Repositório Institucional UNESP

RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo deste documento será disponibilizado somente a partir de 06/03/2027.

Universidade Estadual Paulista “Júlio de Mesquita Filho”
Instituto de Biociências – Câmpus de Botucatu
Programa de Pós-graduação em Biometria

Modelagem de *isoscapes* com *Machine Learning* para inferência da origem geográfica a partir de Isótopos Estáveis

Mariana Antunes Pelegati

Botucatu
2026

Mariana Antunes Pelegati

Modelagem de *isoscapes* com *Machine Learning* para inferência da origem geográfica a partir de Isótopos Estáveis

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Biometria da Universidade Estadual Paulista "Júlio de Mesquita Filho" como parte dos requisitos necessários para a obtenção do título de Mestre em Biometria.

Orientador: Prof. Dr. Joel Mesa Hormaza

Botucatu
2026

P381m

Pelegati, Mariana Antunes
Modelagem de isoscapes com Machine Learning para inferência da origem geográfica a partir de Isótopos Estáveis / Mariana Antunes Pelegati. -- Botucatu, 2026
57 p.

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Instituto de Biociências, Botucatu
Orientador: Joel Mesa

1. Isoscapes. 2. Isótopos estáveis. 3. Machine Learning. 4. Kriging universal. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

Mariana Antunes Pelegati

Modelagem de *isoscapes* com *Machine Learning* para inferência da origem geográfica a partir de Isótopos Estáveis

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Biometria da Universidade Estadual Paulista "Júlio de Mesquita Filho" , como parte dos requisitos necessários para a obtenção do título de Mestre em Biometria.

Comissão examinadora:

Prof. Dr. Joel Mesa Hormaza
Orientador - Titular 1

Prof. Dr. Vladimir Eliodoro Costa
Titular 2

Dr. Marcel Rodrigues Ferreira
Titular 3

Dra. Juliana Celia Denadai
Suplente 1

Prof. Dr. Rafael Plana Simões
Suplente 2

Dedico este trabalho ao meu irmão, que é minha maior inspiração e motivo de orgulho. Que meus passos possam servir de exemplo e incentivo para que você siga em busca dos seus sonhos.

Agradecimentos

Agradeço à minha família e amigos pelo carinho e incentivo ao longo desta jornada. Aos meus pais, que são meu exemplo e inspiração, à minha madrinha e meu tio, por todo investimento na minha educação, e ao meu namorado, por todo amor e por estar sempre ao meu lado.

Agradeço ao meu orientador Professor Dr. Joel Mesa Hormaza por todo o apoio, dedicação e, principalmente, por toda a confiança em meu trabalho desde minha iniciação científica.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro na realização desta pesquisa. Ao Programa de Pós-graduação em Biometria pelo ambiente acadêmico, proporcionando aprendizado e crescimento pessoal e ao Centro de Isótopos Estáveis por todo suporte no desenvolvimento deste trabalho.

Resumo

A variação espacial de isótopos estáveis tem se mostrado uma ferramenta poderosa para inferir a origem geográfica de produtos e compreender processos ambientais. O presente trabalho tem como objetivo construir e comparar *isoscapes* dos isótopos de ^{2}H, ^{13}C e ^{18}O a partir da aplicação de diferentes abordagens de modelagem espacial (*kriging* universal, *Random Forest* e *Generalized Additive Models*) a dados de mel e azeite produzidos no Brasil. As análises foram conduzidas na linguagem R, utilizando dados fornecidos pelo Centro de Isótopos Estáveis. Foram avaliados o desempenho dos modelos e a coerência espacial das isoscapes geradas. Os resultados indicaram que o baixo número de amostras, aliado a uma distribuição espacial desigual, dificultaram a aplicação da *krigagem* universal. Em contrapartida, a inclusão de variáveis bioclimáticas da plataforma *WorldClim* permitiu que os modelos de *Machine Learning* superassem essas limitações. As abordagens de *Random Forest* e *Generalized Additive Models* proporcionaram isoscapes com maior suavização espacial e coerência geográfica, capturando melhor os gradientes isotópicos ao integrar as covariáveis ambientais no processo de modelagem. Apesar das limitações, os modelos resultaram em *isoscapes* com adequada suavização espacial e desempenho estatístico satisfatório. Os resultados oferecem uma base inicial para a predição de valores isotópicos em amostras futuras, demonstrando o potencial das abordagens de *Machine Learning* para aprimorar a modelagem isotópica e oferecer subsídios à rastreabilidade e autenticação de origem geográfica de produtos.

