

ARTIGO ORIGINAL

Índices de vegetação para análise nutricional de *Eucalyptus saligna* Smith usando espectrorradiometria

Vegetation indices for nutritional analysis of *Eucalyptus saligna* Smith using spectroradiometry

Letícia Daiane Pedrali¹ , Juliana Marchesan¹ , Túlio Barroso Queiroz¹ , Elisiane Alba² , Rudiney Soares Pereira¹ , Mauro Valdir Schumacher¹ 

¹Universidade Federal de Santa Maria – UFSM, Santa Maria, RS, Brasil

²Universidade Federal Rural de Pernambuco – UFRPE, Serra Talhada, PE, Brasil

Como citar: Pedrali, L. D., Marchesan, J., Queiroz, T. B., Alba, E., Pereira, R. S., & Schumacher, M. V. (2022). Índices de vegetação para análise nutricional de *Eucalyptus saligna* Smith usando espectrorradiometria. *Scientia Forestalis*, 50, e3742. <https://doi.org/10.18671/scifor.v50.06>

Resumo

O estudo teve como objetivo explicar a associação entre macro e micronutrientes com índices de vegetação, determinando os comprimentos de onda de maior importância para cada nutriente. Além disso, sugerimos equações para descrever o status nutricional de povoamentos de *Eucalyptus saligna* Smith a partir da espectrorradiometria. A pesquisa foi realizada em um plantio localizado no município de Barra do Ribeiro, Rio Grande do Sul, com idade de 18 meses. Para a medição da reflectância foram utilizadas 12 amostras, que serviram também para a quantificação química dos macros e micronutrientes. A estimativa dos nutrientes foi realizada por regressão linear múltipla. Os resultados mostraram que as bandas do visível e da redEdge são mais sensíveis à discriminação de nutrientes, destacando o Mn, P, Ca e S. Na modelagem dos macronutrientes, a estimativa do N, Ca, e S obtiveram melhores ajustes, enquanto que, no grupo de micronutrientes os melhores ajustes foram para o Zn, seguido do Cu e do Mn. Assim, este estudo demonstrou a eficácia da espectrorradiometria para análise de nutrientes na vegetação, a qual pode ser utilizada de forma prática e rápida para diagnosticar o estado nutricional do eucalipto.

Palavras-chave: Características de absorção; Discriminação espectral; Sensoriamento remoto.

Abstract

This study aimed to explain the association between macro- and micro-nutrients with vegetation indices and to determine the most important wavelengths for each nutrient. In addition, equations capable of describing the nutritional status of *Eucalyptus saligna* Smith stands based on spectral radiometric data were suggested. The research was carried out in an 18-month-old plantation located in Barra do Ribeiro, Rio Grande do Sul State, Brazil. For the reflectance measurement 12 samples were used, which also served for the chemical quantification of macro and micronutrients. Nutrients were estimated by using multiple linear regression. The results showed that the visible and red-edge regions are more sensitive for discriminating nutrients in plants, mainly Mn, P, Ca, and S. In the macronutrient modeling, the estimation of N, Ca, and S, yielded the best adjustments, while in the micronutrient group the best adjustments were yielded by Zn, Cu, and Mn. Thus, the present study demonstrated the effectiveness of spectral radiometry to analyze nutrients in vegetation, which can be used in a fast and practical way to diagnose the nutritional status of eucalyptus.

Keywords: Absorption features; Spectral discrimination; Remote sensing.

Fonte de financiamento: Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Conflito de interesse: Nada a declarar.

Autor correspondente: lepedrali@yahoo.com.br

Recebido: 29 junho 2021.

Aceito: 01 fevereiro 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.

1. INTRODUÇÃO

O Brasil, seguido por China, Sudoeste da Ásia e Moçambique ocupam os primeiros lugares no ranking mundial de maior produtividade média e menor rotação no cultivo do eucalipto (Indústria Brasileira de Árvores, 2019). Apesar do Brasil recuar 2,14% de área plantada em relação ao ano 2019 (9,69 milhões de hectares) e ocupar 7,47 milhões de hectares em 2020, ele ainda lidera a produtividade média mundial com $38,6 \text{ m}^3 \text{ ha}^{-1} \text{ ano}^{-1}$ (Indústria Brasileira de Árvores, 2021). Cenários como esse motivam a constante revisão das práticas de manejo, melhoramento genético e constante acompanhamento das mudanças climáticas e nutrição das plantas a fim de manter a qualidade das florestas e o reconhecimento mundial da alta produtividade brasileira, em comparação com os demais países. O acompanhamento nutricional das plantas consiste em um dos fatores de produção de maior potencial de manejo, permitindo manter a capacidade produtiva dos sítios florestais, devido à utilização regulada de insumos industrializados e resíduos que podem ser utilizados na fertilização e correção do solo (Witschoreck & Schumacher, 2015). Este processo tem sido realizado por décadas através da análise do status nutricional de plantas, que usualmente é realizado por métodos destrutivos seguidos de análise química do tecido foliar em diferentes estágios de desenvolvimento da planta. Contudo, a tecnologia tem impulsionado o desenvolvimento de sensores de alta performance e rápida resposta, para o diagnóstico nutricional (Romualdo et al., 2014), como, por exemplo, técnicas de sensoriamento remoto que permitem de forma rápida e eficaz uma análise indireta do tecido vegetal através das características espectrais das folhas (Gökkaya et al., 2015; Oliveira et al., 2017; Peng et al., 2020).

A refletância espectral consiste na razão entre o fluxo radiante refletido e incidente de um objeto, sua resposta independentemente da localização, iluminação, tempo, condições atmosféricas e meteorológicas (Peddle et al., 2001). No entanto, quando se trata de espécies vegetais, o comportamento espectral é reflexo da fisiologia da planta frente às adversidades locais (Zhang et al., 2017). Então, a partir da década de 1960, intensificou-se a utilização dessa tecnologia com aplicação em propriedades óticas foliares (Meroni & Colombo, 2006). A alta correlação entre o comportamento espectral de alvos com aspectos fisiológicos no rendimento e teor de proteínas das plantas têm permitido prever o estado nutricional de uma cultura (Sharabian et al., 2014), o teor de água (González et al., 2016), a distinção de espécies (Pedrali et al., 2016), entre outros. Informações como essas, possibilitam relacionar as propriedades biofísicas e bioquímicas (teor de pigmentos, estrutura da célula e teor de água) com a refletância da folha em comprimentos de ondas específicos (Slaton et al., 2001).

