

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA SANITÁRIA E AMBIENTAL
CURSO DE GRADUAÇÃO EM ENGENHARIA SANITÁRIA E AMBIENTAL

Bruno Rech

**Estimativa do saldo de radiação na bacia hidrográfica da Lagoa da Conceição
(Florianópolis – SC) a partir de imagens Landsat 8**

Florianópolis

2022

Bruno Rech

**Estimativa do saldo de radiação na bacia hidrográfica da Lagoa da Conceição
(Florianópolis – SC) a partir de imagens Landsat 8**

Trabalho de Conclusão de Curso submetido ao curso de graduação em Engenharia Sanitária e Ambiental do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharel em Engenharia Sanitária e Ambiental.

Orientadora: Profa. Patrícia Kazue Uda, Dra.

Florianópolis

2022

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Rech, Bruno

Estimativa do saldo de radiação na bacia hidrográfica da Lagoa da Conceição (Florianópolis - SC) a partir de imagens Landsat 8 / Bruno Rech ; orientadora, Patrícia Kazue Uda, 2022.

108 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Engenharia Sanitária e Ambiental, Florianópolis, 2022.

Inclui referências.

1. Engenharia Sanitária e Ambiental. 2. Sensoriamento Remoto. 3. Balanço de Radiação. 4. Bacia Hidrográfica da Lagoa da Conceição. I. Uda, Patrícia Kazue. II. Universidade Federal de Santa Catarina. Graduação em Engenharia Sanitária e Ambiental. III. Título.

Bruno Rech

**Estimativa do saldo de radiação na bacia hidrográfica da Lagoa da Conceição
(Florianópolis – SC) a partir de imagens Landsat 8**

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de Bacharel em Engenharia Sanitária e Ambiental e aprovado em sua forma final pelo Curso de Graduação em Engenharia Sanitária e Ambiental.

Florianópolis, 13 de dezembro de 2022.

Profa. Maria Elisa Magri, Dra.
Coordenadora do Curso

Banca examinadora

Profa. Patrícia Kazue Uda, Dra.
Orientadora

Prof. Bernardo Barbosa da Silva, Dr.
Universidade Federal de Campina Grande

Prof. Davide Franco, Dr.
Universidade Federal de Santa Catarina

Marcelo Pedroso Curtarelli, Dr.
Fundação CERTI

Florianópolis, 2022.

Dedico este trabalho àqueles que pavimentaram meu caminho até aqui e
àqueles que alegraram a caminhada.

AGRADECIMENTOS

Meu primeiro agradecimento é dedicado à minha mãe, Sueli Brito, e minha irmã, Cauane Rech, as duas pessoas que mais amo nesse mundo. É impossível descrever em palavras, muito menos em tão poucas, todos os motivos pelos quais tenho a agradecer. Eu não seria nada não fosse o amor e o apoio irrestritos de ambas.

Ao meu pai, Inacio Rech (*in memoriam*), agradeço o apoio e o amor sem os quais nada disso teria sido possível.

Agradeço minha madrinha Sandra Aparecida dos Santos, cujo convite a conhecer e fazer Ciência foi o início dessa caminhada em tão iluminada companhia.

Agradeço meu grande amigo Arnaldo Haas Jr., professor do Ensino Médio que me ajudou a despertar para o mundo – da Ciência ao *rock'n roll*.

Ao querido amigo Luiz Carlos Soares, o Luizão (*in memoriam*), agradeço por sempre me incentivar a progredir e por compartilhar suas histórias.

Aos membros do Laboratório de Ecologia de Águas Continentais, agradeço a oportunidade de poder aprender e fazer Ciência. Em especial ao professor e amigo Nei Kavaguichi Leite e à amiga Michelle das Neves Lopes, sou grato pelas inúmeras e valiosas contribuições no meu desenvolvimento profissional e pessoal.

Ao grande amigo Luiz Carlos Garcia, colega de curso e primeiro amigo de faculdade, agradeço pelo companheirismo e pela companhia durante os últimos anos. Sua amizade é uma das melhores coisas que a graduação me proporcionou.

À querida amiga Anna Paula Marchezan, colega de curso, agradeço pela companhia constante nos últimos anos, nos melhores e nos piores momentos da jornada. Sua amizade foi muito importante nessa caminhada.

Agradeço ao meu supervisor de estágio, Rodrigo Kern, pela oportunidade de desenvolvimento profissional e pelo compartilhamento de conhecimento.

À equipe do Laboratório de Hidráulica Marítima, agradeço a amizade, o acolhimento, o companheirismo e a paciência. Em especial à profa. Patrícia Kazue Uda, querida orientadora, agradeço a oportunidade de conhecer o maravilhoso mundo do sensoriamento remoto, o bom humor e o comprometimento com a educação.

Aos membros da banca, agradeço por disponibilizarem seu tempo e sua experiência na avaliação do meu trabalho.

À Universidade Federal de Santa Catarina, agradeço a oportunidade e a infraestrutura disponibilizada.

“And everything under the sun is in tune

But the sun is eclipsed by the moon”

(WATERS, 1973)

RESUMO

O saldo de radiação expressa a diferença entre os fluxos radiativos incidentes e os fluxos radiativos refletidos ou emitidos pela superfície, sendo composto por radiação de ondas curtas e de ondas longas. A energia representada pelo saldo de radiação está disponível a processos como o aquecimento do ar e da superfície e a evapotranspiração. Na estimativa do saldo de radiação, os dados de sensoriamento remoto apresentam grande relevância e aplicabilidade. Não obstante, no estado de Santa Catarina e, mais especificamente, em Florianópolis ainda são poucos os estudos analisando o saldo de radiação e sua estimativa por meio de dados obtidos por satélites. À vista disso, o presente trabalho se propõe a estimar o saldo de radiação instantâneo na bacia hidrográfica da Lagoa da Conceição (Florianópolis – SC), incluindo os saldos de ondas curtas e de ondas longas. Para tanto, a metodologia do modelo *Mapping Evapotranspiration with Internalized Calibration* (METRIC) foi adotada. Os dados de sensoriamento remoto utilizados são constituídos por imagens Landsat 8 OLI/TIRS com reflectância de superfície, além do modelo digital de elevação NASADEM, ambos com 30 m de resolução espacial. Os saldos de radiação foram estimados a partir de 93 imagens adquiridas entre 04/2013 e 09/2022 e avaliados sobre 8 classes de cobertura do solo por estação do ano. O saldo de radiação médio variou de 395 a 690 Wm^{-2} entre as classes, sendo que as dunas apresentaram os menores valores e a água, os mais elevados. Em termos das estações do ano, o saldo de radiação não exibiu diferenças significativas apenas entre primavera e verão e entre outono e inverno ($p\text{-value} > 0,05$). Os saldos de ondas curtas e de ondas longas apresentaram o mesmo comportamento em relação às estações, sendo que este último se mostrou negativo em todas as situações, ou seja, o fluxo de radiação de ondas longas que deixa a superfície supera o fluxo incidente. A forte correlação ($r_s > 0,80$ em módulo) verificada entre os saldos de ondas curtas e longas para todas as classes, por sua vez, indica que o saldo de ondas longas aumenta em valores absolutos com o aumento do saldo de ondas curtas. Esses resultados mostram que a utilização de sensoriamento remoto produz resultados satisfatórios na estimativa dos saldos radiativos da superfície. Além disso, a resolução temporal do satélite Landsat 8 é um desafio ao monitoramento contínuo do saldo de radiação e parâmetros associados, sobretudo nas estações com índices pluviométricos mais elevados. Estudos posteriores podem abordar a influência da precipitação e do relevo no saldo de radiação da região, bem como investigar o comportamento das superfícies aquáticas.

Palavras-chave: Balanço de Radiação; Sensoriamento Remoto; METRIC.

ABSTRACT

Net radiation represents the difference between downward and upward radiative fluxes over the surface, and is composed by shortwave and longwave radiation. The energy represented by net radiation is available to processes such as air and surface heating and evapotranspiration, and the use of remote sensing data has great relevance and applicability in its estimation. Despite that, in the State of Santa Catarina and, more specifically, in the Municipality of Florianópolis, there are few studies analyzing net radiation and its estimation using remote sensing data. In view of this, the present study proposes the estimation of instantaneous net radiation in the Lagoa da Conceição Watershed (Florianópolis – SC), including shortwave and longwave net radiation. To achieve this, the methodology of the model Mapping Evapotranspiration with Internalized Calibration (METRIC) was adopted. The remote sensing data used is constituted by Landsat 8 OLI/TIRS images with surface reflectance, and also the NASADEM digital elevation model, both with spatial resolution of 30 m. Net radiation was estimated from 93 images acquired between 04/2013 and 09/2022 and evaluated over 8 land cover classes and the four seasons. Mean net radiation varied from 395 to 690 Wm^{-2} between classes, where the lowest is associated with dunes and the highest, with water. Regarding the seasons, net radiation did not exhibit significant differences only between spring and summer and between fall and winter (p -value > 0,05). Shortwave and longwave net radiation showed the same behavior concerning to the seasons, and the latter was negative in all cases, i.e., the upward longwave fluxes are greater than the downward ones. The strong linear correlation ($r_s > 0,80$ in absolute values) verified between shortwave and longwave net radiation to all land cover classes, in turn, indicates that longwave net radiation is increased (in absolute values) with the increase of shortwave net radiation. These results show that the use of remote sensing produces satisfactory results on the estimation of radiation budgets over surface. In addition, the temporal resolution of Landsat 8 represents a challenge to continuous monitoring of net radiation and associated parameters, mostly in the seasons with higher precipitation indices. Posterior studies can address the influence of precipitation and terrain in net radiation over the region, and also investigates the behavior of aquatic surfaces.

