

UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

ODÍLIO COIMBRA DA ROCHA NETO

ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO DE DADOS
HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS

Fortaleza
2016

ODÍLIO COIMBRA DA ROCHA NETO

**ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO DE DADOS
HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, como parte dos requisitos para obtenção do Título de Doutor em Engenharia Agrícola. Área de Concentração: Irrigação e Drenagem.

Orientador: Prof. Adunias dos Santos Teixeira, Ph.D.

**Fortaleza
2016**

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca de Ciências e Tecnologia

-
- R574e Rocha Neto, Odílio Coimbra da.
Estimativa da condutividade elétrica por meio de dados hiperespectrais em solos afetados por sais. / Odílio Coimbra da Rocha Neto.– 2016.
119 f. : il. color.
- Tese (Doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Departamento de Engenharia Agrícola, Programa de Pós-Graduação em Engenharia Agrícola, Fortaleza, 2016.
Área de Concentração: Irrigação e Drenagem.
Orientação: Prof. Dr. Adunias dos Santos Teixeira.
1. Sensoriamento remoto. 2. Modelagem computacional. 3. Solos - Salinidade. I. Título.

ODÍLIO COIMBRA DA ROCHA NETO

**ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO DE DADOS
HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola do Departamento de Engenharia Agrícola da Universidade Federal do Ceará, como parte dos requisitos para obtenção do Título de Doutor em Engenharia Agrícola. Área de Concentração: Irrigação e Drenagem.

Orientador: Prof. Adunias dos Santos Teixeira, Ph.D.

Aprovada em: 19/02/2016

BANCA EXAMINADORA

Prof. Adunias dos Santos Teixeira, Ph.D (Orientador)
Universidade Federal do Ceará – UFC

Prof. Dr. Guilherme de Alencar Barreto
Universidade Federal do Ceará - UFC

Prof. Dr. Luis Clenio Jário Moreira
Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE

Prof. Dr. Lênio Soares Galvão
Instituto Nacional de Pesquisas Espaciais - INPE

Prof. Dr. Flávio Jorge Ponzoni
Instituto Nacional de Pesquisas Espaciais - INPE

Aos meus queridos pais, Odílio e Ana Rosa;

Ao meu irmão, cunhada e sobrinhas Francisco

José, Luciana, Laís e Luiza;

Aos meus amigos;

A minha amada namorada Sintia!

AGRADECIMENTOS

Aos meus pais por toda humildade, por minha educação, formação, apoio, incentivo e carinho.

Ao professor Adunias dos Santos Teixeira pela orientação e conhecimentos compartilhados e aos colegas de grupo de pesquisa.

À Universidade Federal do Ceará (UFC) pela formação ao nível de graduação, mestrado e doutorado e a todos os professores que contribuíram para minha formação profissional e passaram mais que conhecimentos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro ao projeto e pela concessão da bolsa. Sem o apoio financeiro desta instituição não seria possível a realização deste trabalho.

Um agradecimento especial para o companheiro de viagem Deodato Aquino e aos amigos Gilney e Karine, pelo período que estudamos no INPE no terceiro período de 2014.

Aos amigos de toda vida Caio Marinho, Thomaz Rocha, Samuel Coelho, Diego Fontenele, Jonhathan Brito, Yale Luck, Yana Luck, Jonathan Negreiros, Renan, Mayrom, Sinara Nalumi, Samara e Yves Carvalho.

E em especial à Sintia Kazumi pela dedicação, paciência e amor que me fez suportar todas as dificuldades sem tirar o sorriso do rosto.

Ao CNPQ – projeto INCTSAL e Casadinho/PROCAD e a CAPES pelo apoio financeiro.

RESUMO

A interpretação de dados do sensoriamento remoto fundamenta-se, basicamente, na análise do comportamento da reflectância espectral dos materiais no intervalo de comprimento de onda do visível ao infravermelho de ondas curtas (400 a 2500 nm). Para isso, pode-se usar a espectrorradiometria de reflectância, que é uma técnica capaz de medir, em diferentes comprimentos de ondas, a energia eletromagnética refletida da superfície dos materiais e representá-la na forma de um gráfico denominado curva de reflectância espectral. O poder analítico desta técnica advém do fato da informação espectral se correlacionar diretamente com a composição química e com as características físicas das substâncias contidas no alvo. No entanto, o grande volume de informações contidas em uma assinatura espectral aumenta a dificuldade de analisá-la, principalmente quando se trabalha com imagens. Com isso, o emprego de modelos computacionais se mostra como uma saída viável para a análise de curvas espectrais. Dessa forma, o objetivo desta tese é avaliar o desempenho de diferentes modelos computacionais como: mínimos quadrados (MQ), rede neural artificial do tipo perceptron de múltiplas camadas (MLP) e máquina de aprendizagem extrema (ELM), treinados em laboratório para estimar a condutividade elétrica do solo, e aplicá-los em imagens de alta resolução espectral. Esta tese foi separada em três etapas onde foram avaliados: a capacidade dos modelos computacionais em estimar a condutividade elétrica do extrato de saturação (CEes) a partir de amostra de condutividade elétrica 1:1 (CE1:1); as estratégias computacionais que melhor estimam a condutividade elétrica de amostras de solo a partir de leituras espectrais de solos obtidas em laboratório; e testar desempenho da melhor estratégia obtida no passo anterior, aplicando-a em uma imagem do sensor aerotransportado SpecTIR, coletado na região do Perímetro Irrigado de Morada Nova. Para avaliação dos algoritmos, foram coletadas amostras de solos na região de Morada Nova com histórico de áreas afetadas por sais. Estas amostras foram utilizadas para a calibração e validação dos modelos. Dados espectrais foram obtidos utilizando o espectrorradiômetro FieldSpec® 4 Hi-Res, entre 350 a 2500 nm. Foi avaliado o ganho de performance dos modelos matemáticos pela transformação dos dados através da análise por componente principal e pela análise derivativa. Com os resultados obtidos, pôde-se observar que as melhores respostas foram alcançadas pelo modelo linear dos mínimos quadrados aplicados aos dados puros, onde as bandas selecionadas para estimar a condutividade elétrica foram de 395, 1642 e 1717 nm. Para estimar a condutividade elétrica do solo na imagem do sensor SpecTIR sobre a área de estudo, o modelo calibrado em laboratório se mostrou interessante, produzindo um RPD de 1,46 e um coeficiente de correlação de Pearson de 0,80. Com isso, conclui-se que os modelos calibrados utilizando amostras em laboratório são satisfatórios para estimar a CE de imagens hiperespectrais.

Palavras-Chave: Salinidade. Algoritmos Computacionais. Regressão.

ABSTRACT

HIPERSPECTRAL DATA APPLIED FOR ESTIMATING ELECTRICAL CONDUCTIVITY IN SALTY SOILS.

Remote sensing data interpretation is based primarily on the spectral reflectance analysis of materials for wavelength ranging from visible to short wave infrared (400 to 2500nm). For this, one can use reflectance spectroscopy which is a technique capable of measuring, at different wavelengths, the electromagnetic energy reflected from the surface of materials and represent it in the form of a graph called spectral reflectance curve. The analytical power of this technique derives from the spectral information being correlated directly with the chemical composition and physical characteristics of the substances that makes the target. However, the large volume of information contained in a spectral signature increases the difficulty of analyzing it, especially if the dataset is made of images. Thus, computational models are expected to be a viable means of analyzing these spectral curves. Therefore, the objective of this thesis is to evaluate the performance of different computational models, such as least squares (LS), multilayer perceptron (MLP) and extreme learning machine (ELM) artificial neural networks, trained on laboratory data to estimate the electrical conductivity of salty soils, and to apply them to a hyperspectral image of the field. This thesis was organized in three parts: first, the ability of computer models to estimate the electrical conductivity of saturation extract (EC_{se}) based on electrical conductivity data from a 1:1 dilution (EC 1:1) is assessed; second, computing strategy for best estimating the electrical conductivity of soil samples using their spectral readings under laboratory conditions are evaluated; and finally, the performance of the best found model applied to an airborne SpecTIR sensor hyperspectral image collected at the Irrigated District of the Morada Nova was evaluated. To evaluate the proposed algorithms, soil samples were collected in the Morada Nova Irrigation District with a history of salinity. These samples were used for model calibration and validation. Spectral data were obtained using the spectroradiometer FieldSpec® 3 Hi-Res, from 350 to 2500nm. In an attempt to improve the performance of the models, data transformation was applied using either principal component analysis or derivative analysis. The results show the best performance was produced by the linear model fitted by least squares algorithm applied to the raw data (no transformation), and the spectral bands selected to estimate the electrical conductivity were 395, 1642 and 1717 nm. To estimate the soil's electrical conductivity from SpecTIR's image sensor data, the model calibrated in the laboratory has proved to be feasible, generating a value of 1.46 for RPD, and 0.80 for the Pearson correlation coefficient. Therefore, one can conclude that the calibrated models using samples in the laboratory are satisfactory for estimating EC based on hyperspectral images.

Keywords: Salinity. Computational Algorithms. Regression.

LISTA DE FIGURAS

Figura 1 – Esquema geral de uma rede neural artificial do tipo MLP.....	30
Figura 2 – Área de Estudo (Perímetro Irrigado Morada Nova).....	37
Figura 3 – Pontos amostrais coletados no dia 12/05/2015, imagem obtida pela plataforma Google Earth.....	38
Figura 4 – Fluxograma mostrando o processo de calibração e validação dos modelos computacionais	39
Figura 5 – Dispersão dos dados das amostras de condutividade elétrica do solo onde a abcissa representa as leituras de CE_{es} e a ordenada representam a CE 1:1	43
Figura 6 – Regressão linear entre os valores de CE do extrato de saturação estimado e observado, sendo A para o modelo dos mínimos quadrados, B para o modelo RNA do tipo MLP e C para o modelo RNA do tipo ELM	44
Figura 7 – Área de Estudo (Perímetro Irrigado Morada Nova) onde em: A-delimitação do Perímetro Irrigado de Morada Nova, B-Localização do Estado do Ceará no Brasil e C- a localização do Perímetro estudado no Estado do Ceará	48
Figura 8 – Pontos amostrais coletados nos dias 12/05/2015 e 31/05/2015, onde em: A- localização dos pontos amostrais em campo em relação a imagem obtida pela plataforma Google Earth, B- localização da área amostral no Perímetro Irrigado de Morada Nova e C- a localização do perímetro irrigado no Estado do Ceará	49
Figura 9 – Fotos retiradas em pontos na coleta realizada no dia 12/05/2015.....	50
Figura 10 – Sistema de leitura de espectros instalados no laboratório	51
Figura 11 – Fluxograma do procedimento de teste dos algoritmos.....	52
Figura 12 – Fluxograma do procedimento de seleção de bandas	53
Figura 13 – Curvas de respostas espectrais obtidas das amostras em laboratório.....	55
Figura 14 – Espectro médio das amostras coletadas (azul cheio) com os limites de valor máximo e mínimo obtidos (azul tracejado) e seu respectivo desvio padrão (vermelho – eixo y secundário).....	56
Figura 15 – Bandas selecionadas para os dados hiperespectrais. Sendo A dados puros, B com as bandas do sensor SpecTIR e C do sensor Hyperion	59
Figura 16 – Área de Estudo (Perímetro Irrigado Morada Nova) onde em: A-delimitação do Perímetro Irrigado de Morada Nova, B-Localização do Estado do Ceará no Brasil e C- a localização do Perímetro estudado no Estado do Ceará	65
Figura 17 – Cobertura da Imagem SpecTIR obtida no dia 23/05/2015 na região do Perímetro irrigado de Morada Nova-Ce.....	65
Figura 18 – Pontos amostrais coletados nos dias 12/05/2015 e 31/05/2015	66
Figura 19 – Aquisição dos dados hiperespectrais em laboratório, onde em: A- Espectrorradiômetro de laboratório, B – foto da aquisição da curva espectral, C- tabulação das respostas espectrais em Excel e D- as curvas espectrais obtidas em laboratório.....	67
Figura 20 – Fluxograma de Treinamento e Validação do Modelo Computacional	69
Figura 21 – Fluxograma do procedimento de seleção de bandas	70
Figura 22 – Coleta dos espectros da Imagem SpecTIR por meio do software ENVI	72

Figura 23 – Comportamento espectral das amostras coletadas, A espectros obtidos em laboratório e B dos pixels amostrados da imagem SpecTIR	73
Figura 24 – Distribuição da Condutividade Elétrica utilizando o modelo calibrado em laboratório aplicado na imagem SpecTIR.....	77
Figura 25 – Resultado da Classificação do algoritmo SVM correlacionando Índice de Salinidade e a Primeira Componente Principal para identificação de áreas salinas em Morada Nova utilizando os sensores/satélite: (A) OLI/Landsat-8 e (B) Hyperion/EO-1	78

LISTA DE TABELAS

Tabela 1 – Classificação dos solos afetados por sais.....	20
Tabela 2 – Classes de salinidade em função da condutividade elétrica (CE_{es})	20
Tabela 3 – Interpretação do Coeficiente de Pearson (r).	40
Tabela 4 – Interpretação do Índice de Desempenho (c).	41
Tabela 5 – Interpretação da Taxa de Desvio da Performance (RPD).....	41
Tabela 6 – Validação dos algoritmos computacionais para converter condutividade elétrica 1:1 em condutividade elétrica do extrato de saturação	43
Tabela 7 – Seleção de atributos entre os diferentes tratamentos dos dados	58
Tabela 8 – Desempenho dos algoritmos computacionais.....	61
Tabela 9 – Desempenho dos algoritmos computacionais calibrados em Laboratório ...	75
Tabela 10 – Desempenho dos algoritmos computacionais em relação à imagem SpecTIR	76

LISTA DE ABREVIACOES E SMBOLOS

μm	micrmetros
λ	comprimento de onda
ACP	anlise da componente principal
ADL	anlise discriminante linear
c	ndice de desempenho
CE	condutividade eltrica
CE_a	condutividade eltrica aparente
CE_{es}	condutividade eltrica do extrato de saturao
dS/m	deciSiemens por metro
ELM	mquina de aprendizagem extrema
EQM	erro quadrtico mdio
id	ndice de concordncia de Willmott
MIR	infravermelho mdio
MLP	perceptron de mltiplas camadas
MQ	mnimos quadrados
NIR	infravermelho prximo
nm	nanmetros
PST	percentagem de sdio trocvel
SD	desvio padro
SWIR	infravermelho de ondas curtas
SVM	mquina de vetores suporte
r	coeficiente de Pearson
R^2	coeficiente de determinao
$R^2_{ajustado}$	coeficiente de determinao ajustado
RNA	rede neural artificial
RPD	taxa de desvio da performance
VIS	faixa espectral do visvel

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Hipótese	16
1.2	Objetivos.....	16
2	REVISÃO DE LITERATURA.....	17
2.1	Salinidade do solo.....	17
2.1.1	Problemas de solos salinos	18
2.1.2	Classificação do solo quanto a problemas de sais	19
2.2	Sensoriamento remoto hiperespectral.....	21
2.3	Espectrorradiometria.....	22
2.4	Tratamento de dados.....	23
2.4.1	Análise por Componente Principal.....	24
2.4.2	Diferenciação de dados.....	26
2.5	Algoritmos Computacionais de Ajuste (Data Fitting)	28
2.5.1	Mínimos Quadrados (MQ)	29
2.5.2	Perceptron de Múltiplas Camadas (MLP)	29
2.5.3	Máquina de Aprendizagem Extrema (ELM)	32
3	ESTRATÉGIA METODOLÓGICA PARA RESPONDER ÀS HIPÓTESES	35
4	ESTIMATIVA DE CONDUTIVIDADE ELÉTRICA DE EXTRATO DE SATURAÇÃO POR MEIO DE SOLUÇÃO 1:1.....	36
4.1	Introdução	36
4.2	Material e Métodos	37
4.3	Resultados e Discussão.....	42
4.4	Conclusões.....	46
5	AVALIAÇÃO DE MODELOS MATEMÁTICOS NA DETERMINAÇÃO DA CONDUTIVIDADE ELÉTRICA DE SOLOS SALINOS POR MEIO DE DADOS HIPERESPECTRAIS.	47
5.1	Introdução	47
5.2	Material e Métodos	48
5.3	Resultados e Discussão.....	55
5.4	Conclusões.....	62
6	AVALIAÇÃO DO DESEMPENHO DE MODELOS COMPUTACIONAIS CALIBRADOS EM LABORATÓRIO, NA DETERMINAÇÃO DA CONDUTIVIDADE ELÉTRICA DE SOLOS POR MEIO DE IMAGENS HIPERESPECTRAIS OBTIDAS POR SENSOR AEROTRANSPORTADO..	63

6.1	Introdução	63
6.2	Material e Métodos	64
6.3	Resultados e Discussão.....	72
6.4	Conclusões.....	78
7	CONCLUSÕES GERAIS.....	80
	REFERÊNCIAS	81
	APÊNDICE	89
	ANEXO	103

1 INTRODUÇÃO

As mudanças ambientais são o assunto mais discutido atualmente, na literatura, em fóruns e em reuniões no mundo todo. Estas mudanças estão fortemente relacionadas com a atividade agrícola e a produção de alimentos, pois impactam negativamente no ambiente, como, por exemplo, acelerando a degradação do solo, comprometendo, por consequência, a sustentabilidade da agricultura.

A combinação clima (semiárido), regime hídrico (distribuição unimodal da precipitação, concentrada em três a quatro meses) e geologia predominante (cristalino) no Estado do Ceará resulta em elevado déficit hídrico (caracterizado por evaporação potencial superior a precipitação), favorecendo a salinização dos solos e de águas superficiais e subterrâneas, uma das principais formas de degradação ambiental em áreas agrícolas.

O estabelecimento de estratégias de identificação e quantificação das áreas salinizadas possibilita melhor gestão das políticas públicas relacionadas a este problema. Vários estudos adotaram a estratégia de utilização de dados georreferenciados, como imagens hiperespectrais.

A quantidade de informações geradas nestas imagens possibilitam a identificação e quantificação de vários elementos a partir da análise e comparação com espectros conhecidos em bibliotecas espectrais ou na literatura.

A obtenção de espectros de amostras muitas vezes é realizada em laboratório, por meio de espectrorradiômetros com melhor relação sinal/ruído do que a dos sensores espaciais e/ou aerotransportados, sob condições controladas, facilitando as interpretações.

Devido à interferência de outros elementos (atmosfera, variação da textura do solo, mistura espectral etc.) no comportamento espectral do alvo em campo, a utilização de espectros obtidos em laboratório, aliada a algoritmos computacionais bem ajustados, confere poder de generalização suficiente para superar as interferências dos dados obtidos em campo e precisão no ajuste do fenômeno estudado.

No entanto, para obter um algoritmo bem ajustado é necessário entender o fenômeno estudado para que se escolha o modelo matemático que melhor se adapte, escolhendo, assim, um algoritmo com alta precisão aliado a um baixo custo computacional.

1.1 Hipótese

A utilização de modelos matemáticos, como mínimos quadrados e redes neurais artificiais, calibrados para as respostas hiperespectrais obtidas em laboratório é uma solução viável para a detecção do nível de salinização do solo em imagens hiperespectrais.

1.2 Objetivos

O objetivo geral desta tese é avaliar o desempenho de modelos computacionais lineares e não-lineares calibrados em laboratório e aplicados a dados de sensoriamento remoto hiperespectral para a detecção da condutividade elétrica de solos expostos.

E como objetivos específicos:

- a) Obter uma relação funcional entre CEes e CE 1:1;
- b) Obter, em laboratório, o comportamento espectral dos solos coletados;
- c) Selecionar comprimentos de onda que mais se correlacionam com a condutividade elétrica do solo;
- d) Avaliar o desempenho de diferentes estratégias de tratamento dos dados, como a análise por componente principal e análise derivativa, na melhoria do desempenho dos modelos avaliados;
- e) Calibrar e avaliar o desempenho do modelo linear dos mínimos quadrados para estimar a condutividade elétrica do solo;
- f) Calibrar e avaliar o desempenho dos modelos não-lineares, rede neural artificial e máquina de aprendizagem extrema, para estimar a condutividade elétrica do solo;
- g) Aplicar e avaliar os algoritmos de melhor desempenho em imagens de alta resolução espacial e espectral do sensor SpecTIR.

2 REVISÃO DE LITERATURA

Neste tópico, serão descritos os processos obtidos na literatura importantes para a execução deste trabalho. São eles: a salinidade do solo, quais são os seus principais problemas e como podem ser classificados; as técnicas de sensoriamento remoto hiperespectral e espectrorradiometria; algumas técnicas de tratamento dos dados utilizadas antes da aplicação dos algoritmos de regressão para melhorar seu desempenho; e o funcionamento dos algoritmos computacionais, alvos deste estudo.

2.1 Salinidade do solo

A composição de vários processos denominada como salinização é referida como o tipo mais frequente de degradação do solo em regiões áridas e semiáridas. Estes processos são o produto de uma complexa interação de vários fatores, provocando mudanças dentro de um período de cerca de uma década, geralmente irreversível, levando a um menor potencial de produção do solo (FARIFTEH *et al.*, 2006).

Dentre os fatores determinantes da salinização do solo estão o clima árido e/ou semiárido, a má drenagem, o lençol freático alto, a baixa permeabilidade do solo, o manejo inadequado da irrigação, os minerais primários e as adubações químicas contínuas e mal conduzidas em solos irrigados (SOUZA *et al.*, 2001). Os autores destacam ainda a ação antrópica como atividade com maior potencial para causar problemas, devido à sistemática adição ao solo dos sais contidos na água.

Segundo Ferreira *et al.* (2002), os solos com alta concentração salina encontram-se nas regiões de clima árido e semiárido. Isto porque as baixas precipitações pluviais não são suficientes para lixiviar os sais do perfil do solo e transportá-los até o leito dos rios perenes e finalmente para o mar. O clima quente, seco e a alta taxa de evaporação contribuem para o acúmulo destes sais no perfil e na superfície do solo.

Para Farifteh *et al.* (2006), os problemas de salinidade têm um grande impacto, especialmente nessas regiões onde as áreas com condições climáticas severas estão sob alta pressão para fornecer os alimentos necessários e fibras para a sua crescente população. Esta pressão resulta das mudanças no uso da terra, principalmente devido à política comum de intensificação agrícola. O uso desta forma acelera os

processos de degradação dos solos, a salinização e, eventualmente, acarreta a diminuição do rendimento.

Os processos de degradação do solo mais importantes causados pela salinização são a dispersão do solo, a impermeabilização, a formação de crostas e as mudanças estruturais, resultando em solo instável e compactado.

Serão relatados a seguir alguns dos problemas que a salinidade de solos pode ocasionar aos campos agrícolas e em seguida serão abordados os parâmetros para a classificação dos solos afetados por sais.

2.1.1 Problemas de solos salinos

O efeito prejudicial do sódio adsorvido sobre as propriedades físicas dos solos resulta em baixa taxa de infiltração de água, baixa permeabilidade à água e gases, aumento da pressão osmótica do solo e empobrecimento da estrutura do solo. O aumento dos sais no solo também resulta em dispersão química, aumentando a susceptibilidade do solo para vedação e formação da crosta (AGUIAR NETTO *et al.*, 2007).

O aumento do sódio trocável promove mudanças estruturais, resultando em um solo instável e compactado. Isto é devido à dispersão das partículas do solo, principalmente em solos sódicos, onde o teor de matéria orgânica tende a cair devido à não decomposição de forma satisfatória. As alterações nas propriedades do solo como resultados de acumulações de sais promovem redução da produtividade (FARIFTEH, 2007).

Quanto à vegetação, os sais contidos na água acumulam-se na zona radicular, diminuindo a disponibilidade de água e acelerando sua escassez. A compreensão do processo de salinização permite encontrar formas de evitar seus efeitos e diminuir a probabilidade de redução dos rendimentos das culturas (GARCIA *et al.*, 2008). Ainda segundo Santana *et al.* (2003), a acumulação de sais na rizosfera prejudica o crescimento e desenvolvimento das culturas, provocando um decréscimo de produtividade e, em casos mais severos, podendo levar a um colapso da produção agrícola. Isso ocorre em razão da elevação do potencial osmótico da solução do solo, por efeitos tóxicos dos íons específicos e alteração das condições físicas e químicas do solo.

Garcia *et al.* (2008), citaram os efeitos imediatos da salinidade sobre os vegetais: seca fisiológica, proveniente da diminuição do potencial osmótico; desbalanceamento nutricional devido à elevada concentração iônica, especialmente do sódio, que inibe a absorção de outros nutrientes; e efeito tóxico de íons, particularmente o cloro e sódio. Ainda segundo os autores, o estresse salino progressivo acarreta a inibição dos mecanismos de crescimento das plantas, o desenvolvimento da gema apical é afetado, os ramos ficam atrofiados, as folhas apresentam-se com menor área e amareladas e grandes porções da parte aérea dessecam totalmente.

2.1.2 Classificação do solo quanto a problemas de sais

A salinidade refere-se à concentração de sais solúveis do solo e aos aspectos tóxicos e osmóticos dos nutrientes, relacionados com a nutrição mineral das plantas. A alcalinidade relaciona-se mais à ação dos sais sobre os solos, promovendo a alteração da estrutura, diminuição da infiltração de água, da condutividade hidráulica e da aeração, aumentando também a concentração de sódio trocável, carbonato e bicarbonato no solo. Os solos salinizados contêm sais solúveis e/ou sódio trocável em quantidade suficiente para reduzir, interferir ou até mesmo impedir o desenvolvimento vegetal. Em razão dos problemas dos sais, os solos podem ser classificados como salinos, salino-sódicos e sódicos (SILVEIRA *et al.*, 2008).

Os três grupos de classificação podem ser distinguidos com base em suas propriedades físico-químicas e biológicas, sua localização geográfica e sua distribuição geoquímica¹. No entanto, o sistema mais utilizado para a classificação de solos afetados por sais no Brasil é baseado nas características propostas por Richards (1954), usando a Condutividade Elétrica do extrato de saturação (CE_{es}) e Percentagem de Sódio Trocável (PST) como critérios de classificação (TAVARES FILHO, 2010), conforme exposto na Tabela 1.

¹ Relatado por Szabolcs em 1974 (FARIFTEH *et al.*, 2008).

Tabela 1 – Classificação dos solos afetados por sais

Tipo de Solo	CE_{es} (dS m⁻¹)	PST (%)
Normal	< 4	< 15
Salino	> 4	< 15
Salino Sódico	> 4	> 15
Sódico	< 4	> 15

Fonte: Richards (1954).

Em virtude da propriedade dos íons em solução conduzirem a corrente elétrica, a condutividade elétrica do extrato da pasta saturada, mais conhecida como condutividade elétrica do extrato de saturação (CE_{es}), é o mais usual método para estimar o total de sais solúveis do solo por conta da condução da corrente elétrica ser diretamente proporcional a quantidade de íons em solução (GHEYI; DIAS; LACERDA, 2010).

O Laboratório de salinidade dos EUA também propôs um padrão de classes de salinidade baseado na condutividade elétrica e no efeito da salinidade sobre as plantas (Tabela 2)

Tabela 2. A unidade padrão da condutividade elétrica (CE) é expressa em deciSiemens por metro (dS/m) a 25°C (RICHARDS, 1954).

Tabela 2 – Classes de salinidade em função da condutividade elétrica (CE_{es})

Classes de salinidades	CE_{es} (dS/m)	Efeito da salinidade sobre as culturas
Não salino	< 2	Efeitos da salinidade são insignificantes
Ligeiramente salino	2 – 4	Rendimentos de culturas muito sensíveis são restringidos
Moderadamente salino	4 – 8	Rendimento de muitas culturas é restringido
Muito salino	8 – 16	Apenas culturas tolerantes têm rendimento satisfatório
Extremamente salino	> 16	Apenas algumas culturas muito tolerantes conseguem produzir

Fonte: Richards (1954).

2.2 Sensoriamento remoto hiperespectral

Em princípio, o sensoriamento remoto é definido como sendo a tecnologia que permite aquisição de informações sobre objetos sem manter contato físico com eles. De acordo com Naue *et al.* (2010), sensoriamento remoto é a utilização conjunta de sensores, equipamentos para processamento de dados, entre outros, com o objetivo de estudar o ambiente da superfície terrestre por meio do registro e análise das interações entre a radiação eletromagnética e as suas diversas coberturas.

Muitos estudos de classificação de culturas foram realizados usando sensores multiespectrais. No entanto, estes sensores oferecem limitada resolução espectral, não oferecendo dados suficiente para uma boa identificação das culturas agrícolas. Com o avanço das tecnologias dos sensores, surgiram os sensores hiperespectrais, que coletam dados em centenas de bandas espectrais somente em uma aquisição (SOUZA, 2013).

A alta resolução espectral dos sensores imageadores denominados hiperespectrais tornou possível a identificação mais precisa dos espectros associados aos diversos materiais presentes nas cenas imageadas, propiciando assim o desenvolvimento de inúmeras aplicações em sensoriamento remoto (PIZARRO e FERNANDES, 2007).

Um sensor imageador hiperespectral tem, como vantagem, a capacidade de adquirir imagens com um número muito maior de informações em relação aos multiespectrais. Tais sistemas possibilitam a construção de um espectro de reflectância praticamente contínuo para cada pixel da cena imageada, pois coletam dados em dezenas ou em centenas de bandas (MONTEIRO, 2009).

Como os materiais terrestres podem ser caracterizados por feições de absorção espectral compreendidas na faixa do espectro eletromagnético entre 0,02 e 2,5 μm , as curvas espectrais correspondentes podem ser extraídas das imagens hiperespectrais e comparadas com espectros medidos em campo ou em laboratório (DUCARTI, 2004).

Ainda segundo Ducarti (2004), existem, em funcionamento, vários sensores deste tipo, os quais, em sua maioria, são sensores aerotransportados, portanto, com escassa cobertura global e custos associados muito elevados. Como exemplo, o sensor Airborne Visible / Infrared Imaging Spectrometer (AVIRIS).

O AVIRIS é um sensor operado pela National Aeronautics and Space Administration (NASA)/Jet Propulsion Laboratory (JPL) e normalmente voa em

aeronaves ER-2 e Twin Otter, principalmente sobre os Estados Unidos. O sensor AVIRIS consiste de 224 bandas espectrais no intervalo em torno de 360 nm a 2500 nm, com uma largura de banda média de 10 nm. A resolução espacial de dados AVIRIS varia de 3 m a 17 m, dependendo da altitude de voo (HE *et al.*, 2015).

Outro exemplo de sensor hiperespectral aerotransportado, sendo este operado nacionalmente pela empresa Fototerra, é o ProSpecTIR, o qual é projetado para coletar em torno de 360 bandas espectrais, com largura nominal de 5 nm, abrangendo a faixa espectral de 390 à 2450 nm.

Os principais sensores hiperespectrais orbitais são: Compact High Resolution Imaging Spectrometer (CHRIS), a bordo do satélite Proba, e Hyperion Imaging Spectrometer, a bordo do satélite EO-1, tendo este descontinuado em 2015.

O sensor CHRIS cobre a faixa do visível (VIS) e infravermelho próximo (NIR), limitando o seu uso. Já o sensor Hyperion era o mais indicado para mapeamento de solo e vegetação, devido à cobertura de faixa espectral entre o VIS e o SWIR (400 a 2500 nm – infravermelho de ondas curtas). Contudo, suas imagens possuem cobertura geográfica extremamente reduzida (MARKOSKI, 2006).

Cada imagem adquirida pelo sensor Hyperion/EO-1 representa 242 bandas espectrais distribuídas entre as faixas 356 e 2577 nm, ou seja, faixas do visível (VIS), do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR), com resolução espectral de aproximadamente 10 nm e resolução espacial de 30 m (NASA, 2012).