Na silvicultura de precisão, o desenvolvimento de mapas de produtividade e de fatores de produção para descrever a fertilidade, apesar de ser dispendiosa, é indispensável para o manejo florestal (Maeda et al., 2014). Por esse motivo, implementar técnicas de silvicultura de precisão pode ser o melhor caminho para descrever a volatilidade da produção e detectar características multiespectrais que tradicionalmente não são detectadas pelo sensoriamento remoto (Zhu et al., 2013). Neste cenário, instrumentos hiperespectrais podem ser usados principalmente em análises exploratórias com o objetivo de projetar radiômetros mais simples em comprimentos de onda distintos para cada condição (Thorp et al., 2017). As técnicas de processamento de dados hiperespectrais auxiliam na descrição de características intrínsecas, como, por exemplo, a composição físico-química do alvo.

Dados hiperespectrais podem ser obtidos por meio de espectrorradiômetros de campo, conhecidos como sensores proximais. Estes sensores permitem medir a resposta espectral de um alvo com baixa interferência radiométrica e devido sua proximidade com a folha, permitem obter dados com alta resolução (Osco et al., 2020). Estudos como estes são essenciais para obter resultados satisfatórios para a modelagem de fenômenos a nível de folha (Peng et al., 2020), uma vez que, permite definir as regiões espectrais apropriadas para estimar esses fenômenos (Osco et al., 2020) auxiliar no desenvolvimento de índices de vegetação e exploram as propriedades espectrais (Oliveira et al., 2019) que podem ser uma alternativa eficaz para análise nutricional de plantas (Osco et al., 2020).

O conhecimento do comportamento espectral de plantações florestais e a relação com os índices de vegetação esclarecem dúvidas sobre o diagnóstico nutricional do eucalipto, permitindo obter resultados de forma rápida e eficaz de maneira não destrutiva. Com base nisso, o objetivo deste estudo foi explicar a associação entre macro e micronutrientes com os índices de vegetação, determinando os comprimentos de onda de maior importância para cada nutriente. Além disso, foram sugeridas acuradas equações capazes de descrever o status nutricional de povoamentos de *Eucalyptus saligna* a partir da espectrorradiometria.

2. MATERIAL E MÉTODOS

2.1 Área de estudo e caracterização do povoamento

Os ensaios em campo foram conduzidos no Horto Florestal Barba Negra, em Barra do Ribeiro no Estado do Rio Grande do Sul, Brasil, entre as coordenadas 30°24'34,81" S e 51°13'17,62" O. A área experimental contou com 12 parcelas de 900 m² (30 m x 30 m). Em cada parcela foram plantadas 96 mudas de *Eucalyptus saligna* no espaçamento 3 m x 3 m, com 2 linhas correspondente à bordadura dupla.

O relevo do município é classificado como Planície Costeira Gaúcha (Instituto Brasileiro de Geografia e Estatística, 2006) e o clima, segundo a classificação de Köppen é do tipo o Cfa, clima subtropical úmido (Alvares et al., 2013). As árvores foram avaliadas aos 18 meses de idade, por meio de medições do diâmetro à altura de 1,3 m do solo (DAP) e altura total (HT), com uso de fita métrica e hipsômetro Forestor Vertex®, respectivamente. Quatro classes diamétricas foram usadas para selecionar o diâmetro médio da parcela, conforme apresentado na Tabela 1. Adicionalmente, foram selecionadas quatro folhas totalmente expandidas para as medições de reflectância que totalizaram 144 amostras. Na idade estudada, o povoamento apresentou diâmetros entre 5,12 cm e 9,86 cm com alturas entre 7,20 m e 9,02 m. O volume médio foi correspondente a 0,2529 m³ árvore⁻¹ (±0,0608).

Tabela 1 – Caracterização dendrométrica do povoamento de *Eucalyptus saligna* aos 18 meses em Barra do Ribeiro – RS

Classe Diamétrica	DAP (cm)*	HT (m)*	Volume (m ³ . árvore ⁻¹)*
5,12 † 6,31	5,65 ± 0,29	7,20 ± 1,20	0,0991 ± 0,0235
6,31 † 7,49	6,70 ± 0,22	7,39 ± 0,75	0,1417 ± 0,0173
7,49 † 8,68	7,85 ± 0,48	8,18 ± 0,65	0,2167 ± 0,0369
8,68 † 9,86	8,75 ± 0,46	8,68 ± 0,67	0,2853 ± 0,0444

*Valores médios por classe diamétrica seguidos do símbolo (±) que separa do desvio padrão

2.2 Espectrorradiometria

As medições de reflectância (350 e 2500 nm) em folhas de 4 classes diamétricas de *Eucalyptus saligna* foram feitas usando um FieldSpec®3, modelo RST 3ZC (Analytical Spectral Devices, Inc., EUA) que conectado à esfera integradora contou com iluminação com incidência ortogonal em mesma intensidade para todas as amostras, a fim de, eliminar interferências do ambiente e permitir resultados precisos e significativos (Quitério et al., 2007). A calibração foi realizada por meio de uma placa de referência padrão antes da medição do valor da reflectância em cada ponto amostral.

As leituras foram realizadas entre 11 h e 13 h, imediatamente após a coleta das folhas. Cada folha foi posicionada no orifício da esfera (espectrorradiômetro), com face ventral voltada para o interior da esfera. Foram selecionadas 12 árvores para medição da reflectância. Para tal, foram obtidas oito medidas de reflectância espectral de folhas do dossel de cada árvore, sendo realizada duas medições nos sentidos norte, sul, leste e oeste nas árvores selecionadas.

Os dados de reflectância foram pré-processados para remover ruídos e garantir estabilidade no comportamento espectral. Os dados no infravermelho de ondas curtas (SWIR) foram eliminados devido à baixa relação sinal-ruído. Para estimativa do teor de macro e micronutrientes, em condições de plantio, foram calculados vinte e quatro índices de vegetação, descritos na Tabela 2.

