







## ARTIGO ORIGINAL

# Modelos espectrais para a estimativa do conteúdo de água em folhas de *Eucalyptus*

## Spectral models for estimating water content in *Eucalyptus* leaves

Taila Fernanda Strabeli<sup>1</sup> , Peterson Ricardo Fiorio<sup>1</sup> , Natália Correr Ré<sup>1\*</sup> , Clayton Alcarde Alvares<sup>2,3</sup> , Ana Claudia dos Santos Luciano<sup>1</sup> , Érica Silva Nakai<sup>1</sup> 

<sup>1</sup>Escola Superior de Agricultura "Luiz de Queiroz" – ESALQ, Universidade de São Paulo – USP, Piracicaba, SP, Brasil

<sup>2</sup>Faculdade de Ciências Agronômicas – FCA, Universidade Estadual Paulista "Júlio de Mesquita Filho" – UNESP, Botucatu, SP, Brasil

<sup>3</sup>Suzano SA., Limeira, SP, Brasil

**Como citar:** Strabeli, T. F., Fiorio, P. R., Ré, N. C., Alvares, C. A., Luciano, A. C. S., & Nakai, E. S. (2023). Modelos espectrais para a estimativa do conteúdo de água em folhas de *Eucalyptus*. *Scientia Forestalis*, 51, e3941. <https://doi.org/10.18671/scifor.v50.49>

### Resumo

O conteúdo relativo de água (CRA) e a espessura equivalente da água (EEA) são parâmetros que fornecem informações sobre a condição hídrica da planta. A resposta espectral na região do visível e infravermelho próximo (VIS-NIR) é uma alternativa para criação de modelos espectrais para prever água em diversas espécies de plantas. O objetivo deste trabalho foi estabelecer as relações existentes entre variações nos parâmetros de CRA e EEA com a resposta espectral da folha de diferentes espécies e híbridos de *Eucalyptus*. Para a determinação do CRA foi necessário determinar o peso fresco (PF), o peso túrgido (PT) e o peso seco (PS) e posteriormente realizar leituras espectrais de cada folha de *Eucalyptus* com o sensor hiperespectral Fieldspec. Foram calculados oito índices espectrais para prever os parâmetros da água nas folhas: Water Index (WI), Moisture Stress Index (MSI), Normalised Difference Water Index (NDWI), Normalized Difference Infrared Index (NDII), Simple Ratio 701 and 820 (SR701,820), Simple Ratio 1300 and 1450 (SR1300,1450), (R850-R2218)/(R850-R1928) e (R850-R1788)/(R850-R1928) em que encontrou-se que o índice SR1300,1450 teve um  $R^2 = 0,72$  ao ser correlacionado com o CRA e um  $R^2 = 0,81$  ao ser correlacionado com o EEA. Os dados espectrais foram correlacionados com os parâmetros da água e encontrou-se que para o CRA o comprimento de onda 1881 nm um coeficiente de correlação máximo negativo de  $r = -0,89$ , enquanto que o EEA apresentou um coeficiente de correlação máximo negativo de  $r = -0,79$  no comprimento de onda 2165 nm. Foram testados dois métodos de seleção das variáveis hiperespectrais para gerar um modelo matemático por meio do método de regressão linear. Para o parâmetro CRA, o método de seleção de variáveis *stepwise* foi o que gerou o maior  $R^2 = 0,86$  e com um RMSE = 13,85%, sendo que neste método restaram apenas seis variáveis preditoras. Enquanto que o método de seleção de variáveis pelas regiões do espectro foi o mais preciso para prever o parâmetro EEA com um  $R^2 = 0,87$  e um RMSE = 0,00012g/cm<sup>2</sup>. Assim, é possível prever CRA e EEA, para o gênero *Eucalyptus* por meio de modelos matemáticos derivados de dados hiperespectrais.

**Palavras-chave:** Densidade equivalente da água; Sensoriamento remoto hiperespectral; Índices espectrais.

### Abstract

The relative water content (RWC) and equivalent water thickness (EWT) are parameters that provide a diversity of information about the plant's hydric condition. Hyper-spectral remote sensing is a fast and non-destructive technique capable of generating data that allow the quantification of vegetation's hydric condition. This study sought to establish the existing relations among the water parameters (RWC and EWT) with the leaf spectral response of different species and hybrids of *Eucalyptus*. For the determination of the relative water content (CRA) it was necessary to determine the fresh weight (FW), the saturated

Fonte de financiamento: FAPESP Proc. n. 2013/22435-9.

Conflito de interesse: Nada a declarar.

Autor correspondente: natalia.re@usp.br

Recebido: 18 agosto 2022.

Aceito: 23 novembro 2022.

Editor: Mauro Valdir Schumacher.



Este é um artigo publicado em acesso aberto (*Open Access*) sob a licença *Creative Commons Attribution*, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que o artigo científico seja corretamente citado.

weight (SW) and the dry weight (DW) and later carry out the spectral readings of each *Eucalyptus* leaf with the Fieldspec hyper-spectral sensor. Eight spectral indices were tested for the prediction of water parameters: Water Index (WI), Moisture Stress Index (MSI), Normalized Difference Water Index (NDWI), Normalized Difference Infrared Index (NDII), Simple Ratio 701 and 820 (SR701,820), Simple Ratio 1300 and 1450 (SR1300,1450),  $(R_{850}-R_{2218})/(R_{850}-R_{1928})$  and  $(R_{850}-R_{1788})/(R_{850}-R_{1928})$  in which the SR1300,1450 index was found  $R^2=0.72$  when correlated with CRA and an  $R^2=0.81$  when correlated with EEA. The spectral data were correlated to the water parameters and it was found that the RWC at 1881 nm presented a maximum negative coefficient of correlation of  $r=-0.89$  whereas the EWT presented a maximum negative coefficient of correlation of  $r=-0.79$  at 2165 nm. Four methods of selecting hyper-spectral variables were tested to generate a mathematical model through linear regression. For the RWC parameter the stepwise variable selection method generated the higher  $R^2=0.86$  with a RMSE = 13,85%, considering that just six predicting variables were left in this method. While the variable selection method by spectral regions was the most precise to predict the EWT parameter with an  $R^2=0.87$  and an RMSE=0,0012g/cm<sup>2</sup>. It is possible to predict CRA and ELA, for the generation of *Eucalyptus* by means of mathematical models derived from hyperspectral data.

**Keywords:** Equivalent water thickness; Hyperspectral remote sensing; Spectral indices.

## INTRODUÇÃO

O conteúdo de água é uma importante característica da vegetação (Zhang & Zhou, 2015), que pode contribuir para determinar seu estado fisiológico (Peñuelas et al., 1993,1994), a tolerância e a adaptação de plantas à seca (Arndt et al., 2015) e a suscetibilidade aos incêndios em áreas florestais (Chuvieco et al., 2004).

O conteúdo relativo de água (CRA) e a densidade equivalente da água (EEA - *Equivalent Water Thickness*) são parâmetros utilizados para estimar a quantidade de água na folha. O CRA é uma medida universal para estimar a quantidade de água na folha, capaz de determinar a tolerância das plantas à seca e sua adaptação a ambientes favoráveis (Sun et al., 2014; Arndt et al., 2015). O EEA estima a quantidade de água pela área foliar (Wang & Li, 2012; Mobasheri & Fatemi, 2013; Yi et al., 2013; Ranjan et al., 2015) e varia de acordo com as características das folhas (Ceccato et al., 2001).

O cálculo do conteúdo de água na vegetação tem sido obtido pelo método tradicional de laboratório que envolve a pesagem e secagem de folhas na estufa para determinar sua perda de massa, processo simples, porém com uma alta magnitude de erros devido à dificuldade ao determinar a massa túrgida (Arndt et al., 2015). Uma técnica rápida e não destrutiva que tem sido muito utilizada para quantificar parâmetros biofísicos (Ahamed et al., 2011) e bioquímicos (Croft et al., 2014) da vegetação é a espectrorradiometria (Zarco-Tejada et al., 2003; Zhang et al., 2012; Mirzaie et al., 2014).

Diferentes regiões do espectro foram correlacionadas com o conteúdo de água em folhas (Mobasheri & Fatemi, 2013), originando diversos índices compostos por duas ou mais bandas que se encontram próximas as regiões que sofrem influência da água, que são: 970 nm, 1200 nm, 1450 nm, 1940 nm e 2500 nm. Datt (1999) desenvolveu dois índices os quais apresentaram uma alta correlação entre o conteúdo de água por unidade de área da folha (EEA) e a reflectância em folhas de *Eucalyptus* sendo estes:  $(R_{850}-R_{2218})/(R_{850}-R_{1928})$  e  $(R_{850}-R_{1788})/(R_{850}-R_{1928})$  e encontrou um coeficiente de correlação de Pearson ( $r$ ) de 0,78 e 0,76 respectivamente. Ranjan et al. (2015) encontraram alta correlação entre o conteúdo relativo de água (CRA) e os índices de vegetação MSI ( $r = 0,90$ ) e NDII ( $r = 0,87$ ) para a espécie *Triticum aestivum* L. Imanishi et al. (2004) utilizaram as bandas presentes na região "red-edge" do espectro para determinar o conteúdo de água em *Quercus glauca* e *Quercus serrata*, em que as melhores bandas para detecção da área foliar (LAI) foram 676,0 nm na segunda derivada ( $r = 0,828$ ) e 687,8–693,7 nm na primeira derivada ( $r = 0,812$ ). Wang & Li (2012) obtiveram maior coeficiente de determinação ao estimar o EEA de folhas de *Fagus crenata* com índice dSR<sub>(1510,1560)</sub> ( $r = 0,6-0,75$ ).