Palavras-chave: *isoscapes*, isótopos estáveis, *Machine Learning*, *kriging*, *Random Forest*, *Generalized Additive Model*.

Abstract

The spatial variation of stable isotopes has proven to be a powerful tool for inferring the geographic origin of products and understanding environmental processes. This study aims to construct and compare isoscapes of ^{2}H, ^{13}C and ^{18}O isotopes by applying different spatial modeling approaches (Universal *Kriging*, Random Forest, and Generalized Additive Models) to honey and olive oil data produced in Brazil. The analyses were conducted in the R language, using data provided by the Center for Stable Isotopes. Model performance and the spatial coherence of the generated isoscapes were evaluated. The results indicated that the small number of samples, combined with an uneven spatial distribution, limited the application of Universal *Kriging*. In contrast, the inclusion of bioclimatic variables from the WorldClim platform allowed Machine Learning models to overcome these limitations. The Random Forest and Generalized Additive Model approaches provided isoscapes with greater spatial smoothing and geographic coherence, better capturing isotopic gradients by integrating environmental covariates into the modeling process. Despite the limitations, the models resulted in isoscapes with adequate spatial smoothing and satisfactory statistical performance. These results provide an initial basis for predicting isotopic values in future samples, demonstrating the potential of Machine Learning approaches to improve isotopic modeling and support the traceability and geographic origin authentication of products.

Keywords: isoscapes, stable isotopes, Machine Learing, *kriging*, Random Forest, Generalized Additive Model.

Lista de figuras

Figura 1 – Exemplo de *isoscape* de hidrogênio. Adaptado de Courtiol (2019) 13
Figura 2 – Distribuição dos valores de $\delta^{13}C$ do mel no estado de Santa Catarina. 21
Figura 3 – Distribuição dos valores de $\delta^{13}C$ do mel no estado de São Paulo. 21
Figura 4 – Distribuição dos valores de $\delta^{2}H$ do azeite no estado do Rio Grande do Sul. . 22
Figura 5 – Distribuição dos valores de $\delta^{13}C$ do mel no estado de Santa Catarina com aplicação do *jitter*. 23
Figura 6 – Distribuição dos valores de $\delta^{13}C$ do mel no estado de São Paulo com aplicação do *jitter*. 24
Figura 7 – Distribuição dos valores de $\delta^{2}H$ do azeite no estado do Rio Grande do Sul com aplicação do *jitter*. 24
Figura 8 – *Isoscapes* do δ^{13}C no mel para o estado de Santa Catarina. 33
Figura 9 – *Isoscapes* do δ^{13}C na proteína do mel para o estado de Santa Catarina. . . . 34
Figura 10 – *Isoscapes* do δ^{13}C no mel para o estado de São Paulo. 35
Figura 11 – *Isoscapes* do δ^{13}C na proteína do mel para o estado de São Paulo. 36
Figura 12 – *Isoscapes* do δ^{2}H no azeite para o estado do Rio Grande do Sul. 37
Figura 13 – *Isoscapes* do $\delta^{13}C$ no azeite para o estado do Rio Grande do Sul. 38
Figura 14 – *Isoscapes* do $\delta^{18}O$ no azeite para o estado do Rio Grande do Sul. 39
Figura 15 – Distribuição dos valores de $\delta^{13}C$ da proteína do mel no estado de Santa Catarina. 49
Figura 16 – Distribuição dos valores de $\delta^{13}C$ da proteína do mel no estado de Santa Catarina com aplicação do *jitter*. 49
Figura 17 – Distribuição dos valores de $\delta^{13}C$ da proteína do mel no estado de São Paulo. 50
Figura 18 – Distribuição dos valores de $\delta^{13}C$ da proteína do mel no estado de São Paulo com aplicação do *jitter*. 50
Figura 19 – Distribuição dos valores de $\delta^{13}C$ do azeite no estado do Rio Grande do Sul. 51
Figura 20 – Distribuição dos valores de $\delta^{13}C$ do azeite no estado do Rio Grande do Sul com aplicação do *jitter*. 51
Figura 21 – Distribuição dos valores de $\delta^{18}O$ do azeite no estado do Rio Grande do Sul. 52
Figura 22 – Distribuição dos valores de $\delta^{18}O$ do azeite no estado do Rio Grande do Sul com aplicação do *jitter*. 52

