

Análise quantitativa da concentração de sais nos solos a partir de dados de espectroscopia de reflectância

Luis Clenio Jário Moreira ^{1,2}
Adunias dos Santos Teixeira ²
Lênio Soares Galvão ³

¹ Instituto Federal de Educação Ciência e Tecnologia do Ceará – IFCE
Limoeiro do Norte - CE, Brasil
cleniojario@ifce.edu.br

² Universidade Federal do Ceará – UFC
Caixa Postal 12.168, CE 60450-760 Fortaleza, Brasil
adunias@ufc.br

³ Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12227-010 - São José dos Campos - SP, Brasil
lenio@dsr.inpe.br

Abstract. The aim of this study was to evaluate the possibility of using reflectance spectroscopy to quantify the salt concentration of the soil enabling the use of hyperspectral imagery for mapping large degraded areas. To develop statistical models 93 soil samples, and to calibrate 2/3 and 1/3 were used to validate. In the two sample subsets spectral measurements were made in the laboratory using the spectroradiometer FieldSpec Pro under controlled conditions and measurements of electrical conductivity (EC) were performed. Three statistical models were used to analyze the reflectance vs EC: linear regression, normalized salinity index (NDSI) and partial least squares regression (PLSR). The linear model was developed to better results with the band positioned at 1945 nm showing significant predictive power ($R^2 = 0.50$, RMSE = 0.987 and RPD = 1.47). Still, it was lower than the model developed from the NDSI (using 1875 and 1935 nm with $R^2 = 0.836$; RMSE = 0.54; RPD = 2.44). Two PLSR models were constructed: one using all the spectral information (PLSR1) and other bands without atmospheric interference (PLSR2). The PLSR1 showed better results ($R^2 = 0.883$, RMSE = 0.44 and RPD = 2.90) compared to the other models developed in this work suggest that the greater the number of spectral information used in the modeling, the greater the ability to predict. However, the optimization of the number of variables to compose the predictive models may be made, enabling better results with the least number of possible input variables.

Palavras-chave: soil salinity, reflectance spectra, PLSR, NDSI, hyperspectral remote sensing, solo salino, espectro de reflectância, sensoriamento remoto hiperespectral.

1. Introdução

A salinização tem contribuído bastante para o aumento da degradação do solo no semiárido brasileiro (SAMPAIO et al., 2005). Os fatores que contribuem para esse sério problema ambiental estão ligados diretamente ao solo (p. ex., material de origem, topografia, profundidade do lençol freático, qualidade da água subterrânea), fatores relacionados ao manejo (irrigação e drenagem) e fatores climáticos (precipitação e evaporação) (DOUAIK et al., 2008).

Geralmente, a caracterização da salinidade de uma área com grande dimensão espacial é feita medindo-se a condutividade elétrica (CE) a partir do extrato de saturação de amostras de solo coletadas em campo, visando a elaborar mapas detalhados desse processo (BEN-DOR et al., 2008).

O sensoriamento remoto é uma alternativa atraente aos métodos tradicionais em função de seu baixo custo, excelente cobertura espacial, boa frequência temporal, podendo permitir o mapeamento das áreas salinizadas (FARIFTEH et al., 2008; WENG et al., 2010). Dados de

sensores multiespectrais (p. ex., Landsat e SPOT) são usados com sucesso para diversas aplicações, no entanto, sua baixa resolução espectral tem limitado a separação de solos com diferentes concentrações salinas (DEHAAN e TAYLOR, 2003; WENG et al., 2010; ALLBED et al., 2014).

Já o sensoriamento remoto hiperespectral tem sido utilizado em muitos estudos, porque permite a discriminação de sutis diferenças entre os materiais constituintes do solo (MASHIMBYE et al., 2012). Por adquirir dados em centenas de bandas os sensores hiperespectrais permitem fazer uma avaliação quantitativa dos solos afetados por sais usando diversos métodos estatísticos no desenvolvimento de modelos de previsão (MCBRATNEY et al., 2003). Regressão linear, índice de salinidade e regressão por mínimos quadrados parciais (PLSR) tem sido utilizado para modelar a relação quantitativa entre a reflectância na faixa de 350 a 2500 nm e características químicas/físicas dos solos com, por exemplo, a salinidade (FARIFTEH et al., 2007; MASHIMBYE et al., 2012; SIDIKE et al., 2014).