Keywords: Radiation Balance; Remote Sensing; METRIC.

LISTA DE FIGURAS

Figura 1 – Principais regiões do espectro eletromagnético.....	21
Figura 2 – Distribuição espectral da radiação solar.....	25
Figura 3 – Variação anual da declinação solar.....	26
Figura 4 – Localização da área de estudo	33
Figura 5 – Mapas de elevação (A), declividade (B) e orientação do terreno (C) na região da área de estudo	35
Figura 6 – Distribuição dos polígonos amostrais na área de estudo	36
Figura 7 – Distribuição temporal das imagens utilizadas no estudo.....	38
Figura 8 – Assinaturas espectrais das amostras selecionadas	49
Figura 9 – Albedo médio na área de estudo	51
Figura 10 – Saldo de radiação de ondas curtas por estação do ano	54
Figura 11 – Saldo de radiação de ondas longas por estação do ano.....	57
Figura 12 – Mapas de saldo de radiação médio por estação do ano	61
Figura 13 – Série temporal do saldo de radiação mediano	62
Figura 14 – Relação entre os saldos de ondas curtas e ondas longas	64

LISTA DE TABELAS

Tabela 1 – Normais climatológicas do período 1991-2020 para a estação climatológica Florianópolis	34
Tabela 2 – Características espectrais das bandas Landsat 8 OLI	37
Tabela 3 – Número de pixels amostrados por classe e por estação	48
Tabela 4 – Reflectâncias medianas das amostras selecionadas	49
Tabela 5 – Albedos médios obtidos para as amostras analisadas	50
Tabela 6 – Saldo de radiação de ondas curtas mediano (Wm^{-2}).....	52
Tabela 7 – Emissividade média das classes de cobertura do solo	55
Tabela 8 – Temperatura média de superfície ($^{\circ}C$)	55
Tabela 7 – Saldo de radiação de ondas longas mediano (Wm^{-2}).....	56
Tabela 10 – Saldo de radiação mediano (Wm^{-2})	58

LISTA DE ABREVIATURAS E SIGLAS

ASTER	Advanced Spaceborne Thermal Emission Reflection Radiometer
CBERS	China-Brazil Earth Resources Satellite
DUN	Dunas
FOD	Floresta Ombrófila Densa
GEE	Google Earth Engine
INMET	Instituto Nacional de Meteorologia
JPL	NASA Jet Propulsion Laboratory
LAHIMAR	Laboratório de Hidráulica Marítima
LAI	Leaf Area Index
LaSRC	Land Surface Reflectance Code
LCP	Lagoa da Conceição – Região Profunda
LCR	Lagoa da Conceição – Região Rasa
MDE	Modelo Digital de Elevação
METRIC	Mapping Evapotranspiration with Internalized Calibration
MODIS	Moderate Resolution Imaging Spectroradiometer
NASA	National Aeronautics and Space Administration
NIR	Near Infrared
NREL	National Renewable Energy Laboratory
OLI	Operational Land Imager
OSEB	One-Source Energy Balance
RAA	Restinga Arbustiva Arbórea
SAVI	Soil Adjusted Vegetation Index
SC	Santa Catarina
SEBAL	Surface Energy Balance Algorithm for Land
SIL	Silvicultura
SR	Surface Reflectance
SRTM	Shuttle Radar Topography Mission
SWIR	Shortwave Infrared
TIRS	Thermal Infrared Sensor
UA	Unidade Astronômica
UFSC	Universidade Federal de Santa Catarina
URB	Área Urbana

USGS United States Geological Survey
VHE Vegetação Herbácea
WMO World Meteorological Organization

LISTA DE SÍMBOLOS

a	Absortividade
W	Água precipitável na atmosfera
α	Albedo
α_s	Albedo da superfície
δ	Ângulo de declinação solar
β	Ângulo de declividade da superfície
θ_{rel}	Ângulo de incidência solar
γ	Ângulo de orientação do relevo
ω	Ângulo horário
θ_{hor}	Ângulo zenital solar sobre uma superfície horizontal
r_s	Coefficiente de correlação de Spearman
K_t	Coefficiente de turbidez da atmosfera
λ	Comprimento de onda
$\lambda_{m\acute{a}x}$	Comprimento de onda de máxima emissão energética
σ	Constante de Stefan-Boltzmann ($5,67 \times 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$)
G_{sc}	Constante solar (radiação solar extraterrestre, 1.367 Wm^{-2})
F	Densidade de fluxo de radiação
n	Dia do ano
d	Distância relativa Terra-Sol
z	Elevação acima do nível do mar
ε	Emissividade
ε_a	Emissividade atmosférica
ε_s	Emissividade da superfície
LE	Fluxo de calor latente
G	Fluxo de calor no solo
H	Fluxo de calor sensível
f	Frequência
$^\circ$	Grau
$^\circ\text{C}$	Grau Celsius
h	Hora local
h_s	Hora solar
K	Kelvin
ϕ	Latitude

L_{st}	Longitude do meridiano padrão do fuso horário local
L_{loc}	Longitude local
m	Metro
B	Parâmetro angular em função do dia do ano
Pa	Pascal
P	Pressão atmosférica
e_w	Pressão de saturação de vapor d'água sobre superfície plana de água pura
e_a	Pressão real de vapor d'água na atmosfera
R_S^\downarrow	Radiação de ondas curtas incidente
R_S^\uparrow	Radiação de ondas curtas refletida
R_L^\uparrow	Radiação de ondas longas emitida
R_L^\downarrow	Radiação de ondas longas incidente
rad	Radiano
ρ	Reflectância
ρ_n	Reflectância de superfície da banda n
R_n^S	Saldo de radiação instantâneo de ondas curtas
R_n^L	Saldo de radiação instantâneo de ondas longas
R_n	Saldo de radiação instantâneo
T	Temperatura
T_s	Temperatura da superfície
T_a	Temperatura do ar
τ_{sw}	Transmissividade atmosférica
u_r	Umidade relativa do ar
E	Valor de correção da hora solar
W	Watt

SUMÁRIO

1	INTRODUÇÃO	18
1.1	OBJETIVOS	20
1.1.1	Objetivo Geral	20
1.1.2	Objetivos específicos	20
2	REVISÃO BIBLIOGRÁFICA	21
2.1	RADIAÇÃO SOLAR	21
2.1.1	Caracterização da radiação eletromagnética	21
2.1.2	Interações da radiação eletromagnética com a matéria	23
2.1.3	Caracterização da radiação solar	24
2.2	SALDO DE RADIAÇÃO	27
2.3	SALDO DE RADIAÇÃO E SENSORIAMENTO REMOTO	29
3	METODOLOGIA	33
3.1	ÁREA DE ESTUDO	33
3.2	SELEÇÃO DE AMOSTRAS DE COBERTURA DO SOLO	35
3.3	DADOS DE SENSORIAMENTO REMOTO	37
3.3.1	Reflectância e temperatura de superfície	37
3.3.2	Elevação	39
3.4	DADOS METEOROLÓGICOS	39
3.5	CÁLCULO DO SALDO DE RADIAÇÃO	40
3.5.1	Radiação de ondas curtas incidente	41
3.5.2	Albedo da superfície	45
3.5.3	Radiação de ondas longas incidente	45
3.5.4	Radiação de ondas longas emitida	46
3.6	TESTES ESTATÍSTICOS	47
4	RESULTADOS E DISCUSSÃO	48
4.1	CARACTERÍSTICAS DAS AMOSTRAS	48
4.2	ALBEDO DA SUPERFÍCIE	50
4.3	SALDO DE RADIAÇÃO DE ONDAS CURTAS	52
4.4	SALDO DE RADIAÇÃO DE ONDAS LONGAS	54
4.5	SALDO DE RADIAÇÃO	58
5	CONCLUSÃO	65
	REFERÊNCIAS	66

APÊNDICE A – LISTA DE IMAGENS UTILIZADAS.....	71
APÊNDICE B – DADOS METEOROLÓGICOS.....	74
APÊNDICE C – TESTES DE KRUSKAL-WALLIS.....	77
APÊNDICE D – TESTE POST-HOC DE DUNN: SALDO DE ONDAS CURTAS.....	78
APÊNDICE E – TESTE POST-HOC DE DUNN: SALDO DE ONDAS LONGAS.....	79
APÊNDICE F – TESTE POST-HOC DE DUNN: SALDO TOTAL	80
APÊNDICE G – MAPAS DO SALDO DE RADIAÇÃO	81
APÊNDICE H – SÉRIE TEMPORAL: SALDO DE RADIAÇÃO DE ONDAS CURTAS.....	82
APÊNDICE I – SÉRIE TEMPORAL: SALDO DE RADIAÇÃO DE ONDAS LONGAS.....	83
APÊNDICE J – CÓDIGO 1/3: FUNÇÕES AUXILIARES.....	84
APÊNDICE K – CÓDIGO 2/3: PROCESSAMENTO DAS IMAGENS	92
APÊNDICE L – CÓDIGO 3/3: ANÁLISES ESTATÍSTICAS.....	100

1 INTRODUÇÃO

A radiação eletromagnética proveniente do Sol é a principal fonte de energia dos processos que ocorrem na superfície da Terra. Parâmetros físicos/ambientais como a temperatura, a pressão e a umidade estão intimamente associados à quantidade de energia aportada ao sistema terrestre (VAREJÃO-SILVA, 2006; VIANELLO; ALVES, 2012).