Lista de tabelas

Tabela 1 – Desempenho dos modelos de predição do $\delta^{13}C$ para mel e proteína do mel. . 30
Tabela 2 – Desempenho dos modelos de predição do $\delta^{2}H$, $\delta^{13}C$ e $\delta^{18}O$ do azeite. . . . 31
Tabela 3 – Desempenho do modelo de RF aprimorado para predição do $\delta^{2}H$, $\delta^{13}C$ e $\delta^{18}O$ do azeite. 31
Tabela 4 – *Range* estimado por variograma para $\delta^{13}C$ (mel e proteína). 40
Tabela 5 – *Range* estimado por variograma para os isótopos do azeite. 40

Lista de abreviaturas e siglas

CIE	Centro de Isótopos Estáveis
GAM	*Generalized additive model*
IAEA	*Internacional Atomic Energy Agency*
IRMS	*Isotope Ratio Mass Spectrometry*
ML	*Machine Learning*
mUr	miliurey
R^2	Coeficiente de determinação
RF	*Random Forest*
RS	Rio Grande do Sul
RMSE	*Root Mean Squared Error*
SC	Santa Catarina
SP	São Paulo
SI	Sistema Internacional de Unidades
VPDB	*Vienna PeeDee Belemnite*
VSMOW	*Vienna Standard Mean Ocean Water*

Sumário

1 INTRODUÇÃO 11
1.1 *Isoscape* 12
1.2 *Machine Learning* 14
1.2.1 *Random Forest* 16
1.2.2 *Generalized Additive Models* 17
1.3 Motivação 17
1.4 Objetivos 18

2 MODELAGEM DAS *ISOSCAPES* 19
2.1 Conjunto de dados 20
2.2 Pré-processamento e georreferenciamento 22
2.2.1 Esclarecimento sobre a incerteza do *jitter* 25
2.3 *Isoscape* com interpolação espacial via *kriging* 25
2.4 *Isoscape* via *Random Forest* 26
2.5 *Isoscape* via *Generalized Additive Model* 27
2.6 Justificativa ecofisiológica dos preditores 28
2.7 Considerações sobre a escala e resolução espacial 28
2.8 Avaliação do desempenho dos modelos 29

3 RESULTADOS E DISCUSSÃO 30
3.1 Desempenho dos modelos 30
3.2 *Isoscapes* 32
3.3 Interpretação das abordagens de modelagem espacial 40

4 CONCLUSÃO 43

Referências 45

Apêndices 48

APÊNDICE A – DISTRIBUIÇÃO DOS VALORES ISOTÓPICOS . . 49

APÊNDICE B – SCRIPTS DE MODELAGEM 53

1 Introdução

Isótopos são átomos de mesmo elemento químico que possuem o mesmo número de prótons e diferem no número de nêutrons, resultando em diferentes números de massa. Os isótopos estáveis são átomos que possuem um núcleo não radioativo e, portanto, não sofrem desintegração ao longo do tempo (Sharp, 2017).

Os isótopos estáveis têm sido amplamente utilizados em estudos ambientais, ecológicos e na autenticação de produtos (Fry, 2006). Hidrogênio (H), carbono (C), oxigênio (O), nitrogênio (N) e enxofre (S) se destacam entre os elementos analisados. Essas análises se baseiam em razões isotópicas específicas, por exemplo, ${}^{2}H/{}^{1}H$, ${}^{13}C/{}^{12}C$, ${}^{18}O/{}^{16}O$, ${}^{15}N/{}^{14}N$ e ${}^{34}S/{}^{32}S$. No caso do hidrogênio, é comum o uso da razão D/H (Sharp, 2017).

As razões isotópicas são expressas pela notação delta δ, que representa a diferença relativa entre a razão isotópica da amostra e a razão isotópica de um padrão de referência. É determinada por espectrometria de massa de razão isotópica (IRMS) e essa notação é dada por:

$$\delta^{i}E = \left(\frac{R\left(\frac{{}^{i}E}{{}^{j}E}\right)_{\text{amostra}} - R\left(\frac{{}^{i}E}{{}^{j}E}\right)_{\text{padrão}}}{R\left(\frac{{}^{i}E}{{}^{j}E}\right)_{\text{padrão}}} \right)$$

em que E representa o elemento e R é a razão entre o isótopo raro ${}^{i}E$ e o isótopo abundante ${}^{j}E$ (Coplen, 2011). Se o valor de δ for positivo, significa que a razão entre o isótopo pesado e leve é maior na amostra do que no padrão, ou seja, indica que a amostra está enriquecida no isótopo pesado. Já um valor negativo de δ tem significado contrário, indicando que a amostra está empobrecida no isótopo pesado (Sharp, 2017).