O Hyperion era um sensor de varredura que operava em uma órbita de 705 km, imageando 256 pixels, correspondente a uma largura de faixa no terreno de 7,5 km. A relação sinal/ruído (SNR) desse sensor é relativamente baixa (nominalmente de cerca de 100:1), o que limita muitas das aplicações científicas. Ducart, Crósta e Souza Filho (2007) observaram a forte presença de ruído do tipo striping principalmente nas bandas do infravermelho de ondas curtas (SWIR).

2.3 Espectrorradiometria

Conceitualmente, a radiometria pode ser definida como a ciência ou a técnica de quantificar a radiação eletromagnética (LORENZZETTI, 2002). A extração de informações contidas em imagens, multi ou hiperespectrais, fundamenta-se no conhecimento sobre como cada objeto imageado comporta-se com relação aos

fenômenos de absorção, emissão e reflexão da radiação eletromagnética (REM) interagida com tal objeto, permitindo, então, analisar os componentes e as condições dos objetos estudados (ALVARENGA *et al.*, 2005).

Para Boulomytis *et al.* (2011), o conhecimento do comportamento espectral dos diferentes alvos é de grande importância para se obter informações sobre os mesmos. Tais informações podem ser obtidas a partir de medições de instrumentos óptico-eletrônicos, conhecidos por espectrorradiômetros, os quais são capazes de representar informações sobre a resposta do alvo em forma de curvas espectrais ao longo dos comprimentos de onda do espectro eletromagnético. Desta forma, podemos conhecer a assinatura espectral de um objeto sob condições controladas, podendo-se fixar variáveis, tais como ângulo de incidência da fonte luminosa, potência do fluxo incidente, altura do sensor etc.

A importância desta técnica de sensoriamento remoto se deve ao fato dela permitir a eliminação do efeito da atmosfera na coleta de dados pelo fato da distância entre o sensor e o alvo ser mínima. Além disso, pode-se fazer uma descrição detalhada dos alvos observados, permitindo a construção de uma biblioteca de informação valiosa para a interpretação de alvos detectados e avaliados por outros sensores (BATISTA, 2005).

A radiometria de campo é uma técnica de fundamental importância para o sensoriamento remoto, tanto ao nível de pesquisa básica como aplicações operacionais (MILTON, 1987). Segundo o mesmo autor, a radiometria atua, no mínimo, em três áreas do sensoriamento remoto: primeiro, agindo como ligação entre as medidas de laboratório e as condições de campo, dessa forma, útil na calibração de sensores orbitais e aerotransportados; segundo, sendo útil tanto na predição de bandas espectrais ótimas como na configuração de visada e horário para realizar uma tarefa particular de sensoriamento remoto; terceiro, fornecendo uma ferramenta para o desenvolvimento, refinamento e teste de modelos, relacionando atributos biofísicos com os dados remotamente sensoriados.

2.4 Tratamento de dados

Um dos grandes problemas de se aplicar algoritmos computacionais em dados hiperespectrais é a possibilidade de haver multicolinearidade entre os dados de entrada e a intensidade de valores de entrada. Neste tópico, serão tratados dois

procedimentos bastante utilizados para tratamento prévio dos dados: a análise da componente principal (RODARMEL & SHAN, 2002; DU & FOWLER, 2008; GOWEN *et al.* 2008; KOOSANIT, JARUSKULCHAI & EIUMNOH 2012) e a diferenciação de dados (CARVALHO JUNIOR *et al.*, 1998; ESTEP e CARTER, 2005; RUDORFF *et al.*, 2007; TORRECILLA e PIERA, 2009).

2.4.1 Análise por Componente Principal

A análise por componentes principais (ACP) é a técnica da estatística multivariada que consiste em transformar um conjunto de variáveis originais em outro conjunto de variáveis de mesma dimensão denominadas de componentes principais, preservando a variância total dos dados originais. Os componentes principais apresentam propriedades importantes: cada componente principal é uma combinação linear de todas as variáveis originais; são independentes entre si; e são estimados com o propósito de reter, em ordem de estimação, o máximo de informação, em termos da variação total contida nos dados.

A ACP pode transformar o conjunto de dados originais em outro conjunto substancialmente menor de variáveis não correlacionadas, representando a maioria da informação no conjunto de dados originais (HOLDEN e LEDREW, 1998).

A ideia central da análise baseia-se na redução do conjunto de dados a ser analisado, principalmente quando os dados são constituídos de um grande número de variáveis inter-relacionadas. Conforme Lopes (2001), “procura-se redistribuir a variação nas variáveis (eixos originais) de forma a gerar o conjunto ortogonal de eixos não correlacionados”. Essa redução é feita transformando o conjunto de variáveis originais em um novo conjunto de variáveis, mantendo, ao máximo, a variabilidade do conjunto, isto é, com a menor perda possível de informação. Além disso, esta técnica nos permite o agrupamento de indivíduos similares, mediante exames visuais, em dispersões gráficas num espaço bi ou tridimensional de fácil interpretação geométrica.

Há vários exemplos na literatura de aplicações da componente principal aliadas a modelos computacionais para tratar dados de sensoriamento remoto.

Liu *et al.* (2010) desenvolveram um trabalho com o intuito de analisar a resposta hiperespectral de panículas de arroz em busca da identificação de plantas doentes. Para atingir este objetivo, os autores utilizaram a interação da análise das

componentes principais (ACP) aliada ao classificador SVM (máquina de vetores suporte).

A técnica ACP foi utilizada pelos autores com o intuito de obter uma redução da dimensionalidade dos dados de entrada, preservando o máximo da variância explicada. Liu et al. ressaltam que esta técnica é muito apropriada para os dados hiperespectrais pela alta dependência e autocorrelação nas bandas de frequência adjacentes. Seus resultados mostram que 99,8% da variância dos dados é explicada com a utilização das três primeiras componentes, reduzindo assim o espaço amostral utilizado para o algoritmo de classificação SVM.

O desempenho obtido na classificação utilizando a combinação entre ACP e SVM foi superior àquele sem o tratamento prévio das componentes principais, obtendo-se valores de R^2 99,14% e 98,71%, respectivamente. Esses resultados mostram que mesmo uma técnica como a rede neural do tipo SVM, que tem o potencial de gerar superfícies de classificação ótimas, podendo se ajustar muito bem aos dados de amostra, ainda tem seu rendimento acrescido com aplicação de técnicas como a ACP.

Shahin e Symons (2011), em seus estudos, investigaram o uso de sensores hiperespectrais na faixa do visível e infravermelho próximo (400-1000 nm) para detecção de grãos de trigo afetados pelo *Fusarium*.

Para auxiliar no estudo, utilizaram a avaliação da componente principal em busca da redução da dimensionalidade e, assim, facilitar as suas análises. Desses resultados, foram escolhidas as componentes que serviram de entrada para o algoritmo de classificação adotado, que foi a Análise Discriminante Linear (ADL).

Os resultados mostraram que a contribuição das 10 primeiras componentes foi de 99,9% da variância explicada e que somente as três primeiras já explicavam 99,5% da variância dos dados.

Nenhuma componente gerada foi suficiente para identificar, isoladamente, os grãos de trigo afetados pelo *Fusarium*. Os autores conseguiram separar, entre as componentes principais, características que poderiam trabalhar em conjunto para identificação do seu alvo. Através da combinação destas componentes com o algoritmo ADL, os autores conseguiram obter uma taxa de precisão de 92% dos dados de validação, mostrando assim o potencial desta técnica para classificação de grãos de trigo afetados.

2.4.2 Diferenciação de dados

Derivar uma série contínua de dados, como dados hiperespectrais, mostra-se interessante ao intérprete. Ao aplicar esta técnica, o modo de interpretação se altera. Assim, onde inicialmente se buscavam as formas de absorção ou semelhanças entre as curvas, com a análise derivativa, buscam-se os pontos de máxima variação ou de constância.

No entanto, Tsai e Philpot (1998) revelam o surgimento de vários problemas quando se aplica análise derivativa, por causa das diferenças inerentes entre análise hiperespectrais de laboratório e análise de sensoriamento remoto, especialmente por conta da diferença de textura. Estas análises são notoriamente sensíveis ao ruído. Assim, minimizar o ruído aleatório é uma questão importante. Entre os vários métodos para a suavização de dados espectrais, algoritmos baseados em ajustes mínimos quadrados são mais comumente selecionados. Talvez o método mais comum é o de Savitzky e Golay (1964), que fornece um procedimento de mínimos quadrados simplificado para simultaneamente suavizar e diferenciar os dados.

Este procedimento, Savitzky-Golay, parte da premissa de que o ruído aleatório tem características semelhantes ao longo do espectro e pode ser tratado por um processo invariante ao longo do espectro.

Kawata e Minami (1984) argumentam o fato de que o ruído aleatório normalmente varia ao longo do espectro. Assim, o ajuste de curva polinomial pode alterar a forma de onda do sinal, em vez de eliminar o ruído. Eles apresentaram uma alternativa baseada na minimização do erro quadrático-médio. O processo é essencialmente um filtro localmente variável ajustado para a proporção de locais de sinal-para-ruído, a fim de suavizar os dados.

Tsai e Philpot (1998) avaliaram estas propostas e mostraram a perda de detalhes importantes do espectro na tentativa de suavizar a curva de acordo com o procedimento dos mínimos quadrados. Os autores também testaram uma nova proposta de algoritmo utilizando um filtro de média e, após aplicação deste filtro, a utilização da derivada primeira. Este procedimento produziu melhores resultados quando aplicados os parâmetros adequados.

A técnica proposta por Tsai e Philpot (1998) consta duas etapas: filtro de suavização média (*Mean Filter Smoothing*) e aproximação finita (*Finite Approximation*).

O filtro de suavização média refere-se a aplicação de uma média móvel entre os dados do espectro contínuo, evitando a amplificação dos ruídos durante a aplicação da derivada. Um filtro de média móvel simples assume o valor espectral médio de todos os pontos dentro de um intervalo espectral específico como sendo o novo valor do ponto central deste intervalo ((1).

$$\hat{s}(\lambda_j) = \frac{\sum s(\lambda_i)}{N} \quad (1)$$

Onde N (número de pontos de amostragem) é o tamanho do filtro e j é o índice do ponto médio do filtro. Se o usuário especifica um número par de pontos como o tamanho do filtro, a média é designada com um o novo valor, aquele de comprimento de onda à direita mais próximo do centro.

A aproximação finita pode ser usada para estimar derivadas por meio de diferenças adequadas de acordo com a resolução finita de bandas, $\Delta\lambda$ (Equação (2).

$$\frac{ds}{d\lambda} \approx \frac{s(\lambda_i) - s(\lambda_j)}{\Delta\lambda} \quad (2)$$

Onde S representa a refletância do comprimento de onda λ .

Estep e Carter (2005) objetivaram detectar, por meio de imagens AVIRIS (Airborne Visible/Infrared Imaging Spectrometer), deficiência de nitrogênio e estresse hídrico na cultura do milho, comparando as abordagens: método da análise derivativa e razão de bandas. As imagens AVIRIS foram computadas em 64 bandas de absorção abrangendo o espectro entre 400 e 1035 nm. Para o método da análise derivativa foram selecionados 12 locais no espectro e foi calculada a derivada primeira e segunda. Para os métodos de razão de bandas foram selecionados diversos modelos para detecção de pigmentos e considerados bons indicadores de detecção de nitrogênio. Os autores observaram que, de acordo com a derivada primeira, o comprimento de onda de 568 nm manteve-se insensível à variação de umidade e que sua derivada segunda identificou todos os tratamentos de N.

Os autores mostraram assim, como uma grande vantagem da análise derivativa, diminuir a interferência da umidade e ressaltar os efeitos dos elementos do solo, uma vez que na análise derivativa são ressaltadas as tangentes do comportamento do espectro e que a umidade afeta inteiramente o espectro.

Este mesmo procedimento foi utilizado por Rudorff *et al.* (2007) em estudos na região da Amazônia com o objetivo de avaliar o desempenho da análise derivativa para avaliar dados de água, confrontando diretamente dados de campo e de laboratório.

O foco principal da pesquisa era demonstrar a eficiência desta técnica para estimar a distribuição espacial da concentração de sedimentos inorgânicos em suspensão e de clorofila-a em relação ao uso de valores originais de reflectância.

Cheng *et al.* (2013), avaliaram o desempenho da análise derivativa a partir de comprimento de ondas suavizados para detectar a presença de clorofila-a em água no lago de Taihu e na baía de Meiliang. O passo mais importante na suavização consta em observar a largura da janela do filtro, o qual, quanto maior, mais suavizada será a resposta. Os autores observaram boas respostas com largura de janela entre 5 e 13 nm. Outra observação é que na medida em que se aumenta o tamanho da janela, parte da informação que o espectro pode fornecer é perdida ou suavizada, mostrando assim a importância de se escolher bem esta janela.

Os autores acima citados perceberam ainda, em suas análises, que a derivada espectral pode observar informações detalhadas em relação às bandas de absorção. No entanto, o ruído ocasionado pelo ambiente pode aumentar. Comparando o desempenho do modelo da derivada em relação a outros modelos para identificação da clorofila foi observado que a derivada primeira tem desempenho inferior para os dados de calibração, no entanto, o seu desempenho é melhorado quando se aumenta o número de bandas para compor o ajuste.

2.5 Algoritmos Computacionais de Ajuste (Data Fitting)

Processar imagens de sensoriamento remoto hiperespectral devida à alta dimensionalidade dos dados é uma tarefa desafiadora para os algoritmos tradicionais. Normalmente, várias centenas de bandas espectrais são adquiridas para cada imagem. Estas bandas podem proporcionar ricas informações espectrais em cada pixel, importantes para identificar ou quantificar características relacionadas ao material dos alvos. No entanto, a informação espectral sozinha, por vezes, não permite a separação dos componentes (LUO e CHANUSSOT, 2009).

A definição do melhor método de ajuste a ser aplicado a um conjunto de dados depende não somente dos dados em si, como também da relação entre custo computacional e taxa de acerto.

Nos tópicos a seguir serão realizadas descrições mais detalhadas dos métodos de ajuste alvos deste estudo, consagrados na literatura em estudos de avaliação de dados hiperespectrais. Serão descritos os seguintes métodos: o método dos mínimos

quadrados (ZHAO e ZHANG, 2009; ZHANG *et al.*, 2010), modelos de regressão não linear como o perceptron de múltiplas camadas - MLP (LICCIARDI e FRATE 2010; PLAZA E PLAZA, 2010; KUMAR *et al.*, 2011; SANTOS *et al.*, 2013; TINOCO *et al.*, 2013) e a máquina de aprendizagem extrema - ELM (BROADWATER e BANERJEE, 2013; BAZI *et al.*, 2014; SAMAT *et al.*, 2014).

2.5.1 Mínimos Quadrados (MQ)

O método dos mínimos quadrados é um dos mais utilizados modelos lineares, tanto para classificação quanto para obtenção de equações de regressão de equações. Andrade (2005) compreende o método como sendo um estimador, atuando na parametrização de uma função $Y = f(X)$ por meio de um vetor de n parâmetros θ .

Na forma matricial a relação de Y , θ e X pode ser expressa na forma da equação (3).

$$Y_{n,1} = \theta_{n,m} X_{m,1} \quad (3)$$

Em que Y é o vetor de variáveis dependentes, X o vetor de variáveis independentes e θ a matriz de transformação. Sendo X não singular, é possível determinar o vetor de parâmetros através da equação ((4) após obtida a inversa de X .

$$\theta = YX^{-1} \quad (4)$$

No entanto, nem todos os sistemas contêm uma matriz inversível, principalmente, as matrizes retangulares. Com isso, o método dos mínimos quadrados tem sido alvo de constante estudo para ser resolvido o problema do cálculo da sua inversa. Neste sentido, o matemático russo Tikhonov desenvolveu um processo matemático, conhecido como regularização de Tikhonov, onde é aplicado um conjunto de operações matriciais com a utilização da matriz transposta X^T (EQUAÇÕES (5) e (6)). Este processo é também conhecido como inversão de matriz por pseudo inversa (FUHRY, 2011).

$$Y = X \theta \quad (5)$$

$$X^T Y = X^T X \theta \quad (6)$$

$$\theta = [X^T X]^{-1} X^T Y \quad (7)$$

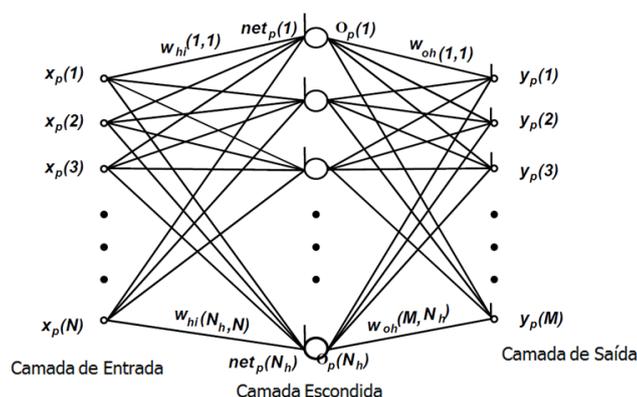
2.5.2 Perceptron de Múltiplas Camadas (MLP)

De acordo com Delashmit (2005), as redes neurais artificiais (RNA) tipo MLP consistem de unidades dispostas em camadas. Cada camada contém nós e, nas redes totalmente conectadas, cada nó se conecta a cada outro em camadas subsequentes,

sendo esta composta por um mínimo de três camadas, constituídas por uma camada de entrada, uma ou mais camada(s) escondida(s) e uma camada de saída.

A camada de entrada distribui as entradas para as camadas subsequentes. Nós de entrada têm funções de ativação lineares e sem limites. Cada nó da unidade escondida e cada nó de saída têm limiares associados, em adição aos seus pesos de ajuste. Os nós de unidades escondidas têm funções de ativação não-lineares e as saídas têm funções de ativação lineares. Assim, cada sinal de alimentação para um nó em uma camada posterior tem a entrada original multiplicada por um peso com um limiar adicional e, em seguida, é passada por meio de uma função de ativação, podendo ser escondida, lineares ou não lineares. Uma rede típica de três camadas é mostrada na Figura 1 (DELASHMIT, 2005).

Figura 1 – Esquema geral de uma rede neural artificial do tipo MLP



Fonte: Adaptado de DELASHMIT (2005).

De acordo com Braga (2000), há diversos algoritmos de treinamento disponíveis e o método e a velocidade do ajuste dos pesos depende do tipo utilizado. Os algoritmos de treinamento podem ser vistos como algoritmos de otimização que promovem a minimização da função erro, definida em relação aos valores esperados na saída, obedecendo aos limites de tolerância pré-estabelecidos.

Dentre as diferentes técnicas de otimização aplicáveis, o algoritmo Backpropagation tem mostrado excelentes resultados.

Algoritmo provê um aprendizado supervisionado, isto é, ele procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, segundo um erro mínimo, ajustando os pesos entre as camadas através da

retropropagação do erro encontrado em cada iteração (VIEIRA e ROISENBERG, 2000).

Morais (2009) relatou o algoritmo neural como tendo quatro passos. No primeiro ocorre a introdução dos dados a rede neural. Nesta etapa é definido o número de camadas, número de neurônios em cada uma das camadas e a introdução dos pesos e limiares (bias) de maneira randomizada. Nesta etapa também são definidos os critérios de parada do treinamento, sendo estes: o número de épocas e/ou o erro mínimo aceitável.

No segundo passo é apresentado o vetor de entradas ($X_j, j = 0, 1, 2, \dots, n$) e a saída desejada (Y_o). Cada unidade de entrada transmite o sinal recebido para a primeira camada intermediária, e da mesma forma, entre as camadas intermediárias e a camada de saída. Em cada unidade de processamento uma combinação linear é realizada, alimentando a função de ativação executada.

No presente estudo, a função de ativação a ser utilizada será a do tipo sigmoide logística, equação (8), na qual, os dados se ajustam entre os valores de 0 e 1. Uma camada recebe uma soma ponderada de todos os valores recebidos dos nós da camada anterior multiplicados pelos pesos de suas respectivas conexões.

$$Y_k = \frac{1}{1 + \exp(-u_k)} \quad (8)$$

Onde Y_k representa a saída obtida pelo neurônio “k”, u_k a resposta obtida pelo somatório ponderado de todas as conexões e os pesos deste neurônio “k”.

O terceiro passo é definido pela retropropagação do erro. Inicialmente se calcula o erro entre o valor obtido pela rede e o valor da resposta desejada, EQUAÇÃO (9). Posteriormente, calcula-se a sensibilidade da camada de saída (σ_s) para a função sigmoide logística, equação (10). Com isso é possível realizar a atualização dos pesos das conexões da camada de saída, equação (11).

$$\text{Erro} = Y_o - Y_e \quad (9)$$

Onde Y_o representa a saída desejada utilizada para o treinamento; Y_e a saída obtida pela RNA.

$$\sigma_s = -\text{erro} \times Y_e \times (1 - Y_e) \quad (10)$$

Onde σ_s representa a sensibilidade da camada de saída.

$$W_{i+1} = W_i - (\alpha \times \sigma \times X_j) \quad (11)$$

Onde o W_{i+1} representa o peso da conexão após a atualização, W_i o peso antes da atualização, α a taxa de aprendizagem (parâmetro definido pelo programador, com valor entre 0 e 1,0), X_j o valor de entrada para a j -ésima conexão.

O processo de atualização das camadas anteriores é semelhante: é calculada a sensibilidade de cada neurônio da camada anterior, equação (12), e utilizado a equação (11) para a atualização dos pesos desta conexão.

No quarto passo é calculado o erro quadrático médio (EQM), obtido pela equação (13). Com isso são aplicados os critérios de parada da rede e se algum dos critérios for alcançado é determinado o fim da etapa de treinamento, se não ocorrer, a rede retorna ao segundo passo e repetem-se os passos 3 e 4.

São dois os critérios de parada adotados: EQM atingido inferior ao mínimo aceitável; e o número de época de treinamento, representado pelo segundo e terceiro passos, foi atingido.

$$\sigma_j = Y_j \times (1 - Y_j) \times W_i \times \sigma_i \quad (12)$$

Onde σ_j representa a sensibilidade do neurônio “j”, Y_j o valor de saída deste neurônio, W_i o peso da conexão deste neurônio para a camada posterior e σ_i a sensibilidade da camada posterior.

$$EQM = \frac{\sum_{i=1}^n (Y_o - Y_e)^2}{n} \quad (13)$$

Onde o EQM representa o erro quadrado médio; n o número de observações de treinamento; Y_o a saída desejada utilizada para o treinamento; Y_e a saída obtida pela RNA.

Makantasis *et al.* (2015) avaliaram o desempenho de classificação da rede MLP na classificação de diferentes tipos de solo, aplicando a imagens hiperespectrais dos sensores AVIRIS e ROSIS. As imagens AVIRIS foram coletadas na região noroeste de *Indiana* e na região oeste da Califórnia, ambos nos Estados Unidos. A imagem ROSIS foi coletada na região central de Pavia, na Itália. Os autores mostraram a eficiência que o modelo MLP possui em classificar solos utilizando imagens hiperespectrais obtendo acurácia superior a 95%.

2.5.3 Máquina de Aprendizagem Extrema (ELM)

O algoritmo de máquina de aprendizagem extrema foi proposto por Huang *et al.* (2006) como uma forma original de construção de uma rede neural feedforward

com uma única camada escondida. Dado um conjunto de observações de $N(x_i, y_i)$, $i \leq n$, com $x_i \in \mathbb{R}^p$ e $y_i \in \mathbb{R}$. A rede neural com m neurônios na camada oculta pode ser expressa pela equação (14).

$$\sum_{i=1}^m \beta_i f(\omega_i x_j + b_i), 1 \leq j \leq n \quad (14)$$

Onde β_i são os pesos de saída, f a função de ativação, ω_i os pesos das entradas e b_i os bias. Supondo-se um o modelo que descreve perfeitamente os dados, a relação funcional do ELM pode ser escrita na forma matricial como $H\beta = y$, sendo:

$$\mathbf{H} = \begin{pmatrix} f(\omega_1 x_1 + b_1) & \dots & f(\omega_m x_1 + b_m) \\ \vdots & \ddots & \vdots \\ f(\omega_1 x_n + b_1) & \dots & f(\omega_m x_n + b_m) \end{pmatrix} \quad (15)$$

$$\beta = (\beta_1, \beta_2, \dots, \beta_m)^T \quad (16)$$

$$y = (y_1, y_2, \dots, y_m)^T \quad (17)$$

A ELM tem início com a inicialização aleatória de ω_i e b_i e procede com o cálculo dos pesos de saída pelo método da pseudo-inversa, conforme descrito no tópico dos mínimos quadrados (Equação (7)). A essência da ELM é a não necessidade de um processo iterativo para o ajuste dos pesos da camada intermediária, além disso, o erro de treinamento $\|H\beta - y\|$ e a norma dos pesos $\|\beta\|$ são minimizados (Huang *et al.* 2006).

Por conta destas características, a ELM tem se destacado por dois fatores: grande velocidade de aprendizagem e excelente capacidade de generalização dos dados (YU, 2013).

A literatura relata alguns exemplos mostrando o potencial desta técnica em imagens hiperespectrais. Um exemplo é o estudo de Li *et al.* (2015) que investiga a eficiência desta técnica analítica em estimar diferentes classes de solo utilizando 3 imagens hiperespectrais, quais sejam: o sensor Aviris obtida da região de Indian Pines no estado da Alabama, o sensor ROSIS na região da universidade de Pavia na Itália e o sensor Aviris na região do Salinas Valley na Califórnia. Os autores relataram como vantagem da ELM em relação às outras estratégias não lineares a sua facilidade de programação, sendo o único parâmetro necessário, o número de neurônios na sua camada intermediária, conseguindo bons resultados, obtendo acurácia superior a 79%.

Zhou, Peng e Chen (2015) também avaliaram o desempenho da rede ELM para estimar classes de solos em comparação a rede neural máquina de vetor suporte (SVM), em imagens do sensor AVIRIS na região de *Indian Pines* e do *Salinas Valley*. Os autores observaram o desempenho superior do modelo ELM em relação ao SVM na maioria dos testes realizados, tanto na precisão da classificação quanto na velocidade de sua aplicação.

3 ESTRATÉGIA METODOLÓGICA PARA RESPONDER ÀS HIPÓTESES

Visando à avaliação das hipóteses propostas, adotou-se como estratégia metodológica a divisão do trabalho em três etapas.

A primeira etapa foi intitulada “Estimativa de condutividade elétrica de extrato de saturação por meio de solução 1:1”. As amostras de campo foram coletadas em duas (02) datas: 12/05/2015 e 31/08/2015. Devido à ausência de um equipamento adequado para medição dos altíssimos níveis de salinidade encontrados na área experimental (CEes > 90 dS/m) e ao longo tempo necessário para obtenção do extrato de saturação de todas as amostras, buscou-se a correlação entre os dados de CEes e os dados da condutividade elétrica da solução 1:1 para aplicação nas demais etapas da pesquisa.

Na segunda etapa, intitulada “Avaliação de modelos matemáticos na determinação da condutividade elétrica de solos salinos por meio de dados hiperespectrais”, foram testados diferentes modelos computacionais e as diferentes estratégias de tratamento dos dados na busca de correlações entre as curvas espectrais obtidas em laboratório e a CE das amostras de solo medida em laboratório. Foi escolhida a melhor estratégia para obtenção da CE do solo por meio da curva espectral.

A terceira etapa da pesquisa foi denominada “Avaliação do desempenho de modelos computacionais calibrados em laboratório, na determinação da condutividade elétrica de solos por meio de imagens hiperespectrais obtidas por sensor aerotransportado”. Comparou-se o desempenho do modelo obtido em laboratório (Etapa 2) com o modelo calibrado com os dados da imagem do sensor SpecTIR.

4 ESTIMATIVA DE CONDUTIVIDADE ELÉTRICA DE EXTRATO DE SATURAÇÃO POR MEIO DE SOLUÇÃO 1:1

4.1 Introdução

A condutividade elétrica do extrato de saturação do solo (CE_{es}) é um dos atributos mais importantes na caracterização de solos afetados por sais, sendo este parâmetro usado para a distinção dos solos salinos e não salinos (PEREIRA *et al.*, 1981). O processo convencional de se obter o extrato de saturação ocorre através da medição da condutividade elétrica na pasta de saturação. Entretanto a obtenção desta pasta é um procedimento demorado, requerendo equipamentos como bombas de vácuo, funis de porcelana e frascos Kitasato, e, portanto, não é adequada para as determinações fora do laboratório, ou em locais com recursos limitados ou mesmo quando os dados são necessários no curto prazo (ZALBA *et al.*, 2013).

Ao contrário do extrato de saturação, o método de solução 1:1 ($CE_{1:1}$) não tenta simular as condições naturais do solo. No entanto, devido à consistência na quantidade de água utilizada e a natureza objetiva do método, a solução 1:1 pode reduzir as dificuldades de preparação da amostra e sua reprodutibilidade, frequentemente encontradas com o extrato de saturação.

Os valores de condutividade elétrica (CE) obtidos nas concentrações 1:1 são tipicamente menores do que os obtidos pelo extrato de saturação, devido a maior quantidade de água na diluição em relação ao método CE_{es} . Contudo, a praticidade, a redução de tempo e menor investimento necessário tem levado muitos pesquisadores a utilizarem a $CE_{1:1}$ como alternativa à CE_{es} (ZHANG *et al.*, 2005).

De acordo com Sonmez *et al.* (2008), pode haver uma conversão entre os dados de CE obtidos pelo extrato de diluição 1:1 e pelo extrato de saturação, no entanto, os autores não encontraram repetitividade nas respostas durante a etapa de validação. Uma possível causa dessa queda no rendimento dos modelos computacionais para os dados de validação pode ser devido ao baixo desempenho dos modelos lineares no ajuste dados de CE, sendo importante avaliar o desempenho de modelos não lineares nestes ajustes.

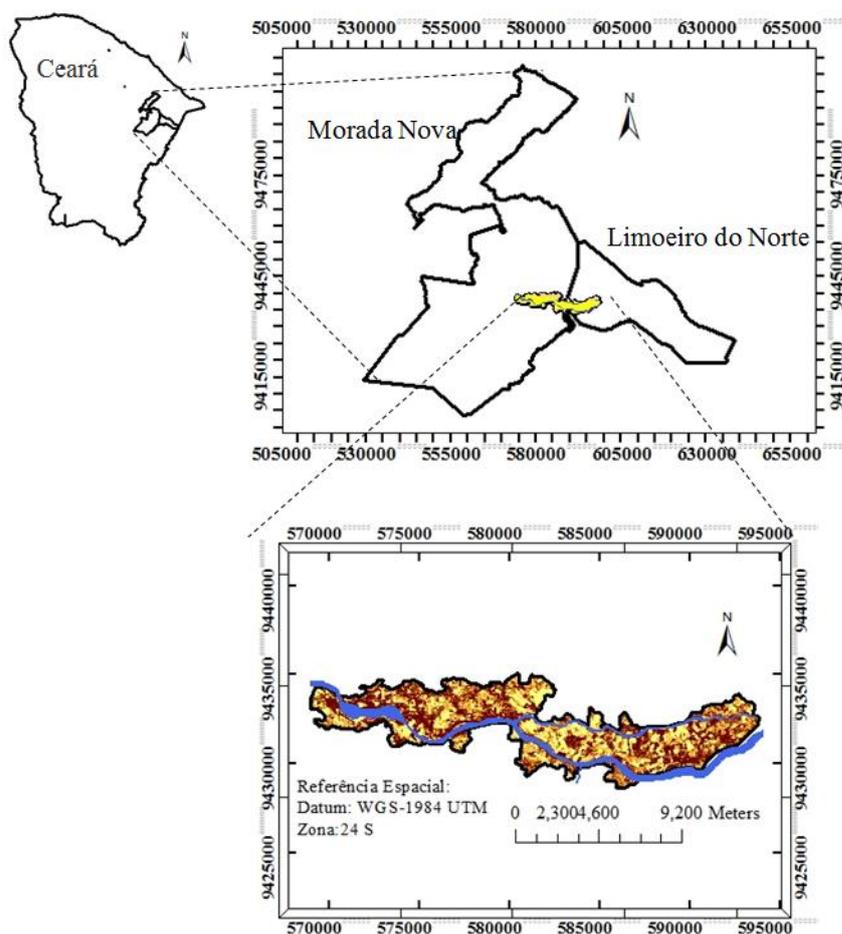
Com isto, o objetivo deste tópico é avaliar o desempenho de modelos computacionais de regressão lineares e não lineares no ajuste de dados obtidos pelo extrato de saturação do solo a partir das medidas feitas em 1:1 (solo:água).

