

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E
METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO**

DINIZ CARVALHO DE ARRUDA

**USO DE DADOS ESPECTRAIS NA DIFERENCIAÇÃO DE REGIÕES VITIVÍCOLAS DO
RIO GRANDE DO SUL, BRASIL**

Porto Alegre – RS, Brasil

2016

DINIZ CARVALHO DE ARRUDA

**USO DE DADOS ESPECTRAIS NA DIFERENCIAÇÃO DE REGIÕES VITIVÍCOLAS DO
RIO GRANDE DO SUL, BRASIL**

Dissertação apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de mestre em Sensoriamento Remoto, área de concentração Sensoriamento Remoto aplicado aos Recursos Naturais.

Orientador: D.Sc. Jorge Ricardo Ducati – UFRGS

Coorientadora: Dra. Rosemary Hoff – EMBRAPA/CNPV

Porto Alegre – RS, Brasil

2016

CIP - Catalogação na Publicação

Carvalho de Arruda, Diniz
USO DE DADOS ESPECTRAIS NA DIFERENCIAÇÃO DE
REGIÕES VITIVINÍCOLAS DO RIO GRANDE DO SUL, BRASIL /
Diniz Carvalho de Arruda. -- 2016.
70 f.

Orientador: Jorge Ricardo Ducati.
Coorientadora: Rosemary Hoff.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de Pós-
Graduação em Sensoriamento Remoto, Porto Alegre, BR-
RS, 2016.

1. regiões vitícolas. 2. reflectância. 3.
sensoriamento remoto. 4. espectrorradiometria. 5.
análise discriminante. I. Ricardo Ducati, Jorge ,
orient. II. Hoff, Rosemary, coorient. III. Título.

**Aprovado pela Banca Examinadora em cumprimento ao requisito exigido para
obtenção do Título de Mestre em Sensoriamento Remoto.**

Dra. Denise Cybis Fontana (UFRGS)

Dra. Gisele Cemin (UCS)

Dr. Celito Guerra (Embrapa)

D. SC. Jorge Ricardo Ducati (UFRGS)
Orientador

Dra. Rosemary Hoff (Embrapa)
Coorientadora

Diniz Carvalho de Arruda

Porto Alegre – RS, Brasil
2016

AGRADECIMENTOS

Ao professor doutor Jorge Ricardo Ducati, pela sua orientação no desenvolvimento desta dissertação. Agradeço os incentivos e pela ajuda nos exaustivos trabalhos de campo.

À pesquisadora doutora Rosemary Hoff, minha coorientadora, pelos auxílios no desenvolvimento das atividades deste trabalho.

À Prof.^a Adriane, pela sua amizade e parceria nos exaustivos trabalhos de campo na vinícola Boscato.

À Prof.^a Virindiana, por sua amizade, motivação e conselhos. Obrigado pelas discussões construtivas sempre acompanhadas de muito café, chocolates e boas risadas.

Aos proprietários das vinícolas Almadén, Boscato, Chandon e Miolo Seival, que disponibilizaram a nossa entrada em suas propriedades para realização dos trabalhos de campo.

À Universidade Federal do Rio Grande do Sul – UFRGS e ao Programa de Pós-graduação em Sensoriamento Remoto – PPGSR, pela infraestrutura oferecida e à CAPES, por meio da bolsa de aperfeiçoamento, nível mestrado, pelo apoio financeiro.

Aos meus companheiros de viagem, Luis Fernando e Tatiana, pela companhia e as boas conversas.

Aos meus amigos Fernando, Mariele e Veridiana, pela amizade e ajuda durante as minhas estadias em Porto Alegre.

Aos meus colegas e amigos “Sensorientos” pelas conversas acompanhadas de bom humor e trocas de conhecimento. A convivência em grupo proporcionou o surgimento de muitas indagações e suposições, que me deixou “Cheio de Problemas”. Graças a vocês pude observar a complexidade da mente humana.

À minha família, meus pais Nairo e Eunice, minhas irmãs Jaqueline e Janice, e ao meu sobrinho Jaderson, pelo incentivo e apoio nos momentos difíceis.

Por fim à Deus, que se permitiu presente durante todo este período e me proporcionou vivenciar momentos únicos, que contribuíram diretamente com meu crescimento intelectual.

RESUMO

Novas regiões vitícolas estão se estabelecendo em muitas regiões brasileiras. Em especial, no estado do Rio Grande do Sul diversos empreendimentos estão instalados ou em fase de projeto de instalação em várias regiões. No contexto da moderna vitivinicultura nacional, um fator importante de agregação de valor aos produtos resultantes da atividade é a sua associação a uma identidade regional, tendência próxima ao conceito de terroir. Tratando-se de regiões produtoras novas, faz-se necessário um complexo levantamento de características de cada região produtora, de modo que sejam definidos parâmetros de diferenciação que confirmem, a cada região, a necessária tipicidade tão próxima à ideia de terroir. Este trabalho propõe-se a trazer uma contribuição à caracterização de algumas novas regiões vitícolas do Rio Grande do Sul, tentando mostrar que é possível evidenciar fatores físicos que diferenciam cada região. Foram escolhidas três áreas na metade sul do estado, sendo duas na Campanha Gaúcha (Almadén em Santana do Livramento e Seival em Candiota), e uma na Serra do Sudeste (Chandon em Encluzilhada do Sul); também foi estudada uma área na Serra Gaúcha (Boscato em Nova Pádua). Como ferramentas de estudo, foram utilizadas técnicas de espectrorradiometria para levantamento de dados de campo nas quatro regiões, onde foram tomados espectros de reflectância foliar no visível e no infravermelho próximo e médio. Foram selecionadas parcelas de parreirais das variedades Cabernet Sauvignon, Merlot, Pinot Noir, Chardonnay e Riesling Itália. Também foram utilizadas imagens de satélite (ASTER) para estudar as áreas da Almadén e Seival, com dados de reflectância no visível e no infravermelho de diversos cultivares de *Vitis vinifera*. Os dados foram analisados usando-se diversas técnicas de separação, como algoritmos de classificação supervisionada e Análise Discriminante. Os resultados, tanto para os dados de radiometria de campo quanto para os dados orbitais, mostraram que a partir da reflectância de folhas e de dossel é possível separar cada uma das regiões, com acurácias da ordem de 80% ou mais, sendo esta separabilidade atribuída à influência do meio físico sobre as plantas. Conclui-se que a utilização de dados e técnicas de Sensoriamento Remoto, com o apoio de técnicas de análise estatística, constitui relevante ferramenta de apoio à caracterização de regiões vitícolas no Rio Grande do Sul, e provavelmente para qualquer região produtora.

Palavras chave: regiões vitícolas, reflectância, análise discriminante.

ABSTRACT

New viticultural regions are being created in several regions across Brazil. For instance, in Rio Grande do Sul State many wineries are already established, are being installed or are in project phase. In the context of modern Brazilian viticulture, an important factor for added value to products from the activity is its association to a regional identity, a tendency which is akin to the terroir concept. Being new regions, a comprehensive survey of the characteristics of each producing area is necessary, a step leading to the definition of parameters of differentiation, which will give to each region the required typicity, crucial to the terroir idea. Presently, we carry out a contribution to the characterization of some new viticultural regions of Rio Grande do Sul, trying to show that it is possible to bring to light physical factors which will differentiate each region. Three areas in the State's *Metade Sul* (southern half) were selected, being two in the Campanha Gaúcha region (Almadén in Santana do Livramento and Seival in Candiota), and another one at the Serra do Sudeste (Chandon in Encruzilhada do Sul); we also selected a winery at the Serra Gaúcha (Boscatto in Nova Pádua). As tools for this study, we used techniques of spectroradiometry to collect field data in all four regions, acquiring spectra of leaf reflectance in visible, wavelengths, and at near and mean infrared as well. We selected vineyards of the grape varieties Cabernet Sauvignon, Merlot, Pinot Noir, Chardonnay and Riesling Itálico. Satellite images (ASTER product) were also taken to study the Almadén and Seival wineries, using reflectance data in visible and infrared for some varieties of *Vitis vinifera*. All data were analyzed through several techniques intended for differentiation, as algorithms for supervised classification and, in Statistics, Discriminant Analysis. The results, from radiometry field data and from satellite data as well, showed that from the reflectance of leaves and canopy it is possible to separate each region, with accuracies as high as 80% and even more. This separability is believed to be due to the influence of the physical environment on plants. It is concluded that the use of data and techniques from Remote Sensing, associated with techniques of statistical analysis, are relevant tools to support the characterization of viticultural regions in Rio Grande do Sul and probably in any producing region.

Keywords: viticultural regions, reflectance, discriminant analysis.

SUMÁRIO

INTRODUÇÃO	14
1.1. CONSIDERAÇÕES INICIAIS.....	14
1.2. JUSTIFICATIVA	16
1.3. OBJETIVO GERAL.....	16
1.4. OBJETIVOS ESPECÍFICOS	16
FUNDAMENTAÇÃO TEÓRICA.....	18
2.1. SENSORIAMENTO REMOTO E VITICULTURA	18
2.2. CARACTERÍSTICA DO SENSOR ORBITAL ASTER	19
2.3. CARACTERÍSTICA DO SENSOR ULTRAESPECTRAL FIELD SPEC 3	20
2.4. COMPORTAMENTO ESPECTRAL	21
2.5. CLASSIFICAÇÃO DOS DADOS	24
2.5.1. <i>Análise Discriminante – AD</i>	25
2.5.2. <i>Probabilidade a priori (Distância de Mahalanobis)</i>	26
2.5.3. <i>Funções Discriminantes Canônicas</i>	27
MATERIAL E MÉTODOS	28
3.1. FLUXOGRAMA GERAL DO TRABALHO	28
3.2. ÁREA DE ESTUDO.....	28
3.3. MEDIDAS ESPECTRORRADIOMÉTRICAS DE REFLETÂNCIA.....	30
3.3.1. <i>Normalização dos espectros</i>	34
3.3.2. <i>Análise Discriminante dos dados espectrorradiométricos</i>	36
3.4. PROCESSAMENTO DAS IMAGENS ASTER	37
3.4.1 <i>Classificação das Imagens</i>	38
RESULTADOS E DISCUSSÃO.....	40
4.1. COMPORTAMENTO ESPECTRAL DAS VARIEDADES DE UVA EM DIFERENTES REGIÕES.	40
4.2. REDUÇÃO DA DIMENSIONALIDADE DOS DADOS	41
4.3. ANÁLISE DISCRIMINANTE DOS DADOS ESPECTRORRADIOMÉTRICOS.....	44
4.3.1. <i>Classificação quanto à coloração</i>	45
4.3.2. <i>Classificação quanto à variedade em diferentes regiões</i>	46
4.3.3. <i>Classificação entre variedades</i>	51
4.3.4. <i>Classificação quanto à região</i>	53
4.4. CLASSIFICAÇÕES NAS IMAGENS ASTER.....	55
4.4.1. <i>Análise Discriminante dos dados orbitais</i>	60
4.5. COMPARAÇÃO ENTRE OS DADOS (ASTER X FIELD SPEC)	62

CONCLUSÃO.....	64
REFERÊNCIAS	66

LISTA DE FIGURAS

Figura 1. Método para definição da resolução espectral para sensor ASD, usando <i>Full Width Half Maximum</i> (FWHM) da resposta do instrumento a uma fonte monocromática. Fonte: (ASD, 2014).	21
Figura 2. Comportamento espectral típico da vegetação saudável, com os fatores causadores das feições espectrais (Adaptado: Pabhakar et al., 2012).	23
Figura 3. Resposta espectral de folhas com diferentes concentrações de antocianinas (Adaptado: STEELE et al., 2009).	24
Figura 4. Fluxograma geral das etapas de desenvolvimento das atividades neste trabalho.	28
Figura 5. Localização da área de estudo em relação ao seu contexto geográfico.	29
Figura 6. Espectrorradiômetro <i>Field Spec 3</i> ASD e o acessório <i>Probe Leaf Clip</i> utilizado neste trabalho.	32
Figura 7. Fluxograma para realização das etapas de processamento das imagens.	39
Figura 8. Espectro de reflectância foliar típico para cada variedade, localizada nas quatro vinícolas.	40
Figura 9. Espectros de reflectância normalizados nas vinícolas estudadas.	41
Figura 10. Gráficos referentes às diferenças normalizadas efetuadas a partir dos espectros de reflectância.	43
Figura 11. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para a classe Chardonnay.	49
Figura 12. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para a classe Merlot.	51
Figura 13. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para todas as variedades.	53
Figura 14. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para todas as regiões.	55
Figura 15. Mapa para classificações entre variedades na vinícola Almadén.	56
Figura 16. Mapa para classificações entre variedades na vinícola Miolo Seival.	58

LISTA DE TABELAS

Tabela 1. Características físicas e operacionais do sensor ASTER. Fonte: NASA, 2014.	20
Tabela 2. Dados referentes às normais climatológicas pluviométricas, em milímetros.	30
Tabela 3. Informações referentes aos trabalhos de campo.	31
Tabela 4. Parâmetros físicos utilizados para cada imagem na correção atmosférica.	38
Tabela 5. Informações referentes aos comprimentos de onda selecionados a partir dos gráficos de diferença normalizada.	42
Tabela 6. Funções discriminantes canônicas para as classes de estudo.	44
Tabela 7. Matriz de correlação resultante dos valores de reflectância foliar, quanto ao tipo de coloração da uva.	46
Tabela 8. Matriz de correlação resultante dos valores de reflectância foliar, para variedade Cabernet Sauvignon, nos vinhedos 1 e 2 da vinícola Boscato.	47
Tabela 9. Matriz de correlação resultante dos valores de reflectância foliar, para a variedade Pinot Noir localizadas nas vinícolas, Chandon e Miolo Seival.	48
Tabela 10. Matriz de correlação resultante dos valores de reflectância foliar para a variedade Riesling Itálico, localizadas nas vinícolas Almadén e Chandon.	48
Tabela 11. Matriz de correlação resultante dos valores de reflectância foliar, para a variedade Chardonnay, localizada nas vinícolas Almadén, Chandon, Miolo Seival.	49
Tabela 12. Matriz de correlação resultante dos valores de reflectância foliar, em diferentes regiões para a variedade Merlot.	50
Tabela 13. Matriz de correlação resultante dos valores de reflectância foliar, quanto às variedades de uva, para todas as regiões.	52
Tabela 14. Matriz de correlação resultante dos valores de reflectância foliar, por regiões.	54
Tabela 15. Matriz de correlação entre variedades, utilizando o classificador pela distância de Mahalanobis entre variedades, para vinhedos Almadén.	57
Tabela 16. Matriz de correlação entre variedades, utilizando o classificador de Máxima Verossimilhança para vinícola Almadén.	57
Tabela 17. Matriz de correlação entre variedades, utilizando o classificador pela distância de Mahalanobis para as variedades da vinícola Miolo Seival.	59
Tabela 18. Matriz de correlação entre variedades, utilizando o classificador de Máxima Verossimilhança para as variedades da vinícola Miolo Seival.	59
Tabela 19. Funções discriminantes canônicas para os dados das imagens ASTER.	60
Tabela 20. Matriz de correlação entre variedades, tomando as observações em todas as regiões, por imagens ASTER.	61

Tabela 21. Matriz de correlação entre as observações em diferentes regiões, por imagens ASTER.....	62
Tabela 22. Os coeficientes discriminantes de Fisher com seus pesos atribuídos com os dados espectrorradiométricos relacionados com as bandas do sensor ASTER.	63

LISTA DE ABREVIATURAS E SIGLAS

AD	Análise Discriminante
ACP	Análise Componente Principal
ASD	Analytical Spectral Devices
ASTER	Advanced Spaceborne Thermal and Reflection Radiometer
FLAASH	Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes
IG	Indicação Geográfica.
VNIR	Visible and Near Infrared
REM	Radiação Eletromagnética
RV	Regiões Vitivinícolas
RS	Rio Grande do Sul
SR	Sensoriamento Remoto
SWIR	Shortwave Infrared
TIR	Thermal Infrared

Introdução

1.1. Considerações iniciais

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 vinhas *Vitis vinifera* de origem européia. Em âmbito estadual destacam-se quatro principais regiões produtoras: Campanha Gaúcha, Campos de Cima da Serra, Serra Gaúcha e Serra do Sudeste. Nestas e em outras regiões há grandes áreas aptas ao cultivo da vinha, dando ao setor da vitivinicultura um papel de importância na economia do Estado. Políticas de proteção e valorização dos produtos do setor, como vinhos e sucos, estão sendo desenvolvidas e implementadas, como, por exemplo, a delimitação geográfica de regiões vitivinícolas, as chamadas Indicações Geográficas – IGs, tendo como pressuposto que cada região ou sub-região porta uma tipicidade quanto a fatores ambientais (geologia, solo, topografia, clima) e aos tratamentos culturais que caracterizam o manejo da vinha. A diversidade ambiental e antrópica que potencialmente dá tipicidade aos vinhos é expressa tecnicamente por muitos autores pelo termo *terroir*, termo de origem francesa, que estabelece uma relação entre regionalidade e tipicidade dos vinhos, sem seguir um exato padrão de escala para mapeamento cartográfico (Vaudour, 2002; 2004).

Como resultado do desenvolvimento de trabalhos e projetos de pesquisa em escala regional, vêm sendo propostas metodologias voltadas à coleta de dados sobre os aspectos físicos de diferentes locais do Estado, informações que subsidiam o desenvolvimento do cultivo da videira em cada região. Nesta perspectiva, uma das abordagens relevantes é a que utiliza técnicas de Sensoriamento Remoto, como o uso de imagens orbitais ou medidas espectrorradiométricas de refletâncias, que podem oferecer informações relevantes sobre característica de clima, solo e planta.

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 parreiral durante um ou mais ciclos vegetativos, podendo detectar variações de parâmetros de sanidade ou outros, possibilitando intervenções no manejo da vinha, impedindo perdas na produção, no rendimento e na qualidade das uvas.

Modernamente uma nova geração de sensores/imageadores aerotransportados (VANTs ou *drones*) está sendo incorporada às pesquisas voltadas à caracterização de

culturas agrícolas; no entanto suas imagens, embora de alta resolução espacial, têm pequena cobertura territorial e os equipamentos são de alto custo e de baixa confiabilidade, sendo ademais exigidos conhecimentos técnicos avançados para o planejamento dos vôos e processamento dos dados. Neste ponto de vista, as imagens de sensores orbitais de média resolução permanecem com alta utilização na agricultura e ganham importância pela sua grande cobertura territorial de mapeamento e o baixo custo na aquisição. Imagens de muitos satélites são disponíveis em serviços *online* de distribuição de diversas agências espaciais, como da agência norte-americana *National Aeronautics and Space Administration* – NASA, ou, no Brasil, o Instituto Nacional de Pesquisas Espaciais – INPE.

Os uso de sensores remotos de média resolução (com resolução espacial em torno de 30 metros) aplicados na viticultura pode sofrer limitações devido ao tamanho do seu pixel. Áreas de parcelas relativamente pequenas (em geral não excedendo cinco hectares) e o espaçamento entre fileiras nos vinhedos que utilizam o sistema de condução em espaldeira (em torno de dois ou três metros), são condicionantes espaciais que ocasionam um efeito de mistura espectral entre a refletância do dossel das videiras e da vegetação entre fileiras (Silva & Ducati, 2009; Cemin & Ducati, 2011). A identificação das classes que compõem a mistura espectral em um pixel é tarefa complexa, principalmente em se tratando de dosséis de parreiras com diversos cultivares. Uma informação relevante para operações de classificação, neste aspecto, é o conhecimento da assinatura espectral de cada cultivar, considerada sua refletância foliar coletada por intermédio do uso de sensores remotos terrestres como os espectrorradiômetros. A aquisição de medidas espectrorradiométricas em campo serve como dado de verdade terrestre, sendo a base para o reconhecimento de diferentes padrões espectrais dos alvos terrestres (Jensen, 2011). Em medidas de campo a ausência da interferência atmosférica e de outras classes de uso (como gramíneas ou solo exposto) permite o registro do comportamento espectral puro do objeto ou alvo observado.