Desta forma, o objetivo do presente estudo foi avaliar a possibilidade do uso de dados de espectroscopia de reflectância em estimar a concentração de salinidade do solo. Para isso, foi investigada a capacidade da regressão linear a partir de bandas individuais, do índice normalizado de salinidade (NDSI) e do PLSR produzirem modelos preditivos confiáveis para quantificar a concentração salina do solo.

2. Material e Métodos

2.1 Área de estudo, coleta e preparo das amostras de solo

As amostras de solos utilizadas nesse trabalho foram coletadas da camada superficial (profundidade de coleta de 0 a 15 cm) no distrito de irrigação de Morada Nova que está localizado nos municípios de Morada Nova e Limoeiro do Norte – CE (Figura 1). A área foi selecionada por apresentar diversos problemas de salinização em função da elevada concentração original de sais que afeta a produtividade agrícola e, muitas vezes, inibe o completo desenvolvimento das culturas. O clima da região, segundo a classificação de Köppen, corresponde a BSW'h' (muito quente e semiárido) com precipitações médias anuais inferiores a 900 mm, temperatura média anual de 27,5° C e evapotranspiração potencial maior que 2000 mm.

Na modelagem foram usadas um total de 93 amostras, sendo que desse conjunto amostral 2/3 foram utilizados para calibrar e 1/3 para validar os modelos estatísticos desenvolvidos. A coleta das amostras de calibração foi realizada em uma área degradada com ausência de vegetação, apresentando salinização natural e com alagamento no período chuvoso do ano (polígono amarelo Figura 1). Esse conjunto amostral foi distribuído dentro de cilindros de PVC de 7,5 cm de diâmetro por 7,0 cm de altura totalizando volumes de aproximadamente 309 cm³ de solo por amostra. Este conjunto foi submetido à salinização através da irrigação de água destilada com três soluções salinas de NaCl, MgCl₂ e CaCl₂ em cinco concentrações crescentes de sal ou de níveis de CE: CE1 (0 dS/m; solução somente com água destilada); CE2 (até 5,48 dS/m); CE3 (5,48-9,52 dS/m); CE4 (9,52-17,25 dS/m) e CE5 (>17,25 dS/m).

As amostras de validação foram coletadas em diferentes pontos (Figura 1) dentro do perímetro irrigado e levadas ao laboratório para posteriores análises químicas e espectrais. Não houve simulações nesse conjunto amostral. Portanto, a salinização apresentada por essas amostras foi originada das condições naturais de campo.

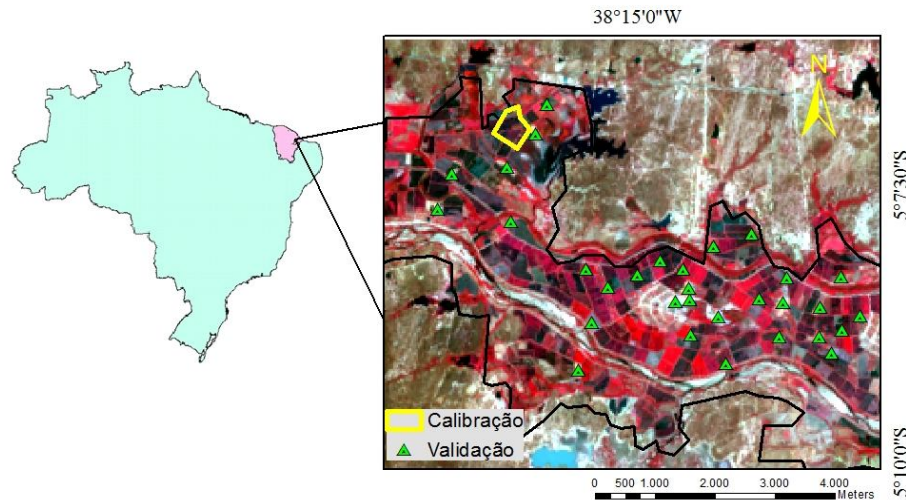


Figura 1. Área de coleta dos pontos amostrais. A composição colorida, datada de 12 de setembro de 2013, inclui as bandas 5, 4 e 3 do sensor multiespectral OLI/Landsat-8 em vermelho, verde e azul, respectivamente.