Em relação à desidratação da vegetação, o índice da água SR<sub>1300,1450</sub> foi proposto a partir de um conjunto de dados radiométricos em que as folhas tiveram uma progressiva perda no conteúdo de água (Seelig et al., 2008). Carter (1998) demonstrou, com o índice SR<sub>701,820</sub>, que o fator de reflectância próximo ao 700 nm é capaz de diagnosticar o *estresse hídrico* da planta.

Os índices de vegetação são associados principalmente ao estado nutricional e hídrico das plantas, permitindo o melhor entendimento das condições ecofisiológicas (Sellers et al., 1997; Szilagyi, 2000). Diferentes regiões do espectro foram correlacionadas com o conteúdo de água em folhas (Mobasheri & Fatemi, 2013), originando índices espectrais composto de duas ou mais bandas, e se encontram próximas às bandas da água que são: 970 nm, 1200 nm, 1450 nm, 1940 nm e 2500 nm.

Os modelos gerados com índices de vegetação para estimar conteúdo de água em folhas, geralmente, não envolvem dados com valores extremos de conteúdo de água, tornando os índices fracos para avaliar risco de mortalidade em florestas, pois a maioria desses são projetados por dados radiométricos de folhas saudáveis (Cao et al., 2015). Assim, considerando os comprimentos de onda de 400 nm – 2500 nm, quanto maior o conteúdo de água na folha, menor é a reflectância nesta faixa do espectro, isto é, folhas mortas em diferentes estágios de estresse hídrico apresentam maior reflectância.

Assim, o objetivo deste trabalho foi estabelecer as relações existentes entre variações do CRA e EEA com a resposta hiperespectral da folha, gerando modelos matemáticos para prever o seu conteúdo de água em espécies de *Eucalyptus*.

## MATERIAL E MÉTODOS

### Localização e caracterização da área de estudo

O presente estudo foi realizado em uma área experimental localizada no município de Piracicaba – SP/Brasil, nas coordenadas geográficas centrais 22°41'07" S e 47°38'38" W e altitude de 550 m. O solo local é classificado como Nitossolo Vermelho distrófico textura argilosa a moderada (Vidal-Torrado & Sparovek, 1993). O clima da região é mesotérmico, tipo Cwa (Alvares et al., 2014), com verões quentes e chuvosos e invernos moderadamente frios e secos, com temperatura média anual de 19,1°C e precipitação média anual de 1170 mm.

Na área estudada estavam presentes 11 genótipos comerciais de *Eucalyptus* mais importantes para o setor florestal brasileiro (Binkley et al., 2017) que foram plantados e conduzidos pelo Programa Cooperativo de Tolerância de *Eucalyptus* spp. clonais aos Estresses Hídricos, Térmico e Biótico - TECHS ([www.ipef.br/techs](http://www.ipef.br/techs)) do Instituto de Pesquisas e Estudos Florestais. Cada uma das 11 parcelas com 20 árvores (idade do povoamento de aproximadamente 2 anos), representam os genótipos plantados em novembro de 2013 com espaçamento de 2,2 m x 2,3 m (5,06 m<sup>2</sup> planta<sup>-1</sup>). Os genótipos de *Eucalyptus* foram classificados em 11 materiais clonais: a) plásticos: incluem *E. grandis* x *E. camaldulensis*, *E. urophylla* x *E. grandis*, *E. urophylla* x ssp., *E. saligna*, b) tropicais: incluem *E. benthamii*, *E. urophylla* x *E. tereticornis*, *E. urophylla*, *E. grandis* x *E. urophylla*, c) subtropicais: incluem *E. urophylla* x *E. globulus*, *E. dunnii*, *E. grandis*.

### Amostragem foliar

Para amostragem foliar foram marcadas quatro árvores em cada parcela e de maneira visual foram separados os terços superior, médio e inferior de cada planta. Para cada árvore marcada; foram coletadas doze folhas em posições opostas, sendo quatro folhas em cada terço da planta (Figura 1A-D). Este procedimento foi padronizado para todos os genótipos. A folha selecionada foi a segunda do ramo por apresentar um aspecto visualmente saudável, plenamente desenvolvida e boas condições fisiológicas.

A coleta das folhas ocorreu nos dias 9, 11 e 12 de dezembro de 2015, sempre entre o horário de 7 e 9 a.m. No primeiro dia foram amostradas todas as folhas do terço inferior dos genótipos estudados, no segundo dia o terço médio e finalizou-se no terço superior. Após cada uma das coletas do material, as folhas foram identificadas, embaladas em sacos plásticos transparentes, colocadas em caixa térmica com gelo (Summy et al., 2011) e, enviadas imediatamente para o local de análise. No laboratório, as folhas foram pesadas assim que chegaram, com o auxílio de uma balança analítica de precisão, para a aquisição dos valores de massa úmida.



**Figura 1-** Localização ilustrativa da coleta, A- Árvore selecionada e marcada, B-Identificação das folhas de *Eucalyptus* coletadas em campo, C-Folhas colocadas em gelo e D- Visão aproximada de uma folha do terço médio

### Determinação do conteúdo relativo de água, da área foliar e da densidade equivalente da água

Para a determinação do conteúdo relativo de água (CRA) foi necessário determinar o peso fresco (PF), o peso túrgido (PT) e o peso seco (PS). Para isso, realizou-se a pesagem das folhas para obtenção do PF, bem como as leituras espectrais de cada folha de *Eucalyptus* com o sensor *Fieldspec®* (ASD - Analytical Spectral Devices Inc., Boulder, CO, EUA). Dessa forma, a leitura radiométrica das folhas foi realizada com o espectrorradiômetro em que o aparelho opera na faixa de 350 nm a 2500 nm do espectro eletromagnético, com uma resolução espectral de 1.4 nm (350 a 1000nm) e 2 nm (1000 a 2500nm).

Em seguida, cada folha foi digitalizada pelo método da imagem digital (Adami et al., 2007) ou método do escâner (Lucena et al., 2011) para a determinação de sua área foliar. Por fim, as folhas foram emergidas em água destilada por 24 horas e pesadas para a obtenção do PT.

Quanto a determinação da área foliar, tem-se que a área foliar está diretamente relacionada com a quantidade de energia absorvida, sendo possível estimar: área foliar específica, taxa de crescimento foliar vegetativo, EEA e quantificação de variações no crescimento das plantas devido as diferenças genéticas (Fonseca & Condé, 1994). Assim, para a determinação da área foliar do presente trabalho foi utilizado um escâner que possibilitou capturar as imagens das folhas na mesma escala e com um fundo de cor branca padrão e, após coletadas todas as imagens, o processamento foi realizado no software SPRING, versão 5.1.8, desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE).

Utilizando as imagens coletadas pelo escâner o cálculo da área foliar baseou-se na escala e na resolução em pontos por polegada (*dots per inch - dpi*), sendo que a imagem gerada pelo escâner tem uma resolução de 200 dpi, dimensão de 1700 x 2338 pixels e profundidade de 24 bits. No programa SPRING, esses dados foram usados para estimar o tamanho do eixo X e Y de cada pixel. Posteriormente a digitalização da folha foi realizado o cálculo da resolução inicial ( $res_{ini}$ ), em que os valores X e Y foram calculados (Equação 1):

$$res_{ini} = \frac{2,54}{dpi} \quad (1)$$



Para essas imagens o tamanho do pixel foi convertido de centímetros para metros. Após a importação das imagens para o programa, foi realizado a segmentação da imagem, com método de crescimento de regiões com similaridade 10 e área 100, gerando um polígono sobre o limbo foliar. Quando necessário, alterações manuais corrigiriam os erros da classificação. Por fim, os valores de área foliar foram convertidos em cm<sup>2</sup>.

Já para a mensuração da reflectância com diferentes quantidades de água, o CRA e EEA e as curvas espectrais de cada folha foram obtidas pela secagem sucessiva das amostras de folhas em uma estufa microbiológica a 40°C com tempo de secagem limitado a 30 minutos. Posteriormente as folhas foram pesadas para obtenção de um novo valor de massa que substituiu o valor de PF. Em seguida, coletou-se a resposta espectral. Esse processo foi repetido sete vezes (S1, S2, S3, S4, S5, S6 e S7) até que os valores de CRA<sub>Tempo</sub> e EEA<sub>Tempo</sub> passaram a ter uma estabilidade. No final das secagens intermediárias as amostras de folhas foram colocadas em uma estufa a 70°C por 72 horas para obtenção do peso seco (Figura 2).

O CRA foi calculado com base na Equação 2, sugerida por Turner (1981). Os valores do peso fresco variaram em função do peso após a passagem da folha pela estufa, sendo que as outras variáveis foram constantes.

