

**UNIVERSIDADE FEDERAL DE SANTA MARIA
COLÉGIO POLITÉCNICO DA UFSM
PROGRAMA DE PÓS-GRADUAÇÃO EM AGRICULTURA DE PRECISÃO**

Márcio da Silva Santos

**ANÁLISE EXPLORATÓRIA DA CORRELAÇÃO ENTRE
ESPECTRORRADIOMETRO DE CAMPO E VARIÁVEIS DE SOLO E
PLANTA EM VINHEDO.**

**Santa Maria, RS
2019**

Márcio da Silva Santos

**ANÁLISE EXPLORATÓRIA DA CORRELAÇÃO ENTRE
ESPECTRORRADIOMETRO DE CAMPO E VARIÁVEIS DE SOLO E
PLANTA EM VINHEDO.**

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura de Precisão, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Mestre em Agricultura de Precisão**.

Orientador: Prof. Dr. Elódio Sebem

Santa Maria, RS
2019

Santos, Márcio da Silva

Análise exploratória da correlação entre
espectrorradiômetro de campo e variáveis de solo e planta em
vinhedo / Márcio da Silva Santos.- 2019.

124 p.; 30 cm

Orientador: Elódio Sebem

Coorientador: Luciano Gebler

Dissertação (mestrado) - Universidade Federal de Santa
Maria, Colégio Politécnico, Programa de Pós-Graduação em
Agricultura de Precisão, RS, 2019

1. Índices de Vegetação 2. Agricultura de Precisão 3.
Sensoriamento Remoto I. Sebem, Elódio II. Gebler, Luciano
III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

©2019

Todos os direitos autorais reservados a Márcio da Silva Santos. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.

Endereço: Rua Pedro Santana nº164, Bairro Centro, Jaguarari, BA. CEP 49960-000

Fone: (0xx) 74 99993-2088 E-mail: geoprural@gmail.com

Márcio da Silva Santos

**ANÁLISE EXPLORATÓRIA DA CORRELAÇÃO ENTRE
ESPECTRORRADIOMETRO DE CAMPO E VARIÁVEIS DE SOLO E
PLANTA EM VINHEDO.**

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura de Precisão, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Mestre em Agricultura de Precisão**.

Aprovado em 26 de agosto de 2019.

**Elódio Sebem, Dr. (UFSM/IFSC)
(Presidente/Orientador)**

Amanda Heemann Junges, Dra. (DDPA/SEAPDR)

Márcio Eduardo Boeira Bueno, Dr. (UCS)

Santa Maria, RS
2019

"Às vezes, são as pessoas que ninguém espera nada, que fazem as coisas que ninguém consegue imaginar."

(Alan Mathison Turing; O Jogo da Imitação, 2014.)

AGRADECIMENTOS

Meu profundo agradecimento primeiramente a DEUS e as pessoas que me ajudaram na elaboração desta dissertação de mestrado e em especial:

Ao Prof. Dr. Elódio Sebem que gentilmente me orientou neste trabalho a quem me concedeu a sua confiança para orientação.

Ao Dr. Luciano Gebler que gentilmente aceitou o convite de co-orientação e emitiu suas opiniões para a sua melhoria, sem esquecer-me de fazer menção a Embrapa Uva e Vinho-Vacaria, pelo suporte e apoio nos trabalhos de campo.

Ao Engenheiro agrônomo Ermano Varaschin por possibilitar a pesquisa em seus vinhedos e pelo apoio nos trabalhos de campo.

Agradeço à minha família que é minha base, meu alicerce, meu porto seguro e meu espelho. Muito obrigado a minha mãe Vera Lúcia, pelo apoio, confiança e motivação incondicional, sem ela nada disso seria possível. Ao meu pai Maurício, pelo exemplo e inspiração, e por último a minha filha Mércia Mirella, pela sua compreensão e paciência em todos os momentos, a eles ofereço esta conquista. Sem vocês nenhuma conquista valeria a pena.

RESUMO

ANÁLISE EXPLORATÓRIA DA CORRELAÇÃO ENTRE ESPECTRORRADIOMETRO DE CAMPO E VARIÁVEIS DE SOLO E PLANTA EM VINHEDO

AUTOR: Márcio da Silva Santos

ORIENTADOR: Elódio Sebem

O objetivo deste trabalho foi avaliar a substituição de procedimentos convencionais de análise de laboratório físico-químico de parâmetros agrônômicos na vitivinicultura por técnicas de sensoriamento remoto através da sua correlação com as variáveis biológicas e atributos agrônômicos de solo em plantio de *Vitis vinifera* L. Foi estabelecida uma malha amostral com 74 pontos. Para as leituras de reflectâncias utilizou-se o espectrorradiômetro portátil *FieldSpec Hand Held 2* e foram calculados 17 índices de vegetação (IV) (SR, NDVI, mNDVI, SGR, RGR, NPCI, SRPI, NPQI, SIPI, PI1, PI2, PI3, EVI, PRI, PSRI, PWI e ARI), em dois métodos de leituras no campo, por clipagem na folha (*leaf clip*) (CP) e por sensoriamento proximal (SP). Os IV foram relacionados por meio do coeficiente de correlação de Pearson, ao nível de 5%, com as variáveis de condutividade elétrica aparente (CEa), química e física do solo, análise química do tecido vegetal, parâmetros enológicos e fitotécnicos. Com base nas correlações obtidas foi possível afirmar que a utilização de IV em substituição à análises físico/química de parâmetros agrônômicos é viável, desde que atinjam, no mínimo, um coeficiente de correlação com magnitude moderada, onde encontramos 36 coeficientes moderadas. Os IV e as variáveis de solo analisadas que apresentaram os maiores coeficiente de correlação por Pearson e magnitudes pelo menos moderadas para a profundidade de 0-20cm foram mNDVI-SP com a CTC Efetiva (0,508), SR-SP com a CTC pH 7,0 (0,534), RGR-SP com o K (-0,447), NPQI-SP com Cu(-0,472), PI1-SP com K(0,546), PI2-SP com a CTC pH 7,0 (-0,545), e o PRI-CP, que apresentou correlação tanto com a CTC pH 7,0 (0,572), bem como com o K (-0,565). Já para a profundidade de 20-40 cm obtivemos apenas o mNDVI-CP com o K (-0,534). Para a relação entre IV e as variáveis do tecido vegetal os melhores resultados foram ARI-CP com B (-0,402), PI3-SP com o K (-0,506) e ARI-SP com o K (0,566).

Palavras-chave: Índices de Vegetação. Agricultura de Precisão. Sensoriamento Remoto.

ABSTRACT

RELATIONS BETWEEN REMOTE SENSING, SOIL AND PRECISION HORTICULTURE VARIABLES

AUTHOR: Márcio da Silva Santos
ADVISER: Elódio Sebem

The objective of this work was to evaluate the replacement of conventional procedures of physical-chemical laboratory analysis of agronomic parameters in viticulture by remote sensing techniques through their correlation with biological variables and agronomic attributes of *Vitis vinifera* L. A sample grid with 74 points on 3 ha of vines was established. For reflectance readings, the FieldSpec Hand Held 2 portable spectrometer was used and 17 vegetation indices (VI) (SR, NDVI, mNDVI, SGR, RGR, NPCI, SRPI, NPQI, SIPI, PI1, PI2, PI3, EVI, PRI, PSRI, PWI e ARI) were calculated, in two field reading methods, by leaf clip (CP) and by proximal sensing (SP). The VI were related by Pearson's correlation coefficient, at 5% level, with the variables of apparent electrical conductivity (ECa), soil chemistry and physics, chemical analysis of plant tissue, oenological and phytotechnical parameters. Based on the obtained correlations it was possible to affirm that the use of IV instead of the physical / chemical analysis of agronomic parameters is viable, provided that they reach at least one correlation coefficient with moderate magnitude, where we found 36 moderate coefficients. The VI and the analyzed soil variables that presented the highest Pearson correlation coefficient and at least moderate magnitudes for the 0-20cm depth were mNDVI-SP with Effective CTC (0.508), SR-SP with CTC pH 7,0 (0.534), RGR-SP with K (-0.447), NPQI-SP with Cu (-0.472), P1-SP with K (0.546), PI2-SP with CTC pH 7.0 (-0.545), and PRI-CP which correlated with both CTC pH 7.0 (0.572) as well as K (-0.565). Already for the depth of 20-40 cm we obtained only the mNDVI-CP with the K (-0.534). For the relationship between IV and plant tissue variables the best results were ARI-CP with B (-0.402), PI3-SP with K (-0.506) and ARI-SP with K (0.566).

Keywords: Vegetation Indexes. Precision Agriculture. Remote Sensing.

LISTA DE ILUSTRAÇÕES

Figura 1 - Área de Reflectância (ρ) espectral característica de uma folha vegetal sadia, para o intervalo de comprimento de onda (λ) entre 0,3 e 2,5 μm	26
Figura 2 - Área de Estudo.....	44
Figura 3 - Malha de amostragem de solo com 74 pontos georreferenciado.....	46
Figura 4 - Georreferenciamento dos pontos amostrais.....	46
Figura 5 - Coleta de solo no campo com trado holandês (A) e Amostras de solo armazenada e identificadas (B).....	47
Figura 6 - Coleta de solo (A); Trado rosca (B) e Armazenamento do solo em sacos plásticos (C).....	48
Figura 7 - Condutivímetro de Condutividade Elétrica Aparente (CEa).....	48
Figura 8 - Coleta do tecido vegetal (a) e amostras secas para análise (b).....	49
Figura 9 - Leituras em campo com o expectroradiômetro portátil FieldSpec Hand Held 2, onde acessório (<i>leaf clip</i>) - CP (A) e Leitura óptica do sensor - SP (B).....	51
Figura 10 - Método de contabilidade dos cachos (A) e pesagem das plantas (B)....	53
Figura 11 - Refratômetro digital portátil (A) e Medidor de pH de bancada (B).....	55
Figura 12 – Assinaturas espectrais médias por métodos de leituras de refletâncias	70
Figura 13 – Médias das assinaturas espectrais por clipagem nas folhas – CP.....	72
Figura 14 – Média das assinaturas espectrais por sensoriamento próximo do dossel - SP.....	72
Figura 15 – Mapa de prescrição do índice de vegetação mNDVI-CP (A) e da variável K da análise química do solo 20-40 cm (B).....	77
Figura 16 - Diagrama de dispersão entre o índice de vegetação mNDVI-CP e a variável K da análise química do solo (20-40 cm).....	77
Figura 17 – Mapa de prescrição do índice de vegetação EVI-CP (A), variável Argila 20-40 cm (B) e Silte 20-40 cm da análise física do solo (C).....	78
Figura 18 - Diagrama de dispersão entre o índice de vegetação EVI-CP e o atributo Argila 20-40 cm (A) e Silte 20-40 cm (B) da análise física do solo.....	79
Figura 19 – Mapa de prescrição do índice de vegetação PRI-CP (A), variável CTC pH 7,0 0-20 cm (B) e K 0-20 cm da análise química do solo (C).....	80
Figura 20 - Diagrama de dispersão entre o IV PRI-CP e as variáveis CTC pH 7,0 0-20 cm (A) e Potássio 0-20 cm (B) da análise química do solo.....	80
Figura 21 – Mapa de prescrição do índice de vegetação ARI-CP (A) e a variável Boro da análise química do tecido vegetal (B).....	81
Figura 22 - Diagrama de dispersão entre o índice de vegetação ARI-CP e a variável Boro da análise química do tecido vegetal.....	82
Figura 23 - Mapa de prescrição do índice de vegetação SR – SP (A) e a variável CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo (B).....	83
Figura 24 - Diagrama de dispersão entre o índice de vegetação SR - SP e a variável o CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo.....	83

Figura 25 – Mapas de prescrição do índice de vegetação mNDVI-SP (A) e a variável CTC Efetiva na profundidade de 0-20 cm da análise química do solo (B).....	84
Figura 26 - Diagrama de dispersão entre o índice de vegetação mNDVI-SP e a variável CTC Efetiva na profundidade de 0-20 cm da análise química do solo.....	85
Figura 27 – Mapa de prescrição do índice de vegetação RGR-SP (A) e a variável K na profundidade de 0-20 cm da análise química do solo (B).....	86
Figura 28 - Diagrama de dispersão entre o índice de vegetação RGR-SP e a variável K na profundidade de 0-20 cm da análise química do solo.....	86
Figura 29 – Mapa de prescrição do índice de vegetação NPQI-SP (A) e a variável Cobre na profundidade de 0-20 cm da análise química do solo (B).....	87
Figura 30 - Diagrama de dispersão entre o índice de vegetação NPQI-SP e a variável Cobre na profundidade de 0-20 cm da análise química do solo.....	87
Figura 31 - Mapa de prescrição do índice de vegetação PI1-SP (A) e a variável K na profundidade de 0-20 cm da análise química do solo (B).....	88
Figura 32 - Diagrama de dispersão entre o índice de vegetação PI1-SP e a variável K na profundidade de 0-20 cm da análise química do solo.....	89
Figura 33 – Mapa de prescrição do índice de vegetação PI2-SP (A) e a variável CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo (B).....	90
Figura 34 - Diagrama de dispersão entre o índice de vegetação PI2-SP e a variável CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo.....	90
Figura 35 – Mapa de prescrição do índice de vegetação PI3-SP (A) e a variável K da análise química do tecido vegetal (B).....	91
Figura 36 - Diagrama de dispersão entre o índice de vegetação PI3-SP e a variável K da análise química do tecido vegetal.....	91
Figura 37 - Mapa de prescrição do índice de vegetação ARI-SP (A) e a variável K da análise química do tecido vegetal (B).....	92
Figura 38 - Diagrama de dispersão entre o índice de vegetação ARI-SP e a variável K da análise química do tecido vegetal.....	93
Figura 39 - Semivariogramas das variáveis da análise de tecido vegetal interpolados pelo método da krigagem: A) Nitrogênio; B) Potássio.....	95
Figura 40 - Semivariogramas dos índices de vegetação interpolados pelo método da krigagem: A) mNDVI-CP; B) EVI-CP; C) ARI-CP; D) mNDVI-SP e E) RGR-SP.....	97
Figura 41 - Semivariogramas das análises física do solo interpolados pelo método da krigagem: A) Umidade (g/g) de 0-20 cm e B) Umidade (g/g) de 20-40 cm.....	101
Figura 42 - Validação Cruzada na interpolação por krigagem para as variáveis: A) Nitrogênio do Tecido Vegetal; B) Potássio no Tecido Vegetal; C) mNDVI-CP; D) EVI-CP; E) ARI-CP; F) mNDVI-SP; G) RGR-SP; H) Umidade do Solo de 0-20 cm e I) Umidade do Solo de 20-40 cm.....	103

LISTA DE TABELAS

Tabela 1 - Estatística descritiva das variáveis químicas do solo.....	58
Tabela 2 - Teste das amostras independentes (Teste t student) das médias aritméticas das variáveis da análise química do solo na profundidade de amostragem de 0-20 e 20-40 cm.....	61
Tabela 3 - Estatística descritiva dos parâmetros fitotécnicos e enológicos.....	62
Tabela 4 - Faixas de recomendação enológica para elaboração de vinhos finos.....	64
Tabela 5 - Estatística descritiva da análise física do solo.....	65
Tabela 6 - Estatística descritiva da análise química do tecido vegetal.....	67
Tabela 7 - Estatística descritiva das variáveis dos índices de vegetação.....	68
Tabela 8 - Estatística descritiva da análise de condutividade elétrica aparente (CEa).....	69
Tabela 9 - Teste não paramétrico de dependência (Kolmogorov-Smirnov).....	74
Tabela 10 - Correlação linear de Person (r) entre IV's e variáveis do tecido vegetal.....	75
Tabela 11 - Correlação linear de Person (r) entre IV's e variáveis físicas do solo.....	75
Tabela 12 - Correlação linear de Person (r) entre IV's e variáveis químicas do solo.....	76
Tabela 13 - Ajuste dos modelos dos semivariogramas da análise de tecido vegetal.....	94
Tabela 14 - Ajuste dos modelos dos semivariogramas da análise de tecido vegetal.....	96
Tabela 15 - Ajuste dos modelos dos semivariogramas das variáveis químicas do solo.....	99
Tabela 16 - Ajuste dos modelos dos semivariogramas das variáveis físicas do solo.....	101
Tabela 17 - Parâmetros da Validação cruzada das estimativas.....	104

LISTA DE ABREVIATURAS E SIGLAS

a	Alcance
Al	Alumínio
AP	Agricultura de Precisão
ARI	Índice de Reflectância de Antocianinas
AT	Acidez Titulável em Ácido Orgânico
B	Boro
BBCH 75	Estádio fenológico
Ca	Cálcio
CEa	Condutividade Elétrica aparente
Co	Efeito Pepita
Co + C	Patamar
CP	Com Probe
CTC Efet.	Capacidade de Troca de Cátion Efetiva
CTC pH 7,0	Capacidade de Troca de Cátion em pH 7,0
Cu	Cobre
CV%	Coefficiente de Variação
DE	Dependência Espacial
EVI	Enhanced Vegetation Index
Fe	Ferro
GPS/GNSS	Global Navigation Satellite System
H ₂ O	Água
IAF	Índice de Área Foliar
IDE	Índice de Dependência Espacial
IDW	Inverso da Distância
IV's	Índices de Vegetação
K	Potássio
K ₂ O	Óxido de Potássio
Mg	Magnésio
MgO	Óxido de magnésio
mNDVI	Índice de Vegetação de Diferença Normalizada Melhorado
MO	Matéria Orgânica
N	Nitrogênio
NDVI	Normalized Difference Vegetation Index
NO ₃ -	Nitrato
NPCI	Índice de Vegetação de Pigmentos Normalizado
NPQI	Normalized Phaeophytinization Index
P	Fósforo
PCD	Plant Cell Density
pH	Potencial Hidrogeniônico
PI ₂	Índice de Pigmentos 2
PI ₃	Índice de Pigmentos 3
PL1	Pigment Index
PRI	Photochemical Reflectance Index
PSRI	Índice de Reflectância de Plantas Senescentes
PWI	Índice de Água na Planta
RGR	Red/Green Ratio
S	Enxofre

SGR	Soma da Reflectância no Verde
SIPI	Índice de Pigmentos de Intensiva Estrutura
SP	Sem Probe
SQR	Soma de quadrados de resíduos
SR	Sensoriamento Remoto
SR	Simple Ratio
SRPI	Índice da Razão Simples de Pigmentos
SS	Sólidos Solúveis
SWIR	Infravermelho Onda Curta
VANTs	Veículos Aéreos não Tripuláveis
VNIR	Infravermelho Próximo
VP	Viticultura de Precisão
Zn	Zinco

SUMÁRIO

1 INTRODUÇÃO.....	15
2 REFERENCIAL TEÓRICO.....	17
2.1 Viticultura no Rio Grande do Sul.....	17
2.2 Viticultura de Precisão.....	19
2.3 Contribuições da Agricultura de Precisão na Vitivinicultura.....	20
2.4 Sensoriamento na Vitivinicultura de Precisão.....	22
2.5 Comportamentos espectral do tecido vegetal.....	24
2.6 Comportamentos espectrais em videiras e a sua representação por índices...27	
2.7 Espectrorradiometria em alternativa a análise de laboratorial.....	31
2.8 Análises geoestatística e variáveis regionalizadas.....	33
2.9 Estatística descritiva.....	37
2.10 Amostras de Solo e Análise Química.....	38
2.11 Condutividade elétrica aparente do solo.....	41
2.12 Análise química do tecido vegetal.....	41
2.13 Composição química do mosto da uva.....	42
3 MATERIAL E MÉTODOS.....	44
3.1 Caracterização da área de pesquisa.....	44
3.2. Métodos.....	45
3.2.1 Delimitação da área.....	45
3.2.2 Procedimentos de coleta e análise de solos.....	47
3.2.3 Leituras da condutividade elétrica aparente do solo.....	48
3.2.4 Análise química do tecido vegetal.....	49
3.2.5 Leituras da reflectância in situ e cálculo dos índices de vegetação.....	50
3.2.6 Parâmetros fitotécnicos.....	51
3.2.7 Procedimentos para análise dos parâmetros enológicos.....	53
3.2.8 Análise dos dados: estatística descritiva e geoestatística.....	55
4 RESULTADOS E DISCUSSÃO.....	57
4.1 Estatística Descritiva.....	57
4.1.1 Variáveis da Análise Química do Solo.....	57
4.1.2 Parâmetros Fitotécnicos e Enológicos.....	62
4.1.3 Análise física do solo.....	64
4.1.4 Análise Química do Tecido Vegetal.....	66
4.1.5 Análise dos Índices de Vegetação.....	68
4.1.6 Análise da condutividade elétrica aparente.....	69
4.2 Assinaturas espectrais dos alvos em estudo.....	70
4.3 Teste não paramétrico de normalidade (Kolmogorov-Smirnov).....	73
4.4 Correlação linear simples por Pearson (r).....	74
4.4.1 Índice mNDVI-CP.....	76
4.4.2 Índice EVI-CP.....	78

4.4.3 Índice PRI-CP.....	79
4.4.4 Índice ARI-CP.....	81
4.4.5 Índice SR-SP.....	82
4.4.6 Índice mNDVI-SP.....	84
4.4.7 Índice RGR-SP.....	85
4.4.8 Índice NPQI-SP.....	86
4.4.9 Índice PI1-SP.....	88
4.4.10 Índice PI2-SP.....	89
4.4.11 Índice PI3-SP.....	90
4.4.12 Índice ARI-SP.....	92
4.5 Análise variográfica das variáveis dos parâmetros agronômicos.....	93
4.5.1 Análise variográfica do tecido vegetal.....	94
4.5.2 Análise variográfica dos índices de vegetação.....	95
4.5.3 Análise variográfica química do solo.....	98
4.5.4 Análise variográfica da física do solo.....	101
4.6 Validação Cruzada.....	102
5 CONCLUSÕES.....	105
REFERÊNCIAS BIBLIOGRÁFICAS.....	107
ANEXO	

1 INTRODUÇÃO

As futuras gerações de sensores remotos deverão facilitar o desenvolvimento de um leque ainda maior de aplicações, na medida em que cresce o interesse na área da agricultura de precisão, principalmente na demanda destes instrumentos acoplados em máquinas e implementos de solo. O crescimento e progresso da tecnologia de sensores deverão ampliar significativamente as capacidades de aquisições rotineiras de dados num amplo leque de escalas espaciais e temporais.

É possível vislumbrar que a aplicação do sensoriamento remoto hiperespectral proximal ou distal, para estudos relacionados com a vegetação agrícola, permitirá o monitoramento de variáveis importantes das culturas, incluindo os estresses (causados por água, insetos ou poluição, entre outros), a produção agrícola, a produtividade, o volume de sequestro de carbono, a fenologia, a maturação das culturas, dentre outros.

O sensoriamento remoto é considerado uma ferramenta indispensável que pode amplificar significativamente a eficácia dos métodos tradicionais de monitoramento do meio ambiente, em razão de sua capacidade em cobrir grandes áreas e ser utilizados conforme as necessidades informacionais dos usuários, fornecendo as informações espaciais e temporais necessárias para o manejo sustentável. Vários avanços tecnológicos associados à diminuição de custos dos equipamentos e melhoria em resoluções e qualidade dos dados têm sido obtidos nas últimas décadas.

Associado ao sensoriamento, o potencial da aplicação dos índices de vegetação para agricultura é vasto em razão da capacidade de avaliação rápida da quantidade e condições das plantas em extensas áreas, repetidamente caso necessário, com fundamentação física e vinculação às respostas reais da cultura no campo, por apresentarem correlações entre a radiação solar e os tecidos fotossinteticamente ativos das plantas. Esses índices podem ser de grande utilidade para a estimativa de variáveis biofísicas como a produtividade, a porcentagem de cobertura verde sobre o solo, a fitomassa, o índice de área foliar (IAF), o conteúdo de água e de componente bioquímicos e a fração da radiação fotossinteticamente ativa, além de permitir a ampliação da capacidade de um manejo mais otimizado e sustentável dos vinhedos.

A exequibilidade desta pesquisa foi testada em um vinhedo comercial, destinado à fabricação de vinhos e espumantes, por meio de análises obtidas da condutividade elétrica aparente, química e física do solo nas profundidades de 0-20 e de 20-40 cm, análises químicas do tecido vegetal e dos principais parâmetros enológicos: Sólidos Solúveis Totais (SST) e Acidez Total Titulável em ácido orgânico (ATT), parâmetros fitotécnicos (produtividade, produção, massa fresca), além das leituras espectrais dos índices de vegetação.

Pesquisas indicam que as técnicas de sensoriamento remoto proximal apresentam eficiência em estabelecer correlações entre as variáveis agrônomicas e enológicas obtidas por procedimentos convencionais, corroborando na tomada de decisão cada vez mais rápida e eficiente.

Justifica-se a realização deste trabalho pelo grande potencial das técnicas de Viticultura de Precisão na identificação de várias características essenciais para otimização dos recursos aplicados na produção agrícola. Para este setor produtivo, pesquisas e trabalhos visando à sustentabilidade ambiental, economia de insumos e aumento de produtividade, são cada vez mais necessários e pertinentes.

O objetivo geral: Avaliar a substituição de procedimentos convencionais de análise de laboratório físico-químico de parâmetros agrônomicos na vitivinicultura por técnicas de sensoriamento remoto através da correlação das variáveis biológicas e atributos agrônomicos de solo em vinhedo de *Vitis vinifera L.* no estágio fenológico BBCH 75.

1) Identificar os melhores índices de vegetação para *Vitis vinifera L.* no estágio fenológico BBCH 75 correlacionados com atributos agrônomicos obtidos em campo;

2) Propor a substituição de procedimentos de coleta de amostras convencionais em campo e de análises de laboratório pelos índices de vegetação.

2 REFERENCIAL TEÓRICO

2.1 Viticultura no Rio Grande do Sul

Segundo a lei nº 10.970, de 12 de novembro de 2004 e regulamentada pelo Decreto nº 8.198, de 20 de fevereiro de 2004, vinho é a bebida obtida pela fermentação alcoólica do mosto simples da uva sã, fresca e madura. Quanto à classe, os vinhos são classificados como de mesa, leve, fino, espumantes, frisante, gaseificado, licoroso e composto (VANZELA et al., 2015).

O setor brasileiro de vinho apresenta uma característica marcante que o distingue de outros mercados; enquanto o mercado estrangeiro aceita somente produtos originários das variedades europeias (*V. vinifera*), no Brasil, também são aceitos produtos originários das variedades americanas (*V. labrusca* e *V. bourquina*) e híbridos (ULIANA, M. R. et al., 2015)

De acordo com Lovatel (2002), os vinhos finos são produzidos com as uvas de origem européia (*vitis viníferas*), que agregam maior valor unitário e produzem vinhos de qualidade superior.

Na última década, o setor vitivinícola brasileiro tem se destacado no mercado interno e externo, devido a excelência de seus produtos. Um exemplo disso é a categoria de vinhos espumantes, que tem conquistado numerosas premiações em diversos concursos e avaliações internacionais (ABE - Associação Brasileira de Enólogos, 2017). Com vistas à expansão do setor vitivinícola brasileiro, muitas empresas têm investido no aumento da produção de vinhos e na busca de novas áreas propícias para implantação de vinhedos.

As regiões vitivinícolas do estado do Rio Grande do Sul são as grandes produtoras de vinhos finos do Brasil, graças às suas condições ambientais e climáticas benéficas ao cultivo de *Vitis vinifera*, abrangendo 64,4% da área cultivada no país e responsável por 90% da produção de vinhos, sucos e demais derivados (IBGE – Instituto Brasileiro de Geografia, 2018). Entre os fatores determinantes para qualidade do vinho destacam-se as variedades e a tecnologia utilizada na produção (CAMARGO, 2003).

Já Protas e Camargo, (2010) afirmavam que muitos fatores influenciam negativamente a qualidade da uva produzida na região da Serra Gaúcha, principal polo vitivinícola do país, como a falta de sanidade do material vegetativo utilizado na

implantação dos vinhedos, a utilização de variedades inadequadas e a falta de organização setorial e, além disso, a qualidade das uvas viníferas produzidas nessa região para a fabricação de vinhos e espumantes, apresenta potencial enológico inferior a países como Chile, Argentina, Itália, França, Portugal, Austrália, Espanha, dentre outros países de clima temperado, concorrentes no mercados de vinho mundial.

Miele et al., (2011), ressalta que a produção e a comercialização dos vinhos finos brasileiros sofrem grande concorrência de produtos importados, especialmente de países da América do Sul e Europa. Mesmo assim, Protas e Camargo, (2010) afirmam que, apesar da dificuldade climática, o Brasil ainda tem sido reconhecido nos cenários interno e externo como produtor de vinhos finos de qualidade e que a melhoria da matéria prima, a racionalização dos custos de produção são fatores primordiais para o aumento da competitividade dos vinhos nacionais.

De acordo com a classificação do IBGE o estado possui 28 microrregiões com produção comercial de uvas, sendo as microrregiões de Caxias do Sul, Vacaria, Guaporé e da Campanha Central, responsáveis por 91,68% da área cultivada (COPELLO, 2015).

O cultivo da videira tem grande importância econômica e social em decorrência do grande número de famílias envolvidas com a atividade nas diversas regiões produtoras do estado do Rio Grande do Sul. A maioria destas famílias, são proprietárias de pequenas áreas e utilizam a mão de obra familiar para realizar as atividades nos vinhedos, sendo que a área média ocupada pela cultura da videira nas propriedades é de 2,5 ha, geralmente localizada em relevo acidentado (PROTAS e CAMARGO, 2010).

Com o intuito de abrandar esse panorama, nota-se o empenho das instituições ligadas ao setor, assim como de algumas empresas líderes, na procura de uma melhor qualidade dos vinhos através da adoção de tecnologias vitícolas e enológicas modernas. Para Miele et al., (2011), as tecnologias relacionadas à Viticultura de Precisão (VP) possibilitarão soluções para o aumento e a competitividade do vinho brasileiro em relação ao importado.

2.2 Viticultura de Precisão

O emprego da Agricultura de Precisão é uma tecnologia relativamente nova no cultivo da videira, onde passa a ser especificamente denominada como Viticultura de Precisão (VP), destacando-se os trabalhos pioneiros conduzidos nos Estados Unidos (WAMPLE et al., 1998) e na Austrália (BRAMLEY e PROFFITT, 1999; PROFFITT et al., 2006). Posteriormente, foi adotada por viticultores de países vitícolas da Europa, como França e Espanha e na América do Sul (MIELE et al., 2014). A vitivinicultura de precisão está relacionada a países que apresentam alto desenvolvimento tecnológico, onde sua adoção e resultados tem trazido êxito à atividade (ESSER, 2002).

No Brasil, a Viticultura de Precisão ainda é uma tecnologia incipiente, ainda são necessárias extensas pesquisas e testes, como também é preciso desenvolver softwares, sensores de campo e equipamentos de distribuição em taxa variável (VRT) voltada a viticultura. Mesmo assim, algumas ações estão sendo desenvolvidas, onde se destacam estudos de comportamento espectral dos solos e vegetação, estudos relacionados à definição de zonas de manejo e colheita diferenciada, estudos da condutividade elétrica e o manejo diferenciado da irrigação entre outros (Molin et al., 2015).

Para Cass, (2013) o conceito de Viticultura de Precisão é análogo ao da agricultura de precisão, que busca identificar as variações dentro de um vinhedo com o objetivo de otimizar a qualidade e quantidade da produção a partir de técnicas tais como poda específica, sincronização de irrigação, aplicação de fertilizantes, dentre outras.

A adoção de tecnologias associadas à (VP) visa, em especial, identificar as zonas distintas ou homogêneas no vinhedo e quantificar o quanto essa zonas interferem no comportamento e desenvolvimento da vinha, melhorar a eficiência do uso de mão-de-obra, da irrigação e fertilização, aumentar a produção, qualidade, rentabilidade e sustentabilidade da atividade (PROFFIT et al., 2006).

Segundo Flores et al., (2011) a (VP) pode ser entendida como a gestão da variabilidade temporal e espacial das parcelas com o objetivo de melhorar o rendimento econômico da atividade, tanto pelo aumento da produtividade e/ou qualidade, como pela redução dos custos de produção e impacto ambiental. Na

prática, a viticultura de precisão envolve sempre um preponderante componente de gestão da variabilidade espacial.

Portanto, o que diferencia a Viticultura Tradicional da Viticultura de Precisão é a compreensão da existência da variabilidade ambiental nos parreirais, que leva a adoção de técnicas específicas para zonas de cultivo homogêneas, com o objetivo de se alcançar em cada área de cultivo, a quantidade e qualidade da uva conforme previamente definido (BOMBIN, 2013).

Para Cass, (2013), as principais tecnologias adotadas atualmente na viticultura de precisão são: detecção remota realizada por meio de sensores embarcados em satélites, aviões ou VANTs (Veículos Aéreos não Tripulados), ou acoplados a equipamentos agrícolas, proporcionando dados de algum atributo das condições do vinhedo; detecção da condutividade elétrica do solo; uso de estações meteorológicas, responsáveis pelas informações relacionadas ao clima; construção de modelos digitais de elevação, que fornecem dados topográficos; técnicas de georreferenciamento; sistemas de informação geográfica, que se constituem em ferramentas digitais para análise baseada em mapas; uso de sensores de proximidade ou proximais. Esses últimos, são sensores que atuam próximo do alvo, dessa forma podem gerar dados mais precisos, sem destruição da amostra e no tempo adequado.

O uso de sistemas sensores proximais é, sem dúvida, muito importante para entender o comportamento espectral dos alvos de interesse. Segundo Moreira (2014), o fato de as medidas serem feitas a curta distância e em pequenas áreas amostrais permite que os resultados obtidos retratem, com maior fidelidade, aquilo que se quer investigar, contribuindo desta forma, para gerações de novos sistemas sensores comerciais.

2.3 Contribuições da Agricultura de Precisão na Vitivinicultura

Atualmente, com os consumidores cada vez mais informados e exigentes, em qualidade, segurança alimentar e consciência ambiental, os agricultores vêm-se obrigados a trabalhar com recursos cada vez mais controlados apostando na qualidade em detrimento da quantidade, sem se distanciar do componente econômico (SAIANDA, 2017). Ainda segundo este autor, os viticultores e enólogos sabem desde sempre que existe variabilidade nas videiras e que pela busca de um

produto diferenciado, terão que fazer um esforço adicional para promover a qualidade do seu produto final, onde a economia é cada vez mais pressionada pelos baixos custos de produção e venda.

A produção de vinhos de qualidade requer uma adequada seleção da fruta que será incorporada ao processo de vinificação. Em muitos vinhedos o ambiente de cultivo varia ostensivamente de um ponto para outro, resultando em heterogeneidade na qualidade da fruta. Os fatores que produzem esta variabilidade vão desde os elementos relativamente estáveis como a textura e a profundidade do solo, até os variáveis, como a química do solo (pH e condutividade elétrica), padrões de infestação de pragas e doenças, entre outros (MIELE et al., 2014).

Um dos problemas enfrentados pelas vinícolas está relacionado ao manejo do vinhedo, realizado de forma homogênea, sem considerar a variabilidade espacial e a existência de sítios específicos (ESSER e ORTEGA BLU, 2002). Localizar essas áreas específicas permite ajustar e otimizar o manejo de acordo com a necessidade do sítio, de forma precisa em cada ponto melhorando a qualidade da uva, incrementando o rendimento da videira e aumentando o poder de decisão que se pode obter a partir do conhecimento mais detalhado do vinhedo (SORT e UBALDE, 2019).

Matese et al.; (2013), ressaltam que no setor vinícola as novas tecnologias podem garantir uma produção de vinhos de maior qualidade, com baixos custos de operação e boas colheitas, com vistas ao máximo potencial enológico dos vinhedos.

A elevada variabilidade espacial dos atributos químicos do solo, da produtividade e dos parâmetros enológicos existentes em um vinhedo, justifica a utilização da Vitivinicultura de Precisão, podendo incrementar a eficiência da produtividade e melhorar a qualidade do mosto da uva, quando comparada ao manejo tradicional (MIELE et al., 2011). Com isto, se poderá vislumbrar a elaboração de dois vinhos diferentes, provenientes da mesma área de cultivo, permitindo-se obter preços mais favoráveis para vinhos provenientes das zonas consideradas de maior qualidade da baga, ou promover diferentes cortes na elaboração de uma composição, melhorando sua qualidade e aumentando sua competitividade em relação ao produto importado (FILIPPINI ALBA et al., 2017).