Os processos de reflexão, que são o fenômeno físico que dá origem aos dados de refletância coletados por espectrorradiometria, diferem de uma espécie vegetal para outra, gerando espectros característicos de cada espécie e que permitem sua mútua diferenciação (Hall et al 2002, Hall et al, 2003). Porém, quando essa distinção é buscada entre classes vegetais consistindo de cultivares da mesma espécie, o processo discriminatório é dificultado, já que as assinaturas espectrais são muito semelhantes. Nestes casos, o emprego de medidas via sensores ultraespectrais, os espectrorradiômetros de campo, proporciona um maior detalhamento do perfil espectral das classes em estudo, quando equiparados com outros sensores hiperespectrais e/ou multiespectrais. Com milhares de bandas espectrais, os sensores ultraespectrais, como ademais todos sensores espectroscópicos, têm a vantagem adicional de operarem em modo não-destrutivo, já que é possível efetuar análises da

composição foliar, que inclui os parâmetros de pigmentos fotossintetizantes, textura e lacunosidade (estrutura celular) e conteúdo de água na folha, sem haver a necessidade de deteriorar a amostra (Steele et al., 2009; Cerovic et al., 2012).

Considerando as vantagens dos sensores ultravioleta quanto à sua alta resolução espectral, pretende-se no decorrer deste trabalho buscar respostas para as seguintes perguntas: Será que é possível distinguir regiões, ou até mesmo representar *terroirs*, por medidas espectrorradiométricas de folhas de videiras? É factível a discriminação espectral de variedades de uvas a partir de dados de imagens orbitais de média resolução, onde ocorre o efeito de mistura de pixel ?

Os passos iniciais para o desenvolvimento de uma metodologia que busque responder a estas indagações passam por adquirir uma maior compreensão do comportamento espectral da vinha, mediante o levantamento de assinaturas espectrais por espectroradiometria de campo e/ou laboratorial, relacionando posteriormente os dados terrestres com medidas coletadas por sensores orbitais.

1.2. Justificativa

A expansão da fronteira vitícola no Rio Grande do Sul requer estudos mais amplos com respeito ao desenvolvimento das videiras frente às variações ambientais e antrópicas que distinguem as regiões. A identidade típica local é um precioso subsídio para a definição das regionalidades das IGs, e neste contexto os dados orbitais e/ou obtidos por espectroradiometria de campo são de suma importância para aumentar a gama de informações nos estudos dirigidos à compreensão do comportamento fisiológico da vinha. Esta dissertação tem como foco estudar os padrões espectrais foliares de videiras, associando suas medidas espectrorradiométricas de campo com imagens satelitais, avaliando a funcionalidade do Sensoriamento Remoto no mapeamento dos dosséis vegetativos de vinhedos localizados em diferentes regiões do Estado.

1.3. Objetivo Geral

- Diferenciar espectros de refletância medidos em folhas e dossel de variedades de videiras (*Vitis vinifera*) cultivadas em diversas regiões do Rio Grande do Sul.

1.4. Objetivos Específicos

- Identificar o comportamento espectral foliar em videiras *Vitis vinifera*, no mesmo estágio fenológico, frente a variações geográficas.

- Explorar o potencial de técnicas estatísticas, em especial da Análise Discriminante, para classificar dados de refletância por cultivar e região;
- Determinar funções discriminantes e os comprimentos de ondas determinantes para discriminação de cada classe de videira;
- Associar imagens do sensor ASTER com medidas espectrorradiométricas e de campo no mapeamento de parcelas vitícolas.

Fundamentação teórica

2.1. Sensoriamento Remoto e Viticultura

O Sensoriamento Remoto (SR) é uma ciência que possibilita a aquisição de dados sobre as mais diversas classes de alvos existentes na Terra, por intermédio da interação física da radiação eletromagnética proveniente do alvo com sensores, sendo os alvos observados e medidos desde longas distâncias, como é caso dos sensores orbitais que observam a Terra. As informações obtidas desta forma são submetidas a técnicas de tratamento de dados, como interpretações visuais ou processamento de imagens por meio computacional.

As aplicações do SR na viticultura estão basicamente voltadas ao mapeamento de parcelas e vinhedos em diferentes escalas, considerando o domínio espacial e espectral. Uma das aplicações mais usuais é a determinação do vigor vegetativo dentro de um vinhedo, para a aplicação de diferentes manejos, monitoramento do desenvolvimento fenológico e identificação de variedades. 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 & Hamilton, 2004; Sethuramasamyraja et al., 2010). A qualidade da uva e dos produtos derivados são influenciados pelas características da topografia, dos tipos de solos em que as vinhas estão cultivadas; em um exemplo de aplicação, vinhedos foram mapeados com sensores multiespectrais em escala regional, sendo considerados os dados de altimetria, declividade, e índices de umidade (Vaudour et al., 2008).

Alguns trabalhos utilizaram imagens do sensor ASTER para mapeamento de parcelas vitícolas. Dados de refletância da superfície obtidos por este sensor são relevantes para o mapeamento de parcelas vitícolas, como reportado por Silva & Ducati (2009), que compararam dados orbitais de parcelas vitícolas da Campanha Gaúcha com dados espectrorradiométricos de parcelas da Serra Gaúcha, no qual identificaram similaridade no comportamento espectral da vegetação em ambos os sensores. Já Cemin & Ducati (2011) observaram as diferenças entre *terroirs* em diferentes países, mediante o agrupamento de índices de vegetação, efetuados em imagens do sensor ASTER. Ainda utilizando dados deste

sensor, Ducati et al (2014) mostraram que é possível distinguir vinhedos convencionais de orgânicos no Vale de Loire, na França.

Contrastando com sensores orbitais, instrumentos portáteis de campo vêm sendo muito utilizados para o estudo e reconhecimento do comportamento espectral de folhas e dossel de variedades de uvas em escala de análise local. A coleta de medidas de refletância nestas condições se dá com 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). As medições também podem ocorrer em laboratório, em ambiente controlado.

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 sensor espectrorradiômetro. 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 da borda do vermelho.

2.2. Característica do sensor orbital ASTER

Em operação a bordo do satélite Terra, o sensor multiespectral ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) é amplamente utilizado para coleta de dados sobre os recursos naturais, por meio de parâmetros de refletância, temperatura de superfície, emissividade e elevação do terreno (JENSEN, 2009). A resolução espacial do sensor é de 15 a 90 metros, dependendo do subsistema no qual são obtidas as imagens, conforme suas características descritas na Tabela 1. O satélite possui uma órbita circular, heliosíncrona descendente com 98,30° de inclinação, posicionado a uma altitude de 705 km. A partir de 2008 o sensor ASTER deixou de adquirir imagens nas bandas do subsistema SWIR (*Shortwave Infrared*) e desde então somente as bandas do subsistema VNIR (*Visible and Near Infrared*) estão acessíveis para utilização. A frequência de revisita da plataforma é de 16 dias. O sensor também disponibiliza o par de bandas estereoscópicas, 3N (Nadir) e 3B (Backward) para criar modelos digitais de elevação. O tamanho da cena é de 60 km por 60 km.

Tabela 1. Características físicas e operacionais do sensor ASTER. Fonte: NASA, 2014.

Faixa Espectral	Banda	Intervalo (nm)	Resolução Espacial (m)	Resolução Radiométrica (bits)
Visível e Infravermelho Próximo	1	0,52 - 0,60	15	
	2	0,63 - 0,69		
	3N	0,78 - 0,86		
	3B	0,78 - 0,86		
Infravermelho Médio	4	1600 - 1700	30	8
	5	2145 - 2185		
	6	2185 - 2225		
	7	2235 - 2285		
	8	2295 - 2365		
	9	2360 - 2430		
Infravermelho Termal	10	8125 - 8475	90	12
	11	8475 - 8825		
	12	8925 - 9275		
	13	1025 - 1095		
	14	1095 - 1165		

2.3. Característica do sensor ultraespectral FieldSpec 3

Os sensores remotos são classificados conforme o número de bandas espectrais. Os mais simples são os multiespectrais, com 3 a 15 bandas. Os hiperespectrais têm centenas de bandas, enquanto os ultraespectrais têm milhares de bandas. Dentre os ultraespectrais estão os espectrorradiômetros, sensores remotos (Jensen 2011) que são usados para a coleta de referências espectrais sobre diversos alvos da superfície. No momento da coleta de medidas de refletância, o perfil gerado informa dados sobre a refletividade em milhares de bandas, com resolução espectral de poucos nanômetros.

Neste trabalho, como sensor remoto ultraespectral, foi utilizado o espectrorradiômetro ASD Field Spec3. Este equipamento é usado para coleta de medidas em campo ou laboratório de parâmetros físicos (Absortância, Irradiância, Radiância, Reflectância, Transmitância). O domínio de sensibilidade espectral se estende do visível ao infravermelho médio, de 350nm a 2500nm; são, portanto, cobertas regiões correspondentes ao VNIR – *Visible and Near Infrared* (350nm-1000nm); SWIR – Shortwave Infrared 1 (1000nm-1830nm); e SWIR – Shortwave Infrared 2 (1830nm – 2500nm). A resolução espectral varia conforme a região espectral: 3nm para os comprimentos de onda até 700nm; 10nm para os comprimentos de onda até 1400nm; 10nm para os comprimentos de onda até 2100nm. Os comprimentos de onda disponíveis pelo espectrorradiômetro são amostrados por meio de um método de interpolação, onde os valores

espectrais foram medidos por meio do cálculo do FWHM - *Full Width Half Maximum* (**Figura 1**) de um próximo pico monocromática em um espectro adquirido ao exibir a saída de um monocromador com o espectrômetro. Após o processo de amostragem dos intervalos de comprimentos de onda, as resoluções espectrais para cada região ficam determinadas: 1,4nm para a região espectral de 350-1000nm; e 2nm para a região espectral de 1000-2500nm.

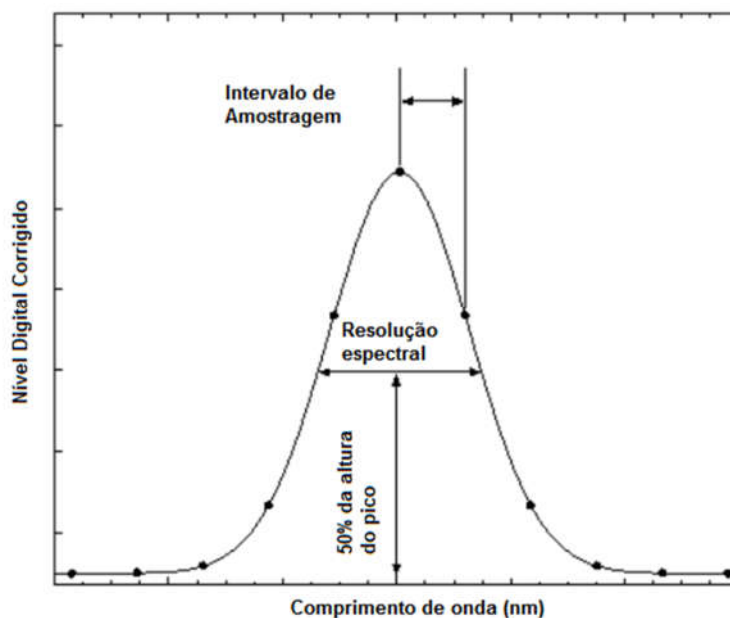


Figura 1. Método para definição da resolução espectral para sensor ASD, usando *Full Width Half Maximum* (FWHM) da resposta do instrumento a uma fonte monocromática. Fonte: (ASD, 2014).

2.4. Comportamento espectral

A caracterização espectral de um objeto localizado na superfície da Terra, de acordo com Ponzoni & Shimabukuro (2010), ocorre mediante a conversão da energia eletromagnética que chega e é registrada no sensor remoto na forma de níveis digitais – ND para variáveis físicas, como a radiância e posteriormente para refletância, medida em valores escalonados entre 0 e 1. Esses são os chamados parâmetros de registro de energia pelo sensor, que ao nível de refletância permitem caracterizar espectralmente os objetos da superfície da Terra. A forma de um espectro é o resultado da interação da radiação eletromagnética emitida pelo Sol e/ou por sensores artificiais ativos (radar), com os alvos da superfície terrestre (água, áreas urbanizadas, solos nus, áreas agrícolas entre outras classes de uso) que aportam uma assinatura espectral. (Novo, 2008; Jensen, 2011; Moreira, 2014).

Dependendo da escala espacial de monitoramento de um vinhedo as características físicas das classes existentes podem se superpor, com reflexos no comportamento espectral. A formação descontínua do dossel de videiras no método de condução em espaldeira leva a um efeito de mistura espectral quando vinhedos deste tipo são registrados em imagens de média resolução espacial, como ocorre com o sensor ASTER, com pixel de 30 metros. Neste caso, um pixel típico deste registra uma mistura espectral com outras classes, compreendendo as folhas da videira (dossel), a vegetação entre fileiras, e o solo exposto. Já ao efetuarmos observações a campo por espectrorradiometria a resposta espectral é mais pura, pois geralmente é possível observar somente uma classe em cada medida. Na classe vegetação, principalmente nas culturas agrícolas, o comportamento espectral das diferentes subclasses é muito similar, e sua diferenciação em mapeamentos por sensores de média resolução espacial e também espectral apresenta dificuldades para identificar as feições intrínsecas dos tipos de vegetação presentes na cobertura do solo, causada por sobreposições e misturas dessas classes vegetais. É o caso, por exemplo, da viticultura, em que os dosséis de videiras frequentemente não cobrem completamente o solo e as parcelas são relativamente pequenas ao serem comparadas com grandes culturas agrícolas como soja ou arroz. As videiras possuem um comportamento espectral muito distinto e variável, extremamente dependente da forma como é cultivada, com o tipo de sistema de condução, orientação e espaçamento entre fileiras, idade da videira ou sistema de poda; estes são fatores relevantes a serem levados em consideração na mistura do pixel, já que podem modificar a forma de como o dossel é apresentado em cada estágio fenológico (Silva & Ducati, 2009; Cemin & Ducati, 2011). As variações encontradas na resposta espectral dos dados, tanto em nível orbital, quanto por espectrorradiometria de campo, são dependentes dos ângulos de iluminação e de visada dos sensores, e das reações físicas da luz ao contato com características fisiológicas e morfológicas das folhas que compõem o dossel vegetativo. (Souza et al., 1996; Ponzoni, 2014). Fatores de deficiência de nutrientes e o estado fitossanitário também modificam as propriedades ópticas da folha. Esses agentes modificadores dos parâmetros de refletância da folha influenciam na resposta espectral em determinados intervalos de comprimento de onda, e podem ser passíveis de serem detectados mediante as alterações que ocorrem no comportamento espectral padrão da vegetação, como demonstrado por Pabhakar et al. (2012) e aqui reproduzido na **Figura 2**.




Figura 2. Comportamento espectral típico da vegetação saudável, com os fatores causadores das feições espectrais (Adaptado: Pabhakar et al., 2012).

Na região do visível os pigmentos são fatores determinantes na absorção/reflexão da energia radiante. Steele et al. (2009) reportaram que o comportamento espectral foliar de parreirais sob diferentes concentrações de antocianinas teriam maiores variações na faixa visível, especificamente nas regiões do verde e do vermelho (**Figura 3**). Renzullo et al. (2006) observaram que determinadas regiões espectrais estão relacionadas às condições fisiológicas de videira, em especial nos intervalos 500-550 nm; 660-690 nm; 700-760 nm; e 900-1450 nm. A região do infravermelho próximo também seria uma região espectral indicativa das modificações estruturais (interna e externa) das células vegetais, sensível ao aumento da densidade foliar de um dossel, e também aos *stresses* relacionados ao excesso de calor e a perda de água (Lacar et al., 2001). A densidade e espessura da folha é um fator a ser considerado nas variações de refletância expressas nas regiões do infravermelho próximo (Slaton et al., 2001).

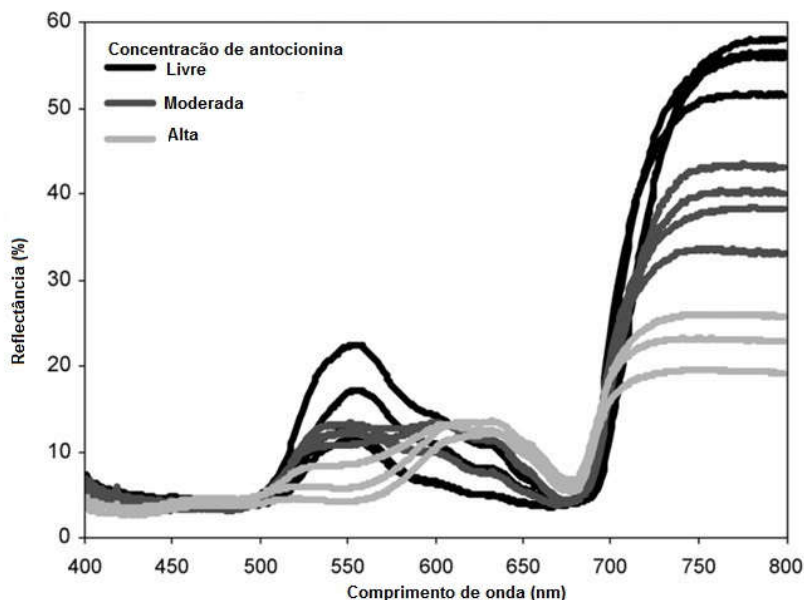


Figura 3. Resposta espectral de folhas com diferentes concentrações de antocianinas (Adaptado: STEELE et al., 2009).

2.5. Classificação dos Dados

A identificação dos dados adquiridos por SR, ou seja, a classificação, é feita através de algoritmos, modelos matemáticos que agrupam os valores dos pixels em classes qualitativas. Dependendo da variável a ser classificada, um determinado classificador é utilizado para tal função. Encontramos na literatura muitos modelos diferenciados pela sua capacidade de discriminação de classes. Geralmente são nomeados pelo método estatístico presente no modelo (paramétricos ou não-paramétricos) ou pelo modo de como é classificada, com ou sem amostras de referência. (Supervisionadas ou não-supervisionadas). Entre vários algoritmos mais usados podemos citar como exemplo o método de Máxima Verossimilhança Gaussiana, que busca maximizar a probabilidade das observações, considerando a normalidade dos dados. Richards (1986) descreve que a classificação é extremamente dependente da quantidade de amostras representativas *a priori*, já que o modelo depende de parâmetros estatísticos (média e matriz de covariância) para discriminação dos grupos e o agrupamento de cada pixel de acordo com a teoria de probabilidade bayesiana. Teoricamente é determinada a distribuição normal dos dados, o que pode não ocorrer na prática em que muitas classes não seguem esse padrão de distribuição, o que prejudica as regras de decisão entre classes, resultando em distorções na classificação final (Mather, 1999).

2.5.1. Análise Discriminante – AD

As técnicas de análise multivariadas são úteis no reconhecimento e na descoberta de novos padrões de dados em grandes volumes de observações, mais conhecidas como ADE – Análise de Dados Exploratória; aqui, as mais variadas classes são descritas ou agrupadas utilizando tais técnicas, e entre as mais citadas na literatura estão os modelos estatísticos, nos quais se incluem a Análise de Componentes Principais – ACP, Análise de Variância, Análise Discriminante – AD, Análise por Cluster e outras.

Entre as técnicas de estatística multivariada mais disseminadas, a AD, que é usada para discriminar amostras ou observações em grupos preditos ou determinados de variáveis dependentes, por meio de variáveis independentes, agrupando cada amostra ao grupo predito (Hair et al., 2005; Mingoti, 2007; Pestana & Gageiro, 2005). Conforme o número de variáveis dependentes (não-métricas) consideradas, as aplicações da AD são classificadas como simples quando entram somente duas variáveis dependentes qualitativas, e múltiplas quando há mais de duas variáveis dependentes.