Tabela 2 – Índices de vegetação utilizados na análise espectral de *Eucalyptus saligna* aos 18 meses de idade em Barra do Ribeiro-RS

	Descrição	Equação
1	Chlorophyll Red-Edge (Chlred-edge)	$\text{Chlred-edge} = \left(\frac{760:800}{690:720} \right)^{-1}$
2	LAI determining index	$\text{LAIDI} = \frac{1250}{1050}$
3	Difference LAI	$\text{DLAI} = \frac{1725}{970}$
4	Disease water stress index	$\text{DSWI} = \frac{802+547}{1657+682}$
5	Leaf Chlorophyll Index	$\text{LCI} = \frac{(850 - 710)}{(850 - 680)}$
6	Mid-infrared vegetation index	$\text{MVI} = \frac{(700:1300)}{(1570:1780)}$
7	Modified Chlorophyll Absorption in Reflectance Index	$\text{MCARI} = ((700-670) - 0,2(700-550)) * \frac{700}{670}$
8	Modified Chlorophyll Absorption in Reflectance Index 1	$\text{MCARI1} = 1,2(2,5(800-670) - 1,3(800-550))$
9	Modified Simple Ratio	$\text{mSR} = \frac{800 - 445}{680 - 445}$
10	Modified Triangular Vegetation Index 1	$\text{MTVI1} = 1,2(1,2(800 - 550) - 2,5(670 - 550))$
11	Normalized Difference leaf canopy biomass	$\text{NDBleaf} = \frac{2160 - 1540}{2160 + 1540}$
12	Plant pigment ratio	$\text{PPR} = \frac{550 - 450}{550 + 450}$
13	Physiological reflectance index	$\text{PRI550/530} = \frac{550-530}{550+530}$
14	Normalized Difference 550/531	$\text{ND550/531} = \frac{550-531}{550+531}$
15	Photosynthetic vigour ratio	$\text{PVR} = \frac{550-650}{550+650}$
16	Normalized Pigment Chlorophyll	$\text{NPCI} = \frac{680-430}{680+430}$
17	Green NDVI	$\text{NDVIg} = \frac{750-550}{750+550}$
18	Red Edge NDVI	$\text{reNDVI} = \frac{750-710}{750+710}$
19	Normalized difference red edge index	$\text{NDRE} = \frac{790-720}{790+720}$
20	Normalized Difference Moisture Index	$\text{NDMI} = \frac{820-1600}{820+1600}$
21	Plant Senescence Reflectance Index	$\text{PSRI} = \frac{678-500}{750}$
22	Red-Edge Stress Vegetation Index	$\text{RVSI} = \frac{718+748}{2} - 733$
23	Moisture Stress Index	$\text{MSI} = \frac{1600}{820}$
24	Simple Ratio 1260/1450	$\text{SR1260/1450} = \frac{1260}{1450}$

2.3 Análise nutricional

Para a análise química do tecido foliar foram utilizadas 12 amostras derivadas das mesmas folhas coletadas para as medições com o espectrorradiômetro. A análise nutricional foi realizada no Laboratório de Ecologia Florestal da Universidade Federal de Santa Maria, quantificando os

macronutrientes: Nitrogênio (N), Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg) e Enxofre (S) e micronutrientes: Boro (B), Cobre (Cu), Ferro (Fe), Manganês (Mn) e Zinco (Zn).

2.4 Análise estatística

Todas as análises estatísticas foram feitas com o auxílio do *software* livre R Project, versão 3.5.3. O teor médio de nutrientes e os comprimentos de onda foram submetidos à análise de correlação de Pearson com, a fim de identificar quais as regiões do espectro eletromagnético melhor se correlacionam com os parâmetros florestais em análise.

Foi elaborado um correlograma, o qual descreve, na abscissa, o comportamento dos nutrientes em cada comprimento de onda e os coeficientes de correlação na ordenada. As curvas de correlação foram suavizadas por meio da técnica de média móvel. Além disso, os nutrientes que obtiveram maior correlação nos respectivos comprimentos de onda foram utilizados no ajuste de equações para prever o status nutricional.

A estimativa dos parâmetros biofísicos foi realizada por meio de regressão linear múltipla. Buscou-se modelos de predição para as onze variáveis dependentes, referentes aos macros e micronutrientes, enquanto as variáveis independentes dos modelos foram compostas pelas faixas do visível, infravermelho próximo e infravermelho médio, bem como os índices de vegetação elaborados. A escolha do melhor modelo de predição para cada nutriente foi a partir do erro padrão da estimativa (Sy_x), coeficiente de determinação ajustado (R^2_{aj}) e análise de dispersão dos resíduos.

3. RESULTADOS E DISCUSSÃO

O povoamento florestal composto por *Eucalyptus saligna* aos 18 meses de idade apresentou um padrão espectral com picos de reflectância na faixa do verde (550 – 650 nm) e no infravermelho (700 – 1000 nm) (Figura 1). Segundo Ponzoni et al. (2012), uma folha verde sadia pode ser descrita principalmente pelos comprimentos de onda dessa região (720 – 1100 nm) e da região do visível (400 – 720 nm). Desse modo, a reflexão de uma folha jovem na região do visível é determinada pelos pigmentos foliares, especialmente pela presença de clorofila α e β (Novo, 2010).

Entretanto, na região do infravermelho próximo a vegetação reflete aproximadamente 50% da energia incidente, sendo que 45 a 50% representam transmitância e menos de 5% absorvância (Swain & Davis, 1978). Além disso, maior reflectância se deve à interferência da estrutura celular do mesófilo (Ponzoni et al., 2012). Assim, o comportamento espectral observado para o povoamento florestal está de acordo com a literatura.