Resumindo, a Vitivinicultura de Precisão engloba um conjunto de técnicas que busca caracterizar a variabilidade espacial do crescimento vegetativo da videira, da produção da uva e sua maturação, identificando os fatores que afetam esse

processo, com o objetivo de aplicar um manejo adequado em cada zona ou parcela considerada (BOMBÍN, J. Y, 2013). Sua eficácia, no entanto, é dependente de condições como: a variação espacial da produtividade e sua estabilidade ano após ano; a identificação das causas da variabilidade e, a gestão dessas causas de forma diferenciada na parcela (BRAMLEY, R. G. V. e HAMILTON, R. P., 2004).

2.4 Sensoriamento na Vitivinicultura de Precisão

Técnicas para o monitoramento e diagnóstico de cultivos agrícolas estão em pleno desenvolvimento, possibilitando determinar o vigor vegetativo e as diferenças entre espécies de plantas através do estudo de suas características espectrais. Com o advento de novos sensores de melhor resolução espacial, temporal e radiométrica, houve um aumento significativo nas possibilidades de utilização de dados gerados por sensores remotos orbitais, aerotransportados e terrestres no estudo e monitoramento de áreas cultivadas (BOMBASSARO, M. G., 2016).

O Sensoriamento Remoto (SR) é definido como a aquisição de informação sobre alguma propriedade de um objeto ou fenômeno sem contato físico com ele (SIMONETTI e ULABY, 1983; ELACHI e ZYL, 2006). Para Slater (1980), Sensoriamento Remoto é o conjunto de atividades utilizadas para a aquisição de informações relativas aos recursos naturais da Terra, ou ao seu meio ambiente, obtidas pela análise da energia eletromagnética refletida, emitida ou retroespalhada pelos alvos, coletada por meio de sensores.

Na agricultura existem inúmeros tipos de sensores para diversos tipos de demandas. Um exemplo são os sensores proximais, que não entram em contato direto com os objetos de estudo. O princípio físico de funcionamento é o mesmo utilizado dos sensores a bordo de aeronave ou de satélites, no caso do sensoriamento remoto, sendo apenas a distância do sensor em relação ao alvo a diferença. Assim, o sensoriamento proximal destinado a aplicações mais in situ ou que exijam resolução centimétrica ou milimétrica nas imagens, ao passo que o sensoriamento remoto convencional visa a áreas extensas, com resoluções menores (FORMAGGIO e SANCHES, 2017).

Portanto, sensores proximais possuem resoluções espaciais altas à muito altas, abrangendo, em geral as faixa espectrais refletivas do visível ao infravermelho médio. Contudo, em termos de cobertura espacial, consegue-se atender a uma

amplitude muito reduzida de observação, indo de milímetros a poucos metros. Por outro lado, não há limites em relação à repetitividade temporal, pois não depende de condições nebulosidade e horário do dia, uma vez que, conforme o tipo de interesse informacional, pode-se utilizar os equipamentos de quantas vezes e quando for necessário (FORMAGGIO e SANCHES, 2017).

O aumento do conhecimento sobre a adequabilidade das diferentes cultivares de uvas frente às variações de *terroirs* constitui um benefício para os gestores vitícolas em suas tomadas de decisões, e nesta perspectiva informações advindas do Sensoriamento Remoto ajudam no acompanhamento de um vinhedo durante um ou mais ciclos vegetativos, podendo detectar variações de parâmetros de sanidade, possibilitando intervenções no manejo da videira, impedindo perdas na produção, no rendimento e na qualidade das uvas (ARRUDA, D. C., 2016).

A obtenção de informações a longa distância tem sido de grande ajuda ao produtor para futuras intervenções. Nesta perspectiva, alguns trabalhos foram elaborados para a identificação do dossel da videira e das linhas de plantio, como o desenvolvimento de métodos de mapeamento descritos por Hall et al., (2003), que identificaram as linhas de plantio da vinha, por meio do vigor do dossel em imagens de alta resolução. A identificação dos objetos e classes em imagens de satélite aportam subsídios valiosos para pesquisas voltadas ao acompanhamento do desenvolvimento da videira, correlacionando dados de refletância com dados de variabilidade espacial, permitindo um gerenciamento com impacto na qualidade final dos produtos, sejam estes in natura (uvas frescas) ou vinhos (BRAMLEY e HAMILTON, 2004; SETHURAMASAMYRAJA et al., 2010).

As características da luz refletida contêm o espectro solar e informações sobre o solo (solo nu, vegetação, corpos d'água, áreas urbanas, nuvens e outras "classes"). Dentro de cada classe, a química, a física e estruturas particulares do objeto refletor podem introduzir uma maior diferenciação. Com isto, resulta que os estudos de uso e cobertura do solo são uma das mais importantes aplicações de Sensoriamento Remoto e, neste caso, informações úteis sobre a vegetação podem ser coletadas e analisadas (PONZONI e SHIMABUKURO, 2007).

Fatores de deficiência de nutrientes e fitossanitários modificam as propriedades ópticas da folha e dossel, e alguns autores já reportaram essa sensibilidade com o uso de espectrorradiômetros. Cerovic et al.; (2012) citaram que o uso de medidas de folhas isoladas é uma alternativa não-destrutiva para analisar o

conteúdo de clorofila sem modificar a estrutura da folha. Já Smit et al.; (2010) identificaram deficiências de potássio em folhas de Cabernet Sauvignon, em comprimentos de onda existentes na faixa de “*red-edge*”.

No Brasil a Fruticultura de Precisão ainda está buscando e adequando ferramentas já utilizadas na agricultura de precisão de grãos. O emprego de algumas destas ferramentas pode auxiliar na identificação de áreas com potencial para produção de frutos com melhor qualidade, e até mesmo no entendimento dos fatores inerentes à mesma, bem como reduzir o uso de mão de obra uma vez que as ferramentas utilizadas são de fácil adaptação à mecanização (BUENO, M. E. B. et al., 2015). Os autores acrescentam que o sensoriamento remoto é uma ferramenta que pode ser utilizada para diagnósticos a campo. Suas técnicas podem ser trabalhadas através de sensores passivos orbitais ou sensores ativos proximais e permitem a obtenção de informações de forma rápida e não destrutiva.

2.5 Comportamentos espectral do tecido vegetal

A energia proveniente do sol (radiação eletromagnética) ou de sistemas ativos atinge um objeto, ocorre à interação com o alvo e a energia tende a ser fracionada em três partes: absorvida, refletida e transmitida (Molin et al., 2015). Estas interações entre radiação eletromagnética e os objetos (ou alvos), quando aplicados à vegetação, segundo Ponzoni et al., (2012), podem ser estimadas por modelos de reflectância ou refletância, pois eles procuram estabelecer uma conexão lógica entre os parâmetros biofísicos da vegetação e as suas propriedades espectrais.

No sensoriamento dedicado á AP prevalece o uso das propriedades de reflectância. Este comportamento está relacionado com as propriedades físicas das folhas. De todos os comprimentos de onda do espectro eletromagnético REM, as regiões do visível e do infravermelho próximo são as mais utilizadas para aplicações no meio agrícola (400 nm a 3.000 nm) (MOLIN et al., 2015).

Quando a radiação eletromagnética incide sobre um dossel, seja de forma direta ou difusa, está sujeita aos processos de espalhamento e absorção da energia incidente. Esses dois processos estão associados com as características do fluxo incidente (comprimento de onda e ângulo de incidência) e com a estrutura do dossel que está diretamente relacionada com o tipo, grau e desenvolvimento da vegetação (KIMES e KIRCHNER, 1983).

Segundo Moreira, M. A. (2011), cerca de 50% do total da energia que chega a planta é absorvida pelos pigmentos contidos na folha. Essa energia participa na síntese de compostos ricos em energia (fotossíntese), altera estruturas moleculares (fotoconversão), acelera reações, como a fotooxidação das xantofilas, dentre outras ações. Dos 50% restantes, uma parte da energia é refletida pelas folhas, fenômeno denominado reflexão, enquanto que outra sofre o processo de transmissão, através das camadas de folhas que compõem a copa e das estruturas que constituem a folha, como a cutícula, o parênquima lacunoso e o paliçádico.

Quanto maior a quantidade de folhas presentes no dossel, maior a reflectância da vegetação, devido ao efeito de espalhamento múltiplo entre as camadas de folhas que o compõem (BELWARD, 1991). À medida que ocorre o aumento da camada de folhas, há um maior espalhamento do fluxo, ocasionando a diminuição da reflectância no visível e no infravermelho médio e um aumento no infravermelho próximo (PONZONI e SHIMABUKURO, 2007). A reflectância espectral de folhas isoladas é ligeiramente superior daquela dos dosséis ao qual pertence, isso ocorre uma vez que no dossel a reflectância é formada pela combinação de folhas e sombra (SILVA e PONZONI, 1995).


Considerando o espectro de reflectância de uma folha verde normal no intervalo entre 400 nm e 2.500 nm pode se dividir em três regiões espectrais: visível, infravermelho próximo e infravermelho de ondas curtas (Figura 1). No visível, ou seja, entre 400 nm (azul) e 700 nm (vermelho), a reflectância é muito baixa. Em 550 nm ocorre o pico máximo no visível, isto é, uma diminuição relativa de absorção, o qual explica por que a vegetação é percebida na cor verde. Esse pico é causado por duas bandas de absorção da clorofila centradas em aproximadamente 450 nm (azul) e 650 nm (vermelho) (HOFFER, 1978).

Nas proximidades de 700 nm, na transição para a região do infravermelho próximo, começa um crescimento acentuado da reflectância. Esse ponto é denominado *red edge* ou *borda vermelha*, sendo considerado o limite entre o processo de absorção pela clorofila no vermelho e o processo de espalhamento do infravermelho próximo devido à estrutura interna das folhas (CURRRAN et al., 1991).

Na região espectral do infravermelho próximo (entre 700 nm e 1.300 nm), as folhas verdes saudáveis apresentam altos valores de reflectância (45% a 50%), alta transmitância (45% a 50%) e baixa absortância (menos de 5%), conforme Hoffer, (1978).

Já região do infravermelho de ondas curtas, segundo Bauer et al., (1980), a reflectância da vegetação verde é denominada por forte bandas de absorção pela água, que ocorrem aproximadamente em 1.400 nm, 1.900 nm e 2.700 nm; portanto as regiões entre essas bandas de absorção são fortemente influenciadas pelo conteúdo de umidade das folhas (FORMAGGIO e SANCHES, 2017). A absorção da energia eletromagnética pelo conteúdo de água na planta nesta região é geralmente baixa, causando um aumento da reflectância. A radiação espectral das folhas nessa região do espectro eletromagnético é o resultado da interação da energia incidente com a estrutura do mesófilo, e quanto mais lacunosa for a estrutura foliar interna, maior será o valor de reflectância (GATES et al., 1965).

Figura 1 - Área de Reflectância (ρ) espectral característica de uma folha vegetal sadia, para o intervalo de comprimento de onda (λ) entre 0,3 e 2,5 μm .



Fonte: NOVO, (1989).

Os sensores passivos usam a irradiação solar na realização de medidas de refletância. Eles possuem alta estabilidade em suas respostas espectrais, pois idealmente estes espectros medidos a campo têm muito pouca influência de flutuações causadas pelas atenuações atmosféricas (Manevski et al., 2012). A calibração interna de sensores passivos é realizada por uma placa de referência de Spectralon, que representa uma superfície lambertiana. Esta calibragem ocorre com a intenção de minimizar os efeitos atmosféricos na radiância, visto que a atmosfera, por causa dos fenômenos de espalhamento, absorção e refração da energia eletromagnética, afetando a radiância refletida pela superfície que é captada pelo

sensor (SANCHES et al., 2011). Os melhores horários para as medições em campos se encontram entre as 11 e 14 horas, no período de menor ângulo de inclinação solar, maior fluxo de energia radiante e condições meteorológicas adequadas, com pouco vento e céu predominantemente livre de nuvens (SENA et al., 2016). Para Lord et al., (1988), a resposta máxima de refletância na região do visível ocorre para o meio dia solar ou para azimutes relativos próximos de zero grau.

2.6 Comportamentos espectrais em videiras e a sua representação por índices

A utilização de dados provenientes de sensores hiperespectrais é cada vez mais presente na agricultura, pois cada espécie possui uma característica espectral única, determinada por sua composição química (pigmentos), morfologia e estrutura celular (ZWIGGELAAR, 1998). Em função desse fato, há a necessidade de delimitar as bandas específicas do espectro eletromagnético sensíveis a diferenciações vegetais, sejam elas relacionadas às espécies ou mesmo ao estado nutricional de plantas de mesma espécie.

Dentre as técnicas de obtenção de dados hiperespectrais, a espectrorradiometria permite detectar a resposta espectral a pequenas distâncias do alvo, o que minimiza as interferências dos fatores ambientais. Segundo Ferri et al., (2001), com o desenvolvimento do sensoriamento hiperespectral abre-se a possibilidade de identificar e quantificar pigmentos fotossintéticos individuais contidos na vegetação.

Os primeiros trabalhos desenvolvidos por Lacar et al., (2001) evidenciaram ser possível diferenciar variedades de castas viníferas, uma vez que analisaram as características espectrais de quatro variedades estabelecendo intervalos de comprimentos de onda que apresentam diferenças espectrais e podem ser detectados com espectroscopia de campo.

Utilizando as informações espectrais obtidas pelo espectrorradiômetro de mão, Brown et al., (2004) identificaram folhas de videiras com a praga da filoxera, diferenciando as folhas doentes das sadias. Neste trabalho, os autores mostraram ser possível detectar as mudanças espectrais causadas pela praga nos intervalos da radiação na região do visível. Da mesma forma, Martins et al., (2007), utilizaram

espectroradiômetro para identificar vinhas atacadas pela clorose de ferro e mapear as áreas afetadas.

Em termos do comportamento espectral da vegetação, as propriedades das folhas influenciam o espectro da planta, o qual também varia em função de cada estágio do ciclo fenológico. Em videiras, devido ao seu grande número de variedades de uvas e ao seu ciclo anual, há uma grande diversidade e variabilidade de espectros, ainda maior se for considerada uma importante variável adicional, que é o solo. Uma das mais importantes aplicações da moderna técnica de agricultura de precisão é sua extensão à viticultura, onde importantes trabalhos (Bramley et al., 2003; Hall et al., 2002) têm sido realizados, mostrando a existência de efeitos em pequena escala espacial (da ordem de poucos pixels ou dezenas de metros), devido a variações de solo ou mesmo de microclima, numa expressão do efeito de terroir (VAN LEEUWEN e SEGUIN, 2006).

A variação espacial do vigor vegetativo influencia o rendimento e a qualidade das uvas dentro de um mesmo vinhedo, alterando a produtividade e qualidade do vinho (HALL et al., 2001). Segundo Bramley e Proffitt (1999), com base em mapas da variação de produtividade é possível perceber diferenças entre parcelas dentro de um vinhedo. No entanto, quando essas distinções são investigadas entre classes vegetais semelhantes ou da mesma espécie, o processo discriminatório necessita de informações espectrais mais detalhadas.

As assinaturas espectrais da folha foram utilizadas como forma de caracterizar o estado fisiológico das plantas. O teor de clorofila relaciona-se diretamente com o potencial fotossintético e, em última análise, com a produtividade da planta (XUE et al., 2008). Os mesmos autores afirmam que como alternativa aos métodos de química analítica, que implicam a destruição da folha, podem ser desenvolvidos vários índices de vegetação que pretendem quantificar os teores de clorofila de forma precisa e não destrutiva.

As assinaturas espectrais das bagas de uva e mosto tem como potencialidade a avaliação de seus constituintes de produtos orgânicos. Liu et al.; (2008) relacionaram com sucesso as absorvâncias espectrais de peras intactas nas regiões do visível e infravermelho próximo com o seu conteúdo de sólidos solúveis. Em relação ao estudo da uva, Herrera et al.; (2003) também demonstraram ser possível determinar o conteúdo de sólidos solúveis da uva com recurso a resposta espectral de bagas inteiras.

O potencial dos IV's para agricultura é vasto em razão de propiciarem a capacidade de avaliar a quantidade e as condições das plantas em extensas áreas de modo rápido e repetível, permitindo sua aplicação em inúmeras finalidades nos diferentes segmentos da sociedade, o conhecimento das características de cada índice é importante no momento da definição do mais adequado para cada situação. Várias características da cobertura vegetal podem ser identificadas a partir dos índices de vegetação, dentre elas destacam-se: índice de área foliar (IAF), percentagem de cobertura vegetal, definição da distribuição espacial, relação entre a biomassa e os prováveis rendimentos de culturas (SEBEM, 2005).

Na Agricultura de Precisão os IV's podem ser utilizados para quantificar a variabilidade espacial das plantas de cada talão produtivo, permitindo ampliar a capacidade de um manejo mais otimizado e sustentável das lavouras (FORMAGGIO e SANCHES, 2017).

Para Miele et al., (2011) os IV's se baseiam, sobretudo, nas refletâncias espectrais de copas ou folhas de uma planta, permitindo o uso dessa ferramenta com objetivo de estabelecer diferentes zonas de manejo dentro de um mesmo vinhedo, sendo que as informações podem ser utilizadas pelo enólogo ou produtor para o planejamento da colheita segmentada o que pode, no caso da vinificação, ser útil para produção de uvas com características enológicas distintas

Os IV's se constituem em modelos matemáticos, com base na análise espectral das ondas eletromagnéticas, utilizados para diagnosticar índice de área foliar, cobertura do solo, produtividade, estado fitossanitário de culturas, cobertura vegetal, dentre outros usos (MARCUSI et al., 2010). Essas transformações matemáticas podem ser interpretadas como medidas semianalíticas da atividade da vegetação e tem sido largamente utilizadas em razão de conseguirem representar com fidedignidade variações da folhagem verde não somente em termos sazonais, mas também ao longo da superfície terrestre, com o objetivo de detectar a variabilidades especializadas.

Gamon et al., (1997) demonstraram que o *Photochemical Reflectance Index* (PRI) pode servir de indicador da atividade fotossintética entre espécies, tipos funcionais e condições de nutrição. Os IV's mais utilizados na viticultura de precisão incluem o PCD (Plant Cell Density), citado por Bramley et al.; (2003), e o NDVI (*Normalized Difference Vegetation Index*) (ARKUN et al., 2000; HALL et al., 2002).

O índice de vegetação NDVI é um dos índices mais conhecido e estudados na agricultura de precisão em razão de sua excelente resposta a variações de vigor da vegetação (MOLIN et al., 2015).

Nesse contexto, pesquisadores têm realizado estudos demonstrando a aplicabilidade dos (IV's) como parâmetro para avaliação do estado nutricional das plantas, estimativas biofísicas, conteúdo de água, componentes bioquímicos, fitomassa e ente outros. Entre os mais utilizados na agricultura se destacam:

- O índice SR (*Simple Ratio*) é obtido pela divisão dos valores referentes ao fator de reflectância do infravermelho próximo pelos valores do fator de reflectância correspondentes à região do vermelho. O índice de vegetação da razão simples foi o primeiro índice a ser utilizado para ressaltar a cobertura vegetal utilizando dados do Landsat – 1 (JENSEN, 2009).

- O índice EVI (*Enhanced Vegetation Index*) incorpora na sua equação, coeficientes de ajuste obtidos a partir de dados experimentais (SEBEM, 2005), foi desenvolvido para realçar o sinal da vegetação, buscando maior sensibilidade para locais com alta fitomassa, procurando aperfeiçoar o monitoramento da vegetação por meio da diminuição das influencia do sinal provenientes dos solos e das influencias atmosféricas (HUETE et al., 1997).

- O índice NPQI (*Normalized Phaeophytinization Index*) está correlacionado com a degradação da clorofila e a detecção precoce do estresse (ZARCO -TEJADO, 2000).

- O índice RGR (*Red/Green Ratio*) está correlacionado com as variáveis antocianinas e clorofila (FUENTES et al., 2001).

- O índice PL1 (*Pigment Index*), proposto por Fuentes et al., (2001) está correlacionado com as variáveis de estresse da planta.

- O PRI (*Photochemical reflectance Index*), proposto por Gamon, Peñuelas e Field (1992), em razão de sua consistência no relacionamento com a variável eficiência do uso da luz (*light use efficiency LUE*), tem potencial de propiciar um monitoramento contínuo da produtividade primária das plantas.

Existem numerosos IV's já desenvolvidos, a partir de dados tanto multiespectrais (banda largas) como hiperespectrais (banda estreitas). O potencial dos IV's para agricultura é vasto em razão de propiciarem a capacidade de avaliar a quantidade e as condições das plantas, em extensas áreas, de modo rápido, repetível e com fundamentação física (FORMAGGIO e SANCHES, 2017).

2.7 Espectrorradiometria em alternativa a análise de laboratorial

Para Molin et al., (2015), o usuário de Agricultura de Precisão (AP) deve usufruir do maior número de técnicas possível para identificar parâmetros do solo, como o levantamento de sua fertilidade e da variação de atributos físicos. Sendo consenso entre os pesquisadores e parte dos usuários, que a densidade amostral que vem sendo adotada comercialmente, não está sendo suficientemente densa para representar fielmente a variabilidade de alguns atributos de solo, principalmente os químicos. Porém, ao aumentar a densidade amostral consequentemente aumentam os custos, o tempo para as coletas e, muitas vezes, esse processo inviabiliza economicamente o produtor rural. Nesse aspecto, a espectrorradiometria poderá ser uma solução interessante na aplicação em AP (SUNDAR RAY, 2016).

Esses fatos tornam urgente a necessidade de pesquisas científicas para a adoção de técnicas que harmonizem maior produção com redução dos custos e menores impactos ambientais. Historicamente, nossa compreensão do sistema do solo e avaliação de suas propriedades foi obtida por meio de análises laboratoriais convencionais. Este último, embora útil e praticamente insubstituível para investigações detalhadas, é dispendioso e consome tempo, por isso não é adequado quando é necessário analisar um grande número de amostras de solo, como por exemplo na agricultura de precisão (LEONE, 2012).

A avaliação não destrutiva feitas em plantas tem recebido crescente interesse, pois proporciona várias vantagens em comparação aos métodos destrutivos tradicionais, como múltiplas medidas simultâneas e possíveis tomada de decisão em tempo real, levando em consideração a variabilidade dentro do campo (VANOLI e BUCCHERI; 2012).

Numerosos atributos físicos e químicos podem ser quantificados durante o amadurecimento do fruto, incluindo tamanho, forma, textura, firmeza, cor externa, cor interna, concentração de clorofila, teor de sólidos solúveis (SS), amido, açúcares, ácidos, óleos e concentração interna de etileno (FORMAGGIO e SANCHES, 2017).

A espectrorradiometria pode auxiliar no aumento da produção a partir da redução dos custos e do tempo dispendidos no processo tradicional de análise de solos laboratorial, inclusive o risco ambiental advindo do posterior descarte do material analisado. A economia destes ativos aumenta o volume de capital disponível para ser investido no processo produtivo. Confirmando o exposto, a

espectrorradiometria mostra-se uma alternativa não destrutiva e eficiente em termos de custo para medições em laboratório de propriedades do solo utilizando a região do visível, Infravermelho próximo e Infravermelho onda curta (VNIR/SWIR), entre 400 e 2500 nm (GOMEZ et al., 2018). Com o mesmo pensamento, Meneses et al., (2001) mencionam que a espectrorradiometria é um dos métodos não invasivo utilizados para avaliar de forma qualitativa e quantitativa propriedades físicas e químicas dos solos.

As folhas são os elementos dominantes das plantas no que se refere à influencia sobre as propriedade espectrais de dosséis vegetais. Assim, alguns autores tem publicado excelentes revisões bibliográfica sobre o comportamento espectral de folhas individuais e também de dosséis vegetais, entre os quais se pode citar Gates et al., (1965), Knippling (1970), Bauer et al., (1980) e Gausman (1985).

Existem muitos estudos realizados sobre a espectrorradiometria de solos comparando dados radiométricos com os valores determinados por análises químicas ou físicas, a exemplo, dos trabalhos de Dalmolin, (2005); Demattê, (2004; 2006; 2015); Souza Júnior et al., (2008); Dotto (2012); Cezar et al., (2012). Porém, diante da complexidade dos cálculos envolvidos para a predição dos atributos, necessitam-se cada vez mais pesquisas relacionadas a essa área.

Os espectrorradiômetros são considerados sensores não imageadores, pois o produto da leitura dos diferentes comprimentos de onda eletromagnética não se constitui em uma imagem, mas sim em uma representação gráfica ou numérica. A sua característica de atuação em intervalos bem estreitos de comprimento de onda, em uma faixa espectral de atuação que vai de 325 a 2500 nanômetros (nm), faz com que sua precisão seja considerada maior quando comparada aos demais tipos de sensores. Pesquisadores têm realizado estudos demonstrando a aplicabilidade da espectrorradiometria na diferenciação de espécies vegetais, assim como do uso de índices de vegetação como parâmetro para avaliação do estado nutricional das plantas (CLARK, 1999).

Com advento de sensores remotos hiperespectrais de campo ou de laboratório, com bandas mais estreitas, as futuras gerações de sensores deverão facilitar o desenvolvimento de um leque ainda maior de aplicações, na medida em que cresce o interesse particularmente na área da agricultura de precisão, que demanda instrumentos montados em tratores e implementos. O crescimento e o progresso da

tecnologia de sensores deverão ampliar significativamente as capacidades de aquisição rotineira de dados hiperespectrais em um grande número de dados e de forma repetitiva. Atualmente o mercado desse tipo de equipamento se expande de forma contínua disponibilizando diferentes modelos como o *Spectron SE – 590* (STEFFEN et al., 1996) e *Field Spec PRO* (MOREIRA, 2005), o primeiro atua na faixa espectral que vai de 400 a 1100 nm, enquanto o segundo atua no intervalo espectral de 350 a 2500 nm. Outro exemplo são os instrumentos das empresas *ASD Inc. FieldSpec®* e *Spectral Evolution* que trabalham com resoluções espectrais de 325 a 2.500 nm e intervalo de medição de 1 nm (FORMAGGIO e SANCHES, 2017).

2.8 Análises geoestatística e variáveis regionalizadas

O surgimento da geoestatística ocorreu na África do Sul durante os estudos sobre as concentrações de ouro. Naquela época Krige (1951), não conseguia perceber sentido nas variâncias calculadas, caso não fossem consideradas as distâncias entre as amostras estudadas (VIEIRA, 2000). Anos mais tarde Matheron (1963, 1971), propôs a Teoria das Variáveis Regionalizadas, segundo a qual, os valores verificados em um determinado local tem relação com sua distribuição espacial, dessa forma pressupõe-se que os valores verificados em um determinado ponto do espaço tem mais similaridade com pontos tomados a curtas distâncias do que comparados àqueles tomados a distâncias maiores (VIEIRA et al., 2002).

O estudo da distribuição espacial e sua variabilidade, bem como a determinação das incertezas associadas a elas são relacionados à caracterização espacial de uma determinada variável de interesse, definindo o objetivo principal da geoestatística (YAMAMOTO e LANDIN, 2013).

O semivariograma experimental ou amostral, a partir dos dados de campo, pode ser calculado a partir da metade da diferença média quadrática entre pares de dados que pertencem a certa classe de distância (lag), que compõe a distância máxima de análise, dado pela equação (1) (ISAAKS e SRIVASTAVA, 1989; VIEIRA, 1998; SOARES, 2006; YAMAMOTO e LANDIM, 2013):

$$\gamma(h) = \frac{1}{2n(h)} \sum_{i=1}^{n(h)} [Z_{(x_i)} - Z_{(x_i+h)}]^2 \quad (1)$$

Onde, $\gamma(h)$ = semivariância estimada; $n_{(h)}$ = número de pares de valores medidos para a distância h ; $Z_{(x_i)}$ = valor da variável no ponto x_i ; $Z_{(x_i+h)}$ = valor da variável no ponto x_i mais uma distância h .

O semivariograma é composto por: efeito pepita (C_0), que corresponde ao erro amostral e as microestruturas não captadas pela escala de amostragem; alcance (a), distância máxima em que as amostras apresentam-se correlacionadas espacialmente (zona de influência da amostra), e a partir do qual os dados perdem essa correlação; contribuição (C_1), variância espacialmente estruturada, dada pelo incremento de variabilidade, obtida no pareamento de dados (diferenças), mediante o aumento da distância; e patamar ($C_0 + C_1$), valor determinado a partir do alcance, onde não há acréscimo de variabilidade com o aumento da distância, caracterizando as regiões de comportamento aleatório da amostra, sendo o valor de patamar próximo ao da variância da amostra dada pela estatística clássica (VIEIRA, 1998; CAMARGO, 2001; ANDRIOTTI, 2003; LANDIM, 2003; SOARES, 2006; YAMAMOTO e LANDIM, 2013). Os modelos teóricos mais utilizados são aqueles que apresentam patamar e conforme Landim (2006) são Esférico, Exponencial e Gaussiano.

Quando o ajuste variográfico não é satisfatório opta-se por processos não estocásticos de interpolação como pode ser por meio do inverso do quadrado da distância, conforme equação (2) (MELLO et al., 2005).

$$X_p = \frac{\sum_{i=1}^n \left(\frac{1}{d_i^2} X_i \right)}{\sum_{i=1}^n \left(\frac{1}{d_i^2} \right)} \quad (2)$$

Onde: X_p : variável interpolada; X_i : valor da variável da i ésima localidade vizinha; d_i : distância euclidiana entre o i ésimo ponto de vizinhança e o ponto amostrado.

Landim (2006), afirma que a Krigagem é um processo de estimativa de valores distribuídos no espaço e/ou no tempo a partir de valores adjacentes enquanto considerados como interdependentes pelo variograma.

Para Seidel e Oliveira (2014), a dependência espacial é fundamental para revelar tanto o grau ou a magnitude da continuidade espacial de um atributo em

estudos de variabilidade espacial quanto o seu modo de variação (sua estrutura). Desta forma, conhecido o semivariograma da variável, e havendo dependência espacial entre as amostras, podem-se interpolar valores em qualquer posição no campo de estudo, sem tendência e com variância mínima (VIEIRA, 2000). Corroborando com os autores acima, Genú (2004), afirma que a krigagem tem como base os dados amostrais da variável regionalizada e as propriedades estruturais do semivariograma obtido a partir destes dados, o que permite visualizar o comportamento da variável na região através de um mapa de isolinhas ou de superfície.

Para Landim (2006) a metodologia geoestatística apresenta diversas técnicas de estimativas disponíveis e a mais usual é a krigagem ordinária. A krigagem ordinária é um método local de estimativa e, dessa forma, a estimativa em um ponto não amostrado resulta da combinação linear de valores encontrados na vizinhança próxima (YAMAMOTO e LANDIM, 2013), conforme a equação (3).

$$Z^*_{KO(x_0)} = \sum_{i=1}^n \lambda_i Z(x_i) \quad (3)$$

Onde $Z^*_{KO(x_0)}$ é o valor estimado da variável para o ponto x_0 ; λ_i a matriz de pesos obtidas do semivariograma e $Z(x_i)$ são os valores da variável dos pontos em torno ao ponto em que se está estimando.

A medida do erro associado à estimativa é que distingue o método da krigagem em relação aos demais algoritmos de interpolação e, desse modo, quando da sua aplicação sempre resultam dois mapas: um com a distribuição dos valores interpolados e outro com as variâncias, ou os desvios padrão, referentes aos valores estimados (LANDIM, 2006).

Molin et al., (2015) recomendam que esse tipo de interpolação deva ser referendada, e sugerem que a Validação Cruzada possa ser o método mais indicado pois apresenta basicamente duas finalidades: i) avaliar o melhor modelo de semivariograma e vizinhança para ser utilizado na Krigagem, ii) estimar a eficácia da krigagem. No caso da primeira finalidade, essa técnica é especialmente útil para confrontar os resultados obtidos com as diferentes funções de ajuste de semivariograma (modelos esférico, exponencial e gaussiano) e de seus parâmetros

(diferentes valores de efeito pepita, alcance e patamar). Nesse caso, a validação cruzada é executada para cada uma das diferentes modelagens, sendo que a opção com melhores resultados é selecionada para efetivamente executar a krigagem.

Molin et al., (2015) mencionam que vários parâmetros de validação cruzada podem ser analisados para identificar a eficiência do procedimento de krigagem e para avaliar os diferentes modelos de semivariograma. O mais comum e simples é plotar um gráfico dos valores preditos contra os valores reais, verificando sua correlação (valor r), inclinação da curva e intercepto.

Para medir o grau de dependência espacial da variável em estudo Cambardella et al., (1994), apresenta uma medida de dependência espacial que relaciona o Efeito Pepita com o Patamar (equação 4).

$$DE(\%) = \frac{C_0}{C_0 + C_1} \cdot 100 \quad (4)$$

Onde, $DE(\%)$ é o grau de dependência espacial em porcentagem; C_0 é o efeito pepita; e $C_0 + C_1$ é o patamar.

A classificação de Cambardella et al.; (1994), tem-se que a dependência espacial é forte, se o valor encontrado for maior que 75%; moderada, se os valores estiverem entre 25% e 75%; e fraca, se o valor for menor que 25%.

A escolha de uma grade amostral com alta densidade tem o propósito de caracterizar adequadamente a dependência espacial dos atributos e as distâncias máximas entre as amostras, baseando-se no conceito de que o número mínimo de amostras para uma boa eficiência de operação por krigagem deve ser superior a 50 pontos amostrais. Isso porque, para a construção de semivariograma confiáveis, é necessário grande número de pares de pontos (OLIVER, 2010). Segundo Molin, et al., (2015), o número mínimo de pares de pontos em cada passo não deve ser inferior a 30.

Segundo Ribeiro JR. e Diggle, (2001); Sebem (2017), quando as variáveis apresentam ausência de variância estruturada, indicam uma distribuição totalmente aleatória, não sendo possível obter superfícies interpoladas por krigagem, nesses casos, a interpolação por inverso da distância mostra-se mais recomendada. Segundo os autores, este método é utilizado para se verificar a autocorrelação espacial, observar a magnitude da correlação entre as amostras e sua similaridade

ou não, com a distância, sendo que a dependência espacial é analisada por ajustes de semivariogramas.

2.9 Estatística descritiva

Como nas técnicas estatística, a geoestatística baseia-se em um conceito probabilístico. Por tanto, para o uso apropriado da geoestatística é necessário um embasamento teórico prévio sobre os fundamentos estatísticos, possibilitando assim que se faça uma análise estatística elementar das variáveis quantitativas a serem submetidas à análise variográfica e interpolação (OLIVEIRA et al., 2015). Segundo os autores, uma análise de consistência sobre os resultado da estatística descritiva é fundamental para avaliar se a condições exigidas pelo formalismo matemático e algoritmos da geoestatística são satisfeitas pelos dados de entradas.

Para Grego et al., (2014), a etapa preliminar de análise exploratória dos dados é de suma importância e tem o objetivo de identificar previamente a normalidade de distribuição de frequência das medidas e a variação dos dados. Corroborando, Molin et al., (2015) afirmam que antes de se realizar qualquer inferência sobre os dados obtidos é necessário realizar a sua análise descritiva e exploratória, independentemente de eles terem sido coletados de forma esparsa, como a amostragem de solo em grade, ou em grande densidade, como os dados de produtividade. Para os autores, essa etapa possui duas principais finalidades: identificar erros e valores discrepantes (valores anômalos ou *outliers*) e obter um entendimento preliminar do comportamento dos dados.

Ferreira, (2014), afirma que através dos coeficientes de correlação é possível saber se duas ou mais variáveis medidas em uma mesma população tem alguma relação ou associação entre si. O mesmo autor ressalta que a identificação do grau de dependência entre duas variáveis pode ser grande auxílio à formulação de hipóteses sobre a dependência espacial entre fenômenos geográficos, ou até sobre relações causa–efeito entre os fenômenos naturais e que um dos pressupostos centrais para que essa medida seja adequadamente utilizada é de que as observações obedeçam à uma distribuição normal, variáveis contínuas, variância aproximada, linearidade da relação, homocedasticidade, entre outros.

2.10 Amostras de Solo e Análise Química

Os solos são constituídos por uma sucessão vertical de camadas horizontais resultantes da ação conjunta dos fatores e processos de formação. Essa sequência vertical é chamada de perfil do solo, que é a unidade básica para seu estudo, realizado por meio da descrição comparativa (morfologia) e análise das camadas que o constituem (análises químicas, físicas e mineralógicas) (LIMA et al., 2007), possibilitando a identificação e classificação do solo, assim como o conhecimento de suas qualidades e limitações quanto ao aspecto agrícola e ambiental.