Alguns autores indicam algumas exigências sobre o comportamento das amostras que entraram na análise, das quais a principal é ter a distribuição de normalidade das variáveis explicativas, sendo ainda necessária a homogeneidade das matrizes. Variáveis com valores discrepantes (*outliers*), entre outros casos, podem ocasionar distorções nos resultados (Hair et al. 2005; Fávero et al. 2009).

Na entrada dos dados na AD é necessário que as observações tenham um comportamento normalizado, isto é, uma distribuição normalizada. Este padrão de distribuição pode ser analisado a partir de histogramas de distribuição de frequência, ou por intermédio de testes de médias, como ANOVA/MANOVA, testes específicos para normalidade. Esses testes procuram analisar se há diferenças significativas entre as médias de duas amostras para uma única variável, determinando se as amostras surgem de populações com médias iguais (Hair et al. 2005). Porém, Sanvicente et al. (1998) demonstraram em seus resultados sobre análise exploratória de dados contábeis que baixos níveis de significâncias não representam necessariamente uma piora no resultado da classificação final.

A AD é aplicada em diversas áreas voltadas para classificação de grandes volumes de dados, em especial em trabalhos onde há grande quantidade de informações de difícil percepção de conjunto e manipulação. Sanvicente et al. (1998) utilizaram a AD para identificação de indicadores contábeis para previsão de concordatas de empresas. Poener et al (2010) utilizaram análise multivariada de dados para diferenciar parâmetros físico-químicos

e elementos minerais de vinhos-base de espumantes provenientes de duas regiões do RS. Já Renzullo et al. (2006) aplicaram AD em observações de reflectância para identificar regiões espectrais que indiquem a separabilidade entre folhas de parreiras sadias e sob *stress*.

2.5.2. Probabilidade *a priori* (Distância de Mahalanobis)

Os métodos de entrada de dados em AD são uma das funções determinantes na inclusão e exclusão das observações na análise, ou seja, quantos descritores participam da seleção. Esse processo pode ser determinado numa forma simultânea, no qual as variáveis seriam independentes e não precisariam ter níveis de significâncias testados. Outra alternativa é determinar os níveis de máximos e mínimos dos conjuntos de observações antes de realizar a análise, passando somente as variáveis significativas; este método é conhecido como *Stepwise*.

O reconhecimento das características gerais *a priori* dos grupos amostrais é necessário e essencial para possuir um tamanho ideal da amostra, já que a técnica tem uma sensibilidade à proporção e à quantidade de observações disponíveis para análise. (Hair et al. 2005). A quantidade mínima de observações deve ser em torno de 20 amostras para cada variável explicativa. As observações muitas vezes podem seguir critérios de seleção para entrada de dados, como sendo variáveis independentes ou métodos de *Stepwise*. A partir da hipótese de que eventuais erros ocorrem nas classificações, uma pré-classificação ou a determinação da probabilidade *a priori* para cada classe pertencer a um determinado grupo, permitiria ao analista escolher por meio de modelos matemáticos a quais populações essa observação pertence, com base nas p-características. Entre os modelos disponíveis para determinação *a priori* dos dados existem os modelos de *lambda* Wilks, variância inexplicada, Distância de Mahalanobis, como exemplos para a remoção ou adição de novas amostras antecedentes à classificação.

A distância de Mahalanobis é um algoritmo que agrupa os dados por meio de um espaço amostral determinado em forma de elipses, onde para as observações mais distantes do centroide do grupo haveria uma menor probabilidade, ou chance, desta observação pertencer a tal classe (Mahalanobis, 1936). A partir da matriz de covariância de cada classe se determinaria a classificação das amostras por grupo. A classe que obtiver a menor distância de Mahalanobis entre as outras pertenceriam à classe mais próxima, usando a teoria Bayesiana da probabilidade de máxima verossimilhança gaussiana.

2.5.3. Funções Discriminantes Canônicas

A discriminação das variáveis qualitativas ocorre através da utilização de regressões múltiplas, no qual a primeira função é responsável pela maior variabilidade e correlação canônica entre amostras de cada grupo, determinados por coeficientes canônicos (Sharma 1996). Esses coeficientes por sua vez, de acordo com Maroco (2007) são utilizados para ponderar as variáveis independentes; quanto maior o valor do coeficiente da variável explicativa, com sinal positivo ou negativo, melhor será o descritor para discriminar os grupos preditos. Os valores dos coeficientes não padronizados das funções discriminantes maximizam a variância entre grupos e aumentam a correlação canônica das amostras dentro do grupo, acrescentando a potencialidade discriminatório das variáveis independentes na classificação. A função regressão geradas pelas correlações canônicas segue a nomenclatura abaixo:

$$Z_n = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad , \quad (1)$$

O valor de escore é denominado Z, correspondente à variável dependente da função discriminante para n observações, α é referente ao valor que intercepta o eixo Y, β é o valor referente aos pesos discriminantes, enquanto X é a variável independente selecionada na análise. O resultado da análise é o escore canônico, ou seja, a regressão múltipla. O número de funções canônicas é diretamente proporcional a quantidade de variáveis dependentes declaradas. A primeira função contém a maior porcentagem de variância explicativa e a maior correlação canônica do agrupamento. Quanto menor o grau de ordem da função, maior a sensibilidade a ruídos da classificação, isto é, menor é a porcentagem da variância explicativa e da correlação canônica (Hair et al., 2005).

O cálculo da média dos grupos é o centroide, o local central em que as variáveis com médias mais próximas a esse centro têm grandes chances de serem classificadas conforme tal grupo. Esta medida também indicaria a distância entre as médias dos grupos em um gráfico de dispersão, podendo ocorrer pequenas sobreposições na distribuição dos escores. As matrizes de correlação, por sua vez, identificam em sua diagonal principal a correlação entre as amostras, e posteriormente determinando uma exatidão global acurada, com possível validação da classificação pelo método de validação cruzada. (Khattree & Naik, 2000; Hair et al., 2005).

Material e Métodos

3.1. Fluxograma geral do trabalho

As atividades desenvolvidas durante o período de realização desta dissertação obedeceram à metodologia descrita no fluxograma apresentado na **Figura 4**, e que será discutida com maior nível de detalhamento no decorrer de cada seção.

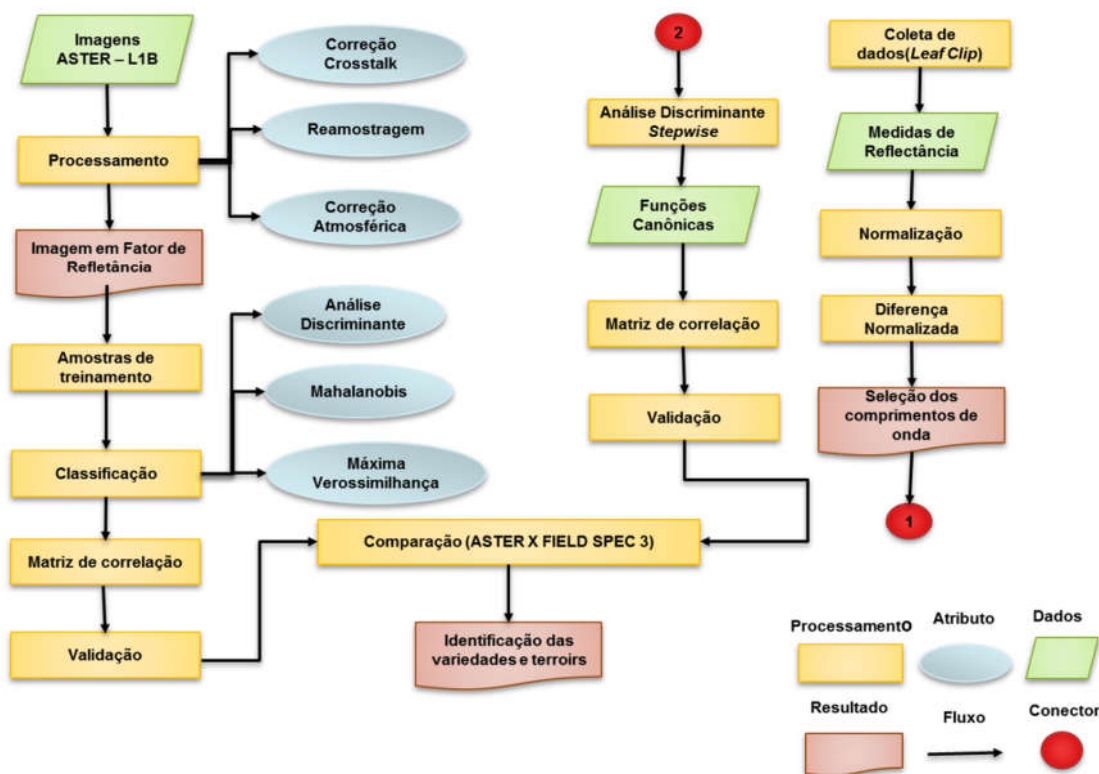


Figura 4. Fluxograma geral das etapas de desenvolvimento das atividades neste trabalho.

3.2. Área de estudo

As propriedades vitivinícolas localizadas no Estado do Rio Grande do Sul selecionadas para as expedições de campo foram as seguintes: Almadén (30°48'28.62"S e 55°22'41.69"O), Miolo Seival (31°23'44.29"S e 53°45'54.44"O), Chandon (30°43'13.06"S e 52°37'54.43"O) e Boscato (29° 1'32.71"S e 51°18'56.64"O). O critério utilizado para a escolha das propriedades foram as condições ambientais (clima e solo) diferenciadas existentes entre as vinícolas, considerando uma escala mais ampla de mapeamento. Esses fatores interferem no desenvolvimento vegetativo da videira, e posteriormente na produção e na qualidade de suas uvas, o que resulta na chamada tipicidade local, ou seja, na caracterização de distintos *terroirs* vitícolas. A disponibilidade de informações cartográficas para identificação das parcelas e a

acessibilidade para as visitas de campo também foram condicionantes para a escolha destas áreas de estudo. O mapa de localização (**Figura 5**) demonstra a área de estudo em seu contexto geográfico.

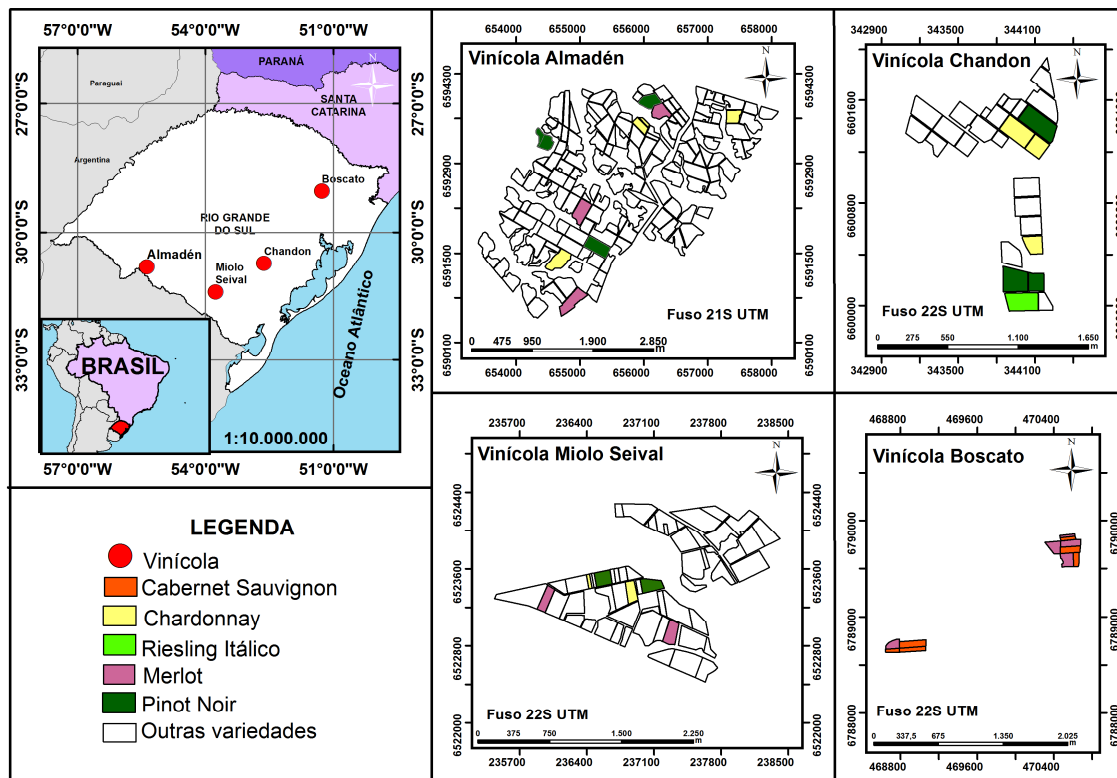


Figura 5. Localização da área de estudo em relação ao seu contexto geográfico.

De modo geral, ao Oeste, na região fisiográfica da Campanha Gaúcha, a topografia possui leves ondulações, mesclando por suas suaves coxilhas e colinas, com altitude variando em torno de 100 a 300 metros. Os solos em modo geral são classificados como classes de Argissolo e Chernossolo (Flores et al, 2007). Mais ao centro do Estado encontra-se a região fisiográfica da Serra do Sudeste, com solos predominantes da classe argissolo distrófico (Flores et al., 2008). A Serra do Sudeste está sobre a região do Escudo Sul-Riograndense e possui formação predominantemente granítica, com altitudes variando entre 200m e 600m. No Planalto Meridional, nordeste do estado, a região fisiográfica da Serra Gaúcha está localizada sobre o Planalto Meridional, que é composto por formação basáltica e apresenta as maiores altitudes, com sua topografia declivosa e com altitudes variando entre 600m e 900m.

Em questões climáticas, de acordo com mapeamento de tipologia climática do RS elaborado por Carneiro et al (2011) há as seguintes características para cada região vitivinícola: Almadén (Santana do Livramento): Encontra-se em um clima subtropical médio, com fortes

variações nas médias anuais de temperatura, com invernos frios e verões quentes; Miolo Seival (Candiota) e Chandon (Encruzilhada do Sul): Clima subtropical com características de pouca umidade, com inverno e verão frescos e com os menores valores de precipitação do Estado; Boscato (Nova Pádua): Localizada em uma região de clima subtropical mais úmido, com maiores quantidades de chuvas registradas, bem distribuídas ao longo do ano.

De acordo com as estações meteorológicas próximas as vinícolas, fornecidas pelo INMET (Instituto Nacional de Meteorologia), visualizados na **tabela 2**, as normais climatológicas indicam a região de Bagé, próxima à vinícola Miolo Seival, com menor nível de pluviometria neste período. A região de Caxias do Sul é a mais chuvosa, com dados da estação próxima à vinícola Boscato.

Tabela 2. Dados referentes às normais climatológicas pluviométricas, em milímetros.

Código	Nome da Estação	UF	Janeiro	Novembro	Dezembro
83980	Bagé	RS	107,5	95,7	99,1
83941	Bento Gonçalves	RS	143,8	116,2	145,7
83942	Caxias do Sul	RS	164,4	122,6	168,1
83964	Encruzilhada do Sul	RS	125,6	101,3	92,9
83927	Uruguaiana	RS	159,7	125,7	139,5

3.3. Medidas espectrorradiométricas de refletância

Para fins de representar estatisticamente cada região e cultivar, foram escolhidas cultivares de uvas presentes em pelo menos duas vinícolas localizadas sobre solos e climas distintos. Anteriormente verificou-se a disponibilidade de informações cadastrais e cartográficas sobre as parcelas de cada vinícola. Algumas informações úteis, como identificação e acesso à parcela, variedade, idade da planta, espaçamento tanto entre fileiras, quanto entre plantas foram averiguadas no processo de seleção das amostras. As variedades selecionadas foram, a saber, Cabernet Sauvignon, Chardonnay, Merlot, Pinot Noir e Riesling Itália. As datas de expedições a campo tiveram como critério o estágio fenológico da videira, no qual é possível identificar visualmente a ocorrência de folhas adultas nas plantas, considerando o ciclo fenológico para videiras no hemisfério sul descrito por Reynier (2002). As parcelas são todas cultivadas no sistema de condução do tipo espaldeira. As visitas de campo foram realizadas em três viagens, entre os meses de novembro de 2014 a janeiro de 2015 como demonstra as informações disponibilizadas na **Tabela 3**.

Tabela 3. Informações referentes aos trabalhos de campo.

Data	Propriedade	Variedade	Parcela	Nº Folhas	Nº medidas	
18/11/2014	Almadén	Chardonnay	CH130	15	45	
			CH15	15	45	
			CH90	14	42	
		Merlot	ME08	16	48	
			ME101	15	45	
			ME42	16	48	
	Mioilo Seival	Chardonnay	CH2C	16	48	
			CH3C	16	48	
		Merlot	ME1B	16	48	
			ME80	16	48	
	Pinot Noir	PN21	16	48		
		PN6B	16	48		
	10/12/2014	Chandon	Chardonnay	CH12	14	42
				CH5AB	16	48
Pinot Noir			PN10	16	48	
			PN4AB	16	48	
Riesling Itálico			RI9B	16	48	
17/01/2015			Boscato	Cabernet Sauvignon	V1BLOCO6F15	16
	V1BLOCO6F7	16			48	
	V1BLOCO71E1	16			48	
	V1BLOCO71E5	16			48	
	V1FILA15F10	16			48	
	V1FILA15F6	16			48	
	V29AÇUDE35	16			48	
	V29AÇUDE38	16			48	
	Merlot	V1A22FILA15			16	48
		V1A22FILA7P		16	48	
		V26AÇUDE		16	48	
		V26AÇUDE30		16	48	
		V22822MAT10		16	48	
		V22822MATO29		16	48	
		V22822MATO36		16	48	
		V22822MATO5		16	48	
		V27A21CF12		16	48	
	V27A21CF18	16		48		
TOTAL				595	1785	

O equipamento utilizado para a tomada das medidas foi o espectrorradiômetro *Field Spec® 3 ASD – Analytical Spectral Devices (Figura 6)*, cedido pelo Programa de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul.



Figura 6. Espectrorradiômetro *Field Spec 3 ASD* e o acessório *Probe Leaf Clip* utilizado neste trabalho.

Trata-se de um equipamento com alta resolução espectral, efetuando medidas de reflectância a intervalos de três a cinco angstroms, no domínio de 350nm a 2500nm, compreendendo, portanto, as faixas espectrais do ultravioleta ao infravermelho (próximo e médio). As medidas foram efetuadas com o acessório *Probe Leaf Clip* acoplado ao corpo principal do equipamento, o que torna o instrumento um sensor ativo, pois no *Leaf Clip* há uma fonte de luz que ilumina o alvo; neste caso, a luz incidente do acessório é refletida pela superfície da folha e é conduzida aos sensores internos por meio de uma fibra óptica. O instrumento é projetado especificamente para simplificar o processo de recolha de espectros na vegetação *in vivo*, com a fixação suave gatilho de bloqueio / liberação para a realização da amostra-alvo no lugar, sem retirar a folha de seu habitat natural, conseqüentemente sem afligir danos.