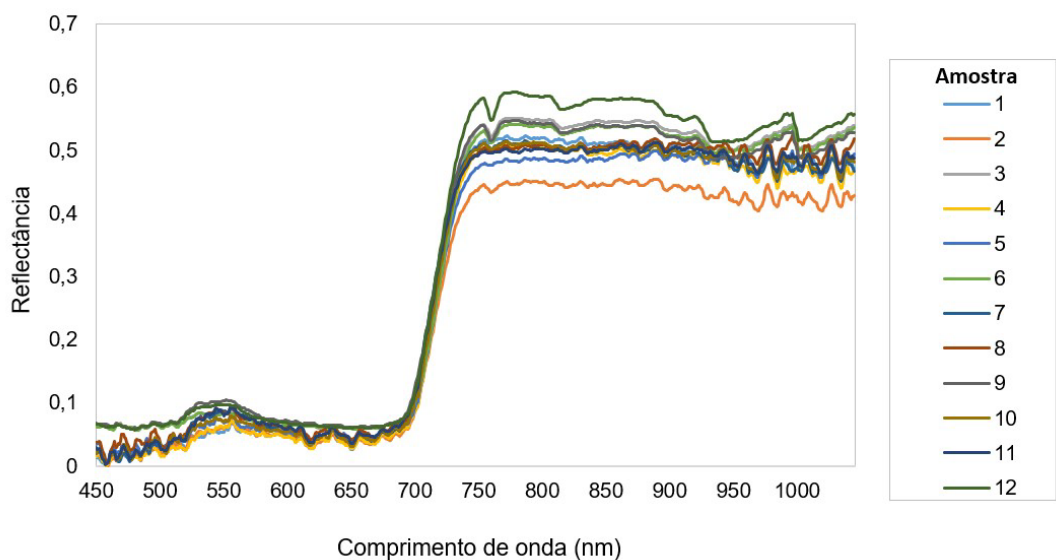


Figura 1 – Comportamento espectral das amostras obtidas de povoamentos de *Eucalyptus saligna* aos 18 meses de idade.

Os resultados da análise nutricional são expostos na Tabela 3.

Tabela 3 – Teor de nutrientes em *Eucalyptus saligna* aos 18 meses de idade cultivados em Barra do Ribeiro – RS

Macronutriente	Média	Desvio Padrão	Variância	Mínimo	Máximo
g kg⁻¹					
N	19,89	3,34	11,16	14,57	25,83
P	1,21	0,14	0,02	0,99	1,43
K	9,76	0,59	0,35	8,47	10,59
Ca	10,41	0,90	0,80	9,30	12,47
Mg	2,57	0,25	0,06	1,98	2,93
S	0,94	0,17	0,03	0,68	1,22
Micronutriente	Média	Desvio Padrão	Variância	Mínimo	Máximo
mg kg⁻¹					
B	40,24	8,19	67,11	27,56	55,12
Cu	5,71	0,63	0,40	4,83	6,55
Fe	85,19	8,55	73,05	73,72	99,87
Mn	886,80	135,90	18467,84	596,70	1098,67
Zn	10,56	1,80	3,25	7,79	13,29

O Mn apresentou a maior variação entre os dados observados, expressando um desvio padrão de 135,90 mg kg⁻¹ (Tabela 3). Por outro lado, o P apresentou menor variação na amostragem nutricional tradicional, comum desvio padrão de 0,14 g kg⁻¹. Essa variabilidade entre as amostras é resposta à fisiologia vegetal, devido a mobilidade do nutriente na planta. O Mn apresenta ligações fracas com os ligantes orgânicos, sendo facilmente oxidado (Kirkby & Römheld, 2007), o que explica sua alta variabilidade. Tal fato deve-se, principalmente, à ciclagem bioquímica que desloca parte dos nutrientes dos tecidos foliares para as outras partes da planta durante o processo de senescência.

A relação entre os nutrientes da planta e os dados espectrais pode ser melhor visualizada por meio do correlograma (Figura 2), o qual foi desenvolvido considerando os comprimentos de onda de 450 a 1.000 nm. Observou-se que as maiores correlações estão presentes na região do visível e na faixa RedEdge (690-730 nm), sendo pouco representativo na região do infravermelho. Na região do visível os nutrientes que obtiveram maior correlação com os comprimentos de onda foram o Mn ($r = 0,80$) em 562 nm (comprimento de onda do verde) e o P ($r = 0,71$) em 649 nm (comprimento de onda do vermelho). Na faixa RedEdge destacou-se o Mn ($r = 0,81$) em 718 nm, o Ca ($r = 0,70$) em 720 nm e S ($r = 0,81$) em 724 nm.

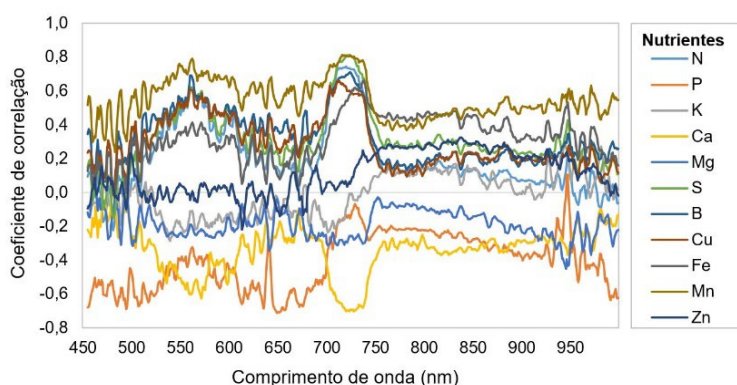


Figura 2 – Correlograma entre os valores de reflectância na região do visível e do infravermelho e as concentrações de nutrientes nas folhas de *Eucalyptus saligna*

Conforme os valores de correlação apresentados acima, notou-se que as faixas do visível e do RedEdge foram mais sensíveis para discriminação dos nutrientes no *Eucalyptus saligna*, uma vez que, apresentaram maiores correlações com os nutrientes estudados. Na região do visível, a maior reflectância ocorre na região do verde, devido, principalmente, à presença de clorofila (Ponzoni et al., 2012). A faixa do RedEdge, por sua vez, coincide com o aumento brusco de reflectância da vegetação verde na faixa de transição entre o vermelho e o infravermelho próximo (Schuster et al., 2012). Portanto, devido à maior reflectância, os comprimentos de onda abrangentes na faixa do verde e do

RedEdge são sensíveis para discriminar diferentes nutrientes em plantas (Hatfield et al., 2008; Yu et al., 2014; Oliveira et al., 2017; Oliveira & Santana, 2020; Martins, et al., 2021).

A relação dos nutrientes com os índices de vegetação pode ser visualizada na Figura 3. Dentre os macronutrientes estudados, o N e o P foram os que apresentaram maior correlação ($\geq 0,7$). Enquanto os índices de vegetação reNDVI, CHLRED-EDE, DSWI e MCARI1 apresentaram maiores valores de correlação para o N, o índice ND apresentou maior correlação com o P (Figura 3A). Neste caso, observa-se que os índices de vegetação relacionados à borda do vermelho possibilitaram obter maior correlação com o N. Conforme Abrahão et al. (2009) os melhores índices de vegetação utilizados para discriminar os teores de N são aqueles resistente à atmosfera na região do visível, sendo, portanto, utilizado a banda de transição do vermelho ao infravermelho próximo. Da mesma forma, Oliveira et al. (2017) destacaram que os índices de vegetação que utilizam a região da borda do vermelho fornecem estimativas mais precisas do nitrogênio foliar.