A principal forma utilizada para avaliar a fertilidade do solo é a análise física e química, que apesar de algumas limitações metodológicas, como problemas na representatividade da amostra, na padronização de extratores químicos empregados e dos valores críticos de nutrientes estabelecidos para o solo e tecido vegetal, se apresenta como fundamental para a materialização do Sistema de Agricultura de Precisão (MOLIN et al., 2015).

A gestão localizada, diferentemente daquela aplicada na agricultura sob gestão convencional, na qual as intervenções ou as doses de insumos são empregados uniformemente na lavoura, baseado nos valores médios obtidos nas análises, difere principalmente na resolução das investigações e nos tratamentos, o que gera ações localizadas mais precisas. Os benefícios da gestão localizada podem ser enquadrados na seguinte categoria: economia de insumos, aumento de produtividade e/ ou qualidade do produto final, melhoria na qualidade das aplicações e mitigação do impacto ambiental MOLIN et al., (2015). Os autores destacam que a forma mais frequente de recomendação dos nutrientes, com exceção de nitrogênio tem sido por meio de amostragem georreferenciada do solo, e a adubação nitrogenada, pelo uso de sensores ópticos. A aplicação é feita a partir de mapas de recomendação, gerados por meios de equações que fornecem as doses de insumos demandada em cada pixel.

Conhecer inicialmente a morfologia do solo e suas características é fundamental para qualquer implantação agrícola no sentido de predizer a vocação do seu uso. No Município de Muitos Capões, os solos são formados a partir de rochas vulcânicas ácidas caracterizadas por riodacitos e riolitos, o relevo varia de suave a fortemente ondulado e a região apresenta o maior volume anual de precipitação do Estado do Rio Grande do Sul. Devido a esses fatores de formação e

por sofrerem uma intemperização intensa, os solos se apresentam ácidos e com grandes profundidades (STRECK et al., 2008).

As classe de solo que ocorrem no Município de Muitos Capões são: *Latossolos Bruno Alumínico Câmbico*, *Latossolo Vermelho Alumínico Típico*; *Latossolo Vermelho Distroférrico Típico*; *Chernossolo Argilúvico Férrico Típico* (RADAM Brasil, 1986), apresentando elevadas concentrações de caulinita e óxido de ferro, lhes conferindo baixa CTC e, portanto, uma baixa reserva de nutrientes (MUITOS CAPÕES, 2010).

Os nutrientes que merecem maior atenção no momento do planejamento de um programa de adubação, seja pela alta exigência da cultura, seja pela limitação da concentração existente nos solos são o Fósforo (P), Potássio (K), Nitrogênio (N), Cálcio (Ca), Magnésio (Mg) e Boro (B) (MELO, 2004).

Apesar dos solos brasileiros, em sua maioria, apresentarem baixos teores de fósforo (P), a prática de adubação de implantação, manutenção e produção faz com que raramente sejam observados sintomas de deficiência desse elemento em nível de campo (MALAVOLTA, 1985).

Em experimentos realizados por Srinivasan e Mullins, (1981) demonstraram que uma ótima nutrição de fósforo promoveu a fertilidade de gemas, pois deficiência de fosfatos se mostrou prejudicial à formação de inflorescências. A cultura da videira absorve aproximadamente 1,4 kg de fósforo (P) para cada tonelada de frutos produzidos (MELO, 2014).

Na maioria dos solos brasileiros o Potássio (K) se apresenta em concentrações consideradas baixas. Já nos solos do estado do Rio Grande do Sul, observa-se uma elevação gradativa dos teores de K, em decorrência da aplicação de fertilizantes (RHEINHEIMER, et al., 2001)

Srinivasan e Mullins, (1981) em seus experimentos, verificaram que a aplicação de potássio (K) em solos deficientes desse mineral causara um aumento acentuado na fertilidade de gemas, pois este nutriente é importante na ativação enzimática e na mobilização de carboidratos em videiras. Segundo Ernani (2008), para a produção de uma tonelada de frutos, são absorvidos cerca de 6 kg de óxido de Potássio (K₂O).

Giovannini (2014), afirma que o Nitrogênio (N) contido no solo é determinado pela concentração de matéria orgânica, seu excesso acarreta excessivo crescimento vegetativo, fenômeno que pode prejudicar a qualidade dos frutos e a sanidade das

videiras, porém pode aumentar a produtividade. Segundo o autor, a forma nítrica (NO_3^-) é preferencialmente absorvida pela planta e sua mobilidade é considerada alta, seu excesso pode levar a produção de cachos pequenos com acidez do mosto elevada. Todavia, em solos com excesso de nitrogênio a continuidade na aplicação deste pode resultar numa redução da fertilidade, por forte crescimento vegetativo (SRINIVASAN e MULLINS, 1981).

A maioria dos solos brasileiros apresenta deficiência natural de Cálcio (Ca), sendo necessário sua incorporação via calagem (MALAVOLTA, 1985). No estado do Rio Grande do Sul não tem ocorrido problemas devido à limitação desse elemento químico, pois as concentrações são consideradas altas, com teores acima de 4 cmolc L^{-1} . Os teores de (Ca) têm sido elevados nessas áreas em decorrência de práticas de calagem, seja no pré-plantio ou na manutenção dos vinhedos (ERNANI, 2008).

Da mesma forma que ocorre com o (Ca), a utilização da calagem tem elevado os teores de Magnésio (Mg) nos solos. Concentrações de (Mg) superiores a $1,0 \text{ mg.dm}^{-3}$ nos resultados de análises de solo podem ser consideradas altas. Já a deficiência de Mg é associada à redução da quantidade de açúcar no mosto da uva e o desequilíbrio da relação entre Mg e K faz com que haja uma maior absorção do potássio (K). Para a produção de uma tonelada de frutos é necessário aproximadamente 1 kg de óxido de magnésio MgO (MELO, 2014).

Melo (2014), aponta ainda que os valores de Boro (B) considerados satisfatórios para a cultura da videira, devem estar na faixa que vai de 0,6 a $1,0 \text{ mg.dm}^{-3}$. Apesar da pequena quantidade necessária para adequada nutrição da videira, a deficiência de B, principalmente quando associada a fatores relacionados ao clima são responsáveis por problemas de polinização.

Diversas pesquisas relacionadas à extração de nutrientes pela videira indicam que os elementos químicos extraídos em maior quantidade são o K, seguido pelo N e Ca. Nem sempre as melhores produtividades e qualidade da fruta estão relacionadas apenas aos nutrientes absorvidos em maior quantidade, sendo assim há a necessidade de busca do equilíbrio entre macro e micro nutrientes adequando seus níveis de acordo a produção e qualidade esperadas (DAL AGNOL, 2016).

2.11 Condutividade elétrica aparente do solo

A informação especializada da condutividade elétrica (CE) tem sido apontada como uma das mais valiosas para ajudar na identificação de diferenças no solo, auxiliando no entendimento da variabilidade na produção das culturas agrícolas (MOLIN et al., 2015). Pesquisas têm demonstrado correlações existentes entre a condutividade elétrica aparente do solo (CEa) e os atributos químicos e físicos do solo (MORAL et al., 2010; RODRÍGUEZ-PÉREZ et al., 2011). Devido sua praticidade e confiabilidade, a (CEa) tem sido utilizada como estimador indireto da variabilidade existente em um campo de produção (CORWIN e LESCH, 2003).

Para Molin et al., (2015) a Condutividade Elétrica (CE) pode ser definida como a habilidade que um material possui em conduzir eletricidade, tendo como unidade padrão Siemens por metro ($S.m^{-1}$). O termo condutividade elétrica aparente, surge pelo fato de que, quando são utilizados sensores e equipamentos para mensurar a (CE) no momento da avaliação de campo, a medida passa a ser aparente uma vez que diversos componentes estão sendo medidos momentaneamente.

Corwin e Lesch, (2005) demonstraram em seus estudos os seguintes tipos de medidas podem ser feitas utilizando a técnica de mensuração da condutividade elétrica aparente do solo: a) medidas diretas das propriedades do solo: salinidade e nutrientes (NO_3^-); umidade; textura (areia, argila, camadas de solo); densidade volumétrica (compactação); b) medidas indiretas das propriedades do solo: relacionada com matéria orgânica (carbono orgânico do solo, químicos orgânicos); capacidade de troca catiônica; lixiviação; estudos de mananciais de água subterrânea e classes de drenagem de solo.

2.12 Análise química do tecido vegetal

As folhas são determinantes da produção, do conteúdo de açúcares e do potencial enológico das uvas. Na videira, assim como na maioria das espécies frutíferas, o balanço entre a carga de frutas (dreno) e a área foliar adequadamente iluminada (fonte) influencia a quantidade e a qualidade da produção (SILVA, 2009). O equilíbrio entre estes dois parâmetros pode ser considerado um critério para definição da qualidade dos vinhos (GOUTOULY et al., 2006).

A análise química de tecido vegetal consiste na determinação de teores dos elementos, principalmente em folhas, resultando em diagnóstico do estado nutricional da planta, que irá permitir, por sua vez, a avaliação complementar das condições da fertilidade do solo. Este diagnóstico reflete os efeitos da interação solo-planta-clima e também do manejo, constituindo-se ferramenta importante no estabelecimento de um programa racional de adubação, que permita o adequado suprimento de nutrientes (EMBRAPA, 2015).

Com a análise das folhas e informações da literatura é possível estabelecer programas racionais de adubação para a cultura. Assim, são visíveis os reflexos na produtividade e qualidade da produção que conduzem a maior lucratividade para o produtor. Existem vários métodos de diagnose nutricional que, em função dos nutrientes e do cultivar, utilizam a análise de pecíolo, de limbos ou da folha completa (MOTOIKE e BORÉM, 2018).

A caracterização e a descrição da variabilidade espacial dos teores foliares de nutrientes e da produtividade das culturas, visando à correlação desses dados podem auxiliar no manejo de adubação, sobretudo no que se refere à aplicação localizada e em taxas variáveis de fertilizantes (VIEIRA et al., 2010).

2.13 Composição química do mosto da uva

São diversos os fatores que determinam a composição do mosto da uva, sendo que esses estão relacionados com a interação entre as práticas culturais, propriedades físicas e químicas do solo, variedade, porta-enxerto, e clima (LEEUEWEN, 2009). Além disso, segundo Giovannini, (1999) a uva é uma fruta não-climatérica que apresenta taxa de atividade respiratória baixa e não amadurece após a colheita. Portanto, deve ser colhida somente ao atingir o ponto de maturação desejado e compatível com a utilização a que se destina.

Apesar das variações, existem características específicas de comportamento climático para as diferentes regiões, em especial quando se consideram a temperatura e a quantidade de chuvas que ocorrem a cada ciclo, o que define identidade regional e características típicas para a fruta colhida e da mesma forma aos vinhos produzidos a partir dela. Esses dois fatores geralmente são determinantes para a definição da qualidade do mosto da uva, sendo que pesquisas demonstram relação entre o acúmulo de compostos fenólicos e intensidade da

coloração da uva com as variações da temperatura diária do ar e da temperatura noturna mínima (DELOIRE et al., 2005).

A composição química da uva define a qualidade dos derivados dela produzidos, apesar de não haver uniformização na concentração dos constituintes da fruta, as pesquisas demonstram que na polpa da uva encontram-se de 650 a 850 g L⁻¹ de água, 120 a 250 g L⁻¹ de açúcares redutores, de 0,5 a 1 g L⁻¹ de compostos nitrogenados, 6 a 14 g L⁻¹ de ácidos orgânicos, e 2,5 a 3,5 g L⁻¹ de substâncias minerais (HASHIZUME, 2001).

Segundo Giovaninni, (1999) os dois principais ácidos orgânicos encontrados nas uvas maduras são ácido tartárico e o ácido málico. O autor menciona que o ácido tartárico é o mais importante na fase de formação da uva, o teor do mosto é de aproximadamente de 15,0 g L⁻¹, diminuindo para 6,0 g L⁻¹ a 7,0 g L⁻¹ no período de maturação, devido principalmente à sua dissolução no mosto em função do aumento do tamanho da baga, e ele está relacionado com a temperatura e com a disponibilidade de água no solo, quanto mais frio e úmido maior é a concentração dessa substância.

O conhecimento das características básicas do mosto da uva é fator importante para a obtenção de vinhos, sucos e demais derivados de qualidade, nesse sentido os principais elementos a serem identificados para determinação do grau de maturação e as características gerais da fruta são a quantidade de sólidos solúveis totais (SST), Acidez Total Titulável e pH (LIMA, 2009). A concentração de sólidos solúveis totais fornece um indicativo da maturação da fruta, sendo que 90% desses sólidos são constituídos por açúcares fermentáveis, que tendem a aumentar gradativamente até a maturação completa da fruta (DAL AGNOL, 2016). O mesmo autor ainda destaca que a acidez, ao contrário da concentração de açúcar, diminui com a proximidade da maturação, e que o equilíbrio entre quantidade de açúcar e acidez do mosto fornece um indicativo sobre a estabilidade biológica, a cor e as características gustativas dos vinhos, sendo que os teores de ácidos normalmente encontrados nas uvas maduras variam de 5 a 10 g L⁻¹.

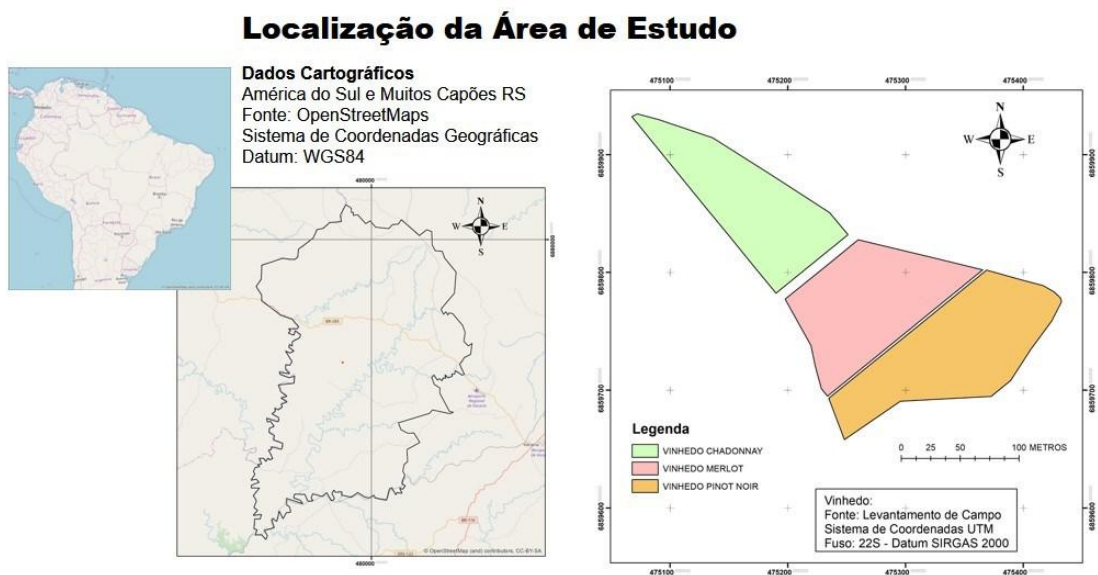
3 MATERIAL E MÉTODOS

3.1 Caracterização da área de pesquisa

A área de estudo foi composta por um vinhedo formado por três partes iguais de 1,0 ha de três variedades viníferas (*Chardonay*, *Merlot* e *Pinot Noir*), localizada na Fazenda de Ermano Varaschin - Vinhedo Entre Rios (Latitude: 28° 19' 00,56" S, Longitude: 51° 11' 02,60" O), nas proximidades da BR-285 (Zona Rural) Muito Capões – RS (Figura 1). Na propriedade são cultivadas exclusivamente variedades da espécie *Vitis Vinifera*, destinadas para a elaboração de vinhos e espumantes.

A propriedade apresenta em sua quase totalidade *Latosolos Bruno aluminico câmbico* sendo o tipo predominante na área do experimento.

Figura 2 - Área de Estudo.



Fonte: Autor.

O clima da região, segundo Köppen, é do tipo Cfb (Peel et al., 2007), com pluviosidade média anual de 1.775 mm e temperaturas médias de 16.2 °C (PEREIRA et al., 2009). O relevo se apresenta suavemente ondulado com altitudes entre 843 e 850 metros. O espaçamento de plantio adotado no vinhedo foi de 1 m entre plantas e 3 m entre linhas, sendo que a condução do vinhedo se dá sob o

sistema de espaldeira adotando o manejo de poda verde. Os técnicos responsáveis pela propriedade, seguem o cronograma de adubação do solo de manutenção, de acordo com o Manual de adubação e de calagem para os Estados do Rio Grande do Sul e de Santa Catarina / Sociedade Brasileira de Ciência do Solo, (2016).

3.2. Métodos

3.2.1 Delimitação da área

A delimitação da área de estudo foi realizada com base em um mapa georreferenciado pré-obtido da equipe da Embrapa Uva e Vinho referente ao um levantamento cadastral de pomares/vinhedos na propriedade Vinhedos Entre Rios, no dia 13/03/2017 (ANEXO 1).

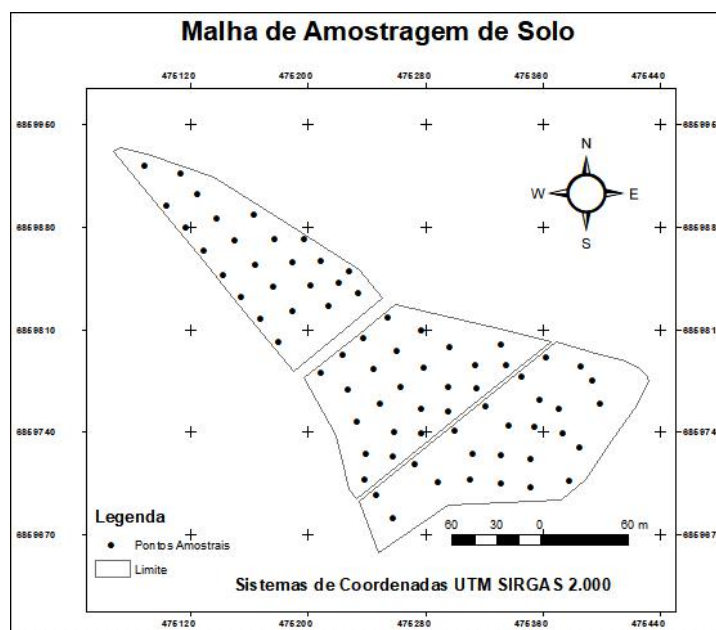
Para construção da grade amostral foi estabelecida uma malha amostral semi dirigida para cada parcela representada pela variedade plantada, com sua linha base situada na fileira de plantas, a partir da qual foram distribuídos pontos a cada 20 metros lateralmente. Para marcação dos pontos ortogonais a essa linha base, quando o ponto teórico do grid situava-se na entrelinha das plantas, sua posição era aproximada da planta mais próxima, aumentando-se ou reduzindo o raio de 20 metros, gerando, portanto, uma nova linha de pontos a cada 4-6 linhas de plantio aproximadamente (buscou-se manter uma relação de representatividade em torno de um ponto para cada 400 m²), totalizando 74 pontos amostrais nos 3 hectares da área de estudo (Figura 3).

Os softwares utilizados para a construção da malha amostral foram o ArcGIS® 10.3, software da ESRI (*Environmental Systems Research Institute*) e o editor MS Office.

A escolha da grade amostral com alta densidade para este estudo teve o propósito de caracterizar adequadamente a dependência espacial dos atributos e as distâncias máximas entre as amostras, baseando-se no número mínimo de amostras para uma boa eficiência de operação por krigagem. A alta densidade de pontos amostrais fundamenta-se no conceito de que o número mínimo de amostras para uma boa eficiência de operação por krigagem deve ser superior a 50 pontos amostrais, para a construção de semivariogramas confiáveis, são necessários no mínimo 30 números de pares de pontos (OLIVER, 2010; MOLIN et al., 2015).

No campo, com a ajuda do mapa da malha amostral a localização dos pontos amostrais foi marcada com fitas zebradas sobre o caule das videiras e posteriormente com auxílio de um receptor GPS/GNSS (RTK GR-3 FH915) foram georreferenciados (Figura 4).

Figura 3 - Malha de amostragem de solo com 74 pontos georreferenciado.



Fonte: autor.

Figura 4 - Georreferenciamento dos pontos amostrais.



Fonte: autor.

A grade amostral serviu de base para posterior análises química e física dos parâmetros de solo e dos parâmetros fitotécnicos e enológicos da planta. Vale ressaltar que os procedimentos de coleta foram semelhantes aos empregados nas amostragens convencionais, alterando-se o georreferenciamento do ponto amostral, que servirá para caracterização da variabilidade espacial do fator investigado.

3.2.2 Procedimentos de coleta e análise de solos

A coleta de solo foi realizada por amostragem simples, para cada ponto da malha amostral, utilizando-se trado holandês nas profundidades de 0-20 e 20-40 cm, de acordo com a metodologia e recomendações da Sociedade Brasileira de Ciência do Solo (2016). A coleta das amostras do solo foi realizada entre os dias 10 e 11 de julho de 2017.

As amostras de solo foram armazenadas em sacos plásticos e identificadas antes do encaminhamento ao laboratório de análises de solo da Universidade Federal de Santa Maria (UFSM) (Figura 5). As variáveis químicas analisadas foram: Argila; pH em H₂O; Fósforo (P); Potássio (K); Matéria Orgânica (MO); Alumínio (Al); Cálcio (Ca); Magnésio (Mg); CTC Efetiva; CTC em pH 7,0; Zinco (Zn); Cobre (Cu); Enxofre (S) e Boro (B).


Figura 5 - Coleta de solo no campo com trado holandês (A) e Amostras de solo armazenada e identificadas (B).



Fonte: autor.

A análise das variáveis físicas do solo também tiveram por base o mesmo sistema de coleta da análise química do solo, sendo utilizado neste procedimento o trado rosca nas profundidades (0-20 e 20-40 cm) e o grid base amostral definido anteriormente. As amostras foram ensacadas, identificadas e encaminhados ao laboratório de solos da Embrapa Instrumentação Agropecuário (São Carlos, SP), nos quais os atributos analisados foram: Umidade (g/g), Frações Areia (%), Silte (%) e Argila (%) (Figura 6), seguindo a metodologia e recomendações da Sociedade Brasileira de Ciência do Solo (2016). A coleta das amostras foram realizadas entre os dias 30 de junho a 1 de julho de 2017.

Figura 6 - Coleta de solo (A); Trado rosca (B) e Armazenamento do solo em sacos plásticos (C).




Fonte: autor.

3.2.3 Leituras da condutividade elétrica aparente do solo

Para a medição da Condutividade Elétrica Aparente (CEa) foi utilizado um protótipo de um condutímetro desenvolvido pela Embrapa Instrumentação que conta com um processador central e um microprocessador de fabricação do Microchip Technology (*PIC18F258*), (Figura 6). O sistema realiza as leituras dos sinais dos eletrodos e converte para níveis digitais armazenando em bancos de memórias. O equipamento faz leituras de (CEa) nas profundidades de 20 e 40 cm a partir do nível do solo. O sistema possui uma interface de comunicação serial padrão (RS232), bloco “porta serial” que pode ser conectado a um microcomputador para o registro das medições como também pode informar ao usuário as leituras através de um mostrador de cristal líquido (RABELLO et al., 2010).

As leituras do solo foram medidas sob o grid base, mediante as profundidades de 20 e 40 cm a partir do nível do solo no dia 04/07/2017.

Figura 7 - Condutímetro de Condutividade Elétrica Aparente (CEa)



Fonte: autor.

3.2.4 Análise química do tecido vegetal

Para a análise química do tecido vegetal foram coletadas 100 folhas inteiras e saudáveis no período de pleno florescimento dentre as 20 plantas (amostra composta), mais próximas à planta referenciada, nos 74 pontos amostrais. A seleção consistiu na coleta da folha na posição oposta do primeiro cacho, a partir da base do ramo (Figura 8). Uma folha por ramo/cacho, no estágio fenológico 81 BBCH segundo a classificação fenológica de Lorens et al., (1995) e de acordo com a metodologia do Manual de Análises Químicas de Solos, Plantas e Fertilizantes da Embrapa, (2009).

As amostras foram identificadas, colocadas em sacos de papel e secas em estufa de circulação forçada de ar, em temperatura que não excedeu 65° C, por 48 horas. (Figura. 8. B)

Neste estudo não foi considerado a coleta por diferenças de cultivares da análise química do tecido vegetal, assumiu-se que a área de estudo é composta apenas por variedades viníferas de acordo com a metodologia do manual de recomendações da Sociedade Brasileira de Ciência do Solo (2016), onde cita apenas a recomendação de adubação para cultivares de uva de mesa e uva vinífera.

Figura 8 - Coleta do tecido vegetal (a) e amostras secas para análise (b).



Fonte: autor.

As amostras foram enviadas para laboratório de análise de tecido foliar da UFRGS (Universidade Federal do Rio Grande do Sul) para fins de verificação de elementos existentes do tecido vegetal. As variáveis químicas analisadas foram: Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg), Enxofre (S), Cobre (Cu), Zinco (Zn), Ferro (Fe), Manganês (Mn) e Boro (B).

3.2.5 Leituras da reflectância in situ e cálculo dos índices de vegetação.

No dia 15 de novembro de 2017 foram realizadas leituras de reflectância nas folhas com a utilização do espectralradiometro portátil FieldSpec Hand Held 2, com resolução espectral de 325 e 1.075 nm e intervalo de medição de 1 nm. As variedades viníferas (*Chardonay*, *Merlot* e *Pinot Noir*) se encontravam entre os estádios fenológicos 75 BBCH (Grãos em tamanho 'ervilha') e 77 BBCH (Inicio da compactação de cachos, conforme escala BBCH de Lorens et al., (1995)

Neste estudo não se separou as leituras espectrais por diferenças de cultivares, assumiu-se que a área de estudo é composta apenas por variedades viníferas conforme a metodologia do manual de recomendações da Sociedade Brasileira de Ciência do Solo (2016), onde cita apenas a recomendação de adubação para cultivares de uva de mesa e uva vinífera.

Foram realizados dois métodos de leituras espectrais no campo para cada índices de vegetação, com alvos vegetativos distintos, sendo o primeiro com contato do equipamento e o limbo foliar por clipagem da folha (*leaf clip*), utilizando-se o acessório probe e fonte interna de energia eletromagnética incidente (**CP**) e o segundo, por sensoriamento próximo do dossel da videira, feito diretamente pela entrada óptica do sensor a 1 m de distância, com ângulo de visada (W_d) de aproximadamente $\pm 25^\circ$, utilizando a reflectância da energia eletromagnética da radiação solar, sem a utilização do acessório pobre (**SP**) (Figura 9).

As leituras de reflectâncias foram realizadas nas 3 plantas mais próximas ao ponto amostral, à direita e esquerda (Figura 10). Foram realizadas no total de 10 leituras espectrais para os métodos de leituras (CP e SP), em cada um dos 74 pontos amostrais. Através do editor MS Excel, fez-se a média aritmética das 10 leituras de reflectância de cada ponto amostral e calculou-se 17 índices de vegetação: (SR = *Razão Simples*, NDVI = *Índice de Vegetação de Diferença Normalizada*; mNDVI = *Índice de Vegetação de Diferença Normalizada Melhorado*; SGR = *Soma de Reflectâncias no Verde*; RGR = *Razão Vermelho Verde*; NPCI = *Índice de Vegetação de Pigmentos Normalizado*; SRPI = *Índice da Razão Simples de Pigmentos*; NPQI = *Índice de vegetação de Feotinizacão Normalizado*; SIPI = *Índice de Pigmentos de Intensiva Estrutura*; PI1 = *Índice de Pigmentos 1*; PI2 = *Índice de Pigmentos 2*; PI3 = *Índice de Pigmentos 3*; PRI = *Índice de Reflectância Fotoquímica*; PSRI = *Índice de Reflectância de Plantas Senescentes*; PWI = *Índice*

de Água na Planta; ARI = Índice de Reflectância de Antocianinas; EVI = Índice de Vegetação Melhorado), observados no Quadro 1.

Figura 9 - Leituras em campo com o espectrorradiômetro portátil FieldSpec Hand Held 2, onde acessório (*leaf clip*) - CP (A) e Leitura óptica do sensor - SP (B).



Fonte: autor

Os índices vegetativos selecionados para este estudo foram escolhidos pela limitação de faixa espectral dos espectrorradiômetros utilizados neste trabalho (de 300 nm a 1.075 nm), e por serem direcionados somente àqueles destinados à análise de correlações entre as variáveis biofísicas, fitomassa e componentes bioquímicos com aplicação reconhecida para produção agrícola segundo Fomaggio e Sanches (2017).

Para a obtenção da calibração do espectrorradiômetro, foi utilizada uma placa de referência *Spectralon* com reflectância aproximada a de uma superfície lambertiana perfeita (100% de reflectância), conforme (Steffen et al., 1996). As leituras espectrais em campos foram realizadas nos horários das 11:00h às 12:45h, em torno desses horários que há menor ângulo de inclinação solar, maior fluxo de energia radiante e condições meteorológicas adequadas, com pouco vento e céu predominantemente livre de nuvens (SENA et al., 2016; LORD et al., 1988).

3.2.6 Parâmetros fitotécnicos

Para análise dos parâmetros fitotécnicos, foi contabilizado todos os cachos das 3 plantas mais próximas de cada ponto amostral do grid (Figura 10). Também foram colhidos aleatoriamente 3 cachos por planta próximo ao ponto amostral (amostragem composta), sendo posteriormente pesados em laboratório em balança

de precisão (SHIMADZU modelo AUW2220D), e feito a média para obtenção da massa dos cachos.

Quadro 1 - Índices de vegetação utilizados no estudo.

Índices de Vegetação	Autor	Equação
Índice de Vegetação de Diferença Normalizada Modificado (mNDVI)	Fuentes et al., (2001)	$mNDVI = \frac{(R750 - R705)}{(R750 + R705)}$ (8)
Índice de Vegetação Melhorado (EVI)	Huete et al., (1997)	$EVI = \frac{G\{NIR - RED}{NIR + C1(RED - C2(BLUE + L))\}}$ (9)
Índice de Reflectância Fotoquímica (PRI)	Gamon, Peñuelas e Field (1992)	$PRI = \frac{(R531 - R570)}{(R531 + R570)}$ (10)
Razão Simples (SR)	Jordan, (1969)	$SR = \frac{NIR}{RED}$ (11)
Razão Vermelho Verde (RGR)	Fuentes et al., (2001)	$RGR = \frac{(R600 - R699)}{(R500 - R599)}$ (12)
Índice de Vegetação de Diferença Normalizada (NDVI)	Rouse et al., (1973)	$NDVI = \frac{(NIR - RED)}{(NIR + RED)}$ (13)
Índice de Vegetação de Pigmentos Normalizado (NPCI)	Peñuelas, Baret e Filela, (1995)	$NPCI = \frac{(R680 - R430)}{(R680 - R430)}$ (14)
Índice da Razão Simples de Pigmentos (SRPI)	Zarco-Tejada, (2000)	$SRPI = \frac{(R430)}{(R680)}$ (15)
Índice de Pigmentos de Intensiva Estrutura (SIPI)	Zarco-Tejada, (2000)	$SIPI = \frac{(R800 - R445)}{(R800 - R680)}$ (16)
Índice de Pigmentos 1 (PI1)	Zarco-Tejada, (2000)	$PI1 = \frac{(R695)}{(R422)}$ (17)
Índice de Pigmentos 2 (PI2)	Zarco-Tejada, (2000)	$PI2 = \frac{(R695)}{(R760)}$ (18)
Índice de Pigmentos 3 (PI3)	Lichtenthaler et al., (1996)	$PI3 = \frac{(R440)}{(R690)}$ (19)
Soma de Reflectâncias no Verde (SGR)	Fuentes et al., (2001)	$SGR = \sum_{n=500}^{599} Rn$ (20)
Índice de Reflectância de Plantas Senescentes (PSRI)	Merzlyak et al., (1999)	$PSRI = \frac{(R680 - R500)}{(R750)}$ (21)
Índice de Reflectância de Antocianinas (ARI)	Gitelson, Merzlyak, Chivkunova, (2001)	$ARI1 = \left(\frac{1}{R550}\right) - \left(\frac{1}{R700}\right)$ (22)
Índice de Água na Planta (PWI)	Peñuelas et al., (1997)	$PWI = \frac{(R900)}{(R970)}$ (23)
Índice de vegetação de Feotinizacão Normalizado (NPQI)	Zarco-Tejada (2000)	$NPQI = \frac{(R415 - R435)}{(R415 - R435)}$ (24)

Onde: R750 = Reflectância em 750 nm; R705 = Reflectância em 705 nm; G = fator de ganho; NIR = reflectância no infravermelho próximo; RED = reflectância no vermelho; BLUE = reflectância no azul; C1= coeficiente de ajuste para o efeito de aerossóis da atmosfera na banda do vermelho; C2= coeficiente de ajuste para o efeito de aerossóis da atmosfera na banda do azul; L= fator de ajustes para o solo; R531 = Reflectância em 531 nm; R570 = Reflectância em 570 nm; NIR = reflectância no infravermelho próximo; RED = reflectância no vermelho; R600 = Reflectância em 600 nm; R699 = Reflectância em 699 nm; R500 = Reflectância em 500 nm; R599 = Reflectância em 599 nm; R680 = Reflectância em 680 nm; R430 = Reflectância em 430 nm; R800 = Reflectância em 800 nm; R445 = Reflectância em 445 nm; R695 = Reflectância em 695 nm; R422 = Reflectância em 422 nm; R695= Reflectância em 695 nm; R760 = Reflectância em 760 nm; R440 = Reflectância em 440 nm; R690 = Reflectância em 690 nm; R599 = Reflectância em 599 nm; R500 = Reflectância em 500 nm; R550 = Reflectância em 550 nm; R700 = Reflectância em 700 nm; R900 = Reflectância em 900 nm; R970 = Reflectância em 970 nm. Os valores adotados para o algoritmo do EVI são: L=1, C1=6 C2=7.5 e G=2.5, (JUSTICE et al., 1998); R415 = Reflectância em 415 nm; R435 = Reflectância em 435 nm; Fonte: Autor.

A coleta dos cachos para fins de quantificação dos parâmetros fitotécnicos foi realizado por amostragem composta, tomando como base a malha amostral com 74

pontos distribuídos nos 3 hectares da área de estudo, ou seja, cada ponto amostral foi representado por 7 plantas.

Os parâmetros fitotécnicos para este estudo foram: Produção média por ponto amostral - **PM**, Produtividade por ponto amostral – **Prod.**, (gramas/ponto) e Massa média dos cachos por ponto amostral – **MMC**, (cachos/g).

Para o cálculo da produtividade por ponto amostral, foram contabilizados todos os cachos de 3 plantas próximas ao ponto amostral, após calculado a média, multiplicou-se pela média da massa dos cachos em cada ponto amostral.

Neste estudo não foram considerados os parâmetros fitotécnicos por diferenças de cultivares, assumiu-se que a área de estudo é composta apenas por variedades viníferas conforme a metodologia do manual de recomendações da Sociedade Brasileira de Ciência do Solo (2016), onde ressalta apenas a recomendação de adubação para cultivares de uva de mesa e uva vinífera.

Os cachos de todas as variedades foram coletados durante a colheita na safra de 2018, entre os dias 18 e 19 de janeiro de 2018 na fase fenológica 89 BBCH (maturação plena), conforme a classificação fenológica de Lorenz et al., (1995).

Figura 10 - Método de contabilidade dos cachos (A) e pesagem das plantas (B).



Fonte: autor

3.2.7 Procedimentos para análise dos parâmetros enológicos

Para fins da análise dos parâmetros enológicos foram coletados 3 cachos nos 74 pontos amostrais, sendo cerca 222 cachos em 3 hectares da área de estudo. A análise química do mosto da uva foi realizada no laboratório de química da estação experimental da Embrapa Uva e Vinho – Vacaria RS, os parâmetros enológicos estudados foram: Sólidos Solúveis Totais (SST) e a Acidez Titulável em ácido

orgânico (ATT). Os cachos de uvas foram coletados entre os dias 18 e 19 de janeiro durante a fase fenológica 89 BBCH (maturação plena), conforme a escala de Lorenz et al., (1995).