Tradicionalmente, os valores de δ são expressos em partes por mil utilizando o símbolo ‰. No entanto, conforme recomendação de Brand e Coplen (2012) e seguindo as diretrizes do Sistema Internacional de Unidades (SI), os resultados serão apresentados em miliurey (mUr).

A fim de realizar comparações precisas, existe um conjunto de padrões de referência internacional reconhecido pela Agência Internacional de Energia Atômica (*International Atomic Energy Agency* - IAEA). No caso do $\delta^{13}C$, utiliza-se o padrão $R({}^{13}C/{}^{12}C)_{VPDB}$, obtido por uma espécie de *Belemnitella americana* de formação *Peedee* da Carolina do Sul, denominando o padrão de *Vienna PeeDee Belemnite* (VPDB). Para $\delta^{2}H$ e $\delta^{18}O$, são utilizados os padrões $R({}^{2}H/{}^{1}H)_{VSMOW}$ e $R({}^{18}O/{}^{16}O)_{VSMOW}$. Esses padrões foram obtidos pela coleta de amostras

de água do oceano em diferentes profundidades, denominando o padrão de *Vienna Standard Mean Ocean Water* (VSMOW) (Sharp, 2017).

A caracterização isotópica da água é uma ferramenta amplamente utilizada em estudos ambientais para identificar diferenças na composição isotópica de águas provenientes de distintas regiões geográficas e climáticas. Essa variação ocorre porque, durante os processos de evaporação e precipitação, as moléculas de água com isótopos mais leves tendem a se mover preferencialmente para a fase gasosa, enquanto as moléculas enriquecidas em isótopos pesados permanecem na fase líquida. Como resultado, surgem gradientes isotópicos que refletem as condições climáticas e a origem geográfica da água (Primrose M. Woolfe, 2010).

Em relação ao carbono, observam-se variações na razão isotópica entre plantas que utilizam diferentes rotas fotossintéticas (C3, C4 e CAM). As plantas C3 realizam a fixação do dióxido de carbono diretamente pelo ciclo de Calvin-Benson, incorporando menor quantidade de ^{13}C, o que resulta em valores de $\delta^{13}C$ mais negativos, geralmente entre -24 e $-34‰$. As plantas C4, por sua vez, realizam uma etapa adicional de fixação inicial do $C\,O_2$ pela via Hatch–Slack antes de entrarem no ciclo de Calvin-Benson, o que leva à maior incorporação de ^{13}C e, consequentemente, a valores de $\delta^{13}C$ menos negativos, normalmente entre -6 e $-19‰$ (Primrose M. Woolfe, 2010). As plantas com metabolismo CAM apresentam valores intermediários, próximos aos encontrados em plantas C3 e C4 (Rhodes et al., 2010).

Dessa forma, a diferença entre os valores de $\delta^{13}C$ permite verificar a autenticidade de produtos e identificar possíveis adulterações. Por exemplo, se um produto declarado como proveniente de matéria-prima C3, como o mel (néctar de flores), apresentar sinal isotópico característico de plantas C4, como xarope de cana-de-açúcar, pode-se inferir a presença de adulterantes (Primrose M. Woolfe, 2010).

Tais variações isotópicas, tanto na água quanto nos compostos orgânicos, refletem condições ambientais e climáticas específicas, como temperatura, regime de chuvas, latitude, altitude e tipo de vegetação. Como essas variáveis apresentam uma distribuição espacial definida, as razões isotópicas associadas a elas também exibem padrões geográficos consistentes. Dessa forma, torna-se possível representar essas assinaturas isotópicas de maneira espacializada, permitindo a visualização e a análise de gradientes isotópicos em escala regional ou global (Bowen, 2010).

Referências

ARAI, Kohma et al. Integrating machine learning with otolith isoscapes: Reconstructing connectivity of a marine fish over four decades. *PLOS One*, v. 18, n. 5, 2023. DOI: 10.1371/journal.pone.0285702. Citado na página 15.

BONSOMS, Josep; NINYEROLA, Miquel. Comparison of linear, generalized additive models and machine learning algorithms for spatial climate interpolation. *Theoretical and Applied Climatology*, v. 155, p. 1777–1792, 2024. DOI: 10.1007/s00704-023-04725-5. Citado na página 17.