A aproximação da luz incidente com o alvo constitui grande vantagem na coleta de espectros, diminuindo a influência de outros fatores externos como variações de ângulo de iluminação solar, ângulo de coleta e contaminação pela luz proveniente de outras reflexões, como vegetação próxima, gramíneas, solo exposto, lâminas d'água ou mesmo o próprio brilho do céu ou de nuvens. Tais fatores externos constituem possíveis fontes de erro quando são utilizados acessórios como o *Probe Pistol*. A cada deslocamento realizado entre as plantas, antes de posicionar no *Probe Leaf Clip* as amostras e no início da medição, foi efetuada a

coleta da referência branca (*white reference*) e a otimização (*optimization*) da placa do tipo *Spectralon*, ambas funções encontradas no programa de controle *ViewSpec Pro®*. A otimização é o primeiro procedimento de calibração das medidas, efetuado internamente, e após é feita a medida da referência branca. O material *Spectralon* tem propriedades de reflexão da luz com percentuais constantes, e próximos a 100%, ao longo de toda a faixa de sensibilidade do instrumento; portanto, tendo sido medida a placa branca, medidas posteriores tomadas do alvo podem ser convertidas para reflectância normalizada, através de uma operação efetuada internamente ao instrumento. Estes processos que envolvem a calibração do sensor são necessários para conversão dos valores de níveis digitais para valores físicos, ou seja, para a radiância e posteriormente para reflectância. A medida resultante é um espectro, armazenada digitalmente como uma tabela, e também mostrada em tela, em tempo real, na forma de um espectro gráfico com intervalos de comprimento de onda entre 350nm a 2500nm no eixo x e no eixo y os valores de reflectância, com intervalo entre 0 e 1. A qualidade desta operação de calibração efetuada pelo sensor, sob o comando do operador, pode ser avaliada ao se monitorar as medidas da referência branca, que idealmente devem ser constantes, e próximas ao valor 1, ao longo de todo domínio de sensibilidade. Do ponto de vista prático, foi observada a existência de ruídos na região do ultravioleta, entre 350 nm e 400 nm, e no final do domínio, próximo a 2500 nm. A calibração também é crucial para tornar suave, e idealmente imperceptível, a transição durante o processo de medida entre os sensores internos do sistema: existem, com efeito, três sensores que operam sucessivamente, sendo o primeiro entre o ultravioleta e o infravermelho próximo, o segundo até o infravermelho médio, e o terceiro até 2500 nm.

Como procedimento de coleta de dados, foi adotada a seguinte sistemática: em cada propriedade foram selecionados entre seis e oito parcelas, sendo cada parcela formada por plantas de uma das variedades selecionadas (Cabernet Sauvignon, Merlot, Chardonnay, Pinot Noir, Riesling Itália). Em cada parcela foram efetuadas medidas de reflectância *in vivo*, sendo escolhidas duas fileiras centrais à parcela, fileiras estas afastada uma da outra. Em cada fileira foram selecionadas quatro plantas, e de cada planta, foram efetuadas leituras em quatro folhas adultas e sadias localizadas na parte superior do dossel. Foram coletadas três leituras de reflectância espectral por folha, adquiridas em uma área homogênea, efetuando-se médias aritméticas por amostra. Obteve-se assim o comportamento espectral por parcela, variedade e região. Ao total em todas as saídas de campo foram coletadas três medidas de reflectância de 600 folhas, somando 1800 medidas espectrais. Este procedimento de medidas por amostragem foi projetado para construir um banco de dados representativo, para fins de análise estatística multivariada e para evitar possíveis deteriorações da estrutura da folha medida, diminuindo o tempo de coleta. Algumas medidas não foram utilizadas na análise de

dados por terem ocorrido problemas de calibração do sensor no momento da tomada, valores anômalos de reflectância e comportamento espectral incomum às características típicas da vegetação em geral, sendo desconsideradas 30 amostras de folhas, aproveitando-se um total de 570 folhas para análise dos dados.

As medidas de reflectância coletadas a campo foram gravadas no formato *ASD - Analytical Spectral Devices*®, que é o formato original dos dados gravado internamente pelo programa de controle do espectrorradiômetro. Posteriormente foi realizada a conversão desses dados para o formato *text file* (.txt), utilizando o programa *ViewSpecPro*®. A conversão desses arquivos foi necessária para tratamento e operações realizadas em outros programas de tabulação e geração de gráficos para as medidas espectrorradiométricas. Esses valores de reflectância foram analisados e editados no programa Excel®.

3.3.1. Normalização dos espectros

O domínio espectral do radiômetro estende-se de 350nm a 2500nm, e dentro desta faixa de comprimentos de onda são tomadas quase duas mil medidas, o que caracteriza o modo de operação como hiperespectral. No caso dos espectros coletados neste trabalho, foi feito um procedimento de normalização, semelhante ao preconizado por Zhang *et al.* (2014), e que é descrito a seguir.

Foram tomadas várias séries de medidas de/em folhas de parreiras, utilizando-se o acessório *leaf clip*. Cada série (de três medidas sucessivas) é diferente de outra série porque a medida é feita sobre outro local da folha ou sobre outra folha. Embora sejam folhas da mesma planta, por exemplo, as superfícies medidas podem apresentar diferenças de brilho (uma parte da folha mais lustrosa), rugosidade, etc, e os espectros serão diferentes. No entanto, tais diferenças provavelmente serão no brilho, ou seja, na reflectância média, e não tanto na forma do espectro. Ou seja, as feições espectrais terão a mesma disposição, mas a intensidade de um dos espectros será maior. Em outras palavras, um espectro terá maior área que o outro (a área é a integral do espaço que está entre a curva que define o espectro e o eixo x), mas as feições espectrais serão as mesmas, tanto em suas posições, quanto em suas intensidades relativas. Portanto, dois espectros do mesmo alvo em geral diferem pelo brilho. Se forem dois espectros de alvos diferentes (duas espécies vegetais), além da diferença de brilho haverá diferenças devidas às diferentes feições espectrais. Para começar, portanto, as áreas dos espectros serão diferentes.

Tem então dois espectros com diferentes áreas. Como compará-los, para ter certeza que a diferença é apenas no brilho (na área)? Será que não são intrinsecamente diferentes? Um exame visual pode ser difícil, se as diferenças de feições forem sutis. Devido a todos estes

fatores, foi feito um procedimento de normalização de espectros, dentro da percepção que uma comparação pode ser feita mais adequadamente se normalizarmos os espectros, ou seja, se transformarmos os valores de reflectância de modo que ambos os espectros tenham a mesma área, de valor unitário.

Considerou-se a área de um espectro como a somatória das reflectâncias em cada comprimento de onda, sobre todos os comprimentos de onda. Se chamarmos A a área; $R\lambda$ a reflectância no comprimento de onda λ ; e se n é o número de medidas que reflectância que formam o espectro, então

$$A = \sum_{\lambda=1}^n R\lambda \quad (2)$$

A normalização se faz dividindo cada $R\lambda$ por A . Após esta divisão, se calcularmos a nova área temos:

$$A' = \sum_{\lambda=1}^n R\lambda/A = 1 \quad (3)$$

Fazendo este procedimento para cada espectro temos um novo conjunto de espectros, onde todos os espectros têm área unitária. Espectros normalizados propiciam um exame mais preciso para detectar diferenças entre eles, por exemplo, superpondo-se vários espectros. Outra utilidade será vista mais adiante.

3.4. Comparação de espectros e redução de dimensionalidade

Temos em nosso trabalho medidas de folhas de videiras de diversas castas (cultivares) diferentes. A observação mostra que um mero exame visual dos espectros não é muito eficaz para que se enxerguem as diferenças. Mas estas diferenças existem, e técnicas mais sofisticadas podem colocá-las em evidência; por exemplo, análises estatísticas.

A aplicação de métodos estatísticos começa pela preparação do banco de dados. No caso de espectros, cada espectro tem milhares de pontos. Muitos destes pontos portam informação redundante com pontos vizinhos. A dimensão do espectro é enorme (milhares de pontos) e o processamento de uma análise pode ser longo e pode produzir resultados confusos. O que fazer? Reduzir a dimensionalidade da amostra, através da detecção de diferenças espectrais, como explicado a seguir.

Tomou-se dois espectros normalizados de duas variedades, como Pinot Noir e Chardonnay; ou de Merlot sadio e Merlot doente. Subtraímos um espectro do outro, ponto a

ponto. Se fossem dois espectros iguais, a diferença seria zero ao longo de todo o domínio espectral. Na verdade, mesmo sendo dois espectros da mesma amostra, tomados sucessivamente, a subtração pode não ser zero, devido ao ruído que incide diferentemente para cada medida. No caso de medidas de amostras de variedades diferentes, a diferença entre os espectros é sutil e em princípio não é percebida visualmente. Um exame mais detalhado é necessário, e neste caso a subtração de espectros normalizados é útil. O resultado da subtração é um espectro-diferença no qual os valores de reflectância (a dimensão do eixo y continua sendo reflectância) são muito pequenos, da ordem de 10^{-4} . A pergunta é: estas feições no espectro-diferença são significativas ou são mera expressão do ruído das duas medidas? Aqui levamos em conta o fato de que a relação sinal/ruído é muito alta, ou seja, as medidas são pouco ruidosas. Portanto, até pode ser que o espectro-diferença porte informação. Há uma maneira de testar isto: já que para cada amostra fizemos mais de uma medida, podemos gerar vários espectros-diferença independentes um do outro, a partir de sub-amostras: Pinot1-Chardonnay1, Pinot2-Chardonnay2, e diferenças semelhantes. Se sistematicamente os espectros-diferença mostrarem feições nos mesmos lugares, é muito provável que estas feições espectrais sejam reais e consistentes, e que expressem diferenças espectrais reais entre as cultivares.

A chave para a redução de dimensionalidade é a identificação dos comprimentos de onda das feições que diferenciam espectros de duas variedades, extraídos do espectro-diferença de espectros normalizados. Pode-se selecionar um conjunto de comprimentos de onda, por exemplo, entre dez e vinte.

Esta é a principal utilidade e aplicação do procedimento de normalizar espectros: poder comparar espectros diferentes. Note-se que a normalização não altera a feição de um espectro, apenas altera a escala vertical.

A partir disto podemos selecionar em todas as medidas somente os valores de reflectância correspondentes aos comprimentos de onda selecionados, e assim formamos o banco de dados para as análises estatísticas que desejarmos fazer, como análise discriminante ou de componentes principais.

3.3.2. Análise Discriminante dos dados espectrorradiométricos

Após o processo de seleção dos comprimentos de onda de interesse, foi possível a preparação dos dados para análise estatística. O banco de dados foi organizado da seguinte maneira: cada linha corresponde a uma observação, havendo especificação de número de folha, cultivar e região (variáveis dependentes); seguem-se os valores de reflectância para cada comprimento de onda (variáveis independentes). As classes foram especificadas

levando em consideração três aspectos: a) as variedades que ocorriam em regiões diferentes; b) a região; c) Coloração (uva branca ou tinta). Estes dados foram analisados no programa estatístico SPSS. As variáveis foram classificadas *a priori* no módulo por *Stepwise* pelo método da Distância de Mahalanobis

3.4. Processamento das Imagens ASTER

As imagens ASTER foram coletadas no serviço *online* Reverb/ECHO (NASA, 2014), no nível L1B, no qual as imagens já são processadas, ou seja, as correções geométricas e radiométricas foram realizadas. Para a escolha das imagens considerou-se a ausência de cobertura de nuvens, e a compatibilidade com os mapas georreferenciados fornecidos pela EMBRAPA. Somente as parcelas das vinícolas Almadén (Santana do Livramento) e Miolo Seival (Candiota) foram utilizadas. De acordo com os critérios mencionados anteriormente, as imagens selecionadas foram: para Almadén a data de 01/12/2004 e para Seival, a data de 01/01/2007. Essas datas escolhidas são compatíveis com o período de maior vigor vegetativo da videira no hemisfério sul. As imagens ASTER L1B apesar de ter um certo nível de processamento, mas alguns tratamentos tornaram-se necessária. Os produtos L1B apresentam as correção geométrica e radiométrica aplicadas e armazenadas em metadados (.met), arquivo acoplado aos formato HDF(*Hierarchical Data Format*), projetadas em UTM (*Universal Transversal Mercator*), com sistema de referência SIRGAS2000. As imagens foram submetidas às correções do efeito *CrossTalk* no programa *Crosstalk Correction*, corrigindo o defeito provocado pelo vazamento da luz do detector da banda 4 para os detectores mais próximos, que medem as bandas 5 e 9, superestimando a reflectância nesses dois últimos canais (ERSDAC, 2013; Vivaldi *et al.* 2013).

Posteriormente foi realizada as correções referentes às influências da atmosfera, e as imagens foram submetidas a reamostragem, compatibilizando as resoluções espaciais dos subsistemas VNIR (15m) e do SWIR 1 e 2 (30m), processo possível pela transformação das imagens pelo algoritmo do vizinho mais próximo. O algoritmo vizinho mais próximo conserva os parâmetros físicos, neste caso os valores dos pixels. Ao inserir as imagens na interface do programa ocorre automaticamente a conversão dos valores dos pixels de nível digital para radiância. A transformação das imagens no formato BIL (*Band interleaved by line*) para a criação de um parâmetro de fator de escala compatível com o módulo FLAASH (*Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes*), se fez necessária. O módulo FLAASH apresenta o algoritmo MODTRAN 4 (*Moderate Atmospheric Radiance and Transmittance*) que corrige os efeitos de espalhamento e absorção pelos gases atmosféricos (vapor d'água, oxigênio, dióxido de carbono, metano, ozônio e partículas presentes na atmosfera) (Anderson

et al. 1999; ENVI, 2010). A entrada de parâmetros específicos se faz necessária para correção. Os parâmetros de entrada em ambos os tratamentos foram: altitude do sensor em torno de 705 km; tamanho do pixel, 15 m; modelo atmosférico *Mid-Latitude Summer*; modelo de aerossol Rural. As características específicas para cada correção atmosférica estão descritas na **Tabela 4**, a seguir:

Tabela 4. Parâmetros físicos utilizados para cada imagem na correção atmosférica.

Vinícola	Pixel Central		Elevação terreno (km)	Vôo	
	Latitude	Longitude		Data	Tempo
Almadén	-30° 52' 41,04' S	-55°21'54,71" O	0,159	01/12/2004	13:47:26
Seival	-31°24' 9,64' S	-54°0'20,17" O	0,25	01/01/2000	13:42:28

3.4.1 Classificação das Imagens

Após as devidas correções realizadas, as imagens foram submetidas ao processo de classificação. Foram utilizados os algoritmos de classificação Máxima Verossimilhança, Mahalanobis e Análise Discriminante, para fins de comparação e discriminação dos dados. Antes de efetuar o processo classificatório, primeiramente se considerou duas classes: variedade e região. Os mapas georreferenciados fornecidos pela EMBRAPA, com a localização das cultivares, possibilitou a delimitação das regiões de interesse e a coleta das informações de refletância nas faixas espectrais das bandas do subsistema VNIR e SWIR do sensor ASTER. Ao total 28 parcelas foram selecionadas, com cultivares de *Vitis vinifera* Cabernet Sauvignon, Merlot, Chardonnay, Pinot Noir, e Riesling Itália de cada região (Almadén e Seival). Foram feitas quatro repetições por variedade. As classes de estudo compreenderam as parcelas de variedades de uvas, excluindo outras classes do uso da terra. A gravação das áreas das amostras, denominadas regiões de interesse, gerou amostras de treinamento dos classificadores, nos módulos disponíveis no programa ENV@ 4.3, gerando as Matrizes de Confusão e Índice Kappa. As médias de refletância das bandas 1, 2, 3N, 4, 5, 6, 7, 8 e 9 foram extraídas dos pixels centrais de cada amostra de treinamento e exportadas para o SPSS®, e posteriormente classificadas usando o módulo de Análise Discriminante, gerando as funções canônicas, a matriz de correlação e validação cruzada. O índice de separabilidade Kappa para as amostras classificadas por AD foi calculado no ambiente Excel. Os valores de reflectância foliar foram avaliados frente aos classificadores e aos dados das imagens. As funções canônicas criadas com os dados espectrorradiométricos foram inseridas nas imagens do programa ENVI@ 4.7, gerando-se as classificações em cada imagem a partir de cada função de acordo com as classes especificadas. As rotinas descritas são esquematizadas na **Figura 7**.

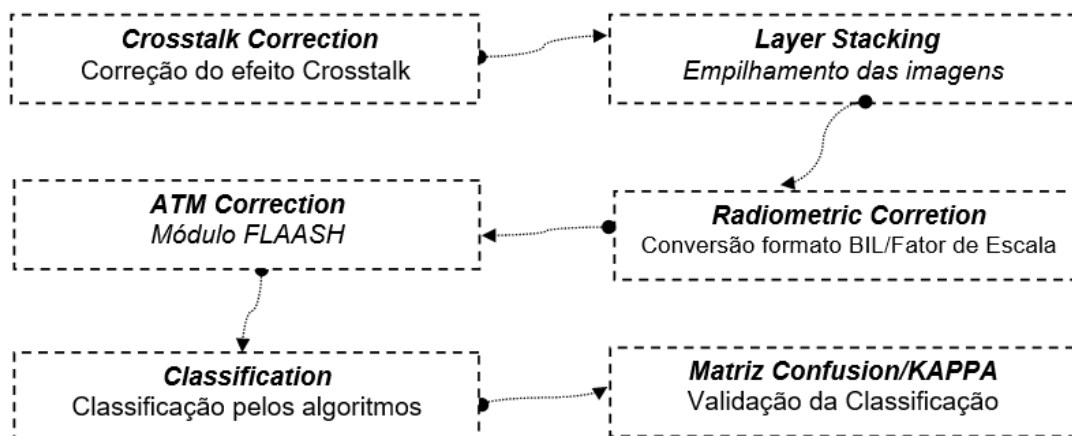


Figura 7. Fluxograma para realização das etapas de processamento das imagens.

Resultados e Discussão

4.1. Comportamento espectral das variedades de uva em diferentes regiões.

A **Figura 8** apresenta as medidas de reflectância coletadas a campo, ilustrando o comportamento espectral de cada variedade, a partir dos dados de reflectância foliar referentes às vinícolas Almadén, Boscato, Chandon e Miolo Seival, para as variedades Cabernet Sauvignon – CS, Chardonnay – CH, Merlot – ME, Pinot Noir – PN e Riesling Itálico – RI. A vinícola Boscato é representada em duas parcelas (V1 – Vinhedo 1 e V2 – Vinhedo 2) que estão localizadas sobre duas litologias distintas. Todos os espectros apresentados possuem características típicas do comportamento espectral de vegetação sadia. Observaram-se as feições típicas da vegetação, como a alta reflectância no infravermelho próximo, que está relacionada à estrutura celular e à geometria da folha, e também um pico de reflectância nos comprimentos de onda referentes à cor verde, região do visível relacionada à concentração de pigmentos fotossintetizantes, em especial a clorofila. Visualmente foram percebidas variações sutis entre os comportamentos espectrais, quando se consideraram as mesmas variedades em diferentes regiões. Muitos comprimentos de onda seguiram o mesmo padrão de resposta espectral, ou seja, valores de reflectância foram similares. Posteriormente realizou-se a redução das informações espectrais para fins de quantificar as diferenças entre cada observação.

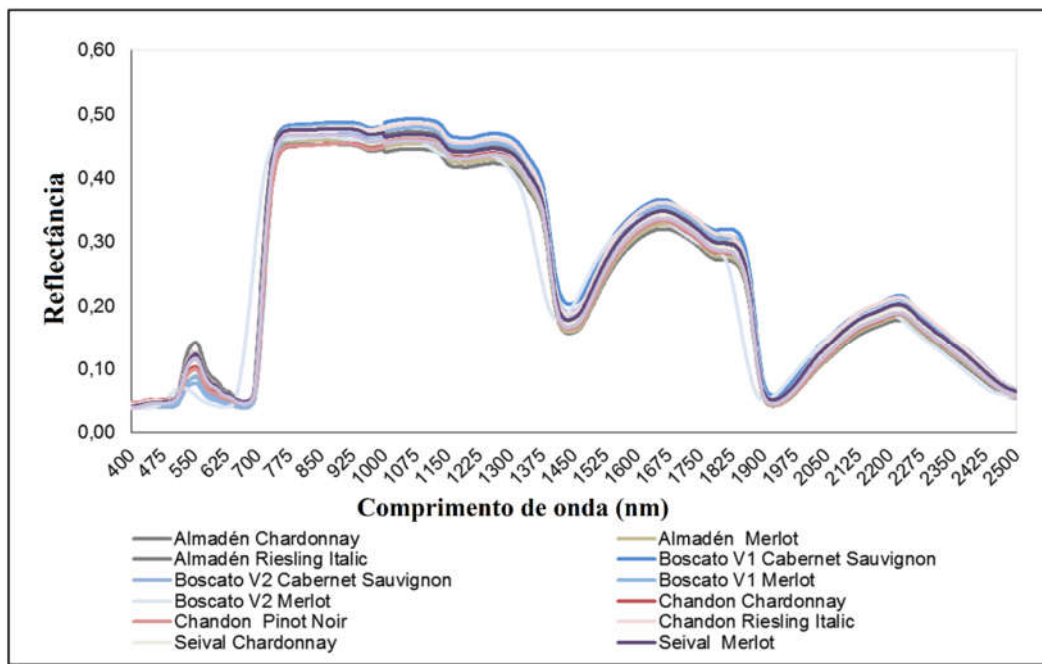


Figura 8. Espectro de reflectância foliar típico para cada variedade, localizada nas quatro vinícolas.