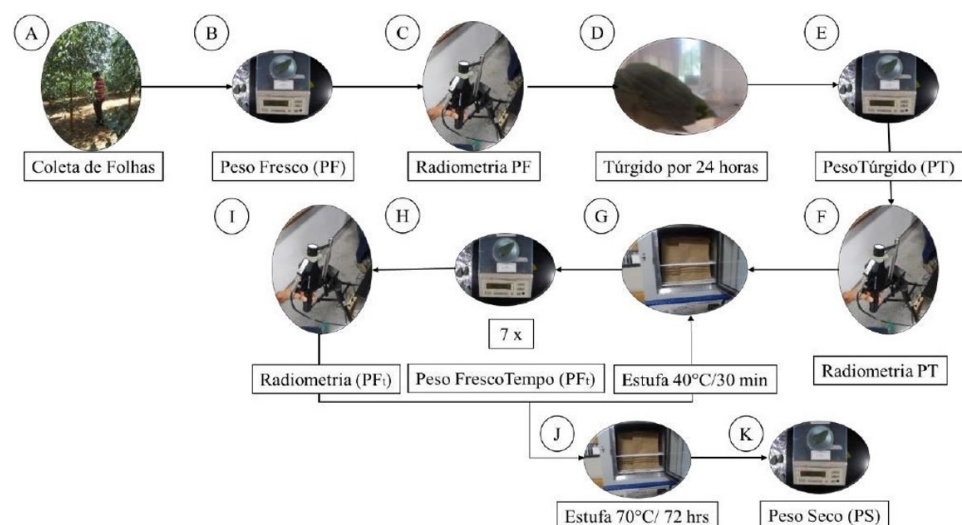
$$CRA = \frac{(PF - PS)}{(PT - PS)} * 100 \quad (2)$$

Em que PF (g) é o peso fresco, PS (g) é o peso seco após 72 horas na estufa a 70°C e PT (g) é o peso túrgido.

Em relação a determinação da densidade equivalente da água, a espessura equivalente da água (EEA) resulta no volume de água por unidade de área da folha (cm<sup>2</sup>), sugeridos por Datt (1999), conforme a Equação 3:

$$EEA = \frac{(PF - PT)}{(\rho * AF)} \quad (3)$$

Em que PF (g) é o peso fresco da folha, PS (g) é o peso seco da mesma folha,  $\rho$  é uma constante física que representa a densidade água pura (1g/cm<sup>3</sup>) e AF é a área foliar (cm<sup>2</sup>).



**Figura 2** – Fluxograma da metodologia para obtenção progressiva do conteúdo relativo de água (CRA), da densidade equivalente da água (EEA) e da radiometria das folhas de *Eucalyptus*

### Determinação do conteúdo de água das folhas por espectrorradiometria

A análise de componentes principais (ACP) foi realizada para todas as curvas espectrais no programa Parles 3.1, a fim de observar e remover os dados discordantes (*outliers*). Após remoção destes *outliers*, foi calculada a média dos dados de fator de reflectância em relação aos quatro pontos opostos da árvore, ou seja, foi obtido um valor médio por terço de cada árvore. Para verificar a relação linear entre o conteúdo de água e os dados hiperespectrais foi realizada análise de correlação univariada Pearson entre os parâmetros da água (CRA e EEA) com os dados hiperespectrais (350 nm - 2500 nm) (Datt, 1999). Os coeficientes de correlação ( $r$ ) foram submetidos ao teste  $t$  de student ( $p \leq 0,05$ ) para averiguar sua significância.

### Índices espectrais utilizados para a predição do conteúdo de água

Foram selecionados oito índices espectrais sensíveis a variação do conteúdo de água em folhas, conforme a literatura (Tabela 1). Com base nos dados hiperespectrais coletados para folhas de *Eucalyptus* foram calculados os índices selecionados. Quanto a correlação dos índices com o teor de água, encontrou-se relação entre os índices calculados e os parâmetros da água por meio do coeficiente de determinação ( $R^2$ ), e testou-se sua significância ao nível de 5%.

**Tabela 1** – Índices de Vegetação selecionados para relacionar com o conteúdo de água nas folhas de *Eucalyptus*

Índice	Equação	Referência
Water Index (WI)	$\frac{\rho_{900}}{\rho_{970}}$	Peñuelas et al. (1997)
Moisture Stress Index (MSI)	$\frac{\rho_{1650}}{\rho_{820}}$	Hunt & Rock (1989)
Normalised Difference Water Index (NDWI)	$\frac{(\rho_{860} - \rho_{1240})}{(\rho_{860} + \rho_{1240})}$	Gao (1996)
Normalized Difference Infrared Index (NDII)	$\frac{(\rho_{819} - \rho_{1600})}{(\rho_{819} + \rho_{1600})}$	Hardisky et al. (1983)
Simple Ratio 701 and 820 ( $SR_{701,820}$ )	$\frac{\rho_{701}}{\rho_{820}}$	Carter (1998)
Simple Ratio 1300 and 1450 ( $SR_{1300,1450}$ )	$\frac{\rho_{1300}}{\rho_{1450}}$	Seelig et al. (2008)
$\frac{(R_{850} - R_{2218})}{(R_{850} - R_{1928})}$	$\frac{(\rho_{850} - \rho_{2218})}{(\rho_{850} - \rho_{1928})}$	Datt (1999)
$\frac{(R_{850} - R_{1788})}{(R_{850} - R_{1928})}$	$\frac{(\rho_{850} - \rho_{1788})}{(\rho_{850} - \rho_{1928})}$	Datt (1999)

\* $\rho_n$  = Comprimento de Onda

Os índices que tiveram significância foram submetidos à análise de regressão linear simples, no programa Excel, e foram considerados variáveis independentes. As variáveis dependentes foram os valores de CRA e EEA encontradas em laboratório. Os modelos foram calibrados com 70% dos dados de CRA e EEA, e validados com o restante dos dados. A precisão dos modelos, gerados pelos índices de vegetação, foi avaliada pelo coeficiente de determinação ( $R^2$ ) e a raiz quadrada do erro médio (RMSE) (Equação 4).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Em que  $y_i$  são os valores do conteúdo de água (CRA e EEA) estimados pelo modelo proposto e  $\hat{y}_i$  são os resultados da análise de laboratório para o conteúdo água (CRA e EEA) na folha e  $n$  é o número de amostras da validação.

O RMSE mostra o erro do modelo e sua unidade de medida é a mesma unidade dos parâmetros mensurados. O melhor índice foi identificado pela combinação entre o maior  $R^2$  e o menor RMSE, respectivamente.

### Seleção de variáveis para obtenção dos modelos

Os modelos matemáticos para a predição dos parâmetros da água foram feitos por meio da análise de regressão linear. Todavia, nos dados hiperespectrais, há grande quantidade de variáveis para a coleta de uma única informação, sendo que na maioria dos casos o número

de observações é menor que o número de variáveis preditoras e muitas delas estão altamente correlacionadas. Assim, as variáveis selecionadas para a predição do modelo foram obtidas por dois diferentes métodos:

- 1) Seleção de variáveis pelo coeficiente de determinação, de acordo com o maior  $R^2$ , obtido pela relação entre os parâmetros da água e os dados hiperespectrais. Nesse método, selecionaram-se as variáveis de maior  $R^2$  dentro das seguintes regiões do espectro: visível (VIS: 350 nm - 720 nm), infravermelho próximo (IVP: 720 nm - 1100 nm), infravermelho médio I (IVMI: 1100 nm - 1700 nm), infravermelho médio II (IVMII: 1700 nm - 2100 nm) e infravermelho médio III (IVMIII: 2100 nm - 2500 nm). Todas as regiões do espectro determinadas acima possuem uma banda da água, exceto a região do visível.
- 2) Seleção de variáveis pelo método *stepwise*. A redução de dimensão dos dados foi feita por meio do *sparse Partial Least Square* (sPLS), no qual é feita a imposição de dispersão (*sparsity*) nas variáveis preditoras, por meio dos princípios dos mínimos quadrados parciais (Chun & Keles, 2010). Essa metodologia foi implementada utilizando o pacote de análises "sPLS", desenvolvido para o programa estatístico R (Chung & Chun, 2015). O critério de seleção das variáveis utilizado foi o critério de informação de Akaike (AIC), porém não representa diretamente a qualidade do modelo final.
- 3) Foram selecionados os 12 comprimentos com maior coeficiente para o CRA e os 12 comprimentos com maior coeficiente para o EEA. Os resultados encontrados pelos diferentes métodos de seleção de variáveis foram submetidos à análise de regressão linear simples e múltipla, no Excel, sendo estas consideradas variáveis independentes. As variáveis dependentes foram os valores dos parâmetros de conteúdo da água CRA e EEA encontradas em laboratório. Cada modelo foi calibrado com 70% dos dados dos respectivos parâmetros: CRA e EEA, e validados com o restante dos dados. A precisão dos modelos gerados foi avaliada pelo coeficiente de determinação ( $R^2$ ) e a raiz quadrada do erro médio (RMSE), já visto na (Equação 4), e o erro relativo (RE%) a seguir (Equação 5).

$$RE (\%) = \left( \sqrt{\frac{1}{n} * \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{\hat{y}_i} \right)^2} \right) * 100 \quad (5)$$

Em que  $y_i$  são os valores do conteúdo de água (CRA e EEA) estimados pelo modelo proposto e  $\hat{y}_i$  são os resultados da análise de laboratório para o conteúdo água (CRA) na folha e  $n$  o número de amostras da validação.