2.2 Medidas de condutividades elétricas (CE) e Reflectância das amostras

As medidas de CE foram feitas a partir do extrato de saturação do solo usando um condutivímetro modelo HI2300 (Hanna instruments). As medições foram realizadas no Laboratório de Análises de Solos e Tecidos Vegetais do Instituto Federal de Educação Ciência e Tecnologia do Ceará – Campus de Limoeiro do Norte.

Para obtenção dos dados espectrais em laboratório, as amostras de solo foram homogêneas, trituradas e passadas na peneira de 2 mm reduzindo o efeito da rugosidade nas medidas em ambos os conjuntos amostrais (calibração e validação). Para essas medidas espectrais utilizou-se o espectrômetro FieldSpec Pro FR 3 (Analytical Spectral Devices Inc.) que opera na região de 350 a 2500 nm, com resolução espectral de 3 nm nas faixas do visível e infravermelho próximo (VNIR = 350-1300 nm) e de 10 nm na faixa do infravermelho de ondas curtas (SWIR = 1300-2500). O sensor foi posicionado a nadir, a 7 cm de distância das amostras. A fonte de iluminação foi uma lâmpada halógena de 250 W de potência com refletor parabólico, feixe colimado para o plano visado e com 30° de ângulo zenital de iluminação. Como padrão de referência absoluta, foi utilizada uma placa de Spectralon branca de alta reflectância, calibrada. Foram obtidas três leituras de reflectância para cada amostra, sendo posteriormente utilizado um valor médio.

2.3 Análise dos dados

O teste de Kolmogorov-Smirnov revelou que a CE das amostras de solos usadas nas avaliações não apresentavam normalidade (p -value = 0,006). Dessa forma, os dados de CE sofreram uma transformação pelo logaritmo natural (ln) com o objetivo de tornar essa variável normal (p -value = 0,20). Assim, os modelos estatísticos foram desenvolvidos usando os valores de logaritmos naturais da condutividade elétrica (ln CE).

Os espectros dos conjuntos amostrais de calibração e validação com valores de reflectância para 2100 bandas (400 a 2500 nm) foram reamostrados para 10 nm totalizando 210 bandas espectrais, facilitando o processamento dos dados sem causar perdas de informações (WENG et al., 2008). Para desenvolver modelos estatísticos quantitativos da concentração salina (CE) a partir da reflectância do solo, foram usadas as seguintes estratégias: regressão linear, regressão linear usando o índice normalizado de salinidade (NDSI) e regressão por mínimos quadrados parciais (PLSR).

Na regressão linear foi usado o coeficiente de correlação de Pearson (correlograma) entre a reflectância e o ln CE das amostras de calibração para identificar o comprimento de onda com maior correlação e a partir desse desenvolver o modelo.

Usando o mesmo princípio do índice de vegetação por diferença normalizada (NDVI), buscou-se dentro do espectro das amostras de calibração, os melhores posicionamentos de bandas para descrever a relação entre a razão da diferença normalizada e ln CE. Esse índice hiperespectral, denominado de *Normalized Difference Spectral Index* (NDSI), foi desenvolvido a partir de um processo iterativo (rotina feita em Matlab), onde cada banda do espectro foi combinada com as demais (Equação 1) para escolher a combinação com maior coeficiente de determinação (R^2) compondo o índice. Foi feita uma equação de regressão para o NDSI vs ln CE para o resultado mais significativo das amostras de calibração. A equação linear foi então validada com o conjunto amostral de validação.

$$\text{NDSI} = (\rho_j - \rho_i) / (\rho_j + \rho_i) \quad (1)$$

Onde ρ_j e ρ_i são reflectâncias de quaisquer dois comprimentos de ondas do espectro.