4.2. Redução da dimensionalidade dos dados

Primeiramente se efetuou a eliminação dos comprimentos de onda da região espectral do ultravioleta (350 nm – 400nm). Esse intervalo continha muitos ruídos, valores discrepantes de reflectância. Quando se aumentou o número de amostras, tornou a classificação suscetível aos outliers, ou seja, aos valores discrepantes. Pense no nosso caso, maior o número de amostras, maior é a variabilidade dos dados, possíveis valores ruidosos irão aparecer. A cada aumento de classes ou variáveis (dependentes ou independentes) causam maiores amplitudes dentro de cada classe dos dados. A classificação fica vulnerável a possíveis erros na classificação (mistura ou sobreposição). Resumindo é os outliers. Colocando-se o 350 nm na classificação, ocorreu um decréscimo no resultado final.

A **Figura 9** apresenta exemplos de espectros normalizados, neste caso para cada variedade em suas respectivas vinícolas. A normalização demonstrou ser em alguns comprimentos de onda uma aproximação dos valores de reflectância, e em outros casos um certo distanciamento, ao equipará-los com os perfis espectrais não normalizados. Essas inversões ocorreram pelo fato de que as integrais de cada perfil foram igualadas, onde os somatórios das reflectâncias tornaram-se iguais a 1.

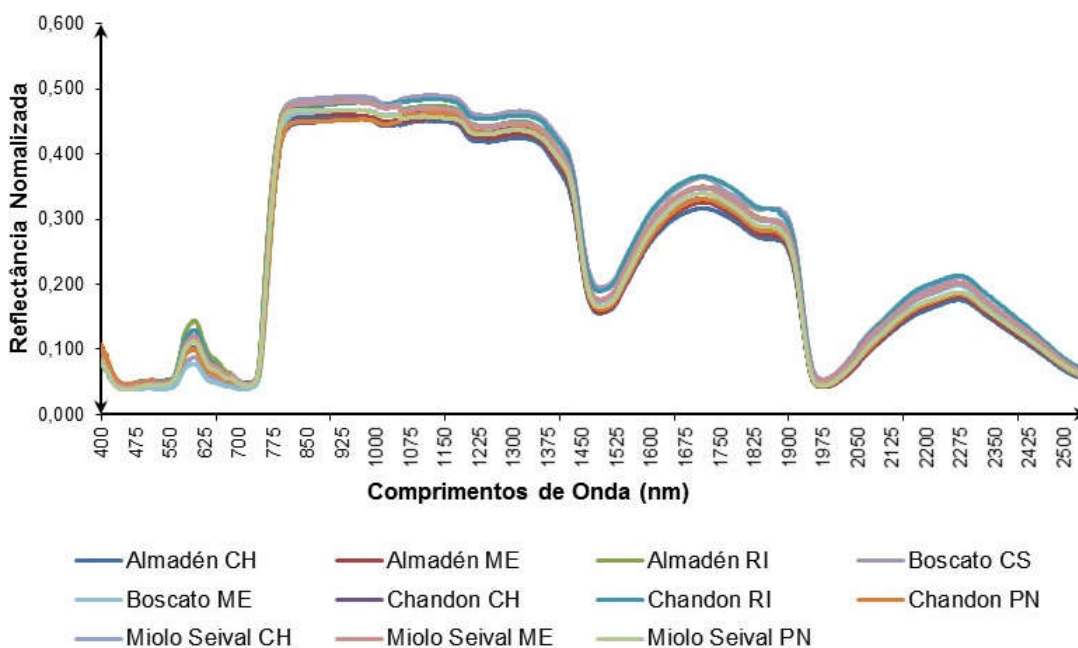


Figura 9. Espectros de reflectância normalizados nas vinícolas estudadas.

Equiparados os perfis, e amenizadas as diferenças de intensidades, efetuou-se o processo de diferença entre os conjuntos de dados espectrais de cada observação. Ao realizar-se a combinação de parcelas de cada vinícola, foram gerados 43 perfis de espectros/diferença, como é demonstrado graficamente na **Figura 10**. As interações

apresentam em todo o espectro diferenças picos e vales. Esses picos indicam uma alta diferença de refletividade entre as observações em um determinado comprimento de onda. Já os vales indicam uma alta similaridade entre os valores de reflectância, com valores de diferença próximos à zero. Não se considerou o nível de significância entre os valores de reflectância, no momento da seleção empírica dos picos dos espectros/diferença. No entanto, ao inseri-los na AD, o procedimento estatístico multivariado efetuou a seleção dos comprimentos de ondas por métodos dos pesos e funções discriminantes canônicas. Na **Tabela 5** informam-se os 83 comprimentos de onda selecionados a partir dos espectros/diferença de reflectância a partir dos λ s correspondentes aos picos de maior amplitude, evidenciados no momento da realização do processo de diferença normalizada. A seleção foi feita visualmente por observação das feições, como picos e depressões. Estes comprimentos de onda foram posteriormente tratados como variáveis independentes na análise estatística.

Tabela 5. Informações referentes aos comprimentos de onda selecionados a partir dos gráficos de diferença normalizada.

Comprimento de onda (nm)									
400	435	437	448	465	482	531	537	541	553
555	558	562	564	565	640	707	710	712	715
719	721	727	728	745	831	834	835	931	1055
1060	1077	1078	1083	1094	1095	1143	1262	1273	1279
1312	1318	1324	1350	1405	1408	1410	1411	1415	1459
1607	1609	1671	1714	1719	1722	1726	1735	1820	1833
1874	1880	1884	1886	1888	1889	1893	2000	2006	2011
2140	2143	2159	2170	2181	2245	2299	2309	2314	2322
2350	2400	2430							

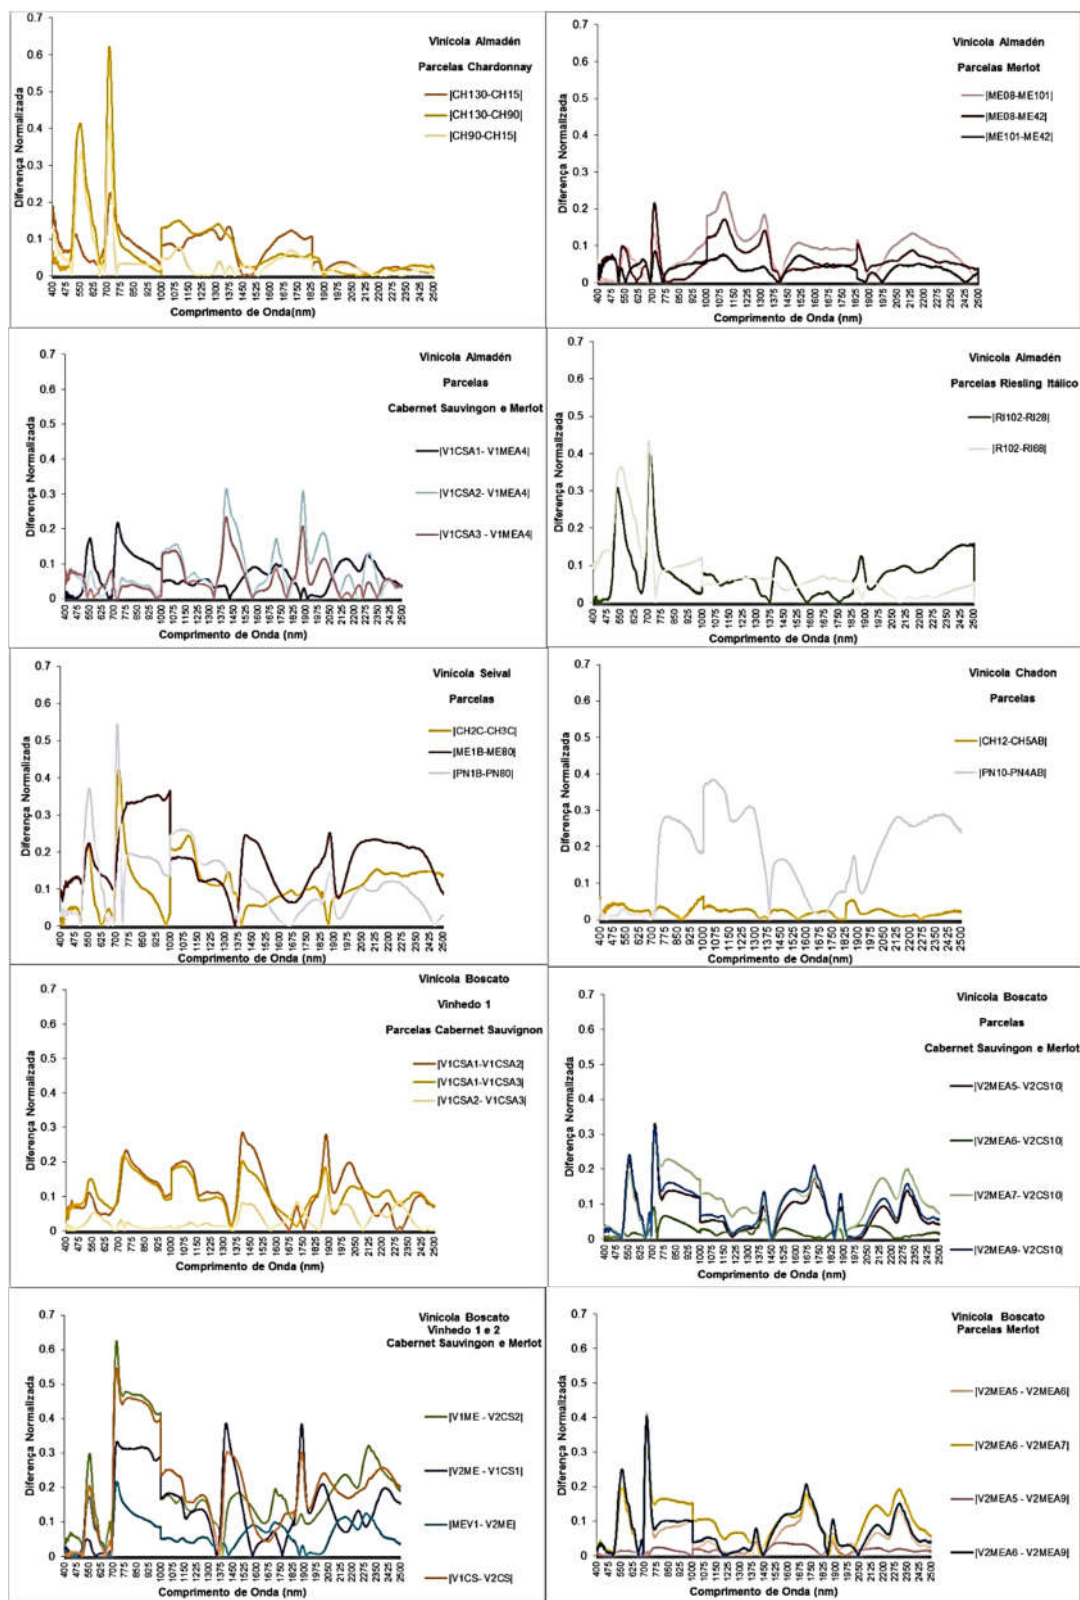


Figura 10. Gráficos referentes às diferenças normalizadas efetuadas a partir dos espectros de reflectância.

4.3. Análise Discriminante dos dados espectrorradiométricos

A **Tabela 6** mostra os coeficientes canônicos responsáveis pela ponderação das variáveis independentes na classificação dos grupos preditos, usando a Análise Discriminante por *Stepwise*. Testaram-se outros métodos de entrada de dados por *Stepwise* e por variáveis independentes. A Distância de *Mahalanobis*, com $P < 0,01$, foi o método que incluiu o maior número de variáveis independentes na classificação e conseqüentemente aumentou a acurácia da classificação final.

Tabela 6. Funções discriminantes canônicas para as classes de estudo.

Classe	Primeira Função Canônica
Cabernet Sauvignon	$Z = 1,398 + 253,70*640 - 71,83*719 + 51,43*2350$
Chardonnay	$Z = -10,36 + 143,25*400 - 192,82*707 - 228,0*721 + 139,34*1833 - 194,54*2011$
Coloração	$Z = 0,85 - 353,21*400 + 1659,31*448 - 1248,78*465 + 98,71*531 - 146,36*640 + 101,89*721 - 37,68*728 + 56,58*1312 + 252,9* 2122 - 346,76*2170 + 64,15*2309$
Merlot	$Z = 2,51 - 810,97*448 - 784,44*465 + 1922,79*482 + 47,66*531 + 185,49*558 - 478,95*640 - 45,47*728 + 52,74*931 - 189,07*1055 + 147,20*1095 + 466,62*1874 - 439,64*1880 + 8,0*2011 + 311,93*2122 - 649,84*2181 + 363,927*2322 - 103,212*2430$
Pinot Noir	$Z = -5,6 + 377,61*400 - 206,35*640$
Riesling Itálico	$Z = -14,5 + 21*400 + 435*3584,129 - 5530,31*437 + 2522,8*448 - 697,93*482 + 76*531 - 50*537 - 29,17*707 - 330*1143 + 75,79*1607$
Variedades	$Z = 0,865 - 119,82*400 - 377,64*436 + -349,9*437 - 1144,0*448 - 30,591*482 + -181,43*531 + 242,45*537 - 462,70,6*640 + 252,78*707 - 281,3*727 + 175,45*831 - 68,803*931 - 262,46*1055 + 267,58*1094 - 131,8*1607 + 176,9*1714 + 119,92*1833 - 281,54*1874 + 160,88*1886 - 60,92*2050 + 625,51*2122 - 598,63*2181 + 49,72*2309 - 17,84*2400$
Região	$Z = 3,71 - 59,8*400 - 70,37*436 + 36,8 *437 - 275,22*448 - 341,9*465 + 1017,13*482 - 292,49*531 + 469,39*541 - 470,32*640 - 16,23*712 - 92,44*745 + 150,3*831 - 49,24*931 - 193,13*1095 + 211,92*1279 + 117,81*1609 - 240,94*1820 + 95,23*1833 - 150,30*1874 + 206,82 *1886 - 121,4*2012 + 184,58*2122 - 311,15*2245 + 137,73*2299 + 51,89*2400$

A primeira função discriminante canônica é a que explica a maior correlação entre as observações do grupo, ou seja, a função que indica a maior variabilidade das funções. O escore Z prediz os valores, com base na ponderação das variáveis independentes. O maior coeficiente da função, desconsiderando os valores negativos ou positivos, indica a variável com maior peso na classificação dos dados. As primeiras funções canônicas de cada classe mostraram qual região espectral foi determinante na classificação. Os comprimentos de onda

para as variáveis PN e RI foram 400nm e 437nm, região espectral do visível, mais especificamente do azul. Já para os grupos de Coloração e Variedades, o maior peso foi da variável 448nm, região espectral do verde. Para as classes ME e Região, o maior peso obtido foi para 482nm. Os grupos CH e CS, região do vermelho e infravermelho próximo, tiveram valores respectivos de 721nm e 640nm. Percebe-se que com o aumento da variabilidade dentro do grupo, ocorreu a maior quantidade de variáveis independentes na primeira função canônica. Note-se que no período do verão Pirie & Mullins (1976) citam uma alta concentração de antocianinas presentes nas folhas das videiras, e as variações espectrais na região do verde e do vermelho, que podem estar relacionadas às diferenças nas concentrações de antocianinas nas folhas das videiras (Steele et al., 2009). Já Lincoln & Ziegler (2012) afirmam que as variações nessas regiões espectrais em folhas vegetais, incluindo a do azul, estão relacionadas aos pigmentos fotossintetizantes (Clorofila a e b), caroteno e betacaroteno.

4.3.1. Classificação quanto à coloração

A primeira matriz de correlação (**Tabela 7**) foi feita com as variáveis dependentes relacionadas ao tipo de coloração da uva, branca ou tinta. Os resultados obtidos tiveram valores de acurácia global de 90,9% e validação cruzada de 90,5%, indicando uma plena separação entre as variedades uvas e brancas pelos seus espectros foliares. Conforme Silva e Ducati (2009) as antocianinas podem ser um fator decisivo na separação de uvas tintas e brancas, detectáveis nos valores de reflectância, quando classificadas pelo sensor ASTER. A causa seria a alteração na estrutura celular das folhas das variedades tintas, devido à presença de vacúolos no interior das células. Ademais, a idade das folhas poderia ser levada em consideração, já que as uvas brancas em geral são mais precoces que as tintas e para o início do período fenológico terão folhas mais maduras.

Tabela 7. Matriz de correlação resultante dos valores de reflectância foliar, quanto ao tipo de coloração da uva.

		Associação ao grupo predito			
		Classe	Branca	Tinta	Total
Original	Contagem	Branca	213	20	233
		Tinta	32	305	337
	%	Branca	91,4	8,6	100,0
		Tinta	9,5	90,5	100,0
Validação cruzada	Contagem	Branca	213	20	233
		Tinta	34	303	337
	%	Branca	91,4	8,6	100,0
		Tinta	10,1	89,9	100,0

4.3.2. Classificação quanto à variedade em diferentes regiões.

Considerou-se na análise as mesmas variedades sobre diferentes regiões. **Na Tabela 8**, mostra-se que a variedade Cabernet Sauvignon em duas áreas foi bem separada, valores de acurácia global de 89%, indicando que os aspectos foliares da videira estão sendo expressos nas medidas de reflectância foliar. Pode-se dizer que as diferenças litológicas (Fáceis Gramado e Fáceis Caxias) estão influenciando no crescimento da planta e conseqüentemente na formação das folhas destes vinhedos. As regiões espectrais do vermelho e infravermelho médio são relevantes, como foi mostrado anteriormente na função canônica para as classes CS.

Tabela 8. Matriz de correlação resultante dos valores de reflectância foliar, para variedade Cabernet Sauvignon, nos vinhedos 1 e 2 da vinícola Boscato.

		Associação ao grupo predito			
		Classe	Cabernet Sauvignon V1	Cabernet Sauvignon V2	Total
Original	Contagem	Cabernet Sauvignon V1	76,0	4,0	80,0
		Cabernet Sauvignon V 2	5,0	27,0	32,0
	%	Cabernet Sauvignon V1	95,0	5,0	100,0
		Cabernet Sauvignon V 2	15,6	84,4	100,0
Validação cruzada	Contagem	Cabernet Sauvignon V1	75,0	5,0	80,0
		Cabernet Sauvignon V 2	6,0	26,0	32,0
	%	Cabernet Sauvignon V1	93,8	6,3	100,0
		Cabernet Sauvignon V 2	18,8	81,3	100,0

Na **Tabela 9, 10 e 11** visualizam-se resultados com alta separação entre as classes PN, RI, CH, com suas respectivas acurácias globais de 100%, 96,1% e 92,6%. Poucas misturas ocorreram entre as classes. A maior mistura ocorreu em CH, que tem observações em três vinícolas, enquanto PN e RI possuem amostras em duas vinícolas. Quanto maior o número de variáveis dependentes na análise, maior foi o acréscimo na mistura das classes. Resumindo, ao aumentar-se a variabilidade dos dados, a ocorrência de misturas foi mais evidente na classificação. Os centroides das classes para variedade CH, visualizado no gráfico de dispersão (**Figura 11**), demonstrou um certo distanciamento, porém a dispersão no grupo referente a vinícola Almadén foi maior. Essa vinícola possui a maior área de plantio e suas parcelas estão mais distantes uma das outras, ao compararmos com a espacialização das parcelas das outras vinícolas. A grande variação da topografia dentro da própria vinícola pode ser um parâmetro de interferência na resposta espectral da vinha.

