

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

FACULDADE DE CIÊNCIAS E ENGENHARIA

Programa de Pós-Graduação em Agronegócio e Desenvolvimento

BRUNO CÉSAR GÓES

**MODELAGEM *FUZZY* DO ACÚMULO DE MATÉRIA SECA E DAS VARIÁVEIS
NUTRICIONAIS DE COBERTURAS VEGETAIS DE PREPARO PARA SISTEMA
PLANTIO DIRETO EM RESPOSTA À DIFERENTES DOSES DE NITROGÊNIO**

TUPÃ-SP

2019

BRUNO CÉSAR GÓES

**MODELAGEM *FUZZY* DO ACÚMULO DE MATÉRIA SECA E DAS VARIÁVEIS
NUTRICIONAIS DE COBERTURAS VEGETAIS DE PREPARO PARA SISTEMA
PLANTIO DIRETO EM RESPOSTA À DIFERENTES DOSES DE NITROGÊNIO**

Dissertação apresentada ao Programa de Pós-Graduação em Agronegócio e Desenvolvimento da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Campus de Tupã, como requisito para a obtenção do título de Mestre em Agronegócio e Desenvolvimento.

Área de concentração:

Agronegócio e Desenvolvimento

Linha de pesquisa:

Desenvolvimento e Meio Ambiente

Orientador:

Prof. Dr. Luís Roberto Almeida Gabriel Filho

Coorientador:

Prof. Dr. Renato Jaqueto Goes

Profa. Dra. Camila Pires Cremasco Gabriel

**TUPÃ-SP
2019**

Ficha catalográfica


G553m Góes, Bruno César.
Modelagem *Fuzzy* do acúmulo de matéria seca e das
variáveis nutricionais de coberturas vegetais de preparo para
sistema plantio direto em resposta à diferentes doses de
nitrogênio / Bruno César Góes. - Tupã, 2019.
87 f.

Dissertação (Mestrado em Agronegócio e Desenvolvimento) –
Faculdade de Ciências e Engenharia – Universidade Estadual
Paulista “Júlio de Mesquita Filho”, 2019.

Orientador Prof. Dr. Luís Roberto Almeida Gabriel Filho
Orientador Prof. Dr. Renato Jaqueto Goes
Orientadora Profa. Dra. Camila Pires Cremasco Gabriel

1. Lógica *Fuzzy*. 2. Modelagem matemática. 3. Cultura de
cobertura. 4. Sorgo. 5 Milheto. I. Título. II. Autor.

Fonte: Seção Técnica de Biblioteca e Documentação por Eliana Kátia Pupim
Bibliotecária CRB 8 – 6202. Essa ficha não pode ser modificada.



CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: MODELAGEM FUZZY DO ACÚMULO DE MATÉRIA SECA E DAS VARIÁVEIS NUTRICIONAIS DE COBERTURAS VEGETAIS DE PREPARO PARA SISTEMA DE PLANTIO DIRETO EM RESPOSTA À DIFERENTES DOSES DE NITROGÊNIO


AUTOR: BRUNO CÉSAR GÓES


ORIENTADOR: LUÍS ROBERTO ALMEIDA GABRIEL FILHO


COORIENTADORA: CAMILA PIRES CREMASCO GABRIEL

COORIENTADOR: RENATO JAQUETO GOES

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONEGÓCIO E DESENVOLVIMENTO, pela Comissão Examinadora:

Prof.^a Dr.^a CAMILA PIRES CREMASCO GABRIEL 
Coordenadoria do Curso de Engenharia de Biosistemas / Faculdade de Ciências e Engenharia - FCE - UNESP
- Tupã/SP

Prof. Dr. MARIO MOLLO NETO 
Coordenadoria do Curso de Engenharia de Biosistemas / Faculdade de Ciências e Engenharia - FCE - UNESP
- Tupã/SP

Prof. Dr. DANIEL DOS SANTOS VIAIS NETO 
Coordenadoria do Curso de Tecnologia em Agronegócio / Faculdade de Tecnologia - FATEC - Presidente Prudente/SP

Tupã, 14 de janeiro de 2019

Dedico,

Aos meus pais, Antônio e Roseli, aos meus irmãos Juninho e Caio, à minha esposa Élide e ao meu filho Bruninho por todo apoio, incentivo e paciência para realização dessa etapa da minha vida.

AGRADECIMENTOS

Inicialmente agradeço à DEUS por me permitir à conclusão de uma etapa tão grandiosa e desejada em minha vida, nunca me deixando desanimar frente aos obstáculos encontrados ao longo desse caminho.

Aos meus pais, Antônio e Roseli, por todo incentivo e carinho por eles demonstrados ao longo da vida, sempre acreditando em minha capacidade. Por toda educação familiar e escolar que me foram concedidas, permitindo-me estudar em uma das melhores universidades, e hoje realizando esta conquista desse tão sonhado título acadêmico. A eles, minha eterna gratidão.

Aos meus irmãos, Juninho e Caio por estarem sempre ao meu lado, me apoiando e aconselhando-me em minhas decisões, além de sempre acreditarem no meu potencial.

A minha esposa, Élide, por sua tamanha importância em minha vida. Sempre perseverando ao meu lado nessa difícil caminhada em busca da realização dos meus sonhos. Por todo carinho, amor e compreensão demonstrados ao longo dessa jornada, sendo fundamentais para a realização dessa conquista.

Ao meu filho, Bruninho, no qual eu tenho como a fonte de maior amor e inspiração, para batalhar em busca dos sonhos, superando e vencendo os mais diversos desafios.

Aos meus amigos, o orientador Prof. Dr. Luís Roberto Almeida Gabriel Filho e Prof. Dr. Fernando Ferrari Putti, pessoas, as quais não me cabem palavras da tamanha gratidão e responsabilidade atribuída a vocês por essa realização, e que sempre os levarei como exemplos de professores e de pessoas ao longo da vida.

A Profa. Dra. Camila Pires Cremasco, por todo apoio e orientação, sempre acreditando em minha capacidade, incentivando a trilhar no caminho do meio acadêmico.

Ao meu amigo Jhonatan Piazzetin, pela amizade, companheirismo e incentivo durante o desenvolvimento de pesquisa do Mestrado, além do convívio proporcionado ao longo do ano de 2018 pelas disciplinas em comum cursadas na FCA em Botucatu.

E ao meu Coorientador Prof. Dr. Renato Jaqueto Goes, pelas inúmeras vezes nas quais foram sanadas minhas dúvidas para que pudesse escrever a dissertação.

Aos funcionários e docentes da Faculdade de Ciências e Engenharia – UNESP Campus de Tupã, pelo convívio diário e por toda presteza e solicitude no atendimento quando se fez necessário durante esses anos.

GÓES, Bruno César. **Modelagem fuzzy do acúmulo de matéria seca e das variáveis nutricionais de coberturas vegetais de preparo para sistema plantio direto em resposta à diferentes doses de nitrogênio**. 2019. 87 f. Dissertação (Mestrado em Agronegócio e Desenvolvimento) – Faculdade de Ciências e Engenharia, Universidade Estadual Paulista, Tupã, 2019.

RESUMO

O Sistema Plantio Direto (SPD) tem como característica a ocupação permanente do terreno agrícola com culturas vegetais além da manutenção da palhada sob a superfície do solo. Entretanto, para eficácia do SPD, é necessário adotar culturas de coberturas adequadas com a região a ser implementado, levando-se em consideração fatores edafoclimáticos e tipos de solo, para que dessa forma, haja a formação e manutenção da palhada sobre a superfície do solo. O sorgo possui como principais características, a tolerância de período de seca, e alto volume de produção de matéria seca, importantes para adoção dos sistemas de sucessão de culturas. O milho, além da alta resistência à períodos de estresse hídrico, possui alta concentração de produção de biomassa. A taxa de decomposição da cobertura vegetal é regulada pela relação Carbono e Nitrogênio (C/N) específico de cada cultura. Nesse contexto, o presente trabalho visou analisar com modelos matemáticos os efeitos do nitrogênio sobre as culturas, sorgo e milho, com finalidade de posterior uso como coberturas vegetais, sob níveis diferentes de nitrogênio em relação às variáveis de produtividade de matéria seca, teor de Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg), Enxofre (S) e Molibdênio (Mo) e acúmulo de N, P, K, Ca, Mg, S e Mo com elaboração do modelo *fuzzy*. Foi realizada a comparação entre os modelos *fuzzy* (gaussiano e triangular) e de regressão polinomial por meio de testes estatísticos de ajustes de modelos e determinação do coeficiente de determinação (R^2). Dessa forma, concluiu-se que o melhor rendimento para os teores dos nutrientes analisados fora apresentado pela cobertura vegetal de milho, já por sua vez, a cobertura vegetal de sorgo, apresentou os melhores rendimentos sobre os acúmulos dos nutrientes, pois obteve a maior produtividade de matéria seca em relação ao milho. Analiticamente, verificou-se os melhores parâmetros estatísticos para a modelagem *fuzzy* triangular em comparação ao modelo *fuzzy* gaussiano e regressão polinomial de grau dois. No entanto, em relação ao comportamento da curva das modelagens matemáticas, o modelo gaussiano mostrou-se mais condizente com a realidade dos fenômenos agrônômicos, em grande parte devida a suavização da curva sobre o conjunto dos dados.

Palavras-chave: lógica *fuzzy*, modelagem matemática, cultura de cobertura, sorgo, milho.

GÓES, Bruno César. ***Fuzzy modeling of dry matter accumulation and nutritional variables of crop cover crops for no - tillage system in response to different nitrogen rates.*** 2019. 87 f. Dissertation (Master in Agribusiness and Development) – School of Sciences and Engineering, São Paulo State University (UNESP), Tupã, 2019.

ABSTRACT

The Direct Planting System (DPS) has as a characteristic the permanent occupation of the agricultural land with plant crops besides the maintenance of the straw under the soil surface. However, for DPS efficacy, it is necessary to adopt adequate cover crops with the region to be implemented, taking into account edaphoclimatic factors and soil types, so that the formation and maintenance of the straw on the soil surface. Sorghum has as main characteristics, to the tolerance of drought period, and high volume of dry matter production, important for the adoption of crop succession systems. Millet, besides the high resistance to periods of water stress, has high concentration of biomass production. The rate of decomposition of the vegetal cover is regulated by the relation Carbon and Nitrogen (C/N) specific of each culture. In this context, the present work aimed to analyze with mathematical models the effects of nitrogen on crops, sorghum and millet, with the purpose of later use as plant cover, under different levels of nitrogen in relation to the variables of dry matter yield content, Nitrogen (N), Phosphorus (P), Potassium (K), Calcium (Ca), Magnesium (Mg), Sulfur (S) and Molybdenum (Mo) and accumulation of N, P, K, Ca, Mg, S and Mo with elaboration of the *fuzzy* model. The comparison between the *fuzzy* (gaussian and triangular) and polynomial regression models was carried out by means of statistical tests of model adjustments and determination of the coefficient of determination (R^2). Thus, it was concluded that the best yield for the nutrient contents analyzed was presented by the plant cover of millet, and in turn, the vegetative cover of sorghum, presented the best yields on the accumulation of nutrients, as it obtained the highest productivity of dry matter in relation to millet. Analytically, the best statistical parameters for triangular *fuzzy* modeling were verified in comparison to the gaussian *fuzzy* model and degree two polynomial regression. However, in relation to the behavior of the mathematical modeling curve, the Gaussian model proved to be more in keeping with the reality of agronomic phenomena, due in large part to the smoothing of the curve over the data set.

Keywords: *fuzzy* logic, mathematical modeling, cover crop, sorghum, millet.

LISTA DE TABELAS

Tabela 1 - Definição das funções de pertinência triangulares da variável de entrada.	23
Tabela 2 - Delimitadores da função de pertinência triangular da variável de entrada.	25
Tabela 3 - Delimitadores da função de pertinência gaussiana da variável de entrada.	25
Tabela 4 - Características dos delimitadores para a variável de saída do sistema baseado em regras <i>fuzzy</i> , com funções de pertinência triangular.	26
Tabela 5 - Associação do conjunto <i>fuzzy</i> de entrada com o conjunto <i>fuzzy</i> de saída.	27
Tabela 6 - Passos de amalgamação do milheto.	39
Tabela 7 - Correlação de Pearson entre as variáveis para a cobertura vegetal milheto com nível de significância de 5%.	40
Tabela 8 . Passos de amalgamação do sorgo.	41
Tabela 9 - Correlação de Pearson entre as variáveis para a cobertura vegetal sorgo com nível de significância de 5%.	42
Tabela 10 - Delimitadores das funções de pertinência da variável de saída produtividade de matéria seca para a cobertura vegetal de milheto.	44
Tabela 11 - Delimitadores das funções de pertinência da variável de saída produtividade de matéria seca para a cobertura vegetal de sorgo.	44
Tabela 12 - Base de regras do sistema <i>fuzzy</i> para a variável produtividade de matéria seca. .	44
Tabela 13 - Validação do modelo <i>fuzzy</i> nas funções triangulares e gaussianas das coberturas vegetais de milheto e sorgo.	45
Tabela 14 - Análise de variância e teste Tukey das coberturas vegetais para a produtividade de matéria seca em relação a doses de nitrogênio.	47
Tabela 15 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de matéria seca.	47
Tabela 16 - Delimitadores das funções de pertinência de saída de tipo triangular para as variáveis de saída da cultura de cobertura de milheto.	53
Tabela 17 - Base de regras do SBRF para a cobertura vegetal de milheto.	54
Tabela 18 - Validação dos modelos <i>fuzzy</i> para as variáveis de saída dos teores de nutrientes da cultura de milheto.	55
Tabela 19 - Validação dos modelos <i>fuzzy</i> para as variáveis de saída dos acúmulos de nutrientes da cultura de milheto.	56
Tabela 20 - Análise de variância e teste de Tukey das coberturas vegetais sob efeito de doses de nitrogênio para os teores de nutrientes.	59

Tabela 21 - Análise de variância e teste de Tukey das coberturas vegetais sob efeito de doses de nitrogênio para os acúmulos de nutrientes.....	62
Tabela 22 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de nitrogênio.....	62
Tabela 23 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de fósforo.	63
Tabela 24 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de potássio.....	63
Tabela 25 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de cálcio.	64
Tabela 26 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de magnésio.....	64
Tabela 27 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de enxofre.....	64
Tabela 28 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de molibdênio.....	65
Tabela 29 - Delimitadores das funções de pertinência de saída de tipo triangular para as variáveis de saída da cultura de cobertura de sorgo.....	70
Tabela 30 - Base de regras do SBRF para a cobertura vegetal de sorgo.....	71
Tabela 31 - Validação dos modelos <i>fuzzy</i> para as variáveis de saída dos teores de nutrientes da cultura de sorgo.....	72
Tabela 32 - Validação dos modelos <i>fuzzy</i> para as variáveis de saída dos acúmulos de nutrientes da cultura de sorgo.	73

LISTA DE FIGURAS

Figura 1 - Valores de precipitação e temperatura em Selvíria-MS.	17
Figura 2 - Características da função de pertinência Gaussiana.	20
Figura 3 - Exemplo de função de pertinência do tipo triangular.	21
Figura 4 - Sistema <i>fuzzy</i> para avaliação das variáveis nutricionais da cobertura vegetal com funções de pertinência gaussianas de entrada.	22
Figura 5 - Sistema <i>fuzzy</i> para avaliação das variáveis nutricionais da cobertura vegetal com funções de pertinência triangulares de entrada.	22
Figura 6 - Funções de pertinência triangulares da variável de entrada doses de nitrogênio... ..	24
Figura 7 - Funções de pertinência gaussianas da variável de entrada doses de nitrogênio.... ..	24
Figura 8 - Exemplo da análise de dendrograma.	31
Figura 9 - Produtividade da matéria seca (MS) das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	32
Figura 10 - Teor de N, P e K das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	33
Figura 11 - Teor de cálcio das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	34
Figura 12 - TMg das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	34
Figura 13 - TS e TMO das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	35
Figura 14 - Acúmulo de nitrogênio (N), fósforo (P) e potássio (K) das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	36
Figura 15 - ACa e AMg das coberturas vegetais de milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	37
Figura 16 - AS e AMO das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$)	37
Figura 17 - Dendrograma das variáveis da cobertura vegetal de milho.	38
Figura 18 - Dendrograma das variáveis da cobertura vegetal de sorgo.	41
Figura 19 - Função de pertinência da produtividade de matéria seca do milho.	43
Figura 20 - Função de pertinência da produtividade de matéria seca do sorgo.	43

Figura 21 - Comparação entre as funções (<i>fuzzy</i> triangular, <i>fuzzy</i> gaussiana, polinomial) para a variável de saída produtividade de matéria seca.....	46
Figura 22 - Funções de pertinência de saída dos teores de nutrientes para a cultura de cobertura vegetal do milho.....	48
Figura 23 - Funções de pertinência de saída dos acúmulos de nutrientes para a cultura de cobertura vegetal do milho.	50
Figura 24 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, TN, TP, TK, TCa, TMg, TS e TMo, para a cultura de cobertura vegetal do milho.	57
Figura 25 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, AN, AP, AK, ACa, AMg, AS e AMo, para a cultura de cobertura vegetal do milho.....	60
Figura 26 - Funções de pertinência de saída dos teores de nutrientes para a cultura de cobertura vegetal do sorgo.....	65
Figura 27 - Funções de pertinência de saída dos acúmulos de nutrientes para a cultura de cobertura vegetal do sorgo.	67
Figura 28 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, TN, TP, TK, TCa, TMg, TS e TMo, para a cultura de cobertura vegetal do sorgo.....	74
Figura 29 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, AN, AP, AK, ACa, AMg, AS e AMo, para a cultura de cobertura vegetal do sorgo.	77

SUMÁRIO

1 INTRODUÇÃO	12
2 OBJETIVOS	16
3 MATERIAL E MÉTODOS	17
3.1 Descrição do experimento	17
3.1.1 Variáveis analisadas	18
3.2 Método de modelagem <i>fuzzy</i>	19
3.2.1 Conjuntos <i>fuzzy</i> da variável de entrada	23
3.2.2 Método de construção dos conjuntos <i>fuzzy</i> das variáveis de saída	25
3.2.3 Método de elaboração da base de regras	26
3.2.4 Método de inferência e <i>defuzzyficação</i>	27
3.3 Análise de regressão	27
3.4 Métodos de análise do grau de ajuste do modelo	28
3.4.1 Coeficiente de determinação (R^2)	28
3.4.2 Raiz do erro quadrático médio (<i>RMSE</i>)	29
3.4.3 Erro absoluto médio (<i>MAE</i>)	29
3.5 Intervalo de confiança	29
3.6 Análise multivariada	30
4 RESULTADOS E DISCUSSÃO	32
4.1 Intervalo de confiança das variáveis das coberturas vegetais	32
4.1.1 Produtividade de matéria seca e teor de nutrientes	32
4.1.2 Acúmulo de nutrientes	35
4.2 Análise multivariada	38
4.3 Modelagem <i>fuzzy</i> das coberturas vegetais	42
4.3.1 Modelagem <i>fuzzy</i> da produtividade de matéria seca do milho e sorgo	43
4.3.2 Modelagem das variáveis da cobertura vegetal do milho	48
4.3.3 Modelagem das variáveis da cobertura vegetal do sorgo	65
5 CONCLUSÕES	79
REFERÊNCIAS	80

1 INTRODUÇÃO

O sistema de preparo convencional do solo tem como objetivo aumentar a produtividade da cultura com o uso de técnicas de aração e gradagens revolvendo camadas do solo reduzindo a compactação, além da utilização de corretivos e fertilizantes para preservar suas características físicas e químicas (SILVA et al., 2011; PÖHLITZ et al., 2018).