A Regressão por mínimos quadrados parciais (descrição completa encontrada em WOLD et al., 2001) é uma técnica amplamente utilizada na estimativa de atributos baseada no comportamento espectral do solo, apresentando bom desempenho (VISCARRA ROSSEL, 2008). O algoritmo PLSR seleciona fatores ortogonais que maximizam a covariância entre as variáveis preditoras X (espectro) e a variável resposta Y (atributo químico, no caso desse trabalho, a CE do solo). O PLSR decompõe ambas as variáveis X e Y e encontra novos componentes (escores), chamados de variáveis latentes, que são ortogonais. A regressão é calculada entre essas novas componentes das variáveis X e Y , resumidamente mostrado nas equações 2, 3 e 4.

Nesse trabalho, os dados de reflectância foram transformados de reflectância para logaritmo do inverso da reflectância ($\log 1/R$). A validação cruzada *leave-one-out* foi empregada na determinação do número ótimo de fatores (variáveis latentes) do PLSR usados para a calibração do modelo. A escolha do modelo utilizado para predição da CE foi feita comparando os seguintes parâmetros da validação cruzada: coeficiente de determinação (R^2), raiz do erro médio quadrático (RMSE), erro médio (EM) e desvio padrão do erro (SDE). O tratamento dos dados, assim como o desenvolvimento, calibração e validação dos modelos, foi feito com o Software ParLes 3.1, proposto por Viscarra Rossel (2008).

3. Resultados e Discussão

3.1 Regressão entre a reflectância de bandas individuais e o ln CE do solo

A banda de absorção que apresentou a relação mais forte entre reflectância e ln CE está centrada em 1945 nm ($r = -0,81$). Foi usado um modelo de regressão preditivo (Figura 2a) obtido a partir dos dados de calibração para estimar o ln CE das amostras do conjunto de validação. Esse modelo linear teve significativa capacidade de acerto (Figura 2b com $R^2 = 0,50$; RMSE = 0,987 e RPD = 1,47). No entanto, essa banda está posicionada em uma região de absorção de água no espectro eletromagnético, o que a torna impossível de ser usada em aplicações com imagens hiperespectrais devido à influência do vapor atmosférico. Já em condições de laboratório, ela tem potencial de uso (MOREIRA et al., 2014). Segundo Weng et al. (2008), essa correlação é consistente porque os sais presentes nas amostras são higroscópicos, causando um aumento da umidade do solo e, conseqüentemente, uma redução da reflectância quando se aumenta sua concentração.

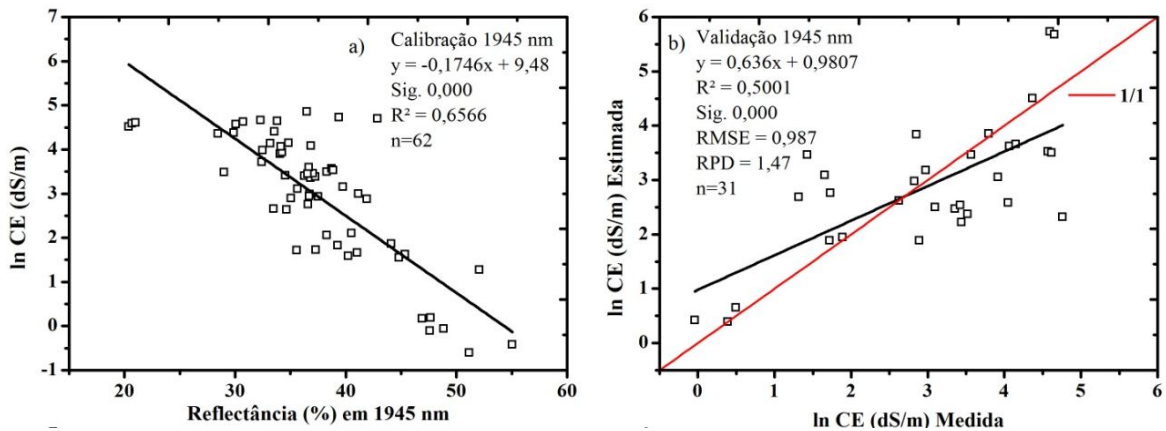


Figura 2. Equações de regressão obtidas a partir da relação entre reflectância e ln CE do solo. a) e b) calibração e validação para 1945 nm, respectivamente.

