - 0,1196 \times Mn^1 - 0,0018 \times \text{Produtividade}^1 + 0,6202$$

¹ Variável Normalizada

Quadro 8 - Regressão SVM para N-DRIS com função de núcleo NormalizedPolyKernel.

$$\begin{aligned} N_DRIS = & +0,4633 \times k[2] - 0,3955 \times k[3] - 3,0 \times k[7] + 3,0 \times k[8] - 3,0 \times k[9] - 3,0 \times k[10] + 2,9896 \times k[11] + 3,0 \times \\ & k[13] + 2,3676 \times k[14] - 0,2320 \times k[15] + 3,0 \times k[16] - 3,0 \times k[17] - 3,0 \times k[18] + 3,0 \times k[19] - 3,0 \times k[20] + 0,5577 \times \\ & k[21] + 3,0 \times k[22] + 3,0 \times k[23] - 2,6952 \times k[24] + 1,0242 \times k[25] - 2,189 \times k[26] + 3,0 \times k[27] - 3,0 \times k[28] - 3,0 \times k[30] + 3,0 \\ & \times k[31] - 2,5390 \times k[33] - 2,8578 \times k[34] + 3,0 \times k[35] - 1,0310 \times k[36] + 0,3395 \times k[37] + 0,2897 \times k[38] + 3,0 \times k[39] - 3,0 \times \\ & k[41] - 2,6162 \times k[42] + 3,0 \times k[43] - 3,0 \times k[44] - 3,0 \times k[45] + 3,0 \times k[46] + 1,0440 \times k[47] - 3,0 \times k[48] + 3,0 \times \\ & k[49] + 1,3801 \times k[50] + 3,0 \times k[51] - 1,2315 \times k[52] + 1,4657 \times k[53] + 0,5005 \times k[54] - 3,0 \times k[55] + 3,0 \times k[56] + 3,0 \times \\ & k[57] - 0,9537 \times k[58] - 0,9086 \times k[59] - 0,7352 \times k[60] - 2,8531 \times k[61] + 0,7103 \times k[62] + 2,7824 \times k[63] + 1,9322 \times \\ & k[65] + 0,7168 \times k[66] + 0,2520 \times k[67] - 3,0 \times k[68] - 3,0 \times k[69] - 3,0 \times k[70] + 3,0 \times k[71] - 2,5743 \times k[72] + 2,7430 \times \\ & k[73] - 3,0 \times k[74] + 2,5432 \times k[75] - 0,014 \times k[76] + 3,0 \times k[77] - 2,3384 \times k[78] - 1,6587 \times k[79] + 3,0 \times k[80] - 1,6950 \times \\ & k[81] - 0,2814 \times k[84] - 3,0 \times k[85] - 1,7515 \times k[86] + 0,4269 \times k[87] - 3,0 \times k[88] + 3,0 \times k[89] + 3,0 \times k[90] - 3,0 \times \\ & k[91] + 3,0 \times k[92] - 3,0 \times k[93] - 1,5949 \times k[94] - 3,0 \times k[95] - 3,0 \times k[96] + 3,0 \times k[97] + 3,0 \times k[98] + 3,0 \times k[99] + 3,0 \times \\ & k[100] - 0,8711 \times k[101] + 0,4014 \times k[102] - 3,0 \times k[103] + 1,5233 \times k[104] - 3,0 \times k[105] - 2,2909 \times k[106] - 3,0 \times k[107] - \\ & 0,7363 \times k[108] + 1,7423 \times k[109] - 0,4422 \times k[110] + 1,0987 \times k[111] + 0,3720 \times k[112] - 3,0 \times k[114] - 3,0 \times k[115] - 3,0 \\ & \times k[116] + 3,0 \times k[117] + 2,3855 \times k[118] + 2,5662 \times k[120] + 0,0412 \times k[121] - 3,0 \times k[122] + 0,5327 \times k[123] - 3,0 \times \\ & k[124] - 1,7565 \times k[125] + 0,1950 \times k[126] - 0,0840 \times k[127] + 0,1798 \times k[128] + 3,0 \times k[130] + 1,7118 \times k[131] + 2,1994 \times \\ & k[132] + 3,0 \times k[134] + 3,0 \times k[135] - 0,8934 \times k[136] - 0,6737 \times k[137] + 1,7470 \times k[138] + 0,4090 \times k[139] + 3,0 \times \\ & k[140] + 3,0 \times k[141] - 3,0 \times k[142] + 3,0 \times k[143] - 2,5431 \times k[144] - 3,0 \times k[145] + 1,6494 \times k[147] - 3,0 \times k[148] - 0,0308 \times \\ & k[149] + 2,9236 \times k[150] + 3,0 \times k[151] + 3,0 \times k[152] - 3,0 \times k[153] + 2,9930 \times k[154] - 1,7277 \times k[155] - 1,6372 \times \\ & k[156] + 3,0 \times k[157] + 3,0 \times k[158] - 0,1353 \times k[159] - 0,7963 \times k[160] + 0,7900 \times k[161] - 3,0 \times k[162] + 3,0 \times k[163] - 3,0 \\ & \times k[164] + 2,2557 \times k[165] - 2,4838 \times k[166] - 3,0 \times k[167] - 3,0 \times k[168] + 2,1825 \times k[169] - 3,0 \times k[170] - 1,5489 \times \\ & k[171] + 2,7285 \times k[172] + 0,6409 \times k[173] + 0,7159 \end{aligned}$$

Optou-se então por utilizar o modelo treinado com a função de núcleo NormalizedPolyKernel e a variável de complexidade igual 3,0 para calcular os índices, uma vez que ele apresentou melhores resultados em relação ao PolyKernel.

Nota-se na Tabela 20 que a SVM apresentou, tanto para grãos como para folhas, altos coeficientes de determinação para a estimativa dos índices (superior a 90%), obtendo assim resultados bem próximos dos modelos originais DRIS e CND.

Em relação aos erros, a SVM foi mais eficiente na estimativa dos índices para o modelo CND tanto em folhas quanto em grãos, apresentando uma média do erro relativo absoluto para folhas de 8,75% e 11,52% para grãos, enquanto para o índice DRIS o erro

relativo absoluto para folhas foi de 10,29% e 13,51% para grãos. Assim, a aplicação da SVM nos modelos CND e DRIS apresentou maior eficiência para a estimativa dos nutrientes determinados na análise foliar, sendo o erro relativo absoluto aproximadamente 24% menor do que os obtidos na análise dos grãos.