Em virtude do movimento da agricultura sustentável, iniciado em meados da década de 1970, que consiste na conservação do solo e dos recursos naturais promovendo o aumento de produtividade das culturas agrícolas (LANDRES, 2005; SIQUEIRA NETO et al., 2010), grandes números de agricultores estão substituindo o sistema de preparo convencional do solo pela Agricultura de Conservação (AC), constituída dos princípios de: (1) minimização de perturbação do solo, (2) maximização da superfície vegetal do solo e (3) e a manutenção da atividade biológica, seja por meio da rotação de culturas ou por culturas de cobertura (DERPSCH et al., 2014).

Nesse contexto, aplica-se o Sistema Plantio Direto (SPD), o qual tem por característica a ocupação permanente do terreno agrícola com culturas vegetais além da manutenção da palhada sob a superfície do solo (COELHO et al., 2013; GOLABI; EL-SWAIFY; IYEKAR, 2014; BRANCO et al., 2017). Tais aplicações atenuam o processo de erosão do solo, aumentam a atividade microbiana promovida pela reciclagem dos nutrientes oriundos da decomposição da matéria orgânica que é gerada pela palhada e aumenta a capacidade de armazenamento de água no solo evitando perdas pelo processo de evaporação (DONK et al., 2010; RIBAS et al., 2015). Contudo, o reflexo no aumento de produção aferida em lucros pelo SPD, é influenciado diretamente pela gestão anterior do solo, na qual proporcionará ao produtor o gerenciamento de uma maior área de cultivo além da redução de custos com insumos e maquinários agrícolas, resultando no aumento de produtividade da cultura (DELAUNE; SIJ, 2012; RUSU, 2014).

Dessa forma, observou-se um aumento expressivo da área de cultivo sob SPD no mundo passando de 45 milhões de hectares em 1999 para quase 156 milhões de hectares no ano de 2015 (DERPSCH et al., 2010; FAO, 2017; PÖHLITZ et al., 2018), liderado pelos Estados Unidos com uma área equivalente a 35,6 milhões de hectares de SPD representando 22,8% da área mundial cultivada, seguido pelo Brasil e Argentina, com áreas de 31,8 milhões de hectares e 29,1 milhões de hectares respectivamente, contabilizando mais de 62% da área cultivada no mundo sob SPD, pelos três países (FAO, 2016).

No Brasil, a tecnologia agrícola do SPD começou a ser adotada no início dos anos de 1970, porém ganhou expressividade a partir da década de 1990, aumentando a área cultivada de 1 milhão de hectares para quase 31,8 milhões de hectares em 2015, o que representa aproximadamente 45% do terreno agrícola do país (FEBRAPDP, 2012; GIAROLA et al., 2013; FAO, 2016), além de tornar-se uma referência mundial no uso da tecnologia do Sistema de Plantio Direto (MOTTER; ALMEIDA, 2015).

Em consonância, verifica-se o grande número de trabalhos correlatos sobre SPD nos últimos anos, a exemplo de Mitchell et al. (2017), no qual verificaram-se a melhora dos aspectos químicos, físicos e biológicos do solo, utilizando culturas de coberturas sob SPD; Rusu (2014) avaliou a eficiência energética da produção sob SPD, resultando no aumento de produtividade comparado ao sistema convencional de cultivo e Damian et al. (2017) analisaram a variabilidade de culturas de coberturas sobre SPD no rendimento da cultura sucessora, para o caso, a influência na produtividade da soja.

Entretanto, para eficácia do SPD, é necessário adotar culturas de coberturas adequadas com a região a ser implementado o Sistema Plantio Direto, levando-se em consideração fatores edafoclimáticos e tipos de solo, para que dessa forma, haja a formação e manutenção da palhada sobre a superfície do solo (KLIEMANN; BRAGA; MARQUES, 2006; GOES, 2016).

O sorgo é uma planta pertencente à família das gramíneas, distribuindo-se em regiões tropicais áridas e semiáridas dos continentes africano, asiático e americano, adaptadas para regiões quentes e secas (QI et al., 2018). É ampla a variedade de utilização da cultura do sorgo, como exemplos na produção de ração para animais (INÁCIO et al., 2017; SELLE et al., 2018), produção de biocombustíveis (CASTRO et al., 2017; APPIAH-NKANSAH et al., 2018) além da sua utilização para consumo humano (LOPES et al., 2018).

Suas principais características estão associadas à tolerância de período de seca, além do alto volume de produção de matéria seca, sendo esses, fatores determinantes para sua utilização como cultura de cultivo em sistemas de sucessão de culturas (PEDREIRA et al., 2003; ARAYA et al., 2018), conforme observado nos trabalhos de Correia e Durigan (2008), no qual avaliaram a fertilidade do solo sob influência de coberturas vegetais (sorgo) e Sales et al. (2016) na avaliação da qualidade física do solo sob sistema de plantio direto e convencional, utilizando o sorgo como cultura de cobertura.

O milheto, assim como o sorgo, é uma planta pertencente à família das gramíneas, cujas características são típicas de regiões quentes e secas (NIELSEN; VIGIL, 2017), com características de alta resistência à períodos estresse hídrico além de possuir o sistema radicular

profundo, que o torna como boa opção para uso como cultura de cobertura, acrescentada à sua alta produção de biomassa (TRINDADE et al., 2017). Seu uso como cultura de cobertura foi avaliado nos trabalhos de Tribouillois, Constantin e Justes (2018) sobre modelagem da emergência das coberturas vegetais e Calonego et al. (2017), que verificaram a produtividade da soja em função da compactação do solo utilizando coberturas vegetais sob SPD.

Assim, as coberturas vegetais tem por finalidade elevar a capacidade de absorção e acúmulo de nutrientes e o aumentar o potencial de produção de fitomassa, melhorando a interação solo-planta quanto à ciclagem e disponibilidade dos nutrientes do solo (ALBUQUERQUE et al., 2013), podendo também ser utilizada para controle de plantas daninhas em culturas (ALVAREZ; STEINBACH; DE PAEPE, 2017), conformem aferidos por García-González et al. (2018), no qual proporcionou melhorias na qualidade do solo com uso de coberturas vegetais em solos degradados. As culturas de coberturas possibilitam também ao produtor a redução de custos com fertilizantes nitrogenados, resultando em ganhos econômicos (PRECHSL et al., 2017), conforme observado no trabalho de Jahanzad et al. (2017), apresentando uma melhora no rendimento de tubérculos de batata e concentração dos nutrientes minerais por meio das culturas de cobertura.

A disponibilidade de nutrientes é fundamental durante o processo de formação, maturação e desenvolvimento das sementes, uma vez que as mesmas, utilizam deles como reserva de fonte energética para constituição das membranas (TEIXEIRA et al., 2005). A sua deficiência pode acarretar em problemas estruturais das membranas, comprometendo a atividade metabólica e enzimática das sementes (MORTVEDT; RÖMHELD; MARSCHNER, 1991).

No entanto, para a formação de matéria seca da cultura de cobertura, a velocidade de decomposição da matéria orgânica depende de características específicas e do volume aplicado da cultura adotada, além da disponibilidade de fauna já existente no solo e das condições edafoclimáticas de cada região, principalmente as taxas de temperatura do ar e precipitação pluvial (BRESSAN et al., 2013; SOUZA et al., 2014). Contudo, a taxa de decomposição da cobertura vegetal é regulada pela relação Carbono e Nitrogênio (C/N) específico de cada cultura, sendo fator determinante para a eficiência de conservação do solo (SOUZA et al., 2014; GOES, 2016).

Nesse contexto, as culturas de coberturas potencializam a liberação de Nitrogênio (N) mineral por meio da mineralização de seus resíduos, influenciando diretamente na relação C/N da cobertura vegetal, a qual controla a taxa de liberação de N incorporados ao solo tornando-se disponíveis para a cultura sucessora (TRIBOUILLOIS et al., 2015). Por sua vez, a

relação C/N é responsável pela taxa de decomposição da matéria orgânica, de maneira que quanto menor esta relação C/N, ou seja, maior concentração de N, maior será a velocidade do processo de decomposição, por outro lado, quando for baixa a concentração do N, e consequentemente, alta a relação C/N, o processo de decomposição ocorrerá lentamente, permanecendo por maior tempo a palhada sobre a superfície do solo (CALVO; FOLONI; BRANCALIAO, 2010).

Dessa maneira, o presente estudo teve como objetivo analisar com modelos matemáticos os efeitos do nitrogênio sobre as culturas do sorgo e do milho, com finalidade para uso como coberturas vegetais, sob níveis diferentes de nitrogênio em relação às variáveis de produtividade de matéria seca (MS), teor e acúmulo de Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg), Enxofre (S) e Molibdênio (Mo).

É de grande abordagem a aplicação de modelos matemáticos na área das ciências agrárias, uma vez que se trata de uma área de cunho experimental, datada de riqueza de dados e experimentação, como consta em Guo, Westra e Maier (2016), no qual utilizaram modelos matemáticos para determinação da evapotranspiração, em Mahn (2017), que modelou matematicamente o efeito da fertilização com selênio na cultura de brócolis.

No entanto, nas modelagens matemáticas, é comum a ocorrência de erros nos modelos de regressão, seja devido à mudanças abruptas no relacionamento entre as variáveis, dependente e independente (LU; CHANG, 2018) ou por erros de medição durante a observação dos experimentos (BOUKEZZOULA; GALICHET; COQUIN, 2018), no qual, muitas vezes ocorridos por informações imprecisas (LI et al., 2016). Nesse contexto, foi introduzida por Zadeh (1965) a modelagem matemática *fuzzy*, cujo intuito, é prever áreas na qual as informações são imprecisas, aproximando-se com a realidade, a ocorrência dos experimentos (LI et al., 2016; GARG; AGGARWAL; SOKHAL, 2017).

Em virtude da aplicabilidade dos modelos matemáticos nas ciências agrárias, é de maneira condizente suas aplicações por meio de modelagem *fuzzy*, a exemplos de Kisi (2013) para determinação da evapotranspiração de referência utilizando a modelagem *fuzzy*, Gabriel Filho et al. (2016) aplicando os modelos *fuzzy* para avaliação da massa corporal de bovinos e Putti et al. (2017a) para determinação da produtividade do trigo com diferentes doses de efluentes.

2 OBJETIVOS

O presente trabalho tem como objetivo a elaboração de modelos *fuzzy* para avaliação dos efeitos do nitrogênio sobre as culturas do sorgo e do milho, com finalidade de posterior uso como coberturas vegetais, em região de clima de cerrado, sob quatro doses de nitrogênio em relação às variáveis de produtividade de matéria seca ($\text{kg} \cdot \text{ha}^{-1}$), teor de N ($\text{g} \cdot \text{kg}^{-1}$), P ($\text{g} \cdot \text{kg}^{-1}$), K ($\text{g} \cdot \text{kg}^{-1}$), Ca ($\text{g} \cdot \text{kg}^{-1}$), Mg ($\text{g} \cdot \text{kg}^{-1}$), S ($\text{g} \cdot \text{kg}^{-1}$) e Mo ($\text{mg} \cdot \text{kg}^{-1}$) e acúmulo de N ($\text{kg} \cdot \text{ha}^{-1}$), P ($\text{kg} \cdot \text{ha}^{-1}$), K ($\text{kg} \cdot \text{ha}^{-1}$), Ca ($\text{kg} \cdot \text{ha}^{-1}$), Mg ($\text{kg} \cdot \text{ha}^{-1}$), S ($\text{kg} \cdot \text{ha}^{-1}$) e Mo ($\text{g} \cdot \text{ha}^{-1}$).

Constituem como objetivos específicos desta pesquisa:

- i) Realizar a análise quantitativa e qualitativa da produtividade da matéria seca e do teor e acúmulo dos nutrientes N, P, K, Ca, Mg, S e Mo das coberturas vegetais de milho e sorgo utilizando modelagem *fuzzy* e métodos estatísticos.

3 MATERIAL E MÉTODOS


Inicialmente, esta seção apresenta a descrição do experimento utilizado para realização da modelagem *fuzzy*, seguida da descrição das análises estatísticas e modelagem *fuzzy* para estudo dos efeitos em relação às diferentes dosagens de nitrogênio aplicadas às coberturas vegetais de sorgo e milho para posterior uso sob SPD.

3.1 Descrição do experimento

O experimento foi conduzido no ano agrícola 2013/14, na Fazenda de Ensino Pesquisa e Extensão (FEPE) da Universidade Estadual Paulista “Júlio de Mesquita Filho”, localizada na cidade de Selvíria-MS à 20 km de Ilha Solteira. A FEPE possui coordenadas 51° 22’ de longitude Oeste e 20° 22’ de latitude Sul, com 335 m de altitude, com solo tipo Latossolo Vermelho de textura argilosa (EMBRAPA, 2006; GOES, 2016), e clima do tipo Aw com precipitação anual total de 1.330 mm, temperatura média anual de 25° C e umidade relativa do ar de 66% conforme a classificação Köppen (CENTURION, 1982).

A análise de variância do experimento foram feitas em Goes (2016). Os dados referentes às variáveis climáticas, temperatura e pluviosidade, durante a realização do experimento no ano 2013/14 são apresentados na Figura 1:

Figura 1 - Valores de precipitação e temperatura em Selvíria-MS.



Legenda: A primeira quinzena refere-se ao dia 20/05/2013, assim, sucessivamente até a vigésima quarta quinzena referindo-se ao dia 07/04/2014. Fonte: Estação Agrometeorológica da Fazenda de Ensino, Pesquisa e Extensão (GOES, 2016).

Para análise das coberturas vegetais, adotou-se o esquema fatorial 2×4 com delineamento em blocos casualizados seguido de três repetições. Foram utilizados como tratamentos, as coberturas vegetais do sorgo e do milho com quatro doses diferentes de nitrogênio para cada cobertura (0, 40, 80 e $120 \text{ kg} \cdot \text{ha}^{-1}$), sendo assim, as parcelas foram constituídas de 14 linhas de 12 m de comprimento e espaçamento de 0,34 m entrelinhas.

O experimento foi conduzido em duas áreas distintas com distanciamento de 30 m, sob irrigação por pivô central. Na área utilizada para condução experimento houve o cultivo da cultura de soja na safra no ano agrícola anterior, 2012/13, sendo realizada em seguida a semeadura das coberturas vegetais (20/05/2013), conforme descrito em Goes (2016).

Foi utilizado 18 kg ha^{-1} de semente de milho para condução do experimento da variedade ADR 300, cuja altura varia entre 189 e 230 cm e florescimento ocorre entre 45 e 50 dias após a emergência das plântulas (PEREIRA FILHO et al., 2003). Por sua vez, foi utilizado $12 \text{ kg} \cdot \text{ha}^{-1}$ de sementes do sorgo de variedade Asgrow Jade®, distribuído por Sementes Semeali, sorgo granífero com características, florescimento decorrido 62 dias após emergência das plântulas e altura de 133 cm e produtividade de $3,34 \text{ t} \cdot \text{ha}^{-1}$ (CASELA et al., 1996).

A fertilização nitrogenada foi realizada nas culturas de coberturas ao lado das plantas, quando estas apresentavam entre quatro e cinco folhas expandidas, e foi utilizada o nitrato de amônio (33% de N) como fonte de nutriente, por apresentar menor perda por volatilização de amônia (GOES, 2016), ocorrendo após a dessecação das coberturas vegetais, o manejo da palhada por meio do rolo-faca (20/11/2013).

3.1.1 Variáveis analisadas

Foram analisadas um total de 15 variáveis, sendo elas: produtividade de matéria seca (MS), teor de nitrogênio (TN), teor de fósforo (TP), teor de potássio (TK), teor de cálcio (Ca), teor de magnésio (TMg), teor de enxofre (TS), teor de molibdênio (TMo), acúmulo de nitrogênio (AN), acúmulo de fósforo (AP), acúmulo de potássio (AK), acúmulo de cálcio (ACa), acúmulo de magnésio (AMg), acúmulo de enxofre (AS) e acúmulo de molibdênio (AMo).