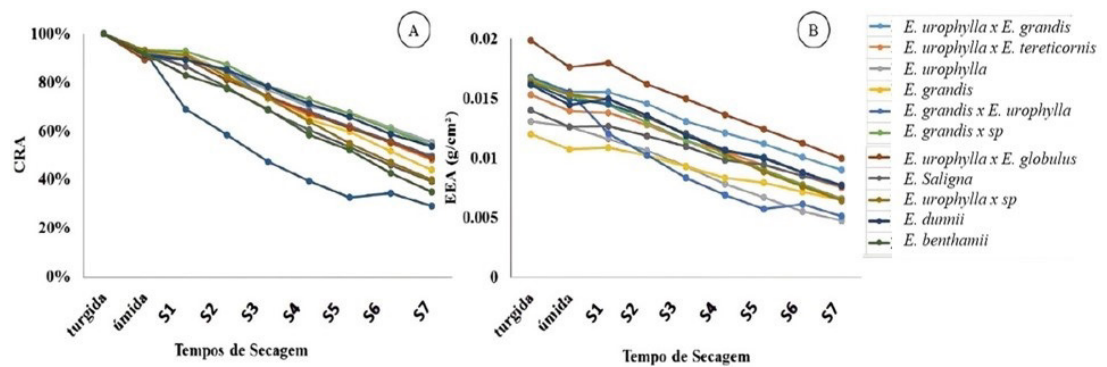
Na construção do modelo foi utilizado o método de validação cruzada em que 70% dos dados são usados para a calibração do modelo e o restante (30%) foi utilizado para a validação. Na fase de seleção de variáveis utilizou o conjunto de dados completo ( $n=322$  amostras).

## RESULTADOS E DISCUSSÃO

### Comportamento do CRA e o EEA

Ambos os parâmetros (CRA e EEA) tiveram uma alta variação entre o seu conteúdo de água máximo e mínimo indicando que o valor de conteúdo máximo de água estava relacionado com o estado de turgor das folhas (máxima quantidade de água), enquanto o valor do conteúdo mínimo de água foi representado pela perda de água nas folhas, devido à secagem das 11 espécies de *Eucalyptus* (Figura 3A, B).

Todas as espécies e híbridos tinham o mesmo conteúdo relativo de água no momento túrgido e as respostas aos tempos de secagem foram similares (Figura 3A), sendo que a perda da água ocorreu de forma gradual e descendente. As respostas de secagem tiveram um EEA inicial diferente entre as espécies (Figura 3B), pois este parâmetro é dependente da área foliar, que varia por espécie. *E. urophylla* x *E. globulus* apresentou maiores valores de EEA para todos os tempos de secagem.




**Figura 3** – Comportamento do CRA (A) e do EEA (B) em função do tempo de secagem

Wang et al. (2009) estimaram o conteúdo de água em três diferentes espécies (*Pinus massoniana*, *hodomirtus tomentosa* e *Dicranopteris dichotoma*) sendo essas arbórea, arbustiva, e a última uma planta anual, e encontraram um CRA (%) de folhas frescas variando de 42,25%-62,53%, isto é, com porcentagem de conteúdo relativo de água inferiores aos resultados encontrados neste trabalho. As três espécies descritas apresentaram um EEA ( $\text{g}/\text{cm}^2$ ) de 0,006 - 0,040, ou seja, resultados superiores ao encontrado em folhas de *Eucalyptus* (Figura 3B), pois essas espécies apresentam maior área foliar quando comparadas às espécies estudadas por Wang et al. (2009).

Já na Figura 4, a curva média de folhas de *Eucalyptus* apresentou um fator de reflectância similar a uma folha sadia e a curva espectral máxima representou o peso túrgido. A curva espectral mínima, quando as folhas tiveram um conteúdo de água muito baixo (peso S7), diminuiu a intensidade da feição nas bandas de absorção de água: 1150 nm – 1260 nm, 1450 nm e 1950 nm (Ranjan et al., 2015; Ceccato et al., 2002). Entretanto, próximo a região de 970 nm perdeu-se completamente a feição de absorção, descaracterizando o comportamento espectral da vegetação, que correspondeu a um conteúdo relativo de água de aproximadamente 5%.

Foi observada alta diferença entre o conteúdo de água máximo e mínimo na resposta espectral de folhas de *Eucalyptus*. Além da água, outros fatores podem ser responsáveis pela variação na resposta espectral, como a concentração de clorofila ou estrutura do mesófilo. Mesmo resultado foi obtido por Datt (1999), que avaliou o comportamento espectral de 21 espécies de *Eucalyptus*. O comportamento espectral da curva de máxima reflectância na folha (Figura 4) apresentou características espectrais semelhantes as apresentadas por Zarco-Tejada et al. (2003) que, em seu estudo, estimaram o teor de água na vegetação. Para os autores, a água não foi o único parâmetro que influenciou no resultado radiométrico das folhas, a quantidade de matéria seca e organização celular também foram fatores relevantes.

Além disso, o momento de ascendência da curva espectral (*red-edge*) foi antecipado para a curva de reflectância máxima (Figura 4), que pode estar relacionado com a degradação dos pigmentos da folha com comportamento espectral máximo. A região do vermelho também teve um maior aumento da reflectância que a região do azul, provavelmente a clorofila foi mais degradada que os outros pigmentos (Ponzoni et al., 2012).



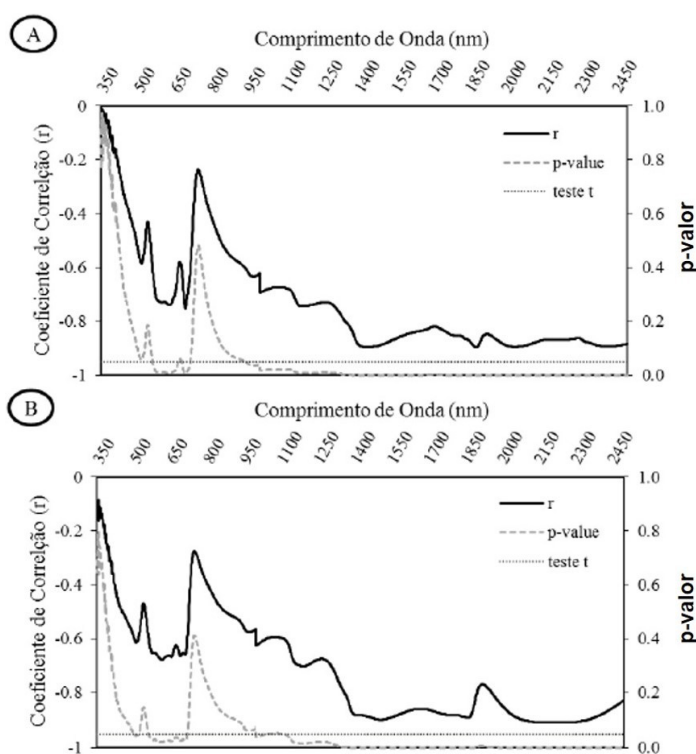
**Figura 4** – Comportamento espectral mínimo, médio e máximo de folhas de *Eucalyptus*



### Relação entre o conteúdo de água na folha de *Eucalyptus* e os dados hiperespectrais

O coeficiente de correlação de Pearson ( $r$ ) foi calculado para todas os comprimentos de onda dentro do intervalo de 350 nm – 2500 nm, para determinar a relação dos parâmetros CRA e EEA com os dados hiperespectrais. As regiões estatisticamente significativas ( $p$ -valor < 0,05), que tiveram um coeficiente de correlação variando entre moderado negativo à forte negativo, foram indicadas na Figura 5A, B.

Algumas regiões do VIS (560 nm - 664 nm e 679 nm - 714 nm) tiveram uma correlação negativa moderada (Figura 5A), enquanto que no comprimento de onda de 939 nm a 2500 nm foi observado uma variação de moderada negativa a forte negativo. Uma relação negativa entre os parâmetros da água e os dados espectrais ocorreu devido a quantidade de energia refletida pelas folhas com água, ou seja, quanto mais água maior será absorção da radiação eletromagnética (REM) na folha. A região do VIS apresentou menor correlação com os parâmetros da água, mas teve forte correlação com o conteúdo de pigmentos na folha.



**Figura 5** – Correlação entre o fator de reflectância e (A) Conteúdo Relativo de Água-CRA e (B) Espessura Equivalente da Água- EEA. Os valores críticos do coeficiente de correlação ( $p$ -valor < 0,05) são indicados com a linha horizontal (pontilhada)

Zhang et al. (2014) encontraram um coeficiente de correlação máximo de 0,8 entre o CRA e os dados hiperespectrais ao estudarem a influência da salinidade do solo nos fatores de reflectância de folhas de algodão, enquanto que neste estudo coeficiente de correlação máximo ( $r = -0,89$ ) foi entre o CRA no comprimento de onda 1881 nm.

Yi et al. (2013) investigaram a relação do EEA com a resposta espectral para folhas de uma cultura de algodão e o coeficiente de correlação negativo máximo foi de  $r = -0,67$  (1725 nm), com a máxima correlação entre as bandas 1550 nm – 1850 nm, que corresponde à região com elevada absorção de energia devido a água. Neste estudo, o coeficiente de correlação entre o EEA e os dados espectrais (Figura 5B) apresentaram uma correlação negativa com todo espectro de folhas de *Eucalyptus*, com um coeficiente de correlação máximo ( $r = -0,79$ ) para o comprimento de onda 2165 nm.

Carter (1994) e Carter & Knapp (2001) mostraram que índices que usam comprimento de onda próximo ao 700 nm e o infravermelho apresentaram uma alta correlação com parâmetros

que predizem água. Neste trabalho, encontrou-se uma baixa correlação entre o CRA e a região de 700 nm, por causa da reflectância das bandas próximas que são fortemente influenciadas pelos pigmentos fotossintetizantes e com baixa influência da água (Cao et al., 2015).