Os fluxos radiativos de origem solar são constituídos majoritariamente por ondas de comprimento menor ou igual a 3.000 nm. A radiação nesse intervalo é chamada de ondas curtas. A Terra, por sua vez, também emite radiação. Contudo, por possuir temperatura muito menor do que aquela registrada no Sol, os fluxos radiativos dela originados são formados por radiação de ondas longas – isto é, ondas com comprimento superior a 3.000 nm (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

A radiação solar é atenuada ao atravessar a atmosfera terrestre e interage de diferentes formas com a superfície e seus elementos constituintes. Dentre essas interações há a reflexão, que varia conforme as propriedades da matéria e com o comprimento de onda da radiação incidente. O albedo (α) é o atributo que expressa a proporção da radiação de ondas curtas incidente que é refletida por uma determinada superfície (NOVO, 2008; PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019).

O processo de absorção, por sua vez, é responsável pelo aumento da energia interna dos materiais e implica na elevação de sua temperatura. Como consequência, a radiação de ondas longas emitida pelos mesmos é maximizada. Esse tipo de radiação é emitido pela superfície em direção à atmosfera e vice-versa (VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019).

Nota-se que a superfície terrestre conta com fluxos radiativos tanto incidentes quanto emitidos/refletidos. A diferença entre as entradas e as saídas representa o saldo de radiação (R_n), composto pelos saldos de ondas curtas (R_n^S) e de ondas longas (R_n^L) (ALLEN; TASUMI; TREZZA, 2007; BASTIAANSSEN et al., 1998; PEREIRA; ANGELOCCI; SENTELHAS, 2002).

Pela variação espacial e dependência das características da superfície apresentadas pelo saldo de radiação, a utilização de dados de sensoriamento remoto na sua estimativa é uma prática largamente difundida. Quando determinado para o

momento de aquisição da imagem de satélite, o saldo de radiação é dito instantâneo. O sensoriamento remoto é definido por Novo (2008) como a obtenção de informações da superfície terrestre a partir do registro da interação entre a radiação eletromagnética e os elementos que compõem a superfície, com uso de sensores remotamente posicionados.

O saldo de radiação é um importante parâmetro na compreensão de fenômenos atmosféricos e hidrológicos, como a evapotranspiração. Conforme Allen, Tasumi e Trezza (2007), a estimativa da evapotranspiração é fundamental na determinação do balanço hídrico e no planejamento e gestão das águas.

Dentre os modelos que utilizam dados de sensoriamento remoto na estimativa dos fluxos de energia da superfície, encontra-se o *Surface Energy Balance Algorithm for Land* (SEBAL), desenvolvido por Bastiaanssen et al. (1998) e o *Mapping Evapotranspiration with Internalized Calibration* (METRIC), desenvolvido por Allen, Tasumi e Trezza (2007). O modelo METRIC parte da formulação do SEBAL, sendo que o algoritmo de cômputo do saldo de radiação é o mesmo em ambos.

A utilização do SEBAL é difundida em todo o mundo. No Brasil, sua aplicação é verificada em diversos trabalhos, como Silva et al. (2015), Ferreira et al. (2020), Miranda et al. (2022) e Silva, Lopes e Azevedo (2005). Já em Santa Catarina (SC), o número de estudos com aplicação de sensoriamento remoto na estimativa do saldo de radiação ou da evapotranspiração é bastante reduzido.

Pela importância da caracterização do saldo de radiação da superfície e o baixo número de estudos do gênero em Santa Catarina, o presente trabalho se propôs a implementar a formulação do modelo METRIC na estimativa do saldo de radiação na bacia hidrográfica da Lagoa da Conceição, em Florianópolis (SC).

Esta pesquisa integra um conjunto de vários outros estudos desenvolvidos pelo Laboratório de Hidráulica Marítima (LAHIMAR) da Universidade Federal de Santa Catarina (UFSC), que estuda a Lagoa da Conceição há décadas. Espera-se que este trabalho possa contribuir para o desenvolvimento de estudos futuros sobre evapotranspiração na região.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Quantificar o saldo de radiação instantâneo na bacia hidrográfica da Lagoa da Conceição, em Florianópolis (SC), utilizando imagens Landsat-8.

1.1.2 Objetivos específicos

- Estimar o saldo de radiação instantâneo de ondas curtas;
- Estimar o saldo de radiação instantâneo de ondas longas;
- Verificar o comportamento sazonal dos saldos de radiação;
- Caracterizar os saldos de radiação sobre diferentes classes de cobertura do solo.

2 REVISÃO BIBLIOGRÁFICA

2.1 RADIAÇÃO SOLAR


2.1.1 Caracterização da radiação eletromagnética

A radiação eletromagnética origina-se da oscilação de ondas elétricas e magnéticas transversas, perpendiculares entre si e em fase. A variação das ondas eletromagnéticas ocorre de maneira senoidal e sua propagação se dá na velocidade da luz (NOVO, 2008; VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019).

Conforme Zanotta, Ferreira e Zorteia (2019), os campos elétrico e magnético que originam a radiação eletromagnética são produzidos a partir da oscilação de cargas elétricas, o que confere às ondas sua característica senoidal. Essa oscilação pode ser tanto natural quanto artificial (NOVO, 2008).

A radiação eletromagnética é caracterizada em termos do comprimento de onda λ e da frequência f , duas grandezas inversamente proporcionais. Enquanto a primeira expressa a distância entre dois picos ou dois vales consecutivos de um pulso de radiação, a última indica o número de oscilações que ocorrem no intervalo de um segundo (VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019).

A partir do comprimento de onda, a radiação eletromagnética é classificada em faixas específicas de acordo com suas propriedades. Esta classificação constitui o chamado espectro eletromagnético (Figura 1), cujo conjunto de comprimentos de onda conhecidos varia dos raios gama às ondas de rádio (NOVO, 2008; ZANOTTA; FERREIRA; ZORTEA, 2019).



Fonte: adaptado de Novo (2008).

Novo (2008) explica que a classificação proposta na Figura 1 leva em consideração: a) os processos físicos dos quais a radiação se origina; b) a forma de interação que a radiação possui com a matéria; c) a transparência atmosférica em relação à radiação. Chama-se a atenção para o estreito espectro do visível, assim denominado por estar associado aos comprimentos de onda distinguíveis pelo olho humano.

Todo corpo com temperatura acima de 0 K (zero absoluto) emite radiação eletromagnética. A quantidade de radiação emitida varia conforme a temperatura e a emissividade ε de cada corpo, sendo esta última definida como a razão entre a emitância do corpo de interesse e a emitância de um corpo negro¹ à mesma temperatura (NOVO, 2008; VAREJÃO-SILVA, 2006; VIANELLO; ALVES, 2012).

Nesse sentido, a lei de Stefan-Boltzmann estabelece que a densidade de fluxo F (Wm^{-2}) de energia emitida por um corpo é diretamente proporcional à quarta potência de sua temperatura absoluta. Matematicamente, esta lei é expressa por

$$F = \varepsilon\sigma T^4 \quad (1)$$

onde ε e T são, respectivamente, a emissividade (adimensional) e a temperatura do corpo (K), e σ é a constante de Stefan-Boltzmann, que vale $5,67 \times 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$ (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

Sabe-se também que existe uma relação inversamente proporcional entre a temperatura absoluta T e o comprimento de onda de máxima emissão energética $\lambda_{m\acute{a}x}$ de um corpo – a chamada lei de Wien. Esta relação é expressa por

$$T \lambda_{m\acute{a}x} = 2,898 \times 10^6 \text{ nmK} \quad (2)$$

Para T em Kelvin e $\lambda_{m\acute{a}x}$ em nanômetros (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

A lei de Kirchhoff afirma que a emissividade de um corpo é igual à sua absorvidade a para um dado comprimento de onda e uma dada temperatura. A absorvidade é definida como a razão entre a quantidade de energia radiante absorvida e o total incidente (VIANELLO; ALVES, 2012).

¹ Corpo teórico capaz de absorver toda a energia radiante que incide sobre ele.

Por fim, a lei do inverso do quadrado da distância enuncia que a quantidade de energia que incide sobre uma superfície é inversamente proporcional ao quadrado da distância entre a referida superfície e a fonte de energia (PEREIRA; ANGELOCCI; SENTELHAS, 2002).

2.1.2 Interações da radiação eletromagnética com a matéria

A radiação eletromagnética interage com a matéria de diferentes maneiras, as quais dependem do comprimento de onda da radiação e de características dos materiais, como sua composição química e suas propriedades físicas (ZANOTTA; FERREIRA; ZORTEA, 2019).

Um dos processos de interação mais importantes é a reflexão, no qual os elétrons dos átomos do objeto sobre o qual incide a radiação são excitados, mas a quantidade de energia fornecida não é compatível com os intervalos atômicos do material. Assim, o elétron retorna ao seu estado inicial rapidamente e libera a mesma quantidade de energia recebida – o que caracteriza a reflexão (ZANOTTA; FERREIRA; ZORTEA, 2019).

Conforme Novo (2008), os fluxos radiantes podem ser totalmente ou parcialmente refletidos. A razão entre o fluxo refletido e o fluxo total incidente de um objeto em uma faixa de comprimento de onda dá-se o nome de reflectância ρ .

A quantidade de radiação refletida – e, portanto, a reflectância – varia de acordo com o comprimento de onda. As folhas de vegetação, por exemplo, absorvem a radiação nos comprimentos de onda referentes ao azul e ao vermelho, mas refletem os comprimentos da faixa do verde, caracterizando sua aparência nessa cor. Materiais que refletem todos os comprimentos de onda da faixa do visível igualmente têm aparência branca, enquanto o oposto vale aos objetos que absorvem igualmente a radiação nesse intervalo (ZANOTTA; FERREIRA; ZORTEA, 2019).