Tabela 9. Matriz de correlação resultante dos valores de reflectância foliar, para a variedade Pinot Noir localizadas nas vinícolas, Chandon e Miolo Seival.

		Associação ao grupo predito			
		Classe	Seival	Chandon	Total
Original	Contagem	Seival	33	0	33
		Chandon	0	32	32
	%	Seival	100,0	0,0	100,0
		Chandon	0,0	100,0	100,0
Validação Cruzada	Contagem	Seival	33	0	33
		Chandon	1	31	32
	%	Seival	100,0	0,0	100,0
		Chandon	3,1	96,9	100,0

Tabela 10. Matriz de correlação resultante dos valores de reflectância foliar para a variedade Riesling Itália, localizadas nas vinícolas Almadén e Chandon.

		Associação ao grupo predito			
		Classes	Almadén	Chandon	Total
Original	Contagem	Almadén	44	0	44
		Chandon	1	15	16
	%	Almadén	100,0	0,0	100,0
		Chandon	6,3	93,8	100,0
Validação cruzada	Contagem	Almadén	44	0	44
		Chandon	3	13	16
	%	Almadén	100,0	0,0	100,0
		Chandon	18,8	81,3	100,0

Tabela 11. Matriz de correlação resultante dos valores de reflectância foliar, para a variedade Chardonnay, localizada nas vinícolas Almadén, Chandon, Miolo Seival.

		Associação ao grupo predito				
		Classe	Seival	Almadén	Chandon	Total
Original	Contagem	Seival	30	3	0	33
		Almadén	3	39	2	44
		Chandon	0	1	30	31
	%	Seival	90,9	9,1	0,0	100,0
		Almadén	6,8	88,6	4,5	100,0
		Chandon	0,0	3,2	96,8	100,0
Validação Cruzada	Contagem	Seival	30	3	0	33
		Almadén	3	37	4	44
		Chandon	0	1	30	31
	%	Seival	90,9	9,1	0,0	100,0
		Almadén	6,8	84,1	9,1	100,0
		Chandon	0,0	3,2	96,8	100,0

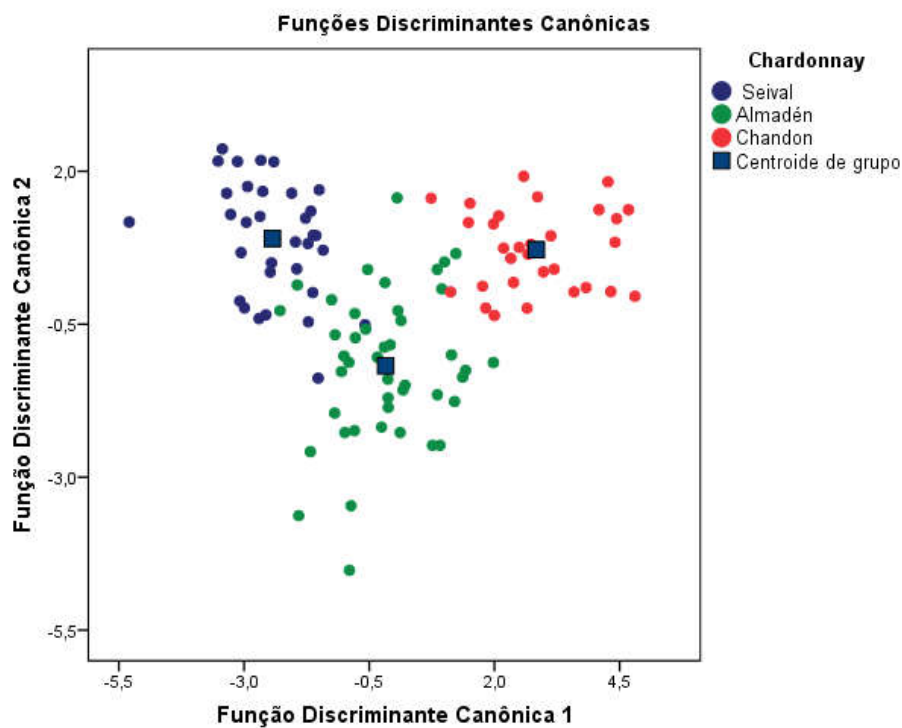


Figura 11. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para a classe Chardonnay.

Para a variedade ME existe observações nas quatro vinícolas, incluindo as parcelas da vinícola Boscato (V1 e V2) que estão localizadas próximas uma da outra. Na **Tabela 12** pode-se verificar entre as regiões a plena separação entre os espectros de reflectância, acurados à 100%.

Nesse caso o aumento da variabilidade de classes, não deteriorou a classificação final, ao contrário, ocorreu uma melhor separação entre os grupos, a separação é evidenciada pelos centroides no gráfico de dispersão (**Figura 12**).

Tabela 12. Matriz de correlação resultante dos valores de reflectância foliar, em diferentes regiões para a variedade Merlot.

		Associação ao grupo predito					
		Classe	Seival	Almadén	Boscato V1	Boscato V2	Total
Original	Contagem	Seival	32	0	0	0	32
		Almadén	0	49	0	0	49
		Boscato V1	0	0	32	0	32
		Boscato V2	0	0	0	112	112
	%	Seival	100,0	0,0	0,0	0,0	100,0
		Almadén	0,0	100,0	0,0	0,0	100,0
		Boscato V1	0,0	0,0	100,0	0,0	100,0
		Boscato V2	0,0	0,0	0,0	100,0	100,0
Validação cruzada	Contagem	Seival	32	0	0	0	32
		Almadén	0	49	0	0	49
		Boscato V1	0	0	32	0	32
		Boscato V2	0	0	1	111	112
	%	Seival	100,0	0,0	0,0	0,0	100,0
		Almadén	0,0	100,0	0,0	0,0	100,0
		Boscato V1	0,0	0,0	100,0	0,0	100,0
		Boscato V2	0,0	0,0	,9	99,1	100,0

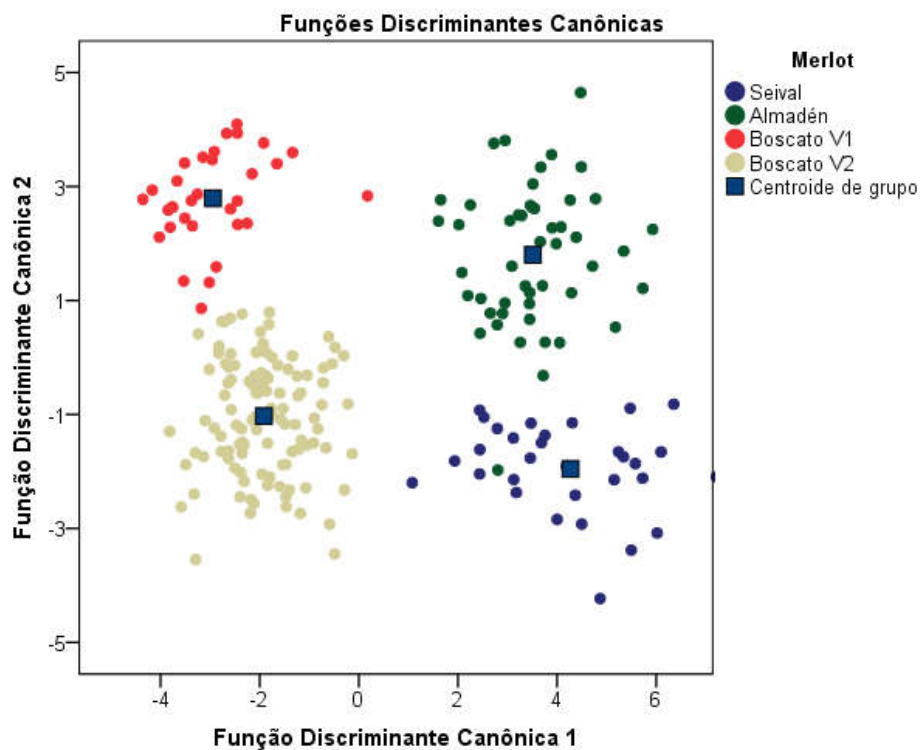


Figura 12. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para a classe Merlot.

4.3.3. Classificação entre variedades.

Nos resultados da matriz de correlação entre variedades, verificou-se nas porcentagens de acurácia global e validação cruzada maiores confusões espectrais entre as classes PN e CH, com valores em torno de 70,8, sendo que 66,15% foi a porcentagem de acerto mais baixa foi para a classe PN, como pode ser visualizado na **Tabela 13**. Registraram-se os valores mais altos na classificação com Riesling Itálico e Cabernet Sauvignon, ambas com valores maiores que 90%. O índice de separabilidade entre as classes foi boa, com Kappa de 0,8.

Tabela 13. Matriz de correlação resultante dos valores de refletância foliar, quanto às variedades de uva, para todas as regiões.

		Associação ao grupo predito						
		Classe	Chardonnay	Merlot	Pinot Noir	Riesling Itálic	Cabernet Sauvignon	Total
Original	Contagem	Chardonnay	86	9	9	4	0	108
		Merlot	10	197	9	1	8	225
		Pinot Noir	9	7	46	3	0	65
		Riesling Itálico	2	0	0	58	0	60
		Cabernet Sauvignon	0	8	1	0	103	112
	%	Chardonnay	79,6	8,3	8,3	3,7	0,0	100,0
		Merlot	4,4	87,6	4,0	,4	3,6	100,0
		Pinot Noir	13,8	10,8	70,8	4,6	0,0	100,0
		Riesling Itálico	3,3	0,0	0,0	96,7	0,0	100,0
		Cabernet Sauvignon	0,0	7,1	,9	0,0	92,0	100,0
Validação cruzada	Contagem	Chardonnay	84	11	9	4	0	108
		Merlot	12	195	9	1	8	225
		Pinot Noir	9	9	43	4	0	65
		Riesling Itálico	4	0	0	56	0	60
		Cabernet Sauvignon	0	9	1	0	102	112
	%	Chardonnay	77,78	10,19	8,33	3,70	0,00	100,00
		Merlot	5,33	86,67	4,00	0,44	3,56	100,00
		Pinot Noir	13,85	13,85	66,15	6,15	0,00	100,00
		Riesling Itálico	6,67	0,00	0,00	93,33	0,00	100,00
		Cabernet Sauvignon	0,00	8,04	0,89	0,00	91,07	100,00

O gráfico de dispersão dos dados visualizado na **Figura 13** demonstrou uma alta concentração das observações da classe CS em relação às outras variedades de uvas, sendo a classe que mais se destaca. Percebeu-se um certo distanciamento entre os espectros foliares entre as uvas tintas e brancas. Há que considerar que as folhas se encontram no mesmo estágio do ciclo fenológico da videira. A variedade CS também pode ter comportado dessa maneira, por suas medidas terem sido coletadas na mesma região, ou mais próximas em relação das outras variedades. As medidas foliares de CS foram realizadas na vinícola Boscato, exatamente no V1 e V2, enquanto as outras classes possuem amostras em mais de uma vinícola. A heterogeneidade das amostras pode estar contribuindo com a misturas entre classes.

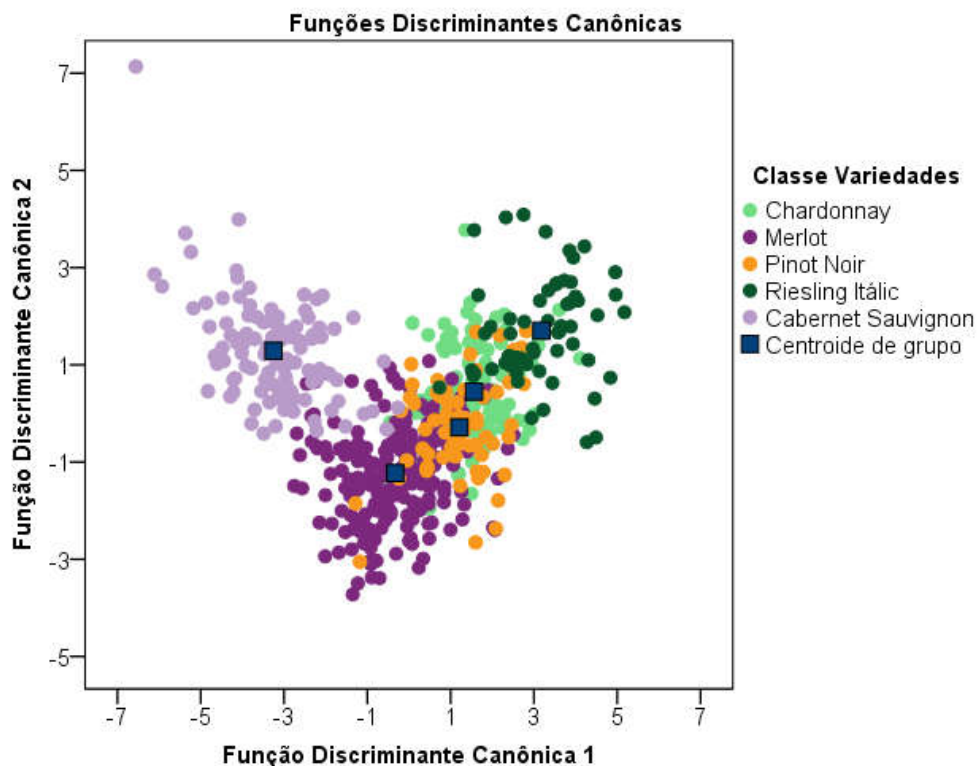


Figura 13. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para todas as variedades.

4.3.4. Classificação quanto à região.

Para as classes de regiões, a separação dos centróides (**Figura 14 e Tabela 14**) ocorreu conforme a localização geográfica de abrangência, expressando suas diferenças de solos e climas, que parecem influenciar as características ópticas das folhas existentes nesses ambientes. As vinícolas Almadén e Miolo Seival, que têm seus centróides próximos, pertencem à Campanha Gaúcha, enquanto a vinícola Chandon, um pouco mais distante, na Serra do Sudeste, já tem o centróide de suas observações mais separado. A vinícola Boscato, na Serra Gaúcha, tem os pontos referentes às medições ali efetuadas bem mais separadas, e ainda mostra separação entre seus dois vinhedos, o que pode ser justificado pela localização dos mesmos, que se encontram em fácies geológicas distintas, estando o Vinhedo 1 na fácies Gramado e o Vinhedo 2 na fácies Caxias. Estes resultados sugerem que a formação geológica, juntamente com o clima, afeta o crescimento, o processo da fotossíntese, a estrutura celular (externa e interna) das plantas e conseqüentemente interferem no comportamento espectral de suas folhas. A separação entre as classes aqui demonstrada através de dados de espectrorradiometria concorda com resultados obtidos de trabalhos

voltados à identificação de videiras por imagens ASTER, que detectaram nos espectros de refletância do dossel das plantas diferenças entre os *terroirs* (Silva e Ducati, 2009; Blauth e Ducati, 2010; Cemin e Ducati, 2011).

Tabela 14. Matriz de correlação resultante dos valores de refletância foliar, por regiões.

		Associação ao grupo predito						
		Classe	Seival	Almadén	Chandon	Boscato V1	Boscato V2	Total
Original	Contagem	Seival	91	7	0	0	0	98
		Almadén	2	133	2	0	0	137
		Chandon	0	7	72	0	0	79
		Boscato V1	0	0	0	110	1	111
		Boscato V2	0	0	0	1	144	145
	%	Seival	92,9	7,1	0,0	0,0	0,0	100,0
		Almadén	1,5	97,1	1,5	0,0	0,0	100,0
		Chandon	0,0	8,9	91,1	0,0	0,0	100,0
		Boscato V1	0,0	0,0	0,0	99,1	,9	100,0
		Boscato V2	0,0	0,0	0,0	,7	99,3	100,0
Validação cruzada	Contagem	Seival	88	9	0	0	1	98
		Almadén	3	131	3	0	0	137
		Chandon	1	8	70	0	0	79
		Boscato V1	0	0	0	110	1	111
		Boscato V2	0	0	0	1	144	145
	%	Seival	89,8	9,2	0,0	0,0	1,0	100,0
		Almadén	2,2	95,6	2,2	0,0	0,0	100,0
		Chandon	1,3	10,1	88,6	0,0	0,0	100,0
		Boscato V1	0,0	0,0	0,0	99,1	,9	100,0
		Boscato V2	0,0	0,0	0,0	,7	99,3	100,0




Figura 14. Gráfico de dispersão dos dados de reflectância foliar, em relação aos valores das Funções Discriminantes Canônicas 1 e 2, para todas as regiões.

4.4. Classificações nas imagens ASTER

Os resultados referentes às classificações entre as variedades da vinícola Almadén (**Figura 15, Tabelas 15 e 16**), obtiveram acurácia de 58,7% e índice Kappa de 0,4 utilizando o classificador da Distância de Mahalanobis. O desempenho da variedade Merlot foi o mais baixo, ocorrendo uma maior mistura. Para as classes Cabernet Sauvignon e Chardonnay foi obtido um maior número de acertos entre as classes, acima de 60%. O desempenho do classificador de Máxima Verossimilhança obteve resultados superiores ao comparar com o classificador da distância de Mahalanobis, com 63% e 4,7 de separabilidade entre classes. Os acertos mais altos ficaram com as variedades do tipo branca, Chardonnay e Riesling Itálico.