### Avaliação de índices espectrais levantados na literatura para a predição de água

No estágio de calibração do modelo de regressão linear simples foi possível identificar que o *Simple Ratio* 701 and 820 teve um  $R^2$  não significativo ao nível de significância de 5% para o parâmetro EEA (Tabela 2). Provavelmente esses comprimentos de onda possuem maior correlação com os pigmentos e estrutura da folha, o que ocultaria os efeitos da água. Esse índice também apresentou uma significância irrelevante para o parâmetro CRA, assim como o  $(R_{850}-R_{2218})/(R_{850}-R_{1928})$ , para diferentes espécies e híbridos de *Eucalyptus* (Tabela 2). O índice MSI apresentou um dos maiores  $R^2$  para os parâmetros da água por conter duas bandas com alta correlação com a água (Ponzoni et al., 2012).

**Tabela 2** – Coeficiente de determinação ( $R^2$ ) entre os parâmetros da água (CRA e EEA) e os índices espectrais usados para a calibração do modelo

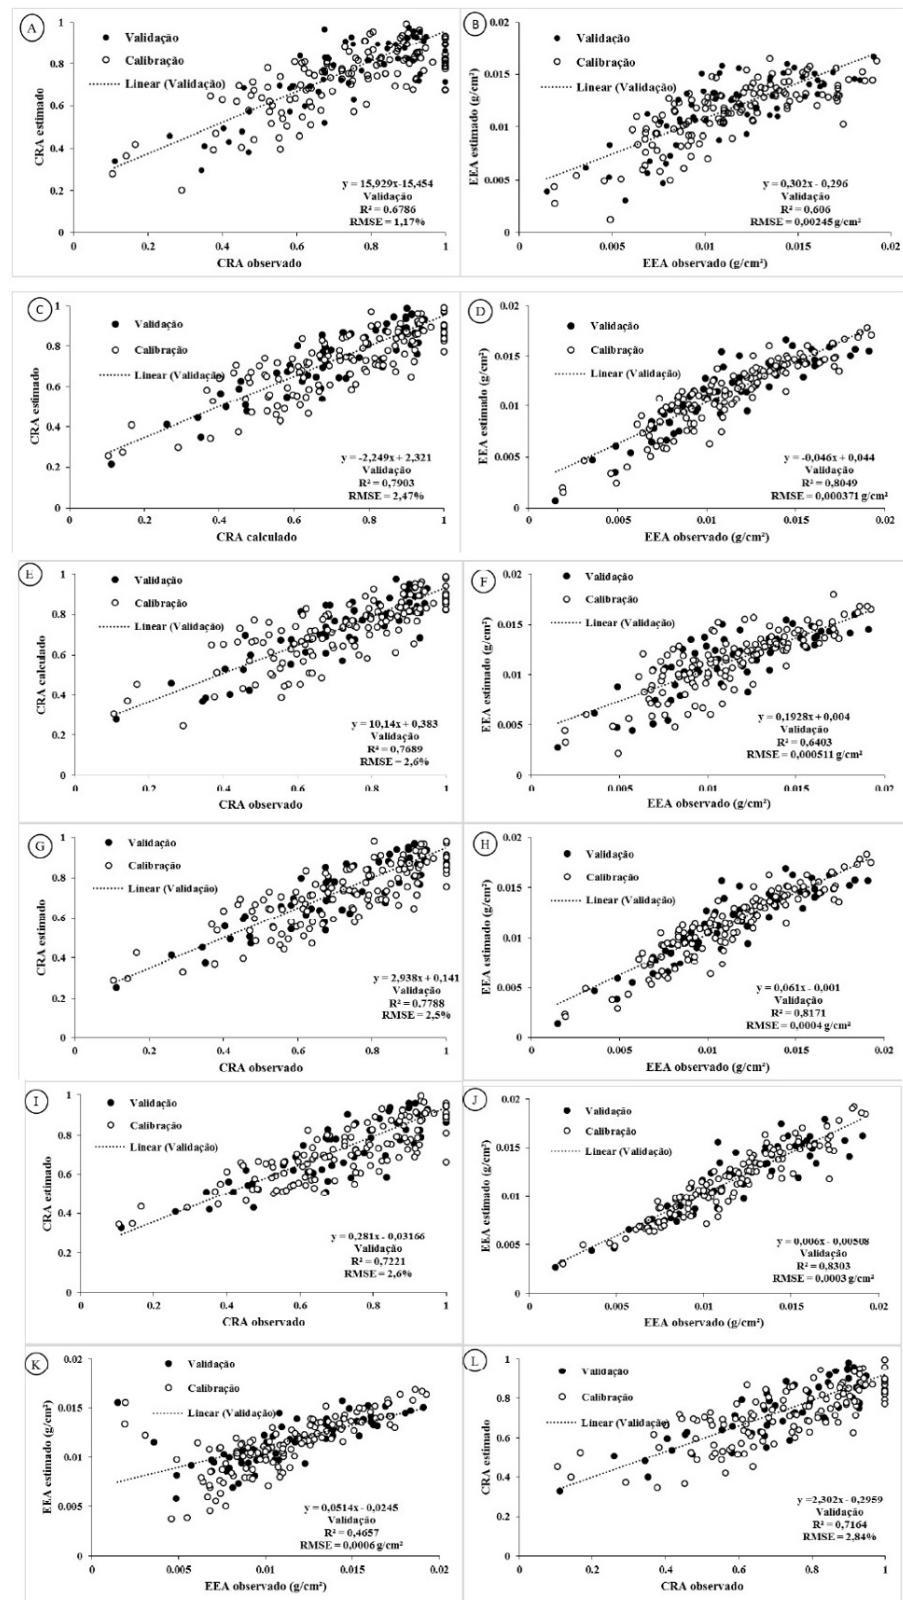
Índices Espectrais	WI	MSI	NDWI	NDII	SR <sub>701,820</sub>	SR <sub>1300,1450</sub>	$(R_{850}-R_{2218})/(R_{850}-R_{1928})$	$(R_{850}-R_{1788})/(R_{850}-R_{1928})$
EEA	0,60*	0,82*	0,67*	0,83*	0,20	0,87*	0,54*	0,81*
CRA	0,61	0,71*	0,70*	0,70*	0,25	0,68*	0,28	0,60*

\*Significativo ao nível de significância de 5%

Os índices espectrais da vegetação mostraram um resultado satisfatório tanto para predição de CRA quanto para o EEA (Figura 6 A-L), porém a maioria dos índices tiveram um  $R^2$  maior ao predizer o parâmetro EEA. O índice SR<sub>1300,1450</sub>, ao estimar o parâmetro EEA, apresentou maior coeficiente de determinação ( $R^2=0,83$ ) e um baixo valor para a raiz quadrada do erro médio (RMSE=0,0003 g/cm<sup>2</sup>), enquanto que o índice MSI apresentou seu maior coeficiente de determinação ( $R^2=0,79$ ) quando correlacionado com o CRA. Isso ocorreu provavelmente porque o índice da água SR<sub>1300,1450</sub> foi baseado em um conjunto de dados radiométricos de folhas com progressiva perda no conteúdo de água. Datt (1999) encontrou um bom coeficiente de determinação ( $R^2=0,81$ ) ao estimar o EEA de folhas de *Eucalyptus* pelo índice  $(R_{850}-R_{2218})/(R_{850}-R_{1928})$ , enquanto que este trabalho apresentou um baixo  $R^2$  para estimar o EEA (Figura 6K). Mesmo assim, os comprimentos de onda 1928 nm e 2218 nm possuíram uma alta correlação linear com os parâmetros da água.

O método de seleção de variáveis pelo coeficiente de determinação permitiu encontrar quais os comprimentos de onda têm maior relação com parâmetros de água (Figura 6A-L), assim como demonstrou Mobasheri e Fatemi (2013). Os resultados do  $R^2$ , encontrados na validação do modelo com o índice WI, foram moderados e inferiores aos outros índices apresentados, tanto para o CRA quanto para o EEA (Figura 6A e Figura 6B). Peñuelas et al. (1997) afirmaram que o WI diminui com a queda da quantidade de água na folha. Peñuelas e Inoue (1999) encontraram uma alta correlação entre os mesmos parâmetros da água e o índice WI para folhas de amendoim e trigo e verificaram que a correlação diminui com a perda de água pela dessecação das folhas e varia de acordo com a espécie, devido à estrutura celular e à elasticidade da parede celular (Peñuelas et al., 1996).

Ranjan et al. (2015) correlacionaram o CRA e o EEA de uma cultura de trigo e encontraram um  $R^2$  que variou de muito baixo a alto. Para o índice MSI, os autores encontraram um  $R^2=0,85$  para EEA e  $R^2=0,81$  para o CRA, enquanto este trabalho apresentou valores de  $R^2$  próximos (Figura 6C e Figura 6D).




**Figura 6** – Teste entre os parâmetros da água e os índices (A) CRAxWI, (B) EEAx WI, (C) CRA x MSI, (D) EEA x MSI, (E) CRA x NDWI, (F)EEA x NDWI, (G) CRA x NDII, (H) EEA x NDII, (I) CRA x SR1300, 1450, (J) EEA x SR1300, 1450, (K) EEA x (R850-R2218)/(R850-R1928), (L) CRA x (R850-R1788)/(R850-R1928)

### Seleção de variáveis predictoras pelo coeficiente de determinação

Os valores de  $R^2$  variam de quase nulo a muito alto (Figura 7A), sendo que a região do IVM (1300 nm – 2500 nm) foi a que apresentou maior relação entre o CRA e os dados espectrais. Em

1882 nm foi encontrado o maior coeficiente de determinação ( $R^2=0,8$ ). Em contraposição, os menores valores foram entre 726 nm e 816 nm e a região "red-edge" (748 nm) teve menor coeficiente de determinação ( $R^2=0,05$ ).