Outro fenômeno originado da interação entre radiação e matéria é o espalhamento, que é análogo à reflexão e ocorre sobretudo em gases. Nesse processo, a radiação interage com todo o volume interno do material e é refletida em todas as direções. Os dois principais tipos de espalhamento são (VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019):

- a) Espalhamento *Rayleigh*: ocorre quando a radiação incide sobre partículas muito menores do que seu comprimento de onda. Por consequência, esse

tipo de espalhamento é mais intenso nos comprimentos de onda pequenos, como o azul;

- b) Espalhamento *Mie*: causado por partículas de tamanho próximo ao comprimento de onda da radiação incidente. Diferentemente do espalhamento *Rayleigh*, o comprimento de onda não exerce grande influência na intensidade do espalhamento *Mie*, que é aproximadamente igual para toda a faixa do visível.

A absorção, por sua vez, é definida como o fenômeno no qual a matéria absorve a energia que incide sobre ela, convertendo-a em energia térmica. Assim como na reflexão e no espalhamento, a ocorrência de absorção e a quantidade de energia absorvida dependem da composição do material e do comprimento de onda da radiação incidente (ZANOTTA; FERREIRA; ZORTEA, 2019).

Já a transmissão – também chamada de refração – constitui o processo no qual a radiação é transmitida através da matéria, sem que haja absorção ou reflexão. Esse fenômeno ocorre quando não há compatibilidade entre a energia da radiação incidente e os subníveis de energia nos átomos do material (ZANOTTA; FERREIRA; ZORTEA, 2019).

2.1.3 Caracterização da radiação solar

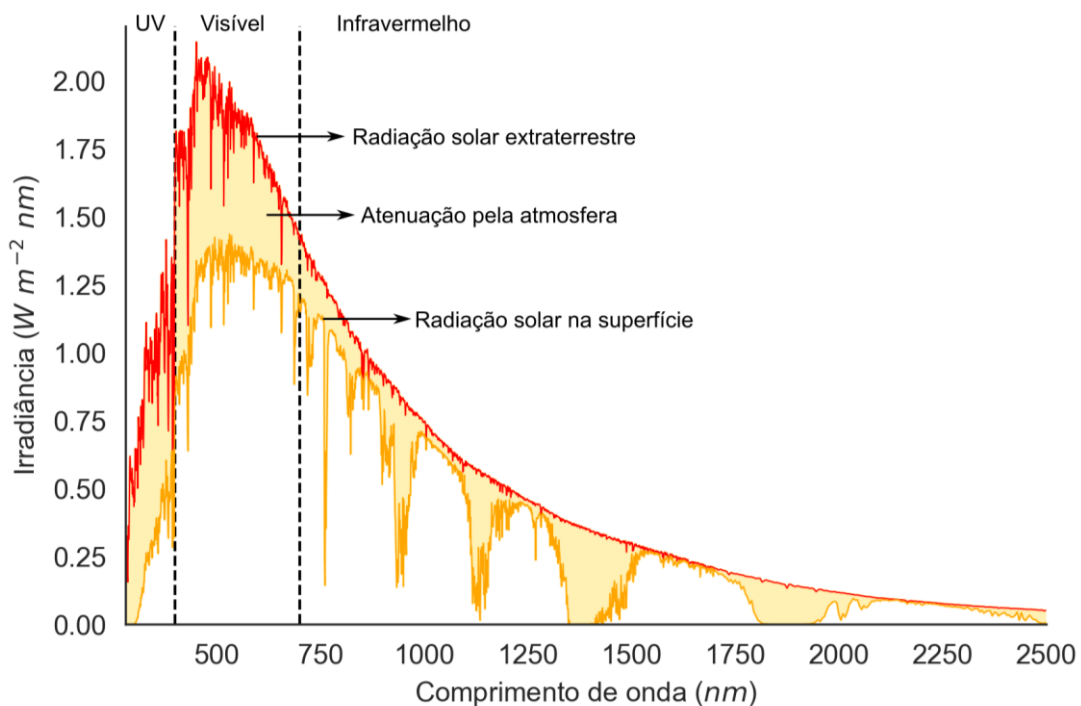
As reações que ocorrem no interior do Sol geram radiação eletromagnética, cuja propagação ocorre por meio de ondas ou partículas em todas as direções. Esse processo constitui a fonte mais importante de energia para a Terra, sendo fundamental a todos os processos terrestres. Dentre os processos desencadeados pela radiação solar, pode-se apontar desde a fotossíntese até os fenômenos meteorológicos e seus elementos associados – como pressão, temperatura, umidade e precipitação (NOVO, 2008; PEREIRA; ANGELOCCI; SENTELHAS, 2002).

Pela distância Terra-Sol média de aproximadamente $1,496 \times 10^{11}$ m (valor da chamada unidade astronômica – UA), assume-se o Sol como uma fonte pontual de radiação. A razão entre o fluxo total de energia emitida pelo Sol e a área de uma esfera concêntrica a este, de raio igual à distância Terra-Sol média, é chamada constante solar ou radiação solar extraterrestre, G_{sc} . Esse valor representa a energia proveniente do Sol por unidade de tempo que incide sobre uma superfície de área unitária perpendicular aos raios solares, localizada a uma distância da fonte igual à distância

Terra-Sol média. A constante solar desconsidera os efeitos de atenuação atmosférica e vale aproximadamente 1.367 Wm^{-2} (DUFFIE; BECKMAN, 2013; PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019).

A radiação solar extraterrestre varia para cada comprimento de onda, como ilustra a Figura 2. O Sol apresenta temperatura média de cerca de 6.000 K, o que resulta em um comprimento de onda de máxima emissão de aproximadamente 500 nm pela lei de Wien. De fato, a figura mostra que as maiores irradiâncias situam-se na região do espectro visível. Além disso, é possível observar uma clara diferença entre a radiação extraterrestre e a radiação na superfície, a qual se deve em grande parte à atenuação provocada pela atmosfera (NOVO, 2008; ZANOTTA; FERREIRA; ZORTEA, 2019).

Figura 2 – Distribuição espectral da radiação solar



Fonte: elaborado pelo autor com base em NREL (2022).


A interação da radiação eletromagnética proveniente do Sol com os constituintes atmosféricos – sobretudo vapor d'água, oxigênio, ozônio e gás carbônico – também varia para cada comprimento de onda. Na Figura 2 é possível observar a existência de bandas de absorção, isto é, regiões do espectro que apresentam forte atenuação pela atmosfera. Já as regiões do espectro menos suscetíveis à atenuação

são denominadas janelas atmosféricas (NOVO, 2008; ZANOTTA; FERREIRA; ZORTEA, 2019).

Entretanto, a atmosfera não é o único fator determinante da quantidade de radiação solar que atinge a superfície terrestre. O movimento de translação da Terra em torno do Sol se dá em uma trajetória elíptica levemente excêntrica, o que implica em pequenas variações da distância Terra-Sol ao longo do ano. Assim, a radiação solar que atinge a superfície se altera conforme a lei do inverso do quadrado da distância (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

Além disso, o eixo da Terra apresenta uma inclinação de aproximadamente $23^{\circ}27'$ em relação ao plano de sua órbita em torno do Sol. Essa característica, em conjunto com o movimento de translação, faz com que o ângulo formado entre o plano do Equador e a reta imaginária que liga os centros da Terra e do Sol seja modificado ao longo do ano. Tal ângulo recebe o nome de declinação solar δ e varia de $23^{\circ}27'$ S a $23^{\circ}27'$ N, conforme ilustra a Figura 3 (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

Figura 3 – Variação anual da declinação solar



Fonte: adaptado de Varejão-Silva (2006) e Vianello e Alves (2012).

O dia 23 de setembro (equinócio) marca o início da primavera no Hemisfério Sul, momento no qual a declinação solar é nula. A declinação solar aumenta no sentido sul até o início do verão em 21 de dezembro (solstício), quando δ atinge o valor de $23^{\circ}27'$ S. A partir daí, δ decresce até tornar-se nulo em 21 de março (equinócio), quando começa o outono. O valor máximo da declinação no sentido norte ocorre em 22 de junho (solstício), com o início do inverno, e volta a diminuir até atingir o valor nulo em 23 de setembro, retomando o ciclo² (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VAREJÃO-SILVA, 2006; VIANELLO; ALVES, 2012).

Entre os equinócios de setembro e março (do ano seguinte) o Hemisfério Sul recebe mais radiação solar do que o Hemisfério Norte, sendo que o maior suprimento energético (maior área iluminada) ocorre no dia do solstício de dezembro. Esse comportamento se inverte entre 21 de março e 23 de setembro (VAREJÃO-SILVA, 2006).

A alteração no comportamento médio da atmosfera resultante das variações na quantidade de energia solar recebida é expressa sobretudo por mudanças na temperatura. Essas variações são mais acentuadas nos locais de maior latitude e têm efeitos nos mais diversos aspectos, como chuva, vento e umidade do ar (VAREJÃO-SILVA, 2006; VIANELLO; ALVES, 2012).

2.2 SALDO DE RADIAÇÃO

O saldo de radiação (R_n) pode ser definido como a diferença entre os fluxos de radiação incidente e de radiação refletida/emitida de uma superfície. No caso do saldo de radiação da superfície terrestre, é comum que seja feita uma diferenciação entre radiação de ondas curtas e radiação de ondas longas. A radiação de ondas curtas é caracterizada pelos comprimentos de onda inferiores a 3.000 nm, sendo que a radiação solar é constituída predominantemente de ondas nessa faixa (Figura 1) (ALLEN; TASUMI; TREZZA, 2007; PEREIRA; ANGELOCCI; SENTELHAS, 2002; VAREJÃO-SILVA, 2006).