3.2 Normalized Difference Spectral Index - NDSI

Na Figura 3 foi plotado o contorno do R^2 obtido das regressões lineares de cada candidato a NDSI com o ln CE referentes ao conjunto amostral de calibração. A razão normalizada mais promissora foi entre 1875 nm (banda i) e 1935 nm (banda j) apresentando coeficiente de determinação de 0,724 (ajuste mostrado na Figura 4a). Dentre todas as combinações, os melhores resultados foram obtidos em torno de 1900 nm da banda i com vários comprimentos de ondas da banda j. O modelo estatístico de predição do NDSI com bandas 1875 e 1935 nm (Figura 4b com $R^2 = 0,836$; RMSE = 0,54 e RPD = 2,44) foi significativo apresentando resultados superiores ao modelo linear da banda individual.




Figura 3. Coeficiente de determinação entre todas as combinações de reflectância de bandas usadas para obter NDSI e ln CE para o conjunto amostral de calibração. A seta indica a posição dos dois índices. O i e j representam o i -ésimo e j -ésimo comprimentos de ondas usados para compor todos os possíveis NDSIs.

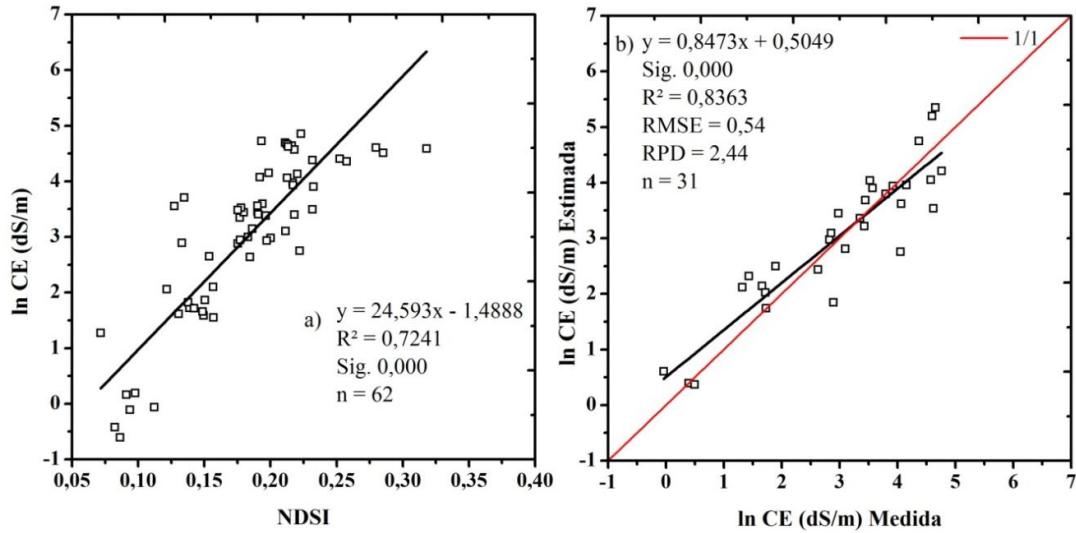


Figura 4. Equação de regressão obtida a partir da relação entre NDSI e ln CE do solo. a) e b) calibração e validação do $NDSI = [1875 - 1935]/[1875 + 1935]$, respectivamente.

3.3 Partial Least Squares Regression - PLSR

A partir dos conjuntos amostrais de calibração e validação, dois modelos PLSR foram construídos. O primeiro modelo PLSR 1 (Figura 5a) foi obtido usando todas as bandas espectrais (210 bandas). Em seu desenvolvimento, o menor erro na validação cruzada ($R^2 = 0,77$) foi garantido usando apenas 4 variáveis latentes explicando 99,74% da variância acumulada. Já o segundo modelo PLSR 2 (Figura 5b), foi construído a partir do espectro sem as faixas de absorção atmosféricas (removidos os comprimentos de ondas em torno de 1400 e 1900 nm totalizando 166 bandas), visando sua aplicação em imagens Hyperion como fizeram Farifteh et al. (2007) e Weng et al. (2008), obtendo resultados satisfatórios. No segundo modelo, o número ótimo de variáveis latentes, garantindo um erro mínimo na validação cruzada ($R^2 = 0,82$) foi 5, explicando 98,22% da variância acumulada.