Na Figura 7A, B, os valores de  $R^2$  variaram de muito baixo à alto, com melhores resultados de  $R^2$  para EEA do que CRA em quase todo o espectro, essa diferença foi mais significativa entre os comprimentos de onda de 2300 nm e 2500 nm. A partir de 800 nm, os dados espectrais tiveram um aumento progressivo da relação com o EEA, porém o valor de  $R^2$  teve uma queda abrupta próximo a 1925 nm. Assim, em regiões de absorção existem comprimentos de onda menos sensíveis à espessura equivalente de água na folha e após 1926 nm, os valores de  $R^2$  voltam a ter um aumento progressivo. Mobasheri & Fatemi (2013) estudaram a relação do EEA com dados espectrais (350 nm – 2500 nm) de 320 amostras espectrais de 80 espécies diferentes, e obtiveram valores mais altos de  $R^2$  na região do IVM (1300 nm – 2500 nm) e identificaram uma queda abrupta do  $R^2$  próximo a 1928 nm. Esses resultados foram semelhantes ao EEA do presente trabalho, que teve uma maior relação com o espectro a partir de 1340 nm.



**Figura 7** – Valores do coeficiente de determinação ( $R^2$ ) da regressão linear entre valores individuais de fator de reflectância das folhas de *Eucalyptus*. (A) Conteúdo Relativo da Água- CRA e (B) Espessura Equivalente da Água- EEA

O menor valor de  $R^2$  (0,07) foi em 749 nm (Figura 7B), enquanto que Mobasheri & Fatemi (2013) encontraram o menor valor de  $R^2$  (0,00001) em 1318 nm, também para EEA. Já a relação entre o EEA e dados hiperespectrais em folhas de *Eucalyptus* no comprimento de 1350nm foi de  $R^2=0,61$ . O maior valor para o coeficiente de determinação ( $R^2=0,83$ ) ocorreu em 2258 nm, próximo ao ponto de absorção de energia devido a água em 2200 nm. Este valor foi selecionado para gerar um modelo com uma única variável independente capaz de prever EEA.

As regiões do VIS e IVP apresentaram maior  $R^2$  em comprimentos de onda semelhantes para os dois parâmetros (Tabela 3). Na região do VIS, o CRA teve maior correlação com o comprimento de onda de 694 nm e o parâmetro EEA com 616 nm. Apesar de pertencerem a bandas diferentes, os dois comprimentos de onda são próximos e fortemente influenciados pela absorção de REM devido a pigmentos fotossintetizantes, visto que a região do visível do espectro eletromagnético é influenciada pelos pigmentos da folha (xantofilas, carotenos e clorofilas "a" e "b"), e corresponde à radiação absorvida para o acúmulo de biomassa (Sims & Gamon, 2002). Na região do IVP, os comprimentos de onda próximos a 1000 nm

apresentaram maior  $R^2$  com os parâmetros da água, porém EEA possui menor relação com essa região do espectro. A partir da região IVMI o  $R^2$  passou a ter um valor mais relevante que as regiões anteriores, e o EEA apresentou maior  $R^2$  que o CRA ao ser correlacionado com os dados espectrais dessas regiões.

**Tabela 3** – Valores de regressão linear ( $R^2$ ) máximos baseados em diferentes regiões do espectro: VIS (350 nm-720 nm), IVP (721 nm - 1100 nm), IVM (1101 nm - 1700 nm), IVMI (1701 nm -2100 nm), IVMIII (2101 nm - 2500 nm)

Regiões do Espectro	CRA		EEA	
	$\lambda$ (nm)	$R^2$	$\lambda$ (nm)	$R^2$
VIS	694	0,562	616	0,459
IVP	1001	0,480	1004	0,390
IVMI	1439	0,800	1510	0,811
IVMI	1883	0,804	2100	0,817
IVMIII	2423	0,798	2258	0,832

O CRA apresentou maior  $R^2$  com os comprimentos de onda próximos as bandas da água nas regiões IVMI e IVMI e o valor de  $R^2$  diminuiu na última região do infravermelho (IVMIII). Para o EEA os valores de  $R^2$  tiveram um aumento progressivo do IVMI para o IVMI, seguido pelo IVMIII, sendo que na última região do espectro foi encontrado um comprimento de onda próximo a banda de absorção devido a água (2200 nm) (Tabela 3). Os modelos gerados por essa seleção de variáveis foram descritos na Tabela 4.

### Seleção de variáveis preditoras pelo método de *stepwise*

Observou-se que a região do VIS e do IVM foram as mais relevantes para a predição do CRA, enquanto que para predição do EEA todos os comprimentos de onda selecionados foram contidos na região do IVM (Tabela 4). Ao selecionar as variáveis preditoras do CRA, o sPLS selecionou 5 comprimentos de onda consecutivos e pertencentes à região do VIS e, para as variáveis preditoras do EEA, o método sPLS selecionou 7 comprimentos de onda entre 1900 nm e 2000 nm. Ao analisar os comprimentos de onda selecionados pelo método *stepwise* para prever EEA, todos foram próximos ao comprimento de onda de 1900 nm.

**Tabela 4** – Desempenho dos modelos espectrais para a predição do conteúdo relativo de água e espessura equivalente da água usando dois diferentes métodos de seleção de variáveis

	CRA		EEA	
	Variáveis independentes (nm)	Modelos	Variáveis independentes (nm)	Modelos
Única Banda	1883	$y = 1,213062 - 3,00447 \cdot \lambda$	2258	$y = 0,024691 - 0,07832 \cdot \lambda$
Seleção de Bandas	Regiões do Espectro	$y = 1,366438 - 0,94477 \cdot \lambda_1 - 0,36067 \cdot \lambda_2 + 1,509241 \cdot \lambda_3 - 3,86283 \cdot \lambda_4 - 0,47854 \cdot \lambda_5$	$\lambda_1 = 616$	$y = 0,018622 -$
			$\lambda_2 = 1004$	$0,01733 \cdot \lambda_1 +$
			$\lambda_3 = 1510$	$0,037395 \cdot \lambda_2 -$
			$\lambda_4 = 2100$	$0,11801 \cdot \lambda_3 +$
			$\lambda_5 = 2258$	$0,183768 \cdot \lambda_4 -$
	Stepwise	$y = 1,123 - 7,793 \cdot \lambda_1 + 9,417 \cdot \lambda_2 - 30,871 \cdot \lambda_3 + 458,232 \cdot \lambda_4 - 425,116 \cdot \lambda_5 - 5,274 \cdot \lambda_6$	$\lambda_1 = 1783$	$y = 0,01856 +$
			$\lambda_2 = 1907$	$0,046787 \cdot \lambda_1 +$
			$\lambda_3 = 1924$	$0,352485 \cdot \lambda_2 -$
			$\lambda_4 = 1925$	$24,5672 \cdot \lambda_3 +$
			$\lambda_5 = 1950$	$25,6335 \cdot \lambda_4 -$
			$\lambda_6 = 1968$	$6,08906 \cdot \lambda_5 +$
			$\lambda_7 = 1990$	$7,887383 \cdot \lambda_6 -$
				$3,32621 \cdot \lambda_7$