Para estimar o nível ótimo e a faixa de suficiência foram utilizados os padrões aplicados no DRIS em uma regressão linear, tendo o índice de nível ótimo igual a zero e a faixa de suficiência no intervalo de $(-6,7 \leq I \leq 6,7)$, e os padrões do CND, nível ótimo igual a zero e a faixa de suficiência no intervalo de $(-0,67 \leq I \leq 0,67)$.

Os resultados apresentados pela SVM foram próximos aos valores obtidos pelo DRIS (Tabela 32) e pelo CND (Tabela 33). As variações dos índices foram muito pequenas, na ordem de décimos, porque os coeficientes de determinação (R^2) ficaram próximos de 1 e os erros apresentados foram consideravelmente baixos (Tabela 31).

Tabela 31 – Melhores resultados da SVM para os métodos DRIS e CND em folhas e grãos de soja.

Nutriente	SVM-DRIS Folhas					SVM-CND Folhas				
	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)
N	0,9882	0,3680	0,6252	8,6082	11,1585	0,9924	0,058	0,0887	7,6308	8,8570
P	0,9843	0,6659	1,0944	10,2063	12,8143	0,9926	0,056	0,0872	7,2344	8,7088
K	0,9910	0,3876	0,5528	8,2740	9,5295	0,9926	0,0612	0,0870	7,5488	8,6828
Ca	0,9839	0,3685	0,6705	10,0721	13,4865	0,9874	0,0653	0,1167	8,6370	11,6517
Mg	0,9835	0,4622	0,7658	11,4260	13,5223	0,9874	0,0748	0,1162	10,2799	11,6409
S	0,9742	0,7428	1,3309	11,3180	16,4131	0,9831	0,0782	0,1328	9,4707	13,2619
B	0,9799	0,5374	0,8025	11,7330	14,1042	0,9841	0,0839	0,1263	10,5045	12,5937
Cu	0,9577	0,9000	1,7577	13,2099	20,7081	0,9795	0,0892	0,1439	10,8447	14,3482
Fe	0,9898	0,5449	0,7791	9,6687	10,0847	0,9928	0,06 00	0,0851	8,1355	8,5038
Zn	0,9936	0,4092	0,5795	6,8189	7,9713	0,9952	0,0493	0,0694	5,7978	6,9209
Mn	0,9677	0,6862	1,3831	11,9074	18,0369	0,9801	0,0793	0,1435	10,1996	14,2633
Nutriente	SVM-DRIS Grãos					SVM-CND Grãos				
	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)
N	0,9813	0,5002	0,9578	9,0827	14,0643	0,9924	0,058	0,0887	7,6308	8,8570
P	0,9866	0,4833	0,7601	9,4500	11,7515	0,9880	0,0726	0,1119	9,1368	11,1554
K	0,9629	0,6720	0,9323	18,1764	19,2542	0,9736	0,1178	0,1634	14,6048	16,2986
Ca	0,9683	0,7499	1,3140	14,3193	18,2694	0,9801	0,0881	0,1432	12,1673	14,3346
Mg	0,9864	0,5317	0,8269	11,2073	11,9945	0,9906	0,0698	0,0991	9,7213	9,8712
S	0,9783	0,8606	1,2552	12,1121	14,7432	0,9849	0,0873	0,1236	10,3158	12,3550
B	0,9635	0,8265	1,1591	16,1081	18,9934	0,9754	0,1133	0,1569	13,1251	15,6445
Cu	0,9859	0,5551	0,8924	10,3986	12,2828	0,9888	0,0681	0,1073	8,8758	10,7194
Fe	0,9214	1,3691	2,3770	22,8215	28,1390	0,9543	0,1532	0,213	20,3574	21,3123
Zn	0,9868	0,5738	0,8431	10,6381	11,4120	0,9892	0,0684	0,1034	8,8361	10,3280
Mn	0,9526	0,5828	1,2445	14,2657	22,3453	0,9716	0,0917	0,1716	11,9279	17,1486

Tabela 32 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela SVM para o método DRIS.

Nutriente	Folhas			Grãos		
	SVM - DRIS Inferior	SVM – DRIS Superior	SVM – DRIS Ótimo	SVM - DRIS Inferior	SVM - DRIS Superior	SVM -DRIS Ótimo
----- g kg ⁻¹ -----						
N	39,8	56,2	48,0	50,6	64,3	57,5
P	2,6	4,9	3,7	4,0	6,0	5,0
K	21,0	31,8	26,4	20,5	25,0	22,8
Ca	6,5	9,3	7,9	1,8	2,9	2,3
Mg	2,8	4,3	3,5	2,2	3,4	2,8
S	1,7	3,9	2,8	1,9	4,4	3,2
----- mg kg ⁻¹ -----						
B	42	62	52	40	49	44
Cu	9	24	16	9	15	12
Fe	109	223	166	56	214	135
Mn	26	40	33	27	42	35
Zn	37	86	61	22	32	27

Tabela 33 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela SVM para o método CND.

Nutriente	Folhas			Grãos		
	SVM - CND Inferior	SVM – CND Superior	SVM – CND Ótimo	SVM – CND Inferior	SVM - CND Superior	SVM - CND Ótimo
----- g kg ⁻¹ -----						
N	47,4	48,6	48,0	53,1	61,9	57,5
P	2,8	4,7	3,7	4,4	5,6	5,0
K	23,3	29,5	26,4	21,9	23,6	22,8
Ca	7,3	8,6	7,9	2,0	2,7	2,3
Mg	3,1	3,9	3,5	2,4	3,2	2,8
S	1,9	3,7	2,8	2,1	4,2	3,2
----- mg kg ⁻¹ -----						
B	46	57	52	42	47	44
Cu	10	23	16	10	14	12
Fe	123	210	166	71	202	136
Mn	28	38	33	29	40	35
Zn	43	80	61	25	29	27

4.5. Rede Neural Artificial (RNA)

A aplicação da RNA utilizou a mesma entrada de dados da SVM, contendo os teores nutricionais de N, P, K, Ca, Mg, S, B, Cu, Fe, Zn e Mn, a produtividade da soja e os índices DRIS e CND como atributos meta, tendo esses últimos sido usados separadamente.