BOWEN, Gabriel J. Isoscapes: Spatial pattern in isotopic biogeochemistry. *Annual Review of Earth and Planetary Science*, v. 38, p. 161–187, 2010. DOI: 10.1146/annurev-earth-040809-152429. Citado 4 vezes nas páginas 12, 16, 22 e 28.

BRAND, Willi A.; COPLEN, Tyler B. Stable isotope deltas: tiny, yet robust signatures in nature. *Isotopes in Environmental and Health Studies*, v. 48, n. 3, p. 393–409, 2012. DOI: 10.1080/10256016.2012.666977. Citado na página 11.

BREIMAN, Leo. Bagging predictors. *Machine Learning*, v. 24, p. 123–140, 1996. Citado na página 16.

BREIMAN, Leo. Random forests. *Machine Learning*, v. 45, p. 5–32, 2001. DOI: 10.1023/A:1010933404324. Citado 2 vezes nas páginas 16 e 19.

CIPRIANO, Cristina et al. Algorithms going wild – a review of machine learning techniques for terrestrial ecology. *Ecological Modelling*, v. 506, 2025. DOI: 10.1016/j.ecolmodel.2025.111164. Citado na página 14.

COPLEN, Tyler B. Guidelines and recommended terms for expression of stable-isotope-ratio and gas-ratio measurement results. *Rapid Communications in Mass Spectrometry*, v. 25, n. 17, p. 2538–2560, 2011. DOI: 10.1002/rcm.5129. Citado na página 11.

COURTIOL, Alexandre. Isoscape computation and inference of spatial origins with mixed models using the r package isorix. In: HOBSON, Keith A.; WASSENAAR, Leonard I. (Ed.). *Tracking Animal Migration with Stable Isotopes*. [S.l.]: Academic Press, 2019. p. 207–236. Data obtained from GNIP, International Atomic Energy Agency (<https://www.iaea.org/water>). Citado 3 vezes nas páginas viii, 13 e 17.

CUTLER, D Richard et al. Random forests for classification in ecology. *Ecology*, v. 88, n. 11, p. 2783–2792, 2007. DOI: 10.1890/07-0539.1. Citado na página 19.

ERTEN, Gamze Erdogan; YAVUZ, Mahmut; DEUTSCH, Clayton V. *Estimation with a Combined Machine Learning and Kriging Spatial Estimation*. [S.l.], 2020. Citado na página 14.

FANG, Wei et al. An evaluation of random forest based input variable selection methods for one month ahead streamflow forecasting. *Scientific Reports*, v. 14, n. 29766, 2024. DOI: 10.1038/s41598-024-81502-y. Citado na página 16.

FICK, Stephen E.; HIJMANS, Robert J. Worldclim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, v. 37, n. 12, p. 4302–4315, 2017. Citado 2 vezes nas páginas 17 e 19.

FRY, Bryan. *Stable Isotope Ecology*. 1st. ed. EUA: Springer New York, 2006. DOI: 10.1007/0-387-33745-8. ISBN 978-0-387-33745-6. Citado na página 11.

GEORGANOS, Stefanos et al. Less is more: optimizing classification performance through feature selection in a very-high-resolution remote sensing object-based urban application. *GIScience and Remote Sensing*, v. 55, n. 2, p. 221–242, 2018. DOI: 10.1080/15481603.2017.1408892. Citado na página 41.

HASTIE, Trevor; TIBSHIRANI, Robert. Generalized additive models. *Statistical Science*, v. 1, n. 3, p. 297–310, 1986. DOI: 10.1214/ss/1177013604. Citado 2 vezes nas páginas 17 e 19.

HENGL, Tomislav et al. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. *PeerJ*, v. 6, n. e5518, 2018. DOI: 10.7717/peerj.5518. Citado na página 16.

HIGDON, Roger. Generalized additive models. In: *Encyclopedia of Systems Biology*. New York, NY, USA: Springer New York, 2013. ISBN 978-1-4419-9863-7. DOI: 10.1007/978-1-4419-9863-7. Citado na página 17.

HIJMANS, Robert J. et al. *WorldClim version 2.1*. 2023. Disponível em: <https://www.worldclim.org>. Citado 4 vezes nas páginas 19, 25, 26 e 27.

HILL, A. F. et al. Precipitation isotopes new zealand (pinz): improvements in precipitation isoscapes with machine learning. *Environmental Chemistry*, v. 22, n. EN24098, 2025. DOI: 10.1071/EN24098. Citado na página 14.