4.2 Material e Métodos

Área de Estudo e amostragem

A área de estudo é o Distrito de Irrigação Morada Nova que está localizado nos municípios de Morada Nova e Limoeiro do Norte (Figura 2), estado do Ceará, na micro-região do Baixo Jaguaribe, sub-vale Banabuiu, a 170 km de Fortaleza, centrado nas coordenadas geográficas $5^{\circ} 06' S$ e $38^{\circ} 23' W$ e a 80 m de altitude.

Figura 2 – Área de Estudo (Perímetro Irrigado Morada Nova)



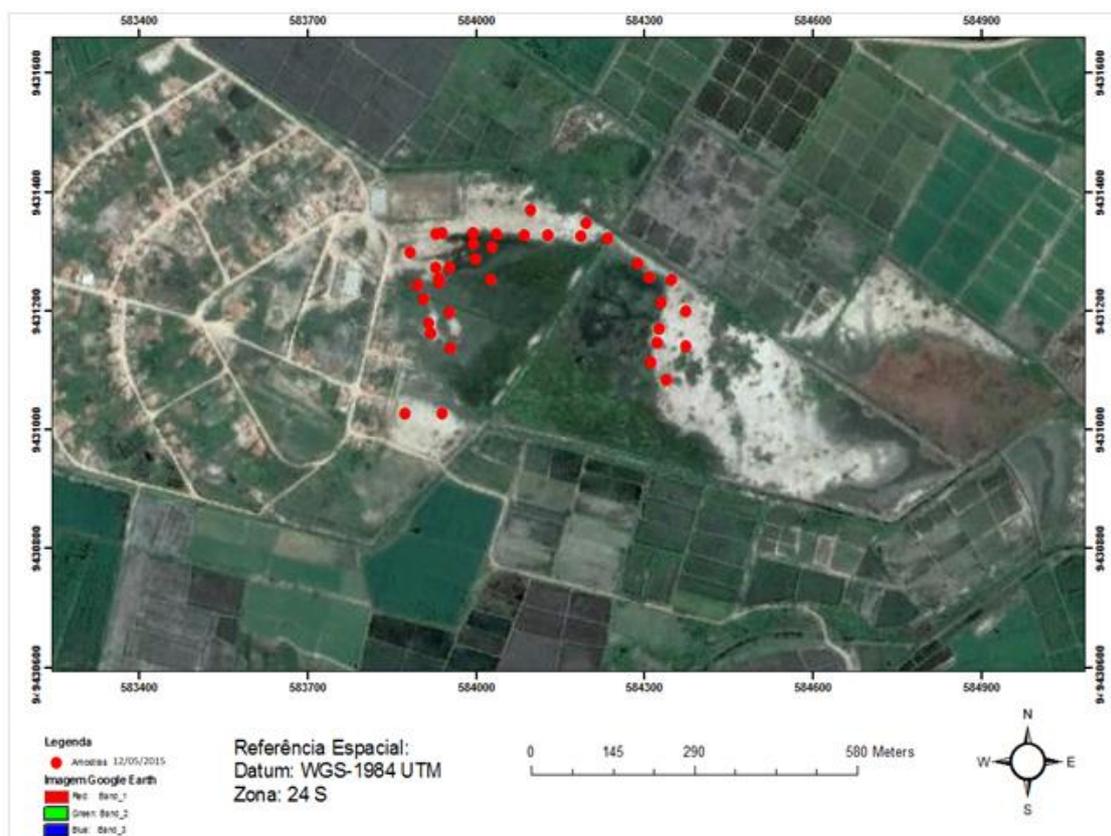
Fonte: Adaptado de Moreira (2014).

Dentro do Distrito de Irrigação foi selecionada uma área experimental com histórico de problemas relacionados a salinidade (Figura 3) e foram escolhidos pontos amostrais onde há altas variações da condutividade elétrica. Desta área, foram coletadas 46 amostras de solo da camada superficial de 0 a 10 cm, levadas para laboratório,

homogeneizadas, trituradas e passadas em peneira de 2 mm para produção de amostra padrão para a análise de CE.

Os valores de CE foram obtidos em laboratório em dois procedimentos, o primeiro pelo extrato de saturação por meio de bomba de vácuo e condutímetro de bancada; o segundo pela leitura em condutímetro de bancada na solução 1:1 (amostra do solo : água destilada).

Figura 3 – Pontos amostrais coletados no dia 12/05/2015, imagem obtida pela plataforma Google Earth



Fonte: Autor.

Modelos Computacionais

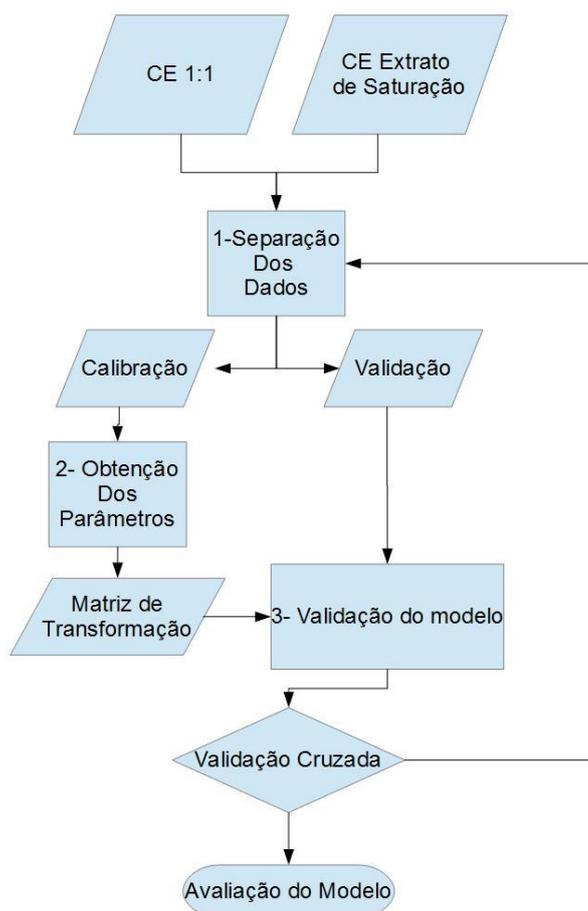
Os dados gerados pelas rotinas de laboratório descrito acima (CE) foram processados no programa MATLAB versão 7.9. O procedimento de análise realizado está descrito no fluxograma da Figura 4.

O processo 1 (separação dos dados), consta na etapa onde são selecionados os conjuntos de dados de CE1:1 e CEes para calibração e para a validação.

O processo 2 (obtenção dos parâmetros) consta na etapa onde os modelos são calibrados e obtidas as matrizes de transformação. Foram avaliados: o modelo linear dos Mínimos Quadrados (MQ) e os modelos não lineares do Perceptron de Múltiplas Camadas (MLP) e Máquina de Aprendizagem Extrema (ELM).

Para a avaliação da rede neural do tipo MLP foram adotados os seguintes parâmetros: 5 neurônios na camada intermediária, pesos obtidos aleatoriamente, taxa de aprendizagem de 95%, função de ativação sigmoide logística e 5.000 épocas de aprendizagem. Para o modelo não linear tipo ELM, foram utilizados os seguintes parâmetros: 5 neurônios na camada intermediária, pesos obtidos aleatoriamente, função de ativação sigmoide logística.

Figura 4 – Fluxograma mostrando o processo de calibração e validação dos modelos computacionais



Fonte: Autor.

Validação

O processo 3 do fluxograma da Figura 4 refere-se a etapa de validação dos modelos testados.

Os modelos foram validados de acordo com as seguintes métricas estatísticas: coeficiente de determinação (r^2), erro quadrático médio (EQM), coeficiente de pearson (r), índice de concordância de Willmott (id), índice de desempenho (c) e a taxa de desvio da performance (RPD). O coeficiente de determinação foi calculado utilizando-se a base dos dados de calibração, já nas demais métricas foram utilizadas os conjuntos de dados de validação. As respectivas equações das métricas são apresentadas a seguir:

$$R^2 = \frac{\sum_{i=1}^N (Y_{c_i} - \bar{Y}_c)}{\sum_{i=1}^N (Y_{o_i} - \bar{Y}_o)} \quad (18)$$

$$EQM = \frac{\sum_{i=1}^N (Y_{c_i} - Y_{o_i})^2}{N} \quad (19)$$

$$r = \frac{N \times \sum_{i=1}^N (Y_{c_i} - Y_{o_i})^2 - \sum_{i=1}^N Y_{o_i} \times \sum_{i=1}^N Y_{c_i}}{\sqrt{[N \times \sum_{i=1}^N Y_{o_i}^2 - (\sum_{i=1}^N Y_{o_i})^2] \times [N \times \sum_{i=1}^N Y_{c_i}^2 - (\sum_{i=1}^N Y_{c_i})^2]}} \quad (20)$$

$$Id = 1 - \frac{\sum_{i=1}^N (Y_{c_i} - Y_{o_i})^2}{\sum_{i=1}^N (|Y_{c_i} - \bar{Y}_o| + |Y_{o_i} - \bar{Y}_o|)^2} \quad (21)$$

$$c = r \times Id \quad (22)$$

$$RPD = \frac{SD(Y_o)}{\sqrt{EQM}} \quad (23)$$

Em que EQM representa o erro quadrático médio; Y_c o valor calculado, Y_o o valor observado, N o tamanho total da amostra e $SD(Y_o)$ o desvio padrão do conjunto dos dados observados. As tabelas a seguir foram utilizadas para as interpretações dos índices utilizados.

Tabela 3 – Interpretação do Coeficiente de Pearson (r).

Valor (em módulo)	Interpretação
Superior a 0,9	Correlação muito forte
Entre 0,7 e 0,9	Correlação forte
Entre 0,5 e 0,7	Correlação moderada
Entre 0,3 e 0,5	Correlação fraca
Inferior a 0,3	Sem Correlação

Fonte: Mukaka (2012).

Tabela 4 – Interpretação do Índice de Desempenho (c).

Valor	Interpretação
Superior a 0,85	Ótimo Desempenho
Entre 0,76 e 0,85	Muito Bom Desempenho
Entre 0,66 e 0,75	Bom Desempenho
Entre 0,61 e 0,65	Desempenho Mediano
Entre 0,51 e 0,60	Desempenho Sofrível
Entre 0,41 e 0,50	Mau Desempenho
Inferior a 0,40	Péssimo Desempenho

Fonte: Silva e Souza (2011).

Tabela 5 – Interpretação da Taxa de Desvio da Performance (RPD).

Valor	Interpretação
Maior que 2,0	Bom modelo
Entre 1,4 e 2,0	Modelo Satisfatório
Menor que 1,4	Modelo Não Confiável

Fonte: Chang *et al.* (2001).

Devido ao tamanho pequeno das amostras, foi aplicado o método de validação cruzada “leave-one-out” no processo de validação dos modelos.

Na validação cruzada, às vezes chamada de estimativa de rotação, o conjunto total de dados é aleatorizado e dividido em subgrupos. Considerando o número k de subgrupos adotados, os modelos utilizados são repetidos k vezes e em cada repetição é utilizado um subgrupo para validar os modelos que ainda não foram utilizados para validação e os demais subgrupos são utilizados para calibração dos modelos. O resultado final dos parâmetros de calibração é igual a média dos resultados das k passagens realizadas.

A validação cruzada “leave-one-out” é um caso especial de validação cruzada onde o número k é igual ao total de amostras disponíveis. Sendo assim, em cada passagem do modelo, os dados de validação formam um conjunto unitário.

4.3 Resultados e Discussão

Análise dos dados

Foram aplicados o teste de normalidade de Kolmogorov-Smirnov com nível de confiança de 95% para as amostras de CE 1:1 e de CE_{es} .

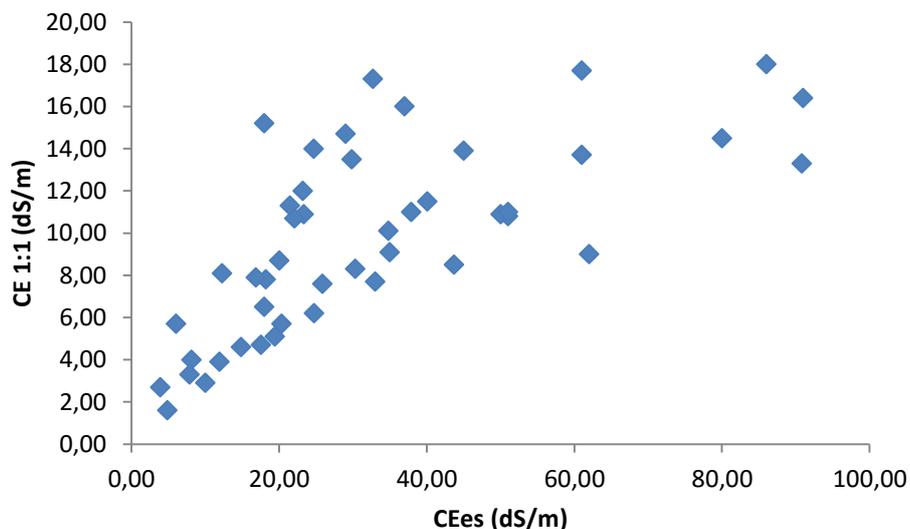
As amostras de CE 1:1 seguem uma distribuição normal, apresentando valores médios de 9,73 dS/m e desvio padrão de 4,40 dS/m, já a CE_{es} , com média de 31,61 dS/m e desvio padrão de 22,45 dS/m, não seguiu uma distribuição de acordo com o teste de normalidade aplicado.

O alto desvio padrão mostra como existe uma alta dispersão das amostras resultante da grande variabilidade na condutividade elétrica presente na região. As amostras coletadas foram provenientes de áreas fortemente degradadas pelo processo de irrigação por inundação no plantio de arroz e foram abandonadas porque apresentam muitos problemas de salinização, como relatado em outras áreas do mesmo perímetro irrigado por Moreira; Teixeira e Galvão (2014).

Na Figura 5 contendo o gráfico de dispersão entre os dados de CE 1:1 e de CE_{es} , pode-se observar que na primeira metade do gráfico (valor da abcissa entre 0 e 40 dS/m) os dados seguem uma tendência linear, no entanto, o nível de dispersão aumenta na metade final (abcissa superior a 40 dS/m).

O teste de correlação de Pearson foi de 0,69 sendo considerada como uma correlação moderada. Observa-se que a baixa correlação ocorreu especialmente por causa da alta dispersão encontrada nos valores de CE_{es} superiores a 40 dS/m.

Figura 5 – Dispersão dos dados das amostras de condutividade elétrica do solo onde a abcissa representa as leituras de CE_{es} e a ordenada representam a CE 1:1



Fonte: Autor.

Avaliação dos modelos

Como observado na Tabela 6 não houve grandes diferenças nas métricas obtidas pelos três modelos avaliados, e com maior atenção observa-se que os parâmetros apresentaram os mesmos valores nos modelos dos mínimos quadrados (MQ) e na máquina de aprendizagem extrema (ELM). Esse resultado mostra que a transformação da CE 1:1 para CE do extrato de saturação se enquadra como um problema linearmente separável.

Tabela 6 – Validação dos algoritmos computacionais para converter condutividade elétrica 1:1 em condutividade elétrica do extrato de saturação

	R²	EQM	r	Id	C	RPD
MQ	0,55	181,71	0,71	0,82	0,59	1,44
MLP	0,54	237,47	0,68	0,80	0,54	1,26
ELM	0,55	181,71	0,71	0,82	0,59	1,44

Onde: R²- coeficiente de determinação; EQM – erro quadrático médio; r – coeficiente de Pearson; Id – índice de concordância de Willmott; C – índice de desempenho; RPD – taxa de desvio da performance. Fonte: Autor.

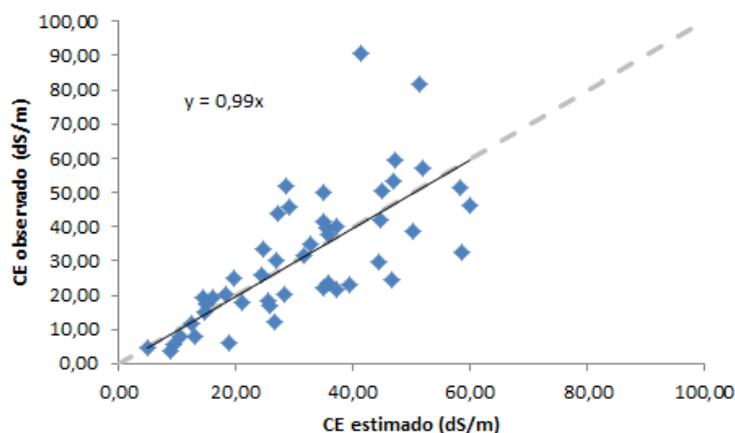
Observa-se também que embora o resultado do coeficiente de correlação anuncie que o modelo possua uma forte correlação (entre 0,7 e 0,9) a resposta do índice

de desempenho (C) mostra que o modelo é sofrível (com valor entre 0,51 e 0,60). Resultado semelhante foi observado com a resposta de RPD obtido, uma vez que de acordo com Cheng *et al.* (2001), um valor entre 1,40 e 2,00 é referente a um modelo que mostra tendência, mas há necessidade de se modificar a estratégia para se conseguir um melhor ajuste.

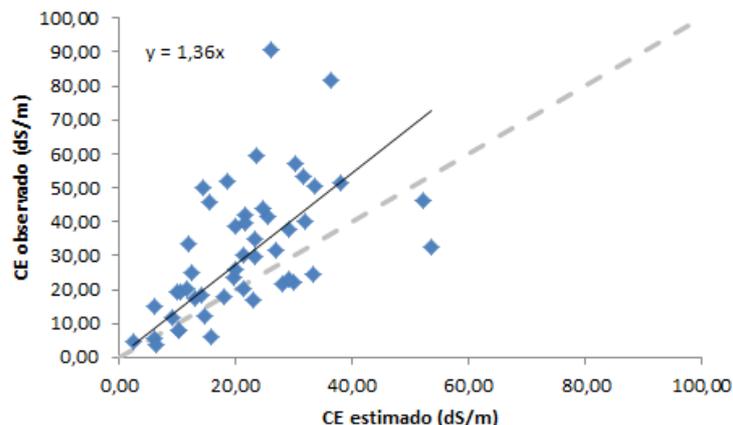
Na Figura 6 observa-se a relação entre os valores estimados e os valores observados da condutividade elétrica do extrato de saturação. Observa-se que o método dos mínimos quadrados não diferiu do método da máquina de aprendizagem extrema, não havendo mudança na resposta do método com a transformação não linear aplicada. Observa-se também que o rendimento do método da rede neural artificial do tipo perceptron de múltiplas camadas foi inferior aos demais, com a linha de tendência possuindo uma tangente superior a um, mostrando assim que o modelo subestima os valores reais.

Figura 6 – Regressão linear entre os valores de CE do extrato de saturação estimado e observado, sendo A para o modelo dos mínimos quadrados, B para o modelo RNA do tipo MLP e C para o modelo RNA do tipo ELM

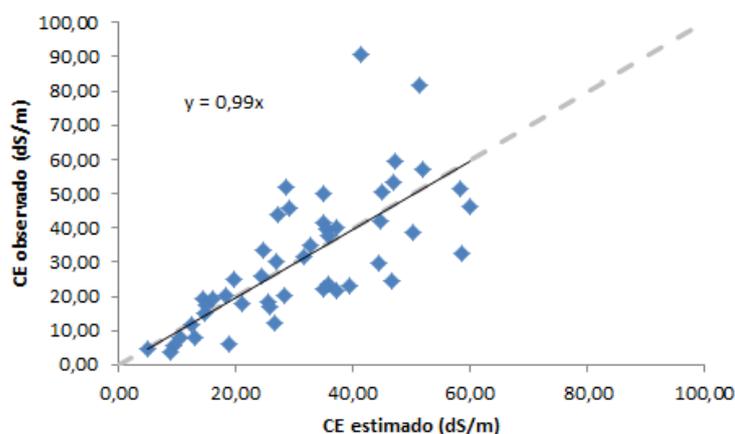
A



B



C



Fonte: Autor.

Zalba *et al.* (2013), reportaram altos valores de coeficiente de determinação ($R^2 > 90\%$) na estimativa da CE do extrato de saturação por meio de extratos mais diluídos. No entanto, os valores de CE_{es} analisados se restringiam aos valores 0 a 20 dS/m, podendo haver, nesse intervalo, uma correlação maior do que a encontrada no presente estudo, onde foram observados valores de CE de até 90,8 dS/m.

He *et al.* (2013), ao tentar estimar a condutividade elétrica por meio de extrato de 1:5 com diferentes abordagens, obtiveram o coeficiente de determinação entre 66 e 75%, mas como no caso anterior, as amostras que os autores avaliaram se tinham CE entre 0 e 20 dS/m. Os autores comentam, ao segmentar os grupos, que naqueles pontos com $CE < 4,0$ dS/m, o desempenho do modelo aumentava substancialmente, onde o R^2 chegou a atingir até 0,93, enquanto usando as amostras superiores a 4,0 dS/m o desempenho dos modelos caiu, ficando entre 0,49 e 0,60.

4.4 Conclusões

Conclui-se que para a faixa de CE estudada (entre 4 e 91 dS/m), o uso de modelos não lineares não oferece melhorias de desempenho em relação ao modelo linear dos mínimos quadrados.

Conclui-se também que, apesar de produzir fortes correlações, os modelos computacionais testados não foram satisfatórios para estimar a condutividade elétrica do extrato de saturação (na faixa de 4 a 91 dS/m) a partir dos dados de CE 1:1.

Recomenda-se que seja intensificada a amostragem do extrato de saturação na faixa de 0 a 4 dS/m na busca de melhores correlações entre CE_{es} e CE1:1.

Como os modelos não foram eficientes para estimar a CE_{es} e tendo em vista a dificuldade operacional na obtenção da CE_{es}, será adotada a CE 1:1 como variável característica da condutividade elétrica do solo nos tópicos 7 e 8 desta tese.

5 AVALIAÇÃO DE MODELOS MATEMÁTICOS NA DETERMINAÇÃO DA CONDUTIVIDADE ELÉTRICA DE SOLOS SALINOS POR MEIO DE DADOS HIPERESPECTRAIS.

5.1 Introdução

A degradação da terra ou um declínio na qualidade da terra causado por atividades humanas, tornou-se uma importante questão global (ESWARAN *et al.*, 2001). Salinização, alcalinização, alagamento e erosão do solo são os principais processos de degradação que levam ao aparecimento de extensas áreas degradadas. Os solos afetados por sais devido à salinização e alcalinização (METTERNICHT e ZINCK, 2003) são as principais causas da degradação de áreas irrigadas em regiões áridas e semiáridas. Estes sais influenciam negativamente as propriedades do solo e resultam na redução do rendimento das culturas e da produtividade da terra (DEHAAN e TAYLOR, 2002).

Informações sobre a distribuição espacial e tendências na expansão e gravidade da salinidade são vitais para o monitoramento e gestão desses solos (KUMAR *et al.*, 2014).

O sensoriamento remoto, devido ao custo acessível e a capacidade de fornecer informações espaciais rapidamente em grandes áreas, é uma alternativa atrativa para avaliação de solos afetados por sais (MASHIMBYE *et al.*, 2012). No entanto, muitos estudos apontam a importância de interpretar dados de alta resolução espectral para ter-se, por exemplo, uma boa detecção da salinidade do solo (DEJAR *et al.*, 2008; HIVELY *et al.*, 2011; KOBAYASHI *et al.*, 2013; YAO *et al.*, 2013).

A interpretação de dados hiperespectrais requer um cuidado especial, uma vez que cada sensor possui características distintas, principalmente quanto à largura de bandas e a multicolinearidade é uma característica comum nos dados.

Com isso, o objetivo deste tópico é avaliar o desempenho de diferentes estratégias computacionais como: modelo linear dos mínimos quadrados e não lineares como a rede neural artificial do tipo perceptron de múltiplas camadas e do tipo máquina de aprendizagem extrema, assim como estratégias de transformação dos dados como a análise da componente principal e análise derivativa na estimativa da

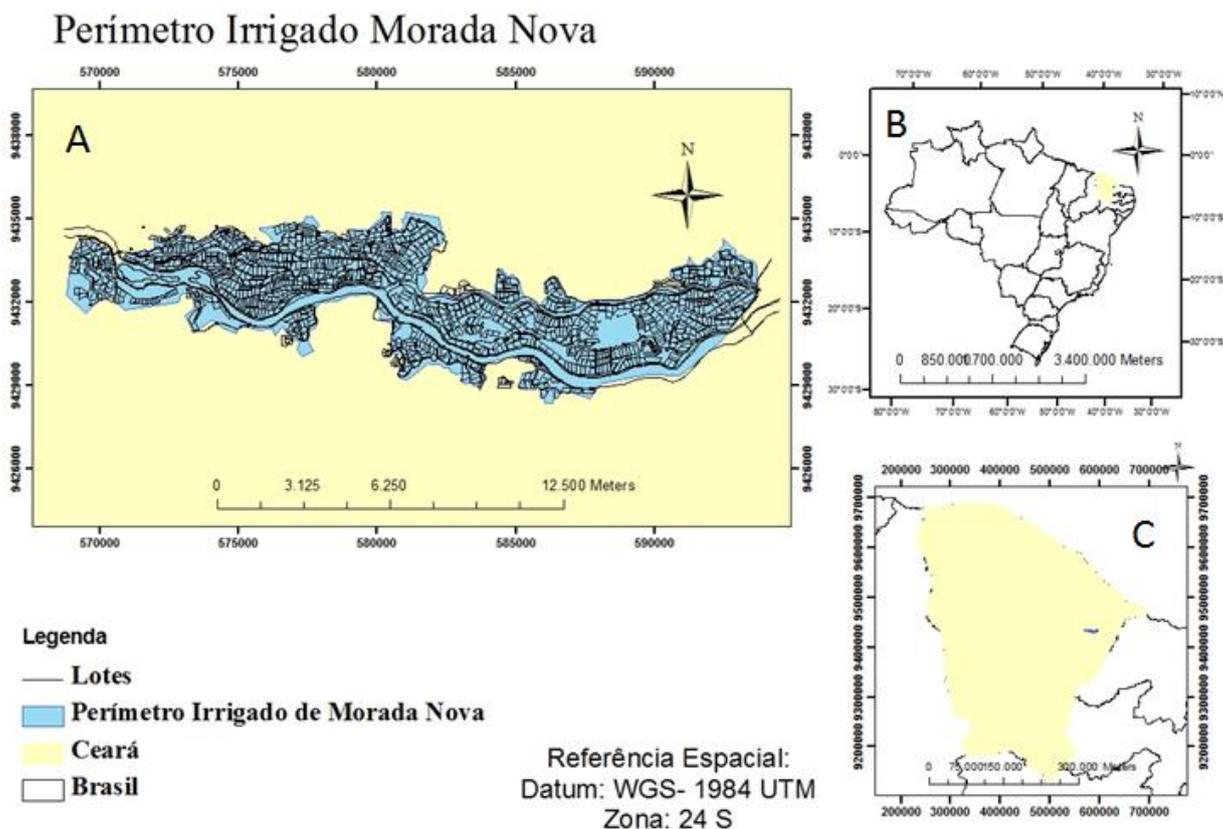
condutividade elétrica de solos expostos por meio de dados de sensor hiperespectral obtidas em análise de laboratório.

5.2 Material e Métodos

Área de Estudo e amostragem

O Distrito de Irrigação Morada Nova está localizado nos municípios de Morada Nova e Limoeiro do Norte (Figura 7), estado do Ceará, na micro-região do Baixo Jaguaribe, sub-vale Banabuiu, a 170 km de Fortaleza, coordenadas geográficas 5° 06' S e 38° 23' W e a 80 m de altitude.

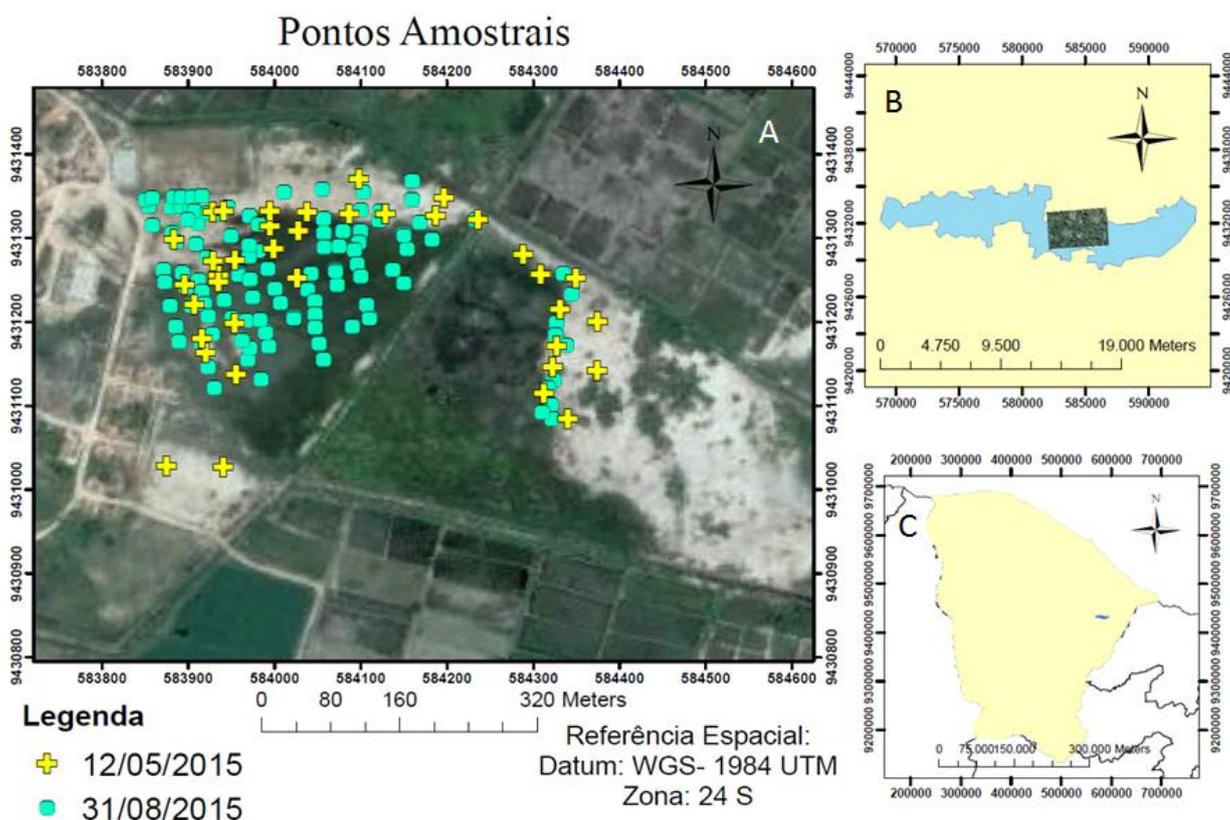
Figura 7 – Área de Estudo (Perímetro Irrigado Morada Nova) onde em: A-delimitação do Perímetro Irrigado de Morada Nova, B-Localização do Estado do Ceará no Brasil e C- a localização do Perímetro estudado no Estado do Ceará



Fonte: Autor.