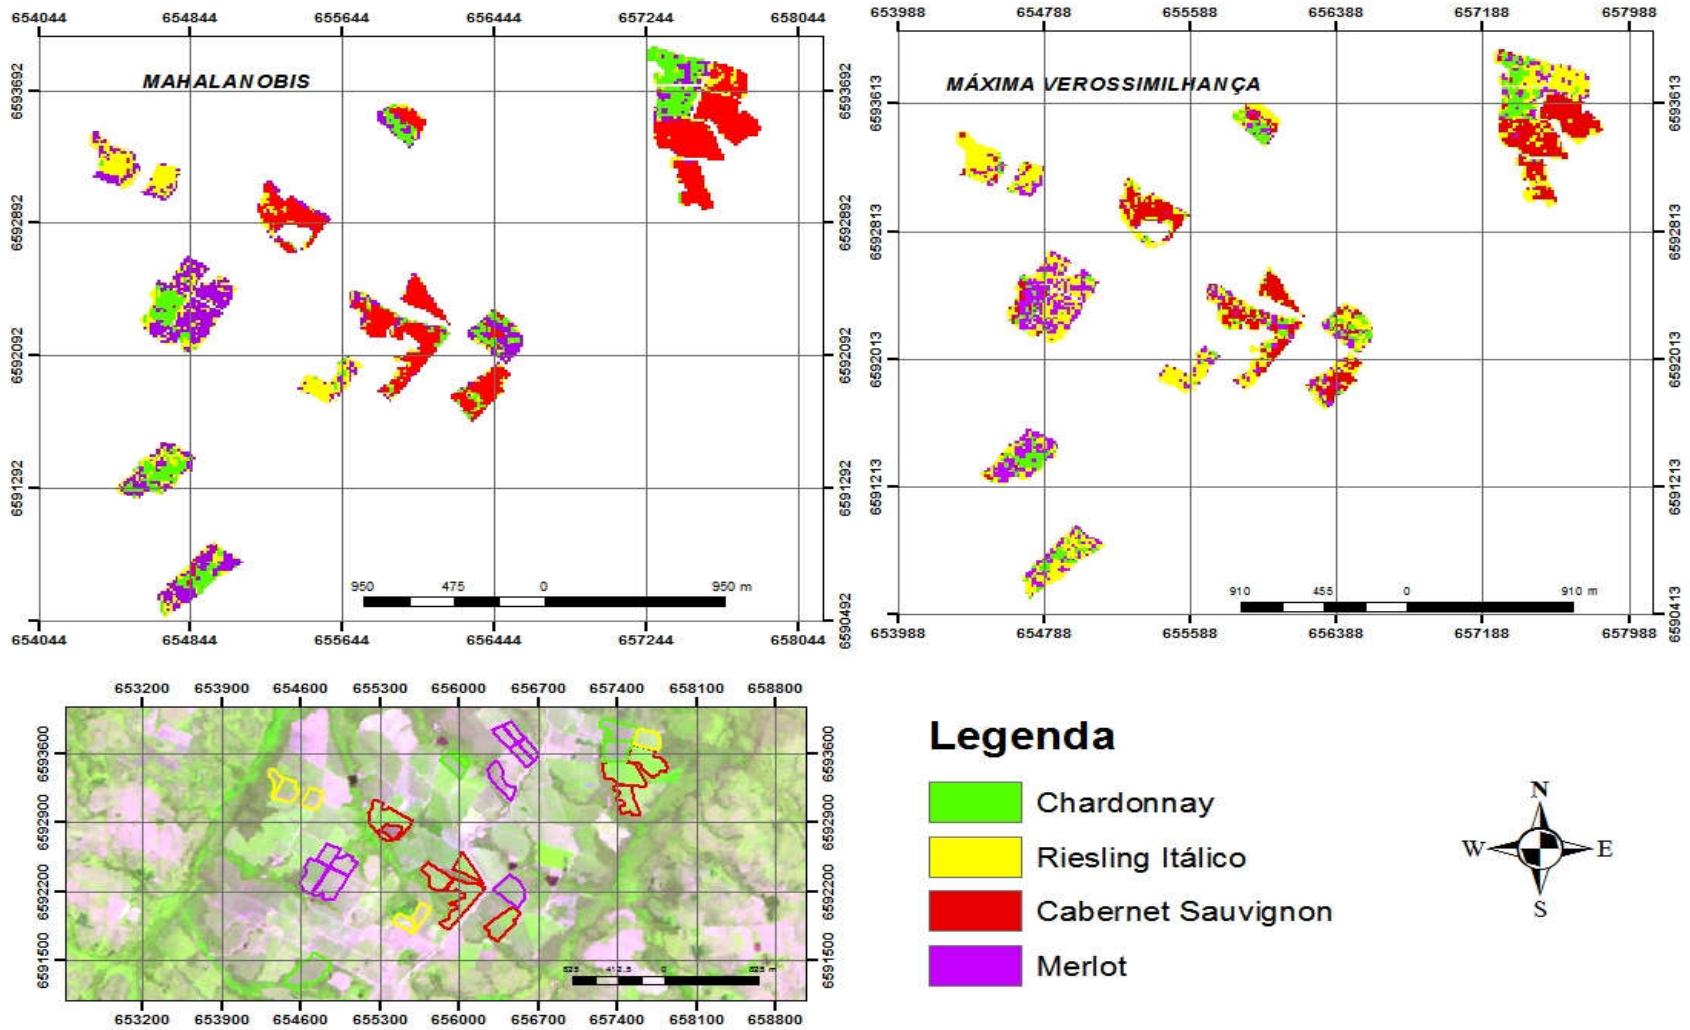


Figura 15. Mapa para classificações entre variedades na vinícola Almadén.

Tabela 15. Matriz de correlação entre variedades, utilizando o classificador pela distância de Mahalanobis entre variedades, para vinhedos Almadén.

Associação de pixels ao grupo predito

		Classe	Cabernet Sauvignon	Merlot	Chardonnay	Riesling Itálico	Total
Original	Contagem	Cabernet Sauvignon	2694	112	43	51	2900
		Merlot	654	1266	175	107	2202
		Chardonnay	552	325	660	48	1585
		Riesling Itálico	640	160	61	507	1368
		Total	4540	1863	939	713	8055
	%	Cabernet Sauvignon	63,44	11,27	4,69	21,74	40,83
		Merlot	15,48	45,73	20,02	12,76	22,77
		Chardonnay	8,63	25,66	62,51	10,94	19,06
		Riesling Itálico	12,44	17,34	12,78	54,56	17,34
		Total	100	100	100	100	100

Tabela 16. Matriz de correlação entre variedades, utilizando o classificador de Máxima Verossimilhança para vinícola Almadén.

Associação de pixels ao grupo predito

		Classe	Cabernet Sauvignon	Merlot	Chardonnay	Riesling Itálico	Total
Original	Contagem	Cabernet Sauvignon	2694	112	43	51	2900
		Merlot	654	1266	175	107	2202
		Chardonnay	552	325	660	48	1585
		Riesling Itálico	640	160	61	507	1368
		Total	4540	1863	939	713	8055
	%	Cabernet Sauvignon	59,34	6,01	4,58	7,15	36
		Merlot	14,41	67,95	18,64	15,01	27,34
		Chardonnay	12,16	17,44	70,29	6,73	19,68
		Riesling Itálico	14,1	8,59	6,5	71,11	16,98
		Total	100	100	100	100	100

Os resultados referentes às classificações entre as variedades da vinícola Miolo Seival (**Figura 16, Tabelas 17 e 18**), obtiveram acurácia de 68,7% e índice Kappa de 0,5; utilizando o classificador da Distância de Mahalanobis. O desempenho da variedade Cabernet Sauvignon foi o mais alto. As classes Pinot Noir e Chardonnay obtiveram maiores taxas de mistura dos valores classificados. O desempenho do classificador de Máxima Verossimilhança obteve resultados superiores em relação à primeira classificação, com 60% e 0,39 de separabilidade entre classes. Os acertos mais altos ficaram com a variedade Chardonnay.

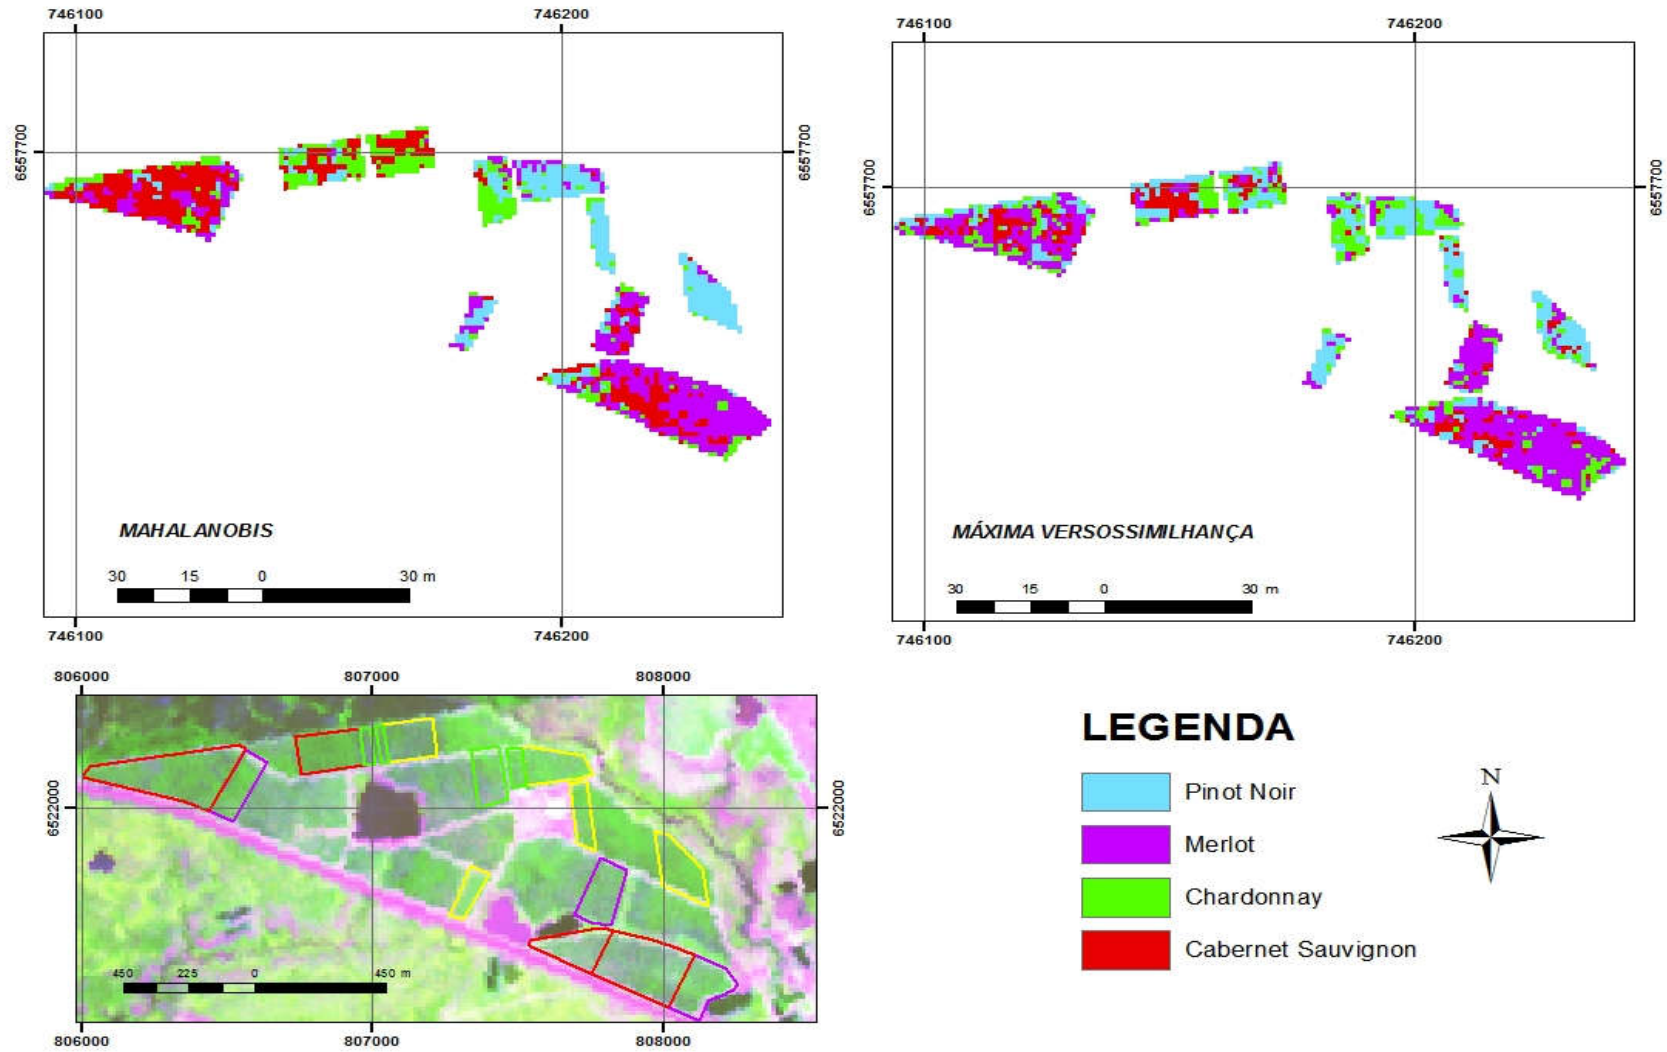


Figura 16. Mapa para classificações entre variedades na vinícola Miolo Seival.

Tabela 17. Matriz de correlação entre variedades, utilizando o classificador pela distância de Mahalanobis para as variedades da vinícola Miolo Seival.

		Associação de pixels ao grupo predito				
		Classe	Pinot Noir	Chardonnay	Cabernet Sauvignon	Total
Original	Contagem	Cabernet Sauvignon	334	51	90	475
		Chardonnay	111	93	153	357
		Riesling Itálico	59	23	651	733
		Total	504	167	894	1565
	%	Pinot Noir	66,27	30,54	10,07	30,35
		Chardonnay	22,02	55,69	17,11	22,81
		Cabernet Sauvignon	11,71	13,77	72,82	46,84
		Total	100	100	100	100

Tabela 18. Matriz de correlação entre variedades, utilizando o classificador de Máxima Verossimilhança para as variedades da vinícola Miolo Seival.

		Associação ao grupo predito				
		Classe	Pinot Noir	Chardonnay	Cabernet Sauvignon	Total
Original	Contagem	Cabernet Sauvignon	341	32	296	669
		Chardonnay	145	134	126	405
		Riesling Itálico	18	1	472	491
		Total	504	167	894	1565
	%	Pinot Noir	67,66	19,16	33,11	42,75
		Chardonnay	28,77	80,24	14,09	25,88
		Cabernet Sauvignon	3,57	0,6	52,8	31,37
		Total	100	100	100	100

Ao efetuarmos classificações via sensor orbital, no caso as imagens ASTER, a mistura espectral é mais evidente, ao equipará-los com os dados por espectrorradiometria foliar (*Leaf Clip*). Ao extrairmos as amostras de treinamento, no pixel de 15-30 metros, no espectro de reflectância, os solos, a vegetação em torno e dossel da videira têm suas respostas misturadas. Nas classificações anteriores as influências destes fatores podem estar influenciando a baixa acurácia dos resultados. O solo exposto é um fator de contribuição no fator mistura. Essa variável não foi considerada na análise, já que o foco principal é as folhas do dossel da videira. Ao analisar-se separadamente cada classe verificamos que as variedades são agrupadas, ou seja, as interferências da resposta espectral do dossel da videira, do conjunto de folhas, estão sendo expressas. A baixa acurácia do classificador de Máxima Verossimilhança deve-se ao número de amostras de treinamentos também ser relativamente baixo, o que comprometeu o desempenho do algoritmo. Quanto ao classificador da Distância de Mahalanobis, obteve-se desempenho superior ao classificador anteriormente citado.

4.4.1. Análise Discriminante dos dados orbitais

Os coeficientes canônicos (**Tabela 19**) ponderados para cada banda indicaram que para os agrupamentos por região os comprimentos de onda correspondentes à banda ASTER B9 compõem o descritor crucial para separação entre as classes. A banda B9 pertence à região do infravermelho médio, região espectral relacionada a influências de solos expostos, ou conteúdo de água na superfície do solo ou vegetação. Para a discriminação por variedades, B1 foi a banda que teve o maior peso para diferenciar as variedades, região espectral influenciada pelos pigmentos da planta; como na classificação foram incluídas diferentes variedades em diferentes estádios dos seus respectivos ciclos, a quantidade de pigmentos no dossel da videira pode ser variável.

Tabela 19. Funções discriminantes canônicas para os dados das imagens ASTER.

Terroir	$Z = 13,101 - 0,022*B1 + 0,006*B2 + 0,002*B3 - 0,026*B4 + 0,021*B5 + 0,005*B6 + 0,030*B7 + 0,001*B8 - 0,037*B9$
Variedade	$Z = 13,101 - 0,031*B1 + 0,016*B2 + 0,002*B3 - 0,013*B4 - 0,009*B5 + 0,012*B6 + 0,003*B7 - 0,006*B8 - 0,009*B9$

Na **tabela 20** é possível verificar que as variedades de uvas se agrupam mesmo quando estão localizadas em diferentes regiões. As classes CS, ME e RI mostram uma boa separabilidade. As maiores confusões ocorrem entre as classes CH e PN. A acurácia global da classificação ficou em torno de 83,9%. As diferenças entre regiões são expressas na **Tabela 21**, onde o grupo de reflectância referentes a cada vinícola obtiveram uma acurácia global de 100%. O índice Kappa para as classificações entre variedades ficou em torno de 0,86 e para a classificação por região teve o valor 1.

Tabela 20. Matriz de correlação entre variedades, tomando as observações em todas as regiões, por imagens ASTER.

		Associação de pixels ao grupo predito						
		Classe	Cabernet Sauvignon	Chardonnay	Merlot	Riesling Itálico	Pinot Noir	Total
Original	Contagem	Cabernet Sauvignon	8	0	0	0	0	8
		Chardonnay	1	6	0	1	0	8
		Merlot	0	0	4	0	0	4
		Riesling Itálico	0	0	0	4	0	4
		Pinot Noir	0	1	0	0	3	4
	%	Cabernet Sauvignon	100	0	0	0	0	100
		Chardonnay	12,5	75	0	12,5	0	100
		Merlot	0	0	100	0	0	100
		Riesling Itálico	0	0	0	100	0	100
		Pinot Noir	0	25	0	0	75	100
Validação cruzada	Contagem	Cabernet Sauvignon	3	1	1	0	3	8
		Chardonnay	1	3	1	1	2	8
		Merlot	1	1	2	0	0	4
		Riesling Itálico	1	1	0	1	1	4
		Pinot Noir	2	1	0	0	1	4
	%	Cabernet Sauvignon	37,5	12,5	12,5	0	37,5	100
		Chardonnay	12,5	37,5	12,5	12,5	25	100
		Merlot	25	25	50	0	0	100
		Riesling Itálico	25	25	0	25	25	100
		Pinot Noir	50	25	0	0	25	100

Tabela 21. Matriz de correlação entre as observações em diferentes regiões, por imagens ASTER.

		Classe	Almadén	Seival	Total
Original	Contagem	Almadén	16	0	16
		Seival	0	12	12
	%	Almadén	100,0	0,0	100,0
		Seival	0,0	100,0	100,0
Validação cruzada	Contagem	Almadén	16	0	16
		Seival	0	12	12
	%	Almadén	100,0	0,0	100,0
		Seival	0,0	100,0	100,0

4.5. Comparação entre os dados (ASTER X FIELD SPEC)

Os resultados obtidos com o espectrorradiômetro portátil, com acessório *Leaf Clip* demonstraram que o comprimento de onda correspondente à região espectral do azul é a principal responsável pelas separações entre variedades e regiões. No entanto, existem intervalos dos comprimentos de onda da região do infravermelho próximo e médio com pesos relevantes na discriminação. O sensor ASTER não compreende os intervalos da região do azul, e por isso as bandas disponíveis do infravermelho médio e verde são as determinantes nas classificações, como era de se esperar.

A variedade CS é a classe com maior separabilidade, pois o seu centroide é o mais afastado das outras classes. As razões deste isolamento nas classificações requerem estudos adicionais, como vincular as características físico-químicas dessas folhas e com as variações ambientais.

As variedades de uvas CH e PN se misturam em algumas classificações realizadas nas imagens. Esta similaridade também ocorreu com as medidas de refletância foliar. Esta confusão espectral também é reportada no trabalho realizado por Cemin & Ducati (2011).

A discriminação das amostras por regiões, para ambos os métodos de coleta de dados, foi satisfatória. As classificações por região, tanto com as medidas de reflectância foliar, quanto com as imagens, ocorreu com uma total separação. Pode-se aqui pensar que as características das folhas e/ou do dossel, apesar da mistura do pixel nas imagens ASTER

proveniente da interferência do solo exposto e das gramíneas entre fileiras, que por sua vez são expressivas, contribuíram para a separabilidade espectral entre regiões e variedades.

Na **tabela 21**, podemos visualizar a relação entre os pesos discriminantes dos comprimentos de ondas oriundos medidas de refletância foliar com as bandas do sensor ASTER. Para as classes de variedades CH, PN e RI obtiveram-se os maiores pesos discriminantes para as bandas do Infravermelho Médio, mais especificamente na B5 e na mesma região espectral a classe ME destaca seu potencial de separabilidade na B9. A variedade que se obteve um alto peso na região do visível foi a classe Cabernet Sauvignon, mais especificamente na B2.

Tabela 22. Os coeficientes discriminantes de Fisher com seus pesos atribuídos com os dados espectrorradiométricos relacionados com as bandas do sensor ASTER.