Foram realizados testes para obter a melhor arquitetura da RNA para cada nutriente e modelo. Os testes realizados variaram o número de camadas de 5 a 12 e a taxa de aprendizagem entre 0,3 e 0,4. Após obter a melhor configuração em torno das camadas e taxa

de aprendizagem foram testados esses resultados com o tempo de aprendizagem variando entre 2000, 2500, 3000 e 3500 épocas.

As melhores configurações estão apresentadas no Quadro 5. As configurações para as amostras foliares e grãos, em sua maioria, tiveram melhores resultados quando treinadas com o tempo de 3500 épocas. Já, a taxa de aprendizagem 0,4 apresentou maior representatividade entre os nutrientes exceto no modelo DRIS para nutrientes foliares e o número de camadas ocultas não obteve uma determinada predominância.

Na Tabela 34 pode-se analisar os resultados obtidos pela execução da RNA com as configurações apresentadas no Quadro 5. Nota-se que os coeficientes de determinação foram tão altos quantos os obtidos pela SVM, porém os erros relativos absolutos apresentaram valores menores que os apresentados pela SVM. Esse resultado deve-se a determinação de uma arquitetura para cada relação entre o modelo e os índices estimados.

Os erros relativos absolutos obtiveram um valor médio de 5,8%, tendo sido inferior ao erro médio da SVM, sendo 14% menor para o modelo CND na análise foliar e 26% na análise de grãos em relação ao DRIS.

Os resultados obtidos pela execução da RNA na análise foliar foram mais eficientes no modelo DRIS obtidos pelos grãos. Já no modelo CND, a análise foliar foi equivalente à análise dos grãos obtendo uma diferença de somente 3% em relação ao erro relativo absoluto.

Para estimar o nível ótimo e a faixa de suficiência foram utilizados os padrões aplicados no DRIS em uma regressão linear, tendo o índice para nível ótimo igual a zero e a faixa de suficiência no intervalo de $(-6,7 \leq I \leq 6,7)$, e os padrões do CND, com o nível ótimo igual a zero e a faixa de suficiência no intervalo de $(-0,67 \leq I \leq 0,67)$.

Os níveis de suficiência apresentados pela RNA foram próximos dos valores obtidos pelo DRIS (Tabela 35) e pelo CND (Tabela 36), demonstrando que a utilização do modelo apresenta viabilidade, uma vez o modelo treinado é capaz de estimar os níveis de suficiência desde que os experimentos sigam os mesmos padrões dos dados.

Tabela 34 - Melhores resultados da RNA para os métodos DRIS e CND em folhas e grãos de soja.

Nutriente	RNA - DRIS Folhas					RNA - CND Folhas				
	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)
N	0,9928	0,3216	0,4785	7,523	8,5404	0,9970	0,0404	0,0552	5,3109	5,5117
P	0,9984	0,2636	0,3471	4,0401	4,0637	0,9990	0,0218	0,0313	2,8102	3,1281
K	0,9940	0,3185	0,4515	6,7983	7,7831	0,9942	0,0546	0,0764	6,7247	7,6263
Ca	0,9918	0,3011	0,4499	8,2291	9,0487	0,9934	0,0555	0,0809	7,3382	8,082
Mg	0,9886	0,3565	0,6068	8,8134	10,7144	0,9930	0,0572	0,0839	7,8685	8,4035
S	0,9976	0,2421	0,3994	3,6887	4,926	0,9990	0,0212	0,0317	2,5742	3,1676
B	0,9932	0,3268	0,4665	7,1344	8,1986	0,9958	0,0455	0,0641	5,6905	6,3939
Cu	0,9916	0,3441	0,7755	5,0501	9,136	0,9950	0,0394	0,0704	4,7876	7,0239
Fe	0,9972	0,2745	0,4105	4,8699	5,3129	0,9984	0,0286	0,0394	3,8736	3,9428
Zn	0,9976	0,2477	0,3578	4,1284	4,9214	0,9972	0,0363	0,0522	4,2677	5,2023
Mn	0,9958	0,2636	0,4977	4,5748	6,4903	0,9978	0,033	0,0474	4,24	4,7153
Nutriente	RNA - DRIS Grãos					RNA - CND Grãos				
	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)	R ²	Erro Médio Absoluto	Erro Médio Quadrático	Erro Relativo Absoluto (%)	Raiz Quadrada do Erro Relativo (%)
N	0,9837	0,3631	0,8886	6,5935	13,0481	0,9974	0,0331	0,0524	3,9819	5,2274
P	0,9942	0,3425	0,493	6,6973	7,6229	0,9960	0,05	0,0646	6,2986	6,4366
K	0,9908	0,3275	0,4601	8,8577	9,5028	0,9942	0,0519	0,0772	6,4336	7,6999
Ca	0,9950	0,3689	0,5159	7,0447	7,173	0,9970	0,0383	0,0558	5,2905	5,5794
Mg	0,9938	0,3322	0,5481	7,002	7,9511	0,9972	0,0358	0,0526	4,9839	5,2352
S	0,9972	0,2968	0,4477	4,1769	5,2586	0,9972	0,0361	0,0533	4,2646	5,3344
B	0,9948	0,3066	0,4373	5,9757	7,1664	0,9972	0,0375	0,0527	4,3466	5,2504
Cu	0,9960	0,302	0,4561	5,6566	6,2783	0,9980	0,0318	0,0456	4,1469	4,5583
Fe	0,9807	0,6851	1,1838	11,4201	14,0137	0,9964	0,0378	0,0617	5,0299	6,1738
Zn	0,9970	0,2892	0,4011	5,3615	5,4292	0,9976	0,0331	0,0478	4,2782	4,7791
Mn	0,9916	0,3553	0,5261	8,6982	9,4467	0,9904	0,0635	0,0982	8,2602	9,8137

Tabela 35 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela RNA para o método DRIS.

Nutriente	Folhas			Grãos		
	RNA –	RNA –	RNA –	RNA –	RNA –	RNA –
	DRIS Inferior	DRIS Superior	DRIS Ótimo	DRIS Inferior	DRIS Superior	DRIS Ótimo
----- g kg ⁻¹ -----						
N	40,1	56,2	48,1	50,6	64,0	57,3
P	2,6	4,9	3,8	4,0	6,0	5,0
K	21,2	31,7	26,5	20,6	24,9	22,8
Ca	6,6	9,3	7,9	1,8	2,9	2,3
Mg	2,8	4,3	3,5	2,2	3,5	2,8
S	1,7	3,9	2,8	2,0	4,4	3,2
----- mg kg ⁻¹ -----						
B	42	62	52	40	49	44
Cu	9	24	16	10	15	12
Fe	109	223	166	60	216	138
Mn	26	40	33	27	42	34
Zn	38	86	62	22	32	27

Tabela 36 - Níveis de suficiência nas folhas e nos grãos de soja gerados pela RNA para o método CND.