LABORATORY, Walter Applied Spatial Ecology. *10.6 - Jitter UTM coordinates before making SpatialPointsDataFrame*. 2023. Disponível em: < https://ecosystems.psu.edu/research/labs/walter-lab/manual/chapter-10-miscellaneous-code/10-6-jitter-utm-coordinates-before-making-spatialpointsdataframe >. Acesso em: 13 de out. de 2025. Citado 2 vezes nas páginas 23 e 25.

LIU, Wenwen et al. Effects of harvest season and altitude on the traceability of fenghuang dancong tea: Based on stable isotopes and machine learning. *Food Chemistry: X*, v. 28, n. 102532, 2025. DOI: 10.1016/j.fochx.2025.102532. Citado na página 14.

MILLER, Catriona et al. A review of model evaluation metrics for machine learning in genetics and genomics. *Frontiers in Bioinformatics*, v. 4, n. 1457619, 2024. DOI: 10.3389/fbinf.2024.1457619. Citado na página 29.

NELSON, Daniel B.; BASLER, David; KAHMEN, Ansgar. Precipitation isotope time series predictions frommachine learning applied in europe. *Proceedings of the National Academy of Sciences*, v. 118, n. 26, 2021. DOI: 10.1073/pnas.2024107118. Citado na página 15.

NWAILA, Glen T. et al. Spatial interpolation using machine learning: From patterns and regularities to block models. *Natural Resources Research*, v. 33, n. 1, 2024. DOI: 10.1007/s11053-023-10280-7. Citado na página 15.

PFOB, André; LU, Sheng-Chieh; SIDEY-GIBBONS, Chris. Machine learning in medicine: a practical introduction to techniques for data pre-processing, hyperparameter tuning, and model comparison. *BMC Medical Research Methodology*, v. 22, 2022. DOI: 10.1186/s12874-022-01758-8. Citado na página 14.

PRIMROSE M. WOOLFE, S. Rollinson S. Food forensics: methods for determining the authenticity of foodstuffs. *Trends in Food Science & Technology*, v. 21, p. 582–590, 2010. DOI: 10.1016/j.tifs.2010.09.006. Citado na página 12.

RHODES, Christopher N. et al. The use of stable carbon isotopes to authenticate claims that poultry have been corn-fed. *Food Chemistry*, v. 118, p. 927–932, 2010. DOI: 10.1016/j.foodchem.2008.05.113. Citado na página 12.

SENA-SOUZA, João Paulo; COSTA, Fábio José Viana; NARDOTO, Gabriela Bielefeld. Background and the use of isoscapes in the brazilian context: essential tool for isotope data interpretation and natural resource management. *Ambiente & Água*, v. 14, n. 2, 2019. DOI: 10.4136/ambi-agua.2282. Citado 2 vezes nas páginas 13 e 15.

SHARP, Zachary. *Principles of Stable Isotope Geochemistry*. 2nd. ed. [S.l.]: The University Of New Mexico, 2017. DOI: 10.25844/h9q1-0p82. Citado 4 vezes nas páginas 11, 12, 16 e 28.

TERRO, Cathrine et al. Isofoodtrack: a comprehensive database and management system based on stable isotope ratio analysis for combating food fraud. *Frontiers in Nutrition*, v. 12, n. 1516521, 2025. DOI: 10.3389/fnut.2025.1516521. Citado 3 vezes nas páginas 13, 14 e 15.

WEBSTER, Richard; OLIVER, Margaret A. *Geostatistics for Environmental Scientists*. 2nd. ed. [S.l.]: John Wiley & Sons, 2007. DOI: 10.1002/9780470517277. ISBN 9780470028582. Citado 3 vezes nas páginas 25, 28 e 41.

WEST, Jason B. et al. *Isoscapes: Understanding Movement, Pattern, and Process on Earth Through Isotope Mapping*. [S.l.]: Springer, 2010. DOI: 10.1007/978-90-481-3354-3. ISBN 9789048133536. Citado na página 41.

WOOD, Simon N. *Generalized Additive Models: An Introduction with R*. 2nd. ed. New York, EUA: Chapman and Hall/CRC, 2017. DOI: 10.1201/9781315370279. ISBN 9781315370279. Citado 3 vezes nas páginas 15, 19 e 42.

YING, Xue. An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, v. 1168, 2019. DOI: 10.1088/1742-6596/1168/2/022022. Citado na página 15.