Como visto anteriormente, a radiação solar (ondas curtas) que incide sobre a Terra é suscetível aos efeitos atenuantes da atmosfera. Os componentes atmosféricos provocam a reflexão, o espalhamento, a absorção e a transmissão da radiação e

² No Hemisfério Norte as estações ocorrem de maneira oposta.

apenas uma parcela da radiação extraterrestre atinge de fato a superfície (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

A parcela de radiação solar que chega à superfície também interage com a matéria, podendo ser absorvida ou refletida. Nesse sentido, o saldo de radiação de ondas curtas (R_n^S) é definido com a diferença entre a radiação de ondas curtas incidente (R_S^\downarrow) e a radiação de ondas curtas refletida (R_S^\uparrow) (ALLEN; TASUMI; TREZZA, 2007; PEREIRA; ANGELOCCI; SENTELHAS, 2002).

A radiação refletida, contudo, depende das características de cada material, que definem a proporção da radiação incidente refletida pela superfície. A essa proporção se dá o nome de albedo, α . O albedo varia conforme as propriedades físicas dos materiais que compõem a superfície e também de acordo com o ângulo zenital do Sol. Em áreas vegetadas, há variações do albedo em função da espécie, fase de desenvolvimento, sanidade, geometria das copas das árvores e índice de área foliar (LAI – *Leaf Area Index*), além de outras características das plantas (ALLEN; TASUMI; TREZZA, 2007; PEREIRA; ANGELOCCI; SENTELHAS, 2002; VAREJÃO-SILVA, 2006; VIANELLO; ALVES, 2012).

Dentre os processos desencadeados na superfície pela absorção de R_S^\downarrow está o aumento da temperatura da superfície devido à sua conversão em energia térmica. Esse fenômeno também ocorre durante a passagem da radiação pela atmosfera, provocando aumento da temperatura do ar em razão da absorção pelos seus constituintes. Dessa forma, tanto a superfície terrestre quanto a atmosfera emitem radiação eletromagnética. Contudo, os comprimentos de onda dessa radiação são maiores pelo fato de estes elementos apresentarem menores temperaturas (conforme lei de Wien), caracterizando-a como radiação de ondas longas (VIANELLO; ALVES, 2012; ZANOTTA; FERREIRA; ZORTEA, 2019).

Nesse sentido, o saldo de radiação de ondas longas R_n^L resulta da diferença entre a radiação de ondas longas emitida pela atmosfera em direção à superfície (R_L^\downarrow), a parcela desta que é refletida, e a radiação emitida pela superfície em direção à atmosfera (R_L^\uparrow). A parcela de radiação refletida, nesse caso, é a radiação incidente descontada a parcela absorvida, que varia em função da absortividade. Pela lei de Kirchhoff e assumindo-se condição de equilíbrio termodinâmico, a absortividade da superfície é igual à sua emissividade ε_s (ALLEN; TASUMI; TREZZA, 2007; VIANELLO; ALVES, 2012).

A partir da soma dos saldos de radiação de ondas curtas e longas se define o saldo de radiação (R_n). O saldo de radiação constitui a quantidade de energia disponível para os processos que ocorrem na superfície. Quando estimado em um instante de tempo (por exemplo, no instante de aquisição de uma imagem de satélite), é chamado de saldo de radiação instantâneo (ALLEN; TASUMI; TREZZA, 2007).

O balanço de energia de um sistema pode ser influenciado por fluxos advectivos, isto é, por trocas laterais de energia, que ocorrem no sentido horizontal de predominância dos ventos. Ao desconsiderar-se tais fluxos e a parcela de energia absorvida na fotossíntese (inferior a 3% de R_n), o balanço de energia da superfície pode ser escrito como (BASTIAANSEN et al., 1998; PEREIRA; ANGELOCCI; SENTELHAS, 2002)

$$R_n \approx G + H + LE \quad (3)$$

Dessa forma, o saldo de radiação é composto por parcelas de:

- a) Fluxo de calor do solo G : energia utilizada no aquecimento do solo;
- b) Fluxo de calor sensível H : energia utilizada no aquecimento do ar e das plantas;
- c) Fluxo de calor latente LE : fluxo de calor latente associado à evapotranspiração.

A proporção de G , H e LE varia conforme o tipo de cobertura da superfície. Áreas com teores de umidade elevados, como regiões vegetadas, têm predominância do fluxo de calor latente no processo de evapotranspiração (OLIVEIRA et al., 2019; PEREIRA; ANGELOCCI; SENTELHAS, 2002; SCHIRMBECK; FONTANA; ROBERTI, 2018; SILVA et al., 2021). Por consequência, o tipo de energia predominante também é dependente do regime pluviométrico (ALVES et al., 2022). Em áreas onde a disponibilidade hídrica é baixa, como áreas urbanas, a maior parte da energia compõe G e H , o que provoca elevação da temperatura do ar, das plantas e do solo (MIRANDA et al., 2022; PEREIRA; ANGELOCCI; SENTELHAS, 2002).

2.3 SALDO DE RADIAÇÃO E SENSORIAMENTO REMOTO

A utilização de técnicas de sensoriamento remoto tem sido crescente desde o lançamento dos primeiros satélites nas décadas de 1950 e 1960. Conforme Novo

(2008), o sensoriamento remoto produz informações a partir de sensores remotamente posicionados, os quais registram a interação entre a radiação eletromagnética e os elementos que compõem a superfície terrestre.

O emprego de dados de sensoriamento remoto na estimativa do saldo de radiação da superfície é uma prática largamente difundida. Trata-se de uma ferramenta viável e de baixo custo, que permite a avaliação de grandes regiões heterogêneas com boa precisão (SILVA et al., 2015; DEBASTIANI et al., 2018).

O saldo de radiação é um dos principais parâmetros utilizados na estimativa de evapotranspiração. Nesse aspecto, Courault, Seguin e Oliosio (2005) propuseram quatro categorias de classificação dos modelos de cálculo de evapotranspiração: métodos empíricos diretos, métodos residuais do balanço de energia, métodos determinísticos e métodos baseados em índices de vegetação.

Dentre os diversos modelos existentes destaca-se o *Surface Energy Balance Algorithm for Land* – SEBAL, desenvolvido por Bastiaanssen et al. (1998) nos Países Baixos. Este modelo é classificado como um método residual do balanço de energia, que é expresso pela equação (3) (BASTIAANSEN et al., 1998, 2005; COURAULT; SEGUIN; OLIOSSO, 2005).

O SEBAL requer informações da radiação eletromagnética na região do visível, do infravermelho próximo e do infravermelho termal, obtidas a partir de sensoriamento remoto. Alguns parâmetros comumente medidos em estações meteorológicas também são necessários para o processamento. No caso da estimativa apenas do saldo de radiação, os dados de sensoriamento remoto requeridos subsidiam a obtenção do albedo e da temperatura da superfície, além de índices de vegetação, enquanto a temperatura e a umidade relativa do ar são os parâmetros necessários provenientes de estações meteorológicas (ALLEN; TASUMI; TREZZA, 2007; BASTIAANSEN et al., 1998, 2005).

O modelo *Mapping Evapotranspiration with Internalized Calibration* – METRIC, proposto por Allen, Tasumi e Trezza (2007), deriva da formulação do SEBAL, utilizando o mesmo método de estimativa do saldo de radiação³. Os autores explicam que a principal diferença entre os métodos diz respeito à forma em que as informações das imagens são escolhidas e utilizadas na calibração dos fluxos de energia.

³ A formulação do modelo é apresentada na metodologia deste estudo.

No Brasil, há uma série de estudos utilizando o modelo SEBAL na determinação do balanço de energia, do saldo de radiação e da evapotranspiração da superfície terrestre. Por exemplo: Silva, Lopes e Azevedo (2005) utilizaram imagens Landsat 5 para estimar o balanço de radiação em áreas irrigadas na Bahia; Gusmão et al. (2012) determinaram o saldo de radiação na Ilha do Bananal (Tocantins) com imagens Landsat 5; Fausto et al. (2014) e Marques et al. (2017) avaliaram o saldo de radiação no Mato Grosso sobre áreas de Cerrado e de transição Amazônia-Cerrado, respectivamente, com imagens Landsat 5; Silva et al. (2015) aplicaram imagens Landsat 5 na estimativa do balanço radiativo da bacia hidrográfica do Mogi-Guaçu, São Paulo; Schirmbeck, Fontana e Roberti (2018) avaliaram os modelos OSEB (*One-Source Energy Balance*) e SEBAL na estimativa do balanço de energia de áreas agrícolas no Rio Grande do Sul; Oliveira et al. (2019) utilizaram imagens ASTER (*Advanced Spaceborne Thermal Emission Reflection Radiometer*) na investigação dos efeitos das mudanças de cobertura do solo no particionamento da energia da superfície, na Amazônia; Ferreira et al. (2020) avaliaram o saldo de radiação em uma região do semiárido brasileiro a partir de imagens Landsat 8; Miranda et al. (2022) estudaram os impactos da urbanização nos fluxos de energia de superfície na região metropolitana do Rio de Janeiro, utilizando imagens Landsat 5, 7 e 8.

Contudo, ao considerar-se apenas o estado de Santa Catarina, o número de estudos relacionados à aplicação de dados de sensoriamento remoto na determinação do balanço de energia da superfície é deveras reduzido.

Goergen (2010) fez uso do método de Penman-Monteith com dados de índice de área foliar derivados de imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*), a partir do qual foram realizadas estimativas de evapotranspiração sobre a bacia do Prata.