Os macronutrientes K e Mg, por sua vez, obtiveram as menores correlações com os índices de vegetação. Gökkaya et al. (2015) ao modelarem nutrientes no nível de dossel em floresta do Canadá utilizando dados hiperespectrais também observaram inferior qualidade no ajuste dos modelos para K. Por outro lado, ao analisar a correlação entre os micronutrientes e dados espectrais (Figura 3B), observou-se que os índices de vegetação CHLRED-EDE e MCARI1 obtiveram maior correlação com o Cu e Mn, respectivamente.

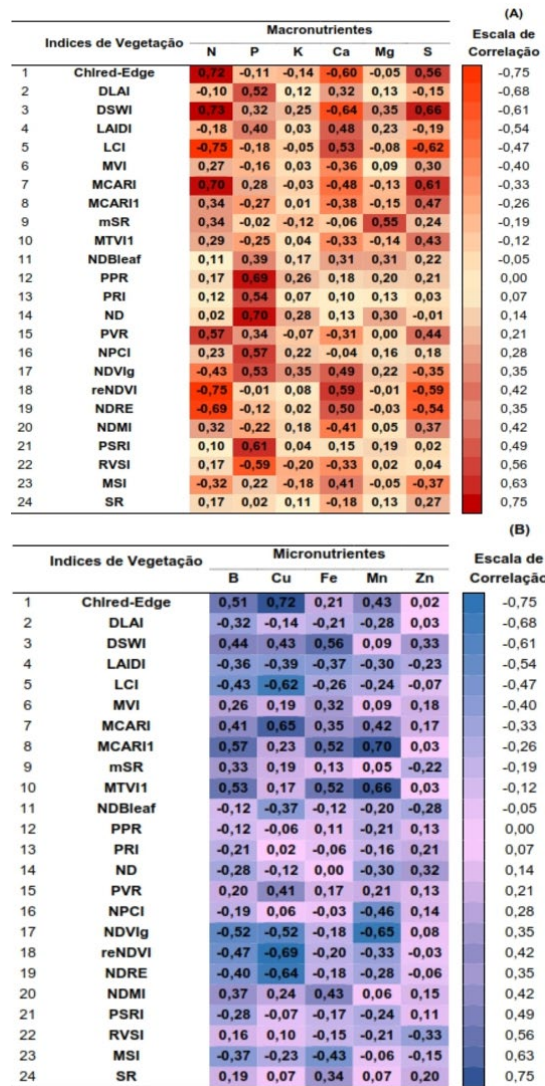


Figura 3 – Correlação entre os Índices de vegetação com os macronutrientes (A) e micronutrientes (B) em *Eucalyptus saligna* aos 18 meses de idade

Nossos resultados demonstraram que aceitáveis estimativas para o status nutricional dos macros e micronutrientes podem ser encontrados por meio dos índices de vegetação (Tabela 4). O limite de decisão foi estabelecido pelo teste F, que significativamente foi maior que 1.

Dentre os macronutrientes, as melhores estimativas foram obtidas para o N ($R^2_{aj} = 0,83$ e $S_{yx} = 1,390 \text{ g kg}^{-1}$), seguido do Ca ($R^2_{aj} = 0,78$ e $S_{yx} = 0,420 \text{ g kg}^{-1}$) e do S ($R^2_{aj} = 0,76$ e $S_{yx} = 0,086 \text{ g kg}^{-1}$), enquanto que para estimativa do Mg e o P os modelos tendem a ser inferiores aos demais ajustes, o K não respondeu a modelagem. Do mesmo modo, Gökkaya et al. (2015) obtiveram resultados positivos para o N (R^2 de 0,91) e negativos o P (R^2 de 0,31), ao analisarem modelos aplicados aos nutrientes no dossel de uma floresta Boreal de Mixedwood a partir de dados hiperespectrais. No entanto, os micronutrientes, obtiveram equações com melhores ajustes entre os dados observados e estimados para o Zn ($R^2_{aj} = 0,91$ e $S_{yx} = 0,546 \text{ g kg}^{-1}$), seguido do Cu ($R^2_{aj} = 0,85$ e $S_{yx} = 0,244 \text{ g kg}^{-1}$) e do Mn ($R^2_{aj} = 0,84$ e $S_{yx} = 54,110 \text{ g kg}^{-1}$).

Tabela 4 - Modelagem para estimativa de macronutrientes e micronutrientes a partir de índices de vegetação

Macro-nutrientes	Modelo de regressão	Syx (g kg ⁻¹)	R ² aj	F
N	$N = 413,5 + 52,9 \cdot \text{MCARI} - 31,3 \cdot \text{PVR} - 515,85 \cdot \text{reNDVI} - 625,5 \cdot \text{chlred-edge}$	1,390	0,83	14,15
P	$P = 4,59 + 1,84 \cdot \text{PPR} - 10,08 \cdot \text{MCARI} - 5,27 \cdot \text{NDBleaf} - 4,71 \cdot \text{PRI} - 6,37 \cdot \text{NDVIg} + 13,75 \cdot \text{PSRI}$	0,088	0,63	4,19
K	Não respondeu à modelagem			
Ca	$Ca = -111,4 + 100,25 \cdot \text{reNDVI} + 39,68 \cdot \text{LAIDI} + 132,27 \cdot \text{chlred-edge}$	0,420	0,78	14,09
Mg	$Mg = -1,7 + 4,89 \cdot \text{DSWI} + 1,03 \cdot \text{mSR} + 1,84 \cdot \text{NDBleaf} + 4,52 \cdot \text{NDRE} - 1,77 \cdot \text{NDMI}$	0,150	0,60	4,35
S	$S = 8,88 - 16,08 \cdot \text{LCI} + 1,57 \cdot \text{MTVI1} - 1,99 \cdot \text{PVR} + 11,46 \cdot \text{NDRE}$	0,086	0,76	9,60
Micro-nutrientes	Modelo de regressão	Syx (mg kg ⁻¹)	R ² aj	F
B	$B = 28,68 + 97,03 \cdot \text{MTVI1} - 115,76 \cdot \text{reNDVI}$	6,185	0,43	5,15
Cu	$Cu = -13,52 - 10,55 \cdot \text{NDBleaf} + 66,38 \cdot \text{reNDVI} - 91,93 \cdot \text{NDRE} + 43,54 \cdot \text{NDMI}$	0,244	0,85	16,63
Fe	$Fe = 247,74 - 379,3 \cdot \text{MVI} + 118,40 \cdot \text{MTVI1} + 1390,32 \cdot \text{NDMI}$	6,413	0,43	3,85
Mn	$Mn = -974,13 + 8186,42 \cdot \text{MCARI} - 383,49 \cdot \text{NPCL} + 2995,42 \cdot \text{reNDVI}$	54,110	0,84	20,46
Zn	$Zn = 0,0533 - 0,0036 \cdot \text{mSR} - 0,221 \cdot \text{NDBleaf} + 0,33 \cdot \text{ND} + 6,34 \cdot \text{NPCL} + 0,056 \cdot \text{reNDVI} + 0,087 \cdot \text{Chlred-Edge} + 0,687 \cdot \text{NDMI}$	0,546	0,91	16,59