Nutriente	Folhas			Grãos		
	RNA –	RNA –	RNA –	RNA –	RNA –	RNA –
	CND Inferior	CND Superior	CND Ótimo	CND Inferior	CND Superior	CND Ótimo
----- g kg ⁻¹ -----						
N	47,3	48,8	48,0	53,0	61,7	57,4
P	2,8	4,7	3,8	4,4	5,6	5,0
K	23,2	29,2	26,2	22,0	23,5	22,7
Ca	7,3	8,6	7,9	1,9	2,7	2,3
Mg	3,1	3,9	3,5	2,4	3,2	2,8
S	2,0	3,7	2,8	2,2	4,3	3,2
----- mg kg ⁻¹ -----						
B	46	57	52	42	47	44
Cu	10	23	16	10	14	12
Fe	123	210	166	73	202	138
Mn	28	38	33	29	40	34
Zn	42	79	60	25	29	27

4.6. Definição de Teores e Faixa Ótima de Nutrientes nas Folhas e nos Grãos de Soja

Os métodos de diagnose do estado nutricional DRIS, CND, SVM-DRIS, SVM-CND, RNA-DRIS e RNA-CND no terceiro trifólio sem pecíolo (Tabela 37) e nos grãos (Tabela 38) de soja concordam na indicação de que o teor ótimo estimado é o próprio teor médio da população de referência. Já, para o método ChM os valores foram divergentes porque os altos valores de determinadas unidades experimentais ocasionaram alta concentração de amostras em poucas classes, causando desvios de normalidade na população de referência.

Em relação à faixa ótima de teores também verificou-se concordância entre os métodos avaliados, à exceção de P nas folhas (Tabela 37) e de Fe nos grãos (Tabela 38), em que a amplitude de valores foi maior quando estimado por meio da ChM. Este comportamento pode ser explicado pela associação de grande número de classes de frequência com valores elevados de chance matemática e da grande amplitude de valores dentro de cada classe.

Para o N, os teores estimados pelos modelos SVM-CND e RNA-CND nas folhas (Tabela 37) e RNA-CND nos grãos (Tabela 38) apresentaram uma faixa ótima muito estreita em comparação com os demais métodos, apesar dos altos níveis de correlação entre o nutriente e o índice. Destaca-se que a amplitude de valores estimados pelo CND tendeu a ser menor em relação ao índice DRIS, mesmo considerando uma faixa de desvio padrão igual para os dois métodos. Diante dessa situação, é sugerida a adoção dos valores de faixa ótima com maior amplitude (KURIHARA, 2004), ou seja, daqueles definidos pelo DRIS.

De acordo com Wadt (1996), o limite inferior da faixa ótima pode ser considerado o nível crítico do nutriente, o que corresponderia ao teor deste associado a uma produtividade equivalente a 90% daquela possível de ser obtida em condições de teor ótimo. Nas determinações tanto em folhas (Tabela 37) como em grãos (Tabela 38), o método CND resultou em valores de níveis críticos maiores do que aqueles estimados pela ChM e pelo DRIS, à exceção do teor de Cu nos grãos cujo nível crítico foi igual para esses três métodos. Mesmo com a aplicação das técnicas SVM e RNA, os níveis críticos se mantiveram maiores para o CND em relação dos demais métodos estudados.

A análise dos métodos estudados na diagnose foliar da soja (Tabela 37) permite inferir que o DRIS apresentou resultados mais consistentes em relação aos métodos de ChM e CND, assim com os apresentados nos trabalhos de Kurihara et al. (2008), Romagnoli et al. (2008) e Urano et al. (2007). Para alguns nutrientes, como P e S nas folhas, o método ChM proporcionou grande amplitude de variação da faixa ótima, enquanto o método CND foi demasiadamente restritivo com relação à essa amplitude de variação.

As faixas de valores obtidas para os teores de nutrientes nos grãos apresentaram normalidade nos resultados pelos métodos ChM, DRIS e CND, o que indica uma possível utilização dos grãos para avaliação do estado nutricional da soja. Destaca-se que, quando o DRIS foi aplicado aos grãos de soja, obteve-se menor rejeição das relações duais em relação à diagnose foliar, evidenciando precisão ainda maior na interpretação dos resultados. Isso indica que a faixa ótima de nutrientes calculada pelo DRIS nos grãos poderia ser uma alternativa viável para a realização de diagnóstico nutricional da cultura da soja. As técnicas de SVM e RNA incorporadas aos métodos DRIS e CND proporcionaram valores de faixa ótima e de teor

ótimo de nutrientes bem próximos daqueles obtidos com os algoritmos originais. Esses resultados sugerem que essas técnicas poderiam ser usadas como alternativa para os modelos no diagnóstico nutricional da soja.

Tabela 37 – Faixa de suficiência e teor ótimo de nutrientes no terceiro trifólio sem pecíolo da soja estimados pelos métodos de Chance Matemática (ChM), DRIS, CND, SVM-DRIS, SVM-CND, RNA-DRIS e RNA-CND.