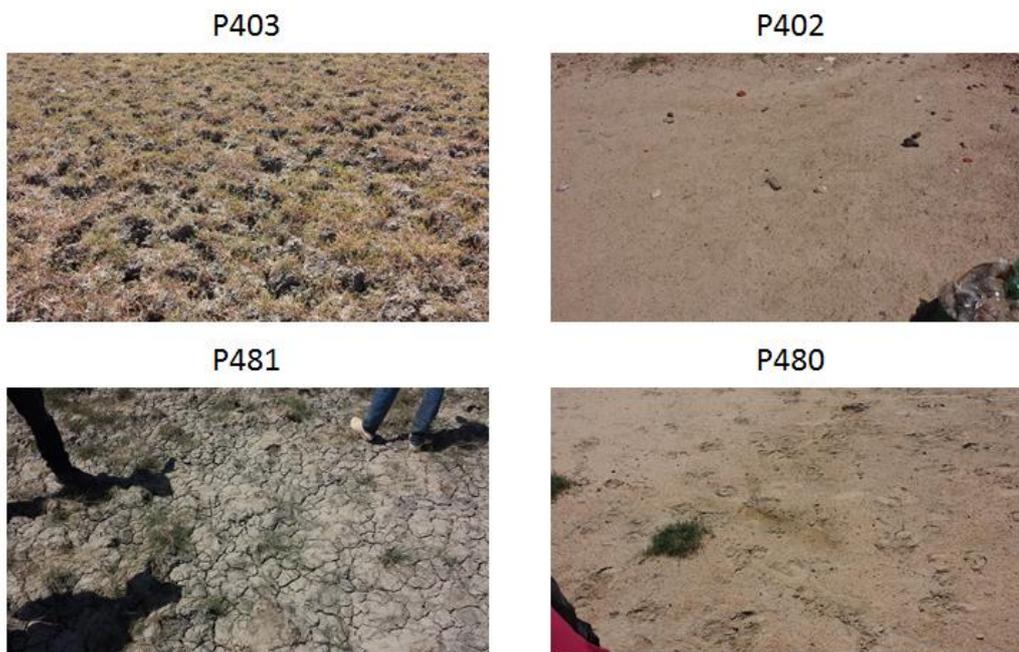
Dentro da área experimental foram escolhidos pontos amostrais onde há altas variações no valor da condutividade elétrica do solo (Figura 8), conforme pode ser observada visualmente na Figura 9, por meio das diferentes rugosidades superficiais do solo na região coletada. Destas áreas, foram realizadas duas coletas de amostras de solo. A primeira coleta ocorreu no dia 12/05/2015 com 46 amostras de solo, e a segunda no dia 31/08/2015 com 107 amostras. Foram obtidas amostras na faixa superficial do solo (0-10 cm), armazenadas em sacos plásticos e conduzidas ao laboratório. Então, as amostras foram homogeneizadas, trituradas e passadas na peneira de 2 mm para reduzir o efeito da rugosidade. Os dados de condutividade elétrica foram obtidos em laboratório por meio de um extrato de diluição 1:1 (amostra do solo : água destilada).

Figura 8 – Pontos amostrais coletados nos dias 12/05/2015 e 31/05/2015, onde em: A- localização dos pontos amostrais em campo em relação a imagem obtida pela plataforma Google Earth, B- localização da área amostral no Perímetro Irrigado de Morada Nova e C- a localização do perímetro irrigado no Estado do Ceará



Fonte: Autor.

Figura 9 – Fotos retiradas em pontos na coleta realizada no dia 12/05/2015



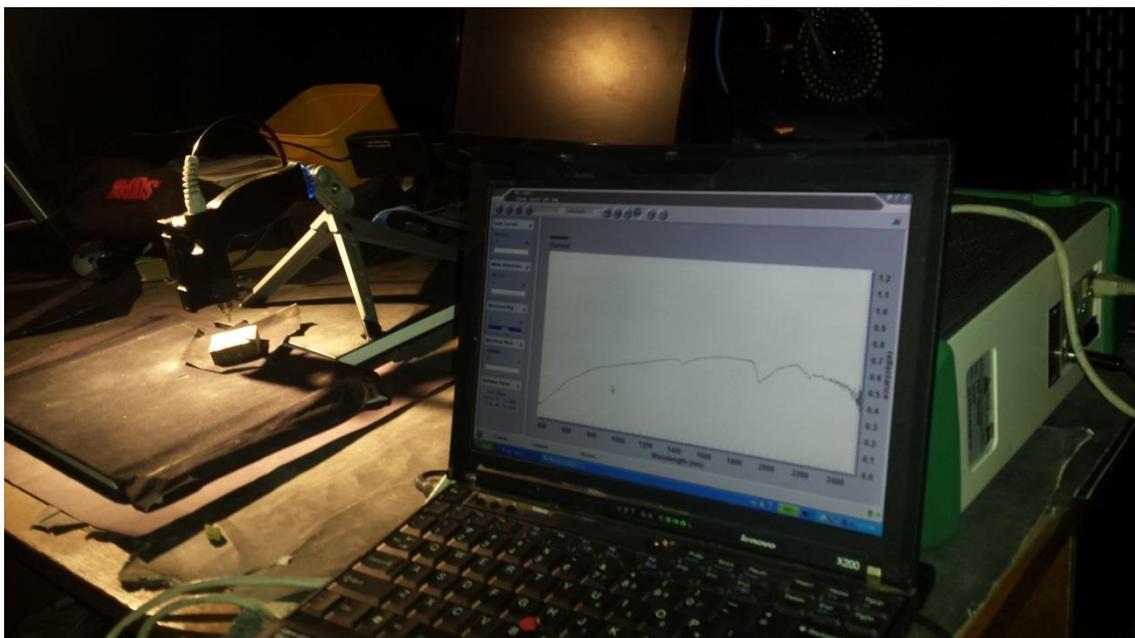
Fonte: Autor.

Leitura Espectral

Para a obtenção dos dados espectrais em laboratório utilizou-se um sistema sensor FieldSpec Pro FR 3, que opera na região de 350 a 2500 nm (Figura 10). Todas as medições espectrais foram feitas em um quarto totalmente escuro para evitar a contaminação por luz difusa. A geometria do sistema baseou-se na posição do sensor disposto verticalmente a 7 cm de distância sobre a amostra. Uma lâmpada halógena de 250 W iluminou as amostras, com refletor parabólico e feixe colimado para o plano visado, com um ângulo zenital aproximadamente de 45°. Utilizou-se como padrão de referência absoluta uma placa spectralon branca, com 100 % de reflectância calibrada. A relação entre a energia refletida pelo alvo e a energia refletida pela placa de referência gera o fator de refletância bidirecional.

Realizaram-se três leituras de reflectância bidirecionais para cada amostra, sendo utilizada a curva espectral média como a curva representativa da amostra. Os procedimentos para as medições espectrais são encontrados em Csillag et al. (1993).

Figura 10 – Sistema de leitura de espectros instalados no laboratório



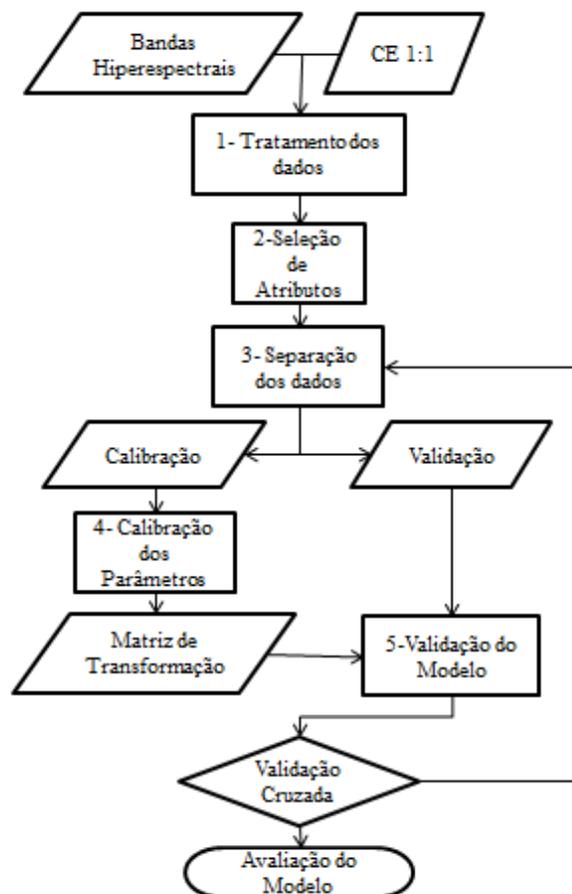
Fonte: Autor.

Avaliação dos modelos computacionais

Os dados espectrais do solo foram pareados com as informações de condutividade elétrica e salvos em formato txt. Para a avaliação dos algoritmos foi utilizado o programa MATLAB. O procedimento realizado foi dividido em 5 passos e estão esquematizados no fluxograma da Figura 11.

O primeiro passo consta no tratamento dos dados. Nesta etapa os dados obtidos da avaliação espectral são reamostrados, segundo dois procedimentos. No primeiro procedimento os dados foram reamostrados quanto a sua resolução espectral, sendo os dados reamostrados nas seguintes resoluções: dados puros; simulando a resposta do sensor Hyperion do satélite EO-1; e simulando a resposta do sensor aerotransportado PROSPECTIR. Para essa simulações foi adotado o valor do sensor FieldSpec que se refere a posição central de cada uma das bandas dos sensores simulados. O segundo procedimento de reamostragem consta na transformação dos dados simulados utilizando os seguintes modelos: dados puros, transformação pela análise por componente principal e transformação pela primeira derivada. Para a análise derivativa foi adotado um filtro de média móvel com janela de três bandas para cada média.

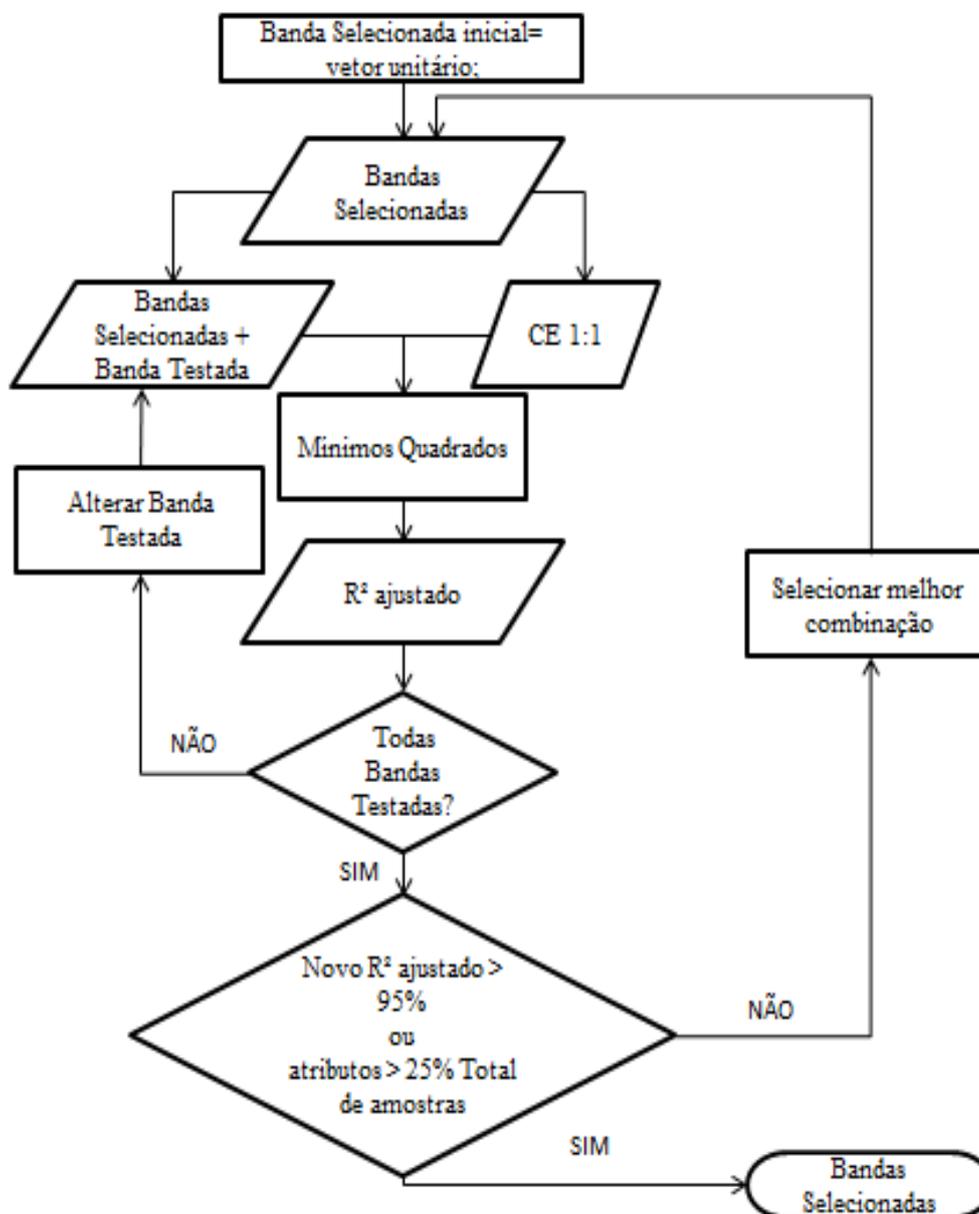
Figura 11 – Fluxograma do procedimento de teste dos algoritmos



Fonte: Autor.

O segundo passo se refere à seleção de atributos (Bandas) de cada modelo. Devido ao grande número de bandas espectrais, para melhorar o desempenho dos algoritmos, foi realizada uma seleção de atributos. Este procedimento é melhor detalhado no fluxograma da Figura 12.

Figura 12 – Fluxograma do procedimento de seleção de bandas



Fonte: Autor.

As bandas hiperespectrais são aquelas obtidas após o processo de tratamento de dados explicado anteriormente (dados puros, componente principal e transformação pela primeira derivada). O processo de seleção de atributos é do tipo *Forward*, onde os atributos selecionados são inicialmente unitários e os demais atributos são adicionados de acordo com o seu incremento de ajuste. O incremento de ajuste adotado foi o R^2 ajustado (Equação (24)). Os critérios de parada utilizados foram: R^2 ajustado superior a

95% e total de bandas selecionadas máxima igual a 25% do tamanho da amostra. Esse segundo critério foi adotado para garantir o poder de generalização do modelo.

$$R_{\text{ajustado}}^2 = 1 - \frac{N - 1}{N - (k + 1)} \times (1 - R^2) \quad (24)$$

Onde: N representa o número de amostras e k representa o número de atributos utilizados no ajuste.

O terceiro passo consta na separação dos dados. Nesta etapa ocorre a seleção do conjunto de dados para calibração dos modelos e conjunto de dados para validação dos mesmos.

No quarto passo ocorre a obtenção dos parâmetros dos modelos. Nesta etapa os modelos são calibrados e obtidas suas matrizes de transformação. Foram avaliados: o modelo linear dos Mínimos Quadrados (MQ) e os modelos não lineares do Perceptron de Múltiplas Camadas (MLP) e Máquina de Aprendizagem Extrema (ELM).

Para a avaliação da rede neural do tipo MLP foram adotados os seguintes parâmetros: 5 neurônios na camada intermediária, pesos obtidos aleatoriamente, taxa de aprendizagem de 95%, função de ativação sigmoide logística e 5.000 épocas de aprendizagem. Para o modelo ELM foram utilizados os seguintes parâmetros: 5 neurônios na camada intermediária, função de ativação sigmoide logística.

Validação

O quinto passo consta da validação dos modelos testados.

Os modelos foram avaliados de acordo com as seguintes métricas estatísticas: coeficiente de determinação ajustado (Equação (24)), erro quadrático médio (Equação (17)), coeficiente de Pearson (Equação (20)), índice de concordância de Willmott (Equação (21)), índice de desempenho (Equação (22)) e a taxa de desvio da performance (Equação (23)). O coeficiente de determinação foi calculado na etapa de calibração, já as demais métricas foram obtidas na etapa de validação.

Para otimizar o pequeno número de amostras, foi aplicada a técnica de validação cruzada “leave-one-out”, onde a separação dos dados em calibração e validação é repetida em número de vezes iguais ao número total de amostras coletados. Em cada uma das repetições, o conjunto de dados utilizados para a validação é unitário e novo, em relação às demais repetições realizadas, processo o qual é repetido até que todas as amostras coletadas sejam utilizadas na validação do modelo.

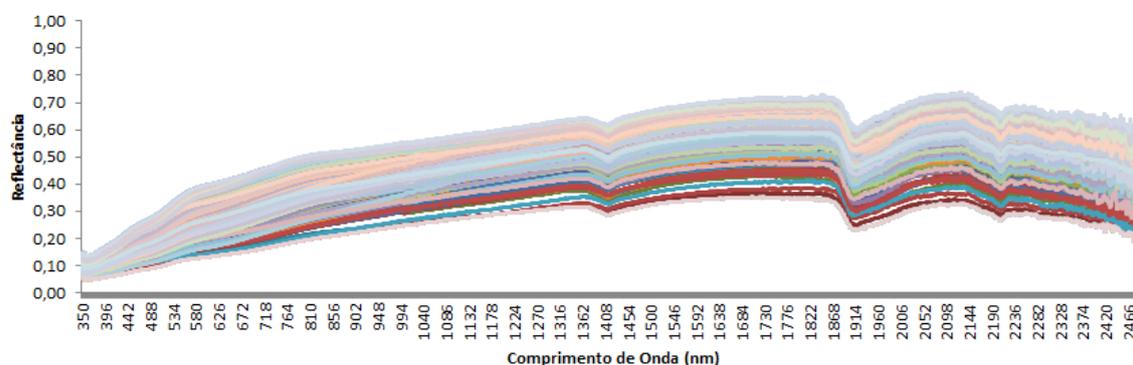
Os resultados obtidos das métricas de validação são iguais ao valor da média dos resultados das repetições.

5.3 Resultados e Discussão

Análise dos dados

Percebe-se, pela observação dos comportamentos espectrais das amostras de solo obtidas em laboratório (Figura 13), que as curvas de respostas espectrais obtidas para as diversas amostras possuem as mesmas tendências de comportamento, com diferenças na magnitude dos valores encontrados. A Figura 14 mostra o comportamento do espectro médio das amostras. Observam-se três faixas de absorção, sendo a primeira por volta de 1400 nm associada a influência da água e hidroxilas (OH). A segunda faixa de absorção observada está entre 1800 e 2000 nm, representando uma faixa de absorção de água.

Figura 13 – Curvas de respostas espectrais obtidas das amostras em laboratório



Fonte: Autor.

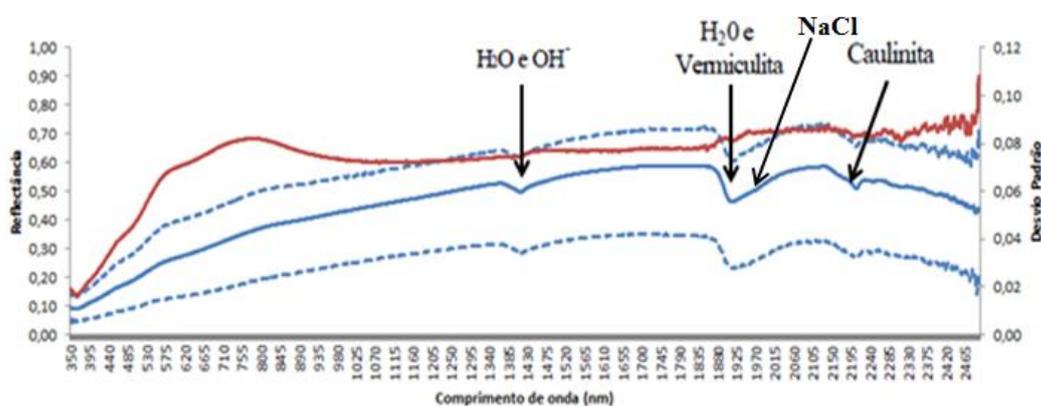
De acordo com Demattê *et al.* (2015a), a faixa de absorção dos 1900 nm é associada ao fragmento de argila 2:1, que possui caráter expansivo. Esta faixa pode ser observada, na Figura 14 e possui uma absorção mais proeminente, mostrando a forte presença deste mineral nas amostras. A visita em campo comprovou a existência deste tipo de argila através do registro de solos com rachadura, o que é uma característica da presença de argila expansiva (Figura 9 – amostra P481).

Moreira, Teixeira e Galvão (2014) avaliaram espectros de solos em área próxima a amostrada neste trabalho, dentro do mesmo perímetro irrigado, tendo

observado, em amostras sem tratamento com gesso, comportamento espectral semelhante ao aqui descrito. No estudo, Moreira, Teixeira e Galvão (2014) associaram a forte absorção da faixa dos 1950 nm a água associada a presença do NaCl, sal muito presente nos solos em regiões semiáridas e compatível com a área estudada.

A terceira faixa apresentada na Figura 14 situa-se no entorno de 2200 nm que é uma faixa de absorção da caulinita. Esta absorção, contudo, não é muito proeminente, mostrando a baixa ocorrência deste mineral.

Figura 14 – Espectro médio das amostras coletadas (azul cheio) com os limites de valor máximo e mínimo obtidos (azul tracejado) e seu respectivo desvio padrão (vermelho – eixo y secundário)



Fonte: Autor.

Seleção de Atributos

Os resultados obtidos na etapa de seleção de atributos estão expostos na

Tabela 7. Observa-se que a reamostragem da resolução espectral resultou numa melhor seleção de bandas, onde os dados absolutos do sensor FieldSpec necessitaram de 20 bandas espectrais para gerar um R^2 ajustado superior a 95%, enquanto que nas resoluções espectrais simuladas do SpectTIR e do Hyperion (simuladas a partir dos próprio FieldSpec), foram necessárias três bandas para gerar o R^2 ajustado superior a 95%, isso utilizando dados puros.

A análise derivativa não foi eficaz na seleção de bandas, uma vez o melhor resultado resultou em R^2 ajustado de 61.95% obtido com os dados do FieldSpec sem reamostragem.

A análise da componente principal foi estável nas três resoluções simuladas, tendo sido necessárias 6 componentes principais para se obter um R^2 ajustado superior a 0,95.

Zhang *et al.* (2014) também observaram que para se estimar alguns elementos (como por exemplo, Fe^{2+} e Si^{2+}) em solos coletados de uma região degradada na China, foi necessário um menor número de bandas simuladas do sensor Hyperion, também obtidas por reamostragem de dados de um sensor de laboratório, em relação aos espectros absolutos. Em geral, neste mesmo trabalho, os modelos utilizando a redução da resolução espectral produziram melhores resultados de validação do que os espectros absolutos do sensor em laboratório, mostrando assim que uma redução e posicionamento ideal do número de bandas podem provocar melhorias no desempenho de alguns modelos computacionais. Interessante informar que apesar dos resultados com uma resolução espectral inferior terem sido melhores, esta redução de dimensionalidade partiu de uma simulação de um sensor (FieldSpec) com alta relação sinal/ruído, em contraposição, o sensor real (Hyperion) tem uma baixa relação sinal/ruído, apresentando vários defeitos em algumas bandas espectrais.

Na Figura 15 observam-se as bandas selecionadas ao longo dos espectros médios dos dados, simulando os diferentes sensores hiperespectrais obtidos a partir dos dados puros. Observa-se que nos dados do FieldSpec, grande parte das bandas selecionadas estão entre 1600 e 2000 nm, corroborando com o resultado obtido por Mashimbye *et al.* (2012). No caso, os autores supracitados obtiveram os resultados ao avaliar o rendimento de razão de bandas em ajustar a condutividade elétrica, observando as melhores relações na banda em torno de 1800 nm e na faixa entre 1600 e 2000 nm e a relação de bandas entre 1400 nm e 2000 nm.

As bandas selecionadas através das simulações dos sensores SpecTIR e Hyperion mostram a importância da resposta espectral em torno de 1640 nm, tendo sido selecionados valores próximos a este valor nos dois casos, quais sejam, 1642 e 1638 nm, respectivamente.

Tabela 7 – Seleção de atributos entre os diferentes tratamentos dos dados

Sensor	Tratamento dos Dados	Bandas Selecionadas	R² Ajustado (%)
FieldSpec	Dados Puros	20	96,75
	Análise Derivativa	38	61,95
	Análise por Componente principal	6	95,71
SpecTIR simulado	Dados Puros	3	95,30
	Análise Derivativa	38	61,88
	Análise por Componente principal	6	95,72
Hyperion simulado	Dados Puros	3	95,02
	Análise Derivativa	38	60,56
	Análise por Componente principal	6	96,02

Onde: R²_{ajustado} – coeficiente de determinação ajustado. Fonte: Autor.

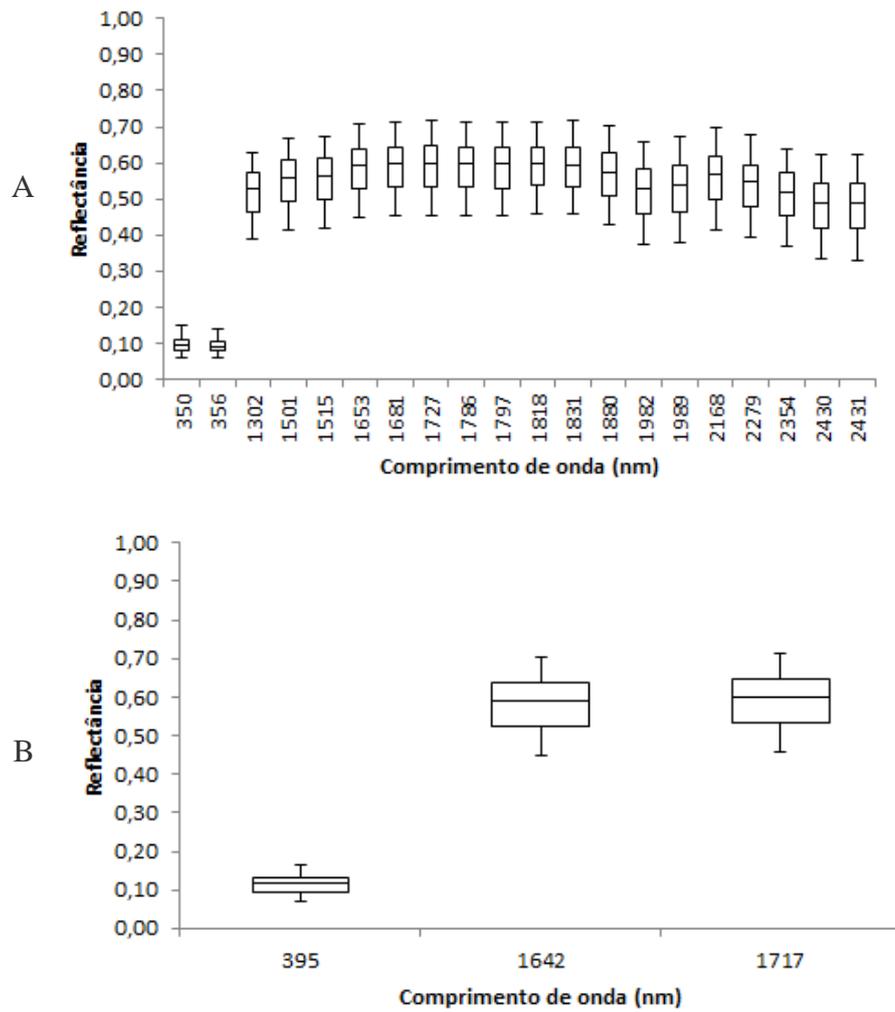
Avaliação dos Modelos de Ajuste

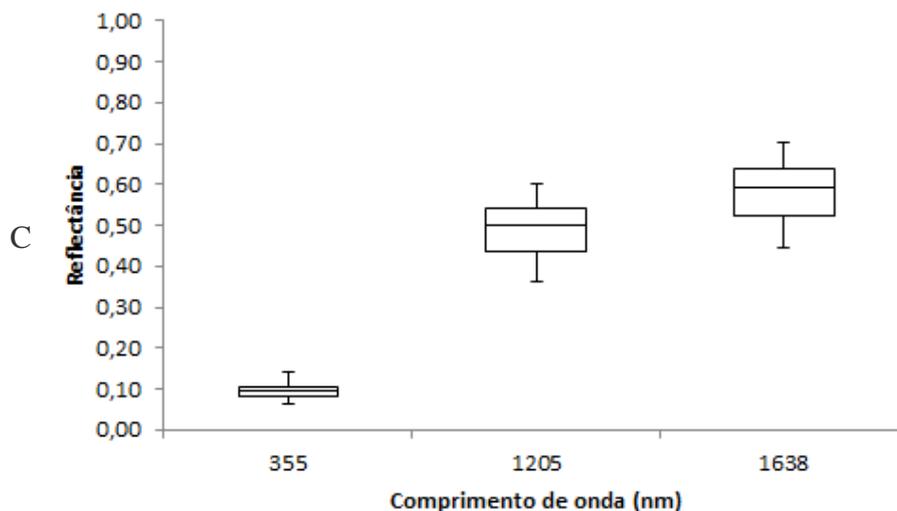
Os resultados do desempenho dos modelos computacionais obtidos a partir das bandas selecionadas na etapa anterior estão expostos na Tabela 8. Observa-se que as respostas de desempenho comparando o algoritmo dos mínimos quadrados e a máquina de aprendizagem extrema não diferiram muito, já o desempenho do perceptron de múltiplas camadas foi inferior em todos os casos.

Como visto na seleção de atributos, a resposta da técnica de análise derivativa foi bem inferior a das demais transformações, onde o melhor resultado foi obtido com a resolução do sensor SpecTIR simulado, com RPD de 1,25, que, como pode ser visto na Tabela 5, classifica o modelo como não confiável.

Aplicação da ACP mostrou melhoria do modelo apenas para a simulação dos dados do sensor Hyperion, em comparação com os resultados obtidos utilizando os Dados Puros.

Figura 15 – Bandas selecionadas para os dados hiperespectrais. Sendo A dados puros, B com as bandas do sensor SpecTIR e C do sensor Hyperion





Fonte: Autor.

Em geral, os melhores rendimentos foram obtidos pelo modelo linear, por ser uma aplicação mais simples e produz excelentes resultados, com R^2 ajustado superior a 95%, c maior que 90% e RPD superior a 2, mostrando assim, a eficiência desses modelos lineares para estimar a condutividade elétrica do solo por meio de dados hiperespectrais.

Mashimbye *et al.* (2012), avaliando o desempenho de algoritmos lineares combinado com técnicas de análise da componente principal aplicados nas curvas espectrais de amostras de solo obtidos em laboratório, constataram desempenho satisfatório (R^2 entre 66 e 81%) na estimativa da condutividade elétrica, superando o desempenho obtido por meio de razão simples de bandas. Já Kobayashi *et al.* (2013), utilizando bandas entre 1970 e 2130 nm, observaram que o desempenho da relação entre bandas ou bandas simples, foi superior ao desempenho da análise da primeira derivada, mostrando que o emprego desta técnica não traz benefícios para estimar a condutividade elétrica.