Neste estudo não foram considerados os parâmetros enológicos por diferenças de cultivares, assumiu-se que a área de estudo é composta apenas por variedades viníferas conforme a metodologia do manual de recomendações da Sociedade Brasileira de Ciência do Solo (2016), onde ressalta apenas a recomendação de adubação para cultivares de uva de mesa e uva vinífera.

Para verificação da quantidade de Sólidos Solúveis Totais (SST), as 74 amostras, foram compostas por bagas extraídas de três cachos e maceradas em almofariz, com auxílio de pistilo até a obtenção de 10 ml de mosto. Para a determinação da quantidade de (SST) foi utilizado um Refratômetro Digital Portátil, (modelo Pal-1), na qual foram colocadas gotas do mosto e feitas três repetições de leituras. (Figura 11.)

Na determinação da Acidez Total Titulável em ácido orgânico (ATT), foi utilizada a técnica de titulação, conforme metodologia descrita pelo Instituto Adolfo Lutz, (1985), citado abaixo:

A solução para titulação foi composta por 10 ml de mosto da uva, diluído em 100 ml de água destilada e homogeneizada em um béquer.

A titulação foi realizada com solução de hidróxido de sódio 0,1 N até uma faixa de pH (8,1- 8,4) verificado com medidor de pH de bancada da marca AAKER devidamente calibrado com as soluções-tampão de 4.0 e 6.86 de acordo com as instruções do fabricante.

A determinação da Acidez Titulável em ácido orgânico foi expressa em miliequivalentes por litro pela seguinte equação:

$$AT = \frac{n \times N \times 1.000}{V} \quad (25)$$

Onde, AT : Acidez total em meq/L; n : Volume da solução de hidróxido de sódio gasto na titulação em mL; N : Normalidade da solução de hidróxido de sódio; V : Volume da amostra (mL).

Figura 11 - Refratômetro digital portátil (A) e Medidor de pH de bancada (B).



Fonte: autor

3.2.8 Análise dos dados: estatística descritiva e geoestatística

As variáveis de condutividade elétrica aparente (CEa) do solo, as variáveis químicas e físicas do solo, as variáveis de análise química do tecido vegetal, os parâmetros fitotécnicos e enológicos da planta, e os índices de vegetação, foram tabulados em planilha eletrônicas e realizado a análise estatística descritiva clássica pelo software estatístico IBM SPSS (*Statistics* versão 12).

Assim, foram determinadas a média, mediana, desvio padrão (s^2), valor mínimo, valor máximo, coeficiente de variação (C.V.%) e variância (s). A normalidade de distribuição de frequência dos dados foi testada pelo teste não paramétrico de dependência de Kolmogorov-Smirnov, dado o nível de valor crítico de $p > 0,5$, conforme proposto por Ferreira, (2014).

Os resultados do coeficiente de variação foram comparados com aqueles sugeridos por Gomes (1985), que considera os coeficientes de variação como baixos, quando são inferiores a 10%; médios, quando estão entre 10 e 20%; altos, quando estão entre 20 e 30%; e muito altos, quando são superiores a 30 %, valores esses sugeridos para experimentos de culturas agrícolas.

Foram realizadas análise dos dados brutos através de histogramas e diagramas de caixa (*boxplot*), identificando valores anômalos e eliminando aqueles que não representavam a realidade, conforme Molin et al., (2015).

O coeficiente de correlação linear de Pearson (r) ao nível de 5% foi aplicado com a finalidade de identificar possíveis associações entre os parâmetros

pesquisados e intervalos de coeficiente de correlação foram interpretados com base na classificação de magnitudes proposto por Ferreira, (2014).

Para a elaboração dos mapas da distribuição espacial de cada variáveis, utilizou-se a análise geoestatística, com base nos semivariogramas experimentais ajustados por modelos teóricos propostos por Robertson, (1998), com o auxílio do programa computacional *Geostatistics for the Environmental Sciences* (GS+) desenvolvido pela *Gamma Design Software*. Tal programa é utilizado para o cálculo dos semivariogramas, obtendo-se assim a faixa de dependência espacial dos variáveis estudadas: Alcance (a), Efeito pepita (Co) e o Patamar (Co + C).

Para definição do modelo e ajuste dos semivariogramas adotou-se como parâmetro a menor soma de quadrados de resíduos (SQR), o menor efeito pepita (C0), menor alcance (ranger) em relação à distância máxima (*lag distance*), a análise de variância e a classificação de dependência espacial (DE), para os dados que cumpriram estes critérios, adotou-se a interpolação por krigagem ordinária seguido pela validação cruzada, de outro modo, admitiu-se o interpolador Inverso da Distância (IDW) (RIBEIRO JR. e DIGGLE, 2001).

Com o auxílio do programa ArcGIS® 10.3, software da ESRI (*Environmental Systems Research Institute*) foi realizado a edição das imagens *raster's* obtidas pelo software (GS+), onde foram criados mapas digitais das variáveis que apresentaram os maiores coeficientes de correlação com magnitude moderada por Pearson ao nível de 5%. Para o processo de edição, foram definidas três classes, (Alta, Média e Baixa) através do método de classificação Quantís, método estatístico do software ArcGIS® 10.3.

4 RESULTADOS E DISCUSSÃO

4.1 Estatística Descritiva

4.1.1 Variáveis da Análise Química do Solo

A partir dos resultados da análise estatística descritiva para os parâmetros relacionados às características químicas do solo, observa-se uma importante variação entre os valores mínimos e máximos, para todas as variáveis nas profundidades (0-20 e 20-40 cm), indicando baixa homogeneidade para uma área de 3 hectares, caracterizada somente como *Latossolos Brunos alumínicos câmbicos* (Tabela 11).

As variáveis da análise química solo da área em estudo, foi encontrado variabilidade estruturada, justificando a aplicação da geoestatística. Segundo Vercesi (2004), a magnitude da variabilidade espacial de um vinhedo é importante por constituir o ponto de partida para adoção de um manejo diferenciado. Por outro lado, se a variabilidade não apresenta estrutura espacial, ou seja, se ela ocorre ao acaso em áreas muito pequenas, a melhor estimativa de qualquer parâmetro nessa área será o valor médio ou a mediana, e a melhor maneira de manejá-la será usando os conceitos da agricultura convencional, por meio de manejo uniforme (COELHO, 2003).

Na (Tabela 1) é demonstrado que a maioria dos valores de Desvio Padrão das variáveis químicas do solo tende a se apresentar afastados em relação à média. A exceção fica por conta do Fósforo na profundidade de (20-40) cm e do Alumínio na profundidade de (0-20) cm, nos quais os dados ficaram fora do intervalo do desvio médio.

O Coeficiente de Variação (C.V.%), segundo a classificação de Pimentel Gomes, (1985), as variáveis que apresentaram muito alta dispersão na distribuição dos dados, foram as variáveis (P, K, Al, Ca, Zn, Cu e B) para a profundidade de 0 a 20 cm e (P, K, Al, Ca, Mg, CTC Efet., Zn, Cu e B) para 0 a 40 cm de profundidade. Já as variáveis que apresentaram alta dispersão na distribuição dos dados foram (Mg, CTC Efet. e S) na profundidade de 0-20 cm e por fim, as variáveis que apresentaram média dispersão na distribuição foram: (Argila, pH H₂O, MO e CTC

pH 7,0) na profundidade de 0-20 cm. Para a profundidade de 20-40 cm, as variáveis foram (Argila, pH H₂O, MO, CTC pH 7,0 e S). Para Landim (2003), o coeficiente de variação (C.V.%) fornece uma medida relativa da precisão do experimento, sendo bastante útil na avaliação da dispersão dos dados.

Tabela 1 - Estatística descritiva das variáveis químicas do solo.

Variável	\bar{X}	<i>Md</i>	<i>Min</i>	<i>Max</i>	<i>s</i>	<i>s</i> ²	<i>CV</i> %
<i>Profundidade de 0 a 20 cm</i>							
Argila (%)	61,257	64,000	25,000	79,000	11,637	135,426	18,998
pH H ₂ O	6,214	6,050	4,600	8,000	0,802	0,643	12,909
P	5,686	4,050	1,000	34,000	5,776	33,366	101,580
K	197,892	192,000	44,000	440,000	92,718	8596,700	46,853
MO	4,000	3,950	3,000	7,200	0,651	0,424	16,286
Al	0,172	0,000	0,000	2,700	0,520	0,270	302,771
Ca	6,916	6,835	0,986	11,797	2,593	6,724	37,492
Mg	4,798	4,970	0,792	6,788	1,418	2,012	29,565
CTC Efet.	12,388	12,500	4,500	18,700	3,527	12,437	28,468
CTC pH 7	15,682	15,850	9,400	20,400	2,257	5,094	14,391
Zn	3,079	2,700	0,650	8,450	1,723	2,969	55,961
Cu	6,715	6,825	1,150	14,030	2,526	6,382	37,622
S	12,885	12,350	8,600	24,200	2,851	8,128	22,125
B	0,172	0,200	0,100	0,400	0,085	0,007	49,667
<i>Profundidade de 20 a 40 cm</i>							
Argila (%)	76,878	80,000	42,000	88,000	11,369	129,259	14,789
pH H ₂ O	5,496	5,200	4,700	7,500	0,779	0,607	14,179
P	4,427	3,000	0,700	31,300	4,956	24,566	111,958
K	88,865	84,000	20,000	192,000	40,788	1663,680	45,899
MO	3,504	3,500	2,500	6,200	0,538	0,289	15,353
Al	1,138	0,700	0,000	3,800	1,196	1,431	105,119
Ca	3,934	3,196	0,777	10,376	2,711	7,350	68,917
Mg	3,252	3,085	0,627	6,869	1,807	3,266	55,572
CTC Efet.	8,549	7,250	4,700	17,400	3,521	12,396	41,185
CTC pH 7	14,578	14,650	9,200	19,800	2,282	5,206	15,651
Zn	1,285	1,135	0,280	4,130	0,758	0,575	58,976
Cu	6,666	6,825	0,890	10,870	2,162	4,674	32,433
S	15,220	14,800	9,500	21,700	2,797	7,824	18,378
B	0,176	0,150	0,100	0,500	0,098	0,010	55,590

Onde: P = Fósforo (mg/dm³); K = Potássio (mg/dm³); MO = Matéria Orgânica (%); Al = Alumínio (cmolc/dm³); Ca = Cálcio (cmolc/dm³); Mg = Magnésio (cmolc/dm³); CTC Efet. = Capacidade de Troca de Cátion Efetiva (cmolc/dm³); CTC pH 7,0 = Capacidade de Troca de Cátion em pH 7,0 (cmolc/dm³); Zn = Zinco (mg/dm³); Cu = Cobre (mg/dm³); S = Enxofre (mg/dm³); B = Boro (mg/dm³); \bar{X} = Média; *Md* = Mediana; *Min* = Valor Mínimo; *Max* = Valor Máximo; *s* = Desvio Padrão; *s*² = Variância; *CV* % = Coeficiente de Variação em Porcentagem.

Estes resultados demonstram que a maioria das variáveis de solo apresentaram alta dispersão dos dados e baixa homogeneidade, sendo que 57,14% das variáveis analisadas apresentaram dispersão muito alta, 10,71% obtiveram dispersão alta e 32,142% alcançaram média dispersão na distribuição dos dados.

A média aritmética do atributo químico (pH em H₂O), entre 0 e 20 cm de profundidade na solução de solo foi de (pH 6,214). Os valores mínimo e máximo variaram entre o pH (4,6 a 8,0) respectivamente. Esta amplitude demonstra que há uma grande variabilidade espacial entre os pontos observados. Ao se considerar as correlações entre observações vizinhas, pode-se definir agrupamentos para diferentes unidades de gestão e realizar as intervenções de manejo de acordo com as necessidades específicas de cada subárea, assim, racionalizar o uso de insumos (MOLIN et al., 2015).

De acordo com Giovannini, (2014), o pH ideal para o melhor desenvolvimento da videira é 6. Segundo o mesmo autor, a maioria dos grandes vinhos é feito de uvas obtidas em solos com pH próximo à neutralidade (entre 6,5 e 7,5).

Em contrapartida, o valor médio do atributo químico do solo de (pH em H₂O) foi de 5,49 na profundidade de 20-40 cm e seus valores de mínimo e máximo estiveram entre o valor de pH (4,7 a 7,5), respectivamente. Esse comportamento se explica pelo fato da adoção da prática de calagem ser realizada na profundidade de 0-20 cm, além disso, de acordo com a Embrapa, (2003), o calcário possui baixa solubilidade no solo, seu deslocamento para camadas inferiores do solo dependerá do tamanho de suas partículas e do tempo de reação.

A média aritmética dos teores de Fósforo (P) encontrado nas análises químicas de solo na profundidade de 0-20 cm, foi de (5,686 mg/dm³), esta disponibilidade de nutriente é considerada baixa para a classe de teor de argila 2, segundo a Comissão de Química e Fertilidade do Solo RS/SC, (2016).

A falta de (P) provoca redução do sistema radicular e da parte aérea, fraca lignificação dos sarmentos, fraca diferenciação das gemas, menor fecundação, retardamento na maturação dos frutos diminuição do teor de açúcares, devendo ser aplicados produtos de solubilização lenta, uniformemente distribuída em todo perfil (GIOVANNINI, 2014).

A partir de uma análise individualizada do atributo Fósforo (P) observa-se uma amplitude extrema entre o teor de valor mínimo (1,0 mg/dm³) e o máximo (34,0 mg/dm³), esta tendência de variação demonstra uma distribuição com maior dispersão dos dados, indicando que estas amostras possuem uma alta variabilidade. Segundo Molin et al., (2015) o fósforo possui comportamento imóvel no solo e alta variação em curtas distâncias, por outro lado, a matéria orgânica e os parâmetros físicos do solo variam menos em curtas distâncias.

Para interpretação dos teores de Potássio (K) na profundidade de 0-20 cm, foi observado a média da capacidade de troca de cátions a pH 7,0, nesse sentido, a média dos teores de (K) das amostras foi de (197,892 mg/dm³), em função da média da CTC a pH 7,0, que foi de (15,682mg/dm³), segundo a Comissão de Química e Fertilidade do Solo RS/SC, (2016), esse resultado enquadra-se na classe Alta do teor de disponibilidade.

A explicação para o alto teor de (K) na área em estudo, é que solo possui em média 61,25% de argila. Solos com estas características lixiviam em menor grau o potássio. O Potássio (K) fica retido nos colóides do solo por meio da capacidade de troca catiônica CTC. O excesso de (K) provoca o dessecamento da ráquis (menor absorção de Ca⁺⁺ e Mg⁺⁺) e antecipa o repouso hibernar, além de retardar o início da brotação e reduzir a acidez do mosto, surgindo sintomas de deficiência de magnésio (GIOVANNINI, 2014).

Os teores de Cálcio (Ca) e Magnésio (Mg) na profundidade de 0-20 cm, se enquadram como Altos, segundo a Comissão de Química e Fertilidade do Solo RS/SC, (2016), sendo que as médias foram de (6,919 cmolc/dm³) e (4,789 cmolc/dm³) respectivamente. Os altos teores especialmente de (Ca) se justificam pela adoção da prática de calagem a qual contribui significativamente para esse fenômeno.

Para os teores de Cobre (Cu) e Zinco (Zn) na profundidade de 0-20 cm, a análise química do solo apresentou teores médios de (6,715 e 3,079 mg/dm³) respectivamente, estão bem acima dos valores considerados altos pela Comissão de Química e Fertilidade do Solo RS/SC, (2016), que são de (0,4 e 0,5 mg/dm³) respectivamente. Esses valores podem ser explicados pela prática rotineira de tratamento fúngico com produtos fitossanitários a base desses dois elementos químicos, sendo que a calda bordalesa, constituída basicamente de sulfato de Cobre e cal, sendo um dos principais produtos utilizados pelos viticultores.

O teor de Matéria Orgânica na faixa de 2,6 a 5% é classificado como médio segundo a Comissão de Química e Fertilidade do Solo RS/SC, (2016). Na análise química do solo o teor médio da Matéria Orgânica entre 0 a 20 cm de profundidade foi de 4%. Esta quantidade de matéria orgânica é justificada pelo manejo conservacionista de cobertura vegetal composta por gramíneas e por restos culturais advindo da poda da videira que além de servirem de cobertura do solo, também fazem a ciclagem dos nutrientes (Embrapa, 2003).

A concentração do teor médio de Boro (B) na análise química do solo, foi de (0,172 mg/dm³), o qual é considerado baixo segundo a recomendação da Comissão de Química e Fertilidade do Solo RS/SC, (2016), que apontam como teores adequados entre (0,6 a 1,0 mg/dm³).

Os teores de Boro (B) considerados normais para videira variam de (15 a 22 mg/dm³). As videiras retiram cerca de 10 g de (B) para produzir um quilo de frutos (Embrapa, 2003).

A deficiência de (B) pode provocar baixa taxa de germinação do pólen e problemas relacionados com o crescimento do tubo polínico o que provoca o aparecimento de cachos e frutos mal formados, além da queda dos frutos no início do seu desenvolvimento (WILIAM NATALE; DANILO EDUARDO ROZANE, 2018).

Segundo o teste de amostras independentes, (Teste t student), dos 10 índices de vegetação relacionados com as profundidades de amostragem de 0-20 cm e 20-40 cm das variáveis químicas do solo não houve diferença nas amostragens para os atributos: Fósforo Cobre e Boro, (Tabela 2). Recomenda-se que a amostragem destes atributos neste trabalho, ocorra somente na profundidade de 0-20 cm.

Tabela 2 - Teste das amostras independentes (Teste t student) das médias aritméticas das variáveis da análise química do solo na profundidade de amostragem de 0-20 e 20-40 cm.

Variáveis	Profundidade de Coleta	
	0 - 20 cm	20 - 40 cm
Argila (%)	61,2568 a	76,8784 b
pH H ₂ O	6,2135 a	5,4959 b
P	5,6865 a	4,427 a
K	197,8919 a	88,8649 b
MO	4,000 a	3,5041 b
Al	0,1716 a	1,1378 b
Ca	6,9163 a	3,9339 b
Mg	4,7975 a	2,0118 b
CTC Efet.	12,3878 a	8,5486 b
CTC pH 7,0	15,6824 a	14,5784 b
Zn	3,0791 a	1,2854 b
Cu	6,715 a	6,6661 a
S	12,8851 a	15,2203 b
B	0,1716 a	0,1757 a

Onde: P = Fósforo (mg/dm³); K = Potássio (mg/dm³); MO = Matéria Orgânica (%); Al = Alumínio (cmolc/dm³); Ca = Cálcio (cmolc/dm³); Mg = Magnésio (cmolc/dm³); CTC Efet. = Capacidade de Troca de Cátion Efetiva (cmolc/dm³); CTC pH 7,0 = Capacidade de Troca de Cátion em pH 7,0 (cmolc/dm³); Zn = Zinco (mg/dm³); Cu = Cobre (mg/dm³); S = Enxofre (mg/dm³); B = Boro (mg/dm³). Médias seguidas por uma mesma letra não diferem entre si pelo teste de t student ($p=0,05$).

4.1.2 Parâmetros Fitotécnicos e Enológicos

Todos os cachos de uvas foram coletados durante a colheita na safra de 2018. Foram coletados 3 cachos nos 74 pontos amostrais, sendo cerca 222 cachos em 3 hectares da área de estudo. Esta é uma coleta muito sensível na vitivinicultura, pois afeta diretamente a produção final de vinho, uma vez que tais parreirais são dimensionados para uma produção de cachos reduzida, favorecendo a qualidade ao máximo em detrimento da produtividade. Assim, não é possível uma amostragem intensa, sob pena de afetar a lucratividade do empreendimento. Assim, a densidade de amostragem de cachos coletados na área de estudo foi definida com base na representação do volume total, ou seja, cerca de 0,5 % do volume total de cachos da área.

Neste estudo não foram considerados as diferenças por cultivares dos parâmetros fitotécnicos e enológicos, assumiu-se que a área de estudo é composta apenas por variedades viníferas conforme a metodologia do manual de recomendações da Sociedade Brasileira de Ciência do Solo (2016), onde ressalta apenas a recomendação de adubação para cultivares de uva de mesa e uva vinífera.

Na (Tabela 3) é demonstrada que a maioria dos valores de Desvio Padrão dos parâmetros fitotécnicos e enológicos tende a se apresentar afastados em relação à média.

Tabela 3 - Estatística descritiva dos parâmetros fitotécnicos e enológicos.

Variáveis	\bar{X}	<i>Md</i>	<i>Min</i>	<i>Max</i>	<i>S</i>	<i>s</i> ²	<i>CV</i> %
Sólidos Solúveis (°Bx)	18,59	18,70	15,00	20,50	0,999	0,988	5,37
Acidez Total Titulável (mEq/L)	119,94	120,00	88,00	208,00	21,230	450,739	17,70
PM (cachos/planta)	65,77	63,00	1,00	112,00	18,213	331,719	27,69
MMC (cachos/g)	245,23	225,00	106,00	555,00	103,857	10.786,470	42,35
PROD. (g/ponto)	1.845,09	1.632,77	11,78	4.842,00	1.010,428	1,02x10 ⁶	54,76

Onde: \bar{X} = Média; *Md* = Mediana; *Min* = Valor Mínimo; *Max* = Valor Máximo; *S* = Desvio Padrão; *s*² = Variância; *CV* % = Coeficiente de Variação em Porcentagem; MMC = Massa Média fresca de três cachos por ponto amostral; PM = Produção Média por ponto amostral; *g* = gramas e PROD. = Produtividade por ponto amostral.

A partir das análises dos resultados obtidos com o estudo da estatística descritiva dos parâmetros enológicos, observou-se que o coeficiente de variação C.V.% de acordo com a classificação de Pimentel Gomes, (1985), a variável Sólidos Solúveis apresentou baixa dispersão na distribuição dos dados e a variável Acidez

Total Titulável apresentou média dispersão. Já para os parâmetros fitotécnicos, a variável Produção Média por ponto amostral (**PM**) apresentou alta dispersão enquanto que a variável Massa Média fresca de três cachos por ponto amostral (**MMC**) e Produtividade por ponto amostral (**PROD.**), apresentaram dispersão Muito Alta.

A produtividade média da área total nas 3 variedades foi de 6.213,63 Kg/ha, sendo 2.871,87 Kg/ha para *Chardonnay*; 1.201,58 kg/ha para *Merlot* e 2.140,17kg/ha *Pinot Noir*. De acordo com o Cadastro Vitícola do RS, que pode ser acessado no site da Embrapa, indica as seguintes produtividades médias em 2015 para plantas com mais de três anos: *Chardonnay* = 8,24 t/ha; *Merlot* =10.74 t/há e *Pinot Noir* = 8.23 t/ha. Segundo Alberto Miele*, os bons vinhedos têm produtividades superiores, sendo que a Denominação de Origem do Vale dos Vinhedos (DO) estabelece o máximo de 13 t/ha.

A baixa produtividade pode ser explicada por conta de um manejo inadequado de escarificação na entre linha do solo que comprometeu as raízes superficiais na tentativa de se construir estrutura de camalhão. A produtividade é uma das mensurações mais importantes, visando auxiliar o produtor nas tomadas de decisões, sejam elas comerciais ou operacionais (TRIBONI et al., 2004).

O conhecimento da variabilidade espacial dos principais indicadores químicos de avaliação da fertilidade também é uma alternativa para o estudo da variabilidade na produtividade (VIANA, 2005; LIMA e SILANS, 1999). Assim, a integração de atributos químicos, físicos e biológicos do solo, combinando com as informações do mapa de produtividade, é possivelmente a alternativa mais completa na investigação dessa variabilidade (MOLIN, 2002; KITCHEN et al., 2003; CAPELLI, 2003; SANTI, 2007).

O mapa de rendimento, quando disponível, é a uma das alternativas eficientes para se estimar a heterogeneidade da área e, talvez uma das mais completas alternativas para prospecção da variabilidade espacial do solo e a definição de unidades de alta e baixa produtividade (MOLIN, 2001; CAMARGO et al., 2004).

A variabilidade inconsistente é atribuída a fatores transitórios variando sua participação na variabilidade de uma safra para outra (CAPELLI 2003; DURIGON, 2007). Para Fiorin (2007), os fatores que determinam a variabilidade da produtividade, destacam-se: baixos teores de matéria orgânica, reduzida

profundidade do solo, acidez do solo, compactação, drenagem deficiente, declividade acentuada, exposição solar entre outros.

Segundo Celito Crivellaro Guerra*, os teores de (SST) e a (ATT) são classificados conforme faixas de recomendação enológica para elaboração de vinhos finos, (Tabela 4). Como mostra a (Tabela 3), o valor médio do (SST) do mosto amostrados foi de 18,593 (°Bx), o autor sugere a necessidade de chaptalização forte. Já o valor médio da (ATT) foi de (119,943 mEq/L), indicando que a amostra possui teor ideal para espumantes, podendo constituir ainda qualquer vinho tranquilo com neutralização.

Tabela 4 - Faixas de recomendação enológica para elaboração de vinhos finos.

Açúcar expresso em Sólidos Solúveis Totais (escala grau brix)	
Abaixo de 15	Insuficiente;
De 15 a 18	Teor mínimo, necessitando chaptalização forte;
De 18 a 21	Teor razoável, necessitando alguma chaptalização;
De 21 a 24	Teor adequado para vinhos de estilo jovem e/ou de longevidade média;
De 24 a 27	Teor ótimo para vinhos de guarda e/ou de colheita tardia.
Acidez Total expressa em (mEq/L) de Ácido Tartárico	
Igual ou superior a 120	Acidez excessiva; gerará produto gustativamente desarmônico;
De 120 a 100	Teor elevado. Ideal para vinhos espumantes;
De 100 a 80	Teor ideal para qualquer vinho tranquilo;
Igual ou inferior a 80	Acidez insuficiente, provavelmente necessitando de correção.

Fonte: Celito Crivellaro Guerra

4.1.3 Análise física do solo

A (Tabela 5) apresenta os dados estatísticos básicos para as variáveis físicas do solo. Observa-se que na amostragem de solo entre 0-20 cm de profundidade a média aritmética da umidade (g/g), apresentou valor menor do que em relação à umidade (g/g) da profundidade de 20-40 cm. De acordo com a Embrapa, (2003) o fenômeno ocorre por conta da percolação sob influência principalmente de forças gravitacionais (potencial hidrostático e gravitacional).

As variáveis de Coeficientes de Variação C.V.%, segundo a classificação de Pimentel Gomes, (1985), apresentou baixa dispersão na distribuição dos dados para: Argila (%) na profundidade de 0-20 cm, Silte (%) e Argila (%) na profundidade de 20-40 cm.

Tabela 5 - Estatística descritiva da análise física do solo.

Variável	\bar{X}	<i>Md</i>	<i>Min</i>	<i>Max</i>	<i>s</i>	<i>s</i> ²	<i>CV</i> %
<i>Profundidade de 0 a 20 cm</i>							
Umidade (g/g)	0,319	0,319	0,216	0,409	0,042	0,002	13,061
Areia (%)	7,619	7,260	5,094	14,800	1,532	2,348	20,112
Silte (%)	27,293	26,827	22,323	33,992	2,829	8,004	10,366
Argila (%)	65,086	65,657	53,900	71,576	3,567	12,726	5,481
<i>Profundidade de 20 a 40 cm</i>							
Umidade (g/g)	0,326	0,327	0,244	0,399	0,035	0,001	10,681
Areia (%)	6,979	6,715	5,510	10,045	1,013	1,026	14,511
Silte (%)	24,201	24,186	20,294	28,303	1,935	3,746	7,997
Argila (%)	68,820	69,195	62,802	73,250	2,561	6,557	3,721

Onde: \bar{X} = Média; *Md* = Mediana; *Min* = Valor Mínimo; *Max* = Valor Máximo; *s* = Desvio Padrão; *s*² = Variância; *CV* % = Coeficiente de Variação em Porcentagem.

Já as variáveis que apresentaram média dispersão na distribuição foram a Umidade (g/g) e Silte (%) na profundidade de 0-20 cm e Umidade (g/g) e Areia (%) na profundidade de 20-40 cm. A variável que apresentou alta dispersão foi Areia (%) na profundidade de 0-20 cm, revelando que 37,5 % dos dados das variáveis físicas da área correspondem à baixa dispersão, 50% corresponde à média dispersão e 12,5 % a alta dispersão. Para Julião et al., (2010), a presença de elevados coeficientes de variação pode demonstrar grandes alterações provocadas pelo manejo do solo como na adubação, em calagens sucessivas e irregulares e, bem como, o local de amostragem.

Como mostra a (Tabela 5) todas as variáveis de Desvio Padrão das análises física do solo tendem a se apresentar afastados em relação à média.

Para Souza (1999), o desvio padrão e o C.V.% dão uma ideia da magnitude de variabilidade de propriedades químicas e físicas dos solos, porém, nada informam quanto à dependência espacial dessas propriedades, o que só é possível através de técnicas geoestatísticas. Segundo Grego e Vieira (2005), mesmo numa parcela experimental de 30x30 m existe grande variabilidade de propriedades físicas do solo e se for considerada como homogênea pode mascarar os resultados dos tratamentos aplicados no manejo por sítio-específico.

A investigação das características físicas do solo pode ser grande valia para o entendimento das causas da variabilidade de rendimento das culturas justificando um estudo sobre a variabilidade espacial das propriedades hidrodinâmicas do solo. Mesmo de aparência homogênea, essas variáveis podem apresentar considerável

variabilidade no espaço e conseqüentemente, na resposta das culturas (LIMA e SILANS, 1999).

4.1.4 Análise Química do Tecido Vegetal

A principal finalidade das análises de tecidos ou folhas é verificar as necessidades nutricionais das culturas através da utilização das folhas como indicativo nutricional das mesmas. Do mesmo modo que se quantifica a variabilidade em produtividade e qualidade de uva, é possível determinar o estado nutricional do vinhedo. Neste sentido, Siverio (2005), relatou que a forma mais comum de realizar um diagnóstico de fertilidade é através de uma análise de solo ou análise foliar. A análise foliar nas culturas perenes irá permitir uma melhor estratégia de adubação para a safra seguinte.

A seleção consistiu na coleta da folha na posição oposta do primeiro cacho, a partir da base do ramo. Foi coletada uma folha por ramo/cacho, no estágio fenológico 81 BBCH, segundo a classificação fenológica de Lorenz et al., (1995) e conforme a metodologia do Manual de Análises Químicas de Solos, Plantas e Fertilizantes da Embrapa, (2009).

Devido à impossibilidade de encontrar 100 folhas por ramo cacho, como determinado no Manual de Análises Químicas de Solos, Plantas e Fertilizantes da Embrapa, (2009), a coleta das folhas para fins de quantificação dos teores químicos do tecido vegetal foi realizado por amostragem composta, tomando como base a malha amostral com 74 pontos distribuídos nos 3 hectares da área de estudo (gerando uma relação de representação em torno 21 m² por ponto amostral), ou seja, a amostragem composta dentre as 20 plantas representa um ponto amostral do grid.

Na (Tabela 6) são apresentadas as médias aritméticas dos valores para avaliação de composição química dos nutrientes nas folhas da videira.

Os Coeficientes de Variação C.V.% das variáveis do tecido vegetal, conforme a classificação de Pimentel Gomes, (1985), apresentaram média dispersão para os dados de N, P, Zn e B, alta dispersão para as variáveis K, Ca, Mg, S, Cu e Mn e muito alta dispersão para a variável Ferro. Revelando que 36,6 % das variáveis de análise de tecido vegetal da área correspondem à faixa de média dispersão dos dados e que 54,54 % das variáveis, correspondem à alta dispersão de dados.

Tabela 6 - Estatística descritiva da análise química do tecido vegetal.

Variável	\bar{X}	<i>Md</i>	<i>Min</i>	<i>Max</i>	<i>s</i>	<i>s</i> ²	<i>CV</i> %
N	3,100	2,000	3,800	0,358	0,128	3,100	11,548
P	0,285	0,220	0,410	0,045	0,002	0,285	15,574
K	1,650	0,960	3,200	0,500	0,250	1,650	29,246
Ca	1,800	1,000	3,700	0,558	0,311	1,800	29,704
Mg	0,595	0,390	1,100	0,141	0,020	0,595	23,039
S	0,285	0,180	0,700	0,069	0,005	0,285	23,570
Cu	12,000	7,000	17,000	2,756	7,596	12,000	23,966
Zn	54,000	37,000	80,000	10,266	105,394	54,000	19,030
Fe	262,000	141,000	755,000	161,353	26034,836	262,000	51,107
Mn	306,500	151,000	552,000	90,308	8155,451	306,500	28,597
B	36,000	22,000	50,000	5,990	35,875	36,000	17,287

Onde: N = Nitrogênio (%) m/m; P = Fósforo (%) m/m; K = Potássio (%) m/m; Ca = Cálcio (%) m/m; Mg = Magnésio (%) m/m; S = Enxofre (%) m/m; Cu = Cobre (mg/kg); Zn = Zinco (mg/kg); Fe = Ferro (mg/kg); Mn = Manganês (mg/kg); B = Boro (mg/kg); \bar{X} = Média; *Md* = Mediana; *Min* = Valor Mínimo; *Max* = Valor Máximo; *s* = Desvio Padrão; *s*² = Variância; *CV* % = Coeficiente de Variação em Porcentagem.

Segundo a Comissão de Química e Fertilidade do Solo RS/SC, (2016), os teores acima 2,40% de Nitrogênio (N) para folhas completas são considerado excessivos para cultura da videira. A análise química do tecido vegetal, (Tabela 7), apresentou teor excessivo de nitrogênio, com média de 3,097%. Este excesso de N pode ser justificado pelo teor médio da matéria orgânica de 4% e pela fração média da argila de 65%, apresentados na análise química do solo na profundidade de 0 a 20 cm, (Tabela 2), influenciado pelo manejo conservacionista de cobertura vegetal adotado na área. A análise química do tecido vegetal para folhas completas apresentou teores médios normais para os nutrientes P, Ca, Mg e Zn, excessivos para K, Fe, Mn e insuficiente para B, segundo a interpretação da Comissão de Química e Fertilidade do Solo RS/SC, (2016).

Teores excessivos de alguns nutrientes na área de estudo podem ser justificado pela aplicação de fungicidas que contêm Cu, Mn e Zn em suas formulações e que são absorvidos pelas folhas (GIOVANNINI, 2014). O mesmo autor afirma que a falta de Boro (B) provoca deficiência na fecundação, reduzindo o número de bagas por cacho, formando uvas de tamanho reduzido sem sementes e bagas manchadas. Os teores de B considerados normais para a videira variam de (15 a 22 mg/dm³).

4.1.5 Análise dos Índices de Vegetação

Na (Tabela 7) é demonstrado que a maioria dos valores de Desvio Padrão dos índices de vegetação tende a se apresentar afastados em relação à média.

Tabela 7 - Estatística descritiva das variáveis dos índices de vegetação.