A parte aérea das coberturas vegetais foram coletadas antes da dessecação para determinação da matéria seca. Para análise do material coletado, as amostras foram levadas para a estufa de circulação forçada atingindo uma temperatura de 65°C , até obtenção da massa

constante, acondicionados em sacos de papel, sendo por fim, realizada a pesagem e conversão dos valores para $\text{kg} \cdot \text{ha}^{-1}$ (GOES, 2016).

Em seguida, uma amostra de cada parcela, devidamente identificada conforme o tratamento especificado, foi moída no moinho tipo Wiley, para determinação do teor nutricional de N, P, K, Ca, Mg, S realizadas de acordo com a metodologia proposta por Malavolta, Vitti, Oliveira (1997) e para determinação do teor de Mo, utilizou-se a metodologia proposta por Pessoa (1998). Já para determinação do acúmulo das variáveis nutricionais foi realizada a multiplicação dos teores obtidos na palhada pela produtividade de matéria seca.

Para estimativa da decomposição da matéria seca das coberturas vegetais, sorgo e milho, foram colocadas bolsas de nylon “*litter bags*” após a emergência da cultura da soja, referentes às parcelas com diferentes dosagens de nitrogênio, sendo as mesmas analisadas a cada 30 dias, de maneira análoga determinada para MS antes da dessecação, e por fim convertido para $\text{kg} \cdot \text{ha}^{-1}$ (GOES, 2016).

3.2 Método de modelagem *fuzzy*

A partir do experimento realizado por Goes (2016), no qual foram utilizadas coberturas vegetais, sorgo e milho sob diferentes doses de nitrogênio, buscou-se realizar uma modelagem *fuzzy* para estudar os efeitos do teor e acúmulo variáveis nutricionais e de produtividade da matéria seca em posterior uso de SPD.

Dessa forma, foi considerado o seguinte modelo matemática para representar a situação proposta agronomicamente por Goes (2016): $F : A \subset \mathbb{R} \rightarrow B \subset \mathbb{R}^{15}$, tal que $x \mapsto F(x) = (y_1, y_2, \dots, y_{15})$ sendo $\mathbb{R}$ o conjunto dos números reais; $A = [0, 120]$, quantidade de nitrogênio e $B = B_1 \times B_2 \times \dots \times B_{15}$, onde $B_i = [b_i^1, b_i^2]$ conjunto das variáveis de saída, no qual cada índice i está associado à uma variável de saída, com $1 \leq i \leq 15$, tal que $i \in \mathbb{N}$, sendo o intervalo B_i definido pelos valores extremos, mínimo e máximo, de cada variável de saída analisada, produtividade de matéria seca, o acúmulo dos nutrientes N, P, K, Ca, Mg, S e Mo e teor dos nutrientes N, P, K, Ca, Mg, S e Mo.

Como exemplo, segue que, se em “produtividade da matéria seca” tivermos $\min = 20 \text{ g}$ e $\max = 150 \text{ g}$, teremos o conjunto $B_1 = [y_1^1, y_1^2] = [20, 150]$.

Dessa forma, foi definido um processador de entrada (*fuzzyficador*) para elaboração do Sistema Baseado em Regras *Fuzzy* (SBRF), um conjunto de regras linguísticas, um método

de inferência *fuzzy* e um processador de saída (ou *defuzzyficador*), representado por um número real para variável de saída.


Para determinação das variáveis de entrada foram utilizadas as funções de pertinência do tipo triangular e Gaussiana, no qual segundo Leite et al. (2011), o uso das funções de pertinência do tipo gaussiana é facilitado devido a suavidade da curva sobre os dados analisados, sendo a função representada de acordo com Pimenta (2009), pela Equação (1), e seu comportamento gráfico ilustrado pela Figura 2:

$$\mu_A(x) = \exp\left(\frac{-(x-m)^2}{2\sigma^2}\right) \quad (1)$$

em que

- m : média;
- σ : desvio padrão.

Figura 2 - Características da função de pertinência Gaussiana.



Fonte: Benini e Meneguette Junior (2009).


Por sua vez, a utilização de funções de pertinência do tipo triangular, permite a manipulação e controle dos dados devido em grande parte pela facilidade computacional, além da obtenção dos menores valores de erros dos teste de ajustes dos modelos, uma vez que a função passa exatamente pela média do conjunto de dados (PEREIRA FILHO, 1999).

A função de pertinência do tipo triangular está representada na Equação (2), de acordo com Cremasco; Gabriel Filho e Cataneo (2010):

$$\mu_A(x) = \begin{cases} 0 & \text{se } x \leq a, \\ \frac{x-a}{b-a} & \text{se } a < x < b, \\ \frac{x-c}{b-c} & \text{se } b < x < c, \\ 0 & \text{se } x \geq c. \end{cases} \quad (2)$$

A Figura 3 ilustra graficamente a exemplificação da função de pertinência do tipo triangular.


Figura 3 - Exemplo de função de pertinência do tipo triangular.



Fonte: Silva Neto (2011)


Estão representadas nas Figura 4 e Figura 5, o SBRF das funções de pertinências do tipo Gaussiana e Triangular, respectivamente, referente à variável de entrada, (doses de nitrogênio) associadas às 15 variáveis de saídas por meio de regras do sistema *fuzzy*.

Figura 4 - Sistema *fuzzy* para avaliação das variáveis nutricionais da cobertura vegetal com funções de pertinência gaussianas de entrada.



Fonte: Elaborada pelo autor.

Figura 5 - Sistema *fuzzy* para avaliação das variáveis nutricionais da cobertura vegetal com funções de pertinência triangulares de entrada.



Fonte: Elaborada pelo autor.

Estes SBRF são representados pela função $F: A \subset \mathbb{R} \rightarrow \mathbb{R}^{15}$ tal que $F(x) = (f_1(x), f_2(x), \dots, f_{15}(x))$ no qual o domínio é o intervalo real representado pelas doses de nitrogênio ($A = [0, 120]$) e o contradomínio $\mathbb{R}^{15}$, representado pelas quinze variáveis de

saída analisadas: produtividade de matéria seca, teor de N, P, K, Ca, Mg, S e Mo e acúmulo de N, P, K, Ca, Mg, S e Mo.

3.2.1 Conjuntos *fuzzy* da variável de entrada

Para a formação do conjunto *fuzzy* de entrada, determinou-se primeiramente a função de pertinência do tipo triangular, desenvolvendo um SBRF, no qual o nitrogênio foi estabelecido como variável de entrada composto de 4 conjuntos *fuzzy* denominados C_1, C_2, C_3 e C_4 conforme as dosagens de 0, 40, 80 e 120 $\text{kg} \cdot \text{ha}^{-1}$ respectivamente, com a finalidade de realizar a conversão dos delimitadores da função de pertinência do tipo triangular para Gaussiana diretamente pelo *software* MATLAB®.

Os delimitadores da função de pertinência triangular foram classificados por $[p_{i-1}, p_i, p_{i+1}]$, sendo as extremidades p_0 e p_5 expressas por $p_0 = p_1 - (p_2 - p_1) = 2p_1 - p_2$ e $p_5 = p_4 + (p_4 - p_3) = 2p_4 - p_3$, conforme observado na Tabela 1.


Tabela 1 - Definição das funções de pertinência triangulares da variável de entrada.

Conjunto <i>Fuzzy</i>	Tipo	Delimitadores
C_1	Triangular	$[p_0, p_1, p_2]$
C_2	Triangular	$[p_1, p_2, p_3]$
C_3	Triangular	$[p_2, p_3, p_4]$
C_4	Triangular	$[p_3, p_4, p_5]$

Fonte: Elaborada pelo autor.


A Figura 6 apresenta as funções de pertinência da variável de entrada que foram adotadas na forma triangular e a Figura 7 apresenta as funções de pertinência que foram adotadas na forma Gaussiana, ambas com a variação do grau de pertinência $[0,1]$ em seus respectivos conjuntos *fuzzy*.

Figura 6 - Funções de pertinência triangulares da variável de entrada doses de nitrogênio.



Fonte: Elaborada pelo autor.

Figura 7 - Funções de pertinência gaussianas da variável de entrada doses de nitrogênio.



Fonte: Elaborada pelo autor.

O conjunto de variáveis de entrada foi definido a partir das diferentes dosagens de nitrogênio utilizado durante o experimento, definido por C_i , para $i = 1, 2, 3, 4$ ao passo de 0, 40, 80 e 120 $\text{kg} \cdot \text{ha}^{-1}$ utilizados de nitrogênio respectivamente.

A Tabela 2 demonstra os conjuntos *fuzzy* definidos com seus delimitadores para a variável de entrada do tipo triangular.

Tabela 2 - Delimitadores da função de pertinência triangular da variável de entrada.

Conjunto Fuzzy	Tipo	Delimitadores
C_1	Triangular	$[-40, 0, 40]$
C_2	Triangular	$[0, 40, 80]$
C_3	Triangular	$[40, 80, 120]$
C_4	Triangular	$[80, 120, 160]$

Fonte: Elaborada pelo autor.

Para a determinação dos delimitadores das funções de pertinência do tipo Gaussiana, realizou-se por meio do *software* MATLAB, a conversão dos parâmetros $[a, b, c]$ triangular, com $b - a = c - b$, para os parâmetros $[\sigma, m]$ gaussianos. Observe que se $b - a = c - b = \Delta$, então os parâmetros serão $[b - \Delta, b, b + \Delta]$ e a Equação (3) será definida por:

$$\sigma = \frac{\Delta}{2 \times \sqrt{-2 \cdot \ln(0,5)}} \quad (3)$$

Apresenta-se na Tabela 3, os delimitadores do tipo gaussiano para as funções de pertinência da variável de entrada.

Tabela 3 - Delimitadores da função de pertinência gaussiana da variável de entrada.

Conjunto Fuzzy	Tipo	Delimitadores
C_1	Gaussiana	$[16, 99 \ 0]$
C_2	Gaussiana	$[16, 99 \ 40]$
C_3	Gaussiana	$[16, 99 \ 80]$
C_4	Gaussiana	$[16, 99 \ 120]$

Fonte: Elaborada pelo autor.

3.2.2 Método de construção dos conjuntos *fuzzy* das variáveis de saída

Utilizou-se a para a construção dos conjuntos *fuzzy* de saída, função de pertinência do tipo triangular, pois, de acordo com Santos (2015), a utilização da função de pertinência do tipo Gaussiana para as variáveis de saídas, gera falta de simetria dos dados. Por outro lado, a função de pertinência triangular para variáveis de saída, facilita-se pelo uso computacional e manipulação dos dados, além dos menores erros estatísticos, uma vez que a função passa pelas médias dos dados (PEREIRA FILHO, 1999).

Os conjuntos *fuzzy* das variáveis de saída foram definidos por 4 delimitadores com base nas funções de pertinência da forma triangular, com a variação do grau de pertinência estabelecido no intervalo $[0,1]$, do mesmo modo definido para variável de entrada.

A definição dos limitadores das funções e pertinência foram baseados conforme a metodologia proposta de Boso (2018), com distância de 1 unidade do desvio padrão da média para as diferentes dosagens de nitrogênio, definidas na Tabela 4.

Tabela 4 - Características dos delimitadores para a variável de saída do sistema baseado em regras *fuzzy*, com funções de pertinência triangular.

Conjunto <i>fuzzy</i>	Tipo	Delimitadores
C_1	Triangular	$[p_1 - \sigma_1, p_1, p_1 + \sigma_1]$
C_2	Triangular	$[p_2 - \sigma_2, p_2, p_2 + \sigma_2]$
C_3	Triangular	$[p_3 - \sigma_3, p_3, p_3 + \sigma_3]$
C_4	Triangular	$[p_4 - \sigma_4, p_4, p_4 + \sigma_4]$

Fonte: Elaborada pelo autor.

3.2.3 Método de elaboração da base de regras

A elaboração para a base da regras das funções de pertinência dos conjuntos *fuzzy* de saída, ocorreu de maneira semelhante nos trabalhos desenvolvidos por Cremasco (2008), Gabriel Filho et al. (2011), Putti et al. (2017) e Boso (2018), no qual os valores da média da variável de saída y_i^j está associada ao conjunto *fuzzy* de entrada C_i , de modo não necessariamente ordenado, $y_1^j \leq y_2^j \leq y_3^j \leq y_4^j$. Sendo assim, foi realizado a reordenação dos valores y_i^j para $y_{n_i}^j$ de modo que $y_{n_1}^j \leq y_{n_2}^j \leq y_{n_3}^j \leq y_{n_4}^j$, e $n_i \in \{1, 2, 3, 4\}$, $i = 1, 2, 3, 4$ e $1 \leq j \leq 15$, associado ao conjunto de saída C_{n_i} .

A Tabela 5 descreve o método utilizado para o desenvolvimento do sistema de regras *fuzzy* de associação entre as variáveis de entrada e variáveis de saída no presente trabalho.

Tabela 5 - Associação do conjunto *fuzzy* de entrada com o conjunto *fuzzy* de saída.

Conjunto <i>fuzzy</i> de entrada	Valor associado na saída	Ordenação dos valores de saída	Conjunto <i>fuzzy</i> de saída associada
C_1	y_1^j	$y_{n_1}^j$	C_{n_1}
C_2	y_2^j	$y_{n_2}^j$	C_{n_2}
C_3	y_3^j	$y_{n_3}^j$	C_{n_3}
C_4	y_4^j	$y_{n_4}^j$	C_{n_4}

Fonte: Elaborada pelo autor.

3.2.4 Método de inferência e *defuzzificação*

Foi utilizado no presente trabalho o método de inferência abordados por Mamdani e Assilian (1975), conhecido como Método de Mamdani, amplamente utilizado na literatura e classificado como controladores universais (CAO; REES; FENG, 2001).

Na *defuzzificação*, a atribuição associada às variáveis de saída inferida pelas bases de regras, foram calculadas com base no centro de gravidade, expresso pela seguinte expressão no qual m_k representa o centro do conjunto *fuzzy* B_k (BELARBI et al., 2005):

$$u = \frac{\sum_{k=1}^m m_k \mu_{B_k}(u)}{\sum_{k=1}^m \mu_{B_k}(u)} \quad (4)$$

Para determinação SBRF, foram utilizadas planilhas eletrônicas (Microsoft Excel) e o *software* MATLAB®, licenciado para uso pela Faculdade de Ciências e Engenharia – FCE/UNESP, Campus de Tupã. Para elaboração gráfica e funções de pertinência, foi utilizada a ferramenta *Fuzzy Logic Toolbox* do *software* MATLAB®.

3.3 Análise de regressão

Foram realizadas juntamente com as curvas das modelagens *fuzzy*, as curvas referentes ao modelo de regressão polinomial em relação às 15 variáveis analisadas no experimento com a finalidade de comparar os diferentes modelos gerados por meio de parâmetros estatísticos.

Sendo assim, a análise de regressão é um método utilizado para analisar o comportamento e interações entre variáveis, dependentes (saída) e independentes (entrada) (TAMUS, 2013), obtendo como resultado um modelo ou equação, que prediz o grau de

relacionamento entre as variáveis, sendo o modelo classificado de acordo com a quantidade de variáveis de respostas (BRAUN; ALTAN; BECK, 2014).

A análise dos modelos de regressão é um processo de interação entre as variáveis, no qual as respostas são utilizadas para diagnosticar as variáveis de entrada, validando ou refutando o relacionamento entre as mesmas (FUMO; RAFAEL BISWAS, 2015). Para tanto, existem vários indicadores de qualidade de modelos de regressão, condizendo ou refutando a interação entre as variáveis.

3.4 Métodos de análise do grau de ajuste do modelo

Para comparação dos resultados, foram também realizados modelos matemáticos com regressão polinomial de grau 2, muito aceitos na área agrônômica. Possibilitando assim, na verificação da adequação do modelo *fuzzy* frente à tais modelos de regressão. Para tanto, foram aplicados os seguintes índices e testes de qualidade para ambos os modelos.

3.4.1 Coeficiente de determinação (R^2)

Para avaliar um bom ajuste de modelo de regressão, é comum realizar o cálculo do coeficiente de determinação (R^2), que representa o valor percentual de variáveis explicadas pelo modelo Rousson e Goşoni (2007). O seu cálculo é representado, de acordo com Ostertagová (2012) pela seguinte Equação (5):

$$R^2 = 1 - \frac{\sum_{i=1}^{n_i} (y_i - \hat{y}_i)^2}{\sum_{i=1}^{n_i} (y_i - \bar{y}_i)^2} \quad (5)$$

em que:

- n_i : número de observações;
- y_i : valor observado;
- $\hat{y}_i$: valor estimado de y_i ;
- $\bar{y}_i$: média das observações.

No entanto, o coeficiente de determinação pode ser facilmente manipulado, aumentado, com a adição de outros parâmetros, não significando necessariamente num melhor ajuste do modelo aos dados, sendo assim, é comum o cálculo de outros testes de ajustes de modelos para prever a correlação entre os dados (DEMING; MORGAN, 1993).

3.4.2 Raiz do erro quadrático médio (*RMSE*)

Os resíduos de um ajuste de modelo, representam o quão distantes os dados encontram-se da linha de regressão. O *RMSE*, é um parâmetro que informa a distribuição dos dados em relação a melhor linha de ajuste de regressão (BARNSTON, 1992), e é expressado de forma:

$$RMSE = \sqrt{\frac{1}{N} \times \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (6)$$

em que:

- N : tamanho da amostra;
- y_i : valor observado;
- $\hat{y}_i$: valor estimado de y_i .