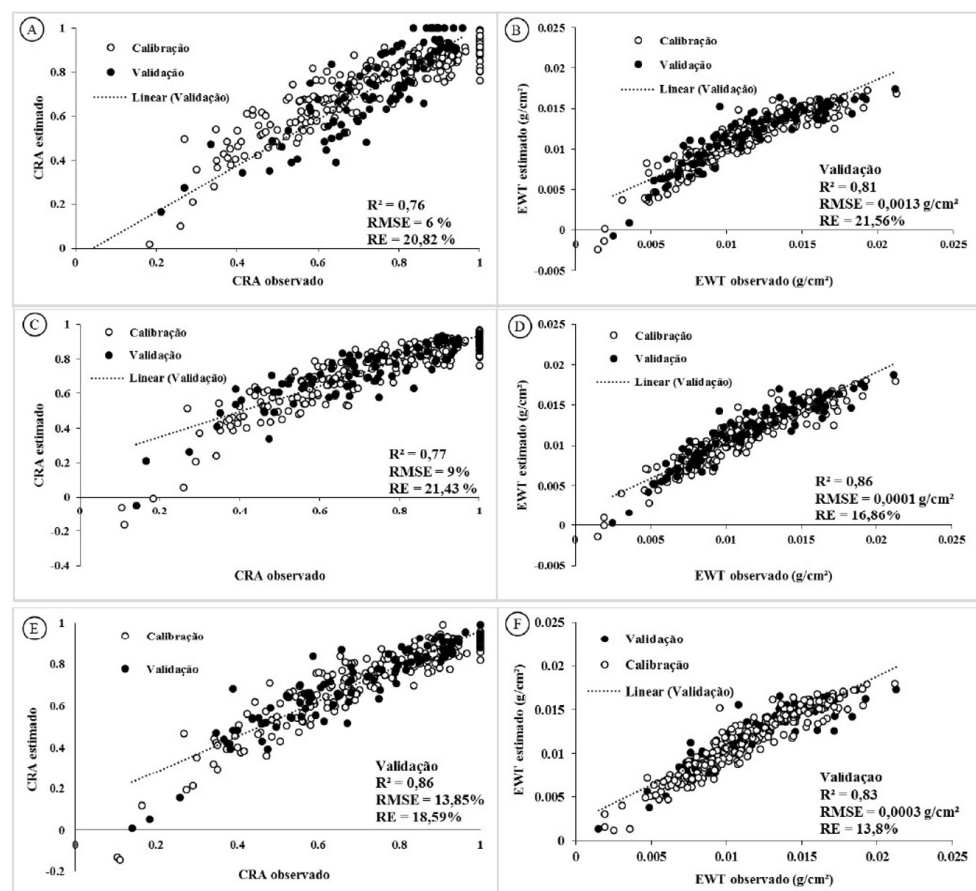


### Calibração de modelos para a predição do conteúdo de água em folhas de *Eucalyptus*

O modelo com uma única banda (Figura 8A) utilizou o método de regressão linear simples, em que a variável independente foi o comprimento de onda de maior  $R^2$  ao ser correlacionado com o CRA. Este modelo apresentou um  $R^2$  (0,76) de validação aceitável de acordo com Sayes et al. (2008), que considerou modelos de predição com um  $R^2$  de 0,66 a 0,81 como aceitáveis. O RMSE foi baixo (6,84%), enquanto que o seu RE foi de aproximadamente 20%. O modelo desenvolvido através das variáveis de região do espectro (Figura 8C) apresentou resultados similares aos do modelo de uma única banda, sendo  $R^2$  de 0,77, o RMSE de 9% e o RE de aproximadamente 21%. Porém, no método de redução e seleção de variáveis *stepwise* (Figura 8E), foi possível observar um aumento no valor do coeficiente de determinação ( $R^2=0,86$ ). De acordo com Sayes et al. (2008), modelos com um  $R^2$  de 0,82 a 0,90 podem ser considerados bons. Assim, este método de seleção de variáveis, apesar de ter apresentado um RMSE maior que os outros modelos, apresentou um RE um pouco inferior aos modelos apresentados.

Para o parâmetro EEA, foi utilizada a mesma metodologia de seleção de variáveis para geração de três modelos, através do método de regressão linear. Os índices de desempenho do modelo para uma única banda (Figura 8B) apresentou resultados satisfatórios com  $R^2=0,81$ , semelhante a Sayes et al. (2008), porém com o mais alto RMSE (RMSE=0,0013 g/cm<sup>2</sup>) e erro relativo (RE=21,56%).

O modelo desenvolvido pelas variáveis selecionadas de acordo com as regiões do espectro (Figura 8D) foi o que apresentou melhores resultados de desempenho para prever o parâmetro EEA, devido a um  $R^2$  satisfatório e superior aos outros resultados e um RMSE inferior ao dos outros modelos, mesmo com maior erro relativo que o modelo de *stepwise* (Figura 8F).



**Figura 8** – Análise gráfica do resultado de calibração e validação dos modelos de regressão para a predição do conteúdo de água em folhas de *Eucalyptus* A) Predição do CRA por uma única banda, B) Predição do EEA por uma única banda, C) Predição do CRA pelas regiões do espectro, D) Predição do EEA pelas regiões do espectro, E) Predição do CRA pelo método de *stepwise* e F) Predição do EEA pelo método de *stepwise*.

Os dados hiperespectrais apresentaram resultados mais satisfatórios ao predizer a quantidade de água por centímetro quadrado de folha que o conteúdo relativo da água. Oumar & Mutanga (2010) também encontraram um  $R^2$  satisfatório ao predizer o conteúdo de água em planta para a espécie *Eucalyptus grandis* ( $R^2=0,7$ ) e um RMSE de 2,83% pelo método de regressão de *stepwise*, por bandas do satélite SumbandlaSat.

Portanto, a seleção de variáveis e geração de modelos para predição do CRA e EEA a partir de dados hiperespectrais foram eficientes com esta metodologia. Os resultados de calibração e validação dos modelos evidenciaram a potencialidade do uso de informações de reflectância para o monitoramento da variação do conteúdo de água em folhas de *Eucalyptus*. Os estudos realizados em folhas dão suporte para que novas pesquisas sejam realizadas a nível de dossel ou mesmo orbital, que são necessárias para corroborar com as informações apresentadas neste trabalho.

## CONCLUSÃO

Os resultados indicaram potencial do uso de dados hiperespectrais para avaliação das variações dos parâmetros CRA e EEA em folhas de *Eucalyptus*. Foi possível predizer CRA e EEA, para o gênero *Eucalyptus* por meio de modelos matemáticos derivados de dados hiperespectrais.

Os comprimentos de onda com maior correlação com os parâmetros de conteúdo de água foram o  $\lambda 1883$  para o CRA e o  $\lambda 2258$  para o EEA. Dentre os índices testados, o índice  $SR_{1300,1450}$  foi o mais adequado para estimar o parâmetro EEA, enquanto que para o CRA o índice mais adequado foi o MSI.

## REFERÊNCIAS

- Adami, M., Hastenreiter, F. A., Flamignan, D. L., & Faria, R. T. (2007). Estimativa de área foliar de soja usando imagens digitais e dimensões foliares. In *Anais do 13º Simpósio Brasileiro de Sensoriamento Remoto* (pp. 9-14). Florianópolis: SBRs.
- Ahamed, T., Tian, L., Zhang, Y., & Ting, K. C. (2011). A review of remote sensing methods for biomass feedstock production. *Biomass and Bioenergy*, 35(7), 2455-2469. <http://dx.doi.org/10.1016/j.biombioe.2011.02.028>.
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., Gonçalves, J. L. M., & Sparovek, G. (2014). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711-728. <http://dx.doi.org/10.1127/0941-2948/2013/0507>.
- Arndt, S. K., Irawan, A., & Sanders, G. (2015). Apoplastic water fraction and rehydration techniques introduce significant errors in measurements of relative water content and osmotic potential in plant leaves. *Physiologia Plantarum*, 155(4), 355-368. PMID:26331213. <http://dx.doi.org/10.1111/ppl.12380>.
- Binkley, D., Campoe, O. C., Alvares, C., Carneiro, R. L., Cegatta, Í., & Stape, J. L. (2017). The interactions of climate, spacing and genetics on clonal *Eucalyptus* plantations across Brazil and Uruguay. *Forest Ecology and Management*, 405, 271-283. <http://dx.doi.org/10.1016/j.foreco.2017.09.050>.
- Cao, Z., Wang, Q., & Zheng, C. (2015). Best hiperespectral indices for tracing leaf water status as determined from leaf dehydration experiments. *Ecological Indicators*, 54, 96-107. <http://dx.doi.org/10.1016/j.ecolind.2015.02.027>.
- Carter, G. A. (1994). Ratios of leaf reflectance in narrow wavebands as indicators of plant stress. *International Journal of Remote Sensing*, 15(3), 697-703. <http://dx.doi.org/10.1080/01431169408954109>.
- Carter, G. A. (1998). Reflectance wavebands and indices for remote estimation of photosynthesis and stomatal conductance of pine canopies. *Remote Sensing of Environment*, 82(1), 198-207. [http://dx.doi.org/10.1016/S0034-4257\(97\)00110-7](http://dx.doi.org/10.1016/S0034-4257(97)00110-7).
- Carter, G. A., & Knapp, A. K. (2001). Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. *American Journal of Botany*, 88(4), 677-684. PMID:11302854. <http://dx.doi.org/10.2307/2657068>.
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., & Grégoire, J.-M. (2001). Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment*, 77(1), 22-33. [http://dx.doi.org/10.1016/S0034-4257\(01\)00191-2](http://dx.doi.org/10.1016/S0034-4257(01)00191-2).
- Ceccato, P., Gobron, N., Flasse, S., Pinty, B., & Tarantola, S. (2002). Designing a spectral index to estimate vegetation water content from remote sensing data. Part 1: theoretical approach. *Remote Sensing of Environment*, 82(2-3), 188-197. [http://dx.doi.org/10.1016/S0034-4257\(02\)00037-8](http://dx.doi.org/10.1016/S0034-4257(02)00037-8).