Kumar, Gautam e Saha (2015), ao avaliarem índices de salinidade obtidos a partir de imagens do sensor Hyperion, observaram que os desempenhos de modelos lineares são satisfatórios quando são usados para estimar valores de condutividade elétrica do solo a partir da resposta espectral.

Tabela 8 – Desempenho dos algoritmos computacionais

Sensor	Tratamento		R² ajustado	EQM	R	Id	c	RPD
FieldSpec	Dados Puros	MQ	96,70	0,02	0,96	0,98	0,94	33,04
		MLP	87,50	52,00	0,91	0,87	0,79	0,65
		ELM	96,90	0,02	0,97	0,98	0,95	33,04
	Análise Derivativa	MQ	61,95	15,01	0,74	1,10	0,47	1,21
		MLP	23,45	15,51	0,28	0,61	0,10	1,19
		ELM	21,25	15,63	0,41	0,70	0,17	1,18
	Análise por Componente Principal	MQ	95,11	0,03	0,96	0,98	0,94	26,54
		MLP	90,70	0,10	0,93	0,95	0,88	14,78
		ELM	96,10	0,02	0,96	0,98	0,94	33,04
Spectir Simulado	Dados Puros	MQ	95,30	0,01	0,96	0,97	0,93	46,72
		MLP	92,30	9,20	0,91	0,91	0,83	1,54
		ELM	95,60	0,01	0,96	0,96	0,92	44,55
	Análise Derivativa	MQ	61,88	13,97	0,82	1,17	0,55	1,25
		MLP	26,69	17,28	0,26	0,35	0,05	1,12
		ELM	44,05	14,71	0,62	0,95	0,34	1,22
	Análise por Componente Principal	MQ	95,20	0,02	0,97	0,96	0,93	32,04
		MLP	84,82	0,02	0,86	0,85	0,83	29,44
		ELM	95,25	0,02	0,96	0,95	0,92	32,71
Hyperion Simulado	Dados Puros	MQ	97,60	0,00	0,97	0,98	0,95	104,48
		MLP	86,96	0,00	0,86	0,87	0,85	93,09
		ELM	96,62	0,00	0,96	0,97	0,94	103,43

Análise Derivativa	MQ	60,56	28,34	0,33	0,48	0,21	1,01
	MLP	53,96	32,06	0,11	0,20	0,03	0,95
	ELM	59,95	29,67	0,22	0,35	0,11	0,99
Análise por Componente Principal	MQ	99,01	0,00	0,99	0,98	0,97	134,88
	MLP	88,23	0,00	0,88	0,87	0,86	120,18
	ELM	98,38	0,00	0,98	0,97	0,96	134,53

Onde: R^2_{ajustado} – coeficiente de determinação ajustado; EQM – erro quadrático médio; r – coeficiente de Pearson; Id – índice de concordância de Willmott; C – índice de desempenho; RPD – taxa de desvio da performance. Fonte: Autor.

5.4 Conclusões

Conclui-se que a avaliação de modelos obtidos com os dados hiperespectrais de laboratório transformados pela análise por componentes principais e pela análise derivativa não resultou em melhorias em relação aos dados puros na estimativa da CE do solo.

Os modelos de seleção de atributos que utilizaram menos bandas espectrais, como o SpecTIR simulado com 357 bandas e Hyperion simulado com 234 bandas, foram mais eficientes do que aqueles utilizando todas as 2151 bandas produzidas pelo sensor FieldSpec.

Conclui-se também que os modelos lineares são mais eficientes para estimar condutividade elétrica do solo por meio de dados hiperespectrais do que os modelos não lineares avaliados.

6 AVALIAÇÃO DO DESEMPENHO DE MODELOS COMPUTACIONAIS CALIBRADOS EM LABORATÓRIO, NA DETERMINAÇÃO DA CONDUTIVIDADE ELÉTRICA DE SOLOS POR MEIO DE IMAGENS HIPERESPECTRAIS OBTIDAS POR SENSOR AEROTRANSPORTADO

6.1 Introdução

Agricultura de precisão não só exige informação espacial para determinar onde e quanto de um insumo (por exemplo, fertilizantes, defensivos agrícolas, água de irrigação) a aplicar, mas também requer informações temporais para se determinar quando aplicar. A determinação de quando aplicar um insumo, especialmente quando irrigar, requer medições em tempo real das condições das plantas e/ou do solo.

Medições em tempo real da condição da planta, em uma condição limitada de extensão do solo, são melhor obtidos com imagens multi e hiperespectrais. O imageamento tem a vantagem de monitorar as condições das plantas em grandes áreas em um curto espaço de tempo e, de maneira análoga, a condutividade elétrica aparente (CEa) reflete a condição do solo (CORWIN e LESCH, 2005).

No entanto, medidas de vegetação podem levar a diferentes interpretações. Por exemplo, uma murcha na planta pode ser tanto devido ao estresse salino quanto ao estresse hídrico. Assim, a medição da CEa no solo traduz diretamente a necessidade de intervenções. Medições espaço-temporais da CEa são os meios mais adequados para as avaliações históricas ou ano-a-ano de tendências, como a forma em que a salinização de um solo ou a recuperação de um solo afetado por sais vem se desenvolvendo (CORWIN e LESCH, 2005).

TUIA *et al.* (2014), relatam como os principais problemas de se trabalhar com imagens hiperespectrais, a necessidade de memória computacional e a capacidade limitada dos algoritmos computacionais trabalharem com a alta quantidade de bandas adquiridas. Com isso para haver mais sucesso nas avaliações, uma das melhores abordagens tem sido a redução de dimensionalidade do conjunto de dados.

De acordo com DEMATTÊ *et al.* (2015b), os métodos que buscam correlacionar múltiplas bandas espectrais com um atributo do solo são eficientes para determinar muito dos componentes do solo, como por exemplo os óxidos de ferro e alumínio. Esta abordagem conduz a altos valores do coeficiente de ajuste e pode ser

aplicada aos dados obtidos por sensoriamento remoto hiperespectrais, detectando assim as áreas degradadas e auxiliando na agricultura de precisão.

No entanto, nem todos os atributos do solo conduzem a altas correlações, havendo assim a necessidade de avaliação antes da adoção do referido método.

A obtenção de dados de alta resolução espectral de melhor qualidade está limitada pelo alto custo em sua aquisição. Com isso é importante avaliar se o objeto de estudo tem alta correlação com a resposta hiperespectral e daí a importância em se fazer avaliações prévias em laboratório com sensores hiperespectrais com alta relação sinal/ruído.

Diante do exposto, o objetivo deste tópico é avaliar a capacidade de modelos calibrados em laboratório em estimar a condutividade elétrica do solo, usando como base imagens hiperespectrais de alta resolução espectral.

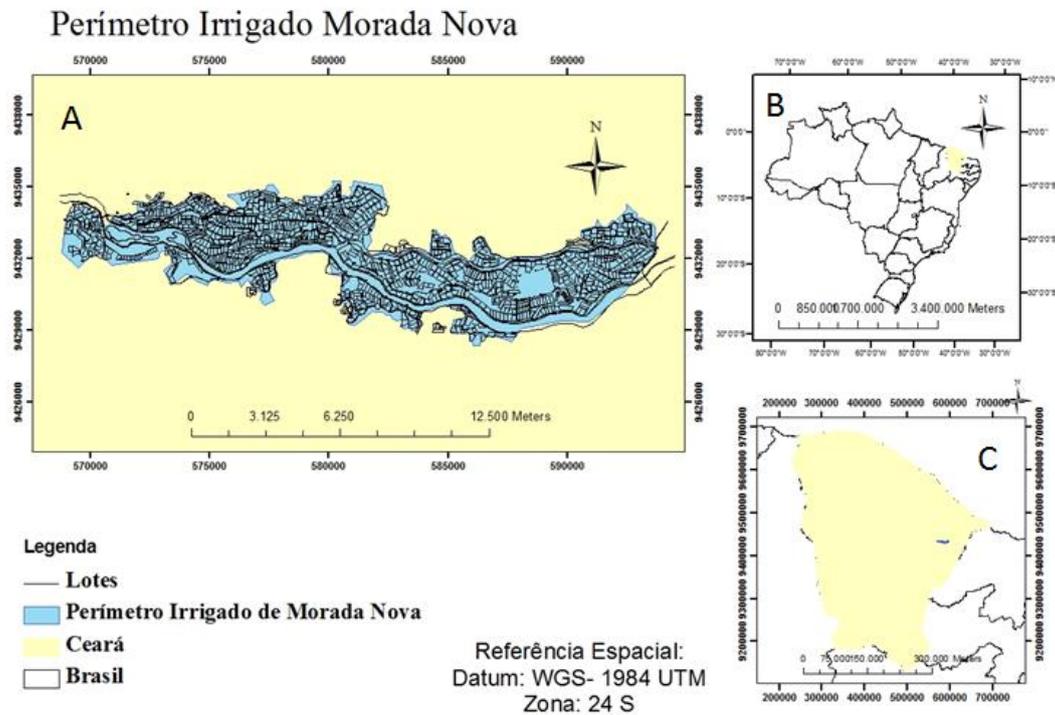
6.2 Material e Métodos

Área de Estudo e amostragem

O trabalho foi realizado no Distrito de Irrigação Morada Nova que está localizado nos municípios de Morada Nova e Limoeiro do Norte, estado do Ceará, na micro-região do Baixo Jaguaribe, sub-vale Banabuiu, a 170 km de Fortaleza, coordenadas geográficas 5° 06' S e 38° 23' W e a 80 m de altitude (Figura 16).

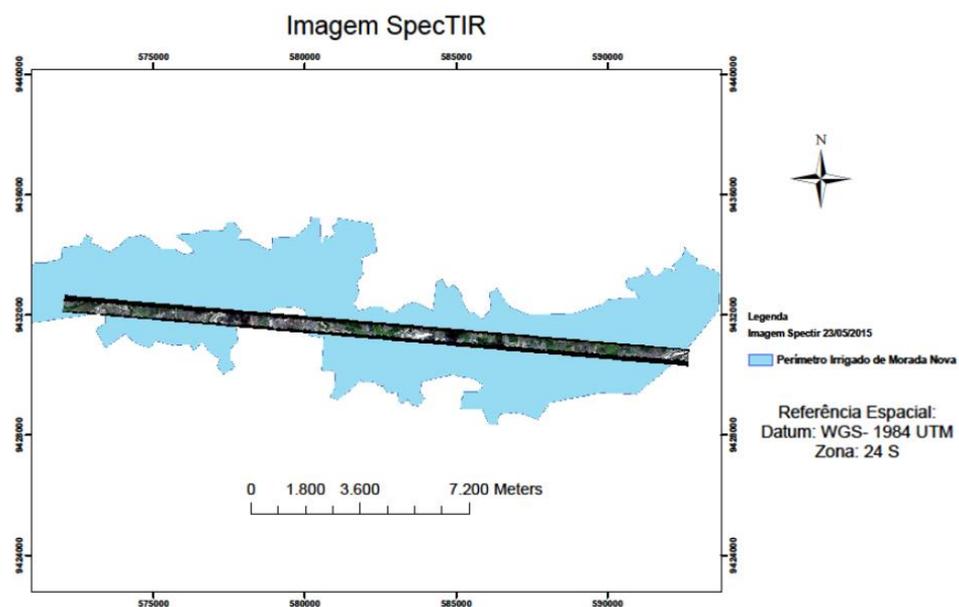
Foi obtida, na região de interesse, uma imagem de alta resolução espectral do sensor aerotransportado SpecTIR com 357 bandas espectrais, abrangendo o espectro de 400 a 2500 nm e com resolução espacial de 1 metro, adquirida no dia 23/05/2015 às 13 horas – 10:00 GMT (Figura 17).

Figura 16 – Área de Estudo (Perímetro Irrigado Morada Nova) onde em: A-delimitação do Perímetro Irrigado de Morada Nova, B-Localização do Estado do Ceará no Brasil e C- a localização do Perímetro estudado no Estado do Ceará



Fonte: Autor.

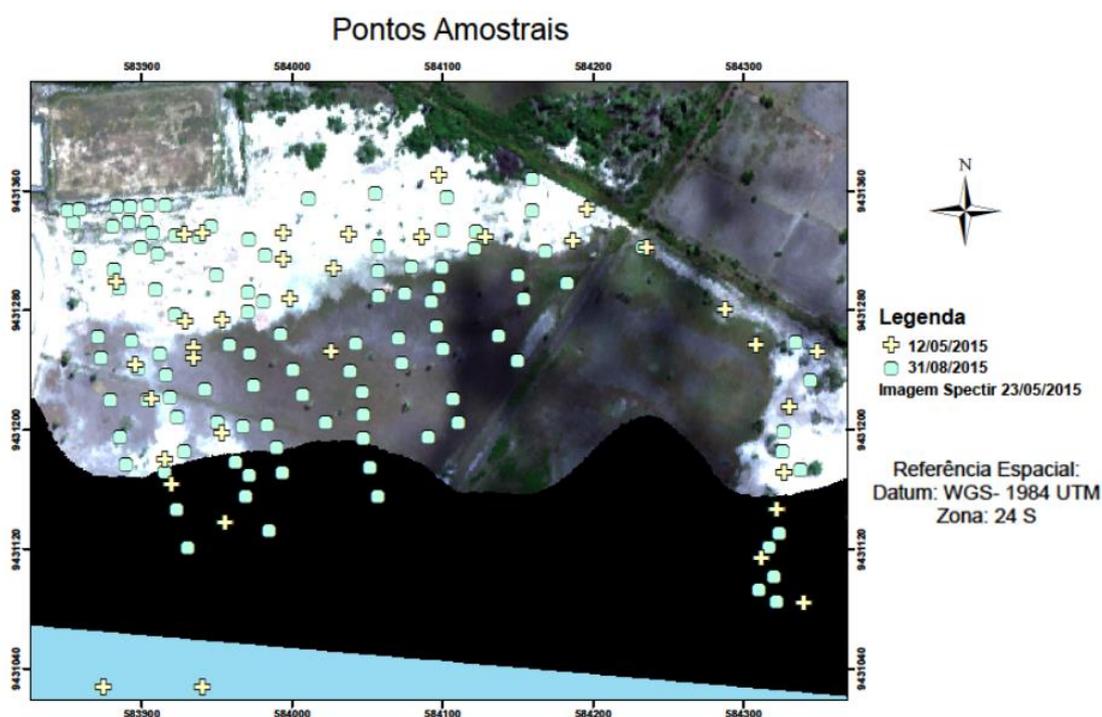
Figura 17 – Cobertura da Imagem SpecTIR obtida no dia 23/05/2015 na região do Perímetro irrigado de Morada Nova-Ce



Fonte: Autor.

Dentro da área experimental, foram definidos pontos amostrais onde há altas variações no valor da condutividade elétrica do solo. Foram realizadas duas coletas de amostras de solo, a primeira ocorrendo no dia 12/05/2015 com 46 amostras de solo e a segunda no dia 31/08/2015 com 107 amostras (Figura 18). As amostras foram coletadas na faixa superficial do solo (0-10 cm), foi obtida também sua coordenada geográfica por meio de um gps de navegação, em seguida, armazenadas em sacos plásticos e conduzidas ao laboratório. Então, as amostras foram, homogeneizadas, trituradas e passadas na peneira de 2 mm para reduzir o efeito da rugosidade. Os dados de condutividade elétrica foram obtidos em laboratório por meio de um extrato de diluição 1:1 (amostra do solo : água destilada).

Figura 18 – Pontos amostrais coletados nos dias 12/05/2015 e 31/05/2015



Fonte: Autor.

Leitura Espectral

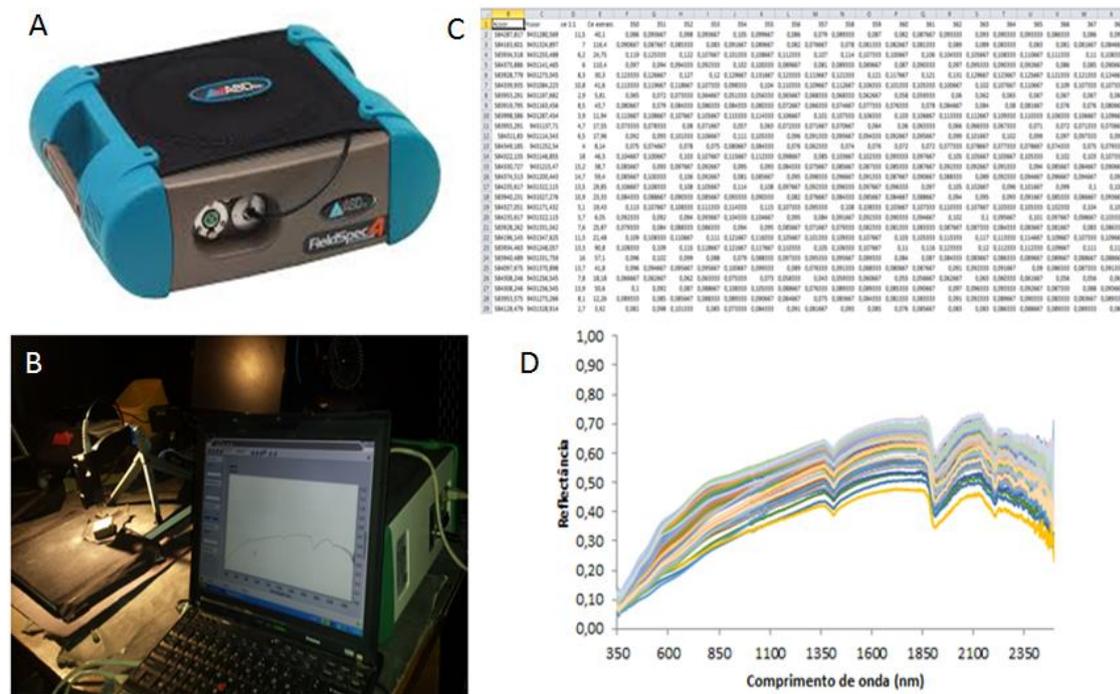
Para a obtenção dos dados espectrais em laboratório, utilizou-se um sistema sensor FieldSpec Pro FR 3, que opera na região de 350 a 2500 nm (Figura 10). Todas as medições espectrais foram feitas em um quarto totalmente escuro para evitar a

contaminação por luz difusa. A geometria do sistema baseou-se na posição do sensor disposto verticalmente a 7 cm de distância sobre a amostra. Uma lâmpada halógena de 250 W iluminou as amostras, com refletor parabólico e feixe colimado para o plano visado, com um ângulo zenital aproximadamente de 45°. Utilizou-se como padrão de referência absoluta uma placa spectralon branca, com 100 % de reflectância calibrada. A relação entre a energia refletida pelo o alvo e a energia refletida pela placa de referência gera o fator de refletância bidirecional.

Realizaram-se três leituras de reflectância bidirecionais para cada amostra, sendo utilizada a curva espectral média como a curva representativa da amostra. Os procedimentos para as medições espectrais são encontrados em Csillag et al. (1993).

Os dados obtidos foram tabulados e trabalhados inicialmente no software EXCEL da Microsoft (Figura 19).

Figura 19 – Aquisição dos dados hiperespectrais em laboratório, onde em: A- Espectrorradiômetro de laboratório, B – foto da aquisição da curva espectral, C- tabulação das respostas espectrais em Excel e D- as curvas espectrais obtidas em laboratório



Fonte: Autor.

Modelagem em Laboratório

Os dados espectrais obtidos em laboratório das 153 amostras foram pareados com as informações de condutividade elétrica e salvos em formato txt. Os modelos computacionais foram aplicados no programa MATLAB versão 7.9. O procedimento realizado foi dividido em 5 processos e estão esquematizados no fluxograma da Figura 20.

O primeiro processo consta na reamostragem dos dados. Nesta etapa os dados obtidos da avaliação espectral são reamostrados para simular os dados do sensor SpecTIR.

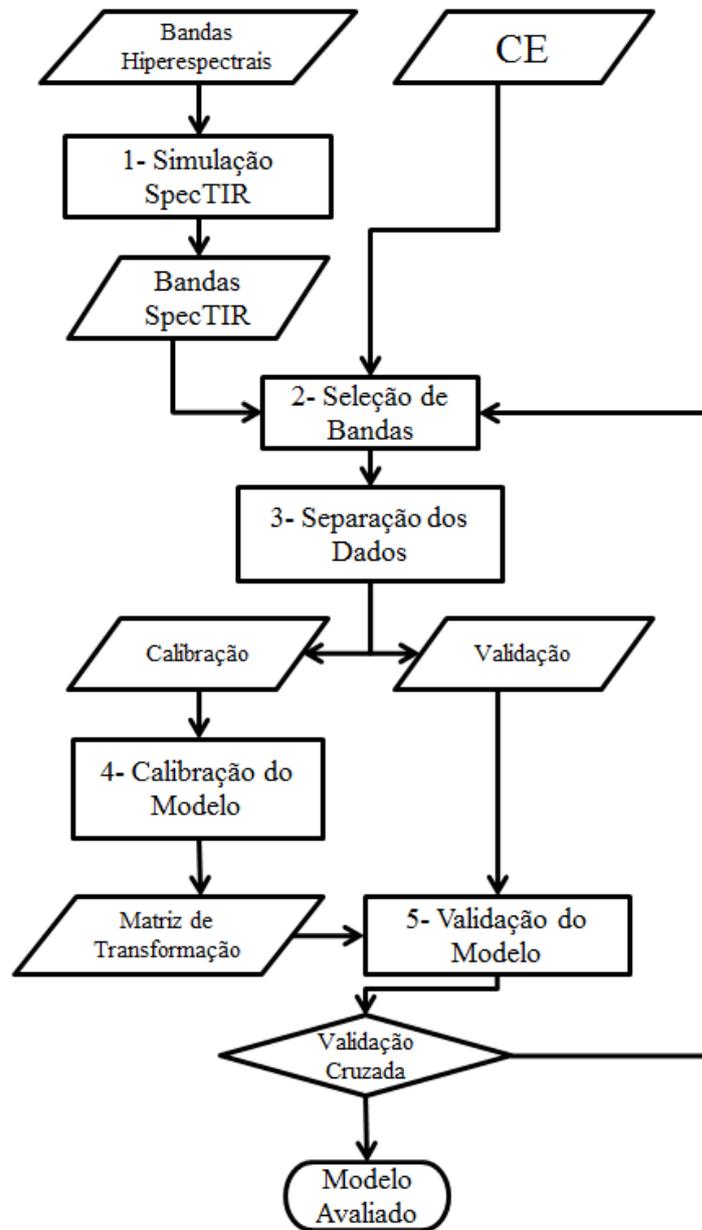
O segundo procedimento se refere à seleção de bandas. Devido ao grande número de bandas espectrais, para melhorar o desempenho dos algoritmos foi realizada uma seleção de atributos. Este procedimento está detalhado no fluxograma da Figura 21.

As bandas hiperespectrais foram obtidas pela transformação dos dados brutos de reflectância do sensor Fieldspec para simular os dados do sensor SpecTIR. Nesta simulação foi realizada uma reamostragem dos espectros obtidos em laboratório (2151 bandas) a partir do Fieldspec para a resolução do sensor SpecTIR (357 bandas). A seleção de bandas foi do tipo *Forward*, onde os atributos selecionados são inicialmente unitários e os demais atributos são adicionados de acordo com o seu incremento de ajuste. Os critérios de parada utilizados foram: R^2 ajustado (Equação (24) superior a 95% e total de bandas selecionadas superiores a 25% do total de amostra. Esse segundo critério foi adotado para garantir a generalização do modelo.

O terceiro processo consta na separação dos dados: nesta etapa ocorre a seleção do conjunto de dados para calibração dos modelos e o conjunto de dados para validação dos mesmos.

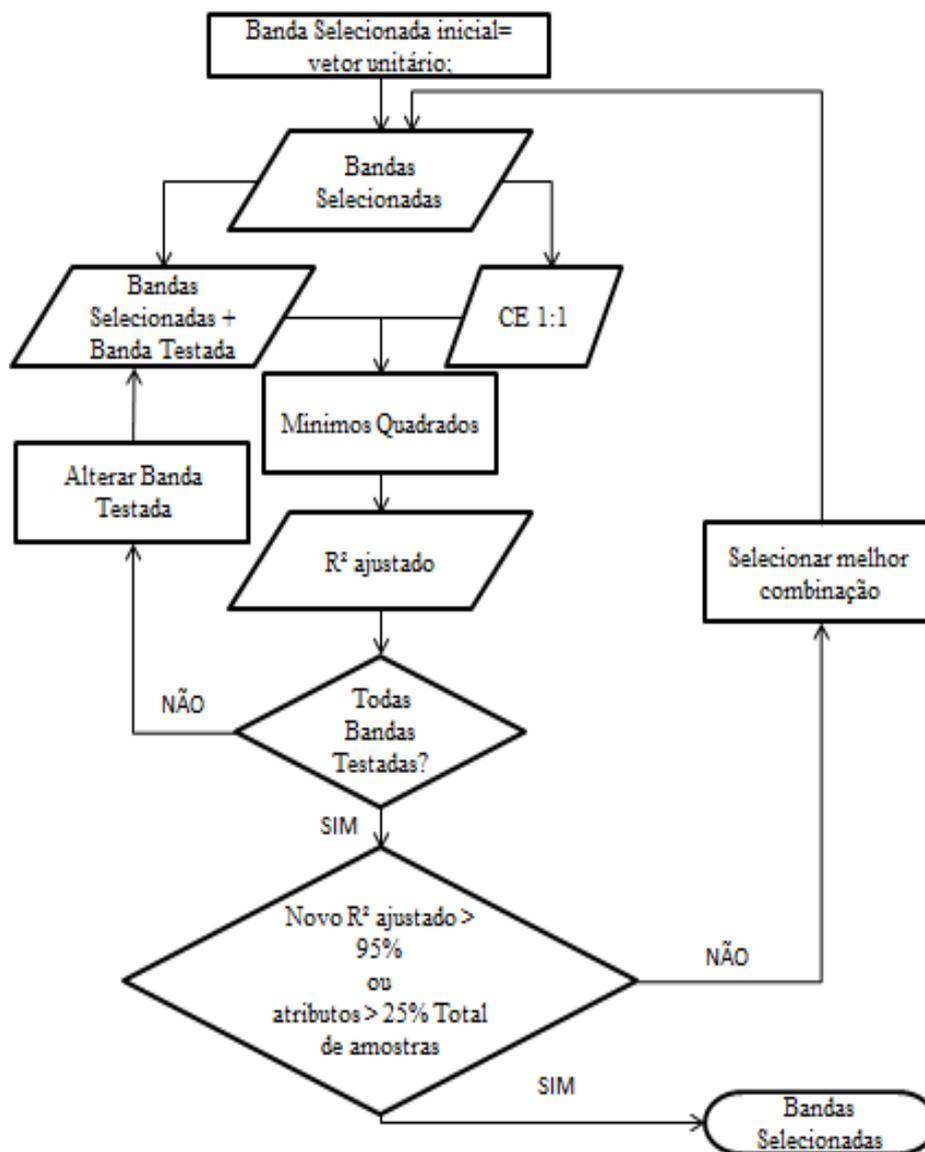
No quarto processo ocorre a obtenção dos parâmetros dos modelos. Nesta etapa os modelos são calibrados e obtidas as matrizes de transformação. Foi aplicado o modelo linear dos Mínimos Quadrados.

Figura 20 – Fluxograma de Treinamento e Validação do Modelo Computacional



Fonte: Autor.

Figura 21 – Fluxograma do procedimento de seleção de bandas



Fonte: Autor.

Validação do modelo com dados de laboratório

O quinto processo consta da validação dos modelos testados.

Os modelos foram avaliados de acordo com as seguintes métricas estatísticas: coeficiente de determinação ajustado (Equação (24)), erro quadrático médio (Equação (17)), coeficiente de Pearson (Equação (20)), índice de concordância de Willmott (Equação (21)), índice de desempenho (Equação (22)) e a taxa de desvio da

performance (Equação (23)). O coeficiente de determinação foi calculado na etapa de calibração, já as demais métricas foram obtidas na etapa de validação.

Para otimizar o pequeno número de amostras foi aplicada a técnica de validação cruzada “leave-one-out”, onde a separação dos dados em calibração e validação é repetida em número de vezes iguais ao número total de amostras coletados. Em cada uma das repetições, o conjunto de dados utilizados para a validação é unitário e novo, em relação às demais repetições realizadas, processo o qual é repetido até que todas as amostras coletadas sejam utilizadas na validação do modelo.

Em cada repetição são obtidos os valores de validação e o valor final de cada métrica de validação é igual à média dentre todas essas repetições.

Aplicação do Modelo aos dados de Campo

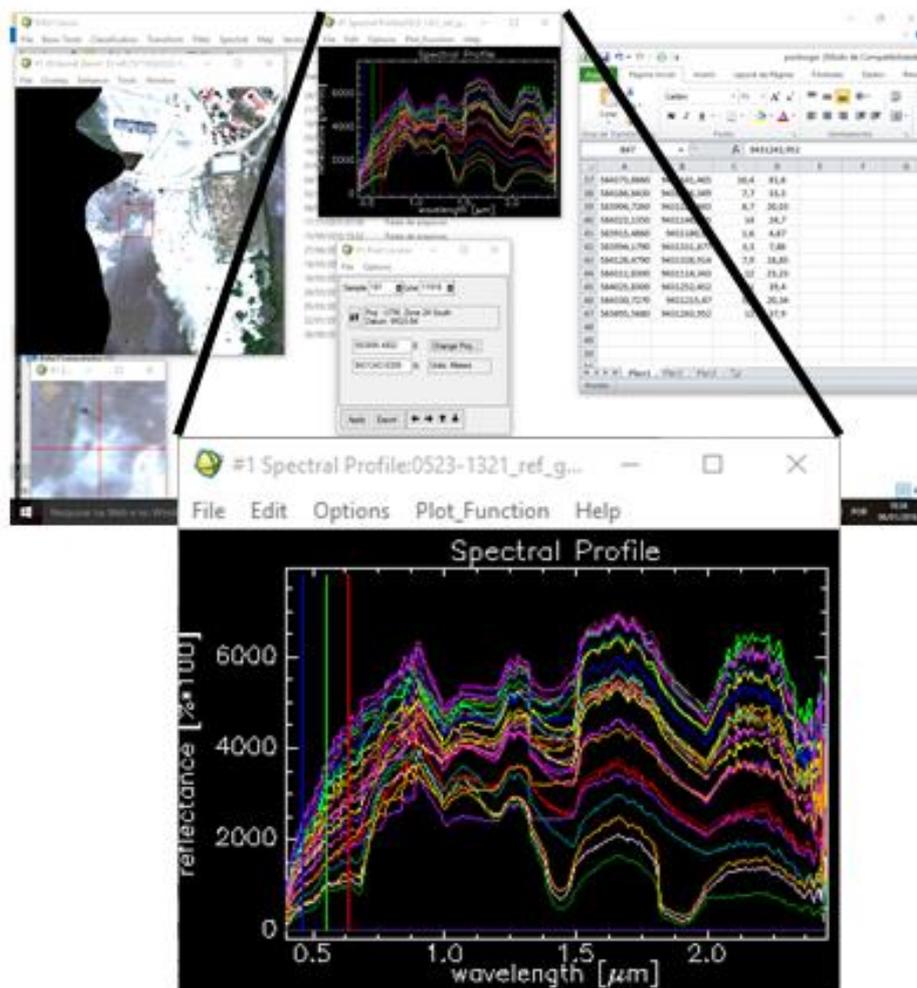
Foi avaliado o desempenho do modelo calibrado em laboratório utilizando os dados obtidos em campo pela imagem do sensor ProSpecTIR-VS. A imagem foi adquirida pela empresa FOTOTERRA e foi obtida no dia 23/05/2015. O processo de obtenção do dado de reflectância de superfície por meio de correção atmosférica foi realizado pela própria empresa. Esse procedimento foi realizado utilizando o procedimento MODTRAN4. Para georreferenciamento das imagens foi utilizado um sistema inercial de navegação que é incorporado ao próprio sensor SpecTIR. Os demais detalhes sobre a aquisição da imagem se encontram no anexo desta tese.