Variável	\bar{X}	<i>Md</i>	<i>Min</i>	<i>Max</i>	<i>S</i>	<i>s</i> ²	<i>CV</i> %
<i>Com Probe</i>							
SR	16,186	16,636	7,934	18,704	1,928	3,719	11,913
NDVI	0,879	0,884	0,776	0,896	0,020	0,000	2,554
mNDVI	0,615	0,613	0,498	0,675	0,031	0,001	5,060
SGR	8,711	8,789	6,734	13,818	1,141	1,302	13,099
RGR	1,967	1,860	1,247	3,524	0,412	0,170	20,949
NPCI	0,092	0,097	-0,011	0,152	0,029	0,001	31,892
SRPI	0,834	0,824	0,737	1,022	0,050	0,003	6,025
NPQI	-0,014	-0,013	-0,096	0,055	0,039	0,002	-275,376
SIPI	1,010	1,011	0,997	1,020	0,003	0,000	0,322
PI1	1,818	1,825	1,136	2,563	0,240	0,058	13,208
PI2	0,100	0,098	0,082	0,163	0,014	0,000	13,856
PI3	0,741	0,736	0,605	0,965	0,053	0,003	7,143
EVI	1,078	1,080	1,038	1,127	0,019	0,000	1,761
PRI	0,016	0,017	-0,031	0,038	0,014	0,000	88,790
PSRI	-0,064	-0,061	-0,131	-0,052	0,013	0,000	-20,101
PWI	0,977	0,975	0,968	1,000	0,007	0,000	0,707
ARI	1,253	1,253	1,135	1,421	0,052	0,003	4,188
<i>Sem Probe</i>							
SR	20,667	20,482	11,611	29,682	3,841	14,757	18,587
NDVI	0,904	0,907	0,841	0,935	0,019	0,000	2,152
mNDVI	0,640	0,646	0,552	0,721	0,042	0,002	6,631
SGR	8,711	8,789	6,734	13,818	1,141	1,302	13,099
RGR	1,041	1,036	0,849	1,286	0,097	0,009	9,277
NPCI	0,126	0,112	0,041	0,269	0,051	0,003	40,175
SRPI	0,780	0,798	0,576	0,920	0,077	0,006	9,846
NPQI	-0,050	-0,049	-0,085	-0,012	0,012	0,000	-24,050
SIPI	1,009	1,007	1,002	1,033	0,006	0,000	0,637
PI1	2,410	2,411	1,577	3,073	0,259	0,067	10,737
PI2	0,091	0,088	0,063	0,143	0,018	0,000	19,406
PI3	0,650	0,657	0,497	0,826	0,059	0,003	9,008
EVI	0,837	0,836	0,630	1,079	0,107	0,011	12,746
PRI	-0,504	-0,507	-0,544	-0,366	0,027	0,001	-5,447
PSRI	0,003	0,001	-0,003	0,021	0,005	0,000	176,328
PWI	0,918	0,915	0,893	0,968	0,013	0,000	1,383
ARI	0,215	0,085	-1,405	2,393	0,805	0,649	374,257

Onde: SR = Razão Simples, NDVI = Índice de Vegetação de Diferença Normalizada; mNDVI = Índice de Vegetação de Diferença Normalizada Melhorado; SGR = Soma da Reflectância no Verde; RGR = Razão Vermelho Verde; NPCI = Índice de Vegetação de Pigmentos Normalizado; SRPI = Índice da Razão Simples de Pigmentos; NPQI = Índice de Vegetação de feofitinação Normalizado; SIPI = Índice de Pigmentos de Intensiva Estrutura; PI1 = Índice de Pigmentos 1; PI2 = Índice de Pigmentos 2; PI3 = Índice de Pigmentos 3; EVI = Índice de Vegetação Melhorado; PRI = Índice de Reflectância Fotoquímica; PSRI = Índice de Reflectância de Plantas Senescentes; PWI = Índice de Água na Planta; ARI = Índice de Reflectância de Antocianinas; \bar{X} = Média; *Md* = Mediana; *Min* = Valor Mínimo; *Max* = Valor Máximo; *S* = Desvio Padrão; *s*² = Variância; *CV* % = Coeficiente de Variação em Porcentagem.

Com base na classificação do Coeficiente de Variação C.V.% segundo Pimentel Gomes, (1985), as distribuições que demonstraram baixa dispersão para os índices de vegetação foram: NDVI-CP, mNDVI-CP, SRPI-CP, NPQI-CP, SIPI-CP, PI3-CP, EVI-CP, PSRI-CP, PWI-CP, ARI-CP, NDVI-SP, mNDVI-SP, RGR-SP, SRPI-SP, NPQI-SP, SIPI-SP, PL3-SP, PRI-SP e PWI-SP, representando 55,88% das variáveis amostradas. Os índices de vegetação que apresentaram média dispersão foram: SR-CP, SGR-CP, PI1-CP, PI2-CP, SR-SP, SGR-SP, PI1-SP, PI2-SP e EVI-SP, representando 26,47% das variáveis amostradas e o que apresentou alta dispersão foi RGR-CP representando 2,94% das variáveis amostradas.

Já os índices que apresentaram dispersão muito alta dos dados foram: NPCI-CP, PRI-CP, NPCI-SP, PSRI-SP e ARI-SP, representando 14,70% das variáveis amostrada. Este resultado demonstra que a maioria dos dados apresenta baixa dispersão dos dados. Ou seja, a maioria das variáveis reflete homogeneidade do conjunto de dados da amostra.

4.1.6 Análise da condutividade elétrica aparente

Na (Tabela 8) das variáveis da condutividade elétrica aparente (CEa), é demonstrado que todos os valores de Desvio Padrão nas profundidades de 0-20 cm e 20-40 cm tendem a se apresentar afastados em relação à média, os mesmos ficaram dentro do intervalo do desvio médio.

Tabela 8 - Estatística descritiva da análise de condutividade elétrica aparente (CEa).

Variável	\bar{X}	<i>Md</i>	<i>Min</i>	<i>Max</i>	<i>s</i>	<i>s</i> ²	<i>CV</i> %
CEa (0-20cm)	0,306	0,289	0,100	0,736	0,129	0,017	42,097
CEa (20-40cm)	1,292	1,200	0,367	3,000	0,572	0,327	44,232

Onde: CEa = Condutividade Elétrica Aparente; \bar{X} = Média; *Md* = Mediana; *Min* = Valor Mínimo; *Max* = Valor Máximo; *s* = Desvio Padrão; *s*² = Variância; *CV* % = Coeficiente de Variação em Porcentagem.

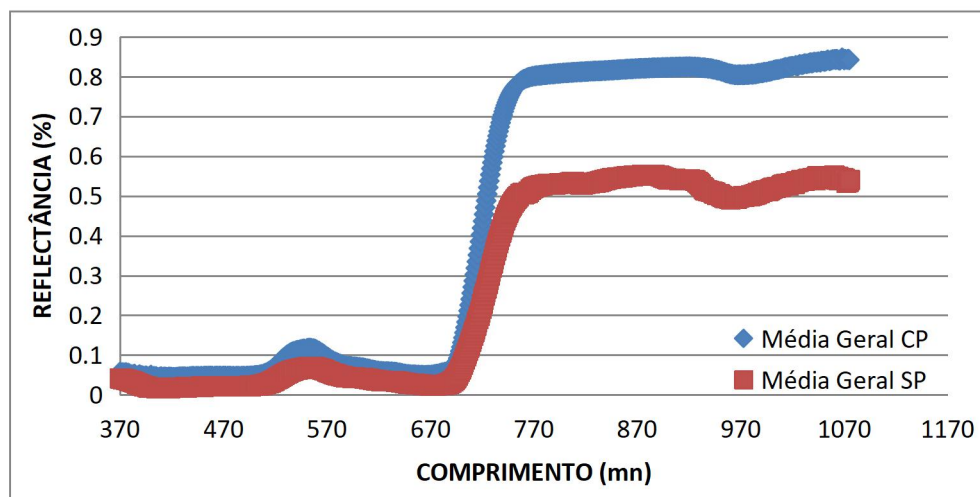
De acordo com a (Tabela 8) o Coeficiente de Variação C.V.% segundo a classificação de Pimentel Gomes, (1985), todas as variáveis de (CEa) de 0-20 e 20-40 cm de profundidade, apresentaram muito alta dispersão na distribuição dos dados. Em estudos em pomares de maçã a (CEa) apresentou altos valores de C. V.% entre 63,95 % e 55,9 % (GEBLER et al., 2015).

A (CEa) do solo pode ser utilizado para identificar a variabilidade espacial do solo para os fatores que invariavelmente afetam a condutividade elétrica (CE), podendo ser utilizada na delimitação de unidades de gestão ou zonas de manejos.

4.2 Assinaturas espectrais dos alvos em estudo

Podemos observar na Figura 12, o comportamento espectral de alvos diferentes de vegetação, sendo a Média Geral (CP), com contato do equipamento e o limbo foliar por clipagem da folha (*leaf clip*), utilizando-se o acessório probe e fonte interna de energia eletromagnética incidente e o segundo (Média geral SP), por sensoriamento próximo do dossel da videira, feito diretamente pela entrada óptica do sensor a 1 m de distância, com ângulo de visada (W_d) de aproximadamente $\pm 25^\circ$, utilizando a refletância da energia eletromagnética da radiação solar, sem a utilização do acessório probe.

Figura 12 – Assinaturas espectrais médias por métodos de leituras de refletâncias



Fonte: autor

Considerando as diferentes regiões espectrais do sensoriamento remoto tanto no limbo de uma folha individual como no dossel de uma planta completa, o comportamento espectral de um alvo de vegetação é influenciado pela refletância por pigmentos foliares, estrutura celular e conteúdo de água, fase fenológica, manejo do dossel e etc. (FORMAGGIO e SANCHES, 2017).

No sensoriamento próximo do dossel, quando se sobrepõem várias camadas de folhas, ocorre um aumento (em comparação com a reflectância de uma folha individual) nos níveis de reflectância nas regiões espectrais do infravermelho próximo até que se atinja um valor estável máximo, denominando reflectância infinita e simbolizado por R_{∞} (ALLEN e RICHARDSON, 1968). Este fenômeno da reflectância infinita é explicado pelas características de reflectância das folhas vegetais na região do infravermelho próximo, conforme a Figura 11. Assim sendo, as propriedades de reflectância de folhas individuais são, evidentemente, fundamentais para o entendimento da refletividade de uma planta inteira ou de um dossel vegetal (comunidade de plantas); contudo, não se pode extrapolar diretamente, sem necessários ajustamentos, os dados espectrais de uma folha individual para os de um dossel.

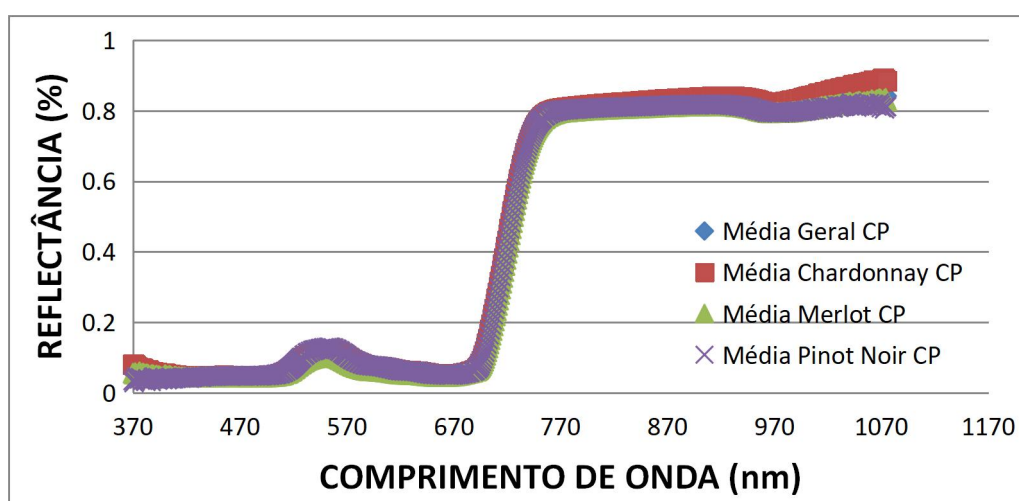
Segundo Formaggio e Sanches, (2017), existem diferenças qualitativas e quantitativas entre os dois espectros (folha individual e dossel) numa base percentual, a reflectância de um dossel é consideravelmente menor do que a de uma folha individual, em virtude de atenuações gerais da radiação devidas a variações no ângulo de iluminação, na orientação das folhas, nas sombras e nas superfícies de fundo não foliares, tais como solo sobre qual crescem as plantas (KNIPLING, 1970). Há então que considerar que os dosséis vegetais são mais simples coleções de folhas, conforme Bauer et al., (1981), e que interações complexas, que não são fatores influenciadores quando espectros de folhas individuais são medidos, devem ser levados em conta no sensoriamento remoto de dosséis que se desenvolvem nas condições de campo.

Entre as mais importantes e mais citadas variáveis que influenciam a reflectância dos dosséis estão o índice de área foliar (IAF), a distribuição de ângulos foliares (DAF), a porcentagem de cobertura de solo (COV), a reflectância do solo e as propriedades ópticas das folhas e dos outros componentes dos dosséis (FORMAGGIO e SANCHES, 2017).

Segundo os mesmos autores, diferenças nesses parâmetros são causadas por variações em fatores culturais e ambientais, incluindo data de plantio, cultivar, espaçamento inter e intrafileiras, adubação e umidade do solo, entre outros. Os ângulos azimutal e zenital do sol e de visada também afetam a reflectância medida das culturas.


Na figura (FIGURA 13 e 14), assinala as diferenças de refletividade que permitem discriminar espécies de plantas e tipos de metodologia de leituras espectrais para diferentes alvos (folha individual e dossel). Segundo Knipling, (1970), as folhas de uma dada espécie tendem a ter algumas características próprias, como superfície (típica de cada espécie), espessura, estrutura interna e conteúdo de pigmentos. O autor afirma que o dossel tanto em sua dimensão horizontal quanto na vertical, tende a ter uma estrutura ou geometria característica, que é determinada pelo tamanho, pela forma e pela orientação das plantas e de suas folhas, bem como pelas práticas culturais e pelas condições ambientais de crescimento.

Figura 13 – Médias das assinaturas espectrais por clipagem nas folhas – CP



Fonte: autor

Figura 14 – Média das assinaturas espectrais por sensoriamento próximo do dossel - SP



Fonte: autor

Assim, alguns autores tem publicados excelentes revisões bibliográficas sobre o comportamento espectral de folhas individuais e dosséis vegetais, entre o quais se pode citar Gates et al., (1965); Knipling (1970); Bauer et al., (1980) e Gausman (1985).

4.3 Teste não paramétrico de normalidade (Kolmogorov-Smirnov)

Para este estudo, foi realizado o teste não paramétrico (Kolmogorov-Smirnov), dado o nível de valor crítico de $p > 0,05$ (Tabela 9). De acordo Ferreira, (2014), as variáveis que apresentaram resultados não significativos, quando ($p > 0,05$) indica normalidade. De outro modo, quando ($p < 0,05$), isso é um indicativo de que o pressuposto da normalidade foi violado, ou seja, o teste foi significativo ao nível de 5% de probabilidade.

Das 88 variáveis estudadas, apenas 31 apresentaram normalidade pelo teste não paramétrico (Kolmogorov-Smirnov), sendo 12 índices de vegetação: mNDVI-CP, EVI-CP, PRI-CP, ARI-CP, SR-SP, mNDVI-SP, RGR-SP, NPQI-SP, PL1 SP, PL2 SP, PL3 SP e ARI-SP e 19 variáveis de parâmetros agronômicos, sendo elas: Análise química do tecido vegetal (N, K, Zn, Mg e B); Análise Física do solo (Umidade e Silte) na profundidade de 0-20 cm, e na profundidade de 20-40 cm (Umidade, Silte e Argila) e na análise química do solo (K, Ca, Mg, CTC Efet., CTC pH 7,0 e Cobre) na profundidade de 0-20 cm e (K, CTC pH 7,0 e Cu) na profundidade de 20-40 cm.

As variáveis dos parâmetros enológicos (SST, ATT), parâmetros fitotécnicos (Número de cachos em três plantas, Massa fresca de três cachos e Produtividade) e o parâmetro físico da Condutividade Elétrica aparente do solo, não apresentaram distribuição normal.

Segundo Cressie (1991), a normalidade dos dados não é uma exigência da geoestatística, é conveniente apenas que no gráfico de distribuição normal o atributo não apresente caudas muito alongadas, o que poderia comprometer as análises.

Para Isaaks e Srivastava, (1989), o mais importante que a normalidade dos dados é a ocorrência ou não do chamado efeito proporcional, em que a média e a variabilidade dos dados sejam constantes na área em estudo, ou seja, ocorrer a estacionariedade necessária ao uso da geoestatística.

Tabela 9 - Teste não paramétrico de dependência (Kolmogorov-Smirnov).

Variáveis	p-valor	Variáveis	p-valor	
<i>Variáveis enológicas</i>		<i>Tecido Vegetal</i>		
Sólidos Solúveis (°Bx)	0,000	Nitrogênio (%) m/m	0,092*	
Acidez Total Titulável (mEq/L)	0,000	Fósforo (%) m/m	0,001	
<i>Variáveis fitotécnicas</i>		Potássio (%) m/m	0,200*	
PM (cachos/planta)	0,004	Cálcio (%) m/m	0,002	
MMC (cachos/g)	0,000	Magnésio (%) m/m	0,014	
PROD. (g/ponto)	0,014	Enxofre (%) m/m	0,000	
<i>Condutividade Elétrica Aparente</i>		Cobre (mg/kg)	0,018	
0 - 20cm	0,000	Zinco (mg/kg)	0,200*	
20 - 40cm	0,000	Ferro (mg/kg)	0,000	
<i>Índices de Vegetação</i>		Manganês (mg/kg)	0,200*	
	CP	SP	Boro (mg/kg)	0,051
SR	0,000	0,200*	<i>Química do Solo</i>	
NDVI	0,000	0,000	Alumínio (cmolc/dm ³)	0-20cm
mNDVI	0,052*	0,066*	Argila (%)	20-40cm
SGR	0,000	0,000	Boro (mg/dm ³)	0,000
RGR	0,013	0,200*	Cálcio (cmolc/dm ³)	0,200*
NPCI	0,045	0,000	Cobre (mg/dm ³)	0,062*
SRPI	0,016	0,001	CTC Efet. (cmolc/dm ³)	0,200*
NPQI	0,029	0,200*	CTC pH 7 (cmolc/dm ³)	0,200*
SIPI	0,001	0,000	Enxofre (mg/dm ³)	0,003
PI1	0,037	0,200*	Fósforo (mg/dm ³)	0,000
PI2	0,000	0,200*	Magnésio (cmolc/dm ³)	0,200*
PI3	0,007	0,200*	Matéria Orgânica (%)	0,000
EVI	0,200*	0,002*	pH H ₂ O (01:01)	0,042
PRI	0,053*	0,013	Potássio (cmolc/dm ³)	0,200*
PSRI	0,000	0,000	Zinco (mg/dm ³)	0,000
PWI	0,000	0,007	<i>Física do Solo</i>	
ARI	0,200*	0,070*	Umidade (g/g)	0-20cm
			Areia (%)	20-40cm
			Silte (%)	0,000
			Argila (%)	0,088*
				0,095*
				0,029
				0,200*

* p-valor = nível de valor crítico de $p > 0,05$.

Estudos em pomares de maçã as variáveis de qualidade do fruto isolado (Brix, tamanho ou diâmetro, firmeza da polpa e cor do fruto) não apresentaram dependência espacial (GEBLER et al., 2015).

4.4 Correlação linear simples por Pearson (r)

Para este estudo foi realizado a análise de correlação estatística através da correlação linear simples de Pearson ao nível de 5% com as variáveis que apresentaram normalidade nas distribuições. Das 31 variáveis normalizadas obteve-se 139 correlações significativas, (Tabelas 10, 11 e 12).

Tabela 10 - Correlação linear de Person (r) entre IV's e variáveis do tecido vegetal.

Índices de Vegetação	Nitrogênio (%) m/m	Potássio (%) m/m	Zinco (mg/kg)	Manganês (mg/kg)	Boro (mg/kg)
mNDVI CP	-0,271*	-0,249*	-0,110 ^{ns}	-0,356 ^{ns}	-0,363*
EVI CP	-0,068 ^{ns}	0,135 ^{ns}	0,160 ^{ns}	0,250*	0,220 ^{ns}
PRI CP	-0,214 ^{ns}	-0,379*	-0,204 ^{ns}	-0,325*	-0,228 ^{ns}
ARI CP	-0,374*	0,221 ^{ns}	-0,123 ^{ns}	-0,294*	-0,402*
SR SP	-0,230*	-0,401*	-0,447*	-0,424*	-0,415*
mNDVI SP	-0,305*	-0,267*	-0,436*	-0,407*	-0,441*
RGR SP	-0,286*	-0,160 ^{ns}	-0,402**	-0,405**	-0,424**
NPQI SP	-0,065 ^{ns}	-0,412*	-0,223 ^{ns}	-0,316*	-0,287*
PI1 SP	0,106 ^{ns}	0,460*	0,259*	0,295*	0,261*
PI2 SP	0,260*	0,335*	0,428*	0,376*	0,375*
PI3 SP	-0,025 ^{ns}	-0,506**	-0,266*	-0,249*	-0,169 ^{ns}
ARI SP	0,007 ^{ns}	0,566*	0,280*	0,291*	0,197 ^{ns}

* Correlação significativa ao nível de 5% de probabilidade; ** correlação significativa ao nível de 1% de probabilidade; ^{ns} não significativo.

Entre os coeficientes representados pelo estudo da correlação linear simples de Pearson observou-se que houve 68 casos de coeficientes de correlação positiva, variando entre (0,235 a 0,572) e 71 casos de coeficientes negativos, (inversamente proporcional) variando entre (-0,565 à - 0,230).

Tabela 11 - Correlação linear de Person (r) entre IV's e variáveis físicas do solo.

Índices de Vegetação	Profundidade de 0 - 20 cm		Profundidade de 20 - 40 cm		
	Umidade (g/g)	Silte (%)	Umidade (g/g)	Silte (%)	Argila (%)
mNDVI CP	-0,193 ^{ns}	0,044 ^{ns}	-0,241*	0,235*	-0,179 ^{ns}
EVI CP	0,060 ^{ns}	0,199 ^{ns}	0,113 ^{ns}	0,310*	-0,310*
PRI CP	-0,100 ^{ns}	0,164 ^{ns}	-0,151 ^{ns}	0,165 ^{ns}	-0,137 ^{ns}
ARI CP	-0,194 ^{ns}	0,252*	-0,220 ^{ns}	0,070 ^{ns}	-0,091 ^{ns}
SR SP	-0,056 ^{ns}	0,022 ^{ns}	-0,158 ^{ns}	0,110 ^{ns}	-0,104 ^{ns}
mNDVI SP	-0,025 ^{ns}	0,129 ^{ns}	-0,171 ^{ns}	0,155 ^{ns}	-0,177 ^{ns}
RGR SP	-0,034 ^{ns}	0,248*	-0,159 ^{ns}	0,198 ^{ns}	-0,218 ^{ns}
NPQI SP	-0,265*	-0,037 ^{ns}	-0,302*	0,060 ^{ns}	-0,008
PI1 SP	0,183 ^{ns}	-0,100 ^{ns}	0,285*	-0,173 ^{ns}	0,138 ^{ns}
PI2 SP	0,022 ^{ns}	-0,100 ^{ns}	0,163 ^{ns}	-0,149 ^{ns}	0,154 ^{ns}
PI3 SP	-0,155 ^{ns}	0,001 ^{ns}	-0,255*	0,117 ^{ns}	-0,078 ^{ns}
ARI SP	0,166 ^{ns}	0,114 ^{ns}	0,253*	-0,066 ^{ns}	0,014 ^{ns}

* Correlação significativa ao nível de 5% de probabilidade; ^{ns} não significativo.

Os coeficientes de correlação linear simples por Pearson obtidos da análise foram interpretados com base em 7 categorias segundo a classificação de

magnitudes da correlação de Ferreira, (2014), encontrando-se 65 correlações com magnitudes moderadas, sendo 29 moderadas positivas e 36 moderada negativa.

Tabela 12 - Correlação linear de Person (r) entre IV's e variáveis químicas do solo.

Índices de Vegetação	Profundidade de 0 - 20 cm					Profundidade de 20 - 40 cm			
	Potássio (mg/dm ³)	Cálcio (cmol/dm ³)	Magnésio (cmol/dm ³)	CTC Efet. (cmol/dm ³)	CTC pH7 (cmol/dm ³)	Cobre (mg/dm ³)	Potássio (mg/dm ³)	CTC pH7 (mg/dm ³)	Cobre (mg/dm ³)
mNDVI CP	-0,495*	0,479*	0,501*	0,491*	0,474*	-0,208 ^{ns}	-0,534*	0,246*	-0,165 ^{ns}
EVI CP	-0,015 ^{ns}	0,123 ^{ns}	0,088 ^{ns}	0,120 ^{ns}	0,118 ^{ns}	-0,089 ^{ns}	-0,106 ^{ns}	0,198 ^{ns}	-0,031 ^{ns}
PRI CP	-0,565*	0,521*	0,528*	0,538*	0,572*	-0,554*	-0,520*	0,376*	-0,484*
ARI CP	-0,107 ^{ns}	0,360*	0,273*	0,367*	0,260*	-0,018 ^{ns}	-0,049 ^{ns}	-0,045 ^{ns}	0,030 ^{ns}
SR SP	-0,454*	0,455*	0,432*	0,471*	0,534*	-0,343*	-0,346*	0,306*	-0,252*
mNDVI SP	-0,471*	0,498*	0,440*	0,508*	0,505*	-0,255*	-0,375*	0,280*	-0,138 ^{ns}
RGR SP	-0,447*	0,433*	0,351*	0,435*	0,385*	-0,183 ^{ns}	-0,304*	0,179 ^{ns}	-0,106 ^{ns}
NPQI SP	-0,450*	0,277*	0,255*	0,308*	0,375*	-0,472*	-0,240*	0,342*	-0,389*
PI1 SP	0,546*	-0,409*	-0,352*	-0,425*	-0,494*	0,474*	0,325*	-0,339*	0,420*
PI2 SP	0,446*	-0,484*	-0,446*	-0,500*	-0,545*	0,325*	0,321*	-0,311*	0,217 ^{ns}
PI3 SP	-0,465*	0,329*	0,292*	0,350*	0,454*	-0,491*	-0,268*	0,322*	-0,448*
ARI SP	0,460*	-0,335*	-0,333*	-0,359*	-0,484*	0,502*	0,316*	-0,336*	0,434*

* Correlação significativa ao nível de 5% de probabilidade; ^{ns} não significativo.

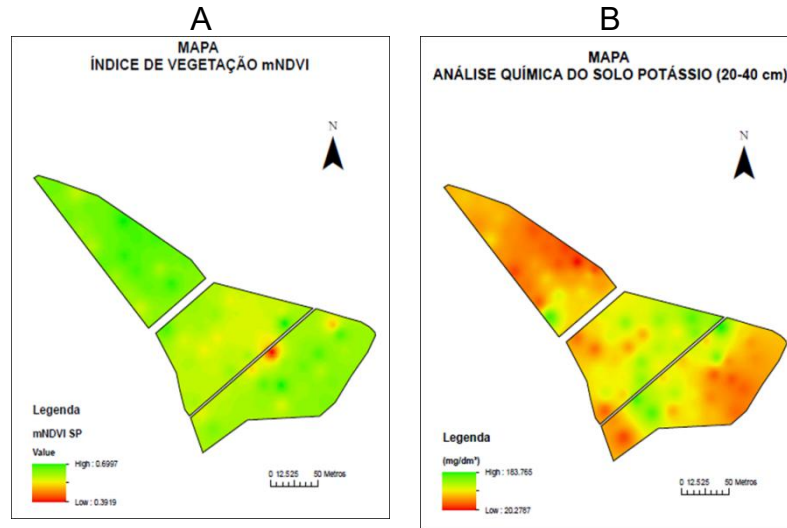
Os índices de vegetação que apresentaram a maior quantidade de correlações por Pearson em relação às variáveis de parâmetros agrônômicos testados foram o SR-SP, NPQI-SP e PI1-SP, com 14 correlações significativas cada. Já considerando a magnitude dos resultados, os índices de vegetação com maiores número de correlações moderadas positivas foram: mNDVI-CP, PRI-CP, mNDVI-SP, PI1-SP e ARI-SP, apresentando 4 correlações cada, enquanto que o SR-SP obteve o maior número de correlações moderadas negativas com 5 correlações significativas.

4.4.1 Índice mNDVI-CP

O índice de vegetação mNDVI-CP foi identificado 12 correlações de linear simples por Pearson ao nível de 5%, sendo 6 correlações com magnitude moderadas. Para as magnitudes moderada negativa apresentou-se a variável K da análise química do solo nas profundidades de 0-20 e 20-40 cm; já para magnitude moderada positiva apresentou-se as variáveis Ca, Mg, CTC Efetiva e CTC pH 7,0 da análise química do solo na profundidade de 0-20 cm.

O maior coeficiente de correlação por Pearson do índice mNDVI-CP, ocorreu com o K do solo na profundidade de 20-40 cm (Figura 15).


Figura 15 – Mapa de prescrição do índice de vegetação mNDVI-CP (A) e da variável K da análise química do solo 20-40 cm (B).



Fonte: Autor.

A variável K da análise química do solo 20-40 cm apresentou coeficiente de magnitude negativa de (-0.534) e valor de coeficiente de determinação (r^2) igual 0.285, ou seja, 72% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme a Figura 16.

Figura 16 - Diagrama de dispersão entre o índice de vegetação mNDVI-CP e a variável K da análise química do solo (20-40 cm).



Fonte: Autor.

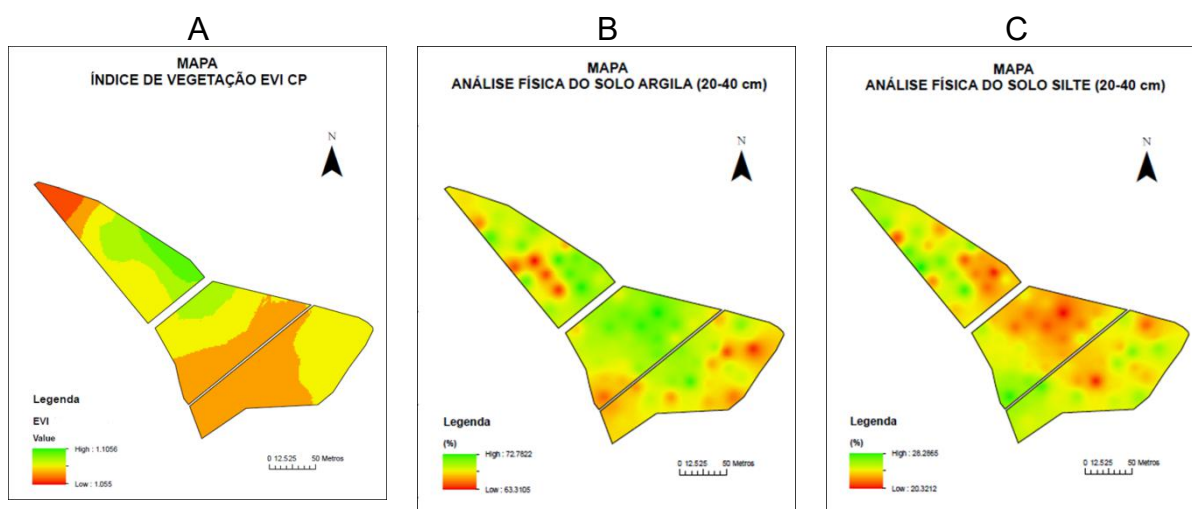
Os autores Skianis et al., (2009) e C. Jurgens (1997) demonstraram em seus trabalhos que o índice de vegetação mNDVI (*Modified NDVI*) possui considerada correlação com propriedades bioquímicas da vegetação. Segundo Fuentes et al., (2001), o mNDVI se correlaciona com o conteúdo de clorofila das folhas.

4.4.2 Índice EVI-CP

O índice de vegetação EVI-CP apresentou 3 correlações com coeficientes de magnitude fracas. O maior coeficiente de correlação por Pearson do índice EVI-CP ocorreu com as variáveis de textura da análise física do solo na profundidade de 20-40 cm (Figura 17B e Figura 17C), sendo que a Argila apresentou coeficiente de correlação negativa de (-0.310) e o Silte apresentou correlação positiva de (0.310), sendo assim, ambos obtiveram o valor de coeficiente de determinação (r^2) de 0.096, ou seja, 99.9% da variação total permanecem sem explicação, demonstrando uma tendência fraca de correlação, conforme a Figura 18A e 18B.

O índice EVI-CP também obteve correlação com magnitude fraca positiva com a variável Mn da análise do tecido vegetal, apresentando coeficiente de (0.250).

Figura 17 – Mapa de prescrição do índice de vegetação EVI-CP (A), variável Argila 20-40 cm (B) e Silte 20-40 cm da análise física do solo (C).

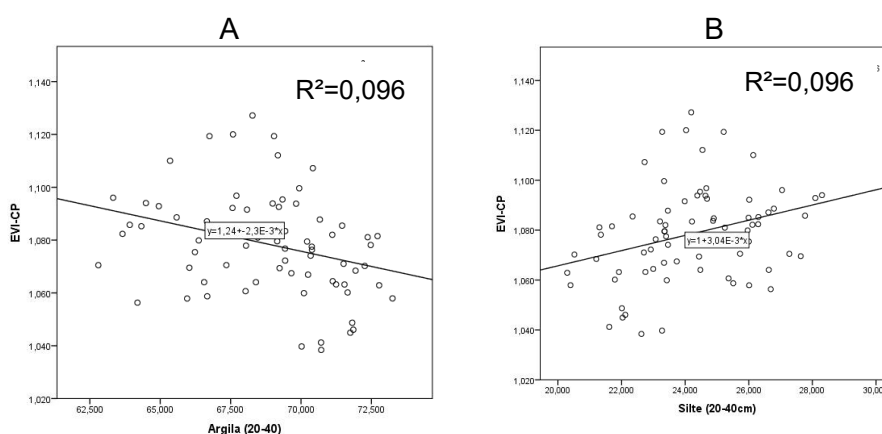


Fonte: Autor.

Segundo Justice et al., (1998), o índice EVI (*Índice de Vegetação Melhorado*) é correlacionado com a biomassa, apresentando resposta sobre dossel, tornando-se

indicativo das propriedades biofísicas dinâmicas relacionados com a produtividade e o balanço de energia da vegetação. Ponzoni et al., (2012), também tem demonstrado a capacidade do índice de vegetação EVI para o sensoriamento remoto na detecção da biomassa na vegetação. Os autores Huete; Justice e Liu, (1994); Huete; Liu; Batchily e Van Leeuwen, (1997), ressaltam que o índice EVI melhora a sensibilidade de detecção em regiões com maiores biomassa, reduzindo a influencia do sinal do solo e atmosfera sobre o a resposta do dossel.

Figura 18 - Diagrama de dispersão entre o índice de vegetação EVI-CP e o atributo Argila 20-40 cm (A) e Silte 20-40 cm (B) da análise física do solo.



Fonte: Autor.

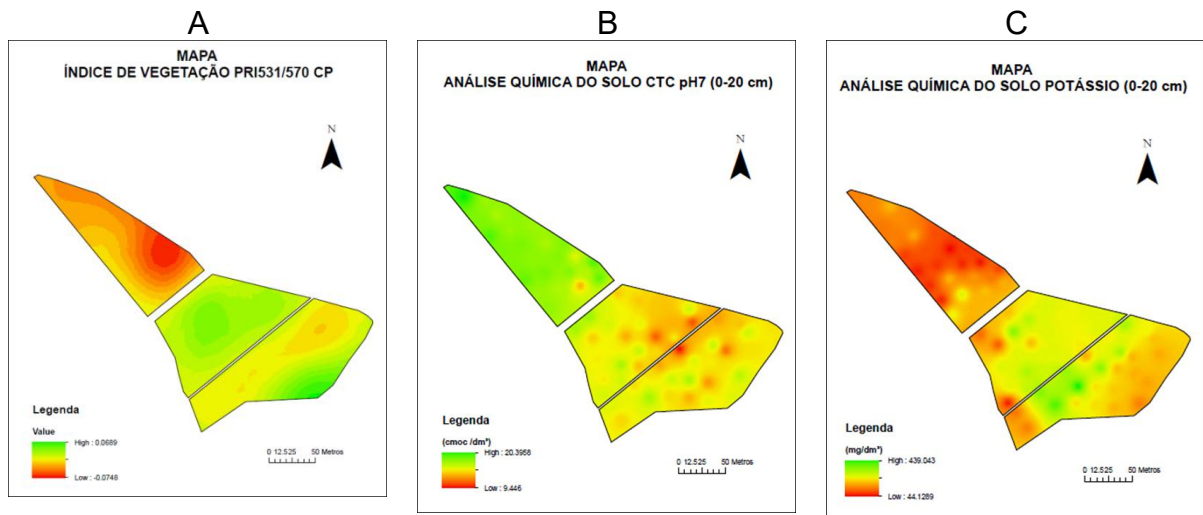
4.4.3 Índice PRI-CP

O índice de vegetação PRI-CP ocorreu 8 correlações por Pearson, sendo 4 correlações moderadas positivas com as variáveis: Ca, Mg, CTC Efetiva e CTC pH 7,0 da análise química do solo na profundidade de 0-20 cm e 4 correlações negativas moderadas com as variáveis química da análise do solo K e Cu nas duas profundidades (0-20 e 40-20 cm).

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice PRI-CP, ocorreu com a variável CTC pH 7,0 na profundidade de 0-20 cm (Figura 19B), apresentando coeficiente de correlação moderada positiva de (0.572), sendo seu valor de coeficiente de determinação (r^2) igual 0.327, ou seja, 68% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme o Figura 20A.