Uda (2012) e Uda, Corseuil e Kobiyama (2013, 2014) utilizaram o modelo SEBAL com imagens ASTER no mapeamento do saldo de radiação e na avaliação da evapotranspiração real da bacia do Alto Rio Negro (Santa Catarina/Paraná).

O modelo METRIC foi utilizado por Uda (2016) na determinação da evapotranspiração real da bacia do Rio Iguaçu (Santa Catarina/Paraná) a partir de imagens MODIS.

Debastiani et al. (2018) aplicaram o modelo SEBAL no mapeamento do saldo de radiação do Parque Nacional de São Joaquim (Santa Catarina), utilizando imagens provenientes do satélite Landsat 8.

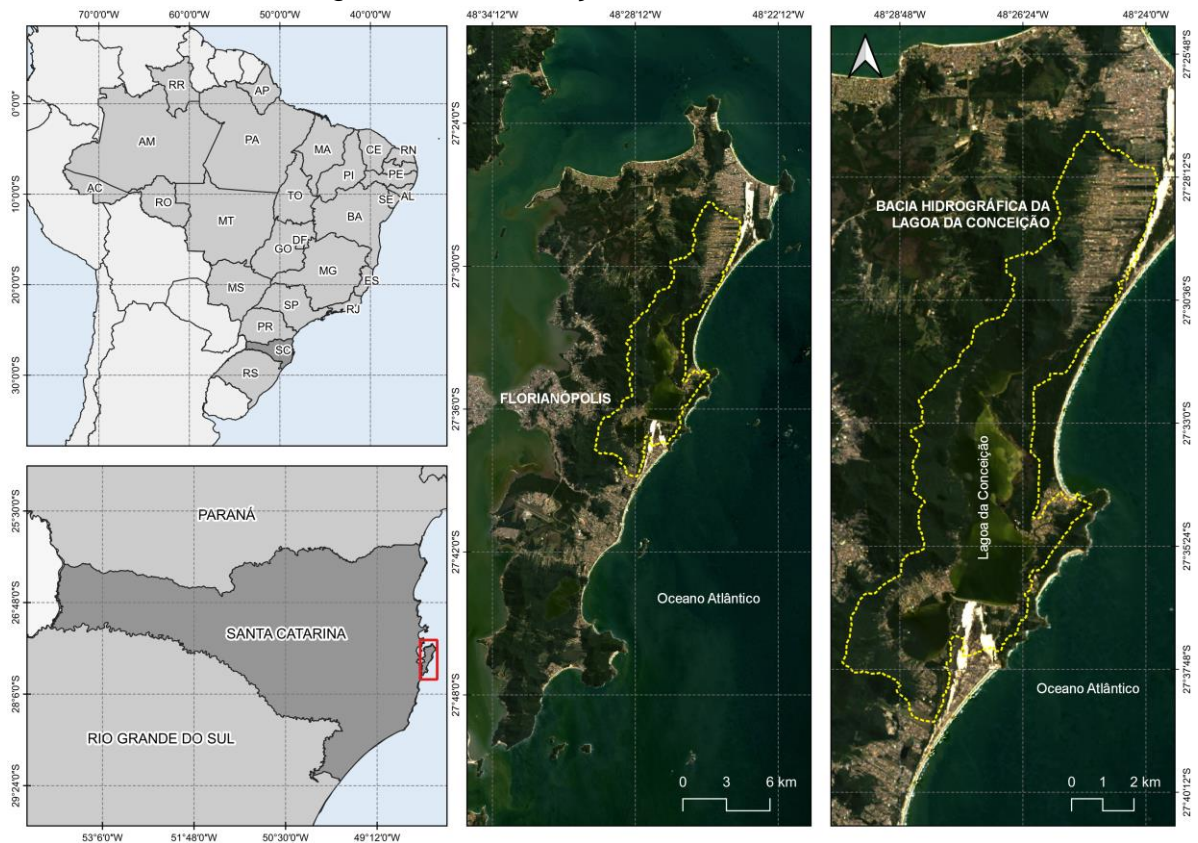
Em Florianópolis, foram encontrados apenas quatro trabalhos com aplicação de dados de sensoriamento remoto na determinação do balanço de energia da superfície: Lazarote (2007) e Corseuil et al. (2008) estimaram a evapotranspiração na bacia hidrográfica do Itacorubi a partir de correlação entre dados de evapotranspiração provenientes de estação climatológica e índice de vegetação obtido de imagens CBERS-2 (*China-Brazil Earth Resources Satellite*); Silva (2013) e Silva et al. (2017) utilizaram o modelo SEBAL e imagens Landsat 5 na determinação da evapotranspiração real diária e mensal na bacia hidrográfica da Lagoa da Conceição.

3 METODOLOGIA

3.1 ÁREA DE ESTUDO

A área de estudo do presente trabalho constitui-se da bacia hidrográfica da Lagoa da Conceição, localizada na parte insular do município de Florianópolis (Santa Catarina, Brasil). Seus limites se estendem desde a região central até o norte da ilha, entre as latitudes $27^{\circ}27'18,87''$ S – $27^{\circ}38'49,63''$ S e as longitudes $48^{\circ}23'46,54''$ W – $48^{\circ}29'55,57''$ W. O mapa de localização é apresentado na Figura 4.

Figura 4 – Localização da área de estudo



Fonte: elaborado pelo autor.

A bacia hidrográfica da Lagoa da Conceição possui área de 75,4 km², dos quais 20,7 km² correspondem ao corpo lagunar que dá nome à bacia. A Lagoa da Conceição apresenta formato alongado no sentido norte-sul, com 13,4 km de comprimento e largura variável entre 0,15 e 2,5 km. Ela é ligada ao oceano Atlântico pelo canal da Barra da Lagoa, que possui cerca de 3 km de extensão (SILVA, 2013).

O clima da região é classificado como subtropical úmido, apresentando verões quentes e ausência de estação seca (ALVARES et al., 2013). As normais climatológicas do período 1991-2020 para a estação Florianópolis (código 83897) indicam temperatura média anual de 21,1 °C e precipitação média anual de 1.766 mm (INMET, 2022). A Tabela 1 apresenta os valores mensais e anuais de temperatura, precipitação e insolação.

Tabela 1 – Normais climatológicas do período 1991-2020 para a estação climatológica Florianópolis

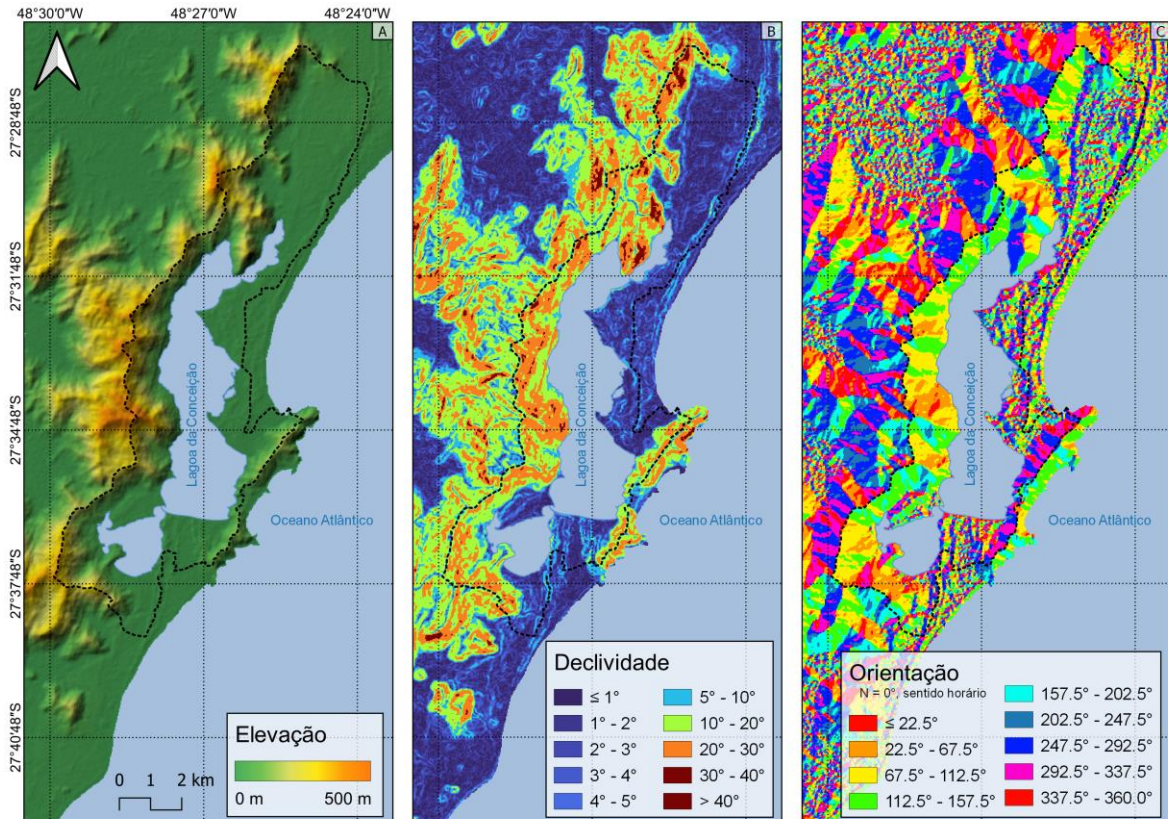
Mês	Temperatura (°C)			Precipitação (mm)	Insolação (h)
	Mínima	Média	Máxima		
Janeiro	21,6	25,2	29,4	241,3	190,7
Fevereiro	21,7	25,3	29,5	198,3	174,0
Março	20,7	24,4	28,7	180,4	186,7
Abril	18,7	22,4	26,9	115,8	179,5
Mai	15,7	19,5	24,0	126,2	173,4
Junho	13,6	17,2	21,9	86,3	153,0
Julho	12,9	16,5	21,1	100,8	162,2
Agosto	13,8	17,4	21,8	93,0	166,7
Setembro	15,4	18,7	22,4	146,9	141,3
Outubro	17,5	20,6	24,2	153,2	142,7
Novembro	18,8	22,3	26,1	146,6	180,5
Dezembro	20,5	24,2	28,3	177,2	191,2
Anual	17,6	21,1	25,4	1.766,0	2.041,9

Fonte: INMET (2022)

Conforme os dados da Tabela 1, os meses de verão apresentam temperatura média de 25 °C e acumulam os maiores valores de precipitação (35% do total anual) e de insolação (27% do total anual). Nos meses de inverno se registra temperatura média de 17,5 °C, o segundo menor acumulado de chuva (19,3% do total anual) e a menor insolação (23% do total anual). As outras estações apresentam valores intermediários – com exceção dos índices pluviométricos no outono, que acumulam o menor valor anual.