Syx (g kg⁻¹) erro padrão da estimativa; **R²aj** - coeficiente de determinação ajustado; **F** - Teste F

A relação entre os valores ajustados e residuais são apresentados na Figura 4. Observou-se um comportamento similar entre os valores estimados pelos dados espectrais e os nutrientes mensurados nas folhas de *Eucalyptus saligna*. As estimativas que seguiram homogeneidade na dispersão da variância foram para o P, Ca, S, e Cu, logo, eles respeitam o postulado da homocedasticidade. Por outro lado, a forte dispersão dos dados em função da reta com tendências de heterocedasticidade foram observados para o N, Mg, B, Fe, Mn e Zn.

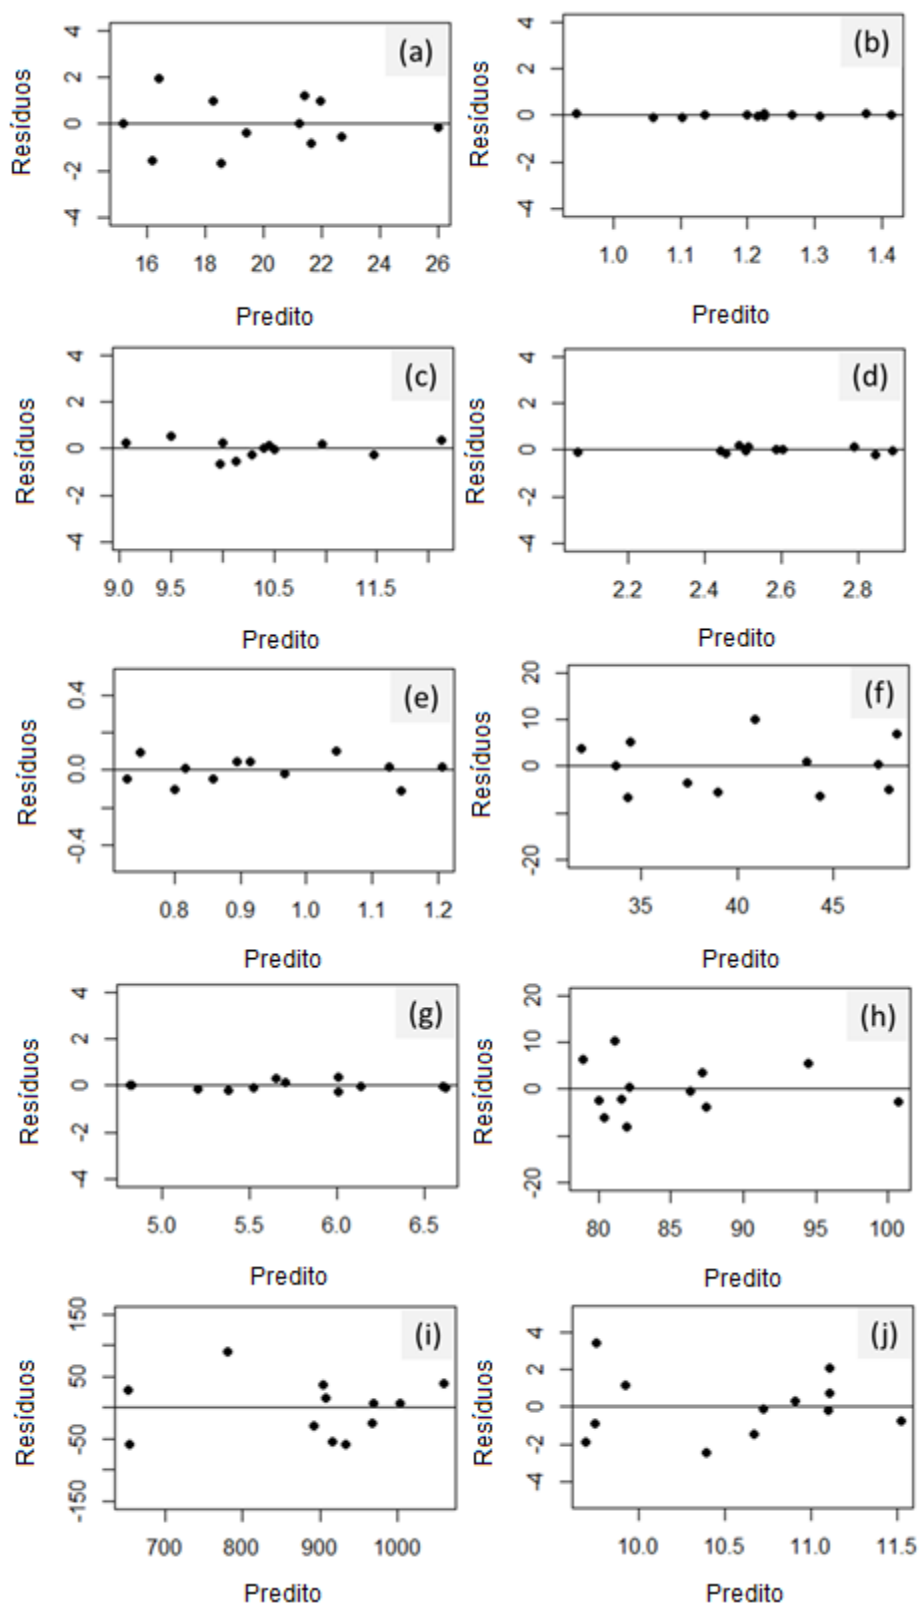


Figura 4 – Gráfico de resíduos dos modelos selecionados para os macronutrientes: N (a), P (b), Ca (c), Mg (d), S (e); e micronutrientes: B (f), Cu (g), Fe (h), Mn (i) e Zn (j)

4. CONCLUSÃO

A espectrorradiometria consiste em uma promissora ferramenta para a discriminação do status nutricional da maioria dos nutrientes presentes nas folhas de *Eucalyptus saligna*. Ao longo do espectro eletromagnético, as faixas mais correlacionadas foram a do visível e da redEdge, as quais

apresentaram alta correlação com a maior parte dos macros e micronutrientes. Além disso, índices de vegetação apresentaram altas correlações com N e P do grupo de macronutrientes, enquanto o Cu e Mg foram os micronutrientes que se destacaram, ambos com correlação superior a 0,70.