Para a avaliação do modelo computacional foram coletados espectros nos pixels na área de interesse onde foram localizados os pontos amostrais obtidos no dia 12/05/2015 (Figura 22).

Foram escolhidos esses pontos amostrais, devido a sua coleta ter ocorrido próxima a data da aquisição da imagem SpecTIR. Foram coletados 35 pontos que resultaram em 35 curvas espectrais.

A calibração do modelo obtido em laboratório foi comparada com uma nova calibração obtida por meio dos dados coletados da imagem SpecTIR. Foram aplicadas as mesmas métricas de validação adotadas na etapa de laboratório.

Figura 22 – Coleta dos espectros da Imagem SpecTIR por meio do software ENVI



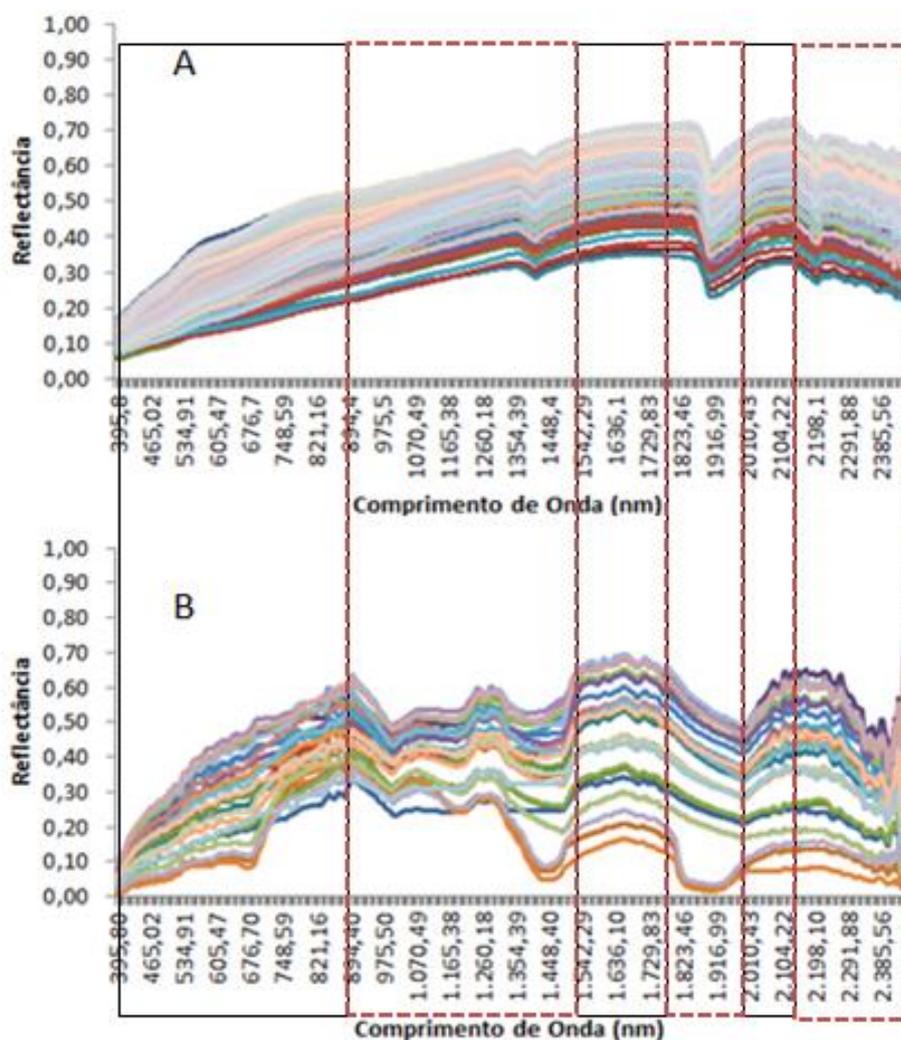
Fonte: Autor.

6.3 Resultados e Discussão

Análise dos dados

Na Figura 23 está exposto o comportamento espectral em laboratório das amostras coletadas em campo ($A = 153$ amostras) e dos espectros extraídos da imagem SpecTIR ($B = 35$ pixels) dos pontos de coleta realizada no dia 12/05/2015. Observam-se, no tracejado vermelho, as faixas espectrais onde houve as maiores diferenças das respostas espectrais obtidas em laboratório em relação aos pixels da imagem.

Figura 23 – Comportamento espectral das amostras coletadas, A espectros obtidos em laboratório e B dos pixels amostrados da imagem SpecTIR



Fonte: Autor.

As maiores diferenças ocorridas nas faixas próximas ao comprimento de onda de 1400 nm e 1900 nm se devem, provavelmente, ao processo de correção da atmosfera, especialmente por serem faixas espectrais com maior interferência devido ao efeito do vapor d'água.

O comportamento divergente dos espectros a partir 2150 nm até o final do espectro pode ser um indicativo da influência do ruído da imagem, podendo assim mascarar o comportamento na faixa de 2200 nm.

Observa-se também o comportamento atípico das curvas espectrais na faixa entre 900 e 1300 nm, que está bem próxima a faixa de transição entre sensores. Os dois

sensores de leitura do ProSpecTIR, com o primeiro sensor captando o VNIR (400-1000 nm) e o segundo sensor captando o SWIR (1000-2500 nm), justamente a faixa de transição com este comportamento atípico.

É importante também destacar que nas leituras em laboratório, todos os efeitos como: mistura espectral, rugosidade das amostras e sombra, são eliminados devido ao tratamento que essas amostras passaram para a realização destas leituras. Com isso, intensificando as diferenças ocorridas entre as duas leituras.

Calibração e validação em laboratório

Os resultados obtidos da calibração em laboratório estão expostos na Tabela 9. Pode ser observado que houve uma grande correlação entre os espectros do solo e os valores de condutividade elétrica, com altos valores de R^2 tanto para os valores de espectro puro quanto para simulação dos dados do sensor SpecTIR. O modelo aplicando a redução do número de bandas espectrais produziu melhor resposta em relação ao modelo aplicando as 2151 bandas dos espectros puros do sensor FieldSpec, sendo selecionadas poucas bandas espectrais (três) e ainda gerando altos valores de coeficiente de determinação (95,3), assim como, altos valores dos índices de validação e, por fim, melhor resultado da taxa de desvio da performance (46,72).

A Equação (25) foi o melhor modelo obtido na calibração em laboratório, onde se destacam as bandas 395, 1642 e 1717 nm. Kumar, Gautam e Saha (2015), estudando a correlação entre bandas do sensor Hyperion e as condutividades elétricas do solo, reportaram encontrar as melhores relações entre as bandas do visível ou do infravermelho próximo, diferindo dos resultados nesse trabalho, onde as melhores correlações indicam predominância do SWIR.

Tabela 9 – Desempenho dos algoritmos computacionais calibrados em Laboratório

Sensor	Bandas Seleccionadas	R ² ajustado	EQM	r	Id	C	RPD
FieldSpec	350, 356, 1302, 1501, 1515, 1653, 1681, 1727, 1786, 1797, 1818, 1831, 1880, 1982, 1989, 2168, 2279, 2354, 2430, 2431	96,7	0,02	0,96	0,98	0,94	33,04
SpecTIR simulado	395, 1642, 1717	95,3	0,01	0,96	0,97	0,93	46,72

Onde: R²_{ajustado} – coeficiente de determinação ajustado; EQM – erro quadrático médio; r – coeficiente de Pearson; Id – índice de concordância de Willmott; C – índice de desempenho; RPD – taxa de desvio da performance. Fonte: Autor.

$$CE = -2,71744 - 96,7574\rho_{395} - 109,995\rho_{1642} + 145,0124\rho_{1717} \quad (25)$$

Onde CE representa a condutividade elétrica 1:1 do solo; ρ_{395} representa o valor da reflectância na banda de 395 nm; ρ_{1642} representa a reflectância em 1642 nm e ρ_{1717} representa a reflectância em 1717 nm.

Desempenho da Imagem SpecTIR

A Tabela 10 mostra a avaliação do desempenho da Eq. (25) na estimativa da CE do solo a partir da imagem SpecTIR e a comparação com o desempenho obtido pelo modelo calibrado a partir dos 35 espectros coletados da imagem SpecTIR. De acordo com a resposta obtida pelo índice RPD, observa-se que o modelo de laboratório foi satisfatório para medir a CE utilizando os dados do sensor SpecTIR (RPD entre 1,4 e 2,0). Observa-se também que, o modelo de laboratório obteve um coeficiente de Pearson superior a 0,80, indicando uma correlação forte. No entanto, o resultado do índice de desempenho foi considerado sofrível.

O modelo calibrado a partir dos espectros do sensor SpecTIR, produziu resultados inferiores quando comparados ao modelo de laboratório. Duas causas podem ser destacadas para essa queda de desempenho entre as análises. A primeira devido às diferenças entre as amostras utilizadas em campo em relação aos espectros obtidos das imagens, principalmente em relação à textura e mistura espectral dos dados da imagem como, por exemplo, vegetação.

O segundo motivo para redução do desempenho do modelo calibrado utilizando a imagem SpecTIR é devido a pequena quantidade de dados amostrais utilizadas para o treinamento, uma vez que para gerar o modelo em laboratório foram utilizados 152 amostras para calibração, enquanto que para o modelo pelo sensor SpecTIR foram utilizados 34 amostras, tendo sido, nos dois casos, aplicados a validação cruzada “leave-one-out”.

Zhang *et al.* (2014), em busca de correlacionar o elemento Ca^{2+} em uma área degradada a partir de imagens do sensor Hyperion, observaram também uma redução do desempenho do modelo computacional treinado com os dados da imagem em relação aos treinados em laboratório, mostrando tanto o efeito da redução da qualidade do sinal do sensor orbital quanto também a limitação na quantidade de amostras para o treinamento do algoritmo.

Tabela 10 – Desempenho dos algoritmos computacionais em relação à imagem SpecTIR

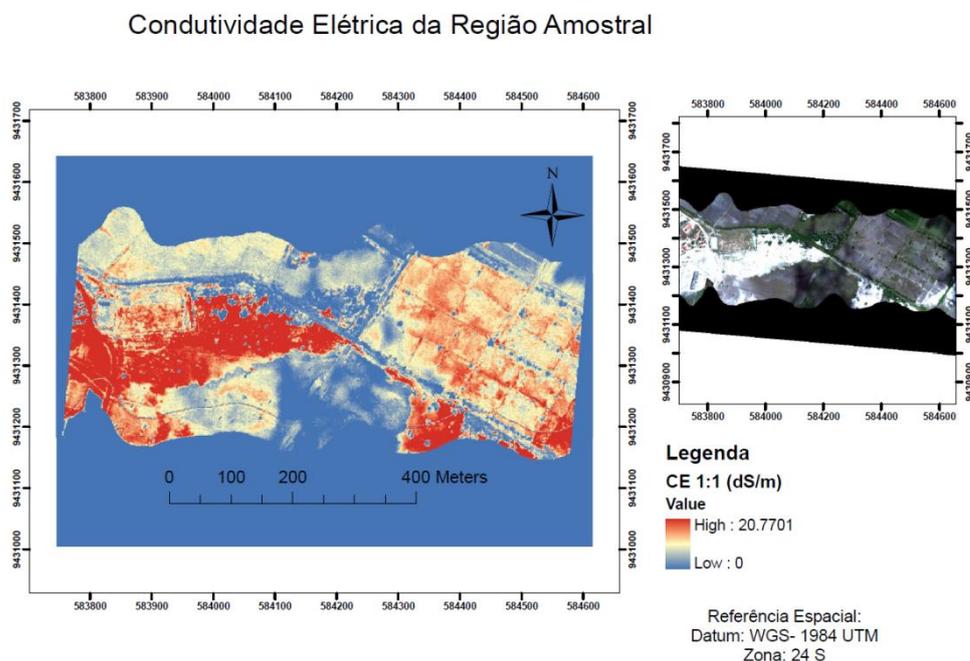
Calibração	EQM	r	Id	C	RPD
Laboratório	7,26	0,80	0,71	0,57	1,46
Imagem SpecTIR	15,82	0,48	0,68	0,33	1,09

Onde: EQM – erro quadrático médio; r – coeficiente de Pearson; Id – índice de concordância de Willmott; C – índice de desempenho; RPD – taxa de desvio da performance. Fonte: Autor.

Na

Figura 24 observa-se o resultado aplicando a Equação (25) na imagem SpecTIR na região do experimento. Observa-se como a região está bastante degradada, com grande parte desta apresentando valores de $\text{CE}_{1:1}$ entre 8 e 20 dS/m (cores amareladas ou avermelhadas, com a predominância do tom vermelho). Identifica-se também que alguns dos pontos de menores respostas (tons mais azulados) são observados em áreas onde há mistura da vegetação, não podendo ser necessariamente baixa salinidade, pois os modelos foram calibrados em solos descobertos e o comportamento da vegetação difere substancialmente.

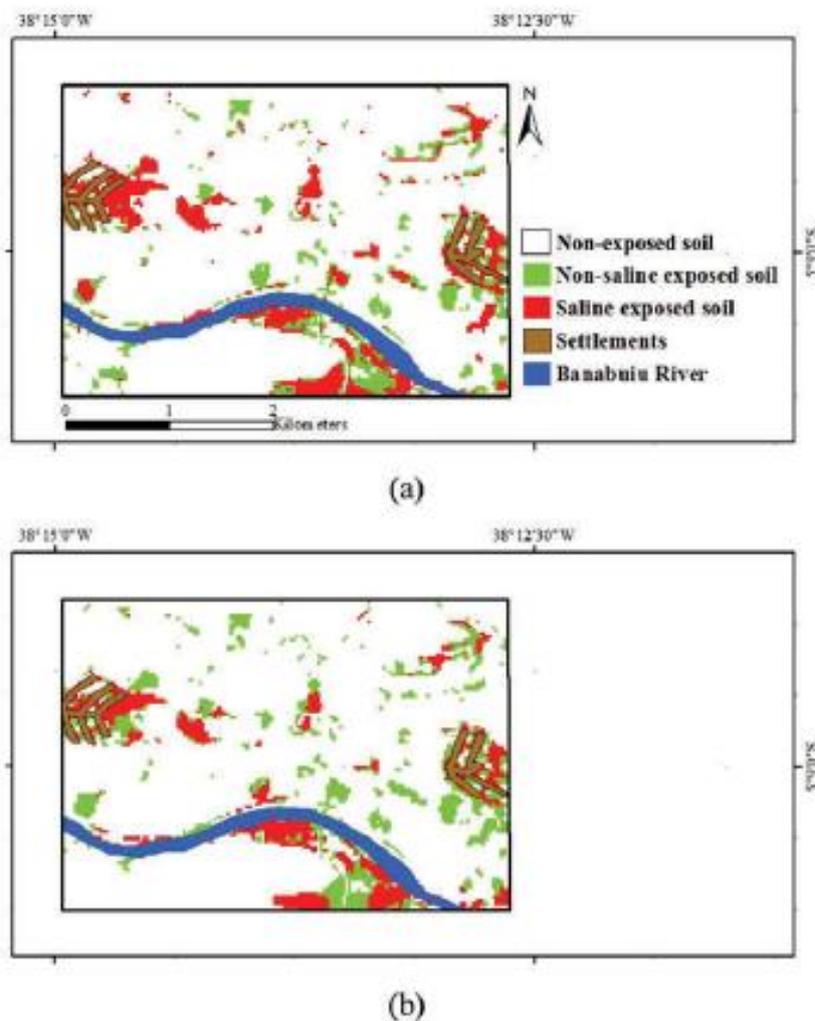
Figura 24 – Distribuição da Condutividade Elétrica utilizando o modelo calibrado em laboratório aplicado na imagem SpecTIR



Fonte: Autor.

Moreira, Teixeira e Galvão (2015), avaliando o desempenho de diferentes classificadores aplicados na região de Morada Nova em imagens multiespectrais (Sensor OLI/Landsat-8) e hiperespectrais (Sensor Hyperio/EO1) com o objetivo de investigar o potencial desses sensores para identificar e mapear áreas salinas, concluíram que a variabilidade da salinidade na região não pode ser facilmente identificada com a resposta espacial dos sensores usados no referido trabalho já que essa característica ocorre em escala menor. Um dos classificadores foi o SVM (Figura 25) constatando que as variações das manchas salinas ocorriam em pequenas distâncias, corroborando com os resultados aqui obtidos.

Figura 25 – Resultado da Classificação do algoritmo SVM correlacionando Índice de Salinidade e a Primeira Componente Principal para identificação de áreas salinas em Morada Nova utilizando os sensores/satélite: (A) OLI/Landsat-8 e (B) Hyperion/EO-1



Fonte: Moreira, Teixeira e Galvão (2015).

6.4 Conclusões

Conclui-se que o modelo calibrado em laboratório foi satisfatório em mensurar a condutividade elétrica em imagens hiperespectrais. Também foi observado que a aplicação de uma calibração por meio de dados de laboratório promove as seguintes vantagens em relação aos modelos calibrados utilizando imagem hiperespectral: obtenção de dados de diferentes datas, não preocupação em relação a interferência em relação a outros elementos como vegetação e água, melhor qualidade do sinal obtido, sem interferência da atmosfera.

Conclui-se também que os comprimentos de onda selecionados (395, 1642, 1717) são interessantes para se diagnosticar o problema de salinidade na região do Perímetro Irrigado de Morada Nova.

É possível utilizar informações de sensores de laboratório para gerar modelos computacionais satisfatórios para se estimar medidas de condutividade elétrica do solo em sensores aerotransportados. Assim como seu desempenho pode ser melhorado pela capacidade de se obter várias amostras em diferentes datas e não presos à necessidade de se obter apenas durante ou próximo à aquisição das imagens.

7 CONCLUSÕES GERAIS

Conclui-se com essa tese que:

Devido a grande dispersão dos dados, os modelos computacionais avaliados não foram eficientes para estimar a CEes a partir dos dados de CE 1:1.

Ao trabalhar com as curvas espectrais obtidas em laboratório por meio do sensor FieldSpec, a análise por componentes principais e a análise derivativa não resultaram em melhorias na modelagem em relação aos dados puros quando o objetivo foi determinar a condutividade elétrica do solo.

Os modelos de seleção de atributos que utilizaram menos bandas espectrais, como o SpecTIR simulado com 357 bandas e Hyperion simulado com 234 bandas, foram mais eficientes do que aqueles utilizando todas as 2151 bandas produzidas pelo sensor FieldSpec.

Os modelos lineares são mais eficientes para estimar condutividade elétrica do solo por meio de dados hiperespectrais obtidos em laboratório do que os modelos não lineares avaliados.

O modelo calibrado em laboratório foi satisfatório em mensurar a condutividade elétrica em imagens hiperespectrais.

A aplicação de uma calibração por meio de dados de laboratório promove as seguintes vantagens em relação aos modelos calibrados utilizando imagem hiperespectral: obtenção de dados de diferentes datas, não preocupação em relação a interferência em relação a outros elementos como vegetação e água, melhor qualidade do sinal obtido, sem interferência da atmosfera.

Os comprimentos de onda selecionados (395, 1642, 1717) são interessantes para se diagnosticar o problema de salinidade na região do Perímetro Irrigado de Morada Nova.

É possível utilizar informações de sensores de laboratório para gerar modelos computacionais satisfatórios para se estimar medidas de condutividade elétrica do solo em sensores aerotransportados. Assim como seu desempenho pode ser melhorado pela capacidade de se obter várias amostras em diferentes datas e não presos à necessidade de se obter dados apenas durante ou próximo à aquisição das imagens.

REFERÊNCIAS

- AGUIAR NETTO, Antenor de Oliveira et al. **Características químicas e salinossidade dos solos do Perímetro Irrigado Califórnia, SE, Brasil.** *Cienc. Rural* [online]. 2007, vol.37, n.6, pp. 1640-1645. ISSN 0103-8478.
- ALVARENGA, B. S.; D'ARCO, E. ; MOREIRA, M. M.; RUDORFF, B. F. T. Avaliação de técnicas de processamento digital de imagens para a estimativa de áreas de arroz irrigado: um estudo de caso no município de Santa Vitória do Palmar/RS. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. 2005. Goiânia. **Anais...** São José dos Campos: INPE, p. 3961-3966, 2005.
- ANDRADE, A. G. P. de. **Comparação de dois métodos de classificação na análise do padrão dinâmico da marcha.** UFMG. 2005. Dissertação de Mestrado.
- BATISTA, G. T. Estudo do Comportamento Espectral das Principais Classes de Cobertura do Solo do Vale do Paraíba e Relação com o Índice de Área Foliar. E-Print **Ciências Agrárias** (<http://hdl.handle.net/2315/45>), v. 45, p 1-11. 2005.
- BAZI, Y., ALAJLAN, N., MELGANI, F., ALHICHRI, H., MALEK, S., YAGER, R. R. Differential evolution extreme learning machine for the classification of hyperspectral images. **IEEE Geoscience And Remote Sensing Letters**. vol. 11. no. 6. 2014.
- BROADWATER, J., BANERJEE, A. Improved atmospheric compensation of hyperspectral imagery using LIDAR. **IEEE International Geoscience and Remote Sensing Symposium**. 2013.
- BOULOMYTIS, V. T. G.; GARCIA, C. E.; Silva, F. B.; TRABAQUINI, K.; CORRÊA, S. C.; Proposta metodológica para o estudo da reflectância e da transmitância de uma superfície lambertiana no âmbito do sensoriamento remoto. **Lat. Am. J. Phys. Educ.** Vol. 5, No. 2, 2011.
- BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais: Teoria e Aplicações.** LTC – Livros Técnicos e Científicos Editora S.A., 2000.
- CARVALHO JUNIOR, O. A. DE; BAPTISTA, G. M. DE M.; MADEIRA NETTO, J. DA S.; MARTINS, É. DE S.; CARVALHO, A. P. F. DE; MENESES, P. R. Utilização de Dados Hiperespectrais do Sensor AVIRIS para Identificação da Feição Espectral da Ligação Magnésio-Hidroxila em Lateritos Niquelíferos. **Anais.** IX Simpósio Brasileiro de Sensoriamento Remoto. Santos. Brasil. 11-18 setembro 1998. INPE. p. 1283-1294.
- CHANG, C.W., LAIRD, D., MAUSBACH, M. J., HURBURGH JR., C.R. Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties. **Soil Science Society of America Journal**, v.65, p.480-490, 2001.
- CHENG, C., WEI, Y., SUN, X., ZHOU, Y. Estimation of Chlorophyll-a Concentration in Turbid Lake Using Spectral Smoothing and Derivative Analysis. **International Journal of Environmental Research and Public Health**. v. 10. p. 2979-2994. 2013.

- CORWIN, D.L., LESCH, S.M. Apparent soil electrical conductivity measurements in agriculture. **Computers and Electronics in Agriculture**, v.46, p.11–43, 2005.
- CSILLAG, F.; PÁSZTOR, L.; BIEHL, L. Spectral band selection for the characterization of salinity status of soils. **Remote Sensing of Environment**. 43, 231–242. 1993.
- DEHAAN, R. L., TAYLOR, G. R. Field-derived spectra of salinized soils and vegetation as indicators irrigation-induced soil salinization. **Remote Sensing of Environment**, v.80, p. 406-417, 2002.
- DELASHMIT, W. H. Recent Developments in Multilayer Perceptron Neural Networks. **Memphis Area Engineering and Science Conference MAESC**. 7th. 2005.
- DEMATTÊ, J. A. M., ARAÚJO, S. R., FIORIO, P. R., FONGARO, C. T., NANNIS, M. R. Espectroscopia VIS-NIR-SWIR na avaliação de solos ao longo de uma topossequência em Piracicaba (SP). **Revista Ciência Agronômica**, v. 46, n. 4, p. 679-688, 2015a.
- DEMATTÊ, J. A. M., ALVES, M. R., GALLO, B. C., FONGARO, C. T., SOUZA, A. B. e, ROMERO, D. J., SATO, M. V. .Hyperspectral remote sensing as an alternative to estimate soil attributes. **Revista Ciência Agronômica**, v.46, n.2, p.223-232, 2015b.
- DETAR, W. R., CHESSON, J. H., PENNER, J. V., OJALA, J. C. Detection of soil properties with airborne hyperspectral measurements of bare fields. **American Society of Agricultural and Biological Engineers**, v.51, p.463-470, 2008.
- DU, Q.; FOWLER, J. E. Low-Complexity Principal Component Analysis for Hyperspectral Image Compression. **International Journal of High Performance Computing Applications**. vol. 22. p. 438-448. 2008.
- DUCART, D. F., CRÓSTA, A. P., SOUZA FILHO, C. R. de. Processamento de imagens hiperespectrais do EO-1/Hyperion para o mapeamento de minerais de alteração hidrotermal na Patagônia Argentina. **Anais, XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, 21-26 abril 2007, INPE, p.6449-6451.
- DUCARTI, F. D. **Caracterização da alteração hidrotermal associadas as ocorrências auríferas de Los Menucos, Argentina, por meio de técnicas de sensoriamento remoto e espectroscopia de reflectância**. Unicamp – SP, 2004. Dissertação de Mestrado.
- EMBRAPA. Centro Nacional de Pesquisa dos Solos (Rio de Janeiro, RJ). **Manual de métodos de análise de solo**. Rio de Janeiro, 1997. 212p.
- ESTEP, L.; CARTER; G. A. Derivative Analysis of AVIRIS Data for Crop Stress Detection. **Photogrammetric Engineering & Remote Sensing**. Vol. 71. No. 12. December. 2005. p. 1417–1421.
- ESWARAN, H., LAL, R., REICH, P. F. Land Degradation: An overview. **International Conference on Land Degradation and Desertification**, Khon Kaen,

Thailand, 2001. Acessado em: 2015.

Link:http://www.nrcs.usda.gov/wps/portal/nrcs/detail/soils/use/?cid=nrcs142p2_054028

FARIFTEH, J., VAN DER MEER, F., VAN DER MEIJDE, M., ATZBERGER, C. Spectral characteristics of salt-affected soils: a laboratory experiment. **Geoderma** 145, 196–206. 2008.

FERREYRA, F. F. H.; SILVA, F. R. Identificação mineralógica das frações areia e argila dos solos aluviais do perímetro K do projeto de irrigação de Morada Nova, Ceará. **Revista Ciência Agronômica**, Fortaleza, v. 22, n. 1/2, p. 29 - 37, jun./dez. 1991.

FIGUEIREDO, G. C., VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto. **Anais. XIII Simpósio Brasileiro de Sensoriamento Remoto**. Florianópolis. Brasil. 21-26 abril 2007. INPE. p. 5755-5762.

FUHR, M. **A new tikhonov regularization method**. University Honors. 2011. Tese de doutorado.

GHEYI, H. R., DIAS, N. S., LACERDA, C. F. Manejo da salinidade na Agricultura: estudos básicos e aplicados. Fortaleza: **INCT Salinidade**, 2010. 472p.

GOWEN, A. A., O'DONNELL, C. P., TAGHIZADEH, M., CULLEN, P. J., FRIAS, J. M., Downey, G. Hyperspectral imaging combined with principal component analysis for bruise damage detection on white mushrooms (*Agaricus bisporus*). **J. Chemometrics**. 2008. 22. p. 259–267.

HE, T., LIANG, S., WANG, D., SHI, Q., GOULDEN, M. L. Estimation of high-resolution land surface net shortwave radiation from AVIRIS data: Algorithm development and preliminary results. **Remote Sensing of Environment**, v.167, p.20–30, 2015.

HE, Y., DESUTTER, T., HOPKINS, D., JIA, X., WYSOCKI, D. A. Predicting EC_e of the saturated paste extract from value of EC1:5. **Canadian Journal Of Soil Science**, v. 93, p. 585-594, 2013.

HIVELY, W. D., MCCARTY, G. W., REEVES III, J. B., LANG, M. W., OESTERLING, R. A., DELWICHE, S. R. use of airborne hyperspectral imagery to map soil properties in tilled agricultural fields. **Applied and Environmental Soil Science**, v. 2011, p. 1-13, 2011.

HOLDEN, H.; LEDREW, E. (1998). Spectral Discrimination of Healthy and Non-Healthy Corals Based on Cluster Analysis, Principal Components Analysis, and Derivative Spectroscopy. **Remote Sensing of Environment**. V. 65. p. 217–224.

HUANG, G. B.; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: Theory and applications. **ScienceDirect. Neurocomputing**. V.70 p. 489–501. 2006.

JOLLIFFE, I. T. **Principal Component Analysis**. 2nd edition. Springer. Heidelberg and New York. 2002.

KAWATA, S.; MINAMI, S. Adaptive smoothing of spectroscopic data by a linear mean-square estimation. **Appl. Spectrosc.** 1984. 38(1): p. 49–58.

KOBAYASHI, C., LAU, I., WHEATON, B., CATER, D., BOURKE, L., ASADA, N., KASHIMURA, O., ONG, C., CUDAHY, T. Estimating soil salinity using hyperspectral data in the western australian wheat belt. **IEEE International Geoscience and Remote Sensing Symposium**, Melbourne, Australia, 2013.

KOONSANIT, K.; JARUSKULCHAI, C.; EIUMNOH, A. Band Selection for Dimension Reduction in Hyper Spectral Image Using Integrated Information Gain and Principal Components Analysis Technique. **International Journal of Machine Learning and Computing**. Vol. 2. No. 3. June. 2012.

KUMAR, U., RAJAS, S. K., MUKHOPADHYAY, C., RAMACHANDRA, T. V. A Multi-layer Perceptron based Non-linear Mixture Model to estimate class abundance from mixed pixels. **IEEE Students' Technology Symposium**. 2011.

KUMAR, S., GAUTAM, G., SAHA, S. K. Hyperspectral remote sensing data derived spectral indices in characterizing salt-affected soils: a case study of Indo-Gangetic plains of India. **Environ Earth Sci**, v.73, p.3299–3308, 2015.

LI, J., DU, Q., LI, W., LI, Y. Improving the Performance of Extreme Learning Machine for Hyperspectral Image Classification. **SPIE**, Vol. 9501, p.1-8, 2015.

LICCIARDI, G., FRATE, F. D. A neural network approach for pixel unmixing in hyperspectral data. **2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)**. 2010.

LIU, Z., SHI, J., ZHANG, L., HUANG, J. Discrimination of rice panicles by hyperspectral reflectance data based on principal component analysis and support vector classification. **Journal of Zhejiang University-SCIENCE B**. v. 11(1). p.71-78. 2010.

LOPES, L. F. D. **Análise de componentes principais à confiabilidade de sistemas complexos**. 2001. Tese (Doutorado Engenharia de Produção) – Universidade Federal Santa Catarina.

LORENZZETTI, J. A. **Princípios Físicos de Sensoriamento Remoto**. Notas de aula dadas no Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1º trimestre de 2002.

LUO, B., CHANUSSOT, J. Hyperspectral image classification based on spectral and geometrical features. **IEEE International Workshop on Machine Learning for Signal Processing**. 2009.

MAKANTASIS, K., KARANTZALOS, K., DOULAMIS, A., DOULAMIS, N. Deep Supervised Learning For Hyperspectral Data Classification Through Convolutional Neural Networks. **Geoscience and Remote Sensing Symposium (IGARSS)**, 2015 IEEE International, p. 26-31 July 2015.