O relevo da área de estudo é caracterizado por uma região de morros na porção oeste, com altitudes de até 500 m e cobertura de Floresta Ombrófila densa (FOD), e uma região predominantemente plana na porção leste, com presença importante de restinga, embora também se verifique a presença de morro com altitude de cerca de 200 m (SILVA, 2013). A Figura 5 apresenta mapas de elevação, declividade e orientação do relevo na bacia hidrográfica da Lagoa da Conceição.

Figura 5 – Mapas de elevação (A), declividade (B) e orientação do terreno (C) na região da área de estudo



Fonte: elaborado pelo autor com base em NASA JPL (2020).

Nota: linha preta tracejada indica a área de estudo.

De acordo com Lopes et al. (2020), a bacia hidrográfica da Lagoa da Conceição experimentou significativo aumento na urbanização nas últimas décadas, variando de 3,5% em 1993 para 10,5% em 2013. Em 2018, conforme mapa de uso do solo elaborado por Martins e Ferretti (2019), as áreas urbanizadas representavam cerca de 12% da bacia. Além disso, há predomínio de floresta ombrófila densa (FOD, 34%), pastagem (12%) e vegetação de planície (11%).

3.2 SELEÇÃO DE AMOSTRAS DE COBERTURA DO SOLO

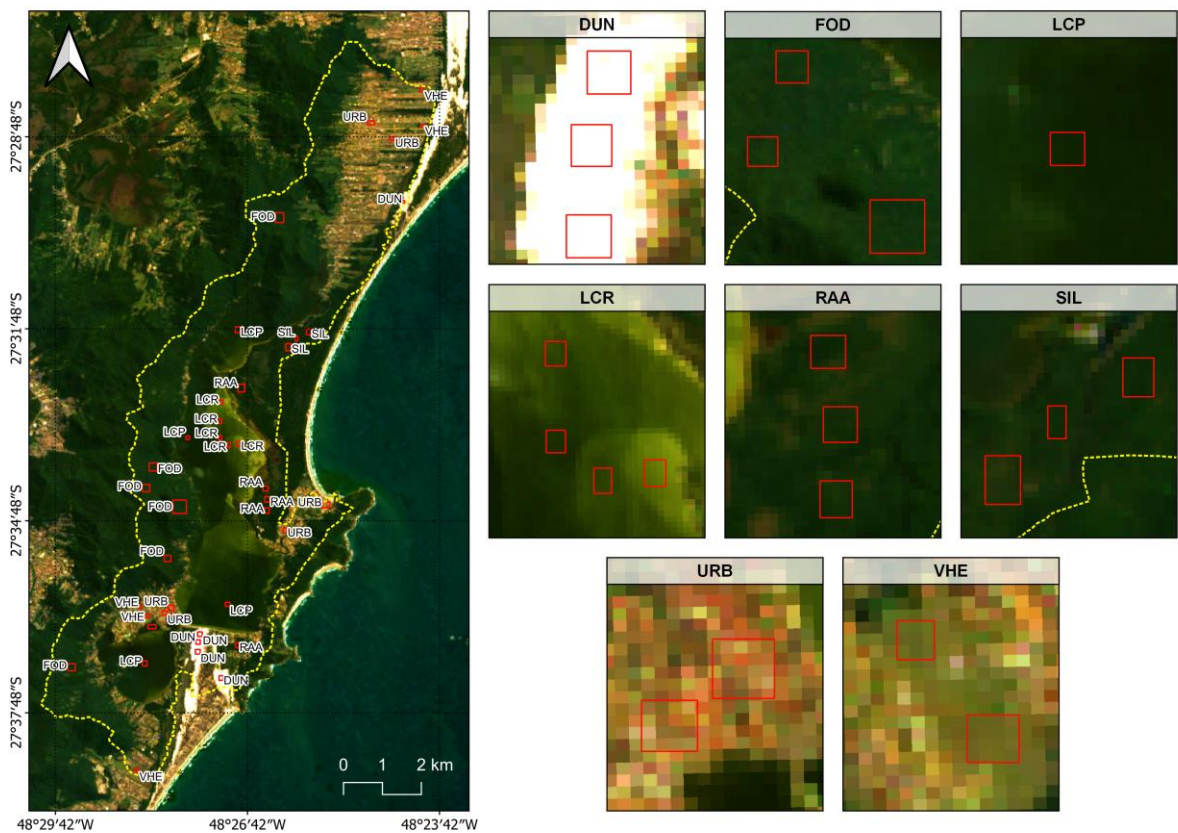
No intuito de se avaliar o albedo e os saldos de radiação para diferentes classes de cobertura do solo, determinou-se um conjunto de polígonos amostrais representativos de 8 classes de interesse. São elas:

- DUN: dunas;
- FOD: floresta ombrófila densa;
- LCP: águas da Lagoa da Conceição na região profunda;

- LCR: águas da Lagoa da Conceição na região rasa;
- RAA: restinga arbustiva-arbórea;
- SIL: silvicultura (pinus);
- URB: áreas urbanas;
- VHE: vegetação herbácea.

A Figura 6 apresenta um mapa com a distribuição dos polígonos amostrais.

Figura 6 – Distribuição dos polígonos amostrais na área de estudo



Fonte: elaborado pelo autor.

As amostras foram definidas com base na primeira e na última imagem do conjunto selecionado, de forma a se evitar locais com cobertura do solo alterada ao longo do tempo. Além disso, tentou-se evitar *pixels* com grande mistura espectral por meio da seleção de amostras em regiões homogêneas. As assinaturas espectrais também foram extraídas.

3.3 DADOS DE SENSORIAMENTO REMOTO

Os dados de sensoriamento utilizados foram obtidos e processados por meio da plataforma *Google Earth Engine* (GEE), que permite o processamento em alta performance de grandes conjuntos de dados geoespaciais (GORELICK et al., 2017). Os códigos⁴ – disponíveis nos apêndices J, K e L – foram escritos em linguagem *Python* (versão 3.8.12) e executados no ambiente de desenvolvimento integrado *Spyder* (versão 5.1.5).

3.3.1 Reflectância e temperatura de superfície

Para o presente estudo foram selecionadas imagens Landsat 8 SR (*Surface Reflectance*), *paths* 219/220 e *row* 79, pertencentes à Coleção 2, Nível 2, *Tier* 1 e adquiridas entre abril de 2013 e setembro de 2022. Os produtos selecionados já são processados pelo algoritmo *Land Surface Reflectance Code* (LaSRC) e fornecem bandas com reflectância e temperatura de superfície (USGS, 2022).

O satélite Landsat 8 é equipado com os seguintes sensores:

- a) OLI – *Operational Land Imager*: produz imagens multiespectrais da superfície em 9 bandas com resolução espacial de 30 m e resolução radiométrica de 12 *bits* (disponibilizadas com 16 *bits*). A Tabela 2 apresenta as características das bandas espectrais Landsat-8 OLI utilizadas no estudo;
- b) TIRS – *Thermal Infrared Sensor*: possibilita a determinação da temperatura de superfície a partir de 2 bandas termais com resolução espacial de 100 m. A banda de temperatura de superfície é reamostrada para resolução espacial de 30 m pela *United States Geological Survey* (USGS, 2022).

Tabela 2 – Características espectrais das bandas Landsat 8 OLI

Banda	B2 (azul)	B3 (verde)	B4 (vermelho)	B5 (NIR)	B6 (SWIR 1)	B7 (SWIR 2)
λ (nm)	452 – 512	533 – 590	636 – 673	851 – 879	1.566 – 1.651	2.107 – 2.294

Fonte: elaborado pelo autor com base em USGS (2022).