3.4.3 Erro absoluto médio (*MAE*)

O erro absoluto médio consiste em calcular sobre a média de um conjunto de dados, a média de seus desvios absolutos. Trata-se de uma medida mais robusta em relação ao desvio padrão, funcionando com uma ferramenta alternativa (ZHAO; MENG; YANG, 2015). De acordo com Meskini-Vishkaee e Davatgar (2018), o erro absoluto médio é dado por:

$$MAE = \frac{1}{N} \times \sum_{i=1}^N |\hat{y}_i - y_i| \quad (7)$$

em que:

- N : tamanho da amostra;
- y_i : valor observado;
- $\hat{y}_i$: valor estimado de y_i .

3.5 Intervalo de confiança

O intervalo de confiança, consiste na determinação de uma amplitude intervalar baseada em amostras para valores de uma população desconhecida com graus de confiabilidade (LINTON, 2017), de forma a obter um parâmetro de uma amostra representativa de um população (CAYCHO-RODRÍGUEZ, 2018).

O grau de confiança é definido de modo que há uma maior certeza de inclusão aleatoriamente dos dados pertencer ao intervalo de confiança definido (CAYCHO-RODRÍGUEZ, 2018), sendo estimado para quase todas as pesquisas científicas uma estimativa

de intervalo de confiança de 95% (HUBIG; MUGGENTHALER; MALL, 2015). De acordo com Linton (2017), o intervalo de confiança é estimado da forma:

$$IC = \bar{x} \pm t_{\alpha/2} \times \frac{\sigma}{\sqrt{n}} \quad (8)$$

em que:

- $\bar{x}$: média amostral;
- $t_{\alpha/2}$: coeficiente de confiança;
- α : nível de confiança;
- σ : desvio padrão da população;
- n : tamanho amostral.

Para determinação do intervalo de confiança para nível de 95%, assume-se o valor de $t_{\alpha/2} = 1,96$. Sendo assim:

$$IC = \left(\bar{x} - 1,96 \times \frac{\sigma}{\sqrt{n}}, \bar{x} + 1,96 \times \frac{\sigma}{\sqrt{n}} \right) \quad (9)$$

3.6 Análise multivariada

Realizou-se a análise multivariada entre todas as variáveis estudadas determinando do grau de relacionamento entre as mesmas, a fim de comparar a similaridade entre as variáveis sobre o comportamento em relação aos diferentes níveis de nitrogênio utilizado para adubação.

A análise multivariada é um método utilizado para extrair informações sobre conjuntos com grande quantidade de dados (YAMANISHI et al., 2018) de modo a entender a influência de múltiplas variáveis $\times$ simultaneamente em y (GRECH; CALLEJA, 2018). Sendo assim, a técnica de análise multivariada consiste no processamento de um conjunto de variáveis de entrada formando um conjunto reduzido de modo a filtrar as redundâncias e ruídos entre elas (MUÑOZ-ROMERO; GÓMEZ-VERDEJO; PARRADO-HERNÁNDEZ, 2017).


Dessa forma, o objetivo é particionar grupos internamente com características semelhantes e externamente distintas, sendo a classificação realizada com base no grau de similaridade e dissimilaridade entre as variáveis (MISHRA; DATTA-GUPTA, 2018).

O agrupamento de um conjunto de dados espalhados em um espaço N-dimensional tem sido amplamente aplicado em áreas científicas e de engenharia (XU; WUNSCHII, 2005; HAMMOU; HAMMOUCHE; POSTAIRE, 2018), de modo que a extração dos dados é realizada por meio de uma função de densidade de probabilidade multimodal com base em

graus de similaridade entre os conjuntos de dados agrupados (HAMMOU; HAMMOUCHE; POSTAIRE, 2018).

Sendo assim, é estabelecida uma hierarquia entre os dados, originando os *clusters*, para a formação e desenho do dendrograma, a etapa de aglomeração (FORINA et al., 2007), tal como ilustra o exemplo da Figura 8.

Figura 8 - Exemplo da análise de dendrograma.



Fonte: Minitab (2018)

A similaridade entre as variáveis é dada em razão da distância entre as mesmas, no qual estão diretamente relacionadas à sua correlação. Ou seja, a distância entre duas variáveis é dada em função de sua subtração de uma unidade, no qual, para correlação de 0,879 a distância será representada por $1 - 0,879 = 0,121$, dessa forma, quanto maior a correlação entre as variáveis, menor será suas distâncias.

4 RESULTADOS E DISCUSSÃO


Os resultados foram descritos conforme as análises realizadas dos testes de qualidade do modelo matemático e de ajustes da curva de regressão, em relação ao comportamento das variáveis nutricionais das coberturas vegetais, sorgo e milho, sob diferentes doses de nitrogênio para posterior plantio direto.

4.1 Intervalo de confiança das variáveis das coberturas vegetais

4.1.1 Produtividade de matéria seca e teor de nutrientes

O comportamento da matéria seca (MS) e das variáveis nutricionais em função as dosagens de nitrogênio (0, 40, 80 e 120 kg · ha⁻¹) aplicada nas coberturas vegetais de sorgo e milho, é demonstrado por meio da análise dos gráficos de intervalos de confiança. A análise da produtividade da matéria seca (kg · ha⁻¹) é identificada na Figura 9.

Figura 9 - Produtividade da matéria seca (MS) das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio (kg · ha⁻¹).




Fonte: Elaborada pelo autor.

As culturas de coberturas sorgo e milho, obtiveram comportamentos semelhantes de produtividade de matéria seca (MS) na ausência de nitrogênio, porém sob efeito das diferentes doses, a cultura do sorgo obteve o melhor rendimento. Pode-se atribuir tal comportamento à fatores climáticos expostos durante o experimento, seguindo de uma período de seca, no qual a cobertura vegetal de milho apresentou sensibilidade sob condições de

estresse hídrico reduzindo o acúmulo de matéria seca, conforme relatado em Goes (2016), fato não observado na cultura do sorgo.

O comportamento dos teores de N, P e K das coberturas vegetais sob diferentes doses de nitrogênio (0, 40, 80 e 120 kg · ha⁻¹) estão apresentados na Figura 10.

Figura 10 - Teor de N, P e K das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio (kg · ha⁻¹) .



Fonte: Elaborada pelo autor.


Para os diferentes níveis de N aplicado nas coberturas vegetais, a cultura do milho apresentou em média valores superiores de TN em relação a cultura do sorgo, porém, sobre o comportamento dos dados, houve um desvio padrão maior para o intervalo de confiança adotado de 95%.

Em relação ao TP, a cobertura vegetal de milho obteve uma leve superioridade em relação ao sorgo, e assim como no TN, o desvio padrão foi superior em relação a cultura do sorgo para o intervalo de confiança de 95%.

Para o TK, a cobertura de milho apresentou grande variação dos dados amostrados, principalmente na ausência do N, no entanto, em média obteve os melhores rendimentos quando comparado com a cultura de cobertura de sorgo.

O TCa para as coberturas vegetais de milho e sorgo está apresentado na Figura 11.

Figura 11 - Teor de cálcio das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$).




Fonte: Elaborada pelo autor.

O TCa, para ambas coberturas vegetais, o comportamento foi semelhante dentro do intervalo de confiança de 95%. Segundo Goes (2016), o TCa pode ser reduzido com o aumento da produção de matéria seca, devido aos efeitos de diluição, fato não ocorrido no experimento.

Na Figura 12, há a análise do efeito das doses de N para o Mg das coberturas vegetais de milho e sorgo.

Figura 12 - TMg das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$).




Fonte: Elaborada pelo autor.

O Mg, para a cobertura vegetal de milho apresentou maior teor para dosagem de $120 \text{ kg} \cdot \text{ha}^{-1}$ e menor teor para o nível de $80 \text{ kg} \cdot \text{ha}^{-1}$, porém com uma discrepância significativa dos dados para o intervalo de confiança de 95%. Contudo, pode-se atribuir um comportamento semelhante do TMg na palhada para ambas as coberturas, que segundo Goes (2016), deve estar relacionado à semelhanças entre as espécies em relação à exigência de nutriente Mg.

A relação entre os diferentes níveis de nitrogênio e os nutrientes S e Mo, estão apresentados na Figura 13.

Figura 13 - TS e TMo das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$).




Fonte: Elaborada pelo autor.

O milho apresentou maior TS em relação a cultura do sorgo, podendo atribuir tal fato ao sinergismo com o P, o qual obteve também maior teor do nutriente (GOES, 2016).

4.1.2 Acúmulo de nutrientes

O comportamento do acúmulo de nitrogênio (N), fósforo (P) e potássio (K) das coberturas vegetais sob diferentes doses de nitrogênio ($0, 40, 80, 120 \text{ kg} \cdot \text{ha}^{-1}$) estão apresentados na Figura 14.

Figura 14 - Acúmulo de nitrogênio (N), fósforo (P) e potássio (K) das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$).




Fonte: Elaborada pelo autor.

A cultura do sorgo sob efeito da adubação nitrogenada, obteve maior acúmulo dos teores N, P e K em relação a cultura do milho, porém sem a presença da adubação nitrogenada, o milho obteve melhor rendimento, comparado ao sorgo. Tal comportamento pode-se atribuir ao fato da cultura do sorgo apresentar maior produtividade de matéria seca sob efeitos das doses de nitrogênio.

Os valores sobre o acúmulo do nutriente Ca e Mg das coberturas vegetais estão representados na Figura 15.

Figura 15 - ACa e AMg das coberturas vegetais de milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$).




Fonte: Elaborada pelo autor.

Tanto para os efeitos do ACa quanto de AMg, notou-se a maior presença na cobertura vegetal de sorgo quando realizada a adubação nitrogenada em comparação ao milho. No entanto, na ausência do nitrogênio, o ACa e AMg do sorgo obtiveram rendimentos semelhantes a cultura do milho, sendo a mesma respondendo de maneira indiferente à diferentes doses da adubação nitrogenada.

Na Figura 16 seguinte, verifica-se o a relação entre os níveis de nitrogênio para os nutrientes, S e Mo.

Figura 16 - AS e AMo das coberturas vegetais, milho e sorgo, sob diferentes doses de nitrogênio ($\text{kg} \cdot \text{ha}^{-1}$).



Fonte: Elaborada pelo autor.


A cultura de cobertura vegetal de sorgo apresentou os melhores resultados em relação ao acúmulo dos nutrientes enxofre (S) e molibdênio (Mo) quando da presença do nitrogênio na palhada.

4.2 Análise multivariada

Foi realizado para cada cobertura vegetal, do sorgo e do milho a análise multivariada entre as variáveis nutricionais, juntamente com a correlação de Pearson para significância de 5%.

A Figura 17 mostra-nos a informação sobre a similaridade entre as variáveis analisadas para a cultura de cobertura vegetal do milho por meio do dendrograma.

Figura 17 - Dendrograma das variáveis da cobertura vegetal de milho.



Fonte: Elaborada pelo autor.

Para análise do dendrograma, a cada passo da amalgamação, há formação de novos agrupados com comportamentos similares, à medida que ocorre o aumento do número de agrupados, decresce o grau de similaridade entre as variáveis analisadas. A exemplo, no dendrograma das variáveis do milho, para um grau de similaridade de 87%, há a formação de 12 grupos e já para o grau de 76% de similaridade, ocorre a formação de oito grupos.

Os passos de amalgamação estão apresentados na Tabela 6.

Tabela 6 - Passos de amalgamação do milheto.

Passo	Agrupados	Similaridade	Distância
1	14	96,4800	0,07040
2	13	93,5395	0,12921
3	12	87,9017	0,24197
4	11	83,1144	0,33771
5	10	79,0082	0,41984
6	9	77,7422	0,44516
7	8	76,5488	0,46902
8	7	72,4837	0,55033
9	6	71,0386	0,57923
10	5	58,8714	0,82257
11	4	58,7444	0,82511
12	3	55,2058	0,89588
13	2	17,4896	1,65021
14	1	10,4646	1,79071

Fonte: Elaborada pelo autor.

No dendrograma representado pela Figura 17, é possível notar a similaridade da MS com as variáveis de AP, AS e AN, com as quais possuem coeficiente de correlação de Pearson de 0,93; 0,87 e 0,88 respectivamente, conforme apresentados na Tabela 7 assim como também se nota o afastamento da MS em relação ao TMo, com coeficiente de correlação de Pearson de -0,65.

A correlação completa de Pearson entre as variáveis analisadas de MS, TN, TP, TK, TCa, TMg, TS, TMo e AN, AP, AK, ACa, AMg, AS, AMo estão representadas na Tabela 7 para níveis de 5% de significância.


Tabela 7 - Correlação de Pearson entre as variáveis para a cobertura vegetal milheto com nível de significância de 5%.

	MS	TN	TP	TK	TCa	TMg	TS	TMo	AN	AP	AK	ACa	AMg	AS
TN	-													
TP	-	-0,75												
TK	-	-	-											
TCa	-	-	-	-										
TMg	-	-	-	-	-									
TS	-	-	-	-	-	-								
TMo	-0,65	-	-	-	-	-	-							
AN	0,88	-	-	-	-	-	-	-0,79						
AP	0,93	-	-	-	-	-	-	-	0,68					
AK	0,72	-	-	-	-0,65	-0,59	-	-	-	0,70				
ACa	0,79	-	-	-	-	-	-	-	0,70	0,75	-			
AMg	0,65	-	-	-	-	-	-	-	-	0,69	-	0,75		
AS	0,87	-	-	-	-	-	-	-	0,66	0,90	0,63	0,74	-	
AMo	-	-0,65	-	-	-	-	-	-	-	0,64	0,58	-	-	-

Legenda: Produtividade de matéria seca (MS), teor de nitrogênio (TN), teor de fósforo (TP), teor de potássio (TK), teor de cálcio (TCa), teor de magnésio (TMg), acúmulo de nitrogênio (AN), acúmulo de fósforo (AP), acúmulo de potássio (AK), acúmulo de cálcio (ACa), acúmulo de magnésio (AMg), acúmulo de molibdênio (AMo) e acúmulo de enxofre (AS). Fonte: Elaborada pelo autor.

A matéria seca teve correlação positiva com 6 variáveis de acúmulos, N, P, K, Ca, Mg e S, e correlação negativa com o TMo, à medida que ocorre o aumento da MS, há um decréscimo do TMo na cobertura do milheto. A correlação negativa foi observada no AK em relação ao TCa e TMg. O AP obteve correlação positiva com os AK, ACa, AMg, AS e AMo. Por sua vez o TN apresentou correlação negativa com o TP e AMo. Por sua vez, o maior grau de correlação ocorreu entre MS e AP, com valor de 0,93.

A informação sobre o nível de similaridade entre as variáveis analisadas para a cultura do sorgo é apresentada no dendrograma da Figura 18.

Figura 18 - Dendrograma das variáveis da cobertura vegetal de sorgo.

Fonte: Elaborado pelo autor.

É possível identificar a formação de 12 grupos com similaridade de 98,6%, com um número maior de grupos com características homogêneas. Já, ao passo de similaridade de 89% são originados 8 grupos com comportamentos semelhantes, conforme é possível observar na Tabela 8 com as informações dos passos da amalgamação.

Tabela 8. Passos de amalgamação do sorgo.

Passo	Agrupados	Similaridade	Distância
1	14	99,5470	0,00906
2	13	98,8108	0,02378
3	12	98,6565	0,02687
4	11	97,7112	0,04578
5	10	96,3081	0,07384
6	9	94,9812	0,10038
7	8	89,3518	0,21296
8	7	86,8245	0,26351
9	6	77,2007	0,45599
10	5	76,0908	0,47818
11	4	55,3185	0,89363
12	3	50,0392	0,99922
13	2	26,8440	1,46312
14	1	12,2128	1,75574

Fonte: Elaborada pelo autor.

Da mesma maneira como ocorreu na cultura do milho, é possível identificar uma forte correlação da MS com as variáveis de AP, AK e AMg, com os coeficientes de correlação de Pearson de 0,99; 0,98 e 0,96 respectivamente. Observa-se a matriz de correção de Pearson na Tabela 9.

Tabela 9 - Correlação de Pearson entre as variáveis para a cobertura vegetal sorgo com nível de significância de 5%.

	MS	TN	TP	TK	TCa	TMg	TS	TMo	AN	AP	AK	ACa	AMg	AS
TN	-													
TP	-	-												
TK	0,61	-	-											
TCa	-	-	-	-										
TMg	-	-	-	-	-									
TS	-	0,73	-	-	-	-0,76								
TMo	-	-	-	-	-	-	-0,71							
AN	0,94	-	-	-	-	-	-	-						
AP	0,99	-	-	0,61	-	-	-	-	0,91					
AK	0,98	-	-	0,73	-	-	-	-	0,92	0,97				
ACa	0,88	-	-	-	-	-	-	-	0,90	0,85	0,86			
AMg	0,96	-	-	0,61	-	-	-	-	0,86	0,95	0,95	0,90		
AS	0,96	-	-	0,57	-	-	-	-	0,97	0,94	0,94	0,90	0,87	
AMo	0,95	-	-	-	-	-	-	-	0,84	0,95	0,92	0,78	0,94	0,86

Legenda: MS (produtividade de matéria seca); TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio); AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.

Desse modo, com base na tabela de correlação de Pearson, verifica-se a correlação positiva entre a MS e o TK, como também com os acúmulos dos demais nutrientes. É possível observar também a correlação positiva entre todos os acúmulos de nutrientes N, P, K, Ca, Mg, S e Mo. Por sua vez, há correlação negativa entre o TS com os TMg e TMo, com valores de -0,76 e -0,71, respectivamente. O maior grau de correlação é notado entre MS e AP com valor de 0,99.

4.3 Modelagem fuzzy das coberturas vegetais

Foi realizada nesta seção a modelagem *fuzzy* para a produtividade da matéria seca em relação às diferentes doses de nitrogênio das coberturas vegetais de milho e sorgo (4.3.1), e as modelagens das demais variáveis analisadas: teor de N, P, K, Ca, Mg, S e Mo e acúmulo de N, P, K, Ca, Mg, S e Mo em relação aos diferentes níveis de nitrogênio para as culturas de coberturas vegetais de milho (4.3.2) e sorgo (4.3.3).