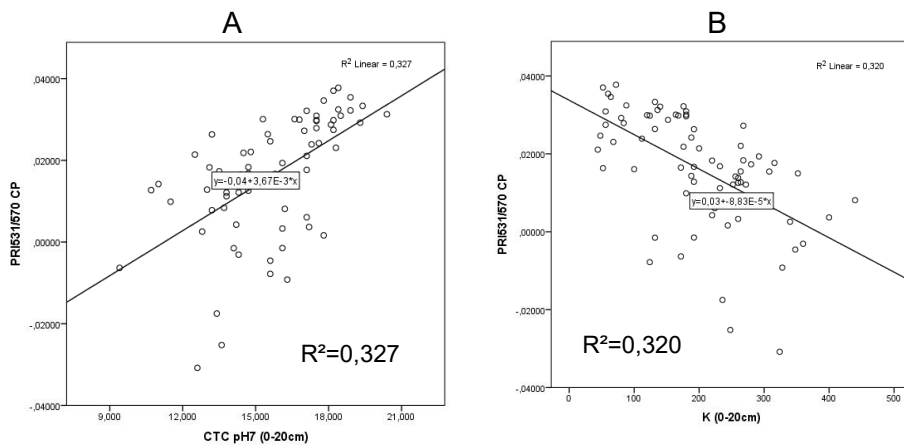
O maior coeficiente de correlação com magnitude moderada negativa, também ocorreu com o índice de vegetação PRI-CP, se correlacionando com a variável a K na profundidade de 0-20 cm (Figura 19C), apresentando coeficiente de correlação moderada negativa de (-0.565), sendo seu valor de coeficiente de determinação (r^2) é igual 0.320, ou seja, 68% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 20B.

Figura 19 – Mapa de prescrição do índice de vegetação PRI-CP (A), variável CTC pH 7,0 0-20 cm (B) e K 0-20 cm da análise química do solo (C).



Fonte: Autor.

Figura 20 - Diagrama de dispersão entre o índice de vegetação PRI-CP e as variáveis CTC pH 7,0 0-20 cm (A) e Potássio 0-20 cm (B) da análise química do solo.



Fonte: Autor.

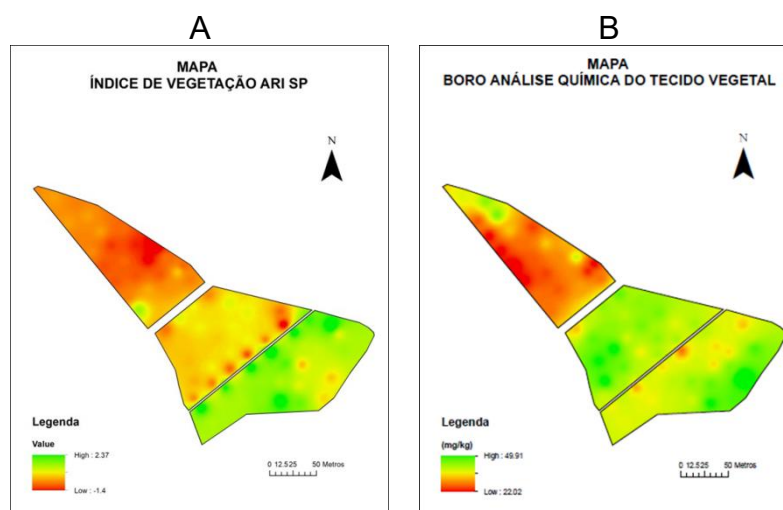
O índice de vegetação PRI tem sido utilizado em razão de sua consistência no relacionamento com a eficiência do uso da luz, tendo, portanto, o potencial de proporcionar um monitoramento global contínuo da produtividade primária das plantas (FORMAGGIO e SANCHES, 2017).

O Índice de vegetação PRI (*Índice de Reflectância Fotoquímica*) foi proposto por Gamon et al., (1992) como um indicador do estado de desoxidação dos pigmentos xantofilas relacionados com processos fotossintéticos. Este índice tem sido usado para avaliar a eficiência do uso da luz segundo os autores Serrano e Peñuelas, (2005); Guo e Trotter, (2004); Sims et al., (2006); Nakaji et al., (2006); Trotter et al., (2002); Strachan et al., (2002); Nichol et al., (2000, 2002); Asner et al., (2005); Drolet et al., (2005); Fuentes et al., (2006), fotossíntese por: Nichol et al., (2000 e 2006); Guo e Trotter, (2004); Sims et al., (2006); Evain et al., (2004) e, mais recentemente, estresse hídrico nas lavouras segundo Peguero-Pina et al., (2008); Suárez et al., (2008, 2009).

4.4.4 Índice ARI-CP

O índice de vegetação ARI-CP apresentou 8 correlações por Pearson apresentando apenas uma correlação com magnitude moderada com a variável da análise química do tecido vegetal Boro (Figura 21).


Figura 21 – Mapa de prescrição do índice de vegetação ARI-CP (A) e a variável Boro da análise química do tecido vegetal (B).



Fonte: Autor.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice ARI-CP, ocorreu com a variável Boro do tecido vegetal, apresentando coeficiente de correlação moderada negativa de (-0.402), sendo seu valor de coeficiente de determinação (r^2) igual 0.162, ou seja, 84% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 22.

Figura 22 - Diagrama de dispersão entre o índice de vegetação ARI-CP e a variável Boro da análise química do tecido vegetal.



Fonte: Autor.

O índice de vegetação ARI (*Índice de Reflectância da Antocianina*) tem sido usado para detectar concentrações mais altas de antocianina na vegetação, permitindo especializar as concentrações deste parâmetro químico, de acordo com os autores Gitelson; MerzLyak; Chivkunova, (2001).

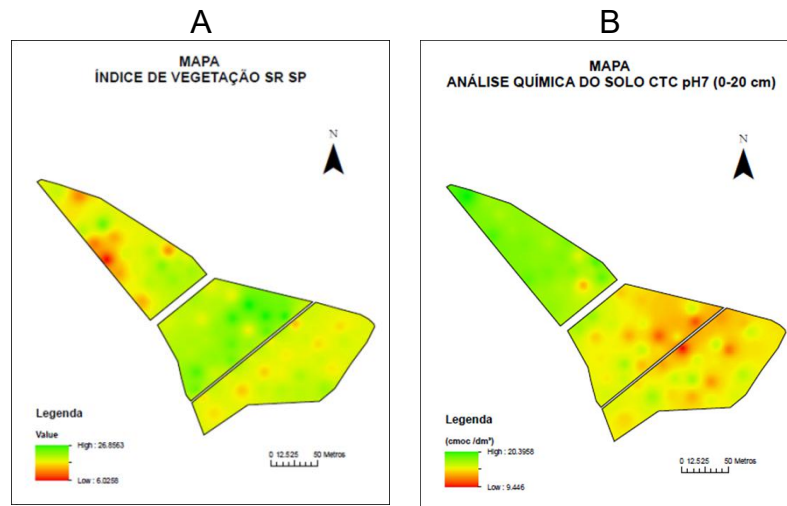
4.4.5 Índice SR-SP

O índice de vegetação SR-SP verificou-se 9 correlações linear simples de Pearson, apresentando 4 correlações com magnitude moderada positiva com as variáveis Ca, Mg, CTC Efetiva e CTC pH 7,0 da análise química do solo na profundidade de 0-20 cm e 5 correlações moderadas negativas com as variáveis K, Zn, Mg e B da análise química do tecido vegetal e a variável K da análise química do solo na profundidade de 0-20 cm.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice SR-SP, ocorreu com a variável CTC do solo a pH 7,0 na profundidade


de 0-20 cm (Figura 23), apresentando coeficiente de correlação moderada positiva de (0.534), sendo seu valor de coeficiente de determinação (r^2) igual 0.285, ou seja, 72% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 24.

Figura 23 - Mapa de prescrição do índice de vegetação SR – SP (A) e a variável CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo (B).



Fonte: Autor.

Figura 24 - Diagrama de dispersão entre o índice de vegetação SR - SP e a variável o CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo.



Fonte: Autor.

Segundo Jordan (1969), o índice de vegetação SR (*simple ration*) possui correlação com a cobertura vegetal. Segundo o autor, este índice é baseado no princípio de que as folhas absorvem relativamente mais vermelho que a luz

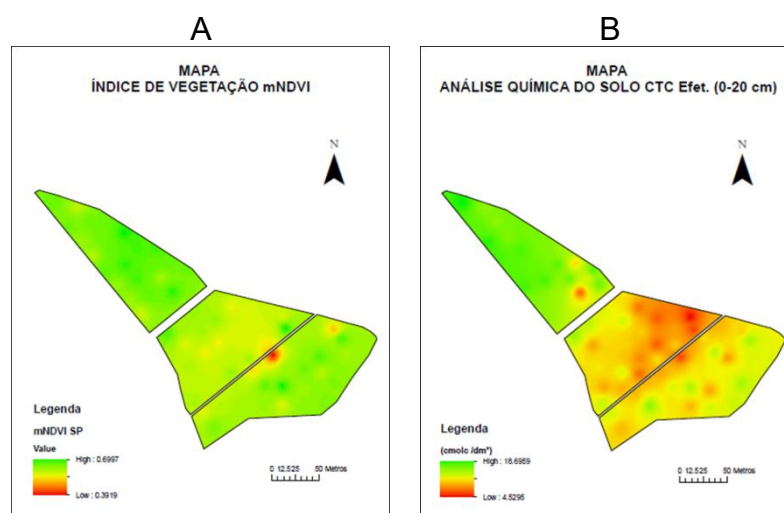
infravermelha e, portanto, quanto mais folhas estiverem presentes no dossel, maior será a proporção.

4.4.6 Índice mNDVI-SP

O índice de vegetação mNDVI-SP ocorreram 13 correlações linear simples de Pearson, sendo 4 correlações moderada positivas com as variáveis da análise química do solo K, Ca, Mg, CTC Efetiva e CTC pH 7,0 na profundidade de 0-20 cm; 4 correlações moderadas negativas com as variáveis Zn, Mg, B da análise química do tecido vegetal e uma correlação com a variável K da análise química do solo na profundidade de 0-20 cm.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice mNDVI-SP, ocorreu com a variável CTC Efetiva do solo na profundidade de 0-20 cm (Figura 25), apresentando coeficiente de correlação moderada positiva de (0.508), sendo seu valor de coeficiente de determinação (r^2) igual 0.241, ou seja, 76% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 26.

Figura 25 – Mapas de prescrição do índice de vegetação mNDVI-SP (A) e a variável CTC Efetiva na profundidade de 0-20 cm da análise química do solo (B).

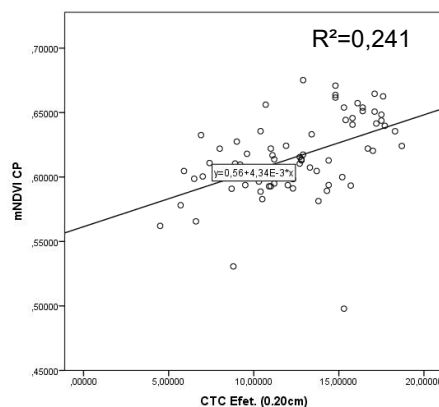


Fonte: Autor.

Proposto por Fuentes et al., (2001) o índice de vegetação mNDVI (*Modified NDVI*) possui correlação com o conteúdo de clorofilas das folhas. Para C. Jurgens

(1997), este índice de vegetação pode ser utilizado para determinar os danos causados pela geada na agricultura com base nos dados do Landsat TM.

Figura 26 - Diagrama de dispersão entre o índice de vegetação mNDVI-SP e a variável CTC Efetiva na profundidade de 0-20 cm da análise química do solo.



Fonte: Autor.

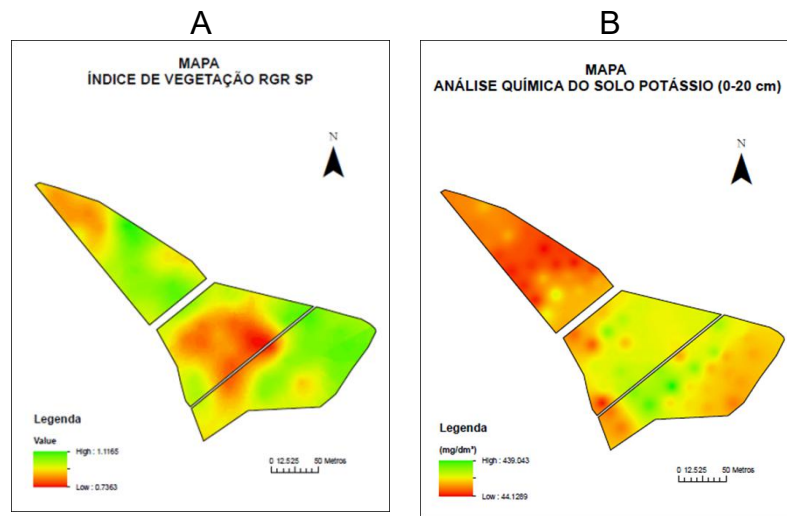
4.4.7 Índice RGR-SP

O índice de vegetação RGR-SP apresentou 11 correlações linear simples de Pearson, sendo 2 correlações moderada positiva com as variáveis Ca e CTC Efetiva do solo na profundidade de 0-20 cm; 4 correlações moderadas negativas, sendo Zn, Mg e K do tecido vegetal e K na profundidade de 0-20 cm.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice RGR-SP, ocorreu com a variável K na profundidade de 0-20 cm (Figura 27), apresentando coeficiente de correlação moderada negativa de (-0.447), sendo seu valor de coeficiente de determinação (r^2) igual 0.20, ou seja, 80% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme o Figura 28.

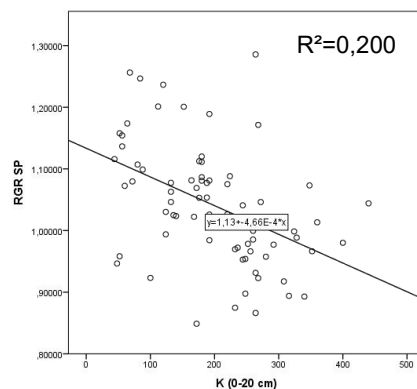
Proposto por Fuentes et al., (2001) o índice de vegetação RGR (*Red/green ration*) possui correlação com o conteúdo de clorofilas e antocianinas. Os autores C. Gamon, et al., (1999) em seus estudos, destacam a correlação do índice RGR com a antocianina.

Figura 27 – Mapa de prescrição do índice de vegetação RGR-SP (A) e a variável K na profundidade de 0-20 cm da análise química do solo (B).



Fonte: Autor.

Figura 28 - Diagrama de dispersão entre o índice de vegetação RGR-SP e a variável K na profundidade de 0-20 cm da análise química do solo.



Fonte: Autor.

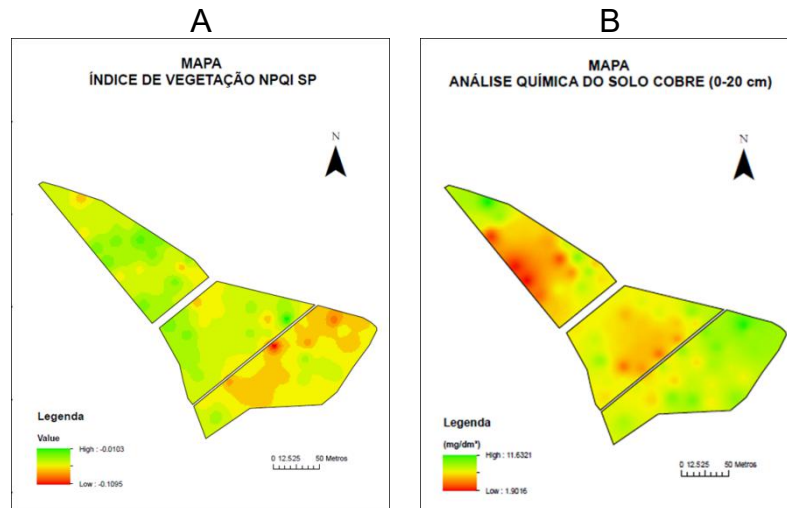
4.4.8 Índice NPQI-SP

O índice de vegetação NPQI-SP apresentou 3 correlações moderadas negativa com as variáveis: K do tecido vegetal e K e Cu do solo na profundidade 0-20 cm.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice NPQI-SP, ocorreu com Cu na profundidade de 0-20 cm (Figura 29), apresentando coeficiente de correlação moderada negativa de (-0.472), sendo seu valor de coeficiente de determinação (r^2) igual 0.223, ou seja, 78% da variação total


permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 30.

Figura 29 – Mapa de prescrição do índice de vegetação NPQI-SP (A) e a variável Cobre na profundidade de 0-20 cm da análise química do solo (B).



Fonte: Autor.

Figura 30 - Diagrama de dispersão entre o índice de vegetação NPQI-SP e a variável Cobre na profundidade de 0-20 cm da análise química do solo.



Fonte: Autor.

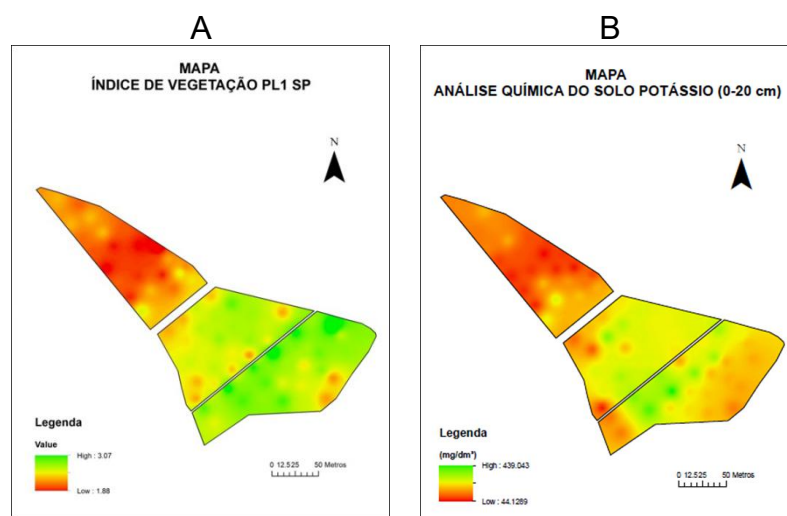
Segundo Zarco-Tejado (2000) o índice de vegetação NPQI (*Normalized Phaeophytinization*) possui correlação com a degradação da clorofila e detecção precoce do estresse.

4.4.9 Índice PI1-SP

O índice de vegetação PI1-SP ocorreram 14 correlações linear simples de Pearson, sendo 3 correlações moderadas positiva com as variáveis: K da análise química do tecido vegetal e K e Cu da análise química do solo na profundidade de 0-20 cm; 3 correlações moderadas negativas com as variáveis da análise química do solo K, CTC Efetiva e CTC pH 7,0 na profundidade de 0-20 cm.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice PI1-SP, ocorreu com a variável K do solo na profundidade de 0-20 cm (Figura 31), apresentando coeficiente de correlação moderada positiva de (0.546), sendo seu valor de coeficiente de determinação (r^2) igual 0.298, ou seja, 71% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 32.


Figura 31 - Mapa de prescrição do índice de vegetação PI1-SP (A) e a variável K na profundidade de 0-20 cm da análise química do solo (B).



Fonte: Autor.

Segundo Zarco-Tejado (2000) o índice de vegetação PI1 (*Pigment index*) possui correlação com o estado de estresse da planta.

Figura 32 - Diagrama de dispersão entre o índice de vegetação PI1-SP e a variável K na profundidade de 0-20 cm da análise química do solo.



Fonte: Autor.

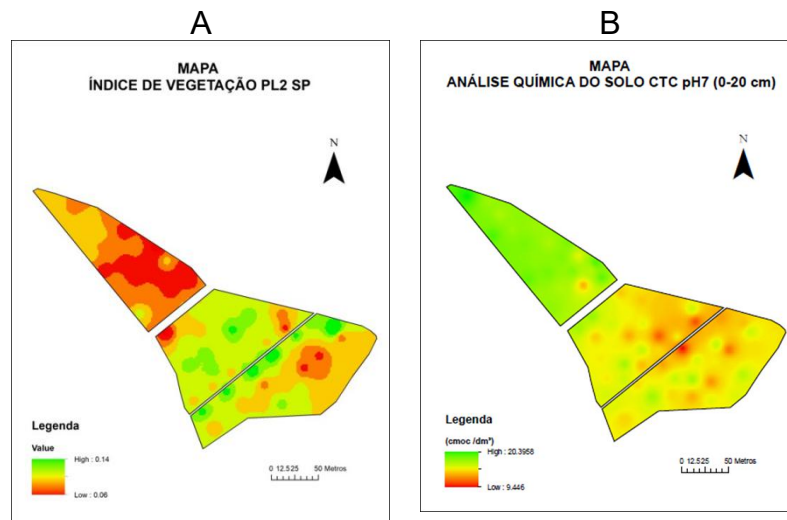
4.4.10 Índice PI2-SP

Para o índice de vegetação PI2-SP ocorreram 13 correlações linear simples de Pearson, sendo 2 correlações moderada positiva com as variáveis Zn da do tecido vegetal e K do solo na profundidade de 0-20 cm e 4 correlações moderadas negativas com as variáveis do solo (K, Ca, Mg, CTC Efetiva e CTC pH 7,0) na profundidade de 0-20 cm.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice PI2-SP, ocorreu com a variável da análise química do solo CTC pH 7,0 na profundidade de 0-20 cm (Figura 33), apresentando coeficiente de correlação moderada negativa de (-0.545), sendo seu valor de coeficiente de determinação (r^2) igual 0.297, ou seja, 71% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 34.

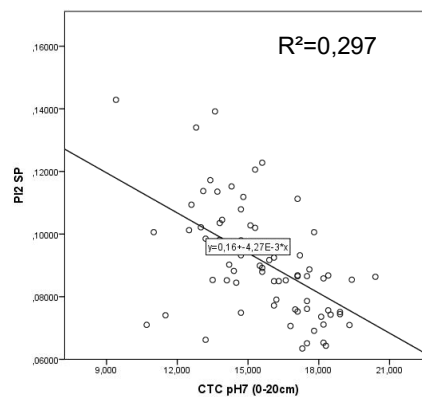
Segundo Zarco-Tejado (2000) o índice de vegetação PI2 (*Pigment index*) possui correlação com o estado de estresse da planta.

Figura 33 – Mapa de prescrição do índice de vegetação PI2-SP (A) e a variável CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo (B).



Fonte: Autor.

Figura 34 - Diagrama de dispersão entre o índice de vegetação PI2-SP e a variável CTC pH 7,0 na profundidade de 0-20 cm da análise química do solo.



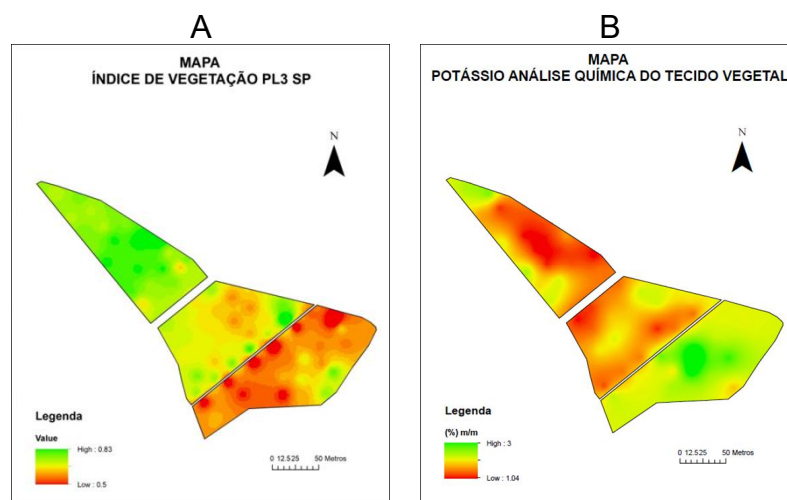
Fonte: Autor.

4.4.11 Índice PI3-SP

Já para o índice de vegetação PI3-SP ocorreram 12 correlações de Pearson, sendo uma correlação moderada positiva com a variável CTC do solo a pH 7,0 da análise química do solo na profundidade de 0-20 cm e 4 correlações moderadas negativa com as variáveis: Zn do tecido vegetal; K do solo na profundidade de 0-20cm e Cu do solo nas duas profundidades (0-20 e 20-40 cm).


O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice PI3-SP, ocorreu com a variável K do tecido vegetal (Figura 35), apresentando coeficiente de correlação moderada negativa de (-0.506), sendo seu valor de coeficiente de determinação (r^2) igual 0.256, ou seja, 75% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 36.

Figura 35 – Mapa de prescrição do índice de vegetação PI3-SP (A) e a variável K da análise química do tecido vegetal (B).



Fonte: Autor.

Figura 36 - Diagrama de dispersão entre o índice de vegetação PI3-SP e a variável K da análise química do tecido vegetal.



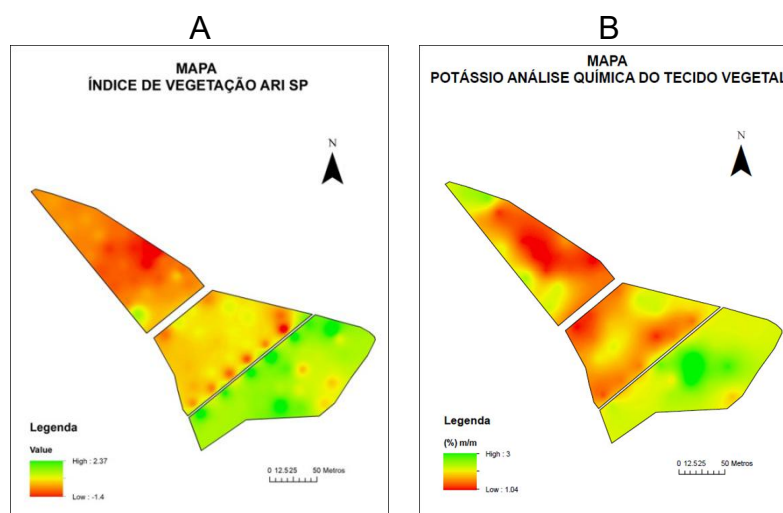
Fonte: Autor.

Para Lichtenthaler et al., (1996) o índice de vegetação PI2 (*Pigment index*) é um índice de saúde da vegetação, e possui correlação com a fluorescência da clorofila.

4.4.12 Índice ARI-SP

O índice de vegetação ARI-SP (Figura 37A) ocorreram 13 correlações linear simples de Pearson, sendo 4 correlações moderadas positiva com as variáveis: K do tecido vegetal (Figura 37B), K e Cu do solo na profundidade de 0-20 cm e Cu do solo na profundidade de 20-40 cm. Já para a correlação moderada negativa apresentou-se a variável CTC do solo a pH 7,0 na profundidade de 20-40 cm.


Figura 37 - Mapa de prescrição do índice de vegetação ARI-SP (A) e a variável K da análise química do tecido vegetal (B).



Fonte: Autor.

O maior coeficiente de correlação significativa por Pearson, correlacionado com o índice ARI-SP, ocorreu com a variável K do tecido vegetal, apresentando coeficiente de correlação moderada positiva de (0.566), sendo seu valor de coeficiente de determinação (r^2) igual 0.321, ou seja, 68% da variação total permanecem sem explicação, demonstrando uma tendência moderada de correlação, conforme Figura 38.

Figura 38 - Diagrama de dispersão entre o índice de vegetação ARI-SP e a variável K da análise química do tecido vegetal.



Fonte: Autor.

4.5 Análise variográfica das variáveis dos parâmetros agrônômicos

Para este estudo, as análises de dependência espacial da análise do tecido vegetal, análise química e física do solo nas profundidades de 0-20 e 20-40 e os índices de vegetação foram realizados com as variáveis que obtiveram correlações lineares simples de Pearson (r) significativa ao nível de 5%. Para fins desta análise foi considerado a classificação de dependência espacial de Cambardella et al.; (1994), que relaciona o Efeito Pepita com o Patamar, esta medida é mais utilizado em trabalhos com geoestatística envolvendo agricultura, (CARVALHO, 2003; SALVIANO et al., 1998; ZARDO, 2009; SEBEM, 2017).

Para definição dos modelos e ajustes dos semivariogramas adotou-se como critério de análise para este estudo: o menor erro da soma de quadrados de erros (SQR), o menor efeito pepita (C_0), a análise de variância (S^2), a classificação de dependência espacial (DE) e o menor alcance (ranger) em relação à distância máxima (lag distance) (RIBEIRO JR. e DIGGLE, 2001; SEBEM, 2017).

Todas as variáveis analisadas apresentaram o modelo isotrópico em seus semivariogramas, ou seja, os semivariogramas amostrais dependeram somente da distância de separação e não da direção (VIEIRA, 1998).

4.5.1 Análise variográfica do tecido vegetal

Na análise do índice de dependência espacial (DE) das variáveis do tecido vegetal do vinhedo, realizada segundo critérios descritos por Cambardella et al.; (1994), indica haver estrutura de dependência espacial considerada moderada, com valores entre 25% e 75%, para as variáveis N e Zn e estrutura de dependência espacial considerada forte para K, Mn e B, com valores inferiores a 25% (Tabela 13).

A variável da análise química do tecido vegetal, N, apresentou moderada dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustada ao modelo Exponencial, enquanto que a variável da análise química do tecido vegetal, K, apresentou forte dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustada ao modelo Exponencial. Optou-se por interpolar ambas pelo método de Krigagem (Figura 39).

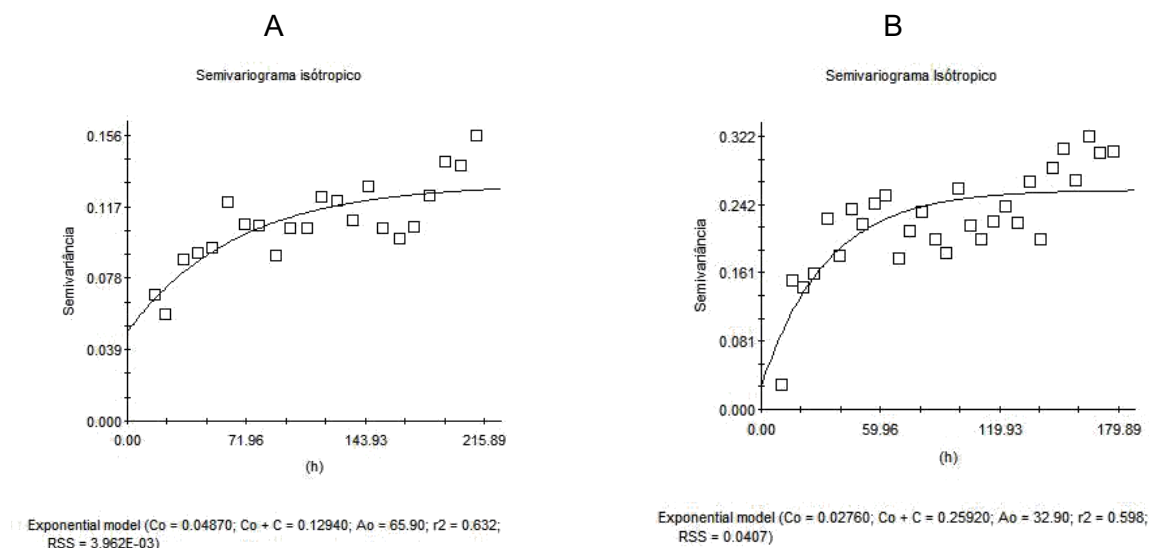
A variável Zn do tecido vegetal, apresentou moderada dependência espacial (DE), porém alto Efeito pepita (C0), maior erro do (SQR) e alta Variância (S^2), enquanto que as variáveis, Mn e B do tecido vegetal, obtiveram alto Efeito pepita (C0), maior erro do (SQR), alta Variância (S^2) e apresentaram forte Dependência espacial (DE). Optou-se, em ambos os casos, pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

Tabela 13 - Ajuste dos modelos dos semivariogramas da análise de tecido vegetal.

Variável	Modelo	C0	C0+C	a (m)	r^2	SQR	s^2	DE	Class	Int
Nitrogênio (%) m/m	Exp	0,05	0,13	197,70	0,632	0,00	0,113	37,63	M	KRIG
Potássio (%) m/m	Exp	0,03	0,26	98,70	0,598	0,04	0,251	10,64	F	KRIG
Zinco mg/kg	Sph	62,20	124,50	161,40	0,604	5.651,00	105,394	49,96	M	IDW
Manganês mg/kg	Gaus	2.420,00	13.880,00	190,18	0,973	4.609.576,00	8.155,452	17,44	F	IDW
Boro mg/kg	Gaus	11,00	48,37	174,94	0,754	1387,00	35,875	22,74	F	IDW

Legenda: Exp = Modelo Exponencial; Sph = Modelo Esférico; Gaus = Modelo Gaussiano; C0 = Efeito Pepita; C0+C = Patamar; a = Alcance em metros; r^2 = Coeficiente de Determinação; SQR = Erro Médio Quadrático do modelo ajustado; s^2 = Variância estimada; DE = Dependência Espacial; Class = Classificação da Dependência Espacial; Int = Interpolador; F = DE Forte; M = DE Moderada; FR = DE Fraca; KRIG = Krigagem; IDW = Interpolador Ponderado pelo Inverso do quadrado da Distância.

Figura 39 - Semivariogramas das variáveis da análise de tecido vegetal interpolados pelo método da krigagem: A) Nitrogênio; B) Potássio.



Fonte: Autor.

4.5.2 Análise variográfica dos índices de vegetação

Na análise do índice de dependência espacial (DE) dos índices de vegetação do vinhedo, realizada segundo critérios descritos por Cambardella et al.; (1994), indica haver dependência espacial considerada moderada, com valores entre 25% e 75%, para os índices de vegetação EVI-CP, ARI-CP, RGR-SP e NPQI-SP e dependência espacial considerada forte para mNDVI-CP, PRI-CP, SR-SP, mNDVI-SP, PI1-SP, PI2-SP, PI3-SP e ARI-SP, com valores inferiores a 25%, (Tabela14). Já a Figura 40 mostra os semivariogramas ajustados para os IV's que tiveram suas estimativas realizadas pelo método de krigagem ordinária pontual.

A variável do índice de vegetação mNDVI-CP apresentou forte dependência espacial (DE), baixo efeito pepita (C_0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustada ao modelo Gaussiano, optando-se interpolar pelo método Krigagem.

A variável do índice de vegetação EVI-CP apresentou moderada dependência espacial (DE), baixo efeito pepita (C_0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustado para o modelo Esférico, com opção de interpolação pelo método de Krigagem.

A variável do índice de vegetação PRI-CP apresentou forte dependência espacial (DE), baixo efeito pepita (C_0), menor erro da soma de quadrados de erros

(SQR) e baixa Variância (S^2), sendo ajustado pelo modelo Esférico, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW) por apresentar um alcance (Ranger) alto, maior que a distância máxima (lag distance) de 176,89 m.

Segundo Journal e Huijbregts (1991), o alcance da dependência espacial representa a distância em que os pontos amostrais estão correlacionados entre si, ou seja, os pontos localizados numa área de raio igual ao alcance são mais parecidos entre si do que com aqueles localizados fora desta área.

Tabela 14 - Ajuste dos modelos dos semivariogramas da análise de tecido vegetal.