A modelagem dos macros e micronutrientes com base nos dados de espectrorradiometria se mostrou eficaz, visto que os modelos preditivos descrevem grande parte da variabilidade das informações nutricionais da folhagem do eucalipto. Entretanto, o K não respondeu à modelagem, sendo necessários outros estudos sobre as técnicas de predição com dados espectrais.

Por fim, nós evidenciamos a relação entre a reflectância e os nutrientes presentes nas folhas e sugerimos o uso de variáveis explicativas, não apenas as faixas espectrais, mas também os índices de vegetação.

AGRADECIMENTOS

À Celulose Riograndese (CMPC) pelo apoio para o desenvolvimento deste estudo. O presente estudo foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abrahão, S. A., Pinto, F., Queiroz, D. M., Santos, N. T., Gleriani, J. M., & Alves, E. A. (2009). Índices de vegetação de base espectral para discriminar doses de nitrogênio em Capim-Tanzânia. *Revista Brasileira de Zootecnia*, 38(9), 1637-1644. <http://dx.doi.org/10.1590/S1516-35982009000900001>.
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., Gonçalves, L. de M., & Sparovek, G. (2013). Koppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711-728. <http://dx.doi.org/10.1127/0941-2948/2013/0507>.
- Gökkaya, K., Thomas, V., Noland, T. L., Mccaughey, H., Morrison, I., & Treitz, P. (2015). Prediction of macronutrients at the canopy level using space-borne imaging spectroscopy and LiDAR data in a mixed wood boreal forest. *Remote Sensing*, 7(7), 9045-9069. <http://dx.doi.org/10.3390/rs70709045>.
- González, M., Minuesa, C., & Del Puerto, I. (2016). Maximum likelihood estimation and expectation-maximization algorithm for controlled branching processes. *Computational Statistics & Data Analysis*, 93, 209-227. <http://dx.doi.org/10.1016/j.csda.2015.01.015>.
- Hatfield, J. L., Gitelson, A. A., Schepers, J. S., & Walthall, C. L. (2008). Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*, 100(S3), 117-131. <http://dx.doi.org/10.2134/agronj2006.0370c>.
- Indústria Brasileira de Árvores – IBÁ. (2019). *Relatório 2019*. Recuperado em 5 de dezembro de 2020, de <https://iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>
- Indústria Brasileira de Árvores – IBÁ. (2021). *Relatório 2021*. Recuperado em 29 de dezembro de 2020, de <https://iba.org/datafiles/publicacoes/relatorios/relatorioiba2021-compactado.pdf>
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2006). *Mapa de relevo do Brasil*. Recuperado em 5 de junho de 2019, de ftp://geoftp.ibge.gov.br/informacoes_ambientais/geomorfologia/mapas/brasil/relevo_2006.pdf
- Kirkby, E. A., & Römheld, V. (2007). *Micronutrientes na fisiologia de plantas: funções, absorção e mobilidade* (Encartes Técnicos - Informações Agronômicas, No. 118). Recuperado em 10 de dezembro de 2019, de [http://www.ipni.net/publication/ia-brasil.nsf/0/8A79657EA91F52F483257AA10060FACB/\\$FILE/Encarte-118.pdf](http://www.ipni.net/publication/ia-brasil.nsf/0/8A79657EA91F52F483257AA10060FACB/$FILE/Encarte-118.pdf)
- Maeda, S., Ahrens, S., Chiarello, S. R., Oliveira, E. B., Stolle, L., Fowler, J. A. P., & Bognola, I. A. (2014). Silvicultura de precisão. In A. Bernardi, J. Naime, A. Resende, L. Bassoi & R. Inamasu (Eds.), *Agricultura de precisão: resultados de um novo olhar* (596 p.). Brasília: Embrapa.
- Martins, J. A., Fiorio, P. R., Barros, P. P. S., Demattê, J. A. M., Molin, J. P., Cantarella, H., & Neale, C. M. U. (2021). Potential use of hyperspectral data to monitor sugarcane nitrogen status. *Acta Scientiarum Agronomy*, 43, e47632. <http://dx.doi.org/10.4025/actasciagron.v43i1.47632>.
- Meroni, M., & Colombo, R. (2006). Leaf level detection of solar induced chlorophyll fluorescence by means of a subnanometer resolution spectroradiometer. *Remote Sensing of Environment*, 104(4), 438-448. <http://dx.doi.org/10.1016/j.rse.2006.03.016>.
- Novo, E. M. L. M. (2010). *Sensoriamento remoto: princípios e aplicações* (4. ed., 387 p.). São Paulo: Blucher.