- Chun, H., & Keles, S. (2010). Sparse partial least squares regression for simultaneous dimension reduction and variable selection. *Journal of the Royal Statistical Society. Series A, (Statistics in Society)*, 72(1), 3-25. PMID:20107611. <http://dx.doi.org/10.1111/j.1467-9868.2009.00723.x>.
- Chung, D., & Chun, H. (2015). *An introduction to the "spl" Package, Version 1.0*. Recuperado em 26 de novembro de 2022, de <http://cran.r-project.org/web/packages/spls/vignettes/spls-example.pdf>
- Chuvieco, E., Cocero, D., Riaño, D., Martín, P., Martínez-Vega, J., de la Riva, J., & Pérez, F. (2004). Combining NDVI and surface temperature for the estimation of live fuels moisture content in forest fire danger rating. *Remote Sensing of Environment*, 92(3), 322-331. <http://dx.doi.org/10.1016/j.rse.2004.01.019>.
- Croft, H., Chen, J. M., & Zhang, Y. (2014). The applicability of empirical vegetation indices for determining leaf chlorophyll content over different leaf and canopy structures. *Ecological Complexity*, 7, 119-130. <http://dx.doi.org/10.1016/j.ecocom.2013.11.005>.
- Datt, B. (1999). Remote sensing of water content in *Eucalyptus* leaves. *Australian Journal of Botany*, 7(6), 909-923. <http://dx.doi.org/10.1071/BT98042>.
- Fonseca, C. E. L., & Condé, R. C. C. (1994). Estimativa da área foliar em mudas de mangabeira (*Hancornia speciosa* Gom.). *Pesquisa Agropecuária Brasileira*, 29(4), 593-599.
- Gao, B. C. (1996). NDWI: a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257-266. [http://dx.doi.org/10.1016/S0034-4257\(96\)00067-3](http://dx.doi.org/10.1016/S0034-4257(96)00067-3).
- Hardisky, M. A., Klemas, V., & Smart, R. M. (1983). The influence of soil salinity, growth form, and leaf moisture on the spectral reflectance of *Spartina alterniflora* canopies. *Photogrammetric Engineering and Remote Sensing*, 49, 77-83.
- Hunt Jr, E. R., & Rock, B. N. (1989). Detection of changes in leaf water content using near and middle: infrared reflectance. *Remote Sensing of Environment*, 30(1), 43-54. [http://dx.doi.org/10.1016/0034-4257\(89\)90046-1](http://dx.doi.org/10.1016/0034-4257(89)90046-1).
- Imanishi, J., Sugimoto, K., & Morimoto, Y. (2004). Detecting drought status and LAI of two *Quercus* species canopies using derivative spectra. *Computers and Electronics in Agriculture*, 43(2), 109-129. <http://dx.doi.org/10.1016/j.compag.2003.12.001>.
- Lucena, R. R. M., de Vasconcelos Batista, T. M., Dombroski, J. L. D., Lopes, W. D. A. R., & de Oliveira Rodrigues, G. S. (2011). Medição de área foliar de aceroleira. *Revista Caatinga*, 24(2), 40-45.
- Mirzaie, M., Darvishzadeh, R., Shakiba, A., Matkan, A. A., Atzberger, C., & Skidmore, A. (2014). Comparative analysis of different uni- and multi-variate methods for estimation of vegetation water content using hyper-spectral measurements. *International Journal of Applied Earth Observation and Geoinformation*, 26, 1-11. <http://dx.doi.org/10.1016/j.jag.2013.04.004>.
- Mobasheri, M., & Fatemi, S. (2013). Leaf equivalent water thickness assessment using reflectance at optimum wave lengths. *Theoretical and Experimental Plant Physiology*, 25(1), 196-202. <http://dx.doi.org/10.1590/S2197-00252013005000001>.
- Oumar, Z., & Mutanga, O. (2010). Predicting plant water content in *Eucalyptus grandis* forest in Kwazulu-Natal, South Africa using field spectra resampled to the Sumbandila satellite sensor. *International Journal of Applied Earth Observation and Geoinformation*, 12(3), 158-164.
- Peñuelas, J., Filella, I., Biel, C., Serrano, L., & Save, R. (1993). The reflectance at the 950-970 nm region as an indicator water status. *International Journal of Remote Sensing*, 14(10), 1887-1895. <http://dx.doi.org/10.1080/01431169308954010>.
- Peñuelas, J., Filella, J., Serrano, L., & Savé, R. (1996). Cell wall elasticity and water index (R970 nm/R900 nm) in wheat under different nitrogen availabilities. *International Journal of Remote Sensing*, 17(2), 373-382. <http://dx.doi.org/10.1080/01431169608949012>.
- Peñuelas, J., Gamon, J. A., Fredeen, A. L., Merino, J., & Field, C. B. (1994). Reflectance indices associated with physiological changes in nitrogen and water limited sunflower leaves. *Remote Sensing of Environment*, 48(2), 135-146. [http://dx.doi.org/10.1016/0034-4257\(94\)90136-8](http://dx.doi.org/10.1016/0034-4257(94)90136-8).
- Peñuelas, J., & Inoue, Y. (1999). Reflectance indices indicative of changes in water and pigment contents of peanut and wheat leaves. *Photosynthetica*, 36(3), 355-360. <http://dx.doi.org/10.1023/A:1007033503276>.
- Peñuelas, J., Piñol, J., Ogaya, R., & Filella, J. (1997). Estimation of plant water concentration by the reflectance index WI (R900/R970). *International Journal of Remote Sensing*, 18(13), 2869-2875. <http://dx.doi.org/10.1080/014311697217396>.
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. (2012). *Sensoriamento remoto da vegetação* (2ª ed., 160 p.). São Paulo: Oficina de Textos.
- Ranjan, R., Sahoo, R. N., Chopra, U. K., Pramanik, M., Singh, A. K., & Pradhan, S. (2015). Assessment of water status in wheat (*Triticum aestivum* L.) using ground based hyperspectral reflectance. *Proceedings of the National Academy of Sciences. India. Section B, Biological Sciences*, 5(20), 1-12.

- Sayes, W., Mouazen, A. M., & Ramon, H. (2008). Potential for onsite and analysis of manure using visible and near infrared reflectance spectroscopy. *Biosystems Engineering*, 91(4), 393-402. <http://dx.doi.org/10.1016/j.biosystemseng.2005.05.001>.
- Seelig, H. D., Hoehn, A., Stodieck, L. S., Klaus, D. M., Adams 3rd, I. W. W., & Emery, W. J. (2008). Relations of remote sensing leaf water indices to leaf water thickness in cowpea, bean, and sugar beet plants. *Remote Sensing of Environment*, 112(2), 445-455. <http://dx.doi.org/10.1016/j.rse.2007.05.002>.
- Sellers, P. J., Dickinson, R. E., Randall, D. A., Betts, A. K., Hall, F. G., Berry, J. A., Collatz, G. J., Denning, A. S., Mooney, H. A., Nobre, C. A., Sato, N., Field, C. B., & Henderson-Sellers, A. (1997). Modeling the exchanges of energy, water, and carbon between continents and the atmosphere. *Science*, 275(5299), 502-509. PMID:8999789. <http://dx.doi.org/10.1126/science.275.5299.502>.
- Sims, D. A., & Gamon, J. A. (2002). Relationships between leaf pigment content and spectral reflectance across a wide range of species, leaf structures and developmental stages. *Remote Sensing of Environment*, 81(2-3), 337-354. [http://dx.doi.org/10.1016/S0034-4257\(02\)00010-X](http://dx.doi.org/10.1016/S0034-4257(02)00010-X).
- Summy, K. R., Lieman, J., Gandy, Y. P., Mamachen, A., Goolsby, J., & Moran, P. J. (2011). Effects of leaf excision and sample storage methods on spectral reflectance by foliage of giant reed, *Arundo donax*. *Yaredai Zhiwu Kexue*, 63, 54-64.
- Sun, P., Wahbi, S., Tsonev, T., Haworth, M., Liu, S., & Centritto, M. (2014). On the use of leaf spectral indices to assess water status and photosynthetic limitations in *Olea europaea* L. during waterstress and recovery. *PLoS One*, 10(3), e0118420. PMID:25136798.
- Szilagyi, J. (2000). Can a vegetation index derived from remote sensing be indicative of areal transpiration? *Ecological Modelling*, 127(1), 65-79. [http://dx.doi.org/10.1016/S0304-3800\(99\)00200-8](http://dx.doi.org/10.1016/S0304-3800(99)00200-8).
- Turner, N. C. (1981). Techniques and experimental approaches for the measurement of plant water status. *Plant and Soil*, 58(3), 339-366. <http://dx.doi.org/10.1007/BF02180062>.
- Vidal-Torrado, P., & Sparovek, G. (1993). *Mapa pedológico detalhado do Campus Luiz de Queiroz*. Piracicaba: ESALQ. Escala 1: 10000.
- Wang, J., Xu, Y., & Yang, S. (2009). Estimations of plant water content by spectral absorption features centered at 1450 nm and 1940 nm regions. *Environmental Monitoring and Assessment*, 157(1-4), 459-469. PMID:18853268. <http://dx.doi.org/10.1007/s10661-008-0548-3>.
- Wang, Q., & Li, P. (2012). Identification of robust hiperespectral indices on forest leaf water content using prospect simulated dataset and field reflectance measurements. *Hydrological Processes*, 26(8), 1230-1241. <http://dx.doi.org/10.1002/hyp.8221>.
- Yi, Q., Bao, A., Wang, Q., & Zhao, J. (2013). Estimation of leaf water content in cotton by means of hiperespectral indices. *Computers and Electronics in Agriculture*, 90, 144-151. <http://dx.doi.org/10.1016/j.compag.2012.09.011>.
- Zarco-Tejada, P. J., Rueda, C. A., & Ustin, S. L. (2003). Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*, 85(1), 109-124. [http://dx.doi.org/10.1016/S0034-4257\(02\)00197-9](http://dx.doi.org/10.1016/S0034-4257(02)00197-9).
- Zhang, F., & Zhou, G. (2015). Estimation of canopy water content by means of hyperspectral indices based on drought stress gradient experiments of maize in the north plain China. *Remote Sensing*, 7(11), 15203-15223. <http://dx.doi.org/10.3390/rs71115203>.
- Zhang, F., Zhou, G., Zhang, G., Meng, Y., Chen, B., & Wang, Y. (2014). Monitoring cotton (*Gossypium hirsutum* L.) leaf ion content and leaf water content in saline soil with hyperspectral reflectance. *European Journal of Remote Sensing*, 47(1), 593-610. <http://dx.doi.org/10.5721/EuJRS20144733>.
- Zhang, Q., Li, Q., & Zhang, G. (2012). Rapid determination of leaf water content using VIS/NIR spectroscopy analysis with wavelength selection. *Journal of Spectroscopy*, 27(2), 93-105. <http://dx.doi.org/10.1155/2012/276795>.

**Contribuição dos Autores:** TFS: Análise Formal, Metodologia, Investigação; PRF: Conceituação, Obtenção de Financiamento, Administração do Projeto, Supervisão; NCR: Escrita – Primeira Redação, Escrita – Revisão e Edição; CAA: Escrita – Primeira Redação, Escrita – Revisão e Edição; ACSL: Escrita – Primeira Redação, Escrita – Revisão e Edição; ESN: Escrita – Primeira Redação, Escrita – Revisão e Edição.