O desempenho da validação com o conjunto amostral independente mostrou que o modelo PLSR 1 ($R^2 = 0,883$; RMSE = 0,44 e RPD = 2,90) apresentou melhores resultados do que o modelo PLSR 2 ($R^2 = 0,695$; RMSE = 0,77 e RPD = 1,90). A aplicação do PLSR 1 em imagens hiperespectrais nas áreas salinizadas de solos expostos para produzir mapas de salinidade fica limitada já que nesse modelo estão inclusas faixas espectrais de absorção atmosférica. Nesse caso, apesar da menor capacidade preditiva, o PLSR 2 poderá ser explorado para tal fim.

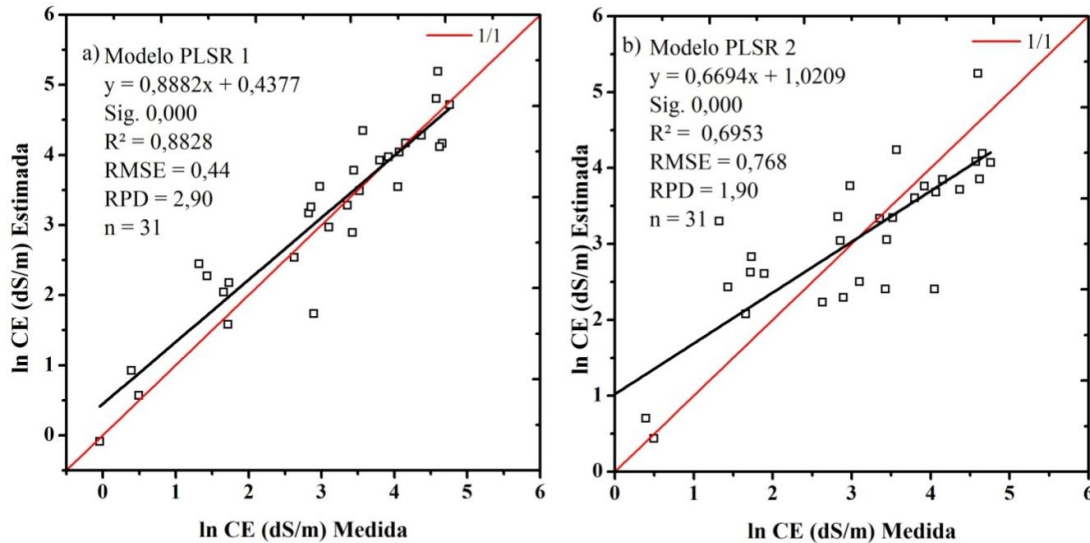


Figura 5. a) Validação do modelo PLSR 1. b) validação do modelo PLSR 2.

Os modelos preditivos PLSR tiveram melhores desempenhos do que os modelos com bandas individuais e NDSI, exceto o modelo PLSR 2 que apresentou desempenho inferior ao NDSI usando bandas em torno de 1900 nm. Os melhores resultados dos modelos PLSR provavelmente são devidos à maior quantidade de informações das variáveis utilizadas (bandas espectrais).

4. Conclusões

Sob condições controladas de laboratório (umidade, rugosidade, etc), a concentração de sal no solo medida pela condutividade elétrica (CE) pôde ser quantificada a partir de informações espectrais. Apesar dos melhores resultados do presente trabalho ser com os modelos PLSR, equações de regressão com boa capacidade de previsão podem ser obtidas de bandas espectrais isoladas ou índices hiperespectrais (NDSI). Isso indica que uma otimização do número de variáveis para compor os modelos preditivos pode ser feita, possibilitando melhores resultados com o menor número de variáveis de entrada possível. Excluindo as regiões espectrais de absorção de água, modelos semelhantes ao NDSI e PLSR podem potencialmente ser calibrados a partir de imagens hiperespectrais e utilizados para produzirem mapas de salinidade.