Nutriente	ChM		DRIS		CND		SVM-DRIS		SVM-CND		RNA-DRIS		RNA-CND	
	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo
----- g kg ⁻¹ -----														
N	39,8–58,7	50,8	40,0–56,1	48,0	43,6–52,4	48,0	39,8 – 56,2	48,0	47,4 – 48,6	48,0	40,1 – 56,2	48,1	47,3 – 48,8	48,0
P	1,4–5,6	3,3	2,6–4,9	3,8	2,8–4,7	3,8	2,6 – 4,9	3,7	2,8 – 4,7	3,7	2,6 – 4,9	3,8	2,8 – 4,7	3,8
K	18,3–33,5	27,4	21,1–31,7	26,4	23,4–29,4	26,4	21,0 – 31,8	26,4	23,3 – 29,5	26,4	21,2 – 31,7	26,5	23,2 – 29,2	26,2
Ca	6,1–9,1	7,7	6,6–9,3	7,9	7,3–8,6	7,9	6,5 – 9,3	7,9	7,3 – 8,6	7,9	6,6 – 9,3	7,9	7,3 – 8,6	7,9
Mg	2,3–4,3	3,4	2,8–4,3	3,5	3,1–3,9	3,5	2,8 – 4,3	3,5	3,1 – 3,9	3,5	2,8 – 4,3	3,5	3,1 – 3,9	3,5
S	0,9–4,9	2,2	1,8–3,9	2,8	2,0–3,7	2,8	1,7 – 3,9	2,8	1,9 – 3,7	2,8	1,7 – 3,9	2,8	2,0 – 3,7	2,8
----- mg kg ⁻¹ -----														
B	40–67	52	42–62	52	46–57	52	42 – 62	52	46–57	52	42–62	52	46–57	52
Cu	6–14	11	9–24	16	10–23	16	9 – 24	16	10 – 23	16	9 – 24	16	10 – 23	16
Fe	80–189	140	110–223	167	123–210	167	109 – 223	166	123 – 210	166	109 – 223	166	123 – 210	166
Mn	23–98	54	38–86	62	44–80	62	26 – 40	33	28 – 38	33	26 – 40	33	28 – 38	33
Zn	20–37	29	26–40	33	28–38	33	37 – 86	61	43 – 80	61	38 – 86	62	42 – 79	60

Tabela 38 – Faixa de suficiência e teor ótimo de nutrientes nos grãos de soja estimados pelos métodos de Chance Matemática (ChM), DRIS, CND, SVM-DRIS, SVM-CND, RNA-DRIS e RNA-CND.

Nutriente	ChM		DRIS		CND		SVM-DRIS		SVM-CND		RNA-DRIS		RNA-CND	
	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo	Faixa ótima	Teor ótimo
----- g kg ⁻¹ -----														
N	46,7–71,9	56,4	50,8–64,2	57,5	53,2–61,8	57,5	50,6 – 64,3	57,5	53,1 – 61,9	57,5	50,6 – 64,0	57,3	53,0 – 61,7	57,4
P	3,6–6,4	5,1	4,0–5,9	5,0	4,4–5,5	5,0	4,0 – 6,0	5,0	4,4 – 5,6	5,0	4,0 – 6,0	5,0	4,4 – 5,6	5,0
K	19,8–25,8	23,2	20,6–24,9	22,8	22,0–23,5	22,8	20,5 – 25,0	22,8	21,9 – 23,6	22,8	20,6 – 24,9	22,8	22,0 – 23,5	22,7
Ca	1,2–3,0	2,2	1,8–2,9	2,3	2,0–2,7	2,3	1,8 – 2,9	2,3	2,0 – 2,7	2,3	1,8 – 2,9	2,3	1,9 – 2,7	2,3
Mg	2,1–3,7	2,7	2,2–3,4	2,8	2,4–3,2	2,8	2,2 – 3,4	2,8	2,4 – 3,2	2,8	2,2 – 3,5	2,8	2,4 – 3,2	2,8
S	1,2–4,2	2,6	2,0–4,4	3,2	2,2–4,2	3,2	1,9 – 4,4	3,2	2,1 – 4,2	3,2	2,0 – 4,4	3,2	2,2 – 4,3	3,2
----- mg kg ⁻¹ -----														
B	36–50	43	40–49	44	42–47	44	40 – 49	44	42 – 47	44	40 – 49	44	42 – 47	44
Cu	10–13	12	10–15	12	10–14	12	9 – 15	12	10 – 14	12	10 – 15	12	10 – 14	12
Fe	39–270	107	61–215	138	74–201	138	56 – 214	135	71 – 202	136	60 – 216	138	73 – 202	138
Mn	21–35	27	23–32	27	25–29	27	27 – 42	35	29 – 40	35	27 – 42	34	29 – 40	34
Zn	27–45	36	27–42	35	29–40	35	22 – 32	27	25 – 29	27	22 – 32	27	25 – 29	27

5. CONCLUSÕES

O método de avaliação do estado nutricional Sistema Integrado de Diagnose e Recomendação (DRIS) apresentou resultados mais consistentes em relação aos métodos Chance Matemática (ChM) e Diagnose da Composição Nutricional (CND) para representar os níveis de suficiência de teores de nutrientes nas folhas de soja.

Os grãos de soja podem ser utilizados em substituição às folhas para a diagnose do estado nutricional da cultura da soja. Os níveis de suficiência para a cultura da soja podem ser obtidos a partir da estimativa das faixas ótimas de teores de nutrientes nos grãos, por meio do método DRIS, para uma faixa de equilíbrio de $\pm 10 \frac{2}{3}$ desvios padrão em torno do índice igual à zero (fator de ajuste $c = 10$).

A utilização das técnicas Máquina de Vetor de Suporte (SVM) e Redes Neurais Artificiais (RNAs) apresentaram valores próximos dos extraídos pelos métodos DRIS e CND, indicando a possibilidade de utilização dessas técnicas para avaliar o estado nutricional da cultura da soja.

REFERÊNCIAS

- AITKENHEAD, M.J.; COULL, M.C.; TOWERS, W.; HUDSON, G.; BLACK, H.I.J. Predicting soil chemical composition and other soil parameters from field observations using a Neural Network. *Computers and Electronics in Agriculture*, v.82, p.108–116, 2012.
- ARAÚJO, S.R.; WETTERLIND, J.; DEMATT, J.A.M.; STEMBERG, B. Improving the prediction performance of a large tropical vis-NIR spectroscopic soil library from Brazil by clustering into smaller subsets or use of data mining calibration techniques. *European Journal of Soil Science*, v.65, p.718–729, 2014.
- BATAGLIA, O.C.; SANTOS, WR. Efeito do procedimento de cálculo e da população de referência nos índices do sistema integrado de diagnose e recomendação (DRIS). *Revista Brasileira de Ciência do Solo*, v.14, p.339-344, 1990.
- BEAUFILS, E.R. Diagnosis and recommendation integrated system (DRIS). A. general scheme for experimentation and calibration based on principles developed from research in plant nutrition. *Soil Science Bulletin*, v.1, p.132, 1973.
- BEN-HANAN, U.; PELEGI, K.; GUTMAN, P. Classification of Fruits by a Boltzmann Perceptron Neural Network. *Automatica*, v.28, p.961-968, 1992.
- BORKERT, C.M.; YORINORI, J.T.; CORREA-FERREIRA, B.S.; ALMEIDA, A.M.R.; FERREIRA, L.P.; SFREDO, G.J. Seja o doutor da sua soja. *Informações Agrômicas*, n.66, 1994.
- BURKS, T.F.; SHEARER, S.A.; GREEN, J.D.; HEATH, J.R. Influence of weed maturity levels on species classification using machine vision. *Weed Science*, v.50, p.802–811, 2002.
- CAMACHO, M.A., SILVEIRA, M.V.D., CAMARGO, R.A., NATALE, W. Faixas normais de nutrientes pelos métodos ChM, DRIS e CND e nível crítico pelo método de distribuição normal reduzida para laranja-pera. *Revista Brasileira de Ciência do Solo*, v.36, p.193-200, 2012.