4.3.1 Modelagem *fuzzy* da produtividade de matéria seca do milho e sorgo

Após a definição das variáveis de entrada do experimento realizado por Goes (2016), determinou-se a base de regras para a realização e validação do modelo *fuzzy* para a produtividade de matéria seca das coberturas vegetais de milho e sorgo em relação aos diferentes níveis de nitrogênio (0, 40, 80 e 120 kg · ha⁻¹).

Adotou-se a função para o conjunto das variáveis de entrada as funções de pertinência do tipo gaussiana; e para o conjunto da variável de saída, adotou-se a função de pertinência triangular.


Apresenta-se nas Figura 19 e Figura 20 as funções de pertinência da produtividade de matéria seca das culturas de coberturas de milho e sorgo respectivamente; e nas Tabela 10 e Tabela 11, são apresentados os valores dos delimitadores das funções de milho e sorgo.

Figura 19 - Função de pertinência da produtividade de matéria seca do milho.



Fonte: Elaborada pelo autor.

Figura 20 - Função de pertinência da produtividade de matéria seca do sorgo.



Fonte: Elaborada pelo autor.

Tabela 10 - Delimitadores das funções de pertinência da variável de saída produtividade de matéria seca para a cobertura vegetal de milho.

Conjunto <i>fuzzy</i>	Tipo	Delimitadores
C_1	Triangular	[5294,118 5882,353 6470,588]
C_2	Triangular	[5521,676 6078,431 6635,187]
C_3	Triangular	[5588,235 6764,706 7941,176]
C_4	Triangular	[7941,176 8235,294 8529,412]

Fonte: Elaborada pelo autor.

Tabela 11 - Delimitadores das funções de pertinência da variável de saída produtividade de matéria seca para a cobertura vegetal de sorgo.

Conjunto <i>fuzzy</i>	Tipo	Delimitadores
C_1	Triangular	[6176,471 6250 6323,529]
C_2	Triangular	[10612,024 11862,745 13113,466]
C_3	Triangular	[13970,588 15808,824 17647,059]
C_4	Triangular	[14412,41 16274,51 18136,61]

Fonte: Elaborada pelo autor.

A Tabela 12 apresenta a base de regra para os modelos *fuzzy* na variável de produtividade de matéria seca para as coberturas vegetais de milho e sorgo.

Tabela 12 - Base de regras do sistema *fuzzy* para a variável produtividade de matéria seca.

Regra	Conjunto de Entrada	Saída Milho	Saída Sorgo
1	1	1	1
2	2	3	3
3	3	4	4
4	4	2	2

Fonte: Elaborada pelo autor.

A validação dos modelos foi realizada com base na comparação com o modelo de regressão polinomial de grau dois e apresentação dos testes de ajustes de modelos, do coeficiente de determinação (R^2), desvio do quadrado médio da raiz ($RMSE$) e do erro quadrado médio da raiz (MAE), com o objetivo de verificar qual modelo exibe o melhor comportamento, frente à realidade agrônômica dos fatos para a produtividade da matéria seca. Apresenta-se na Tabela 13 a validação do modelo para a variável de produtividade de matéria seca.

Tabela 13 - Validação do modelo *fuzzy* nas funções triangulares e gaussianas das coberturas vegetais de milho e sorgo.

	Índices	Fuzzy triangular	Fuzzy gaussiana	Regressão polinomial
Milheto	Equação	-	-	$y = -0,475x^2 + 62,132x + 5671,569$
	R^2	0,706 (p=0,0006)	0,703 (p=0,0007)	0,522 (p=0,008)
	RMSE	595,341	655,997	759,329
	MAE	449,347	532,350	611,111
Sorgo	Equação	-	-	$y = -2,180x^2 + 305,210x + 6460,78$
	R^2	0,920 (p=0)	0,507 (p=0,009)	0,907 (p=0)
	RMSE	1184,359	3802,318	1274,908
	MAE	906,878	2636,997	1067,926

Legenda: R^2 = coeficiente de determinação; RMSE = desvio do quadrado médio da raiz; MAE = erro quadrado médio da raiz. Fonte: Elaborada pelo autor.

Analisando os resultados da Tabela 13, verifica-se que os menores valores de erros de ajustes são obtidos pela modelagem *fuzzy* do tipo triangular, assim como também o maior valor de coeficiente de determinação (R^2). Sua precisão é confirmada, devida à passagem da curva do modelo exatamente pelos pontos médios dos conjuntos (0, 40, 80 e 120), fato que não ocorre para as funções *fuzzy* do tipo gaussiana e as funções originadas pelos modelos de regressão polinomial.

Entretanto, vale ressaltar, que para o modelo *fuzzy* do tipo gaussiano ocorre a suavização das curvas geradas, fazendo com que seu comportamento represente de melhor maneira graficamente os experimentos agronômicos, conforme pode ser observado na Figura 21. A exemplo o comportamento da variável saída da produtividade de matéria seca para a cobertura vegetal de sorgo, para a qual a curva da modelagem *fuzzy* gaussiana, comportou-se de igual maneira a curva originada da modelagem *fuzzy* triangular, mesmo em decorrência dos valores dos parâmetros de validação de modelos serem inferiores aos parâmetros da curva de regressão polinomial, ressaltando no seu comportamento mais condizente com a realidade dos experimentos agronômicos.

Dessa forma, a modelagem *fuzzy* das variáveis de entrada para as funções de pertinência do tipo triangular, servem como base dos modelos gaussianos.


Todavia, o objetivo das curvas de modelagem *fuzzy*, é realizar previsões de fenômenos não ocorridos com maior grau de exatidão com base em dados amostrais, e não apenas na aferição dos melhores parâmetros estatísticos de validação de modelos.

Nesse sentido, estudos científicos comprovaram a eficiência da modelagem *fuzzy* em relação aos modelos de regressão polinomial para interpretação de fenômenos agronômicos,

como foi verificado no trabalho de Putti (2015) para determinação da produtividade da cultura da alface.

Verifica-se na Figura 21 o comportamento gráfico das funções *fuzzy* triangular e gaussiana, e de regressão polinomial de grau dois para a variável da produtividade de matéria seca das coberturas vegetais de milho e sorgo.

Figura 21 - Comparação entre as funções (*fuzzy* triangular, *fuzzy* gaussiana, polinomial) para a variável de saída produtividade de matéria seca.



Fonte: Elaborada pelo autor.

Analisando as funções de repostas das coberturas vegetais, verifica-se uma semelhança no comportamento de ambas as culturas na ausência da adubação nitrogenada, aferindo valores médios próximo de $6.000 \text{ kg} \cdot \text{ha}^{-1}$, entretanto, para a presença de nitrogênio nos valores de 40, 80 e $120 \text{ kg} \cdot \text{ha}^{-1}$, a cultura do sorgo produziu a maior quantidade de matéria seca, aferindo maior produtividade de acordo com os modelos gerados na quantidade entre 40 e $80 \text{ kg} \cdot \text{ha}^{-1}$ de nitrogênio.

A baixa produtividade de matéria seca para a cultura do milho é atribuída, segundo Goes (2016), às baixas temperaturas durante os estádios iniciais de desenvolvimento da cultura, aferindo valores menores à 20°C no período. Resultados semelhantes foram constatados por Maman et al. (2003), no qual verificou-se baixa produtividade de biomassa em relação ao sorgo para temperaturas amenas. Por outro lado, o sorgo não apresentou queda de produtividade quando submetido às mesmas condições climáticas.

Para complementação da discussão referentes aos resultados apresentados pelas curvas das modelagens *fuzzy* das coberturas vegetais para a produtividade de matéria seca, encontra-se na Tabela 14, a análise de variância e teste de Tukey realizado por Goes (2016).

Tabela 14 - Análise de variância e teste Tukey das coberturas vegetais para a produtividade de matéria seca em relação a doses de nitrogênio.

Tratamentos	Ano 2013/14			
	1 DAE	31 DAE	61 DAE	91 DAE
Coberturas Vegetais (kg · ha⁻¹) - C				
Milheto	6740,2	5441,2	3713,2	2794,1
Sorgo	12549,0	9963,2	7022,5	5735,3
DMS	1336,9	1109,3	1398,9	1102,2
Doses de N (kg · ha⁻¹) - N				
0	6066,2	5441,2	4852,9	2573,5
40	11286,6	8088,2	6029,4	4852,9
80	12254,9	9485,3	7130,3	6102,9
120	8970,6	7794,1	4842,7	3529,4
Teste F				
C	144,46**	76,28**	25,68**	32,68**
N	32,49**	10,50**	5,84**	8,97**
C × N	16,07**	12,20**	4,94*	7,42**
CV (%)	12,27	16,46	29,79	29,55

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Verifica-se significância estatística entre as interações das coberturas vegetais e as doses de nitrogênio utilizadas para adubação. Para tanto, realizou-se a análise de variância, a fim de realizar o desdobramento da interação entre as coberturas vegetais e as doses de nitrogênio referente a produtividade de matéria seca, apresentado na Tabela 15.

Tabela 15 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de matéria seca.

Coberturas Vegetais	Doses de N (kg · ha ⁻¹)			
	0	40	80	120
Milheto	5882,3a	6764,7b	8235,3b	6078,4b
Sorgo	6250,0a	15808,8a	16274,5a	11862,7a
Teste F	0,14 ^{ns}	87,55**	69,17**	35,81**

DMS (C d. N): 2070,9 kg · ha⁻¹

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Analisando a interação entre as coberturas vegetais e as doses de nitrogênio, verifica-se que na ausência do nitrogênio, as coberturas vegetais não diferem estatisticamente, com médias de 5.882,3 kg · ha⁻¹ e 6.250,0 kg · ha⁻¹, para milheto e sorgo, respectivamente, fato

observado pelos gráficos das curvas de modelagens. No entanto, a medida em que ocorre a incrementação do nitrogênio nas coberturas vegetais, nota-se diferença estatisticamente significativa entre os resultados apurados pelas coberturas vegetais referente ao acúmulo de matéria seca, com a cultura de cobertura vegetal de sorgo expressando valores superiores ao da cultura de cobertura de milho.


4.3.2 Modelagem das variáveis da cobertura vegetal do milho





Conforme os dados do experimento realizado por Goes (2016), assim definidas as variáveis de entrada, foi possível determinar a base de regras e realizar a validação dos modelos *fuzzy* para as 14 demais variáveis analisadas em relação aos diferentes níveis de nitrogênio para as culturas de coberturas vegetais de milho e sorgo. Esta seção apresenta os sistemas baseados em regras *fuzzy* para as variáveis: teor de N, P, K, Ca, Mg, S e Mo, e os acúmulos de N, P, K, Ca, Mg, S e Mo, para as diferentes doses de nitrogênio (0, 40, 80 e 120 kg·ha⁻¹) para a cobertura vegetal de milho.


O sistema *fuzzy* foi desenvolvido utilizando funções de pertinência do tipo gaussiana para o conjunto das variáveis de entrada e para o conjunto das variáveis de saídas foram utilizadas funções de pertinência triangulares.

As funções de pertinência triangulares para as variáveis de saída referentes aos teores de nutrientes estão representadas na Figura 22.

Figura 22 - Funções de pertinência de saída dos teores de nutrientes para a cultura de cobertura vegetal do milho.














Fonte: Elaborada pelo autor.

Estão representadas na Figura 23, as funções de pertinência em relação aos acúmulos de nutrientes da cobertura vegetal de milheto. Os delimitadores das funções de pertinência triangulares das variáveis de saídas referentes aos teores e acúmulos de nutrientes, encontram-se na Tabela 16.

Figura 23- Funções de pertinência de saída dos acúmulos de nutrientes para a cultura de cobertura vegetal do milheto.







Fonte: Elaborada pelo autor.

Tabela 16 - Delimitadores das funções de pertinência de saída de tipo triangular para as variáveis de saída da cultura de cobertura de milheto.

Funções de Pertinência															
Variáveis de Saída	C_1				C_2				C_3				C_4		
	TN	[17,341	19,236	21,132]	[17,704	19,927	22,151]	[18,249	20,294	22,339]	[20,122	20,548	20,974]		
	TP	[4,663	4,79	4,916]	[4,322	4,827	5,331]	[4,498	4,874	5,251]	[4,613	4,892	5,171]		
	TK	[15,66	17,167	18,674]	[16,065	18,333	20,602]	[16,778	19	21,222]	[15,04	19,583	24,127]		
	TCa	[2,463	2,905	3,348]	[2,891	3,001	3,112]	[2,549	3,001	3,454]	[2,821	3,097	3,374]		
	TMg	[2,917	3,75	4,583]	[3,365	3,889	4,413]	[3,616	4,097	4,578]	[3,872	4,306	4,739]		
	TS	[2,328	2,567	2,805]	[2,349	2,594	2,838]	[2,157	2,61	3,063]	[2,628	2,656	2,685]		
	TMo	[1,701	1,792	1,883]	[1,746	1,972	2,198]	[1,948	2,064	2,18]	[1,756	2,342	2,928]		
	AN	[97,19	117,619	138,047]	[106,336	123,316	140,295]	[112,33	139,333	166,336]	[147,666	158,057	168,447]		
	AP	[25,394	28,638	31,881]	[28,125	29,642	31,159]	[26,867	32,39	37,913]	[34,265	39,849	45,433]		
	AK	[88,451	114,755	141,058]	[98,48	115,441	132,403]	[96,972	115,625	134,278]	[133,29	150,809	168,328]		
	ACa	[16,225	17,486	18,746]	[16,804	18,786	20,768]	[17,349	20,228	23,107]	[20,167	23,928	27,688]		
	AMg	[19,319	24,265	29,211]	[22,308	26,062	29,817]	[21,94	26,236	30,531]	[23,358	30,964	38,57]		
	AS	[14,055	15,176	16,297]	[15,047	15,682	16,317]	[14,675	17,992	21,308]	[18,538	21,179	23,82]		
	AMo	[11,909	12,506	13,103]	[11,4	13,233	15,066]	[11,129	13,616	16,103]	[13,661	14,766	15,871]		

Legenda: TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio); AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.

A base de regra originada a partir do SBRF para a formação do conjunto *fuzzy* de saída das variáveis analisadas para a cobertura vegetal de milho, apresenta-se na Tabela 17.

Tabela 17 - Base de regras do SBRF para a cobertura vegetal de milho.

Regra	Conjunto Entrada	Conjunto de Saída													
		TN	TP	TK	TCa	TMg	TS	TMo	AN	AP	AK	ACa	AMg	AS	AMo
1	1	2	3	4	3	3	3	4	1	1	1	1	1	1	3
2	2	4	1	1	2	1	4	2	3	3	2	3	2	3	2
3	3	1	2	2	1	2	1	1	4	4	4	4	4	4	4
4	4	3	4	3	4	4	2	3	2	2	3	2	3	2	1

Legenda: TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio); AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.

Após a elaboração das funções de pertinência dos conjuntos *fuzzy* das variáveis de saída, foi realizado o processo de validação dos modelos *fuzzy* por meio de testes estatísticos de ajuste de modelos; desvio do quadrado médio da raiz (*RMSE*), erro quadrado médio da raiz (*MAE*) e do coeficiente de determinação (R^2). Apresenta-se nas Tabela 18 e Tabela 19, os valores determinados dos testes de ajustes de modelos para validação dos modelos *fuzzy* da dos teores e acúmulo de nutrientes da cobertura vegetal de milho respectivamente.

Tabela 18 - Validação dos modelos *fuzzy* para as variáveis de saída dos teores de nutrientes da cultura de milho.

Variável	Índices	Modelo fuzzy gaussiano	Modelo fuzzy triangular	Regressão polinomial
TN	<i>Equação</i>	-	-	$y = 0,00007x^2 - 0,009x + 20,143$
	R^2	0,096 (p=0,326)	0,102 (p=0,312)	0,005 (p=0,823)
	<i>RMSE</i>	1,478	1,466	1,543
	<i>MAE</i>	1,205	1,178	1,266
TP	<i>Equação</i>	-	-	$y = 0,00002x^2 - 0,003x + 4,87$
	R^2	0,019 (p=0,669)	0,019 (p=0,666)	0,018 (p=0,677)
	<i>RMSE</i>	0,286	0,286	0,286
	<i>MAE</i>	0,234	0,232	0,232
TK	<i>Equação</i>	-	-	$y = 0,0005x^2 - 0,059x + 19,379$
	R^2	0,121 (p=0,268)	0,128 (p=0,254)	0,095 (p=0,330)
	<i>RMSE</i>	2,372	2,345	2,389
	<i>MAE</i>	1,987	1,931	2,011
TCa	<i>Equação</i>	-	-	$y = 0,00003x^2 - 0,003x + 3,02$
	R^2	0,052 (p=0,474)	0,053 (p=0,470)	0,032 (p=0,578)
	<i>RMSE</i>	0,286	0,286	0,289
	<i>MAE</i>	0,249	0,245	0,245
TMg	<i>Equação</i>	-	-	$y = 0,0001x^2 - 0,013x + 4,128$
	R^2	0,159 (p=0,199)	0,161 (p=0,196)	0,143 (p=0,225)
	<i>RMSE</i>	0,484	0,481	0,486
	<i>MAE</i>	0,401	0,405	0,416
TS	<i>Equação</i>	-	-	$y = -0,000003x^2 + 0,00001x + 2,623$
	R^2	0,018 (p=0,679)	0,019 (p=0,666)	0,005 (p=0,831)
	<i>RMSE</i>	0,233	0,232	0,234
	<i>MAE</i>	0,172	0,169	0,172
TMo	<i>Equação</i>	-	-	$y = 0,0001x^2 - 0,015x + 2,355$
	R^2	0,347 (p=0,044)	0,363 (p=0,038)	0,355 (p=0,041)
	<i>RMSE</i>	0,268	0,263	0,265
	<i>MAE</i>	0,190	0,184	0,191

Legenda: R^2 = coeficiente de determinação; *RMSE* = desvio do quadrado médio da raiz; *MAE* = erro quadrado médio da raiz. TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio). Fonte: Elaborada pelo autor.