Agradecimentos

Os autores agradecem à Universidade Federal do Ceará (UFC), Instituto Nacional de Pesquisas Espaciais (INPE), Instituto Federal de Ciência e Tecnologia do Ceará (IFCE-LN), Instituto Nacional de Ciência e Tecnologia da Salinidade (INCTSal), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

Referências Bibliográficas

ALLBED, A.; KUMAR, L.; SINHA, P. Mapping and Modelling Spatial Variation in Soil Salinity in the Al Hassa Oasis Based on Remote Sensing Indicators and Regression Techniques. **Remote Sens.**, v. 6, n°. 2, p. 1137-1157; jan. 2014.

BEN-DOR, E.; GOLDSHLEGER, N.; ESHEL MOR, V. Combined Active and Passive Remote Sensing Methods for Assessing Soil Salinity: A Case Study from Jezre'el Valley, Northern Israel. In: **Remote**

Sensing of Soil Salinization: Impact on Land Management, Metternicht, G., Zinck, J.A., Eds.; CRC Press: Boca Raton - FL, USA, 2008; p. 236–253.

DEHAAN, R.; TAYLOR, G.R. Image-derived spectral endmembers as indicators of salinization. **Int. J. Remote Sens.**, v. 24, p. 775-794, 2003.

DOUAIK, A.; MEIRVENNE, M.; TOTH, T. Stochastic Approaches for Space–Time Modeling and Interpolation of Soil Salinity. In: **Remote Sensing of Soil Salinization: Impact on Land Management**, Metternicht, G., Zinck, J.A., Eds.; CRC Press: Boca Raton - FL, USA, 2008; p. 273–289.

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

FARIFTEH, J.; VAN DER MEER, F.; ATZBERGER, C.; CARRANZA, E.J.M.; Quantitative analysis of salt-affected soil reflectance spectra: a comparison of two adaptive methods (PLSR and ANN). **Remote Sensing of Environment**, v. 110, p. 59–78, set. 2007.

MASHIMBYE, Z.E.; CHO, M.A.; NELL, J.P.; CLERCQ, J.P.; 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, n° 5, p. 640 – 649, out. 2012.

MCBRATNEY, A.; SANTOS, M.D.L.M.; MINASNY, B. On digital soil mapping. **Geoderma**, v. 117, p. 3-52, nov. 2003.

MOREIRA, L.C.J.; TEIXEIRA, A.S.; GALVÃO, L.S. Laboratory Salinization of Brazilian Alluvial Soils and the Spectral Effects of Gypsum. **Remote Sens.**, v. 6, n° 4, p. 2647-2663, mar. 2014.

SAMPAIO, E.V.S.B.; ARAÚJO, M.S.B.; SAMPAIO, Y.S.B. Impactos ambientais da agricultura no processo de desertificação no Nordeste do Brasil. **Revista de Geografia**, Recife: UFPE – DCG/NAPA, v.22, n°1, p. 90-112, jan/jun.2005.

SIDIKE, A.; ZHAO, S.; WEN, Y. Estimating soil salinity in Pingluo County of China using QuickBird data and soil reflectance spectra. **International Journal of Applied Earth Observation and Geoinformation**, v. 26, p. 156-175, fev. 2014.

VISCARRA ROSSEL, R. A. ParLeS: Software for chemometric analysis of spectroscopic data. Chemometrics Intelligent Laboratory. **Chemometrics and Intelligent Laboratory Systems**, Amsterdam, v.90, p.72-83, jan. 2008.

WENG, Y.; GONG, P.; ZHU, Z. Reflectance spectroscopy for the assessment of soil salt content in soils of the Yellow River Delta of China. **Int. J. Remote Sens.** v. 29, p. 5511-5531, 2008.

WENG, Y.L.; GONG, P.; ZHU, Z.L. A spectral index for estimating soil salinity in the Yellow River Delta Region of China using EO-1 Hyperion data. **Pedosphere**, v. 20, p. 378 – 388, jun. 2010.

WOLD, S., SJÖSTRÖM, M., & ERIKSSON, L. (2001). PLS-regression: A basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, v. 58, n° 2, p. 109-130, out. 2001.