- Oliveira, L. F. R., & Santana, R. C. (2020). Estimation of leaf nutrient concentration from hyperspectral reflectance in *Eucalyptus* using partial least squares regression. *Scientia Agrícola*, 77(6), e20180409. <http://dx.doi.org/10.1590/1678-992x-2018-0409>.
- Oliveira, L. F. R., Oliveira, M. L. R., Gomes, F. S., & Santana, R. C. (2017). Estimating foliar nitrogen in *Eucalyptus* using vegetation indexes. *Scientia Agrícola*, 74(2), 142-147. <http://dx.doi.org/10.1590/1678-992x-2015-0477>.
- Oliveira, T. F., Pinto, F. A. C., & Silva, D. J. H. (2019). Spectral vegetation indexes applied to nitrogen sufficiency index: A strategy with potential to increase nitrogen use efficiency on tomato crop. *Engenharia Agrícola*, 39(1), 118-126. <http://dx.doi.org/10.1590/1809-4430-eng.agric.v39n1p118-126/2019>.
- Osco, L. P., Ramos, A. P. M., Fanta Pinheiro, M. M., Moriya, É. A. S., Imai, N. N., Estrabis, N., Ianczyk, F., Araújo, F. F., Liesenberg, V., Jorge, L. A. C., Li, J., Ma, L., Gonçalves, W. N., Marcato Junior, J., & Eduardo Creste, J. (2020). Machine learning framework to predict nutrient content in valencia-orange leaf hyperspectral measurements. *Remote Sensing*, 12(6), 1-21. <http://dx.doi.org/10.3390/rs12060906>.
- Peddle, D. R., Peter White, H., Soffer, R. J., Miller, J. R., & LeDrew, E. F. (2001). Reflectance processing of remote sensing spectroradiometer data. *Computers & Geosciences*, 27(2), 203-213. [http://dx.doi.org/10.1016/S0098-3004\(00\)00096-0](http://dx.doi.org/10.1016/S0098-3004(00)00096-0).
- Pedrali, L. D., Marchesan, J., Queiroz, T. B., Baldin, T., Sousa, R. dos S., Batista, F. de J., & Pereira, R. S. (2016). Comportamento espectral de espécies utilizadas em arborização urbana. *Revista Ecologia e Nutrição Florestal*, 4(1), 19-32. <http://dx.doi.org/10.5902/2316980X23082>.
- Peng, Y., Zhang, M., Xu, Z., Yang, T., Su, Y., Zhou, T., Wang, H., Wang, Y., & Lin, Y. (2020). Estimation of leaf nutrition status in degraded vegetation based on field survey and hyperspectral data. *Scientific Reports*, 10(1), 1-12. <http://dx.doi.org/10.1038/s41598-020-61294-7>.
- Ponzoni, F. J., Shimabukuro, Y. E., & Kuplich, T. M. (2012). *Sensoriamento remoto da vegetação* (2. ed., 160 p.). São Paulo: Oficina de Textos.
- Quitério, G. C. M., Souza Filho, C. R., & Almeida, T. I. R. (2007). Mudanças fisiológicas e espectrais induzidas por hidrocarbonetos em *Brachiaria brizantha* e *Dolichos lab lab*: uma avaliação sobre o uso da cobertura vegetal como bioindicador de escape de hidrocarbonetos. In *Anais do 13º Simpósio Brasileiro de Sensoriamento Remoto* (pp. 4389-4391). Florianópolis: INPE.
- Romualdo, L. M., Luz, P. H. C., Devecchio, F. F. S., Marin, M. A., Zúñiga, A. M. G., Bruno, O. M., & Herling, V. R. (2014). Use of artificial vision techniques for diagnostic of nitrogen nutritional status in maize plants. *Computers and Electronics in Agriculture*, 104, 63-70. <http://dx.doi.org/10.1016/j.compag.2014.03.009>.
- Schuster, C., Förster, M., & Kleinschmit, B. (2012). Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. *International Journal of Remote Sensing*, 33(17), 5583-5599. <http://dx.doi.org/10.1080/01431161.2012.666812>.
- Sharabian, V. R., Noguchi, N., & Ishi, K. (2014). Significant wavelengths for prediction of winter wheat growth status and grain yield using multivariate analysis. *Engineering in Agriculture, Environment and Food*, 7(1), 14-21. <http://dx.doi.org/10.1016/j.eaef.2013.12.003>.
- Slaton, M. R., Hunt, E. R., & Smith, W. K. (2001). Estimating near-infrared leaf reflectance from leaf structural characteristics. *American Journal of Botany*, 88(2), 278-284. <http://dx.doi.org/10.2307/2657019>.
- Swain, P. H., & Davis, S. M. (1978). *Remote sensing: the quantitative approach* (396 p.). New York: McGraw-Hill.
- Thorp, K. R., Wang, G., Bronson, K. F., Badaruddin, M., & Mon, J. (2017). Hyperspectral data mining to identify relevant canopy spectral features for estimating durum wheat growth, nitrogen status, and grain yield. *Computers and Electronics in Agriculture*, 136, 1-12. <http://dx.doi.org/10.1016/j.compag.2017.02.024>.
- Witschoreck, R., & Schumacher, M. V. (2015). Alocação de nutrientes em povoamentos de *Eucalyptus saligna* Sm. na região de Guaíba - Rio Grande do Sul. *Cerne*, 21(4), 625-632. <http://dx.doi.org/10.1590/01047760201521041963>.
- Yu, K., Zhao, Y., Li, X., Shao, Y., Liu, F., & He, Y. (2014). Hyperspectral imaging for mapping of total nitrogen spatial distribution in pepper plant. *PLoS One*, 9(12), e116205. <http://dx.doi.org/10.1371/journal.pone.0116205>.
- Zhang, Q., M. Chen, J., Ju, W., Wang, H., Qiu, F., Yang, F., Fan, W., Huang, Q., Wang, Y., Feng, Y., Wang, X., & Zhang, F. (2017). Improving the ability of the photochemical reflectance index to track canopy light use efficiency through differentiating sunlit and shaded leaves. *Remote Sensing of Environment*, 194, 1-15. <http://dx.doi.org/10.1016/j.rse.2017.03.012>.

Zhu, L., Zhao, X., Lai, L., Wang, J., Jiang, L., Ding, J., Liu, N., Yu, Y., Li, J., Xiao, N., Zheng, Y., & Rimmington, G. M. (2013). Soil TPH concentration estimation using vegetation indices in an oil polluted area of eastern China. *PLoS One*, 8(1), e54028. <http://dx.doi.org/10.1371/journal.pone.0054028>.

Contribuição dos Autores: LDP: Escrita – Primeira Redação, Escrita – Revisão e Edição, Metodologia, Curadoria de Dados, Análise Formal, Conceituação, Administração do Projeto, Investigação; JM: Escrita – Primeira Redação, Escrita – Revisão e Edição, Metodologia, Curadoria de Dados, Análise Formal, Investigação; TBQ: Escrita – Primeira Redação, Escrita – Revisão e Edição, Metodologia, Curadoria de Dados, Análise Formal, Conceituação, Administração do Projeto, Investigação; EA: Escrita – Primeira Redação, Escrita – Revisão e Edição, Metodologia, Curadoria de Dados, Análise Formal; RSP: Supervisão, Recursos; MVS: Supervisão, Recursos.