Tabela 19- Validação dos modelos *fuzzy* para as variáveis de saída dos acúmulos de nutrientes da cultura de milho.

Variável	Índices	Modelo <i>fuzzy</i> gaussiano	Modelo <i>fuzzy</i> triangular	Regressão polinomial
AN	<i>Equação</i>	-	-	$y = -0,009x^2 + 1,148x + 115,095$
	R^2	0,489 (p=0,011)	0,49 (p=0,011)	0,427 (p=0,021)
	<i>RMSE</i>	16,426	16,035	16,999
	<i>MAE</i>	14,243	13,677	15,352
AP	<i>Equação</i>	-	-	$y = -0,002x^2 + 0,288x + 27,569$
	R^2	0,56 (p=0,005)	0,608 (p=0,003)	0,428 (p=0,021)
	<i>RMSE</i>	3,899	3,524	4,258
	<i>MAE</i>	3,323	2,849	3,086
AK	<i>Equação</i>	-	-	$y = -0,006x^2 + 0,768x + 109,493$
	R^2	0,459 (p=0,015)	0,465 (p=0,014)	0,193 (p=0,153)
	<i>RMSE</i>	16,800	16,505	20,269
	<i>MAE</i>	15,138	14,904	17,697
ACa	<i>Equação</i>	-	-	$y = -0,001x^2 + 0,167x + 16,996$
	R^2	0,549 (p=0,006)	0,555 (p=0,005)	0,44 (p=0,019)
	<i>RMSE</i>	2,242	2,158	2,420
	<i>MAE</i>	1,906	1,827	2,069
AMg	<i>Equação</i>	-	-	$y = -0,001x^2 + 0,149x + 23,628$
	R^2	0,237 (p=0,109)	0,243 (p=0,103)	0,163 (p=0,193)
	<i>RMSE</i>	4,412	4,375	4,601
	<i>MAE</i>	3,778	3,726	3,885
AS	<i>Equação</i>	-	-	$y = -0,001x^2 + 0,168x + 14,723$
	R^2	0,588 (p=0,003)	0,632 (p=0,002)	0,517 (p=0,008)
	<i>RMSE</i>	2,076	1,809	2,073
	<i>MAE</i>	1,802	1,359	1,661
AMo	<i>Equação</i>	-	-	$y = -0,0003x^2 + 0,031x + 13,331$
	R^2	0,262 (p=0,088)	0,265 (p=0,087)	0,103 (p=0,308)
	<i>RMSE</i>	1,383	1,362	1,504
	<i>MAE</i>	1,096	1,104	1,123


Legenda: R^2 = coeficiente de determinação; *RMSE* = desvio do quadrado médio da raiz; *MAE* = erro quadrado médio da raiz. AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.


Analisando as Tabela 18 e Tabela 19 de validação dos modelos, verifica-se que as modelagens *fuzzy* triangular e gaussiana apresentam os menores erros de ajustes de modelos em comparação ao modelo de regressão polinomial, além de obter maiores índices do coeficiente

de determinação (R^2), validando a eficiência dos modelos *fuzzy* gerado em relação aos parâmetros analisados.

A Figura 24 apresenta graficamente a comparação dos modelos *fuzzy*, triangular e gaussiana, e de regressão polinomial, para a cultura de cobertura vegetal do milho para as variáveis de saída, TN, TP, TK, TCa, TMg, TS e TMo. Na Figura 25, a comparação gráfica dos modelos para as variáveis de saída: AN, AP, AK, ACa, AMg, AS e AMo.

Figura 24 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, TN, TP, TK, TCa, TMg, TS e TMo, para a cultura de cobertura vegetal do milho.





Fonte: Elaborada pelo autor.

As curvas das funções de modelagem *fuzzy*, triangular e gaussiana, ao longo dos diferentes níveis de nitrogênio, comportou-se de maneira semelhante para as variáveis dos teores de nutrientes analisados, mostrando alta assertividade dos modelos *fuzzy* gerados.

Comparando o comportamento dos modelos *fuzzy* com a regressão polinomial, verifica-se semelhanças para grande maioria das curvas, excetos para os teores de N, K e Mo. É possível que em grande parte dos teores de nutrientes, o comportamento crescente de suas concentrações, à medida que ocorre aumento da adubação nitrogenada, excetos para os nutrientes Mo, K e Mg, os quais obtiveram altos valores de concentração de nutrientes na ausência do nitrogênio.

Para melhor interpretação dos resultados, apresenta-se na Tabela 20, a análise de variância e o teste de Tukey realizados em Goes (2016) em relação aos teores de nutrientes das coberturas vegetais sob efeito das diferentes doses de nitrogênio.


Tabela 20 - Análise de variância e teste de Tukey das coberturas vegetais sob efeito de doses de nitrogênio para os teores de nutrientes.


TEORES DE NUTRIENTES							
Tratamentos	N	P	K	Ca	Mg	S	Mo
Coberturas Vegetais (kg · ha ⁻¹) - C							
Milheto	20,0a	4,84a	18,6a	3,00a	4,01a	2,61a	2,04a
Sorgo	13,4b	4,21b	12,1b	2,62b	3,81a	1,68b	1,55b
DMS	1,3	0,24	1,9	0,34	0,39	0,19	0,24
Doses de N (kg · ha ⁻¹) - N							
0	15,9	4,52	15,4	2,83	4,21	2,09	2,02
40	16,8	4,55	15,1	2,96	3,90	2,17	1,73
80	16,2	4,52	15,7	2,57	3,67	2,09	1,66
120	17,9	4,51	15,0	2,88	3,86	2,21	1,78
Teste F							
C	115,05**	31,04**	53,01**	5,52*	1,19 ^{ns}	99,46*	17,75**
N	2,12 ^{ns}	0,02 ^{ns}	0,14 ^{ns}	1,07 ^{ns}	1,56 ^{ns}	0,39 ^{ns}	1,82 ^{ns}
C × N	1,46 ^{ns}	0,27 ^{ns}	1,28 ^{ns}	0,54 ^{ns}	1,79 ^{ns}	0,38 ^{ns}	0,49 ^{ns}
CV (%)	8,96	6,17	14,20	13,96	11,42	10,66	15,79

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Nota-se para a maioria dos nutrientes, os melhores teores foram obtidos pela cultura de cobertura vegetal de milho, havendo em relação aos teores de nutrientes, diferença estatística quanto ao tipo adotado de cobertura vegetal, exceto para o teor de Mg, sendo indiferente estatisticamente em relação ao tipo de cobertura, como também, às diferentes dosagens utilizadas de nitrogênio para adubação.

Figura 25 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, AN, AP, AK, ACa, AMg, AS e AMo, para a cultura de cobertura vegetal do milho.





Fonte: Elaborada pelo autor.

O comportamento das curvas dos modelos gerados em relação ao acúmulo de nutrientes, foi semelhante praticamente para todos os nutrientes analisados, apresentando as maiores concentrações ao nível de 80 kg · ha⁻¹ de nitrogênio. Tal fato pode ser explicado pelo comportamento gráfico da curva da variável de produtividade de matéria seca, a qual mostrou-se com maior produção ao nível de 80 kg · ha⁻¹, uma vez que a concentração do acúmulo de nutrientes é calculada em função da produtividade de matéria seca da palhada.

Para melhor interpretação sobre o comportamento das curvas geradas por meio dos modelos *fuzzy*, apresenta-se na Tabela 21, a análise de variância das coberturas vegetais em relação aos diferentes níveis de nitrogênio referentes ao acúmulo dos nutrientes.

Tabela 21 - Análise de variância e teste de Tukey das coberturas vegetais sob efeito de doses de nitrogênio para os acúmulos de nutrientes.

ACÚMULOS DE NUTRIENTES							
Tratamentos	N	P	K	Ca	Mg	S	Mo
Coberturas Vegetais (kg · ha⁻¹) - C							
Milheto	134,6	32,6	124,1	20,1	26,9	17,5	13,5
Sorgo	170,4	52,9	154,6	32,8	47,1	21,1	19,3
DMS	20,3	9,3	19,2	4,3	5,7	1,9	2,4
Doses de N (kg · ha⁻¹) - N							
0	96,1	27,4	92,5	17,1	25,7	12,5	12,1
40	172,9	50,3	159,6	33,1	44,2	22,3	18,5
80	186,4	54,1	181,8	30,2	44,7	23,8	19,9
120	154,5	39,4	123,7	25,3	33,5	18,6	15,1
Teste F							
C	14,21**	80,08**	11,53**	39,24**	57,87**	16,61**	25,24**
N	17,58**	27,95**	19,26**	11,99**	11,82**	32,63**	9,35**
C × N	7,73**	13,95**	10,52**	7,18**	7,55**	12,17**	7,68**
CV (%)	15,25	13,02	15,76	18,78	17,62	11,16	17,06

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

De fato, houve estatisticamente, diferenças entre os acúmulos de nutrientes para a interação entre as coberturas vegetais e concentração de nitrogênio utilizada para adubação. Nesse sentido foram realizados os desdobramentos de tais interações com o propósito de influência de cada fator analisado. Para tal, apresenta-se na Tabela 22, o desdobramento da interação em relação ao acúmulo dos nutrientes, nitrogênio.

Tabela 22 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de nitrogênio.

ACÚMULO DE NITROGÊNIO - N				
Coberturas Vegetais	Doses de N (kg · ha ⁻¹)			
	0	40	80	120
Milheto	117,6a	139,4b	158,1b	123,3b
Sorgo	74,5b	206,6a	214,7a	185,7a
Teste F	5,16*	12,55**	8,89**	10,79**
DMS (C d. N): 40,7 kg · ha⁻¹				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Assim como constatado no gráfico das curvas de modelagens, nota-se para a cultura do milheto, ao nível de $80 \text{ kg} \cdot \text{ha}^{-1}$, concentração de maior produtividade de matéria seca, o maior valor apurado em relação a concentração no nitrogênio, de $158,1 \text{ kg} \cdot \text{ha}^{-1}$.

Apresenta-se na Tabela 23, a interação entre as coberturas vegetais e doses de nitrogênio referente ao acúmulo de fósforo apresentado.

Tabela 23 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de fósforo.

ACÚMULO DE FÓSFORO - P				
Coberturas Vegetais	Doses de N ($\text{kg} \cdot \text{ha}^{-1}$)			
	0	40	80	120
Milheto	28,6a	32,4b	39,8b	29,7b
Sorgo	26,1a	68,2a	68,4a	29,7 ^a
Teste F	0,31 ^{ns}	61,97 ^{**}	39,57 ^{**}	18,41 ^{**}
DMS (C d. N): $9,8 \text{ kg} \cdot \text{ha}^{-1}$				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

O desdobramento da interação para a nutriente de potássio, em relação as coberturas vegetais e doses de nitrogênio, apresenta-se na Tabela 24.

Tabela 24 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de potássio.

ACÚMULO DE POTÁSSIO - K				
Coberturas Vegetais	Doses de N ($\text{kg} \cdot \text{ha}^{-1}$)			
	0	40	80	120
Milheto	114,8a	115,4b	150,8b	115,6a
Sorgo	70,2b	203,6a	212,8a	131,8a
Teste F	6,16 ^{**}	24,16 ^{**}	11,95 ^{**}	0,81 ^{ns}
DMS (C d. N): $38,4 \text{ kg} \cdot \text{ha}^{-1}$				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Apresenta-se nas Tabela 25 e Tabela 26, os desdobramentos das interações entre as coberturas vegetais e níveis de nitrogênio para os acúmulos dos nutrientes de cálcio e magnésio, respectivamente.

Tabela 25 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de cálcio.

ACÚMULO DE CÁLCIO - Ca				
Coberturas Vegetais	Doses de N (kg · ha ⁻¹)			
	0	40	80	120
Milheto	17,5a	20,2b	23,9b	18,8b
Sorgo	16,7a	46,1a	35,6a	31,8a
Teste F	0,04 ^{ns}	40,75**	9,69**	10,32**
DMS (C d. N): 8,7 kg · ha⁻¹				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Tabela 26 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de magnésio.

ACÚMULO DE MAGNÉSIO - Mg				
Coberturas Vegetais	Doses de N (kg · ha ⁻¹)			
	0	40	80	120
Milheto	24,3a	26,1b	30,9b	26,2b
Sorgo	27,1a	62,2a	58,5a	40,7a
Teste F	0,29 ^{ns}	46,15**	26,74**	7,35**
DMS (C d. N): 11,4 kg · ha⁻¹				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

As interações em relação ao acúmulo de enxofre e acúmulo de molibdênio, das coberturas vegetais com as diferentes doses de nitrogênio, apresentam-se nas Tabela 27 e Tabela 28, respectivamente.

Tabela 27 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de enxofre.

ACÚMULO DE ENXOFRE - S				
Coberturas Vegetais	Doses de N (kg · ha ⁻¹)			
	0	40	80	120
Milheto	15,2a	18,0b	21,2b	15,7b
Sorgo	9,8b	26,5a	26,4a	21,6a
Teste F	9,32**	23,56**	8,74**	11,52**
DMS (C d. N): 3,7 kg · ha⁻¹				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).

Tabela 28 - Interação entre coberturas vegetais e doses de nitrogênio referente ao acúmulo de molibdênio.

ACÚMULO DE MOLIBDÊNIO - Mo				
Coberturas Vegetais	Doses de N ($\text{kg} \cdot \text{ha}^{-1}$)			
	0	40	80	120
Milheto	13,6a	13,2b	14,8b	12,5b
Sorgo	10,6a	23,7a	25,1a	17,7a
Teste F	1,76 ^{ns}	20,97**	20,31**	5,24**
DMS (C d. N): 4,9 $\text{kg} \cdot \text{ha}^{-1}$				

Legenda: Médias seguidas de letras iguais nas colunas não diferem entre si pelo teste de Tukey a 1% e 5% de probabilidade. DMS (Diferença média significativa); CV (Coeficiente de variação); * significativo a 1% e ** significativo a 5%, ^{ns} - não significativo. Fonte: Goes (2016).


4.3.3 Modelagem das variáveis da cobertura vegetal do sorgo





Esta seção apresenta os sistemas baseados em regras *fuzzy* para as variáveis: teor de N, P, K, Ca, Mg, S e Mo, e os acúmulos de N, P, K, Ca, Mg, S e Mo, para as diferentes doses de nitrogênio (0, 40, 80 e 120 $\text{kg} \cdot \text{ha}^{-1}$) para a cobertura vegetal de sorgo.


Para o desenvolvimento do sistema *fuzzy*, utilizou-se para elaboração do conjunto das variáveis de entrada, as funções do tipo triangular e gaussiana, e sendo adotado para o conjunto das variáveis de saídas, funções de pertinência apenas do tipo triangular.

Vale ressaltar, que as funções de pertinência das variáveis de saída serão as mesmas independentemente do tipo de função de pertinência adotada para variável de entrada, gaussiana ou triangular. Sendo assim, está representada na Figura 26 as funções de pertinência das variáveis de saída dos teores de nutrientes da cobertura vegetal de sorgo.

Figura 26 - Funções de pertinência de saída dos teores de nutrientes para a cultura de cobertura vegetal do sorgo.














Fonte: Elaborada pelo autor.

Encontra-se na Figura 27, as funções de pertinência das variáveis de saída referente aos acúmulos de nutrientes da cobertura vegetal de sorgo. Os delimitadores das funções de pertinência das variáveis de saída da cobertura vegetal de sorgo, encontram-se na Tabela 29.

Figura 27- Funções de pertinência de saída dos acúmulos de nutrientes para a cultura de cobertura vegetal do sorgo.







Fonte: Elaborada pelo autor.

Tabela 29 - Delimitadores das funções de pertinência de saída de tipo triangular para as variáveis de saída da cultura de cobertura de sorgo.

Funções de Pertinência													
		C_1			C_2			C_3			C_4		
Variáveis de Saída	TN	[11,354	11,927	12,5]	[12,075	13,113	14,151]	[12,269	13,207	14,145]	[14,002	15,596	17,19]
	TP	[3,919	4,144	4,37]	[4,033	4,173	4,314]	[4,112	4,209	4,305]	[4,025	4,313	4,602]
	TK	[9,439	11	12,561]	[10	11,25	12,5]	[12,396	12,917	13,437]	[12,939	13,083	13,228]
	TCa	[2	2,25	2,5]	[2,146	2,667	3,187]	[2,089	2,667	3,244]	[2,628	2,917	3,205]
	TMg	[2,713	3,001	3,29]	[3,128	3,417	3,705]	[3,439	3,583	3,728]	[3,704	4,333	4,962]
	TS	[1,387	1,566	1,746]	[1,5	1,63	1,759]	[1,525	1,688	1,852]	[1,795	1,821	1,848]
	TMo	[1,338	1,487	1,636]	[1,362	1,495	1,629]	[1,34	1,532	1,724]	[1,31	1,698	2,086]
	AN	[71,447	74,525	77,603]	[151,628	185,707	219,787]	[186,524	206,603	226,682]	[188,512	214,712	240,912]
	AP	[24,999	26,087	27,176]	[43,246	49,173	55,1]	[58,686	68,197	77,708]	[60,963	68,467	75,971]
	AK	[63,266	70,251	77,237]	[100,428	131,789	163,15]	[187,496	203,585	219,673]	[189,96	212,806	235,653]
	ACa	[12,933	16,691	20,45]	[23,336	31,826	40,316]	[31,44	36,556	41,673]	[39,299	46,109	52,919]
	AMg	[23,047	27,096	31,144]	[33,649	40,686	47,724]	[49,359	58,493	67,626]	[50,636	62,224	73,813]
AS	[8,661	9,79	10,92]	[19,212	21,613	24,015]	[25,55	26,36	27,171]	[24,147	26,56	28,974]	
AMo	[8,214	10,607	13,001]	[15,706	17,697	19,688]	[18,633	23,691	28,749]	[19,947	25,057	30,166]	

Legenda: TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio); AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.