MARKOSKI, P. R. **Avaliação de imagens do sensor ASTER para caracterização e mapeamento de rejeitos de garimpo de ametistas.** Universidade Federal do Rio Grande do Sul, 2006, 70 p. Dissertação de Mestrado.

MASHIMBYE, Z. E., CHO, M. A., NELL, J. P., CLERCQ, W. P. de, VAN NIEKERK, A., TURNER, D. P. Model-based integrated methods for quantitative estimation of soil salinity from hyperspectral remote sensing data: a case study of selected South African soils. **Pedosphere**, v.22, p.640–649, 2012.

METTERNICHT, G. I., ZINK, J.A. Remote sensing of soil salinity: potentials and constraints. **Remote Sensing of Environment**, v.85, p. 1 – 20, 2003.

MILTON, E. J. Principles of field spectroscopy. Int. **Journal of Remote Sensing**, v. 8, n.12, p. 1807-27, 1987.

MONTEIRO, P. F. C. **Efeitos das lâminas de irrigação e da adubação nitrogenada no comportamento espectral da cultura do feijão.** Tese de doutorado. Piracicaba – SP, Escola superior de agricultura Luiz de Queiroz, 2009. 183 p.

MORAIS, P. F. T. B. de. **Estudo do uso da informação mútua na seleção de atributos para o treinamento de redes neurais.** 2009. 59 p. Monografia (Graduação em Ciência da Computação). Universidade Federal de Pernambuco. Recife.

MOREIRA, L. C. J., TEIXEIRA, A. dos S., GALVÃO, L. S. Laboratory Salinization of Brazilian Alluvial Soils and the Spectral Effects of Gypsum. **Remote Sensing**, v.6, p. 2647–2663, 2014.

MOREIRA, L. C. J., TEIXEIRA, A. dos S., GALVÃO, L. S. Potential of multispectral and hyperspectral data to detect salineexposed soils in Brazil. **GIScience & Remote Sensing**, v. 4, p. 416-436, 2015.

MUKAKA, M. M. A guide to appropriate use of Correlation coefficient in medical research. **Malawi Med J.** 2012 Sep; 24(3): 69–71.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. Disponível em: <http://aviris.jpl.nasa.gov>. Acesso: 27 fev. 2012

NAUE, C. R.; MARQUES, M. W.; LIMA, N. B.; GALVÍNCIO, J. D.; Sensoriamento remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. **Revista Brasileira de Geografia Física**. V. 03, 2010. p. 190 – 195.

PEREIRA, F. A. M., MEDINA, B. F., ETCHEVERS, J. D., GHEYI, H. R. Efeito da relação solo-água nos valores de condutividade elétrica. **Agropecuária Técnica**. V.02, Nº 2, 1981, p. 148-154.

PIZARRO, M. A.; FERNANDES, D. Determinação de membros de referência em dados hiperespectrais pelo método da máxima entropia. **Revista Brasileira de Cartografia**. Nº 59/03, 2007.

PLAZA, J., PLAZA, A. Comparative analysis of training strategies for neural network-based spectral unmixing of laboratory-simulated forest hyperspectral scenes. **IAPR workshop on pattern recognition in remote sensing**. 2010.

RAIJ, B.; QUAGGIO, J. A. **Métodos de análise de solo para fins de fertilidade**. Campinas: IAC, 1989. 40p. (Boletim técnico, 8).

RICHARDS, L.A., 1954. **Diagnosis and Improvement of Saline and Saline and Alkali Soils**. (Agricultural Handbook No. 60). US Department of Agricultural. US Government printing office. Washington. DC.

RODARMEL, C.; SHAN, J. Principal Component Analysis for Hyperspectral Image Classification. **Surveying and Land Information Systems**. Vol. 62. No. 2. 2002. p.115-000.

RUDORFF, C. M.; NOVO, E. M. L. M.; GALVÃO L. S.; PEREIRA FILHO, W. Análise derivativa de dados hiperespectrais medidos em nível de campo e orbital para caracterizar a composição de águas opticamente complexas na Amazônia. **Acta Amazonica**. VOL. 37(2). 2007. p.269 – 280.

SAMAT, A., DU, P., LIU, S., LI, J., CHENG, L. E²LMs: Ensemble Extreme Learning Machines for Hyperspectral Image Classification. **IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing**. vol.PP. no.99. p.1,1. 2014.

SANTOS, A. B., ARAÚJO, A. de A., MENOTTI, D. Combining Multiple Classification Methods for Hyperspectral Data Interpretation. **IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing**. vol. 6. no. 3. 2013.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and Differentiation of Data by Simplified Least Squares Procedures. 1964. **Anal. Chem.** 36:1627–1639.

SHAHIN, M. A., SYMONS, S. J. Detection of Fusarium damaged kernels in Canada Western Red Spring wheat using visible/near-infrared hyperspectral imaging and principal component analysis. **Computers and Electronics in Agriculture**. v.75. p. 107–112. 2011.

SILVA, A. P. N. da, SOUZA, L. R. de. Estimativa de Evapotranspiração de Referência no Semiárido Pernambucano. **Engenharia Ambiental**, Espírito Santo do Pinhal, v. 8, n. 4, p. 003-022, out./dez. 2011.

SILVEIRA, K. R.; RIBEIRO, M. R.; OLIVEIRA, L. B.; HECK, R. J.; SILVEIRA, R. R. Gypsum saturated water to reclaim alluvial saline sodic and sodic soils. **Scientiae Agricola**, Piracicaba, v. 65, p. 69-76, 2008.

SONMEZ, S., BUYUKTAS, D., OKTUREN, F., CITAK, S. Assessment of different soil to water ratios (1:1, 1:2.5, 1:5) in soil salinity studies. **Geoderma**, v.144. 2008, p. 361-369.

SOUZA, A. M. de; POPPI, R. J. Experimento didático de quimiometria para análise exploratória de óleos vegetais comestíveis por espectroscopia no infravermelho médio e análise de componentes principais: um tutorial, parte I. **Quím. Nova** [online]. 2012, vol.35, n.1 ISSN 0100-4042.

SOUZA, V. L. C. A. o uso de imagens hiperespectrais com efeitos de reflectância bidirecional na melhoria da classificação de culturas agrícolas. *Revista Eletrônica: Tempo - Técnica - Território*, V.4, N.1 (2013), 1:20 ISSN: 2177-4366.

SOUZA, E. M.O de. **O “novo modelo de irrigação” e os colonos de Morada Nova: política para qual público?**. Fortaleza, 2005, 147 p. Dissertação de Mestrado.

TAVARES FILHO, A. N. **Níveis da Necessidade de Gesso sobre as características físico-químicas e na correção de solos salino-sódicos do Perímetro Irrigado de Ibimirim** – PE. 2010. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Federal Rural de Pernambuco.

TINOCO, S. L. J. L., SANTOS, MENOTTI, D., SANTOS, A. B., SANTOS, J. A. dos. Ensemble of classifiers for remote sensed hyperspectral land cover analysis: an approach based on linear programming and weighted linear combination. **IEEE International Geoscience and Remote Sensing Symposium**. 2013.

TORRECILLA, E.; PIERA, J. Derivative analysis of hyperspectral oceanographic data. **Advances in Geoscience and Remote Sensing**. ISBN 978-953-307-005-6. October. 2009.

TSAI, F.; PHILPOT, W. Derivative Analysis of Hyperspectral Data. **REMOTE SENS. ENVIRON**. v.66, p.41–51, 1998.

TUIA, D., VOLPI, M., MURA, M. D., RAKOTOMAMONJY, A., FLAMARY, R. Automatic Feature Learning for Spatio-Spectral Image Classification With Sparse SVM. **IEEE Transactions On Geoscience And Remote Sensing**, v.52, n.10, p.6062-6074, 2014.

VIEIRA, R. C.; ROISENBERG, M. **Redes Neurais Artificiais: Um Breve Tutorial**. UFSC. Florianópolis. 17 p. 2000.

YAMAMOTOA, S. HOSOYAB, Y. TSUMURAC, N. OGAWA-OCHIAI, K. Principal component analysis for dental shade color. **Dental materials**. v. 28, p. 736–742, 2012.

Yao, R. J., YANG, J. S., GAO, P., SHAO, H. B., LIU, G. M., YU, S. P. Comparison of statistical prediction methods for characterizing the spatial variability of apparent electrical conductivity in coastal salt-affected farmland. **Environ Earth Sci**, v.71, p.233–243, 2014.

YAOHUA, L. GUO, K. SHIBO, Z. ZHONGPING, T. MAOZHI, W. Feature extraction of hyperspectral remote sensing in parallel computing research based on GPU. **Proceedings of the 4th GEOBIA**. May 7-9. 2012 - Rio de Janeiro - Brazil. p.381.

YU, Q. **Machine learning for corporate bankruptcy prediction**. 2013. 117 p. Tese

(Doutorado em Ciências da Computação). School of Science Aalto University. Helsinki.

ZALBA, P., GARAY, M., AMIOTTI, N., ARES, A. Improved field method for estimating soil salinity. **Cienc Suelo**, v. 31(2), p. 265-269, 2013.

ZHANG, H., SCHRODER, J. L., PITTMAN, J. J., WANG, J. J., PAYTON, M. E. Soil salinity using saturated paste and 1:1 soil to water extracts. **Soil Science Society of America Journal**, v. 69, 2005, p. 1146-1151.

ZHANG, J., WU, J., ZHOU, L. Estimation of vegetation equivalent water thickness using hyperspectral data and partial least square regression. **18th International Conference on Geoinformatics**. 2010.

ZHANG, T., SHAO, Y.1, GONG, H., LI, L., WANG, L. Salt Content Distribution and Paleoclimatic Significance of the Lop Nur “Ear” Feature: Results from Analysis of EO-1 Hyperion Imagery. **Remote Sensing**, v. 6, p. 7783-7799, 2014.

ZHAO, L., ZHANG, K. A new least squares subspace projection approach to unmix hyperspectral data. **WRI Global Congress on Intelligent Systems**. 2009.

ZHOU, Y., PENG, J., CHEN, C. L. P. Extreme Learning Machine With Composite Kernels for Hyperspectral Image Classification. **IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing**, vol. 8, no. 6, 2015.

APÊNDICE

Algoritmo de avaliação utilizado no tópico 5

```

%Algoritmo para a validação leave-one-out para: 5. ESTIMATIVA DE
%CONDUTIVIDADE ELÉTRICA DE EXTRATO DE SATURAÇÃO POR MEIO DE
EXTRATO 1:1
%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira

%limpar tela
clear all
clc

%carregar os dados
load 'pontos_matlab.txt'
dados=pontos_matlab(:,3:4);
dados=[padronizados(dados(:,1),0,1),padronizados(dados(:,2),0,
1)];
[tm1 tm2]=size(dados);
X=[ones(tm1,1),dados(:,1)];
Y=dados(:,2);
desempenho=[0,0,0,0];
modelo=1;
for i=1:tm1
if i==1
Xt=X(2:end,:);Yt=Y(2:end);
Xv=X(i,:);Yv=Y(i);
end
if i>1&&i<tm1
Xt=[X(1:(i-1),:);X(i+1:end,:)];Yt=[Y(1:(i-1));Y(i+1:end)];
Xv=X(i,:);Yv=Y(i);
end
if i==tm1
Xt=X(1:(i-1),:);Yt=Y(1:(i-1));
Xv=X(i,:);Yv=Y(i);
end

if modelo==1
beta = MQ(Xt,Yt,2,0);%função na raiz criada na raiz
r2=calculaR2MQ(1,Xt,Yt,beta);%função criada na raiz
r2a=calculaR2MQ(2,Xt,Yt,beta);
Y2v=Xv*beta;
end

if modelo==2
[w1,w2,custo]=MLP(Xt,Yt,2,0.1,1,1000,0.95,.1);
r2=calculaR2MLP(1,w1,w2,1,Xt,Yt);%função criada na raiz
r2a=calculaR2MLP(1,w1,w2,2,Xt,Yt);
uy2=Xv*w1';
y2temp= 1./(1 + exp(-uy2));
Y2v= [ones(tm1,1),y2temp] * w2;
end

if modelo==3
[w1,w2]=ELM(Xt,Yt,10,0.00001,1);%função na raiz do programa
r2=calculaR2ELM(1,w1,w2,1,Xt,Yt);%função criada na raiz

```

```

r2a=calcularR2ELM(1,w1,w2,2,Xt,Yt);
uy2=Xv*w1';
y2temp= 1./(1 + exp(-uy2));
Y2v= y2temp * w2;
end

desempenho(i,:)=[r2,r2a,Yv,Y2v];
end
[tm2 tm1]=size(desempenho);
y=desempenho(:,3);y2=desempenho(:,4);
%Erro quadrático médio
EQM= sum((y2-y).^2)/tm2;

%Coeficiente de correlação de Pearson
r= (tm2*sum(y.*y2)-sum(y)*sum(y2))/((tm2*sum(y.^2)-
sum(y)^2)*(tm2*sum(y2.^2)-sum(y2)^2))^0.5);

%Índice de Concordância de Willmott
ym= mean(y); y2m= mean(y2);
Id= 1-(sum((y2-y).^2)/(sum((abs(y2-ym)+ abs(y-ym)).^2)));

%Índice de confiança ou desempenho
c= r*Id;

%Taxa de desvio da performance
SD= std(y);
RPD= SD/sqrt(EQM);

DESEMPENHO= mean(desempenho(:,1:2));
DESEMPENHO(3:7)= [EQM,r,Id,c,RPD];

```

Funções complementares

Cálculo dos pesos para o algoritmo MQ

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function resposta=MQ(X,Y,modelo,vetor1)
%resposta->matriz de transformação BETA
%X->matriz/vetor de entradas
%Y-> Matriz/vetor de saídas
%modelo->qual o procedimento de cálculo sendo 1->pinv e 2->modelo
escrito
%da pseudoinversa
%vetor1-> se quer ou não o vetor de 1 (sendo 0, caso não queria ou
1 caso
%querendo)
if vetor1==1
[tm1 tm2]=size(X);
X=[X;ones(tm1)];
end
if modelo==1
resposta=pinv(X)*Y;
end
if modelo==2

```

```

resposta=inv(X'*X)*X'*Y;
end

```

Cálculo dos pesos para o algoritmo MLP

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function [w z custo]=MLP(X,Y,NCI,b,modelo,epoc,alfa,Ed)
%w->Pesos da primeira camada
%z->pesos da segunda camada
%custo->vetor referente ao custo da rede por passagem
%X->vetor/matriz de entrada
%Y->Vetor de Saída
%NCI-> número de neuronios da camada intermediária
%b->fator de escala, interessante ser numero bem pequeno
%modelo-> representa do modelo não linear aplicado. 1->sigmoide
logistica
%[0,1];2->tangente hiperbólica[-1,1]
%epoc-> número de passagens do código
%alfa->taxa de aprendizagem
%Ed->erro mínimo desejado
%MLP
%definição do número de interações e o peso da aprendizagem
[aux ent] = size(X);

%Inicialização dos pesos e bias
a = 0;
w = a+(b-a).*rand(NCI,ent);
z = a+(b-a).*rand(1,(NCI + 1));
NDT = aux; % numero de treinamento
t=1;
E=100;
custo = ones(1,epoc) * Ed;
display = 0;

while (t<(epoc+1)) && (E>Ed)

    E1 = 0;
    ERRO = 0;
    %cada época
    for i = 1:NDT
        %cálculo do feedforward
        u=X(i,:)*w';
        if modelo==1
            yO = 1./(1 + exp(-u));
        end
        if modelo==2
            yO = (1-exp(-u))./(1+exp(-u));
        end
        yC(i)= [1,yO]*z';

        %cálculo do ERRO
        erro = Y(i) - yC(i);
        E1= E1 + (erro ^2);
        ERRO = ERRO + abs(erro);
    end
    t=t+1;
    E=E1;
end
custo=custo+t;

```

```

        %cálculo da sensibilidade e atualização dos pesos da última
camada

        deriFz = yC(i) * (1 - yC(i));
        sensibilidadeZ = - erro * deriFz;

        %atualização dos pesos
        z = z - (alfa * sensibilidadeZ*[1,y0]);

dos

        %cálculo da sensibilidade da camada escondida e atualização

        %pesos
        if modelo==1
            deriFw= y0.*(1.-y0);
        end
        if modelo==2
            deriFw=SECH(y0).^2;
        end
        sensibilidadew = deriFw.*z(:,2:end)*sensibilidadeZ;
        aux=length(sensibilidadew);
        temp1=w ;
        for j=1:aux
            w(j,:)= w(j,:)-(alfa*sensibilidadew(j)*X(i,:));
        end
        temp2=w;
    end

    E = ERRO/NDT;
    Et(t)=E;
    CUSTO = E1 / (NDT * 2);
    custo(t) = CUSTO;
    t = t + 1;

end

```

Cálculo dos pesos para o algoritmo ELM

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function [W M]=ELM(X,Y,q,b,modelo)
%W->Pesos da primeira camada
%M->pesos da segunda camada
%X->vetor/matriz de entrada
%Y->Vetor/matriz de Saída
%q-> número de neuronios da camada intermediária
%b->fator de escala, interessante ser numero bem pequeno
%modelo-> representa do modelo não linear aplicado. 1->sigmoide
logistica
%[0,1];2->tangente hiperbólica[-1,1]
%ELM
%número de entradas
[~, p] = size(X);

%criação dos pesos aleatoriamente
a = 0;

```

```

W = a+(b-a).*rand(q,p);
%camada oculta
u = X * W';
if modelo==1
    y0 = 1./(1 + exp(-u));
end
if modelo==2
    y0 = (1-exp(-u))/(1+exp(-u));
end
%mínimos quadrados
M = inv(y0'*y0)*y0'*Y;

```

Cálculo do R^2 para o algoritmo MQ

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function resposta=calculaR2MQ(modeloR2,X,Y,Matriz)
%resposta->retorna o r2 ou o r2 ajustado
%modeloR2->modelo de r2 desejado sendo 1->r2 e 2->r2 ajustado
%X-> dados de entrada
%Y-> dados de saída
%Matriz-> matriz de transformação do modelo testado

Y2 = X*Matriz;

Ym = mean(Y); Y2m = mean(Y2);
SSTO = sum((Y-Ym).^2); SSR = sum((Y2-Y2m).^2);
r2 = SSR/SSTO;

if modeloR2==1
    resposta=r2;
end
if modeloR2==2
    [n p]= size(X);
    r2a=1-((n-1)/(n-p))*(1-r2);
    resposta=r2a;
end

```

Cálculo do R^2 para o algoritmo MLP

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function resposta=calculaR2MLP(ativacao,W,Z,modeloR2,X,Y)
%resposta->retorna o r2 ou o r2 ajustado
%ativacao-> função de ativação. 1->sigmóide logística, 2->tangente
%hiperbólica
%W->pesos das primeira camada
%Z->pesos da segunda camada
%modeloR2->modelo de r2 desejado sendo 1->r2 e 2->r2 ajustado
%X-> dados de entrada
%Y-> dados de saída
%Matriz-> matriz de transformação do modelo testado

```

```

%calculo de y2
uy2=X*W';
if ativacao == 1
    y2temp= 1./(1 + exp(-uy2));
end
if ativacao ==2
    y2temp=(1-exp(-uy2))/(1+exp(-uy2));
end
[tm1 tm2]=size(y2temp);
y2= [ones(tm1,1),y2temp] * Z';

Ym = mean(Y); Y2m = mean(Y2);
SSTO = sum((Y-Ym).^2); SSR = sum((Y2-Y2m).^2);
r2 = SSR/SSTO;

if modeloR2==1
    resposta=r2;
end
if modeloR2==2
    [n p]= size(X);
    r2a=1-((n-1)/(n-p))*(1-r2);
    resposta=r2a;
end

```

Cálculo do R^2 para o algoritmo ELM

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function resposta=calculaR2ELM(ativacao,W,M,modeloR2,X,Y)
%resposta->retorna o r2 ou o r2 ajustado
%ativacao-> função de ativação. 1->sigmóide logistica, 2->tangente
%hiperbólica
%W->pesos das primeira camada
%M->pesos da segunda camada
%modeloR2->modelo de r2 desejado sendo 1->r2 e 2->r2 ajustado
%X-> dados de entrada
%Y-> dados de saída
%Matriz-> matriz de transformação do modelo testado

%calculo de y2
uy2=X*W';
if ativacao == 1
    y2temp= 1./(1 + exp(-uy2));
end
if ativacao ==2
    y2temp=(1-exp(-uy2))/(1+exp(-uy2));
end
Y2= y2temp * M;

Ym = mean(Y); Y2m = mean(Y2);
SSTO = sum((Y-Ym).^2); SSR = sum((Y2-Y2m).^2);
r2 = SSR/SSTO;

```

```

if modeloR2==1
    resposta=r2;
end
if modeloR2==2
    [n p]= size(X);
    r2a=1-((n-1)/(n-p))*(1-r2);
    resposta=r2a;
end

```

Algoritmo de seleção de atributos utilizado no tópico 6

```

%teste do algoritmo para a validação leave-one-out
%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
%limpar tela
clear all
clc

%carregar os dados
load 'dadosCE.txt'
%dados2=dadosCE;
load 'dadosCE31082015.txt'
dados=[dadosCE31082015;dadosCE];
[tm1 tm2]=size(dados);
CE=dados(:,1);
%-----Entrada dos Dados-----
resolucao=2; %1- fildspec, 2-spectir, 3-hyperion
tratamento=3; %1-sem tratamento, 2-derivativa, 3-acp
padronizaCE=1; %normaliza a Ce: 1-não normaliza, 2-Normaliza entre
0-1

%-----Tratamento de Dados-----
banda=bandaselecionadasensor(resolucao,350,2500);
    if resolucao==1 %ate achar a solucao da funcao acima
        banda=[350:1:2500]';
    end
%-----Resolução espectral-----
if resolucao==1
    CEajustado=dados(:,2:end);
end
if resolucao==2
    CEajustado=ajustesensor(dados,resolucao,2,350,2500,0);%função
criada na raiz do
    %arquivo
end
if resolucao==3
    CEajustado=ajustesensor(dados,resolucao,2,350,2500,0);%função
criada na raiz do
    %arquivo
end
%-----tratamento dos dados-----
if tratamento==2
    CEajustado=derivspect(CEajustado,banda,1);
end

if tratamento==3
    AUTOVETOR=acp(CEajustado,0,1,0);

```

```

    CEajustado=CEajustado*AUTOVETOR;
end

if padronizaCE==2
CE=padronizados(CE,0,1);%função criada na raiz do arquivo
end

CE=[CE,CEajustado];
%-----Seleção de Atributos-----
[tm1 tm2]=size(CE);
selecionado = [0,0,0];%[Numero da linha, banda, r2a]
Dadosfixos=ones(tm1,1);
for z=1:(floor(0.25*tm1))%->número de atributos selecionados
tic
for j=2:tm2%j->banda espectral
teste =0;
if find(selecionado(:,2)==(j-1))>0
teste=1;
%r2
R2a((j-1),:)= [j,-9999];
end

if teste==0
dados=[CE(:,1),Dadosfixos,CE(:,j)];
SD=std(dados(:,1));
%separação de X e Y dos dados
Xt = dados(:,2:end);
Yt = dados(:,1);
beta = pinv(Xt)*Yt;
%Avaliação dos dados de calibração
Yt2 = Xt*beta;
Ytm = mean(Yt); Yt2m = mean(Yt2);
SSTO = sum((Yt-Ytm).^2); SSR = sum((Yt2-Yt2m).^2);
r2 = SSR/SSTO;
[n p]= size(Xt);
r2a=1-((n-1)/(n-p))*(1-r2);
R2a((j-1),:)= [ (j-1), r2a];

end
end

selecionado(z,1)= z;
[selecionado(z,3),selecionado(z,2)] = max(R2a(:,2));
Dadosfixos(:,(z+1))=CE(:,(selecionado(z,2))+1);
if selecionado(z,3)>0.95
break
end
z
tempo=toc
end
if tratamento~=3
Selecionados=banda(selecionado(:,2));
end
if tratamento==3
CompSel=selecionado(:,2);
end

```

Algoritmo de avaliação dos modelos de regressão utilizado no tópico 6

```

%Algoritmo para a validação leave-one-out para:6.  AVALIAÇÃO DE
ALGORITMOS
%COMPUTACIONAIS NA DETERMINAÇÃO DA CONDUTIVIDADE ELÉTRICA DE SOLOS
SALINOS POR MEIO DE DADOS HIPERESPECTRAIS.
%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira

%limpar tela
clear all
clc

%modelo avaliado
modelo=1;%1->MQ 2->MLP 3->ELM
tratamento=1;%1->sem tratamento 2->derivativa 3->acp

%carregar os dados
if modelo==1
    if tratamento==1
        load 'MQST.txt'
        dados=MQST;
    end
    if tratamento==2
        load 'MQD.txt'
        dados=MQD;
    end
    if tratamento==3
        load 'MQACP.txt'
        dados=MQACP;
    end
end
if modelo==2
    if tratamento==1
        load 'MLPST.txt'
        dados=MLPST;
    end
    if tratamento==2
        load 'MLPD.txt'
        dados=MLPD;
    end
    if tratamento==3
        load 'MLPACP.txt'
        dados=MLPACP;
    end
end
if modelo==3
    if tratamento==1
        load 'ELMST.txt'
        dados=ELMST;
    end
    if tratamento==2
        load 'ELMD.txt'
        dados=ELMD;
    end
    if tratamento==3
        load 'ELMACP.txt'
        dados=ELMACP;
    end
end
end

```

```

[tm1 tm2]=size(dados);
X=dados(:,2:end);
Y=dados(:,1);
desempenho=[0,0,0,0];

for i=1:tm1
if i==1
    Xt=X(2:end,:);Yt=Y(2:end);
    Xv=X(i,:);Yv=Y(i);
end
if i>1&&i<tm1
    Xt=[X(1:(i-1),:);X(i+1:end,:)];Yt=[Y(1:(i-1));Y(i+1:end)];
    Xv=X(i,:);Yv=Y(i);
end
if i==tm1
    Xt=X(1:(i-1),:);Yt=Y(1:(i-1));
    Xv=X(i,:);Yv=Y(i);
end

if modelo==1
beta = MQ(Xt,Yt,2,0);%função na raiz criada na raiz
r2=calculaR2MQ(1,Xt,Yt,beta);%função criada na raiz
r2a=calculaR2MQ(2,Xt,Yt,beta);
Y2v=Xv*beta;
end

if modelo==2
[w1,w2,custo]=MLP(Xt,Yt,2,0.1,1,1000,0.5,.1);
r2=calculaR2MLP(1,w1,w2,1,Xt,Yt);%função criada na raiz
r2a=calculaR2MLP(1,w1,w2,2,Xt,Yt);
uy2=Xv*w1';
y2temp= 1./(1 + exp(-uy2));
Y2v= [ones(tm1,1),y2temp] * w2;
end

if modelo==3
[w1,w2]=ELM(Xt,Yt,10,0.00001,1);%função na raiz do programa
r2=calculaR2ELM(1,w1,w2,1,Xt,Yt);%função criada na raiz
r2a=calculaR2ELM(1,w1,w2,2,Xt,Yt);
uy2=Xv*w1';
y2temp= 1./(1 + exp(-uy2));
Y2v= y2temp * w2;
end

desempenho(i,:)= [r2,r2a,Yv,Y2v];
end
[tm2 tm1]=size(desempenho);
y=desempenho(:,3);y2=desempenho(:,4);
%Erro quadrático médio
EQM= sum((y2-y).^2)/tm2;

%Coeficiente de correlação de Pearson
r= (tm2*sum(y.*y2)-sum(y)*sum(y2))/(((tm2*sum(y.^2)-
sum(y)^2)*(tm2*sum(y2.^2)-sum(y2)^2))^0.5);

%Índice de Concordância de Willmott
ym= mean(y); y2m= mean(y2);
Id= 1-(sum((y2-y).^2)/(sum((abs(y2-ym)+ abs(y-ym)).^2)));

%Índice de confiança ou desempenho

```

```

c= r*Id;

%Taxa de desvio da performance
SD= std(y);
RPD= SD/sqrt(EQM);

DESEMPENHO= mean(desempenho(:,1:2));
DESEMPENHO(3:7)= [EQM,r,Id,c,RPD];

```

Função auxiliar para determinar o vetor de bandas espectrais

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function
resposta=ajustesensor(matriz,sensor,colunainicial,compondainicial,comp
ondafinal,n)
%matriz->dados que desejam ajustar onde:nas linhas são as repetições e
nas
%colunas os dados como comprimento de onda e variáveis analisadas
%(obs:espectros contínuos com comprimento de onda 1 em 1 nm
%sensor->o sensor desejado ou ajuste de resolução(3-hyperion,2-
spectir)

%coluna inicial->a primeira coluna onde contém o espectro
%comprimento inicial: primeiro comprimento contido na matriz
%comprimento final: último comprimento de onda contido na matriz
%n= para criar uma coluna de 1 no começo dos dados, n=1 ->cria coluna
de 1,
%n=0-> não cria coluna de 1
if sensor==3
x=[355.5900000000000;...; 2577.080000000000;];
x=floor(x*1000);
y=x(find(x>=compondainicial&x<=compondafinal));
y=y-compondainicial+1;
end
if sensor==2
x=[0.3958000000000000;...;2.454210000000000;];
x=floor(x*1000);
y=x(find(x>=compondainicial&x<=compondafinal));
y=y-compondainicial+1;
end

resposta=matriz(:,colunainicial:end);
temp=[compondainicial:1:compondafinal];
resposta=[temp;resposta];
resposta=resposta(2:end,y);

if n==1
[tm1 tm2]=size(resposta);
resposta=[ones(tm1,1),resposta];
end

```

Função auxiliar para reamostrar a resolução espectral de acordo com o sensor hiperspectral desejado

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function
resposta=ajustesensor(matriz,sensor,colunainicial,compondainicial,comp
ondafinal,n)
    %matriz->dados que desejam ajustar onde:nas linhas são as
repetições e nas
    %colunas os dados como comprimento de onda e variáveis analisadas
    %(obs:espectros continuos com comprimento de onda 1 em 1 nm
    %sensor->o sensor desejado ou ajuste de resolucao(3-hyperion,2-
spectir)

    %coluna inicial->a primeira coluna onde contem o espectro
    %comprimento inicial: primeiro comprimento contido na matriz
    %comprimento final: último comprimento de onda contido na matriz
    %n= para criar uma coluna de 1 no começo dos dados, n=1 ->cria
coluna de 1,
    %n=0-> não cria coluna de 1
    if sensor==3
        x=[355.590000000000;...;2577.080000000000;];
        x=floor(x);
        y=x(find(x>=compondainicial&x<=compondafinal));
    end
    if sensor==2
        x=[0.3958000000000000;...;2.4542100000000000;];
        x=floor(x*1000);
        y=x(find(x>=compondainicial&x<=compondafinal));
    end

    resposta=matriz(:,colunainicial:end);
    temp=[compondainicial:1:compondafinal];
    resposta=[temp;resposta];
    resposta=resposta(2:end,find(y));
    if n==1
        [tm1 tm2]=size(resposta);
        resposta=[ones(tm1,1),resposta];
    end
end

```

Função auxiliar para aplicar análise derivativa

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function resposta=derivspect(dadosX,bandas,n)
%resposta->transformação dos dadosX para solução da derivada
%dadosX->dados que se deseja transformar
%bandas-> vetor indice das bandas espectrais
%n->método de derivativa (1-posteriore,2-media)
[tm1 tm2]= size(dadosX);
if n==1
    resposta= zeros(tm1,(tm2-1));
end

```

```

    for i=1:(tm2-1)
        resposta(:,i) = (dadosX(:,(i+1))-dadosX(:,i))/(bandas(i+1)-
bandas(i));
    end
end
if n==2
    resposta= zeros(tm1,(tm2-2));
    for i=1:(tm2-2)
        resposta(:,i) = (dadosX(:,(i+2))-dadosX(:,i))/(bandas(i+2)-
bandas(i));
    end
end
end

```

Função auxiliar para aplicar análise da componente principal

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function resposta=acp(dadosX,Argumento,qdes,ncomponentes)
%resposta->matriz de transformação, necessário multiplicar a
matriz de
%dados e esta matriz (EX: xTACP = X*Q)
%Argumento-> definir redução de dimensionalidade(0-sem redução;1-
redução a
%partir da variância explicada (q); 2-por meio do número de
componentes
%desejado;3-por meio da solução Kaiser 1958 apud norusis
1990(selecionar as
%componentes cujo o autovalor é superior a 1)
%qdes->variância explicada desejada (caso não queria, por 1) (de 0
a 1)
%ncomponentes->numero de componentes desejado (caso nao queira por
0)

%Passo 1, organizando os atributos e tirando a média
[tm1 tm2] = size(dadosX);
Xmedia = mean(dadosX);
%Passo 2: subtrair a média
Xc = dadosX - repmat(Xmedia, tm1, 1);
%Passo 3: estimar a matriz de covariância
Cx = cov(Xc);
%Passo 4: obter os autovalores e autovetores da matriz de
covariância
[Vi, Li] = eig(Cx);
%Passo 5: reordenar os autovetores
Vi = fliplr(Vi);
Li = fliplr(diag(Li)');
%determinar a significância dos autovetores
i=tm2;
if Argumento~=0
    for i = 1 : tm2

        if Argumento==1
            q = sum(Li(1 : i))/sum(Li(1 : tm2));
            if q >= qdes%ajustar a variância explicada
                break
            end
        end
    end
end

```

```

end
if Argumento==2
    i=ncomponentes;
    break

end
if Argumento==3
    if Li(i) <1%solução por kaiser 1958 apud norusis 1990
        i=i-1;
        break
    end
end
end

end
end
resposta = Vi(:, 1 : i);

```

Função auxiliar para normalização dos dados

```

%Tese de doutorado: ESTIMATIVA DA CONDUTIVIDADE ELÉTRICA POR MEIO
%DE DADOS HIPERESPECTRAIS EM SOLOS AFETADOS POR SAIS
%Autor: Odílio Coimbra da Rocha Neto
%Orientador: Adunias dos Santos Teixeira
function
resposta=padronizadados(vetor,limiteinferior,limitesuperior)
    %vetor->vetor que quer que seja padronizado
    %limite inferior->ajuste desejado para o menor valor
    %limite superior->ajuste desejado para o maior valor
    tempmin=min(vetor); tempmax=max(vetor);
    resposta=((vetor-tempmin)/(tempmax-tempmin))*(limitesuperior-
limiteinferior)+limiteinferior;
end

```

ANEXO

Caracterização do sensor ProSpecTIR acessado em: http://www.spectir.com/wp-content/uploads/2012/02/ProSpecTIR_VS_specs_2011.pdf

www.spectir.com



ProSpecTIR™ VS

VNIR – SWIR Hyperspectral Instrument

SpecTIR™ presents the ProSpecTIR™ VS as part of our full line of pushbroom-imaging spectral instruments for remote sensing. The rugged high-performance instruments have superior spectral imaging capability and are built with components for maximum performance and utility - great performing dispersive optics, high dynamic range imaging devices, an integrated GPS/INS sensor, a durable housing, all integrated with flight operations and recording hardware.