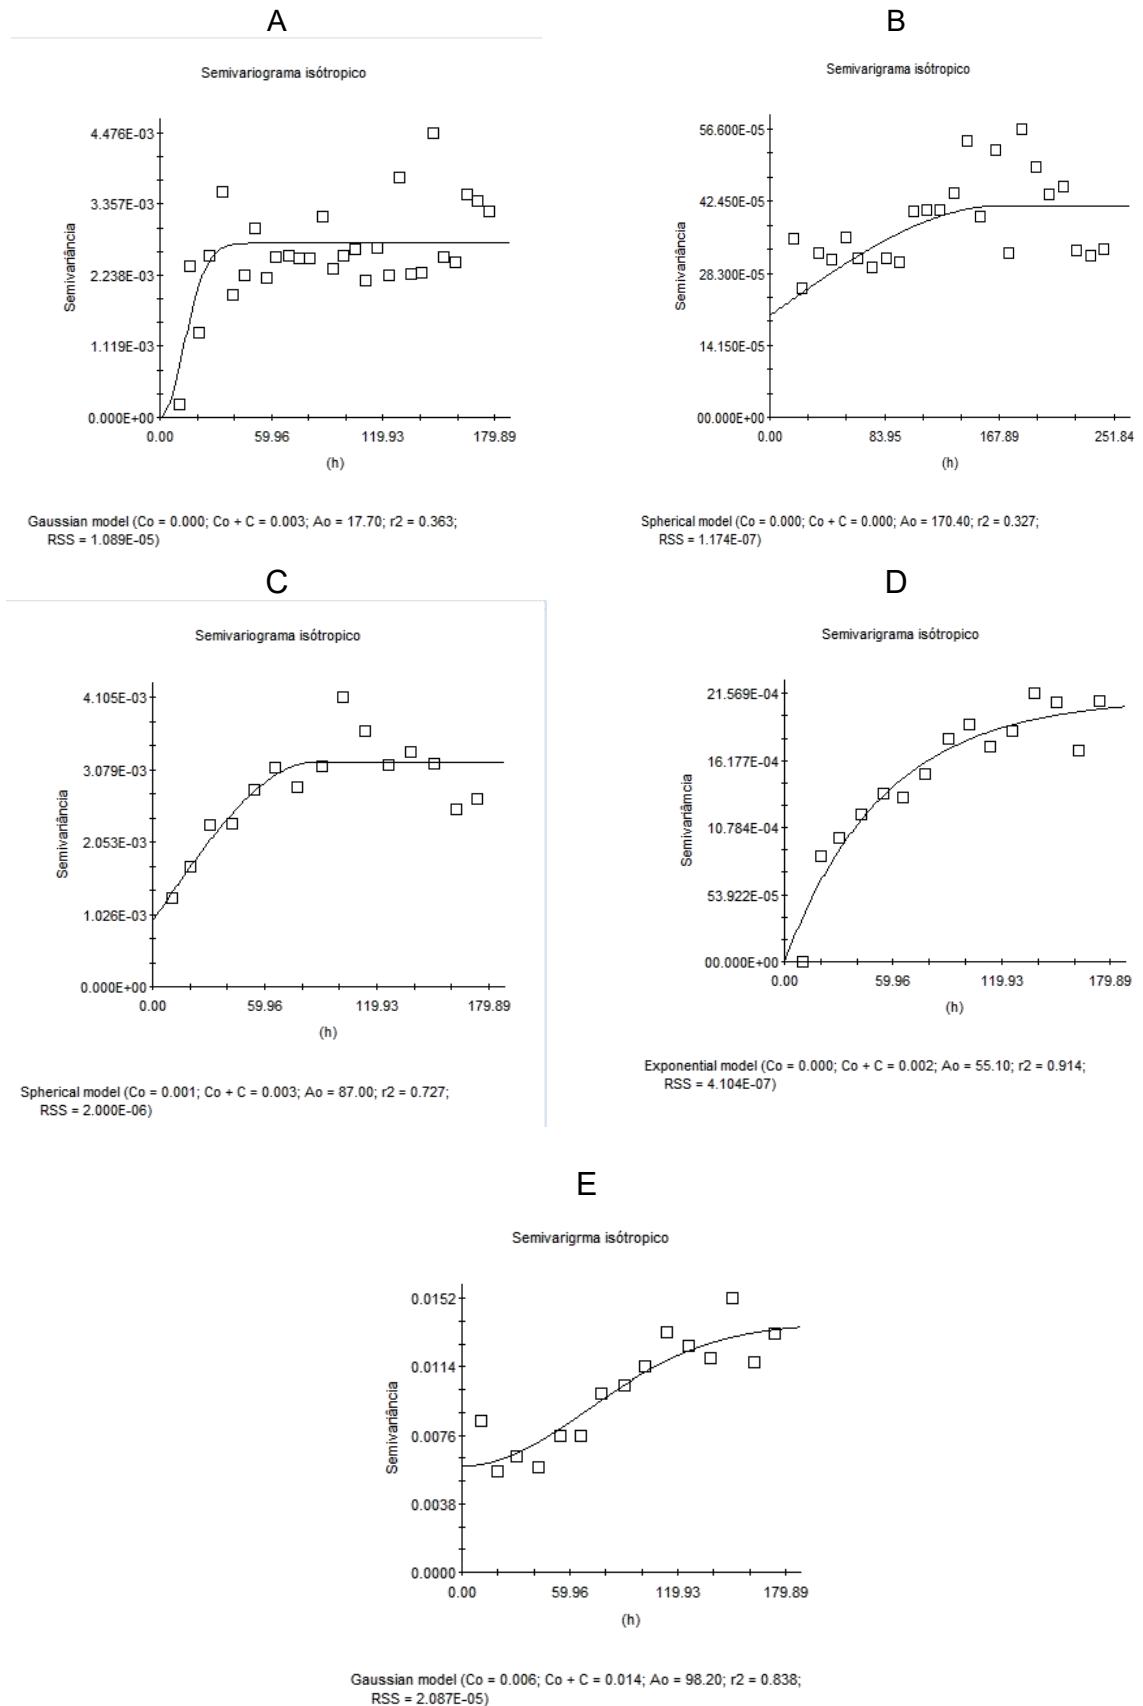
Variável	Modelo	C0	C0+C	a (m)	r ²	SQR	s ²	DE	Class	Int
mNDVI CP	Gaus	0,0000	0,0027	30,66	0,363	0,0000109	0,003	0,04	F	KRIG
EVI CP	Sph	0,0002	0,0004	170,40	0,327	0,0000001	0,000	49,88	M	KRIG
PRI531/570 CP	Sph	0,0000	0,0005	410,90	0,896	0,0000000	0,000	4,49	F	IDW
ARI CP	Sph	0,0009	0,0032	87,00	0,727	0,0000020	0,003	28,98	M	KRIG
SR SP	Exp	0,4210	1,7470	295,20	0,733	0,5080000	1,284	24,10	F	IDW
mNDVI SP	Exp	0,0000	0,0021	165,30	0,914	0,0000004	0,002	0,47	F	KRIG
RGR SP	Gaus	0,0059	0,0139	170,09	0,838	0,0000209	0,009	42,80	M	KRIG
NPQI SP	Sph	0,0001	0,0002	324,00	0,825	0,0000000	0,000	28,09	M	IDW
PI1 SP	Gaus	0,0219	0,2538	519,44	0,919	0,0006082	0,058	8,63	F	IDW
PI2 SP	Exp	0,0000	0,0005	255,90	0,853	0,0000000	0,000	10,63	F	IDW
PI3 SP	Gaus	0,0023	0,0113	624,23	0,633	0,0000032	0,003	20,49	F	IDW
ARI SP	Exp	0,2560	1,4000	893,10	0,665	0,1650000	0,649	18,29	F	IDW

Legenda: Exp = Modelo Exponencial; Sph = Modelo Esférico; Gaus = Modelo Gaussiano; C0 = Efeito Pepita; C0+C = Patamar; a = Alcance em metros; r² = Coeficiente de Determinação; SQR = Erro Médio Quadrático do modelo ajustado; s² = Variância estimada; DE = Dependência Espacial; Class = Classificação da Dependência Espacial; Int = Interpolador; F = DE Forte; M = DE Moderada; FR = DE Fraca; KRIG = Krigagem; IDW = Interpolador Ponderado pelo Inverso do quadrado da Distância.

A variável do índice de vegetação ARI-CP apresentou moderada dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustado para o modelo Esférico, optou-se interpolar pelo método de Krigagem.

A variável do índice de vegetação SR-SP apresentou forte dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustado pelo modelo Exponencial, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW), por apresentar um alcance (Ranger) alto, maior que a distância máxima (lag distance) de 176,89 m.

Figura 40 - Semivariogramas dos índices de vegetação interpolados pelo método da krigagem: A) mNDVI-CP; B) EVI-CP; C) ARI-CP; D) mNDVI-SP e E) RGR-SP.



Fonte: Autor.

A variável do índice de vegetação mNDVI-SP apresentou forte dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR) e baixa Variância (S^2), sendo ajustado pelo modelo Exponencial, foi interpolado pelo método de Krigagem.

A variável do índice de vegetação RGR-SP apresentou moderada dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR), baixa Variância (S^2) tendo sido ajustado pelo modelo gaussiano e interpolado pelo método de Krigagem.

A variável do índice de vegetação NPQI-SP apresentou moderada dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR), baixa Variância (S^2) tendo sido ajustado pelo modelo Esférico, porém optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW) por apresentar um alcance (Ranger) alto, maior que a distância máxima (lag distance) de 176.89 m.

As variáveis PI1-SP, PI2-SP e PI3-SP apresentaram forte dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR), baixa Variância (S^2) e alcance alto, sendo ajustadas pelos modelos Gaussiano, Exponencial e Gaussiano, respectivamente; porém optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW) por apresentar um alcance (Ranger) alto, maior que a distância máxima (lag distance) de 176.89 m.

A variável do índice de vegetação ARI-SP apresentou fraca dependência espacial (DE), baixo efeito pepita (C0), menor erro da soma de quadrados de erros (SQR), baixa Variância (S^2) e alcance alto, sendo ajustado pelo modelo Exponencial, porém optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW) por apresentar um alcance (Ranger) alto, maior que a distância máxima (lag distance) de 176.89 m.

4.5.3 Análise variográfica química do solo

Na análise do índice de dependência espacial (DE) da análise química do solo do vinhedo, realizada segundo critérios descritos por Cambardella et al.; (1994), representados na (Tabela 14), indica haver dependência espacial considerada moderada com valores entre 25% e 75% para as variáveis Mg e Cu na profundidade

de 0-20 cm e K, CTC pH 7,0 e Cu na profundidade de 20-40 cm; Dependência espacial considerada forte com valores inferiores a 25% para as variáveis K, Ca, CTC Efetiva e CTC pH 7,0 na profundidade de 0-20 cm.

Tabela 15 - Ajuste dos modelos dos semivariogramas das variáveis químicas do solo.

Variável	Modelo	C0	C0+C	a (m)	r ²	SQR	s ²	DE	Class	Int
Potássio (0-20cm)	Sph	1.450,000	12.620,000	209,70	0,833	67.700.000,0	8.596,70	11,49	F	IDW
Calcio (0-20cm)	Gaus	2,180	11,350	225,34	0,936	20,4	6,72	19,21	F	IDW
Magnésio (0-20cm)	Gaus	0,907	2,866	235,73	0,854	2,2	1,81	31,65	M	IDW
CTC Efet. (0-20cm)	Gaus	4,140	21,500	234,69	0,946	61,3	12,44	19,26	F	IDW
CTC pH 7 (0-20cm)	Gaus	2,570	10,980	358,71	0,700	122,0	5,09	23,41	F	IDW
Cobre (0-20cm)	Sph	2,130	5,620	251,10	0,208	123,0	4,25	37,90	M	IDW
Potássio (20-40cm)	Sph	585,000	1.934,000	152,60	0,776	1.078.095,0	1.537,03	30,25	M	IDW
CTC pH 7 (20-40cm)	Sph	3,390	6,790	318,40	0,285	129,0	5,21	49,93	M	IDW
Cobre (20-40cm)	Sph	1,656	3,313	117,20	0,736	0,6	3,34	49,98	M	IDW

Legenda: Exp = Modelo Exponencial; Sph = Modelo Esférico; Gaus = Modelo Gaussiano; C0 = Efeito Pepita; C0+C = Patamar; a = Alcance em metros; r² = Coeficiente de Determinação; SQR = Erro Médio Quadrático do modelo ajustado; s² = Variância estimada; DE = Dependência Espacial; Class = Classificação da Dependência Espacial; Int = Interpolador; F = DE Forte; M = DE Moderada; FR = DE Fraca; KRIG = Krigagem; IDW = Interpolador Ponderado pelo Inverso do quadrado da Distância.

A variável K na profundidade de 0-20 cm apresentou forte dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S²), tendo sido ajustado pelo modelo Esférico, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável Ca na profundidade 0-20 cm apresentou forte dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S²), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável Mg na profundidade de 0-20 cm apresentou moderada dependência espacial (DE), baixo efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S²), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável CTC Efetiva na profundidade de 0-20 cm apresentou forte dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S²), tendo sido ajustado pelo modelo Gaussiano,

optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável CTC pH 7,0 na profundidade de 0-20 cm apresentou forte dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S^2), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável, Cu na profundidade de 0-20 cm apresentou moderada dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S^2), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável K na profundidade de 20-40 cm apresentou moderada dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S^2), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso da Distância (IDW).

A variável CTC pH 7,0 na profundidade de 20-40 cm apresentou moderada dependência espacial (DE), alto efeito pepita (C0), alto erro da soma de quadrados de erros (SQR), alta Variância (S^2), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

A variável, Cu na profundidade de 20-40 cm apresentou moderada dependência espacial (DE), baixo efeito pepita (C0), baixo erro da soma de quadrados de erros (SQR), alta Variância (S^2), tendo sido ajustado pelo modelo Gaussiano, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

Estudo em pomares de maçãs os semivariogramas ajustados pelas funções Esférica, Exponencial e Gaussiana apresentaram dependência espacial para a maioria dos parâmetros físico-químicos do solo, com prevalência do modelo de ajuste Esférico (GEBLER et al., 2015). Grego e Vieira, (2005) em estudos com variabilidade espacial em de propriedade físicas de solo demonstraram que o modelo Esférico foi ajustado a todo o solo atributos físicos, considerado o principal modelo nos estudos de ciências do solo.

4.5.4 Análise variográfica da física do solo


Na análise do índice de dependência espacial (DE) das variáveis da análise física do solo vinhedo, realizada segundo critérios descritos por Cambardella et al.; (1994), representados na (Tabela 16), indica haver dependência espacial considerada moderada com valores entre 25% e 75% para as variáveis Umidade (g/g), Silte (%) na profundidade de 0-20 cm e Umidade (g/g) e Argila (%) na profundidade de 20-40 cm; Dependência espacial considerada forte com valores inferiores a 25% para a variável Silte (%) na profundidade 0-20 cm. A Figura 41 mostra os ajustes variográficos das variáveis que foram interpoladas pelo método de krigagem ordinária pontual.

Tabela 16 - Ajuste dos modelos dos semivariogramas da variáveis físicas do solo.

Variável	Modelo	C0	C0+C	a (m)	r ²	SQR	s ²	DE	Class	Int
Umidade (0-20cm)	Sph	0,001	0,002	226,30	0,314	0,000013	0,0017	31,21	M	KRIG
Silte (0-20cm)	Exp	0,460	8,918	173,40	0,920	5,480000	7,0382	5,16	F	IDW
Umidade (20-40cm)	Gaus	0,001	0,002	256,69	0,329	0,000010	0,0013	41,45	M	KRIG
Silte (20-40cm)	Exp	2,088	4,177	150,90	0,853	0,554000	3,7429	49,99	M	IDW
Argila (20-40cm)	Exp	3,290	6,581	147,30	0,915	0,440000	6,5550	49,99	M	IDW

Legenda: Exp = Modelo Exponencial; Sph = Modelo Esférico; Gaus = Modelo Gaussiano; C0 = Efeito Pepita; C0+C = Patamar; a = Alcance em metros; r² = Coeficiente de Determinação; SQR = Erro Médio Quadrático do modelo ajustado; s² = Variância estimada; DE = Dependência Espacial; Class = Classificação da Dependência Espacial; Int = Interpolador; F = DE Forte; M = DE Moderada; FR = DE Fraca; KRIG = Krigagem; IDW = Interpolador Ponderado pelo Inverso do quadrado da Distância.

Figura 41 - Semivariogramas das análises física do solo interpolados pelo método da krigagem: A) Umidade (g/g) de 0-20 cm e B) Umidade (g/g) de 20-40 cm.



Fonte: Autor.

As variáveis da análise física do solo Umidade (g/g) na profundidade de 0-20 cm e Umidade (g/g) na profundidade de 20-40 cm, apresentaram moderada dependência espacial (DE), baixo efeito pepita (C0), baixo erro da soma de quadrados de erros (SQR), baixa Variância (S^2), tendo sido ajustadas para os modelos Esférico e Gaussiano, respectivamente. Optou-se interpolar pelo método de Krigagem ordinária pontual.

A variável da análise física do solo Silte (%) na profundidade de 0-20 cm apresentou forte dependência espacial (DE), baixo efeito pepita (C0), alto erro da soma de quadrados de erros (SQR) e alta Variância (S^2), tendo sido ajustada para o modelo Exponencial, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

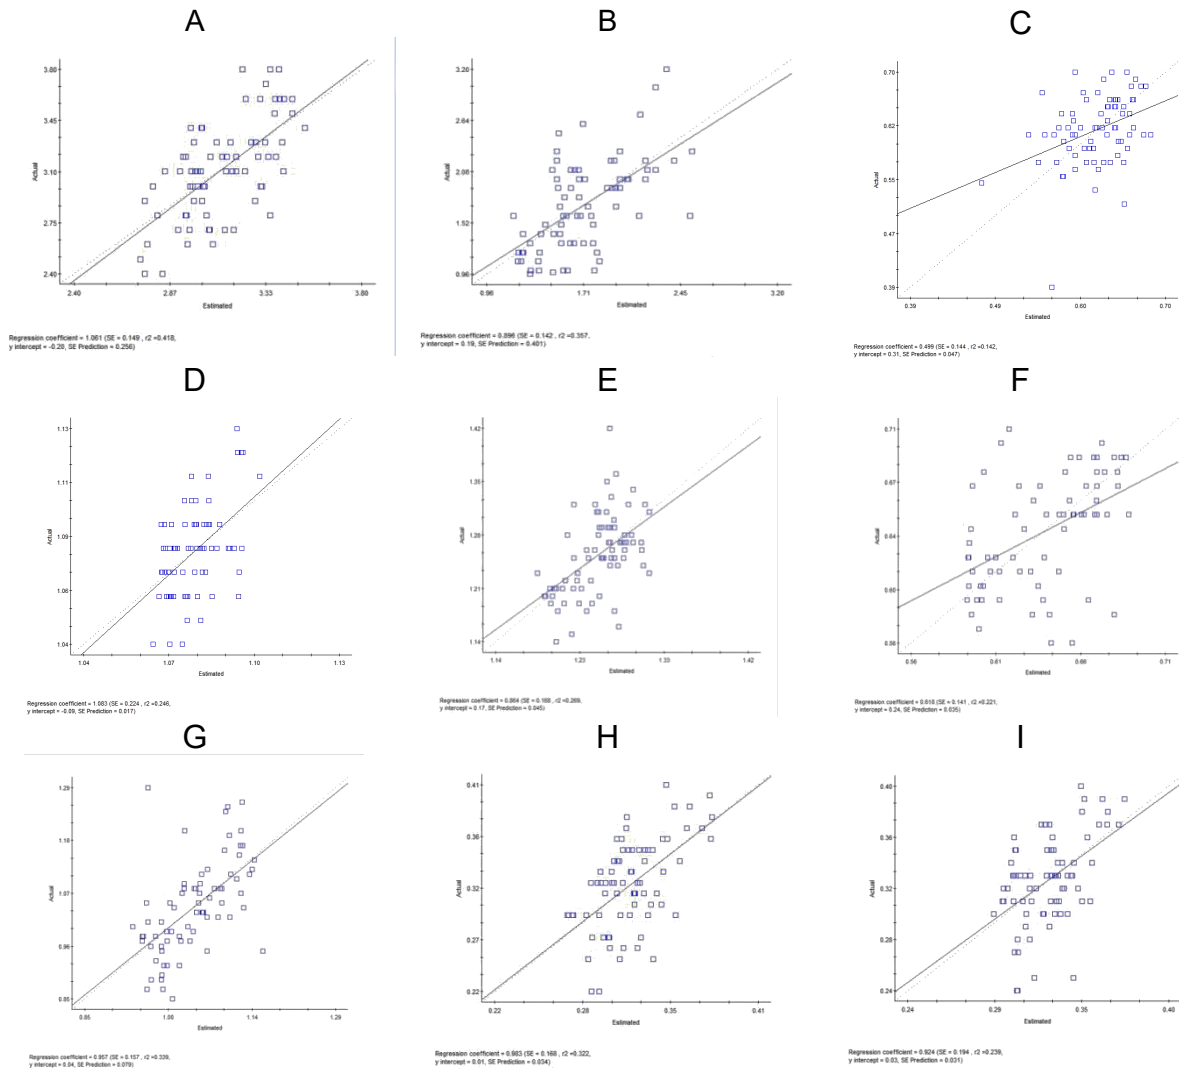
As variáveis da análise física do solo Silte (%) e Argila (%) na profundidade de 20-40 cm apresentaram moderada dependência espacial (DE), alto efeito pepita (C0), baixo erro da soma de quadrados de erros (SQR) e alta Variância (S^2), tendo sido ajustadas para o modelo exponencial, optou-se interpolar pelo método de Ponderação pelo Inverso do quadrado da Distância (IDW).

4.6 Validação Cruzada

Foi executada a validação cruzada a fim de justificar a escolha do interpolador geostatístico por krigagem ordinária pontual e validar sua eficácia (Tabela 17), conforme Molin et al.; (2015), baseando-se na plotagem de um gráfico gerado pelos valores preditos contra os valores reais e analisando os seguintes parâmetros: a) inclinação da curva ou coeficiente angular (que deve apresentar valores próximo de 1); b) intercepto ou coeficiente linear (que deve apresentar valores próximos a zero); c) coeficiente de correlação entre os dois ou r^2 (que deve ser o mais próximo possível de 1). A Figura 42 mostra os parâmetros obtidos na validação cruzada e os gráficos correspondentes

Os resultados obtidos pela validação cruzada apresentaram valores satisfatórios quanto ao (coeficiente angular e o coeficiente linear) e seus valores de correlação, de acordo com Molin et al.; (2015). Exceto para as variáveis dos índices de vegetação mNDVI-CP e mNDVI-SP, conforme mostra a Figura 26C e 26F, que apresentaram inclinação da curva, intercepto e baixos valores de coeficiente de correlação (R^2).

Figura 42 - Validação Cruzada na interpolação por krigagem para as variáveis: A) Nitrogênio do Tecido Vegetal; B) Potássio no Tecido Vegetal; C) mNDVI-CP; D) EVI-CP; E) ARI-CP; F) mNDVI-SP; G) RGR-SP; H) Umidade do Solo de 0-20 cm e I) Umidade do Solo de 20-40 cm.



Fonte: Autor.

Tabela 17 - Parâmetros da Validação cruzada das estimativas.

Variável	Coefficiente Angular	Coefficiente Linear	R²
<i>Análise do Tecido Vegetal</i>			
Nitrogênio (%) m/m	1,061	-0,200	0,418
Potássio (%) m/m	0,896	0,190	0,357
<i>Índices de Vegetação</i>			
mNDVI-CP	0,499	0,310	0,142
EVI-CP	1,083	-0,090	0,246
ARI-CP	0,864	0,170	0,269
mNDVI -SP	0,240	0,618	0,221
RGR-SP	0,957	0,040	0,339
<i>Análise Física do Solo</i>			
Umidade (g/g) 0-20 cm	0,983	0,010	0,322
Umidade (g/g) 20-40 cm	0,924	0,030	0,239

Fonte: Autor.

5 CONCLUSÕES

Concluindo em relação aos objetivos específicos, temos que:

- a) No presente trabalho das 88 variáveis estudadas, apenas 31 apresentaram normalidade pelo teste não paramétrico (Kolmogorov-Smirnov), sendo 12 índices de vegetação (mNDVI-CP, EVI-CP, PRI-CP, ARI-CP, SR-SP, mNDVI-SP, RGR-SP, NPQI-SP, PL1 SP, PL2 SP, PL3 SP e ARI-SP) e 19 variáveis de parâmetros agronômicos: na análise química do tecido vegetal (N, K, Zn, Mg e B); na análise Física do solo (Umidade e Silte) na profundidade de 0-20 cm, e na profundidade de 20-40 cm (Umidade, Silte e Argila) e na análise química do solo (K, Ca, Mg, CTC Efet., CTC pH 7,0 e Cobre) na profundidade de 0-20 cm e (K, CTC pH 7,0 e Cu) na profundidade de 20-40 cm.

Entre as 19 variáveis de parâmetros agronômicos versus as 12 variáveis de índices vegetativos, foram obtidos 139 correlações lineares simples por Pearson ao nível de 5%. Destas, 68 foram correlações positivas (variando entre 0,235 a 0,572), das quais 29 foram classificadas como moderadas e as demais como fracas. Já as 71 correlações restantes, foram classificadas como negativas (variando entre -0,565 à - 0,230), sendo 36 classificadas como moderadas, e as demais como fracas.

Os índices de vegetação que apresentaram o maior número de correlações por Pearson em relação as variáveis dos parâmetros agronômicos testados foram o SR-SP, NPQI-SP e PI1-SP, com 14 correlações significativas cada. Já considerando a magnitude dos resultados, os índices de vegetação com maiores número de correlações moderadas positivas foram: mNDVI-CP, PRI-CP, mNDVI-SP, PI1-SP e ARI-SP, apresentando 4 correlações cada, enquanto que o SR-SP obteve o maior número de correlações moderadas negativas com 5 correlações significativas;

- b) Com base nas correlações obtidas é possível a utilização de índices de vegetação em substituição às análises físico/química de parâmetros agronômicos, desde que eles atinjam pelo menos magnitude moderada no coeficiente da correlação. Na falta de disponibilidade de recursos laboratoriais para uma tomada de decisão, também é possível utilizar para tomada de

decisão os índices que atingiram somente a magnitude fraca, necessitando novos estudos posteriores. Os índices de vegetação que apresentaram os maiores coeficiente de correlação por Pearson (r) ao nível de 5% e magnitudes moderadas são: **mNDVI-CP** que apresentou correlação o K da análise química do solo na profundidade de 20-40 cm, com coeficiente de correlação negativa de (-0,534); **mNDVI-SP** que apresentou correlação positiva de (0.508) com a CTC Efetiva do solo na profundidade de 0-20 cm; **ARI-CP** que apresentou correlação negativa de (-0.402) com B do tecido vegetal; **SR-SP** que apresentou correlação positiva de (0.534) com a CTC pH 7,0 do solo na profundidade de 0-20 cm; **RGR-SP** que apresentou correlação negativa de (-0.447) com o K do solo na profundidade de 0-20 cm; **NPQI-SP** que apresentou correlação negativa de (-0.472) com Cu do solo na profundidade de 0-20 cm; **PI1-SP** que apresentou correlação positiva de (0,546) com K do solo na profundidade de 0-20 cm; **PI2-SP** que apresentou correlação negativa de (-0,545) com a CTC pH 7,0 do solo na profundidade de 0-20 cm; **PI3-SP** que apresentou correlação negativa de (-0,506) com o K do tecido vegetal; **ARI-SP** que apresentou correlação positiva de (0,566) cm o K do tecido vegetal e o **PRI-CP**, que apresentou coeficiente de correlação positiva de (0.572) com a CTC pH 7,0 do solo na profundidade de 0-20 cm, e coeficiente de correlação negativa com a variável da análise química do solo K na profundidade de 0-20 cm, apresentando coeficiente de correlação de (-0,565).

REFERÊNCIAS BIBLIOGRÁFICAS

- ABE- ASSOCIAÇÃO BRASILEIRA DE ENÓLOGOS. **Premiação**. Bento Gonçalves, 2017 disponível em: <<https://www.enologia.org.br/premiacao/2017/vinus-2017>> Acesso em: 1 jul. 2019.
- AGAVI - **Associação Gaúcha de Vinicultores**, Rio Grande do Sul, 2018. Disponível em: <<http://agavi.com.br/website/>> data de acesso: 27 jun.19.
- ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística**. São Leopoldo: Unisinos, 2003. 165p.
- ARKUN S., MEL; JOHNSON L.; LAMB D.; LIEFF WMORGAN G. **Airbone Remote Sensing of the Vine Canopy**, 2000.
- ARRUDA, D. C.; GUASSELLI, L. A.; SILVA FILHO, L. C. P.; ANDRADE, A. C. F.; **Índice de condição da vegetação (VCI) para mapeamento de seca no Norte do Estado de Minas Gerais**. Anais XVIII Simpósio Brasileiro de Sensoriamento remoto, João Pessoa-PB, Brasil. Disponível em: < <http://www.dsr.inpe.br/sbsr2015/files/p0314.pdf>> Acesso em: 27 jun. 2019.
- ASNER, G.P.; CARLSON, K.M. and MARTIN, R.E. 2005. **Substrate age and precipitation effects on Hawaiian forest canopies from spaceborne imaging spectroscopy**. Remote Sensing of Environment, 98, 457-467.
- BELWARD, A. S. Spectral **characteristics of vegetation, soil and water in the visible, near-infrared and middle- infrared wavelengths**. In Remote Sensing and Geographical Information Systems for resource management in developing countries. Springer Netherlands, 1991, p. 31-53.
- BOMBASSARO, M. G. **Análise espectral de variedades de *Vitis vinifera* a partir de dados radiométricos de dossel em vinhedos de Pinto Bandeira, RS**. 2016, Tese (Pós-Graduação em Sensoriamento Remoto) Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2016.
- BOMBÍN, J. Y. et. al. **Guía de Mantenimiento del suelo en viñedo mediante cubiertas vegetales**, Ministerio da Agricultura, Alimentación y medio Ambiente, España, 2013.
- BRAMLEY, R. G. V.; HAMILTON, R. P. **Understanding variability in winegrape production systems, Within vineyard in yield over several vintages**. Australian Journal of Grape and Wine Research, 2004, p. 32-35.
- BRAMLEY, R. G. V.; LAMB, D. W. **Making sense of vineyard variability in Australia**. In: Otega, R and Esser, A. Precision Viticulture. Proceedings of an international symposium held as part of the I X congresso Latinoamericano de Viticultura y Enología, Chile. Centro de agricultura de precision. 2003, p 35-44.
- BRAMLEY, R. G. V.; PROFFITT, A. P. B. **Managing variability in viticultural production. The Australian & New Zealand Grapegrower & Winemaker**, n. 427, 1999, p. 11-16.

BROWN, R. B.; LAMB, D. W.; SIDAHMED, M. M. **Using grape leaf reflectance for spatially variable vineyard management**, ASAE Annual intertional Meeting, Ottawa, Canada, 2004, p. 563-571.

BUENO, M. E. B.; RUFATO, L.; GLEBER, L.; RUFATO, A de R. **Técnicas de Sensoriamento Remoto na Cultura da Macieira**. Décimo terceiro Encontro de Iniciação Científica e Nono Encontro de Pós- graduandos da Embrapa Uva e Vinho, XLIV Congresso Brasileiro de Engenharia Agrícola- CONBEA, São Pedro, São Paulo, 2015. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/127377/1/Bueno-13IC-p37-2015.pdf>>. Acesso em: 26 jun. 2019.

CAMARGO, E. C. G. **Geoestatística: Fundamentos e aplicações**. INPE: São José dos Campos, 2001. Disponível: <http://www.dpi.inpe.br/gilberto/tutoriais/gis_ambiente/5geoest.pdf>. Acesso em 19 Jun 2019.

CAMARGO, U. M. **Tecnologia vitícola: Novas variedades**. X Congresso Brasileiro de Viticultura e Enologia, p.127-128. 2003. Disponível em: <https://www.researchgate.net/profile/Umberto_Camargo/publication/242521147_Tecnologia_viticola_novas_variedades/links/5899b5ac92851c8bb681bf4c/Tecnologia-viticola-novas-variedades.pdf>. Acesso em: 25 jun. 2019.

CAMARGO, W. P. et. al. **Análise temporal da variabilidade espacial de mapas de produtividade**. Congresso Brasileiro de Agricultura de Precisão- piracicaba, SP ESALQ/USP, 2004. Disponível em:<http://afurlan.com.br/lap/cp/assets/layout/files/tc/cgr-11_d.pdf>. Acesso em: 25 jun. 2019.

CAMBARDELLA, C. A. et al. **Field-scale variability of soil properties in Central Iowa soils**. Soil Science Society of American Journal, n. 58, p. 1501-1511, 1994.

CAPELLI, N. T. **Agricultura De Precisão - Novas Tecnologias Para o Processamento Produtivo**. Disponível em: <[HTTP://www.bases.cnptia.embrapa.br/cria/gip/capelli](http://www.bases.cnptia.embrapa.br/cria/gip/capelli)>. Acesso em: 26 Jun. 2019.

CARVALHO, M. P.; TAKEDA, E. Y.; FREDDI, O. S. **Variabilidade espacial de atributos de um solo sob videira em Vitória Brasil (SP)**. Revista brasileira de ciência do solo. Viçosa, n. 27, p. 605-703, 2003.

CASS, A. **Viticultura de precisión: Introducción y objetivos Viticultura de Precisión**. In: Viticultura de precisión, 8. Madrid: Fundación para la Cultura del Vino, 2013. Disponível em: <http://culturadelvino.org/fcv/wp-content/uploads/pdf/encuentros/encuentro_2013.pdf>. Acesso em: 1Jun. 2018.

CEROVIC, Z. G.; et, al. **A new optical leaf-clip meter for simultaneous non-destructive assessment of leaf chlorophyll and epidermal flavonoids** *Physiologia Plantarum*, Blackwell Publishing Ltd, 146, 251-260. Disponível em: <<http://dx.doi.or:10.1111/j.1399-054.2012.01639.x>>. Acessado em: 26 Jun. 2019.

CEZAR, E.; NANNI, M. R.; CHICATI, M. L.; SOUZA JUNIOR, I. G.; COSTA, A. C. S. Avaliação e quantificação das frações silte, areia e argila por meio de suas respectivas reflectâncias. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 36, n. 4, p. 1157-1166, Ago. 2012.

CLARK, R. N. **Spectroscopy of rocks and minerals, and principles of spectroscopy**. In: Remote Sensing for Earth Sciences (A.N. Rencz & R. A. Ryerson, eds), Manual of Remote Sensing, Vol. 3, New York: John Wiley & Sons, 1999, p.3-58.

COELHO, A M, **Agricultura de Precisão: Manejo da Variabilidade Espacial e Temporal dos Solos e das Culturas**. In: Tópicos em Ciências do Solo. V. 3 Sociedade Brasileira de Ciência do Solo, Viçosa, 2003, p.249-290.

COMISSÃO DE QUÍMICA E FERTILIDADE DO SOLO RS/SC, **Manual de Calagem e Adubação para os estados do Rio Grande do Sul e de Santa Catarina**, sociedade brasileira de ciência do solo. Núcleo Regional Sul, Comissão de química e fertilidade do solo, 376p, 11ª edição, 2016.

COPELLO, M. **As regiões produtoras do Brasil**. Revista Anuário Vinho do Brasil. Baco multimídias. São Paulo. SP. 2015

CORWIN, D. L.; LESCH, S. M. **Application of Soil Electrical Conductivity to Precision Agriculture**. Agronomy Journal Abstract - Symposium Papers, v 95, no. 3. 2003, p 455-471.

CORWIN, D. L.; LESCH, S. M. **Apparent soil electrical conductivity measurement in agriculture**. Computers and Electronics in Agriculture. v 46, ed 1-3, 2005, p 11-43.

CRESSIE, N. 1991. **Statistics for spatial data**. New York: John Wiley.

DAL AGNOL, O. **Variabilidade Espacial Dos Atributos Químicos Do Solo, Índices De Vegetação E Sua Relação Com Atributos Químicos Do Mosto Da Uva**. Dissertação (Mestrado em Agricultura de Precisão). Universidade Federal de Santa Maria, Santa Maria, RS. 2016, 84p.

DALMOLIN, R.S.D., GONÇALVES, C.N., KLAMT, E., DICK, D. P. **Relação entre os constituintes do solo e seu comportamento espectral**. Ciência Rural, vol.35 nº.2 Santa Maria Mar./Abr. 2005.

DELOIRE, A.; VAUDOUR, E.; CAREY, V.; BONNARDOT, V.; LEEUWEN, V C. **Grapevine responses to terroir: A global approach**. Journal international des sciences de la vigne et du vin. V. 39, no 4 (2005), 149-162.

DEMATTÊ, J. A. M.; ARAÚJO, S. R.; FIORIO, P. R.; FONGARO, C. T.; NANNI, M. R. **Espectroscopia VIS-NIR-SWIR na avaliação de solos ao longo de uma topossequência em Piracicaba (SP)**. Revista Ciência Agronômica, v. 46, n. 4, p. 679-688, out-dez, 2015.

DEMATTÊ, J. A. M.; CAMPOS, R. C.; ALVES, M. C.; FIORIO, P. R.; NANNI, M. R. **Visible-NIR reflectance: a new approach on soil evaluation**.

DEMATTE, J. A. M.; SOUSA, A. A.; ALVES, M. C.; NANNI, M. R.; FIORIO, P. R.; CAMPOS, R. C. **Determining soil water status and other soil characteristics by spectral proximal sensing**. *Geoderma* v. 135, p. 179-195. 2006.