CASTAMANN, A.; ESCOSTEGUY, P.A.V.; BERRES, D.; ZANELLA, S. Diagnosis and Recommendation Integrated System (DRIS) of Soybean Seed Oil content. *Revista Brasileira de Ciência do Solo*, v.36, p.1820-1827, 2012.

COMPANHIA NACIONAL DE ABASTECIMENTO. Acompanhamento da safra brasileira de grãos. – v.2, Safra 2014–15, n.11 (2015) – Brasília: Conab, 2015.

DEUS J.A.L.; BARRETO J.H.B.; SOARES I. ; SOUZA N.C.S.; SALES J.A.F.; OLIVEIRA FILHO J.S.; Chance Matemática na Determinação do Estado Nutricional do Amendoim. *Bioscience Journal*, v.28, p.351-357, 2012.

EMBRAPA. Soja em números (safra 2012/2013), 2013. Disponível em <http://www.cnpso.embrapa.br/index.php?cod_pai=69&op_page=294>. Acesso em 16 Fev. 2014.

EVENHUIS, B.; WAARD, P.W.F. *Principles and practices in plant analysis*. FAO. Soils. Rome, 1980. p.152–163.

FERRIS, I.G.; FRECKER, T.C.; HAIGH, B.M.; DURRANT, S. HERBICIDE ADVISER: A decision support system to optimise atrazine and chlorsulfuron activity and crop safety. *Computers and Electronics in Agriculture*, v.6, p.295- 317, 1992.

FILGUEIRAS, P. R.; de SOUZA, A. M.; POPPI, R.; COELHO, M.; PARÉS, J.; CUNHA, T.; DART, R. D. O. Avaliação de modelos de calibração PLS e SVM na determinação do carbono orgânico do solo por espectroscopia NIR. In: REUNIÃO ANUAL DA SOCIEDADE BRASILEIRA DE QUÍMICA, 35., Águas de Lindóia, SP, 2012. Águas de Lindóia: SBQ, 2012.

FORTIN, J.G.; MORAIS, A.; ANCTIL, F.; PARENT L.E. SVMLEACH – NK POTATO: A simple software tool to simulate nitrate and potassium co-leaching under potato crop. *Computers and Electronics in Agriculture*, v.110, p.259–266, 2015.

GAGO, J.; MARTÍNEZ-NÚÑEZ, L.; LANDÍN, M.; GALLEGOS, P.P. Artificial Neural Networks as an alternative to the traditional statistical methodology in plant research. *Journal of Plant Physiology*, v.167, p.23–27, 2010.

GRASSI FILHO, H. Diagnose foliar: princípios e aplicações. In: PRADO, R.M.; ROZANE, D.E.; VALE, D.W.; CORREIA, M.A.R.; SOUZA, H.A. (Eds.) Nutrição de plantas: diagnose foliar em grandes culturas. Jaboticabal: FCAV, 2008. p.35-60.

GOEL, P.K.; PRASHER, S.O.; LANDRY, J.A.; PATEL, R.M.; VIAU, A.A. Hyperspectral image classification to detect weed infestations and nitrogen status in corn. *Transactions of the ASAE*, v.46, p.539–550, 2003.

GUERRERO, J.M.; PAJARES, G.; MONTALVO, M.; ROMEO, J.; GUIJARRO, M. Support Vector Machines for crop/weeds identification in maize fields. *Expert Systems with Applications*, v.39, p.11149–11155, 2012.

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

HARGER N.; FIORETTO R.; RALISCH R. Avaliação nutricional da cultura da soja pelos métodos DRIS e níveis de suficiência. *Semina: Ciências Agrárias*, v.24, p.219-224, 2003.

JONES, C.A. Proposed modifications of the diagnosis and recommendation integrated system (DRIS) for interpreting plant analyses. *Communications in Soil Science and Plant Analysis*, v.12, p.785-794, 1981.

KHIARI, L.; PARENT, L.E. & TREMBLAY, N. Critical compositional nutrient indexes for sweet corn at early growth stage. *Agronomy Journal*, v.93, p.809-814, 2001a.

KHIARI, L.; PARENT, L.E. & TREMBLAY, N. The phosphorus compositional nutrient diagnosis range for potato. *Agronomy Journal*, v.93, p.815-819, 2001b.

KOVAČEVIĆ, M.; BAJAT, B.; GAJIĆ, B. Soil type classification and estimation of soil properties using Support Vector Machines. *Geoderma*, v.154, p.340–347, 2010.

KURIHARA, C.H.; STAUT, L.A.; MAEDA, S. Faixas de suficiência para teores foliares de nutrientes em algodão e soja, definidas pelo uso do método DRIS de diagnose do estado nutricional. In: REUNIÃO BRASILEIRA DE FERTILIDADE DO SOLO E NUTRIÇÃO DE PLANTAS, 28.; REUNIÃO BRASILEIRA SOBRE MICORRIZAS, 12.; SIMPÓSIO BRASILEIRO DE MICROBIOLOGIA DO SOLO, 10.; REUNIÃO BRASILEIRA DE BIOLOGIA DO SOLO, 7., Londrina, 2008. Anais. Londrina: Embrapa Soja:IAPAR, Universidade Estadual de Londrina, 2008.

KURIHARA, C.H.; VENEGAS, V.H.A; NEVES, J.C.L.; NOVAIS, R.F. Acúmulo de matéria seca e nutrientes em soja, como variável do potencial produtivo. *Revista Ceres*, v.60, p.690-698, 2013a.

KURIHARA, C.H.; VENEGAS, V.H.A; NEVES, J.C.L.; NOVAIS, R. F.; STAUT, L.A. Faixas de suficiência para teores foliares de nutrientes em algodão e em soja, definidas em função de índices DRIS. *Revista Ceres*, v.60, p.412-419, 2013b.