A base de regra originada a partir do SBRF para a formação do conjunto *fuzzy* de saída das variáveis analisadas para a cobertura vegetal de sorgo, apresenta-se na Tabela 30.

Tabela 30 - Base de regras do SBRF para a cobertura vegetal de sorgo.

Regra	Conjunto Entrada	Conjunto de Saída													
		TN	TP	TK	TCa	TMg	TS	TMo	AN	AP	AK	ACa	AMg	AS	AMo
1	1	2	3	2	3	4	1	4	1	1	1	1	1	1	1
2	2	2	4	3	4	1	3	1	3	3	3	4	4	4	3
3	3	3	3	4	1	3	2	3	4	4	4	3	3	3	4
4	4	4	1	1	2	2	4	2	2	2	2	2	2	2	2

Legenda: TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio); AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.

De maneira análoga ao item 4.3.2, foi realizado o procedimento de validação dos modelos *fuzzy* por meio de testes estatísticos de ajustes de modelos, desvio padrão médio da raiz (*RMSE*), erro quadrático médio (*MAE*) e do coeficiente de determinação (R^2) apresentados nas Tabela 31 e Tabela 32 referentes aos teores e acúmulos de nutrientes das coberturas vegetais de sorgo, respectivamente.

Tabela 31 - Validação dos modelos *fuzzy* para as variáveis de saída dos teores de nutrientes da cultura de sorgo.

Variável	Índices	Modelo <i>fuzzy</i> gaussiano	Modelo <i>fuzzy</i> triangular	Regressão polinomial
TN	<i>Equação</i>	-	-	$y = 0,0002x^2 + 0,005x + 12,096$
	R^2	0,620 (p=0,002)	0,598 (p=0,003)	0,632 (p=0,002)
	<i>RMSE</i>	1,096	1,075	0,978
	<i>MAE</i>	0,954	0,936	0,845
TP	<i>Equação</i>	-	-	$y = -0,00003x^2 + 0,003x + 4,188$
	R^2	0,107 (p=0,299)	0,123 (p=0,264)	0,095 (p=0,329)
	<i>RMSE</i>	0,168	0,166	0,169
	<i>MAE</i>	0,147	0,143	0,150
TK	<i>Equação</i>	-	-	$y = -0,0006x^2 + 0,069x + 11,213$
	R^2	0,471 (p=0,014)	0,554 (p=0,005)	0,547 (p=0,006)
	<i>RMSE</i>	1,020	0,846	0,857
	<i>MAE</i>	0,874	0,625	0,671
TCa	<i>Equação</i>	-	-	$y = 0,00003x^2 - 0,005x + 2,767$
	R^2	0,314 (p=0,058)	0,314 (p=0,058)	0,038 (p=0,543)
	<i>RMSE</i>	0,358	0,354	0,420
	<i>MAE</i>	0,306	0,306	0,351
TMg	<i>Equação</i>	-	-	$y = 0,00004x^2 - 0,012x + 4,338$
	R^2	0,337 (p=0,048)	0,192 (p=0,154)	0,558 (p=0,005)
	<i>RMSE</i>	0,446	0,554	0,312
	<i>MAE</i>	0,347	0,423	0,252
TS	<i>Equação</i>	-	-	$y = 0,00001x^2 + 0,0005x + 1,588$
	R^2	0,402 (p=0,027)	0,41 (p=0,025)	0,303 (p=0,064)
	<i>RMSE</i>	0,119	0,113	0,123
	<i>MAE</i>	0,106	0,093	0,099
TMo	<i>Equação</i>	-	-	$y = 0,00003x^2 - 0,005x + 1,681$
	R^2	0,15 (p=0,213)	0,161 (p=0,195)	0,126 (p=0,257)
	<i>RMSE</i>	0,197	0,195	0,200
	<i>MAE</i>	0,158	0,157	0,158

Legenda: R^2 = coeficiente de determinação; *RMSE* = desvio do quadrado médio da raiz; *MAE* = erro quadrado médio da raiz. TN (teor de nitrogênio); TP (teor de fósforo); TK (teor de potássio); TCa (teor de cálcio); TMg (teor de magnésio); TS (teor de enxofre); TMo (teor de molibdênio). Fonte: Elaborada pelo autor.

Tabela 32- Validação dos modelos *fuzzy* para as variáveis de saída dos acúmulos de nutrientes da cultura de sorgo.

Variável	Índices	Modelo <i>fuzzy</i> gaussiano	Modelo <i>fuzzy</i> triangular	Regressão polinomial
AN	<i>Equação</i>	-	-	$y = -0,025x^2 + 3,874x + 78,868$
	R^2	0,885 (p=0)	0,894 (p=0)	0,867 (p=0)
	<i>RMSE</i>	35,076	19,410	21,705
	<i>MAE</i>	29,136	15,147	17,463
AP	<i>Equação</i>	-	-	$y = -0,01x^2 + 1,325x + 27,201$
	R^2	0,813 (p=0,0001)	0,908 (p=0)	0,890 (p=0)
	<i>RMSE</i>	12,253	5,524	6,059
	<i>MAE</i>	9,544	4,453	4,641
AK	<i>Equação</i>	-	-	$y = -0,034x^2 + 4,504x + 71,945$
	R^2	0,913 (p=0)	0,917 (p=0)	0,913 (p=0)
	<i>RMSE</i>	23,757	17,383	17,791
	<i>MAE</i>	19,141	14,232	15,020
ACa	<i>Equação</i>	-	-	$y = -0,005x^2 + 0,73x + 18,881$
	R^2	0,805 (p=0,0001)	0,810 (p=0,0001)	0,638 (p=0,002)
	<i>RMSE</i>	5,912	5,144	7,107
	<i>MAE</i>	5,297	4,527	5,572
AMg	<i>Equação</i>	-	-	$y = -0,008x^2 + 1,085x + 28,335$
	R^2	0,800 (p=0,0001)	0,809 (p=0,0001)	0,778 (p=0,0001)
	<i>RMSE</i>	8,366	6,875	7,417
	<i>MAE</i>	7,336	5,777	6,047
AS	<i>Equação</i>	-	-	$y = -0,003x^2 + 0,492x + 10,412$
	R^2	0,953 (p=0)	0,954 (p=0)	0,913 (p=0)
	<i>RMSE</i>	2,387	1,501	2,067
	<i>MAE</i>	2,026	1,217	1,695
AMo	<i>Equação</i>	-	-	$y = -0,003x^2 + 0,44x + 10,757$
	R^2	0,756 (p=0,0002)	0,761 (p=0,0002)	0,759 (p=0,0002)
	<i>RMSE</i>	3,590	3,198	3,216
	<i>MAE</i>	3,034	2,578	2,575

Legenda: R^2 = coeficiente de determinação; *RMSE* = desvio do quadrado médio da raiz; *MAE* = erro quadrado médio da raiz. AN (acúmulo de nitrogênio); AP (acúmulo de fósforo); AK (acúmulo de potássio); ACa (acúmulo de cálcio); AMg (acúmulo de magnésio); AS (acúmulo de enxofre); AMo (acúmulo de molibdênio). Fonte: Elaborada pelo autor.


Observa-se pelas Tabela 31 e Tabela 32, comparando-se os modelos de regressão polinomial e *fuzzy* gaussiana, verifica-se a superioridade dos valores determinados pelos coeficientes de determinação (R^2) em seis variáveis analisadas pelo modelo de regressão polinomial e oito em relação a modelagem *fuzzy* gaussiana, porém quando comparada em









relação a modelagem *fuzzy* triangular, a superioridade da regressão cai para apenas duas variáveis, TN e TMg, sobre as demais 12 variáveis nas quais há a superioridade dos valores de (R^2) da modelagem *fuzzy* triangular. Mostrando o melhor ajuste das modelagens *fuzzy* frente ao fenômeno estudado.


Toda vai, embora os erros de ajuste de modelos da modelagem *fuzzy* gaussiana serem em grande parte, maiores em relação ao modelo de regressão polinomial originado, o comportamento da curva frente ao aumento do nível de nitrogênio utilizado para adubação, descreveu-se de melhor maneira a realidade dos fenômenos agrônômicos ocorridos durante o experimento realizado.

Sendo assim, a Figura 28 apresenta graficamente a comparação entre os modelos gerados sobre os fenômenos agrônômicos ocorridos em relação aos teores dos nutrientes analisados no experimento de Goes (2016).

Figura 28 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, TN, TP, TK, TCa, TMg, TS e TMo, para a cultura de cobertura vegetal do sorgo.







Fonte: Elaborada pelo autor.


Verifica-se em relação aos dois modelos *fuzzy* analisados, a semelhança no comportamento das curvas geradas ao longo do aumento do nível de nitrogênio, em que, embora constatado os maiores erros de ajustes de modelos para a modelagem *fuzzy* do tipo gaussiana em relação ao modelo de regressão polinomial, o comportamento gráfico das curvas geradas, condizem de melhor maneira com a realidade dos experimentos agrônomo, uma vez que utilizando a modelagem *fuzzy* triangular como base para previsão dos fenômenos, esta, apresenta os melhores ajustes de modelos, R^2 , $RMSE$ e MAE em comparação aos modelos de regressão polinomial.


Os valores médios obtidos em relação aos teores dos nutrientes para a cultura de cobertura vegetal de sorgo, foram apresentados na Tabela 20, de onde foi possível constatar valores inferiores para a cultura do sorgo em comparação aos valores médios da cultura de cobertura vegetal de milho.

Todavia, espera-se das modelagens matemáticas através de dados amostrais, a previsão de fenômenos para os valores que não foram analisados experimentalmente, que represente de melhor maneira a realidade dos fenômenos agrônomicos. Destacando-se, nesse sentido, o comportamento das curvas geradas pelas modelagens *fuzzy* do tipo gaussiana devido à suavização das curvas sobre o conjunto de dados analisados.

São apresentadas na Figura 29 a comparação entre as curvas de modelagens para as variáveis analisadas referente ao acúmulo de nutrientes para a cultura de cobertura vegetal de sorgo.

Figura 29 - Comparação das curvas dos modelos desenvolvidos das variáveis de saída, AN, AP, AK, ACa, AMg, AS e AMo, para a cultura de cobertura vegetal do sorgo.





Fonte: Elaborada pelo autor.

O comportamento das curvas de modelagens *fuzzy*, assim como constatada anteriormente, foi semelhante para ambos modelos *fuzzy*. Verifica-se o acúmulo de nutrientes com maior concentração, aos níveis de nitrogênio compreendido entre 40 e 80 kg · ha⁻¹, uma vez que a maior produtividade da matéria seca para cultura do sorgo ocorreu para os níveis também de nitrogênio entre 40 e 80 kg · ha⁻¹, conforme mostrada no item 4.3.1.

Os valores médios obtidos em relação aos acúmulos dos nutrientes, foram apresentados na Tabela 21, constatando-se os valores superiores obtidos para a cultura de cobertura vegetal de sorgo em relação ao milheto, em razão da aferição da maior produtividade de matéria seca da cobertura vegetal de sorgo, conforme foram apresentados nas Tabela 14 e Tabela 15.

5 CONCLUSÕES

De modo geral, as coberturas vegetais responderam de maneira satisfatórias às diferentes dosagens de nitrogênio, apresentando-se como potenciais coberturas vegetais em posterior uso para plantio direto. A cultura do milho apresentou os maiores rendimentos para os teores dos nutrientes, porém menor produtividade de matéria seca, já o sorgo por sua vez, em decorrência do maior rendimento de matéria seca, este apresentou valores superiores dos acúmulos dos nutrientes em relação ao milho para variações das diferentes doses de nitrogênio.

Assim, verificou-se em relação a produtividade de matéria seca, o maior rendimento para cultura do milho, quando adubada ao nível de $80 \text{ kg} \cdot \text{ha}^{-1}$ de nitrogênio, conforme as curvas das modelagens *fuzzy* para funções de tipo gaussiana e triangular, valor superior ao encontrado por Goes (2016), que de acordo com o modelo de regressão polinomial de 2º grau, foi constatado o valor de $65,1 \text{ kg} \cdot \text{ha}^{-1}$.

Muito embora, para algumas variáveis a modelagem *fuzzy* gaussiana não tenha se destacado em relação aos parâmetros de testes de ajustes sobre os modelos de regressão polinomial; por outro lado, o comportamento da curva ao longo do aumento do nível de nitrogênio, em decorrência da suavização da mesma, representou-se de maneira mais condizente com a realidade dos fenômenos agrônômicos.

Nesse ponto, a modelagem *fuzzy* representa com maior veracidade a ocorrência dos fenômenos agrônômicos, no qual a modelagem *fuzzy* gaussiana mostrou-se melhor ajustada ao comportamento da curva condizente com a realidade, tendo como base a função *fuzzy* triangular para fins de parâmetros de validação dos modelos geados.

As modelagens *fuzzy* apresentaram de maneira geral, os melhores resultados comprado aos modelo de regressão polinomial de 2º grau, para os testes de coeficiente de determinação (R^2), ao teste da raiz do erro quadrático médio (*RMSE*) e ao erro absoluto médio (*MAE*).

Torna-se de grande utilidade ao produtor rural, a observação em relação ao comportamento das curvas de modelagens *fuzzy*, com a finalidade de obter o conhecimento a respeito do maior rendimento em relação ao nutriente desejado em função dos níveis diferentes de nitrogênio utilizado para adubação, agregando-se ao fato de proporcionar uma economia em relação aos gastos com fertilizantes, que por sua vez, resultando em uma maior produtividade da cultura.

REFERÊNCIAS

- ALBUQUERQUE, A. W. et al. Plantas de cobertura e adubação nitrogenada na produção de milho em sistema de plantio direto. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 7, p. 721–726, 2013.
- ALVAREZ, R.; STEINBACH, H. S.; DE PAEPE, J. L. Cover Crop Effects on Soils and Subsequent Crops in the Pampas: A Meta-Analysis. **Soil and Tillage Research**, v. 170, p. 53–65, 2017.
- APPIAH-NKANSAH, N. B. et al. Ethanol Production from Mixtures of Sweet Sorghum Juice and Sorghum Starch Using Very High Gravity Fermentation with Urea Supplementation. **Industrial Crops and Products**, v. 111, p. 247–253, 2018.
- ARAYA, A. et al. Grain Sorghum Production Functions under Different Irrigation Capacities. **Agricultural Water Management**, v. 203, p. 261–271, 2018.
- BARNSTON, A. G. Correspondence among the correlation, RMSE, and heidke forecast verification measures; refinement of the hidke score. **Notes and Correspondence**, v. 7, p. 699–709, 1992.
- BELARBI, K. et al. Design of Mamdani Fuzzy Logic Controllers with Rule Base Minimisation Using Genetic Algorithm. **Engineering Applications of Artificial Intelligence**, v. 18, n. 7, p. 875–880, 2005.
- BENINI, L. C.; MENEGUETTE JUNIOR, M. Uma Abordagem para modelagem de dados com o uso de Sistemas Neuro-Fuzzy: Aplicações Geoespaciais. **Notas em Matemática Aplicada**, v. 43, p. 88, 2009.
- BOSO, A. C. M. R. **Modelagem matemática e computacional na avaliação do uso de água magnetizada na irrigação do rabanete utilizando o sistema Mamdani**. 2018. 106 f. Dissertação (Mestrado em Irrigação e Drenagem) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2018.
- BOUKEZZOULA, R.; GALICHET, S.; COQUIN, D. From Fuzzy Regression to Gradual Regression: Interval-Based Analysis and Extensions. **Information Sciences**, v. 441, p. 18–40, 2018.
- BRANCO, R. B. F. et al. Nitrogen Fertilization of Vegetables Cultivated under No-Tillage after Cover Crops. **Horticultura Brasileira**, v. 35, n. 1, p. 103–110, 2017.
- BRAUN, M. R.; ALTAN, H.; BECK, S. B. M. Using Regression Analysis to Predict the Future Energy Consumption of a Supermarket in the UK. **Applied Energy**, v. 130, p. 305–313, 2014.
- BRESSAN, S. B. et al. Plantas de cobertura e qualidade química de Latossolo Amarelo sob plantio direto no cerrado maranhense. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, n. 4, p. 371–378, 2013.
- CALONEGO, J. C. et al. Soil Compaction Management and Soybean Yields with Cover Crops under No-till and Occasional Chiseling. **European Journal of Agronomy**, v. 85, p. 31–37, 2017.