The ProSpecTIR™ VS instrument has dual sensors individually covering visible/near-infrared (VNIR) wavelengths of 400-1000nm and short-wave infrared (SWIR) in the 1000-2500nm wavelength range. The dual sensors are co-boresighted and include all hardware, acquisition and processing software for flight operations and spectral mapping with a choice of navigation packages.

The ProSpecTIR™ VS can be installed in almost any light aircraft with aerial camera capability. The imagery is navigated with the integrated DGPS/IMU and, when processed with the included CalGeo software, provides geo-referenced radiance and reflectance files readily imported into ENVI or other spectral analysis programs.



Mounted sensor system dimensions
25 x 19 x 16 inches (HWD)



Total Turnkey Remote Sensing System

All ProSpecTIR™ systems provide an integrated turnkey solution, ready for installation and operation.

The VS system consists of:

- VNIR + SWIR hyperspectral sensors with all cables and connections
- Real time acquisition computer with user-friendly flight operations software
- GPS/INS navigation and flight solution
- Power supplies
- CalGeo post-processing software

The ProSpecTIR dual system is ideal for geological applications. Sample data of Buddingtonite Outcrops, Cuprite, NV USA

SpecTIR™ is an Equal Opportunity/Affirmative Action Employer. All Rights Reserved



www.spectir.com



ProSpecTIR™ VS Instrument

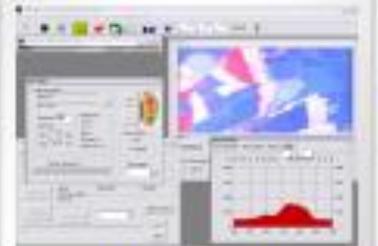
PROSPECTIR™ VS TYPICAL SPECIFICATIONS						
SPECTRAL RANGE	VNIR 400-975 nm			SWIR 975-1650 nm		
	Total 1000-2550 nm					
SPECTRAL RESOLUTION (OPTICAL)	VNIR 2.8 nm			SWIR 3.3 nm		
	*100 typical operation, 100 at highest resolution					
SPECTRAL CHANNELS	VNIR			SWIR		
	2x	2x	6x	2x	2x	6x
SPECTRAL CHANNELS	204			28		
	11.2	60		2.8	11.6	28.2
SPECTRAL SAMPLING (nm)	2.8			3.3		
	5.6	6.2		6.6	11.6	28.2
TERRAIN COVERAGE & FIELDS OF VIEW						
SPATIAL PIXELS	320					
FOV	28 degrees					
FOV	0.675 degrees (L to small)					
OPERATIONAL CHARACTERISTICS						
CAMERA A/D	VNIR	16 BIT 12 bits		SWIR	16 BIT 12 bits	
SNR	150:1 typical, 750:1 peak			650:1 typical, 1200:1 peak		
INTEGRATION PERIODS	adjustable at each camera for optimum exposure levels					
IMAGE RATE	Up to 300 images/s					
MECHANICAL						
DIMENSIONS	28 x 19 x 18 inches (HWD)					
WEIGHT	100kg nominal					
ENVIRONMENTAL						
TEMPERATURE	+5°C to + 35° C Operational			+5°C to + 35° C Storage		
HUMIDITY	5 - 95% Operational			5-95% Storage		
VIBRATION	10-2000 Hz, 10 min (transportation) 10 - 2000 Hz, 2.5g, 2 Out/hrs (resonance) [MIL-STD-883C Method 314.6, Procedure 2]					
SHOCK	20g, 15ms, each/axis pulse [MIL-STD-883C Method 314.6, Procedure 2]					

DESCRIPTION OF OPERATIONS AND DATA COLLECTION

The VNIR and SWIR data are combined and saved in a single image covering the spectral range of 400 to 2500 nm.

A single flight operations computer is used for data acquisition, collecting both the VNIR and SWIR data coincident swath width of 320 pixels.

RSCube Remote Sensing Software provides images and information to the flight operator, controlling flight experiments and data recording.



Images from both the VNIR and SWIR are acquired synchronously with each other and time stamped and tagged with GPS information and line-of-sight information from the Inertial Navigation System.



See more details and example applications at www.spectir.com/products.html

SpecTIR™ is an Open-Source, Virtual-Airborne Sensor. © All Rights Reserved



**Relatório fornecido pela empresa FOTOTERRA em relação a aquisição
da imagem SpectIR.**



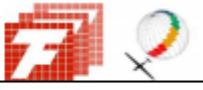
RELATÓRIO TÉCNICO

**DESCRITIVO DO MAPEAMENTO
HIPERESPECTRAL NA REGIÃO DE
MORADA NOVA (CE)**

Data: 2015-06-02

Elaboração: MSc. Alexander Sergio Evaso – FotoTerra

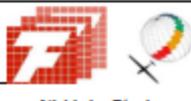
FotoTerra Atividades de Aerolevantamentos Ltda
Rua Traipú, 509 – Pacaembu
01235-000 - São Paulo-SP-Brasil
phone:+55 (11) 3883
www.FotoTerra.com.br

 Atividades Técnicas	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 2 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

Conteúdo

Conteúdo.....	2
1 OBJETIVO.....	3
2 INTRODUÇÃO.....	3
3 ÁREA DO PROJETO.....	4
4 DETALHAMENTO DA METODOLOGIA DE EXECUÇÃO, ANÁLISE E PADRONIZAÇÃO.....	5
4.1 Sobre a aquisição dos dados.....	5
4.1.1 Especificações sobre o levantamento.....	5
4.1.2 Sobre levantamentos especiais.....	6
4.1.3 Determinação da área de projeto e planejamentos de voo.....	6
4.1.4 Descrição do levantamento.....	6
4.2 Sobre o processamento dos dados.....	7
4.2.1 Radiância.....	7
4.2.2 Mapas de Saturação.....	8
4.2.3 Processamento da Refletância.....	9
4.2.4 Refletância VELC.....	10
4.2.5 Processamento de Geocorreções (Georreferenciamento).....	11
4.3 Padronização de diretórios de entrega.....	12
5 CONCLUSÃO.....	13
6 SOFTWARES.....	13
Figura 1 – Localização do Levantamento Hiperespectral do Quadrilátero Ferrífero.....	4
Figura 2 – Inserção de um Monocromador em um sistema de medição / calibração.....	7

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 3 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

1 OBJETIVO

O presente relatório tem como objetivo descrever a metodologia de calibração, coleta, processamento e padronização, de forma a abrir o caminho para a futura classificação imagens hiperespectrais, objetivando a geologia.

2 INTRODUÇÃO

Para a realização das atividades, a FotoTerra conta com profissionais qualificados com intuito de garantir a qualidade e precisão das coletas, interpretação e organização de material. Para tanto, são utilizados softwares de interpretação de imagens e de navegação nas versões mais atualizadas, equipamentos de posicionamento geodésico por satélites, entre outros.

A FotoTerra visando sempre a qualidade de seus produtos, procura sempre seguir todas as normas técnicas que dispõem a respeito de aerolevanteamento e levantamento geodésicos em âmbito nacional.

 Atividades Técnicas	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC - 2.0.14	
		Revisão: 00	Folha: 4 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

3 ÁREA DO PROJETO

As atividades foram inicialmente projetadas para serem realizadas em quatro áreas distintas, contudo, por inviabilidade climática, apenas uma área foi executada em primeira oportunidade (circunscrita em preto), a do oeste de Ouro Preto. Todo o restante do lote do Quadrilátero Ferrífero foi executado no presente voo, e está destacado pelos três polígonos circunscritos pela área vermelha. O projeto inteiro se encontra no centro sul-sudeste dos estado de Minas Gerais.

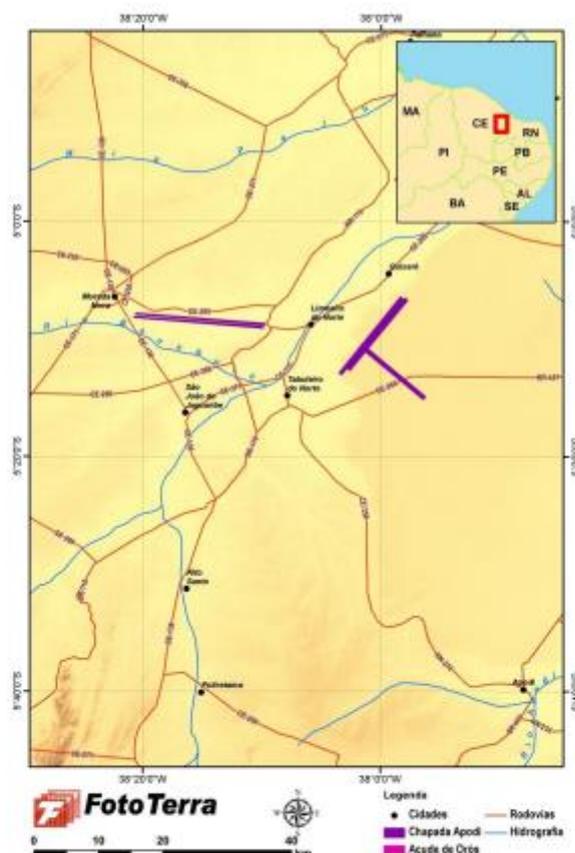


Figura 1 – Localização do Levantamento Hiperespectral de Morada Nova.

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 5 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

4 DETALHAMENTO DA METODOLOGIA DE EXECUÇÃO, ANÁLISE E PADRONIZAÇÃO

A Fototerra, em parceria com a SpecTIR, LLC (EUA), foi contratada para a aquisição, processamento e entrega de dados de imagens hiperespectrais, utilizando o sensor ProSpecTIR-VS. Este relatório descreve o planejamento, o levantamento, o processamento de dados e os arquivos de entrega final envolvidos na conclusão deste trabalho.

Os dados a serem entregues são gerados em formato legível do ENVI, que também é diretamente acessível por meio de outros programas de processamento de imagens, como o ERDAS Imagine. Os arquivos ASCII *.hdr associados a estes trazem consigo todas as informações necessárias para importar os dados para dentro de qualquer outra plataforma de análise comercial ou personalizada.

4.1 Sobre a aquisição dos dados

4.1.1 Especificações sobre o levantamento

Configurações específicas de sistema, tal como o tempo de integração e a taxa de quadros por segundo para cada arquivo de dados podem ser encontradas no arquivo ENVI *.hdr associado, dentro do diretório DATA. Esses arquivos ASCII também incluem outras informações, como os horários inicial e final e as respectivas localizações para cada arquivo de dados, a lista completa dos comprimentos de onda centrais, as larguras de banda e valores de FWHM (full width half mean).

Para uma coleção de dados qualquer, os parâmetros gerais de aquisição são os seguintes:

- Localidade
 - Sistema Sensor
 - Amplitude Espectral
 - Resolução Espectral
 - Numero de Bandas
 - Ground Spatial Distance (GSD)
-

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 6 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

4.1.2 Sobre levantamentos especiais

Existem configurações específicas, que atendem as diversas necessidades de um cliente. Nesse sentido, sempre se deve notabilizar situações especiais que influenciam no levantamento e na qualidade dos dados. Detalhes como o estágio das marés ou limitações de ângulo de insolação devem ser relatados antes do levantamento, a fim de permitir que se configure adequadamente o sensor e o planejamento do projeto.

4.1.3 Determinação da área de projeto e planejamentos de voo

Todo o planejamento de voo é feito usando o programa TOPOFLIGHT, que incorpora Modelos Digitais de Elevação (DEMs) para assegurar a compensação topográfica e a uniformidade na amostragem dos pixels. O cliente geralmente fornece shapefiles (*.SHP) ou vetores do Google Earth (*.KMZ), e/ou coordenadas que delimitam uma região de interesse.

As figuras resultantes do plano de voo, contendo a cobertura da área de projeto para cada localidade, constam no material de entrega, e se encontram disponíveis no diretório "PROJECT OVERVIEW/DOCS" (em formato JPG). Também neste diretório encontra-se uma tabela Excel que demonstra as coordenadas geográficas de início e término, bem como a altitude calculada, para cada faixa de voo.

4.1.4 Descrição do levantamento

Uma cópia dos registros de voo pode ser encontrada no diretório "PROJECT OVERVIEW/DOCS". Nesses registros constam as datas e horários de todas as missões acerca do projeto em questão. Para facilitar a visualização, imagens "*quick-look*" de três bandas, individualmente registradas, bem como um mosaico completo, são fornecidas na pasta "PROJECT OVERVIEW/QL".

Para facilitar a exploração e análise dos dados, um arquivo vetorial do ENVI, bem como um Shapefile ESRI, são fornecidos no diretório "PROJECT OVERVIEW/INDEX MAP". A esses polígonos são atribuídos seus nomes de arquivo raiz, e podem ser usados para navegar espacialmente pelos arquivos fornecidos.

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 7 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

4.2 Sobre o processamento dos dados

4.2.1 Radiância

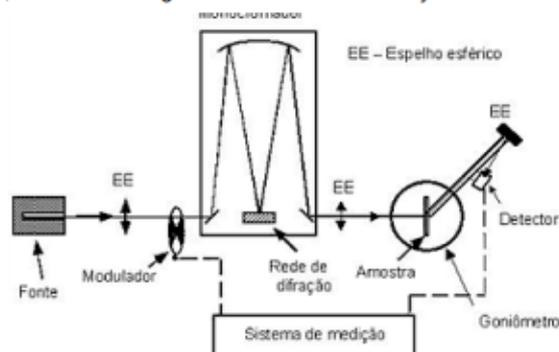
4.2.1.1 Calibração Radiométrica e Espectral

A história da SpectIR na coleção e operação de séries hiperespectrais, parceira da Fototerra, conduziu a uma riqueza de experiência na área de calibração radiométrica e espectral. Graças ao pioneirismo e arrojo da Fototerra, essa experiência vem sendo trazida ao Brasil. Uma calibração radiométrica padrão é alcançada através do uso de uma fonte uniforme Labsphere USS-2000-V. Essa esfera de Ulbricht, com diâmetro de 20 polegadas ($\varnothing = 50,8\text{cm}$), é equipada com quatro fontes externas de iluminação halogênica, sendo três de 45W e uma de 75W. Cada lampada é alimentada por fontes de corrente contínua (DC) isoladas, cada qual acoplada a um atenuador de variação de voltagem (VVA), que permite uma precisão ainda maior no controle dos níveis de iluminação. A luminância resultante varia entre 0 e 4000 pés-lambert (0 e 13.705,04 candelas/m²) e a uniformidade aferida é maior que 98% por toda a janela de observação de 8 polegadas (20,32cm). Essa esfera é calibrada conforme os padrões da NIST (Instituto Nacional de Padrões e Tecnologia dos EUA), dentro de uma faixa entre 400 e 2500nm, a intervalos regulares de 5nm. A calibração resultante permite que se forneçam dados dentro de faixas com +/-5% de radiância absoluta.

Figura 2 – Inserção de um Monocromador em um sistema de medição / calibração.

A calibração do comprimento de onda é gerada através de um monocromador Oriel Cornerstone 130 1/8m. Esse monocromador, automático e controlado

por computador fornece saídas calibradas e repetidas em intervalos de canal de 1nm na faixa do IVP, e de 3nm na faixa do IV de ondas curtas. A localização central desses comprimentos de onda é conhecida, e é certificada com acurácia de 0,5nm. Além disso, as rotinas de processamento do controle de garantia e de qualidade (QA/QC) utilizam parâmetros atmosféricos bem documentados, como a linha Fraunhofer do Oxigênio, aos 760nm, a fim de assegurar a precisão do mapeamento de comprimentos de ondas.



	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código	
		Revisão:	Folha:
		00	8 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

4.2.1.2 Processamento da Radiância

Os seguintes passos descrevem a geração da radiancia calibrada a partir de dados de imageamento ainda brutos.

Medições da corrente de obscuridade (dark current) são incluídas ao final de cada linha de voo. O primeiro passo do processamento é o da remoção do "sinal" da corrente de obscuridade das imagens. Se um dado proveniente do ProSpecTIR-VS é processado, então um mapa de "elementos ruins" é aplicado ao IV de ondas curtas, utilizando-se um algoritmo de compensação (de propriedade da SpecTIR) para remover a contribuição espacial e espectral desses elementos na coleção.

O arquivo de calibração dos ganhos é aplicado para a conversão dos valores dos dados brutos para unidades de radiancia. As unidades de radiancia e os fatores de escala ficam armazenados nos arquivos de cabeçalho de cada uma das linhas de voo processadas. A unidade padrão é o $mW/(cm^2 \cdot sr \cdot \mu m)^1$, com um fator de escala de 1000. Essa configuração significa que para um ND de 4500, o valor verdadeiro é de $4.5mW/(cm^2 \cdot sr \cdot \mu m)$.

Os arquivos de exportação seguem uma convenção de nomenclatura que se inicia com o numero da linha de voo correspondente ao plano, seguido por quarto dígitos que indicam mês e dia, seguido por uma referência de hora também em quatro dígitos. Exemplo: 001_0719-1307_rad.dat (Linha de voo 001, dia 19 de julho, às 13:07h).

4.2.2 Mapas de Saturação

Um arquivo de saída adicional associado ao processamento de radiancia é chamado "mapa de saturação" que é gerado para cada arquivo *_rad.dat. São dois mapas de saturação que são gerados permitindo que o analista lance mão de diversas ferramentas para identificar, mascarar e/ou compensar a saturação de pixels brutos ou a saturação causada pelo reescalamento.

O primeiro arquivo, identificado pelo nome *_saturation.map (acompanhado de um arquivo HDR do ENVI), é um arquivo de três bandas do ENVI, que fornece ao usuário final informações pixel a pixel que são relacionadas com a saturação bruta proveniente do instrumento ou da subsequente "saturação de reescalamento" que pode ocorrer no durante a conversão de valores em ponto flutuante (floating point) para valores de integral em 16bits. Os mapas de saturação fornecem aos analistas com informações úteis para a aplicação de máscaras sobre possíveis assinaturas

¹ A unidade "sr" corresponde ao esterorradiano, ou esferorradiano

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 9 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

espectrais falsas, que não devem ser identificadas como legítimos alvos espectrais.

A primeira banda do arquivo *_saturation.map identifica aqueles pixels que apresentam saturação de sensor. Um pixel nessa banda pode ter um dos seguintes valores e seus significados associados:

- 0 = Saturação inexistente do RAW
- 1 = Saturação no imageador IVP (VNIR)
- 2 = Saturação no imageador IVOC (SWIR)
- 3 = Saturação nos dois sensores (IVP e IVOC)

A segunda banda é análoga à primeira, entretanto, esta identifica aqueles pixels que podem não ter saturado durante a fase de aquisição, mas que "estouraram" durante o processamento radiométrico e escalonamento para valores integrais em 16bits. De novo, os valores variam entre 0 e 3, como na banda de saturação ainda na fase bruta.

A última banda não tem utilidade para o usuário final, por se tratar de algo útil para o processamento de dados para conferência interna dos analistas, e registro do escalonamento de saturação, bem como para conferência dos valores da corrente de obscuridade que estejam abaixo do limiar esperado.

Ainda que o arquivo *_saturation.map seja valioso, a informação não é completa, porque a saturação reportada nesse formato está disposto essencialmente em termos binários, e não serve para um uso qualitativo. É possível que, para um pixel qualquer, a saturação possa ter ocorrido em apenas uma das bandas espectrais, e em uma região que não seja do interesse do usuário final. Portanto, o usuário pode não querer excluir aquele pixel do processamento.

De forma a permitir o entendimento da quantidade de saturação em um domínio espectral, um segundo tipo de arquivo de saturação é fornecido. Esse arquivo é identificado como *_FullSaturation.map (com respectivo arquivo HDR do ENVI).

O arquivo *_FullSaturation.map é um mapa de saturação binário, que atinge todos os pixels de todas as bandas da imagem de radiancia que lhe é associado. Nesse arquivo, nenhuma distinção é feita se o excedente observado advém do dado bruto (RAW) ou de algum artifício resultante da aplicação dos fatores de reescalonamento ou de ganho.

4.2.3 Processamento da Refletância

De forma a converter os dados de radiancia para valores de refletância da superfície, os analistas empregam uma implementação programada do código de transferência radiativa (atmosférica) que é

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código	
		Revisão:	Folha:
		00	10 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

padrão industrial, o MODTRAN4. O programa ATCOR4 utiliza tabelas de referência atmosférica do MODTRAN4, e técnicas proprietárias de correção para os componentes de absorção e espalhamento atmosféricos. Durante o processamento, o ATCOR4 gera arquivos de registro para cada linha de voo, que fornece informações a respeito de todos os parâmetros e configurações de programa. Esses arquivos ASCII estão incluídos no diretório de distribuição de dados.

Ao lidar com as situações de absorção atmosférica, o ARCOR4 dispõe de três esquemas de interpolação possíveis. Ao gerar o produto de refletância final, os analistas selecionam a melhor combinação de opções de interpolação para o conjunto de dados. A interpolação linear é empregada nas regiões de 760, 725 e 825nm. Uma interpolação não linear é aplicada nas faixas de 940 e 1130nm, que são partes do espectro relacionadas à retenção de água nas plantas. Finalmente, outra interpolação não linear é aplicada nas faixas 1400nm e 1900nm, que se referem à absorção do vapor d'água, por meio do ajuste das curvas com um contorno padrão dos espectros de vegetação ou solo. A configuração dos parâmetros de interpolação são identificados nos arquivos de registro (log) associados e, além disso, todos os canais que sofreram interpolação são marcados com um asterisco ("*") dentro dos cabeçalhos (em formato ENVI - HDR) dos arquivos de refletância.

Os dados brutos de refletância resultantes do processo são avaliados a fim de se identificar falhas, que podem ser relacionadas a modelagem ou ao sensor, e eventualmente encaminhados para ajuste via espectros provenientes de bibliotecas e polimento. O polimento da refletância é conseguido por meio de um programa de propriedade da SpecTIR, que se baseia em um algoritmo Savitsky-Golay, que manipula de forma refinada as feições de absorção atmosférica que são associadas ao CO₂ e à água.

4.2.4 Refletância VELC

Ainda que a modelagem da refletância baseada no MODTRAN seja um padrão industrial, a SpecTIR veio encontrando que esses procedimentos podiam causar, com relativa frequência, a perda de fidelidade espectral na região extrema do IVOC (2000-2500nm), que é uma parte de grande interesse para a análise geológica. Para combater essa situação, a SpecTIR desenvolveu um novo procedimento para atingir uma calibração por linha empírica virtual (VELC). Essa metodologia obtém a pseudorefletância diretamente dos dados calibrados de refletância, por meio de operações numéricas e estatísticas sobre a imagem, cena por cena. A vantagem disso é que correções independentes são desenvolvidas para cada cubo de dados², ao invés de se empregar uma

² Em contextos de programação de computadores, um cubo de dados (ou datacube) é uma matriz de três (ou mais) dimensões de valores, comumente usados para descrever uma série temporal de dados de imagem. Um cubo de dados é

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 11 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

calibração única para uma ou, no melhor das hipóteses, alguns alvos espectrais no solo, como é feito nas correções tradicionais de linha empírica. A aplicação desse método tem demonstrado produzir resultados excepcionais no IVOC extremo, e então é oferecido como um produto para entrega adicional.

4.2.5 Processamento de Geocorreções (Georreferenciamento)

Dependendo do pacote de Sistema Inercial de Navegação (SIN) que está acoplado ao sistema, os instrumentos incorporam giroscópios de precisão, comandados por fibra ótica (FOG) ou sistemas mecânicos-microeletrônicos (MEMS), baseados em sensores de regulação angular, bem como MEMS baseados em acelerômetros, sejam estes convencionais ou equipados com tecnologia compensatória (usando a tecnologia háptica), a fim de dar maior acurácia para o georreferenciamento dos dados. Os instrumentos da SpecTIR incorporam um Sistema Inercial de Navegação (SIN) giratório a laser e de três anéis, de forma a fornecer um georreferenciamento preciso dos dados. O Sistema de Medição Inercial (SMI) trabalha em conjunto com um sistema GPS de 12 canais, que utiliza as correções diferenciais em tempo real da Omnistar para alimentar o filtro Kalman que se encontra bem fixado do SIN.

A fim de assegurar a tradução ótima dos dados de posicionamento do SIN para a imagem, o SIN e a câmera devem ser interalinhadas entre si. Para conseguir isso, a SpecTIR estabeleceu que o local de calibração de alinhamento fica ao sul do aeroporto de Stead, Nevada (EUA). Como controle, se utiliza uma ortofotografia de 6 polegadas (15,24cm), e dados de curva de nível (coincidentes com a ortofoto) com 2 pés (60,96cm) de equidistância foi fornecida pelo condado de Washoe.

De modo a viabilizar imagens hiperespectrais ortorretificadas, a SpecTIR possui o banco de dados completo do NED DEM, com 10m de resolução, cobrindo os Estados Unidos continental. Se acurácia ainda maior é demandada, DEMs fornecidos pelo cliente, provenientes de fontes como o LIDAR podem ser incorporados no fluxo de processamento. Para coletas internacionais, DEMs do SRTM são utilizados caso não existam DEMs com resolução maior a disposição. No presente projeto, foi constatado um erro médio espacial de aproximados 6m, devido à incorporação do SRTM de 90m, a melhor resolução disponível. Durante o processamento, o desempenho do georreferenciamento é avaliado com base nas imagens USGS de 1m DOQQ, ou, no caso de localidades internacionais, a resolução mais alta disponível.

também utilizado no campo da imagem de espectroscopia, uma vez que uma imagem espectralmente resolvida é representada como um volume tridimensional.

Para obter uma sequência temporal de imagens coloridas a matriz é geralmente de quatro dimensões, com as dimensões da imagem que representam coordenadas X e Y, o tempo, e os planos de informação RGB (ou espaço de cores).

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 12 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

O processamento de georreferenciamento gera um arquivo de Mapa de Geometria Interna (IGM), que consiste de duas bandas de pixels, com a identificação dos valores de leste (banda 1) e de norte (banda 2) para dados da imagem não retificada. Uma Tabela de Referência Geográfica (GLT) associada a esse arquivo também é fornecida junto, que consiste de uma banda, projetada no espaço mapeado. Qualquer um desses arquivos pode ser usado por programas de processamento de imagens, para gerar imagens totalmente exploráveis ou produtos de análise subsequente.

Os dados IGM e GLT são fornecidos de acordo com a projeção e datum de preferência do cliente.

4.3 Padronização de diretórios de entrega

Estrutura BÁSICA de Diretórios

>Projeto#-Nome do Cliente

- RELATÓRIO DE PROJETO: Este documento

>Project Overview

>Projeto#-Cliente-Nome do Local

>Docs

- Plano de Voo
- Log do levantamento

>QL

- Imagens individuais de 3 bandas georreferenciadas
- Mosaico de 3 bandas de todos os dados

>INDEX MAP

- Mapa índice vetorial de todas as faixas voadas, facilitando a navegação e identificação das faixas

	RELATÓRIO DE ATIVIDADES TÉCNICAS	Código RC – 2.0.14	
		Revisão: 00	Folha: 13 / 13

Aprovação: Luis Antônio de Lima – Diretor Técnico	Data: 02/06/2015	Elaboração: MSc. Alexander Sergio Evaso
--	---------------------	--

- >Data
 - > Projeto#-Cliente-Nome do Local
 - >RAD
 - Arquivos de radiância processados
 - >Saturation Maps
 - Mapas de Saturação
 - >IGM_GLTS
 - Arquivos IGM e GLT associados
 - Arquivos de Navegação (equivalentes ao SBET)
 - >REF
 - Arquivos de refletância processados
 - >MODTRAN
 - >VELC

5 CONCLUSÃO

Foi empreendido o levantamento aéreo da área de interesse de Morada Nova pela equipe de campo da FotoTerra, durante o mês de maio 2015. O produto final deste levantamento permite um futuro trabalho de classificação. Inclui-se, nesta entrega, também as faixas reprovadas por cobertura de nuvens.

6 SOFTWARES

Durante esta etapa do trabalho foram utilizados os seguintes softwares:

- > ENVI 5.0;
- > Quantum GIS;
- > Global Mapper;