KURIHARA, C.H. Demanda de nutrientes pela soja e diagnose de seu estado nutricional. Tese (Doutorado em Agronomia), Universidade Federal de Viçosa, 2004. p.

LORENA, A.C., de CARVALHO, A.C. Uma introdução às Support Vector Machines. *Revista de Informática Teórica e Aplicada*, v.14, p.43-67, 2007.

MAEDA, S. Interpretação do estado nutricional de soja pelo DRIS no Mato Grosso do Sul. Tese (Doutorado em Ciências). Universidade Federal do Paraná, Curitiba, 2002. 107p.

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

MUCHERINO, A.; PAPAJOJGI, P.; PARDALOS, P.M.A survey of data mining techniques applied to agriculture. *International Journal of Operations Research*, v.9, p.121–140, 2009.

OLIVEIRA, S. A. Análise Foliar. In: SOUZA, D. M. G.; LOBATO, E. (Ed.). Cerrado: correção do solo e adubação. 2. ed. Brasília, DF: Embrapa Informações Tecnológicas, 2004. cap. 10, p. 245-256.

PARENT, L.E.; DAFIR, M.A. theoretical concept of compositional nutrient diagnosis. *Journal of the American Society for Horticultural Science*, v.117, p.239-242, 1992.

PARTELLI, F.L., DIAS, J.R.M., VIEIRA, H.D., WADT, P.G.S., JÚNIOR, E.P. Avaliação nutricional de feijoeiro irrigado pelos métodos CND, DRIS e Faixas de Suficiência. *Revista Brasileira de Ciência do Solo*, v.38, p.858-866, 2014.

POLITI, L.S; FLORES, R.A.; SILVA, J.D.; WADT, P.G.; PINTO, P.D.C.; PRADO, R.D.M Estado nutricional de mangueiras determinado pelos métodos DRIS e CND. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v.17, p.11-18, 2013.

ROMAGNOLI, LUCAS MESSIAS, ALVARES FÁBIO. Normas DRIS para avaliação do estado nutricional de cultivares de soja convencional e transgênica. In: JORNADA ACADÊMICA DA EMBRAPA SOJA, Londrina, 2008. Resumos expandidos... Londrina: Embrapa Soja, 2008.

SANTOS, E.F; DONHA, R.M.A.; MAGNO, C.M. Faixas normais de nutrientes em cana-de-açúcar pelos métodos ChM, DRIS e CND e nível crítico pela distribuição normal reduzida. *Revista Brasileira de Ciência do Solo*, v.37, p.1651-1658, 2013.

SARUTA, K.; HIRAI, Y.; TANAKA, K.; INOUE, EIJI; OKAYASU, T.; MITSUOKA, M. *Predictive Models for Yield and Protein Content of Brown Rice Using Support Vector Machine. Computers and Electronics in Agriculture*, v. 99, pg.93–100, 2013.

SERRA, A.P., MARCHETTI, M.E., VITORINO, A.C.T., NOVELINO, J.O., CAMACHO, M.A. Desenvolvimento de normas DRIS e CND e avaliação do estado nutricional da cultura do algodoeiro. *Revista Brasileira de Ciência do Solo*, v.34, p. 97-104, 2010.

TAN, K.Z.; CHAY, Y.H.; SONG, W.X.; CAO, X.D. Identification of diseases for soybean seeds by computer vision applying BP neural network. *International Journal of Agricultural and Biological Engineering*, v.7, p.43-50, 2014.

TAN, P.; STEINBACH, M.; KUMAR, V. Introdução ao Data Mining (Mineração de Dados). Editora Ciência Moderna, 2009.

TEIXEIRA, L. A. J., TECCHIO, M. A., MOURA, M. F., TERRA, M. M., & PIRES, E. J. P. Normas DRIS e níveis críticos de nutrientes para videira ‘Niagara Rosada’ cultivada na região de Jundiaí-SP. *Revista Brasileira de Fruticultura*, v.37, p.247-255, 2015.

TOMIO D.B.; UTUMI M. M.; PEREZ D. V.; DIAS J.R.M.; WADT P. G. S. Antecipação da diagnose foliar em arroz de sequeiro, *Pesquisa Agropecuária Brasileira*, v.50, p.250-258, 2015.

URANO E.O.M.; KURIHARA C.H.; MAEDA S.; VITORINO A.C.T.; GONÇALVES M. C.; MARCHETTI M. E. Avaliação do estado nutricional da soja. *Pesquisa Agropecuária Brasileira*, v.41, p.1421-1428, 2006.

URANO, E. O. M.; KURIHARA, C. H.; MAEDA, S.; VITORINO, A. C. T.; GONÇALVES, M. C.; MARCHETTI, M. E. Determinação de teores ótimos de nutrientes em Soja pelos métodos Chance Matemática, Sistema Integrado de Diagnose e Recomendação e Diagnose da Composição Nutricional. *Revista Brasileira de Ciência do Solo*, v.31, p.63-72, 2007.

WADT, P.G.S. Os métodos da Chance Matemática e do Sistema Integrado de Diagnose e Recomendação (DRIS) na avaliação nutricional de plantios de eucalipto. Tese (Doutorado em Agronomia) - Universidade Federal de Viçosa, Viçosa, 1996. 123p.

WADT, P.G.S., NOVAIS, R.D., ALVAREZ V, V.H., FONSECA, S., BARROS, N. D. Valores de referência para macronutrientes em eucalipto obtidos pelos métodos DRIS e Chance Matemática. *Revista Brasileira de Ciência do Solo*, v.22, p. 685-692, 1998.

WADT, P.G.S., SILVA, D.J., MAIA, C.E., TOMÉ JÚNIOR, J.B., PINTO, P.D.C., MACHADO, P.D.A. Modelagem de funções no cálculo dos índices DRIS. *Pesquisa Agropecuária Brasileira*, v.42, p.57-64, 2007.


WADT, P.G.S.; ANGHINONI I.; GUINDANI, R.H.P.; LIMA, A.S.T.; PUGA, A.P.; SILVA, G.S.; PRADO, R.M. Padrões nutricionais para lavouras arrozadeiras irrigadas por inundação pelos métodos da CND e Chance Matemática. *Revista Brasileira de Ciência do Solo*, v.37, p.145-156, 2013.

YU, H.; LIU, D.; CHEN, G.; WAN, B.; WANG, S.; YANG, B. A Neural Network Ensemble Method for precision fertilization modeling. *Mathematical and Computer Modelling*, v.51, p.1375-1382, 2010.