Variedades	Funções discriminantes lineares de Fisher
Chardonnay	$Z = -473 + 3455 \cdot B1 + 733 \cdot B2 + 3023 \cdot B3 + 478 \cdot B4 - 5577 \cdot B5 + 2309 \cdot B8 + 2400 \cdot B9$
Merlot	$Z = -483 + 3658 \cdot B1 + 1208 \cdot B2 + 3506 \cdot B3 - 139 \cdot B4 - 5320 \cdot B5 - 250 \cdot B8 - 6598 \cdot B9$
Pinot Noir	$Z = -489 + 4336 \cdot B1 + 474 \cdot B2 + 3555 \cdot B3 - 137 \cdot B4 - 6685 \cdot B5 - 4,575 \cdot B8 - 713 \cdot B9$
Riesling Itálico	$Z = -537 + 5132 \cdot B1 + 222 \cdot B2 + 3682 \cdot B3 - 21 \cdot B4 - 6671 \cdot B5 + 797 \cdot B8 - 1886 \cdot B9$
Cabernet Sauvignon	$Z = -513 + 3046 \cdot B1 + 3075 \cdot B2 + 2337 \cdot B3 + 996 \cdot B4 - 2867 \cdot B5 + 447 \cdot B8 - 1416 \cdot B9$

Conclusão

Os resultados obtidos pela Análise Discriminante em relação às classes por regiões apresentaram altos valores de acurácia indicando uma boa separação entre os grupos. Este afastamento entre os centróides de cada classe pode estar indicando que as características ambientais e climáticas associadas à regionalidade têm uma ligação com os respectivos espectros de refletância foliar. As vinícolas com maior semelhança, neste aspecto, são Almadén e Seival. Em geral a separação entre variedades das classes Chardonnay, Pinot Noir, Riesling Itálico, Merlot e Cabernet Sauvignon obteve bons resultados ocorrendo uma maior aproximação de seus centróides nas variedades brancas e um maior isolamento da variedade Cabernet Sauvignon. Quanto ao tipo de coloração a metodologia demonstrou que existe uma separação entre variedades de uvas brancas e tintas e que pode ser expressa pelas folhas das videiras, transmitida aos espectros foliares.

A AD permitiu detectar os comprimentos de onda que portam a informação necessária para separar as classes de variedade e *terroir*. Os comprimentos da faixa do azul apresentaram-se como a região espectral com maior potencial para discriminação entre as variedades de uva e as variações entre regiões. Pode-se dizer que utilização da AD nas observações de reflectância permite a seleção de poucos descritores para a identificação das variedades de uvas, evitando assim uma utilização maciça dos dados disponibilizados no momento da coleta das medidas em campo.

Os classificadores de Máxima Verossimilhança e Distância de Mahalanobis foram funcionais, embora tenha havido algumas confusões entre as classes nas imagens. O primeiro obteve um melhor desempenho para a vinícola Almadén enquanto o segundo foi mais acurado para a região da vinícola Miolo Seival. Quanto ao uso da AD para a classificação das imagens, demonstrou-se que as variedades das duas regiões se agrupam, ocorrendo alguma confusão entre as variedades Chardonnay e Pinot Noir. O modelo estatístico apontou fortemente a separação entre as duas regiões; neste caso, as regiões espectrais do verde e infravermelho médio foram cruciais para tal discriminação.

Ficou demonstrado neste trabalho que diferentes territórios imprimem na vegetação características espectrais que permitem, por medidas radiométricas de reflectância foliar, e também através da análise da reflectância registrada em imagens de satélite, a diferenciação territorial, ou seja, é possível diferenciar regiões pelo espectro das respectivas vegetações. Este ganho de percepção é, em nosso entender, relevante contribuição para a caracterização de regiões que reivindicam a condição de Indicação Geográfica.

Em futuros trabalhos poderão ser abordadas investigações mais profundas no que diz respeito às interferências dos efeitos de *terroir* na estrutura físico-química das folhas da videira, correlacionando dados espectrorradiométricos com os de sensores remotos de melhor resolução espectral e espacial, e com outros parâmetros, como mapas de fertilidade, tipos de solos, análise foliar, espessura e conteúdo de clorofila, possibilitando maiores informações sobre os efeitos do ambiente nas características das folhas e conseqüentemente na resposta espectral da videira.

Referências

- ANDERSON, G.P., PUKALL, B., ALLRED, C.L., JEONG, L.S., HOKE, M., CHETWYND, J.H., ADLERGOLDEN, S.M., BERK, A., BERSTEIN, L.S., RICHTSMEIER, S.C., ACHARYA, P.K. and MATTHEW, M.W. 2009. **FLAASH and MODTRAN4: state-of-the-art atmospheric correction for hyperspectral data**, *IEEE Aerospace Conference*, 4, 177–181. Disponível em: < <http://dx.doi.org/10.1109/AERO.1999.792088> >. Acessado em: 26 de novembro de 2013.
- ASD. *Analytical Spectral Devices*, inc. **Centro de Recursos e documentos para os produtos ASD**. 2014. Disponível em: <<http://www.asdi.com/resource-enter/documents>>. Acessado em 24 de setembro de 2014.
- BLAUTH, D. A. & DUCATI, J. R. A Web-based system for vineyards management, relating inventory data, vectors and images. **Journal Computers and Electronics in Agriculture** . 2010. 71, 182 – 188. Disponível em: < <http://dx.doi.org/10.1016/j.compag.2010.01.007> >. Acessado em: 24 de abril de 2014.
- BRAMLEY, R. G. V.; HAMILTON, R. P. 2004. Understanding variability in winegrape production systems. **Australian Journal of Grape and Wine Research**. v. 10, p. 32 – 45.
- CAMARGO, U. A.; TONIETTO, J.; HOFFMANN, A.2011. Progressos na viticultura brasileira. **Revista Brasileira de Fruticultura**. v. 33. Outubro. 2011. ISSN 0100-2945.
- CARNEIRO, E. L.; ROSSATO, M.S. **Mapa de tipologia climática**. Versão Digital.2011. Disponível em: < https://dakirlarara.files.wordpress.com/2011/05/tipos_de_clima_.jpg >. Acessado em: 18 de maio de 2014.
- CEMIN, G.; DUCATI, J. R. Spectral Discrimination of Grape Varieties and a Search for Terroir Effects Using Remote Sensing. 2011. **Journal of Wine Research**. v. 22, p. 57-78. Disponível em: <<http://dx.doi.org/10.1080/09571264.2011.550762>>. Acessado em: 20/06/14
- CEROVIC, Z. G.; MASDOUMIER, G.; GHOZLEN, N. B. & LATOUCHE, G. 2012. 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.org/10.1111/j.1399-3054.2012.01639.x> >. Acessado em: 12 de janeiro de 2014.
- COZZOLINO, D.; SMYTH, H. E. & GISHEN, M. Feasibility Study on the Use of Visible and Near-Infrared Spectroscopy Together with Chemometrics To Discriminate between Commercial White Wines of Different Varietal Origins. **Journal of Agricultural and Food Chemistry**. v.51, p. 7703-7708, 2003. Disponível em: <<http://dx.doi.org/10.1080/0957126022000017981>>. Acessado em 25 de Abril de 2014.
- DAUGHTRY, C. S. T.; GALLO, K. P.; GOWARD, S.N.; PRINCE, S.D.; KUSTAS, W.P. 1992. Spectral estimates of absorbed radiation and phytomass production in corn and soybean canopies. **Original Research Article Remote Sensing of Environment**. V.39, Issue 2, February 1992, p. 141-152. Acessado em: 15 de setembro de 2014.
- DUCATI, J.R., SARATE, R.E., FACHEL, J.M.G. 2014. Application of Remote Sensing Techniques to Discriminate between Conventional and Organic Vineyards at Loire Valley, France. **Journal International des Sciences de la Vigne et du Vin** 48, 135-144. 2014.
- ENVI. 2010 Software ENVI: **Guia do ENVI em português**. ITT *Visual Information Solutions*. Editora: SulSoft Serviços de Processamento de Dados.

ERSDAC. 2003. **The crosstalk correction software user's guide**. Disponível em: < <http://www.gds.aster.ersdac.or.jp/gds> >. Acesso em: 15 de dezembro de 2013.

FÁVERO, L. P.; BELFIORE, P.; SILVA, F. L.; CHAN, B. L. 2009. **Análise de dados: modelagem multivariada para tomada de decisões**. Rio de Janeiro: Elsevier.

FLORES, C. A.; POTTER, R.O.; HASENACK, H.; WEBER, E. 2007. **Levantamento semidetalhado de solos na região da Campanha – folha Palomas**. Rio Grande do Sul. Labgeo. Departamento de Ecologia UFRGS. Editora: UFRGS. ISBN:978-85-7025-905-9.

FLORES, C. A.; POTTER, R.O.; HASENACK, H. 2008. Levantamento semidetalhado dos solos na Serra do Sudeste, RS como subsídio ao zoneamento vitivinícola: Folha Encruzilhada do Sul. In: Congresso Brasileiro de Enologia e Viticultura, **Anais...**Bento Gonçalves.

HAIR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. 2005. **Análise multivariada de dados**. Editora: Bookman. Porto Alegre.

HALL, A.; LAMB, D.W.; HOLZAPFEL, B.; LOUIS, J. 2002. Optical remote-sensing applications in viticulture – a review. *Australian Journal of Grape and Wine Research* 8, 36-47.

HALL, A.; LOUIS, J. & LAMB, D. 2003. Characterizing and mapping vineyard canopy using high-spatial-resolution aerial multispectral images. **Computers & Geosciences**. 29, 813 – 822. Disponível em: < [http://dx.doi.org/10.1016/S0098-3004\(03\)00082-7](http://dx.doi.org/10.1016/S0098-3004(03)00082-7) >. Acessado em: 18 de maio de 2014.

INMET. Instituto Nacional de Meteorologia. **BDMEP – Banco de Dados Meteorológicos para Ensino e Pesquisa**. 2014. Disponível em: < <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep> >. Acessado em: 19 de maio 2014.

JENSEN, JOHN R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. 2. ed. São José dos Campos - SP: Parêntese, 2011. Tradução: José Carlos Neves Epiphanyo (coordenador).

KHATTREE, R.; NAIK, D.N. **Multivariate data reduction and discrimination with SAS software**. Cary, NC, USA: SAS Institute Inc., 2000.

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: 16 Junho 2014.

LANDIS, J. R.; KOCH, G. 1977. An Application of Hierarchical Kappa-type Statistics in the Assessment of Majority Agreement among Multiple Observers., **International Biometric Society**. Vol. 33, No. 2. Jun. pp. 363-374. Disponível em: Acessado em: 15 de novembro de 2013.

LINCOLN, T.; ZEIGER E.2012. **Fisiologia Vegetal**. Editora ARTMED.Nacional.5ª Edição. ISBN:8536327952.

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

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**

Sensing 5(2):604–616. Disponível em: < <http://dx.doi.or 10.1109/JSTARS.2012.2190044>>. Acessado em: 12 de junho de 2014.

MAHALANOBIS, P.C. 1936 .On the generalised distance in statistics. **Proceedings of the National Institute of Sciences of India 2**: p. 49–55. Disponível em: <<http://www.isical.ac.in/>>. Acessado: 20 de junho de 2014

MAROCO, J. 2007. **Análise estatística com utilização do SPSS**. Editora: Sílabo. Lisboa. 3ª Edição.

MATHER, P. M. 1999. **Computer Processing of remotely-sensed images: an introduction**. 2º ed. John Wiley & Sons. p. 292.

MINGOTI, S.A. 2005. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Belo Horizonte: Editora UFMG. p.297.

MOREIRA, M. A. 2014. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 4ª Edição Atualizada e Ampliada. Viçosa. MG. Ed. UFV. 2014. ISBN: 978-85-7269-381-3.

NASA. *National Aeronautics and Space Administration*. EOSDIS – Nasa’s Earth Observing System Data and information System. **Reverb/ECHO**. Disponível em :<<http://reverb.echo.nasa.gov/reverb/>> Acesso: 10 Março 2014.

NOVO, E. M. L. 2008. **Sensoriamento Remoto: Princípios e Aplicações**. 3ª Edição revisada e ampliada. São Paulo. Blucher.

PATAKAS, A., NOITSAKIS, B., STAVRAKAS, D.1997. **Adaptation of leaves of Vitis vinifera L. to seasonal drought as affected by leaf age**. *Vitis*, 36, pp. 11–14.

PESTANA, M. H. & GAGEIRO, J. N. 2005. **Análise de Dados para Ciências Sociais: A Complementaridade do SPSS**. Lisboa, Edições Sílabo.

PIRIE, A. and MULLINS, M.G., 1976. **Changes in anthocyanin and phenolic content of grapevine leaf and fruit tissues treated with sucrose, nitrate, and abscisic acid**. *Plant Physiology*, 58, pp. 468–472.

POERNER, N.; RODRIGUES, E.; CELSO, G. P.; MANFROI, V.; HERTZ F. P. 2010. Diferenciação analítica de vinhos-base para espumantes de duas regiões vitícolas do Rio Grande do Sul. **Revista Ciência Rural**. Santa Maria. V.40, N.5, P1186-1192, mai, 2010. ISSN01038478.

PONZONI, F. J. & SHIMABUKURO, Y. E. 2007. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos, São Paulo. Editora: Parêntese.

PONZONI, F. J.; SILVA, C. B. D.; SANTOS, S. B. D.; MONTANHER, O. C. & SANTOS, T. B. D. 2014. Local Illumination Influence on Vegetation Indices and Plant Area Index (PAI) Relationships. **Remote Sensing**, 6, 6266-6282. Disponível em: < <http://dx.doi.org/10.3390/rs6076266>>. Acessado em: 27 de janeiro de 2014.

PRABHAKAR, M.; PRASAD, Y.G.; RAO M. N. 2012. Chapter 16: **Remote Sensing of Biotic Stress in Crop Plants and Its Applications for Pest Management**. Livro: *Crop Stress and its Management: Perspectives and Strategies*. Springer Netherlands. ISBN: 978-94-007-2219-4. Disponível em: < <http://dx.doi.org/10.1007/978-94-007-2220-016> >. Acessado em: 18 de novembro de 2014.

REINERT, D. J.; REICHERT, J. M.; DALMOLIN, R. S. D.; AZEVEDO, A. C.; PEDRON, F. A. **Principais solos da Depressão Central e Campanha do Rio Grande do Sul**. Departamento de solos. Universidade Federal de Santa Maria. Santa Maria. RS. 2007. Disponível em: <http://www.fisicadosolo.ccr.ufsm.whoos.com.br/downloads/Disciplinas/FundCiSolo/Guia_ex_cursao_fundamentos_3edv3.pdf>. Acessado em: 23 de junho de 2014.

REIS, S. F. dos. 1988. Morfometria e estatística multivariada em biologia evolutiva. **Revista Brasileira de Zoologia**, v.5, n.4, p.571-580. Disponível em: <<http://dx.doi.org/10.1590/S0101-81751988000400005>>. Acesso em: 19 de setembro de 2014.

RENZULLO, L. J.; BLANCHFIELD, A. L.; POWELL, K. S. 2006. A method of wavelength selection and spectral discrimination of hyperspectral reflectance spectrometry. **IEEE Transactions on Geoscience and Remote Sensing**, v.44, p.1986-1994. Disponível em: <<http://dx.doi.org/10.1109/TGRS.2006.870441>>. Acesso em: 20 de outubro de 2014.

REYNIER, A.2002. **Manual de Viticultura: guia técnica de viticultura**. 6. ed. Madrid: Mundi-Prensa.

RICHARDS, J. A.1986. **Remote Sensing Digital Image Analysis - An Introduction**. New York: Springer-Verlag.

SANVICENTE, A. Z., & Minardi, A. M. A. F. 1998. **Identificação de indicadores contábeis significativos para a previsão de concordata de empresas**. Instituto Brasileiro de Mercado de Capitais, *Working Paper*.

SETHURAMASAMYRAJA, B.; SACHIDHANANTHAM, S.; WAMPLE, R. 2013. Geospatial Modeling of Wine Grape Quality Indicators (Anthocyanin) for Development of Differential Wine Grape Harvesting Technology. **International Journal of Geomatics and Geosciences**. ISSN: 0976-4380. Disponível em:< <http://www.indianjournals.com/> >. Acessado em: 15 Novembro 2013.

SHARMA, S. 1996. **Proactive environmental responsiveness: Catalysts for changing organizational paradigms and organizational capabilities**. BPS, ONE, and SIM. Academy of Management Annual Meetings, Cincinnati, OH, August.

SHUL'GIN, I, A.; KLESHNIN, A.F. 1959. Correlation between optical properties of plant leaves and their chlorophyll content. *Doklady Akademi Nauk S.SSR*, 125(6):1371,. Translation: A.I.B.S. DOKLADY 125, pp. 119,121.

SILVA, P.R.; DUCATI, J.R. Spectral features of vineyards in south Brazil from ASTER imaging. **International Journal of Remote Sensing**, v. 30, n. 23-24, p. 6085-6098, 2009. Disponível em: <<http://dx.doi.org/10.1080/01431160902810612> >. Acessado em: 18/06/2014.

SLATON, M., R.; HUNT, E., R.; SMITH, W. K. 2001. Estimating near infrared leaf reflectance from leaf structural characteristics. **American Journal of Botany** 88(2): 278–284. 2001.

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: 20/06/2014.

STEELE, MARK R.; GITELSON, ANATOLY A.; RUNDQUIST, DONALD C.; AND MERZLYAK, MARK N. 2009. Nondestructive Estimation of Anthocyanin Content in Grapevine Leaves. **Papers in Natural Resources**. 2009. Paper 283. Disponível em: <<http://digitalcommons.unl.edu/natrespapers>>. Acessado: 20 de agosto de 2014.

SOUZA, C.L.; PONZONI, F.J.; RIBEIRO, M. C. 1996. Influência do tempo e do tipo de armazenamento na reflectância espectral de folhas de *Eucalyptus grandis* "Ex situ". **Revista Árvore**, 20(2):255-265.

TAGEEVA, S.V.; BRANDT, A.B.; DEREVIANKO, V.S. 1960. Changes in optical properties of leaves in the course of the growing season. **Doklady Akademi Nauk S.S.S.R.**, 135(5):1270. Translation: A.I.B.S. Doklady 135, pp.266-68.

VAUDOIR, E. 2002. The Quality of Grapes and Wine in Relation to Geography: Notions of *Terroir* at Various Scales. **Journal of Wine Research**, v. 13, n. 2, p. 117 – 141. Disponível em: <<http://dx.doi.org/10.1080/0957126022000017981>>. Acessado em: 25/04/14.

VAUDOIR, E. 2004. **Les Terroirs Viticoles: définitions, caractérisation et protection**. France: Dunod-IRIS. ISBN 9782100064540.

VAUDOIR, E. 2008. Remote sensing of Red Mediterranean soils: a case study in the viticultural southern Rhone Valley using SPOT satellite imagery. **Geocarto International**, 23, 197-216. Disponível em: < <http://dx.doi.org/10.1080/10106040701207555> >. Acessado: 25/05/2014.

VAUDOIR, E., CAREY V., GILLIOT J.M. 2010. Digital zoning of South African viticultural terroirs using bootstrapped decision trees on morphometric data and multitemporal SPOT images. **Remote Sensing of Environment**, v.114, p. 2940-2950.

VIVALDI, D. D.; BAPTISTA, G. M. M.; MENESES, P. R. 2013. Avaliação dos processamentos de *crosstalk* e de correção atmosférica em dados ASTER para identificação da relação mineralógica caulinita/(caulinita + gibbsita) em solos no município de São João d'Aliança (GO). **Braz. J. Geol.** [online]. v.43, n.3, p. 571-582.

ZARCO-TEJADA. P. J.; BERJÓN, A.; LÓPEZ-LOZANO, R.; MILLER, J. R.; MARTÍN, P.; CACHORRO, V.; GONZÁLEZ, M. R.; FRUTOS, A. 2005. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. **Remote Sensing of Environment**. v. 99, p.271-287. Disponível em: < <http://dx.doi.org/10.1016/j.rse.2005.09.002>>. Acessado em: 25 de Março de 2014.

ZHANG, C.; KOVACS, J. M.; LIU, Y.; FLORES-VERDUGO, F. & FLORES-de-SANTIAGO, F. 2014. Separating Mangrove Species and Conditions Using Laboratory Hyperspectral Data: A Case Study of a Degraded Mangrove Forest of the Mexican Pacific. **Remote Sensing**, v. 6, p.11673. Disponível em: <[doi.10.3390/rs61211673](https://doi.org/10.3390/rs61211673)>. Acessado: 20 de outubro de 2014.