DOTTO, A. C. **Funções de pedotransferência do solo: estimativa por radiometria**. Universidade Federal de Santa Maria, Santa Maria, 2012. 68 p. Dissertação de Mestrado.

DROLET, G.G.; HUENNRICH, K.F.; HALL, F.G.; MIDDLETON, E.M.; BLACK, T.A.; BARR, A.G. and MARGOLIS, H.A. 2005. **A MODIS-derived photochemical reflectance index to detect inter-annual variations in the photosynthetic light-use efficiency of a boreal deciduous forest**. *Remote Sensing of Environment*, 98, 212-224.

DURIGON, R. **Aplicação de técnicas de manejo localizado na cultura do arroz irrigado (*Oryza sativa* L.)**. 147 F. 2007. Tese (doutorado em engenharia agrícola), Universidade Federal de Santa Maria.

ELACHI, C.; ZYL, J. J. V. **Introduction to the physics and techniques of remote sensing**. Wiley series in remote sensing and image processing. 2 ed, 2006, 584 p.

EMBRAPA 2003. **Uvas para processamento, Aspectos Técnicos**. Editor técnico KUHN, G. B. Embrapa Uva e Vinho (Bento Gonçalves-RS) –Brasília. Embrapa Informação tecnológica. 134p.

ERNANI, P.R. **Química do solo e disponibilidade de nutrientes**. Lages: P.R. Ernani, 2008. 230p.

ESSER, A. A. **Aplicaciones de la viticultura de precisión en Chile**. Trabajo de finalización del curso (Graduación en Agronomía) - Pontificia Universidad Católica de Chile. Santiago. 2002. 26 p.

ESSER, A. A.; ORTEGA BLU, R. **Aplicaciones de la viticultura de precisión en Chile: Estudio de casos**. *Agronomía y Forestal*, Santiago, v. 5, n. 17, p.17-21, may/jun., 2002.

EVAIN, S.; FLEXAS, J. and MOYA, I. 2004. **A new instrument for passive remote sensing: 2. Measurement of leaf and canopy reflectance changes at 531 nm and their relationship with photosynthesis and chlorophyll fluorescence**. *Remote Sensing of Environment*, 91, 175-185.

FERREIRA, M. C. **Iniciação a análise geoespacial: teoria técnicas e exemplos para geoprocessamento**, 1 ed São Paulo, editora UNESP, 2014, 344p.

FERRI, C.; RANGEL, M. E.; GURGEL, S. H. Da C. SUGAWARA, L. M.; PINTO, M L. De A. **Relação entre o Fator de Reflectância Hemisférica e o Fator de Reflectância Hemisférica Bidirecional de Folhas Isoladas da *Tibouchina granulosa cogn.*** *Anais X SBRS*, Foz do Iguaçu, 2001, p.1461-1467.

FILIPPINI ALBA, J. M.; FLORES, C. A.; MIELE, A. **Geotecnologias e Mapeamento de Solos para Delimitação de Zonas de Manejo como Abordagem da Precisão da Viticultura**. Ciência aplicada e ambiental do solo, v. 2017, 2017. 10p.

FIORIN, J. E. (Coord.) **Manejo e Fertilidade do Solo no Sistema Plantio Direto**. PaEd. Berthier, Passo Fundo, 2007. 184 p.

FLORES, C. A.; ALBA, J. M. F.; LEVIEN, H. F.; ZARNOTT, D. H.; MIELE, A.; PAVAN, C. **Levantamento detalhado dos solos e a viticultura de precisão**. In: CONGRESSO BRASILEIRO DE CIÊNCIA DO SOLO, 33., 2011, Uberlândia, XXXIII Congresso brasileiro de ciência do solo. Uberlândia: SBCS 2011.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017.

FUENTES, D.A.; GAMON, J.A.; CHENG, Y.; CLAUDIO, H.C.; QIU, H.L.; MAO, Z.; SIMS, D.A.; RAHMAN, A.F.; OECHEL, W. and LUO, H. 2006. **Mapping carbon and water vapour fluxes in a chaparral ecosystem using vegetation indices derived from AVIRIS**. Remote Sensing of Environment, 103, 312-323.

FUENTES, D. A.; GAMON, J. A.; QIU, H. L.; SIMS, D. A.; ROBERTS, D.A. **Mapping Canadian boreal forest vegetation using pigment and water absorption features derived from the AVIRIS sensor**. Journal of geophysical Research, v. 106, 2001, p 33565-33577

GAMON, J. A.; SURFUS, J. S. **Assessing leaf pigment content and activity with a reflectometer**. The New Phytologist, v. 143, n. 1, p. 105-117, 1999.

GAMON, J.A.; PEIIUELAS, J.; FIELD, C. B. **A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency**. Remote Sensing of Environment, v.41, ed. 1, 1992, p 35-44.

GAMON, J.A.; SERRANO, L.; SURFUS, J.S. **The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels**. Oecologia, v. 112, n.4, 1997, p. 492-501.

GATES, D. M. et al. **Spectral properties of plants**. Applied optics, v. 4, n. 1, 1965, p. 11-20.

GEBLER, Luciano et al. **Spatial influence of physical and chemical parameters on management zone definition in apple orchards**. Eng. Agríc., Jaboticabal, v. 35, n. 6, p. 1160-1171, Dec. 2015. Available from <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S010069162015000601160&lng=en&nrm=iso>. Acesso em: 20 jul. 2019.
Geoderma v. 121 (1-2), p. 95-112. 2004.

GIOVANNINI, E. **Manual de viticultura, eixo produção alimentícia e recursos naturais**. Editora Bookman, Porto Alegre 2014.

GIOVANNINI, E. **Produção de uvas para vinho, suco e mesa**. Porto Alegre: Renascença, 1999. 364p.

GITELSON, A. A.; MERZLYAK, M. N.; CHIVKUNOVA, O. B. **Optical properties and nondestructive estimation of anthocyanin content in plant leaves**. Photochemistry and photobiology, v. 74, n. 1, 2001, p. 38-45.

GOMES, F P. **Curso de estatística experimental**. Editora Nobel, Piracicaba, 1985, 466 p.

GOMEZ, C.; ADELIN, K.; BACHA, S.; DRIESSEN, B.; GORRETTA, N.; LAGACHERIE, P.; ROGER, J. M.; BRIOTTET, X. **Sensitivity of clay content prediction to spectral configuration of VNIR/ SWIR imaging data, from multispectral to hyper spectral scenarios**. Remote Sensing of Environment, Vol. 204, January 2018, p. 18-30.

GOUTOULY, J.P.; DRISSI, R.; FORGET, D.; GAUDILLÈRE, J.P. (2006). **Characterization of vine vigor by ground based NDVI measurements**. Congrès International des terroirs viticoles, Bordeaux.

GREGO, C. R. & VIEIRA, S. R. **Variabilidade espacial de propriedades físicas do solo em uma parcela experimental**. Revista Brasileira de Ciência do Solo, Viçosa, v. 29, n. 2, 2005, p. 169- 177.

GREGO, C. R.; OLIVEIRA, R. P.; VIEIRA, S. R. **Geoestatística aplicada a Agricultura de Precisão**. Agricultura de Precisão- Resultados de um Novo Olhar. Brasília, DF: Embrapa, 2014, p. 74-83.

GREGO, CR; VIEIRA, SR **Variabilidade espacial de propriedades físicas de solo em uma parcela experimental**. Revista Brasileira de Ciência do Solo, Viçosa, MG, v.29, n.2, p.169-177, 2005.

GUO, J. and TROTTER, C.M. 2004. **Estimating photosynthetic light-use efficiency using the photochemical reflectance index: variations among species**. Functional Plant Biology, 31, 255-565.

GUO, J. and TROTTER, C.M. 2004. **Estimating photosynthetic light-use efficiency using the photochemical reflectance index: variations among species**. Functional Plant Biology, 31, 255-565.

HALL, A. L. J. P. & LAMB, D.W. **Extracting detailed information from high resolution airborne digital images of vineyards**, In: GeoComputation, proceedings of 6th International Conference on Geocomputation, 2001.

HALL, A., LAMB, D.W., HOLZAPFEL AND LOUIS, J. (2002) **Optical remote sensing applications in viticulture - a review**. Australian Journal of Grape and Wine Research, 2002 p.36-47.

HALL, A., LOUIS, J. AND LAMB, D. (2003) **Characterising and mapping vineyard canopy using high-spatial-resolution aerial multispectral images**. Computers & Geosciences, 2003, p.813-822.

HASHIZUME, T. **Tecnologia do vinho**. In: BORZANI, W. et al. Biotecnologia industrial: Biotecnologia na produção de alimentos. São Paulo: editora Edgard Bluscher, V. 4, 2001, p. 21-68.

HERRERA, J; GUESALAGA, A.; AGOSIN, E. **Espectroscopia de ondas curtas de infravermelho próximo para determinação não destrutiva da maturação de uvas para vinho**. Ciência e Tecnologia de Medição, v. 14, n. 5, 2003, p. 689.

HUETE, A. R. et al. **A comparison of vegetation indices over a global set of TM images for EOS-MODIS**. Remote sensing of environment, v. 59, n. 3, 1997, p. 440-451.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; & VAN LEEUWEN, W. J. D. (1997). **A comparison of vegetation indices over a global set of TM images for EOS-MODIS**. Remote Sensing of Environment, 59, 440–451.

HUETE, A.; JUSTICE, C.; & LIU, H. (1994). **Development of vegetation and soil indices for MODIS-EOS**. Remote Sensing of Environment, 49, 224– 234.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Sistema IBGE de Recuperação Automática – SIDRA**. Disponível em: <https://sidra.ibge.gov.br/tabela/1618>. Acesso em: 1 Jun. 2019.

INSTITUTO ADOLFO LUTZ – IAL. **Normas analíticas, métodos químicos e físicos para análise de alimentos**. 3 ed. São Paulo, 1985. 533 p. (v. 1)

ISAAKS, E. H.; SRIVASTAVA, R. M. 1989. **Applied geostatistics: introduction to applied geostatistics**. Oxford: University Press, 561p.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Editora parêntese, 2009.598p.

JORDAN, C. F. **Derivation of leaf-area index from quality of light on the forest floor**. Ecology, v. 50, n. 4, 1969, p. 663-666.

JOURNEL, A. G.; HUIJBREGTS, C. J. 1991. **Mining geostatistics**. London, Academic Press, 600p.

JURGENS, C. **The modified normalized difference vegetation index (mNDVI) a new index to determine frost damages in agriculture based on landsat TM data**. International Journal of Remote Sensing. V. 18, no. 17, p. 3583-3594, 1997.

JUSTICE, C. O.; et. Al. **Moderate resolution imaging spectroradiometer (modis): Land remote sensing for global change research**. IEEE transactions on geosciences and remote sensing, 1998. v.36, no4, p 1228-1247.

KIMES, D. S.; KIRCHNER, J. A. **Directional radiometric measurements of row-crop temperatures**. International journal of remote sensing, v. 4, n. 2, 1983, p. 299-311.

KITCHEN et al. **Evaluation of methods for determining site specific management zones**. 2003; Disponível em: <<http://www.fse.missouri.edu/mpac/pubs.pdf>> acesso em: 25 Jun. 2019.

KRIGE, D. G. **A statistical approach to some mine valuation and allied problems on the Witwatersrand**: 1951. Tese de Doutorado. University of the Witwatersrand. Johannesburg, Africa 1951.

LACAR, F.; LEWIS, M. & GRIERSON, I. 2001. **Use of hyperspectral reflectance for discrimination between grape varieties Geoscience and Remote Sensing Symposium**, 2001. IGARSS '01. IEEE 2001 International, v.6, p.2878-2880. Disponível em: <dx.doi.org/10.1109/IGARSS.2001.978192>. Acessado: 25 Jun 2019.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. 2ª. Edição, São Paulo: Editora Unesp, 2003. 253p.

LANDIM, P. M. B. Sobre geoestatística e mapas. **Terra e Didática**, v.2, n.1, p.19-33, 2006.

LEEUWEN, C. V. et al. **Vine water status is a key factor in grape ripening and vintage quality for red Bordeaux wine. How can it be assessed for vineyard management purposes?** Journal International des Sciences de la Vigne et du Vin, v.43, 2009, p.121- 134.

LEONE, A. P.; VISCARRA-ROSSEL, R. A.; AMENTA, P.;BUONDONNO, A. **Prediction of Soil Properties with PLSR and vis-NIR Spectroscopy:Application to Mediterranean Soils from Southern Italy**. Current Analytical Chemistry, 2012, 8, 283-299.

LIMA, C. A. G.; SILANS, A. P. **Variabilidade espacial da infiltração de água no solo**. Pesquisa agropecuária brasileira, Brasília v. 34, no12 p.2311-2320, dezembro, 1999.

LIMA, M. A. C. CHOUDHURY, M. M. **Colheita e manejo pós colheita. Uva de mesa: pós colheita**, 2 ed. Brasília Embrapa informática agropecuária/ Embrapa Semiárido, 2007, p.31-48.

LIMA, M. A. C. **Fisiologia, tecnologia e manejo pós colheita**, In: SOARES, J. M.; LEÃO, P. C. DE S. A vitivinicultura no semiárido brasileiro. 1 ed. Brasília Embrapa informática agropecuária/ Embrapa Semiárido, 2009, p.597-656.

LIU, W. T. H. 2006. **Aplicações em Sensoriamento Remoto**. Editora UNIDERP Campo Grande. São Paulo.

LORD, D.; DESJARDINS, R.L.; DUBÉ, P.A. **Sun-angle effects on the red and near infrared reflectances of five different crop canopies**. Canadian Journal of Remote Sensing, Ottawa, v.14, p.46-55, 1988.

LOVATEL, E. **Fatores Empresariais Determinantes da Competitividade da Indústria de Vinhos Finos da Serra Gaúcha**. Dissertação (Mestrado em Administração). UFRGS, Porto Alegre, 2002.

MALAVOLTA, E. **Manual de química agrícola - Adubos e adubação**. 3 ed. SP, Ceres 1981, p. 596.

MANEVSKI, K., MANAKOS, I., PETROPOULOS, G. P., AND KALAITZIDIS, C. 2012. **Spectral discrimination of Mediterranean maquis and phrygana vegetation: Results from a case study in greece**. IEEE Journal of Selected Topics in Applied Earth Observations and Remote

MARCUSSI, A. B. et al. **Utilização de índices de vegetação para os sistemas de informação geográfica- Caminhos de geografia**, v. 11, n. 35, 2010.

MARTÍN, P.; ZARCO-TEJADA, P. J.; GONZÁLEZ, M. R.; BERJÓN, A. **Using hyperspectral remote sensing to map grape quality in 'Tempranillo' vineyards affected by iron deficiency chlorosis**. Vitis Journal of grapevine Research, v.46, 2007. p. 7–14.

MATESE, A.; VACCARI, F.P.; TOMASI, D.; GENNARO, S.F.D.; PRIMICERIO, J.; SABATINI, F. E GUIDONI, S. **CrossVit: Enhancing Canopy Monitoring Management Practices in Viticulture**. Sensors, vol. 13, n. 6, p. 7652- 7667. 2013.
MATHERON, G. Principles of geostatistics. **Economic Geology, Lancaster**, v. 58, p. 1246-1266, 1963.

MATHERON, G. **The theory of regionalized variables and its application**. Les Cahiers du Centre de Morphologie Mathematique, n. 5, 1971.

MELO, G. W.; MEURER, E. J.; PINTO, L. F. S. **Fontes de potássio em solos distroférricos cauliniticos originados de basalto no rio grande do sul**. Revista brasileira de ciência do solo, viçosa, 2004, v.28, p.597-603.

MENESES, P. R.; MADEIRA NETTO, J. S. **Sensoriamento remoto: reflectância dos alvos naturais**. Editora Universidade de Brasília; Planaltina: Embrapa Cerrados, 2001.

MERZLYAK, M. N. et al. **Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening**. Physiologia plantarum, v. 106, n. 1, 1999, p. 135-141.

MIELE, A.; FLORES, C. A.; ALBA, J. M. F. **Efeito da variabilidade espacial de solos do Vale dos Vinhedos na composição do vinho Merlot – Safra 2012**. Agricultura de Precisão: resultados de um novo olhar. p. 361 – 367. 2014.

MIELE, A.; FLORES, C. A.; ALBA, J. M. F. **Status atual da pesquisa de viticultura de precisão no Rio Grande do Sul: primeiros resultados da UP Uva para Vinho.** Agricultura de Precisão: um novo olhar. Embrapa Instrumentação. p. 266-272. 2011.

MOLIN, J. P. **Agricultura de precisão – O gerenciamento da variabilidade** piracicaba/SP 2001 83p.

MOLIN, J. P. **Definição de unidades de manejo a partir de mapas de produtividade.** Engenharia Agrícola. Jaboticabal v22 n1 p 83-92. 2002.

MOLIN, J. P., AMARAL, L. R., COLAÇO, A. F. **Agricultura de precisão.** 1. Ed. São Paulo: Oficina de Textos, 2015. 119-130 p.

MORAL, F.J.; TERRÓN, J.M.; SILVA, J. R. M. D. **Delineation of management zones using mobile measurements of soil apparent electrical conductivity and multivariate geostatistical techniques.** Soil and Tillage Research, v. 106, n. 2, 2010, p.335-343.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação.** 3. ed. atual ampl. Viçosa: Ed. UFV, 2007.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto.** 4 ed. Viçosa. Editora UFV, 2011.422p.

MOREIRA, M.A. **Fundamentos de Sensoriamento Remoto e metodologias de Aplicação,** 3ª ed. Viçosa: UFV, 2005, 320p.

MOTOIKE, S.; BORÉN, A. **Uva do plantio à colheita,** editora UFV, 2018. 185p.

MUITOS CAPÕES. Prefeitura Municipal. **Projeto Plano Ambiental do Município de Muitos Capões-2010.** Disponível em: Acesso em: 24 Jun. 2019.

NAKAJI, T.; OGUMA, H. and FUJINUMA, Y. 2006. **Seasonal changes in the relationship between photochemical reflectance index and photosynthetic light use efficiency of Japanese larch needles.** International Journal of Remote Sensing, 27(3), 493-509.

NATALE, N.; ROZANE, D. E. **Análise de solo, folhas e adubação de frutíferas –** Registro UNESP campos experimental de registro, Universidade federal do Paraná, Brasil, 2018.

NICHOL, C.J.; HUENNRICH, K.F.; BLACK, T.A.; JARVIS, P.G.; WALTHALL, J.G. and HALL, F.G. 2000. **Remote sensing of photosynthetic-light-use efficiency of boreal forest.** Agricultural and Forest Meteorology, 101, 131-142.

NICHOL, C.J.; HUENNRICH, K.F.; BLACK, T.A.; JARVIS, P.G.; WALTHALL, J.G. and HALL, F.G. 2000. **Remote sensing of photosynthetic-light-use efficiency of boreal forest.** Agricultural and Forest Meteorology, 101, 131-142.

- NICHOL, C.J.; LLOYD, J.; SHIBISTOVA, O.; ARNETH, A.; RÖSER, C.; KNOHL, A.; MATSUBARA, S. and GRACE, J. 2002. **Remote sensing of photosynthetic-light-use-efficiency of a Siberian boreal forest.** *Tellus*, 54B, 677-687.
- NICHOL, C.J.; LLOYD, J.; SHIBISTOVA, O.; ARNETH, A.; RÖSER, C.; KNOHL, A.; MATSUBARA, S. and GRACE, J. 2002. **Remote sensing of photosynthetic-light-use-efficiency of a Siberian boreal forest.** *Tellus*, 54B, 677-687.
- NICHOL, C.J.; RASCHER, U.; MATSUBARA, S. and OSMOND, B. 2006. **Assessing photosynthetic efficiency in an experimental mangrove canopy using remote sensing and chlorophyll fluorescence.** *Trees*, 20, 9-15.
- NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações.** Edgard Blücher Ltda., 1ª edição, 1989.
- OLIVEIRA et al. **Geoestatística aplicada na agricultura de precisão utilizando o vésper,** Brasília DF Embrapa, 2015.
- OLIVEIRA, A. S. et al. Tecidos vegetais. **Embrapa Pecuária Sudeste-Capítulo em livro científico (ALICE)**, 2005.
- OLIVER, M. A. **Geostatistical applications for precision agriculture.** New York: springer, 2010.
- PEEL, M. C. FINLAYSON, B. L. MCMAHON, T. A.. **Updated world map of the Köppen-Geiger climate classification.** *Hydrology and Earth System Sciences Discussions*, European Geosciences Union, 2007, 4 (2), pp.439-473.
- PEGUERO-PINA, J.J.; MORALES, F.; FLEXAS, J.; GIL-PELEGRÍN, E. and MOYA, I. 2008. **Photochemistry, remotely sensed physiological reflectance index and de-epoxidation state of xanthophyll cycle in Quercus coccifera under intense drought.** *Oecologia*, 156(1), 1-11.
- PEÑUELAS, J. et al. **Estimation of plant water concentration by the reflectance water index WI (R900/ R970).** *International Journal of Remote Sensing*, Abingdon, v. 18, n. 13, 1997, p. 2869-2875.
- PEÑUELAS, J.; BARET, F.; FILELLA, I. **Semiempirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance.** *Photosynthetica*, Dordrecht, v. 31, 1995, p. 221-230.
- PEREIRA, T.P. et al. **O clima da Região dos Campos de Cima da Serra,** Rio Grande do Sul: condições térmicas e hídricas. *Pesquisa Agropecuária Gaúcha*, Porto Alegre, v.15, n.2. p.145-157, 2009. Acesso em: 20 jul. 2019.
- PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação.** Editora Parêntese. **São José dos Campos, 127p**, v. 20017, 2007.
- PONZONI, F. J.; SHIMBUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento Remoto da Vegetação.** São José dos Campos, SP, Oficina de Textos, 2ª edição, 176 p., 2012.

PROFFITT, T.; BRAMLEY, R.; LAMB, D.; WINTER, E. **Precision viticulture: A new era in vineyard management and wine production**. Ashford: Winetitles, 2006. 90 p.

PROTAS, J. F. da S.; CAMARGO, U. A. **Vitivinicultura brasileira: panorama setorial de 2010**. Brasília: SEBRAE; Bento Gonçalves: IBRAVIN / Embrapa Uva e Vinho, 2011. 110 p.

RABELLO, L. M.; INAMASU, R. Y.; BERNARDI, AC de C. **Sistema de medida de condutividade elétrica do solo**. Embrapa Instrumentação-Circular Técnica (INFOTECA-E), 2010.

RADAM Brasil. Folha SH. 22 Porto Alegre e Parte das Folhas SH. 21, Uruguaiana e SI. 22: **Ecologia, Geomorfologia, Pedologia, Vegetação, Uso Potencial da Terra**. Rio de Janeiro, IBGE, 1986.

RHEINHEIMER, D. S.; ANGHINONI, I. **Distribuição do fósforo inorgânico em sistemas de manejo de solo**. Pesquisa agropecuária brasileira, Brasília, v36, p151-160, 2001.

RIBEIRO, J.R.; DIGGLE, P. J. **A package for geostatistical analysis**. R-NEWS, Vol 1, N. 2. 2001. ISSN 1609-3631. Disponível em <<http://cran.r-project.org/doc/Rnews>>. Acesso em: 27 Jun 2019.

ROBERTSON, G. P. **Geostatistics for the environmental sciences** (version 5.1 for windows) – GS+ User's Guide. Plainwell, Gamma Design Software, 1998. 152p.

RODRIGUEZ- PÉREZ, J. R. et al. Using apparent **soil electrical conductivity (EC_a) to characterize vineyard soils of high clay content**. Precisoim Agriculture, v. 12, n. 6, 2011, p 775-794.

ROLAS 2016. **Manual de Calagem e Adubação Para os Estados do Rio Grande do Sul e Santa Catarina**, Comissão de química e fertilidade do solo. Edição 2016.

ROUSE Jr, J. W et al. **Monitoring vegetation systems in the Great Plains with ERTS**. 1974.

SAIANDA, B. R. **Avaliação e validação da variabilidade espacial da produção e qualidade recorrente a monda de cachos, nas castas Touriga nacional**. Instituto Superior de Agronomia da Universidade de Lisboa. Dissertação (Mestrado em patrimônio cultural) - Instituto Superior de Agronomia da Universidade de Lisboa, 2017.

SALVIANO, A.A.C.; VIEIRA, S.R. & SPAROVEK, G. **Variabilidade espacial de atributos de solo e de Crotalaria juncea-L em área severamente erodida**. R. Bras. Ci. Solo, 1998, p.115-122.

SANCHES, I.; ANDRADE, R.; QUARTAROLI, C.; RODRIGUES, C. **Análise comparativa de três métodos de correção atmosférica de imagens Landsat 5 – TM para obtenção de reflectância de superfície e NDVI.** In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 30., 2011, Curitiba. Anais XV, São José dos campos INPE, 2011. Artigos, p.7564. On-line. Disponível em: <<http://dsr.inpe.br/sbsr2011/files/p1555.pdf>>. Acesso em: 24 Jun. 2019.

SANTI, A. L. **Aprimoramento do manejo do solo utilizando as ferramentas da agricultura de precisão.** 2007. Tese de doutorado, 210 p tese (doutorado em ciência do solo) - Programa Pós graduação em ciência do solo, Universidade Federal de Santa Maria, Santa Maria, 2007

SEBEM, E. **Aportaciones de la teledetección em el desarrollo de um sistema metodológico para la evaluación de los efectos del cambio climático sobre la producción de las explotaciones agrárias.** 2005. 381p. tese (doutorado em agronomia). Universid politécnica de Madrid, Madrid, 2005.

SEBEM, E. **Distribuição Espacial de Famílias Botânicas em Parcela de Floresta Ombrófila Mista e Suas Relações com *Araucariaceae* na Flona ne São Francisco de Paula, Rs.** Monografia (Especialização) - Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Especialização em Estatística e Modelagem Quantitativa, RS, 2017, 106p.

SEIDEL, E J; OLIVEIRA, M S. **A classification for a geostatistical index of spatial dependence.** Revista Brasileira de Ciência do Solo, v. 40, p. 1-10 (e0160007), 2016.

SEIDEL, E J; OLIVEIRA, M S. **Novo índice geoestatístico para a mensuração da dependência espacial.** Revista Brasileira de Ciência do Solo, v. 38, n. 3, p. 699-705, 2014.

SEIDEL, E.J.; OLIVEIRA, M.S. **New geostatistical index for measuring spatial dependence.** Revista Brasileira de Ciência do Solo, v.38, p.699-705, 2014. Disponível em: < doi:10.1590/S0100-06832014000300002. scielo.br/pdf/rbcs/v38n3/02.pdf>. Acesso em: 23 jun. 2019.

SERRANO, L. and PEÑUELAS, J. 2005. **Assessing forest structure and function from spectral transmittance measurements: a case study in a Mediterranean holm oak forest.** Tree Physiology, 25, 67-74.

SETHURAMASAMYRAJA, B.; SACHIDHANNTHAM, S.; WAMPLE, R. **Geospatial Modeling of Wine Grape Quality Indicators (Antocyanin) for Development of Differential Wine Grape Harvesting Technology,** Internacional Journal Geomatics and Geosciences. V 1,No 3, Fresno, USA, 2010.

SILVA, E. L. S.; PONZONI, F. J. **Comparação entre a reflectância hemisférica de folhas e a reflectância bidirecional de um dossel.** Revista árvore, v. 19, n. 4, 1995. p. 466-478.

SILVA, F. M.; Chaves, M. S.; Lima, Z. C. L.; **Geografia Física II.** Natal, RN: EDUFRN, 2009. 240 p.

SILVA, M. A. V.; MOSCON, E. S.; SANTANA, C. C. **Determination of biomass production of cotton using satellite images and spectral indexes.** Journal of Hyperspectral Remote Sensing, v. 7, n. 2, p, 2017, p73-81.

SIMONETTI, D. S.; ULABY, F. T. (EDS). **Manual of Remote Sensing.** 2. ed. Vol. I. Falls Church VA: American Society of Photogrammetry, 1983, 1232 p.

SIMS, D.A.; LUO, H.; HASTINGS, S.; OECHEL, W.C.; RAHMAN, A.F. and Gamon, J.A. 2006. **Parallel adjustment in vegetation greenness and ecosystem CO₂ exchange in response to drought in a Southern California chaparral ecosystem.** Remote Sensing of Environment, 103, 289-303.

SIVERIO, J. J. M. **Viticultura de precisión: uma radiografia para El diagnóstico.** ACE Revista de Enología, Catalan, n. 65, ene. 2005. Disponível em: <[HTTP://www.acenologia.com/ciencia7303.htm](http://www.acenologia.com/ciencia7303.htm)>. Acesso em: 28 Jun 2019.

SKIANIS, G. A.; NIKOLAKOPOULOS, K. G. **A study of the Performance of the Modified Simple Vegetation Index (MSVI), based on probability theory.** Proceedings of the 29th Earsel Symposium, Chania, Greece, 15–18 2009, 287–294.

SLATER, P. N. **Remote Sensing, Optics and Optical Systems.** Boston (MA): Addison-Wesley Pub. Co., 1980, 575 p.

SMIT, J. L.; SIHOLE, G.; STREVER, A. E. 2010. **Vine signal extraction: an application of remote sensing in precision viticulture.** S. Afr. J. Enol. Vitic. 31(2), 65-74. Disponível em: < <http://hdl.handle.net/10019.1/8420> >. Acessado em: 25 Jun. 2019.

SOARES de Souza Lima; JULIÃO et al. **ANÁLISE ESPACIAL DE ATRIBUTOS QUÍMICOS DO SOLO E DA PRODUÇÃO DA CUTURA PIMENTA-DO-REINO (PIPER NIGRUM, L.)** Idesia, Arica, v. 28, n. 2, p. 31-39, agosto 2010. Disponível em <https://scielo.conicyt.cl/scielo.php?script=sci_arttext&pid=S07183429201000020004&lng=es&nrm=iso>. Acesso em: 20 jul. 2019.

SOARES, A. **Geoestatística para ciências da terra e do ambiente.** 2 ed., Lisboa: Instituto Superior Técnico, 2006, 214p.

SORT, X.; UBALDE, J. M. **Valorización De Los Estudios De Zonificación Vitícola Como Estrategia Frente Al Cambio Climático.** 2009. Data de acesso: 27 Jun. 2019.

SOUZA JÚNIOR, J.G.A.; DEMATTÊ, J.A.M.; GENÚ, A.M. **Comportamento espectral dos solos na paisagem a partir de dados coletados por sensores terrestre e orbital.** Revista Brasileira de Ciência do Solo, v. 32, p. 727-738, 2008.

SOUZA, L. C. **Variabilidade espacial da salinidade de um solo aluvial no árido paraibano.** 1999. 77p. Dissertação (mestrado em agronomia) Universidade Federal de Paraíba, Campina Grande 1999.

SRINIVASAN, C. & MULLINS, M. G. **Fisiologia do florescimento na videira: uma revisão. Tradução Celso V. Pommer, Luiz Antonio Biasi.** Campinas, Instituto Agrônomo de Campinas, 2000, 27p. (Documentos IAC,67). Título original: Physiology of flowering in the grapevine – A review, publicado pela University of California, Davis, Califórnia, 1981.

STEFFEN, C. A. et.al. **Técnicas radiométricas com o Spectron SE-590.** Simpósio Brasileiro de Sensoriamento Remoto, v. 8, 1996, p. 9-14.

STRACHAN, I.B., PATTEY, E. and BOISVERT, J.B. 2002. **Impact of nitrogen and environmental conditions on corn as detected by hyperspectral reflectance. Remote Sensing of Environment**, 80, 213-224.

STRECK et al. **Solos do Rio Grande do Sul.** Porto Alegre, UFRGS: EMATER/RS-ASCAR.2. Ed ver. Ampl. 2008, 222 p.

SUÁREZ, L.; ZARCO-TEJADA, P. J., SEPULCRE-CANTÓ, G., PÉREZ-PRIEGO, O., MILLER, J.R., JIMÉNEZ-MUÑOZ, J.C. and SOBRINO, J. 2008. **Assessing Canopy PRI For Water Stress Detection With Diurnal Airborne Imagery. Remote Sensing of Environment**, 112, 560-575.

SUNDAR RAY, A. **Remote Sensing in Agriculture.** International J. of Environment, Agriculture and 43 Biotechnology, v. 1 (3), 2016, p. 362 – 367.

TRIBONI, H. R.; BARBOSA, J. C.; **Estimativa do número de frutos por amostragem de parte da copa em laranjeiras.** Revista Brasileira de Fruticultura, Jaboticabal, v.26, n. 3, p. 454-458, Dez 2004. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-29>. Acesso em: 23 jun. 2019.

TROTTER, G.M.; WHITEHEAD, D. and PINKNEY, E.J. 2002. **The photochemical reflectance index as a measure of photosynthetic light use efficiency for plants with varying foliar nitrogen contents. International Journal of Remote Sensing**, 23(6), 1207-1212.

ULIANA, M. R.; VENTURINI FILHO, W. G.; OLIVEIRA, J. M.; Teixeira, J. A. **Vinhos de mesa varietais de uvas americanas: análises químicas e energéticas.** Energia na Agricultura (UNESP. Botucatu. CD-Rom), v. 30, p. 98-103, 2015.

VAN LEEUWEN, C. & SEGUIN, G. **The Concept of Terroir in Viticulture.** Journal of Wine Research, Vol. 17, Nº. 1, 2006, p.1–10.

VANOLI, M.; BUCCHERI, M. **Overview of the methods for assessing harvest maturity.** Stewart Postharvest Rev. v. 8 (1), 2012, p. 1–11.

VANZELA, E. S. L.; DA-SILVA, R.; BAFFI, M. A. **Uvas e Vinhos: química, bioquímica e microbiologia.** Editora UNESP e Editora SENAC, São Paulo, 1.ed., v. 1., 2015. 192p.

VERCESI, A. **Projetare um vigneto per laproducedi uva diqualità com l'aiuto Del terrelivamento e Del La viticoltura di precisione: Lê sceltedecisionali in fase di impianto e conduzione Del vigeto posso nooggiav valer si di tecnologie all'avanguardia.** Phytomagazine, Milano, v. 33, Ott. 2004.

VIANA, J. H. M. **Distribuição espacial de atributos físico-químicos mineralógicos e micromorfológicos de latossolos, visando o mapeamento das áreas produtivas.** Tese de doutorado - Programa de Pós Graduação em Solos e Nutrição de Plantas, Universidade Federal de Viçosa, Viçosa, 2005. 194p.

VIEIRA, R. S.; CARVALHO, J. R.P.; GONZÁLES, A. P. **Jack Knifing For Semivariogram Validation,** *Bragantia*, v 69, 2010, p. 97- 105.

VIEIRA, S. R. **Geoestatística em estudos de variabilidade espacial.** Campinas: IAC, 1998.

VIEIRA, S. R. **Geoestatística aplicada à agricultura de precisão.**-Capitulo 5, *Principios em Agricultura de precisão, GIS Brasil*, v. 98, 2000. p 93-106.

VIEIRA, SIDNEY R. et al. **Handbook for geostatistical analysis of variability in soil and climate data.** *Tópicos em ciência do solo*, v. 2, 2002. p. 1-45.

WAMPLE, R. L.; MILLS, L.; DAVENPORT, J. R. **Use of precision farming practices in grape production.** In: *International Conference On Precision Agriculture*, 4. 1998, Saint Paul, Estados Unidos. Minneapolis: University of Minnesota, 1999. p. 897-905.

XUE, Y.LI. Y.; GUANG, J.; ZHANG, X.; GUO, J. **Small satellite remote sensing and applications – history, current and future.** *International journal of remote sensing*, v.29, no. 15, 2008. p. 4339-4372.

YAMAMOTO, J. K.; LANDIM, P. M. B. **Geoestatística: Conceitos e aplicações.** São Paulo: Oficina de Textos, 2013, 215p.

ZARCO-TEJADA, P. J. **Hyperspectral remote sensing of closed Forest canopies: Estimation of chlorophyll fluorescence and pigment content.** PhD thesis, graduate programme in earth and space science, York university, Toronto, Ontario, Canada, 2000. 210p.

ZARDO, K. **Viticultura De Precisão Aplicada A Produção e Qualidade De Uva Pinot Noir No Rio Grande Do Sul.** 2009. 98 f. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal de Santa Maria, Santa Maria, 2009.

ZWIGGELAAR, R. **A review of spectral properties of plants and their potential use for crop/wed discrimination in row- crops.** UK, v. 17, ed. 3, 1998, p 189-206.

ANEXO 1 – MAPA BASE