ZÚÑIGA, A.M.G. Sistema de visão artificial para identificação do estado nutricional de plantas. Dissertação (Mestrado em Ciências – Ciência da Computação e Matemática Computacional). Universidade de São Paulo, São Carlos, 2012. p.91-134.

APÊNDICE A – Telas do Sistema

Tela Inicial.



Tela de Cadastro de Solos



Tela de Cadastro de Fazendas e Parcelas

[illegible]

Tela de Análise por Chance Matemática

Análise por Chance Matemática

Valor de Alta Produção: 3600


Folha

Analisar

Nutriente	ChM Ótimo	Chm Faixa Inferior	Chm Faixa Supe...
N	50,746	39,8	58,7
P	3,392	1,4	6,8
K	27,348	18,3	33,5
Ca	7,829	6,1	10,3
Mg	3,406	2,3	4,3
S	2,233	0,9	5,4
B	52,42	40,1	66,5
Cu	10,756	5,5	17,1
Fe	139,75	79,8	188,8
Zn	31,962	19,8	47,8
Mn	54,195	22,7	97,5

Sair

Tela de Análise por CND



Análise por Diagnóstico da Composição Nutricional

Valor de Alta Produção: 3600

Tipo: Folha

Analisar

Nutriente	CND Ótimo	CND Faixa Inferior	CND Faixa Superior
N	48,011	43,643	52,379
P	3,752	2,793	4,712
K	26,41	23,39	29,43
Ca	7,935	7,295	8,574
Mg	3,517	3,119	3,914
S	2,831	1,956	3,706
B	51,709	46,304	57,114
Cu	16,481	10,316	22,646
Fe	166,58	123,023	210,137
Zn	32,803	27,651	37,955
Mn	61,751	43,602	79,9

Sair

Tela de Análise por DRIS

Analise pelo Sistema Integrado de Diagnose e Recomendações

Valor de Alta Produção: 3600 Tipo: Folha

Nutriente	DRIS Ótimo	DRIS Faixa Inferior	DRIS Faixa Supe...
N	48,011	39,966	56,057
P	3,752	2,623	4,882
K	26,41	21,105	31,715
Ca	7,935	6,564	9,306
Mg	3,517	2,775	4,258
S	2,831	1,749	3,913
B	51,709	41,842	61,576
Cu	16,481	9,259	23,703
Fe	166,58	109,879	223,281
Zn	32,803	25,613	39,993
Mn	61,751	37,793	85,709

Tela de Análise por RNA

Analise por Redes Neurais Artificiais

Valor de Alta Produção: 3600 Tipo: Folha

Nutriente	SVM DRIS Ótimo	SVM DRIS Faixa Inferior	SVM DRIS Faixa Superior	SVM CND Ótimo	SVM CND Faixa Inferior	SVM CND Faixa Superior
N	48,006	39,978	56,035	47,8866	43,51415	52,20297
P	3,701	2,566	4,835	3,7283502	2,7684383	4,688262
K	26,382	21,03	31,735	26,30817	23,254833	29,361507
Ca	7,93	6,556	9,305	7,9206877	7,2810216	8,560353
Mg	3,52	2,779	4,261	3,5170765	3,1163096	3,9178433
S	2,837	1,75	3,925	2,8262303	1,9475541	3,7049065
B	51,733	41,822	61,843	51,48707	46,074806	56,859337
Cu	16,461	9,247	23,674	16,43762	10,304369	22,57147
Fe	166,839	110,457	223,222	166,5126	123,018936	210,00627
Zn	32,714	25,5	39,928	32,624355	27,47189	37,77682
Mn	61,378	37,517	85,238	61,55299	43,463444	79,64253

Tela de Análise por SVM

Analise por Máquina de Vetor de Suporte

Valor de Alta Produção Tipo

3600 Folha Gerar

Nutriente	SVM DRIS Ótimo	SVM DRIS Faixa Inferior	SVM DRIS Faixa Superior	SVM CND Ótimo	SVM CND Faixa Inferior	SVM CND Faixa Superior
N	48,003	39,788	56,219	48,024	43,84254	52,405357
P	3,738	2,573	4,904	3,7455263	2,771925	4,7191277
K	26,405	21,003	31,807	26,400663	23,329475	29,471851
Ca	7,925	6,514	9,336	7,925735	7,271939	8,579531
Mg	3,509	2,747	4,271	3,5128102	3,1060066	3,9196138
S	2,81	1,895	3,924	2,8159628	1,9252433	3,7068822
B	51,854	41,585	61,723	51,995364	46,15989	57,17084
Cu	16,389	8,772	24,006	16,473772	10,189919	22,757626
Fe	165,952	108,973	222,931	166,19743	122,48576	209,9091
Zn	32,77	25,558	39,982	32,777885	27,609106	37,946667
Mn	61,403	36,562	86,244	61,492428	42,8273	80,157555

Tela de Análise por ChM, CND e DRIS

Resultado Geral

Valor de Alta Produção Tipo

3600 Folha Analisar Relatório

Nutriente	ChM Ótimo	ChM Faixa Inferior	ChM Faixa Superior	DRIS Ótimo	DRIS Faixa Inferior	DRIS Faixa Superior	CND Ótimo	CND Faixa Inferior	CND Faixa Superior
N	50,746	39,8	58,7	48,011	39,966	56,057	48,011	43,643	52,379
P	3,392	1,4	6,8	3,752	2,623	4,882	3,752	2,793	4,712
K	27,348	18,3	33,5	26,41	21,105	31,715	26,41	23,39	29,43
Ca	7,829	6,1	10,3	7,935	6,564	9,306	7,935	7,295	8,574
Mg	3,406	2,3	4,3	3,517	2,775	4,258	3,517	3,119	3,914
S	2,233	0,9	5,4	2,831	1,749	3,913	2,831	1,956	3,706
B	52,42	40,1	65,5	51,709	41,842	61,576	51,709	45,304	57,114
Cu	10,756	5,5	17,1	16,481	9,259	23,703	16,481	10,316	22,646
Fe	139,75	79,8	188,8	166,58	109,879	223,281	166,58	123,023	210,137
Zn	31,962	19,8	47,8	32,803	25,813	39,993	32,803	27,651	37,955
Mn	54,195	22,7	97,5	61,751	37,793	85,709	61,751	43,602	79,9

Sair