- CALVO, C. L.; FOLONI, J. S. S.; BRANCALIAÃO, S. R. Produtividade de fitomassa e relação C/N de monocultivos e consórcios de guandu-anão, milho e sorgo em três épocas de corte. **Bragantia**, v. 69, n. 1, p. 77–86, 2010.
- CAO, S. G.; REES, N. W.; FENG, G. Mamdani-Type Fuzzy Controllers Are Universal Fuzzy Controllers. **Fuzzy Sets and Systems**, v. 123, n. 3, p. 359–367, 2001.
- CASELA, C. R. et al. Cultivares de sorgo. **Informativo Agropecuário**, v. 12, n. 144, p. 40–42, 1996.
- CASTRO, E. et al. Potential for Ethanol Production from Different Sorghum Cultivars. **Industrial Crops and Products**, v. 109, p. 367–373, 2017.
- CAYCHO-RODRÍGUEZ, T. Considerations for the Correct Interpretation of Confidence Intervals in Nursing Research. **Enfermería Clínica (English Edition)**, fev. 2018. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S2445147918300213>>. Acesso em: 13 maio. 2018.
- CENTURION, J. F. Balanço hídrico na região de Ilha Solteira. **Científica**, v. 10, n. 1, p. 57–61, 1982.
- COELHO, M. E. H. et al. Coberturas do solo sobre a amplitude térmica e a produtividade de pimentão. **Planta Daninha**, v. 31, n. 2, p. 369–378, 2013.
- CORREIA, N. M.; DURIGAN, J. C. Culturas de cobertura e sua influência na fertilidade do solo sob Sistema de Plantio Direto (SPD). **Bioscience Journal**, v. 24, n. 4, p. 12, 2008.
- CREMASCO, C. P. **Aplicação da lógica fuzzy para avaliação do faturamento do consumo de energia elétrica e demanda de uma empresa de avicultura de postura**. 2008. 97 f. Tese (Doutorado em Energia na Agricultura) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2008.
- CREMASCO, C. P.; GABRIEL FILHO, L. R. A.; CATANEO, A. Metodologia de determinação de funções de pertinência de controladores fuzzy para a avaliação energética de empresas de avicultura de postura. **Energia na Agricultura**, v. 25, n. 1, p. 21, 2010.
- DAMIAN, J. M. et al. Monitoring Variability in Cash-Crop Yield Caused by Previous Cultivation of a Cover Crop under a No-Tillage System. **Computers and Electronics in Agriculture**, v. 142, p. 607–621, 2017.
- DELAUNE, P. B.; SIJ, J. W. Impact of Tillage on Runoff in Long Term No-till Wheat Systems. **Soil and Tillage Research**, v. 124, p. 32–35, 2012.
- DEMING, S. N.; MORGAN, S. L. Analysis of Variance (ANOVA) for Linear Models. In: **Experimental design**. a chemometric approach. 2. ed. Amsterdam: Elsevier, 1993. 11p. 436.
- DERPSCH, R. et al. Current Status of Adoption of No-till Farming in the World and Some of Its Main Benefits. **International Journal of Agricultural and Biological Engineering**, v. 3, n. 1, p. 25, 2010.
- DERPSCH, R. et al. Why Do We Need to Standardize No-Tillage Research? **Soil and Tillage Research**, v. 137, p. 16–22, 2014.

DONK, S. van et al. Crop residue cover effects on evaporation, soil water content, and yield of deficit-irrigated corn in west-central Nebraska. **American Society of Agricultural and Biological Engineers**, v. 53, n. 6, p. 1787–1797, 2010.

EMBRAPA. CENTRO NACIONAL DE PESQUISA DE SOLOS. **Sistema brasileiro de classificação de solos**. 2. ed. Rio de Janeiro: EMBRAPA - SPI, 2006.

FAO. **AQUASTAT Main Database** United Nations, , 2016. . Disponível em: <<http://www.fao.org/nr/water/aquastat/data/query/results.html>>. Acesso em: 6 abr. 2018.

FAO. **Conservation Agriculture Adoption Worldwide** United Nations, , 2017. . Disponível em: <<http://www.fao.org/nr/water/aquastat/data/query/results.html>>. Acesso em: 2 abr. 2018.

FEBRAPDP. **Evolução área do Sistema Plantio Direto no Brasil** Federação Brasileira de Plantio Direto e Irrigação, , 2012. . Disponível em: <<https://febrapdp.org.br/area-de-pd>>. Acesso em: 7 abr. 2018.

FORINA, M. et al. A New Algorithm for Seriation and Its Use in Similarity Dendrograms. **Chemometrics and Intelligent Laboratory Systems**, v. 87, n. 2, p. 262–274, 2007.

FUMO, N.; RAJE BISWAS, M. A. Regression Analysis for Prediction of Residential Energy Consumption. **Renewable and Sustainable Energy Reviews**, v. 47, p. 332–343, 2015.

GABRIEL FILHO, L. R. A. et al. Application of Fuzzy Logic for the Evaluation of Livestock Slaughtering. **Engenharia Agrícola**, v. 31, n. 4, p. 813–825, 2011.

GABRIEL FILHO, L. R. A. et al. Software to Assess Beef Cattle Body Mass through the Fuzzy Body Mass Index. **Engenharia Agrícola**, v. 36, n. 1, p. 179–193, 2016.

GARCÍA-GONZÁLEZ, I. et al. Cover Crops to Mitigate Soil Degradation and Enhance Soil Functionality in Irrigated Land. **Geoderma**, v. 322, p. 81–88, 2018.

GARG, B.; AGGARWAL, S.; SOKHAL, J. Crop Yield Forecasting Using Fuzzy Logic and Regression Model. **Computers & Electrical Engineering**, p. 1–21, 2017.

GIAROLA, N. F. B. et al. On the Visual Evaluation of Soil Structure: The Brazilian Experience in Oxisols under No-Tillage. **Soil and Tillage Research**, v. 127, p. 60–64, 2013.

GOES, R. J. **Doses de nitrogênio em coberturas vegetais e molibdênio foliar na soja em sucessão**. 2016. 77 f. Tese (Doutorado) - Curso de Agronomia, Sistema de Produção, Universidade Estadual Paulista, Ilha Solteira, 2016.

GOLABI, M. H.; EL-SWAIFY, S. A.; IYEKAR, C. Experiment of “No-Tillage” Farming System on the Volcanic Soils of Tropical Islands of Micronesia. **International Soil and Water Conservation Research**, v. 2, n. 2, p. 30–38, 2014.

GRECH, V.; CALLEJA, N. WASP (Write a Scientific Paper): Multivariate Analysis. **Early Human Development**, 2018. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0378378218302494>>. Acesso em: 7 maio. 2018.

- GUO, D.; WESTRA, S.; MAIER, H. R. An R Package for Modelling Actual, Potential and Reference Evapotranspiration. **Environmental Modelling & Software**, v. 78, p. 216–224, 2016.
- HAMMOU, F.; HAMMOUCHE, K.; POSTAIRE, J.-G. Convexity Dependent Anisotropic Diffusion for Mode Detection in Cluster Analysis. **Neurocomputing**, 2018. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S092523121830448X>>. Acesso em: 9 maio. 2018.
- HUBIG, M.; MUGGENTHALER, H.; MALL, G. Confidence Intervals in Temperature-Based Death Time Determination. **Legal Medicine**, v. 17, n. 1, p. 48–51, jan. 2015.
- INÁCIO, D. F. S. et al. The Use of Sorghum Silage in Feeding Weanling Horses: Body Development. **Livestock Science**, v. 215, p. 46–48, 2017.
- JAHANZAD, E. et al. Improving Yield and Mineral Nutrient Concentration of Potato Tubers through Cover Cropping. **Field Crops Research**, v. 212, p. 45–51, 2017.
- KISI, O. Applicability of Mamdani and Sugeno Fuzzy Genetic Approaches for Modeling Reference Evapotranspiration. **Journal of Hydrology**, v. 504, p. 160–170, 2013.
- KLIEMANN, H. J.; BRAGA, A. J. P.; MARQUES, P. Taxas de decomposição de resíduos de espécies de cobertura em latossolo vermelho distroférico. **Pesquisa Agropecuária Tropical**, v. 36, n. 1, p. 21–28, 2006.
- LANDRES, J. N. **Plantio Direto: Histórico, características e benefícios do Plantio Direto**. Brasília, DF: Associação Brasileira de Educação Agrícola Superior - ABEAS, 2005.
- LEITE, D. F. et al. Modelagem evolutiva granular fuzzy. **Simpósio Brasileiro de Automação Inteligente**, v. 10, p. 7, 2011.
- LI, J. et al. A New Fuzzy Regression Model Based on Least Absolute Deviation. **Engineering Applications of Artificial Intelligence**, v. 52, p. 54–64, 2016.
- LINTON, O. Confidence Intervals and Sets. In: **Probability, Statistics and Econometrics**. [s.l.] Elsevier, 2017. p. 199–210.
- LOPES, R. C. S. O. et al. Evaluation of the Health Benefits of Consumption of Extruded Tannin Sorghum with Unfermented Probiotic Milk in Individuals with Chronic Kidney Disease. **Food Research International**, v. 107, p. 629–638, 2018.
- LU, K.-P.; CHANG, S.-T. A Fuzzy Classification Approach to Piecewise Regression Models. **Applied Soft Computing**, 2018. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S1568494618302370>>. Acesso em: 5 maio. 2018.
- MAHN, A. Modelling of the Effect of Selenium Fertilization on the Content of Bioactive Compounds in Broccoli Heads. **Food Chemistry**, v. 233, p. 492–499, 2017.
- MALAVOLTA, E.; VITTI, G. C.; OLIVEIRA, S. A. de. **Avaliação do estado nutricional das plantas**. 2. ed. Universidade Comell: Associação Brasileira para Pesquisa da Potassa e do Fosfato, 1997.

MAMAN, N. et al. Pearl Millet and Grain Sorghum Yield Response to Water Supply in Nebraska. **Agronomy Journal**, v. 95, n. 6, p. 1618, 2003.

MAMDANI, E. H.; ASSILIAN, S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. **International Journal of Man-Machine Studies**, v. 7, n. 1, p. 1–13, 1975.

MESKINI-VISHKAEI, F.; DAVATGAR, N. Evaluation of Different Predictor Models for Detailed Soil Particle-Size Distribution. **Pedosphere**, v. 28, n. 1, p. 157–164, 2018.

MINITAB. Disponível em: <<https://support.minitab.com/pt-br/minitab/18/help-and-how-to/modeling-statistics/multivariate/how-to/cluster-observations/interpret-the-results/all-statistics-and-graphs/dendrogram/>>. Acesso em: 9 jan. 2019.

MISHRA, S.; DATTA-GUPTA, A. Multivariate Data Analysis. In: **Applied Statistical Modeling and Data Analytics**. [s.l.] Elsevier, 2018. p. 97–118.

MITCHELL, J. P. et al. Cover Cropping and No-Tillage Improve Soil Health in an Arid Irrigated Cropping System in California's San Joaquin Valley, USA. **Soil and Tillage Research**, v. 165, p. 325–335, 2017.

MORTVEDT, J. J.; RÖMHELD, V.; MARSCHNER, H. Function of Micronutrients in Plants. In: **Micronutrients in Agriculture**. MORTVEDT, J. J. (Ed.): Soil Science Society of America, 1991. p. 297–328.

MOTTER, P.; ALMEIDA, H. G. de (ed.). **Plantio direto: A tecnologia que revolucionou a agricultura brasileira**. Foz do Iguaçu: Parque Itaipu, 2015.

MUÑOZ-ROMERO, S.; GÓMEZ-VERDEJO, V.; PARRADO-HERNÁNDEZ, E. A Novel Framework for Parsimonious Multivariate Analysis. **Pattern Recognition**, v. 71, p. 173–186, 2017.

NIELSEN, D. C.; VIGIL, M. F. Water Use and Environmental Parameters Influence Proso Millet Yield. **Field Crops Research**, v. 212, p. 34–44, 2017.

OSTERTAGOVÁ, E. Modelling Using Polynomial Regression. **Procedia Engineering**, v. 48, p. 500–506, 2012.

PEDREIRA, M. dos S. et al. Características agronômicas e composição química de oito híbridos de sorgo [*Sorghum bicolor* (L.) Moench]. **Revista Brasileira de Zootecnia**, v. 32, n. 5, p. 1083–1092, 2003.

PEREIRA FILHO, I. A. et al. Manejo da cultura do milheto. **Embrapa Milho e Sorgo**, p. 17, 2003.

PEREIRA FILHO, R. D. **Desenvolvimento e implementação de controladores nebulosos em uma coluna piloto de destilação em batelada**. 199 f. Dissertação (Mestrado em Engenharia Química) - Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas, 1999.

PESSOA, A. C. S. **Atividades de nitrogenase e redutase do nitrato e produtividade do feijoeiro em resposta à adubação com molibdênio e fósforo**. 151 f. Tese (Doutorado em Solos) - Faculdade de Agronomia, Universidade Federal de Viçosa, Viçosa, 1998.

PIMENTA, A. H. de M. **Geração genética de classificador fuzzy intervalar do tipo 2**. 2009. 91 f. Dissertação (Mestrado em Ciência da Computação) - Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos, São Carlos, 2009.

PÖHLITZ, J. et al. Computed Tomography and Soil Physical Measurements of Compaction Behaviour under Strip Tillage, Mulch Tillage and No Tillage. **Soil and Tillage Research**, v. 175, p. 205–216, 2018.

PRECHSL, U. E. et al. Assessing the Environmental Impacts of Cropping Systems and Cover Crops: Life Cycle Assessment of FAST, a Long-Term Arable Farming Field Experiment. **Agricultural Systems**, v. 157, p. 39–50, 2017.

PUTTI, F. F. **Análise dos indicadores biométricos e nutricionais da cultura da alface (*Lactuca sativa* L.) irrigada com água tratada magneticamente utilizando modelagem fuzzy**. 2015. 186 f. Tese (Doutorado em Irrigação e Drenagem) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2015.

PUTTI, F. F. et al. Fuzzy Modeling on Wheat Productivity under Different Doses of Sludge and Sewage Effluent. **Engenharia Agrícola**, v. 37, n. 6, p. 1103–1115, 2017a.

PUTTI, F. F. et al. A Fuzzy Mathematical Model to Estimate the Effects of Global Warming on the Vitality of *Laelia Purpurata* Orchids. **Mathematical Biosciences**, v. 288, p. 124–129, 2017b.

QI, Y. et al. Optimization of Starch Isolation from Red Sorghum Using Response Surface Methodology. **LWT**, v. 91, p. 242–248, 2018.

RIBAS, G. G. et al. Temperatura do solo afetada pela irrigação e por diferentes coberturas. **Engenharia Agrícola**, v. 35, n. 5, p. 817–828, out. 2015.

ROUSSON, V.; GOŞONIU, N. F. An χ^2 -Square Coefficient Based on Final Prediction Error. **Statistical Methodology**, v. 4, n. 3, p. 331–340, 2007.

RUSU, T. Energy Efficiency and Soil Conservation in Conventional, Minimum Tillage and No-Tillage. **International Soil and Water Conservation Research**, v. 2, n. 4, p. 42–49, 2014.

SALES, R. P. et al. Physical quality of a Latosol under no-tillage and conventional tillage in the semi-arid region. **Revista Ciência Agronômica**, v. 47, n. 3, p. 429–438, 2016.

SANTOS, J. F. D. **Sistema inteligente fuzzy para auxílio ao diagnóstico de níveis de risco da gestação integrado à plataforma de telemedicina preneonatal**. 2015. 96 f. Dissertação (Mestrado em Ciência da Computação) - Universidade do Estado do Rio Grande do Norte e Universidade Federal Rural do Semi-Árido, Mossoró, 2015.

SELLE, P. H. et al. Outlook: Sorghum as a Feed Grain for Australian Chicken-Meat Production. **Animal Nutrition**, v. 4, n. 1, p. 17–30, 2018.

SILVA, J. C. da et al. Análise comparativa entre os sistemas de preparo do solo: aspectos técnicos e econômicos. **Enciclopédia Biosfera**, v. 7, n. 12, p. 11, 2011.

SILVA NETO, G. C. D. **Um método para solução de problemas de otimização multiobjetivo em ambiente fuzzy**. 2011. 83 f. Dissertação (Mestrado em Matemática) - Instituto de Ciências Exatas, Universidade Federal do Amazonas, Manaus, 2011.

SIQUEIRA NETO, M. et al. Soil Carbon Stocks under No-Tillage Mulch-Based Cropping Systems in the Brazilian Cerrado: An on-Farm Synchronic Assessment. **Soil and Tillage Research**, v. 110, n. 1, p. 187–195, 2010.

SOUZA, A. P. de et al. Taxas de decomposição de resíduos vegetais submetidos a lâminas de irrigação. **Irriga**, v. 19, n. 3, p. 512–526, 2014.

TAMUS, Z. Á. Regression Analysis to Evaluate the Reliability of Insulation Diagnostic Methods. **Journal of Electrostatics**, v. 71, n. 3, p. 564–567, 2013.

TEIXEIRA, I. R. et al. Teores de nutrientes e qualidade fisiológica de sementes de feijão em resposta à adubação foliar com manganês e zinco. **Bragantia**, v. 64, n. 1, p. 83–88, 2005.

TRIBOUILLOIS, H. et al. Modelling Agroecosystem Nitrogen Functions Provided by Cover Crop Species in Bispecific Mixtures Using Functional Traits and Environmental Factors. **Agriculture, Ecosystems & Environment**, v. 207, p. 218–228, 2015.

TRIBOUILLOIS, H.; CONSTANTIN, J.; JUSTES, E. Analysis and Modeling of Cover Crop Emergence: Accuracy of a Static Model and the Dynamic STICS Soil-Crop Model. **European Journal of Agronomy**, v. 93, p. 73–81, 2018.

TRINDADE, J. da S. et al. Produtividade do milho em três densidades de semeadura e duas alturas de corte. **Ciência Animal Brasileira**, v. 18, p. 1–10, 2017.

XU, R.; WUNSCHII, D. Survey of Clustering Algorithms. **IEEE Transactions on Neural Networks**, v. 16, n. 3, p. 645–678, 2005.

YAMANISHI, J. et al. Multivariate Analysis for Scanning Tunneling Spectroscopy Data. **Applied Surface Science**, v. 428, p. 186–190, 2018.

ZADEH, L. A. Fuzzy Sets. **Information and Control**, v. 8, p. 338–353, 1965.

ZHAO, Y.; MENG, X.; YANG, H. Jackknife Empirical Likelihood Inference for the Mean Absolute Deviation. **Computational Statistics & Data Analysis**, v. 91, p. 92–101, 2015.