⁴ Dados e códigos disponíveis no repositório GitHub: https://github.com/b-rech/net_radiation

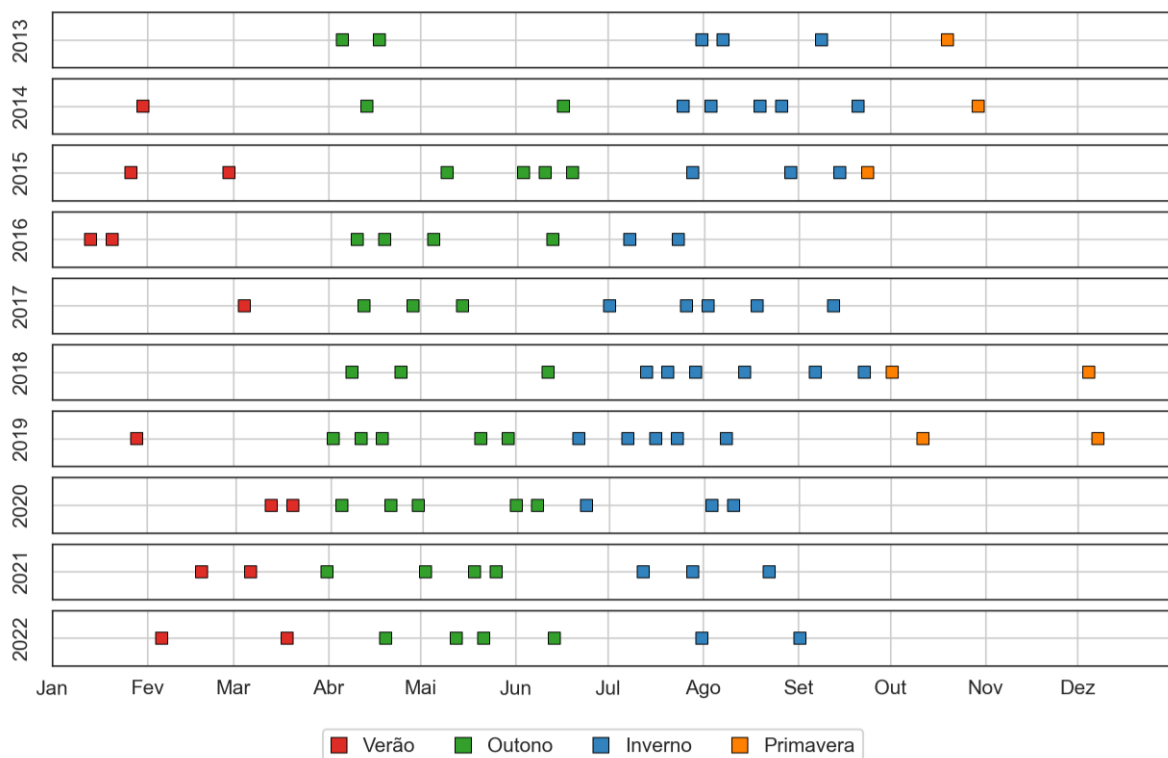
A seleção das cenas levou em consideração o nível de processamento, a qualidade das bandas OLI e TIRS e a cobertura de nuvens sobre a área de estudo. Assim, apenas as cenas com todas as bandas de reflectância e temperatura de superfície disponíveis, qualidade máxima dos sensores e cobertura de nuvens igual ou inferior a 5% na área de estudo foram consideradas adequadas.

A determinação da cobertura de nuvens foi realizada com base no *bit 6* da máscara *QA_PIXEL*, que identifica os *pixels* que representam nuvens ou nuvens dilatadas. Tais *pixels* foram removidos das cenas selecionadas.

A bacia hidrográfica da Lagoa da Conceição é privilegiada por sua localização em uma região coberta por dois *paths* da órbita do satélite Landsat 8. Como consequência, são geradas imagens da área a aproximadamente cada 9 dias, enquanto o tempo de revisita do satélite é de 16 dias.

A etapa de seleção gerou um conjunto de 96 cenas. Contudo, as análises das assinaturas espectrais das amostras apontaram problemas em 3 delas, nas quais a banda *QA_PIXEL* apresentou falha na representação adequada da cobertura de nuvens. Uma vez removidos os dados com problemas, obteve-se um conjunto final com 93 imagens. A distribuição temporal do conjunto é ilustrada na Figura 7.

Figura 7 – Distribuição temporal das imagens utilizadas no estudo



Fonte: elaborado pelo autor.

A Figura 7 evidencia a predominância de imagens disponíveis nos meses de outono (36) e inverno (37), que representam 78,4% dos dados. A primavera (7) e o verão (13) incluem 7,5% e 14,0% das cenas selecionadas, respectivamente, sendo que em alguns anos se registra a ausência de imagens representando essas estações.

A distribuição temporal desigual de cenas se deve à indisponibilidade por cobertura de nuvens acima do limite estabelecido (5%). As normais climatológicas do INMET indicam que a precipitação total média dos meses de primavera e verão é de 1.097 mm, em contraponto a 669 mm nos meses de outono e inverno. O número de dias com precipitação também é maior nas estações mais chuvosas, o que resulta em um grande número de imagens cobertas por nuvens nesses períodos.

A lista completa das imagens selecionadas, suas respectivas datas de aquisição, cobertura de nuvens na área de estudo e outras informações de interesse é apresentada no Apêndice A.

3.3.2 Elevação

As altitudes foram obtidas do modelo digital de elevação (MDE) NASADEM, com resolução espacial de 30 m. Este modelo é proveniente do reprocessamento de dados SRTM (*Shuttle Radar Topography Mission*) com acurácia aprimorada pela incorporação de dados auxiliares (NASA JPL, 2020). A declividade e a orientação do terreno foram derivadas do mesmo MDE.

3.4 DADOS METEOROLÓGICOS

Os dados meteorológicos utilizados nas análises são provenientes da estação meteorológica automática A806 do Instituto Nacional de Meteorologia (INMET), localizada no município de São José (SC), na latitude 27°36'00" S e longitude 48°37'12" W. Trata-se da estação mais próxima da área de estudo (aproximadamente 12 km) com dados disponibilizados em frequência horária e em tempo real.

Foram empregados os valores de temperatura T_a (°C) e umidade relativa u_r do ar da hora seguinte ao momento de aquisição das imagens de satélite (isto é, 14h). Os valores estão disponíveis no Apêndice B.

3.5 CÁLCULO DO SALDO DE RADIAÇÃO

O saldo de radiação instantâneo R_n (Wm^{-2}) de uma superfície pode ser definido pela expressão (PEREIRA; ANGELOCCI; SENTELHAS, 2002):

$$R_n = R_n^S + R_n^L \quad (4)$$

onde:

R_n^S = saldo de radiação de ondas curtas (Wm^{-2});

R_n^L = saldo de radiação de ondas longas (Wm^{-2}).

Por sua vez, o saldo de radiação de ondas curtas R_n^S (Wm^{-2}) é definido como a diferença entre a radiação de ondas curtas incidente e refletida pela superfície (PEREIRA; ANGELOCCI; SENTELHAS, 2002):

$$R_n^S = R_S^\downarrow - R_S^\uparrow \quad (5)$$

onde:

R_S^\downarrow = radiação de ondas curtas incidente (Wm^{-2});

R_S^\uparrow = radiação de ondas curtas emitida (Wm^{-2}).

Entretanto, R_S^\uparrow é equivalente à parcela de R_S^\downarrow refletida pela superfície, a qual é definida em função do albedo. Assim, podemos reescrever a equação (5) como:

$$R_n^S = (1 - \alpha_s)R_S^\downarrow \quad (6)$$

onde:

α_s = albedo da superfície.

De maneira análoga, o saldo de radiação instantâneo de ondas longas R_n^L (Wm^{-2}) é dado por (ALLEN; TASUMI; TREZZA, 2007; PEREIRA; ANGELOCCI; SENTELHAS, 2002):

$$R_n^L = R_L^\downarrow - R_L^\uparrow - (1 - \varepsilon_s)R_L^\downarrow \quad (7)$$

onde:

R_L^\downarrow = radiação de ondas longas incidente (Wm^{-2});

R_L^\uparrow = radiação de ondas longas emitida (Wm^{-2});

ε_s = emissividade da superfície.

Na equação (7), o termo $(1 - \varepsilon_s)R_L^\downarrow$ se refere à parcela de radiação de ondas longas incidente que é refletida pela superfície (ALLEN; TASUMI; TREZZA, 2007).

Substituindo as equações (6) e (7) em (4) e simplificando, tem-se:

$$R_n = (1 - \alpha_s)R_S^\downarrow - R_L^\uparrow + \varepsilon_s R_L^\downarrow \quad (8)$$

Para a estimativa dos parâmetros acima descritos, o presente estudo baseou-se no modelo METRIC – *Mapping Evapotranspiration with Internalized Calibration*, proposto por Allen, Tasumi e Trezza (2007) com o objetivo de estimar a evapotranspiração por meio de dados de sensoriamento remoto. As equações e a origem dos dados utilizados são descritas na sequência.

3.5.1 Radiação de ondas curtas incidente

A radiação de ondas curtas que incide sobre a superfície, R_S^\downarrow (Wm^{-2}), foi estimada pela equação (ALLEN; TASUMI; TREZZA, 2007):

$$R_S^\downarrow = \frac{G_{sc} \cos \theta_{rel} \tau_{sw}}{d^2} \quad (9)$$

onde:

G_{sc} = constante solar (W m^{-2});

θ_{rel} = ângulo de incidência solar (rad);

τ_{sw} = transmissividade atmosférica no domínio da banda larga (adimensional);

d = distância relativa Terra-Sol (UA).

Utilizou-se G_{sc} igual a 1.367 Wm^{-2} , valor adotado pelo *World Radiation Center* com incerteza na ordem de 1% (DUFFIE; BECKMAN, 2013). A distância relativa Terra-Sol foi obtida dos metadados das imagens Landsat 8 utilizadas. Além disso, quando se assume que a área de interesse é plana, θ_{rel} torna-se constante e é obtido pela equação (21). No presente estudo, a topografia foi levada em consideração e θ_{rel} foi estimado para cada pixel pela equação (15).

A transmissividade atmosférica no domínio da banda larga τ_{sw} foi calculada por (ALLEN et al., 2005; ALLEN; TASUMI; TREZZA, 2007):

$$\tau_{sw} = 0,35 + 0,627 \exp \left[\frac{-0,00146P}{K_t \cos \theta_{hor}} - 0,075 \left(\frac{W}{\cos \theta_{hor}} \right)^{0,4} \right] \quad (10)$$

onde:

P = pressão atmosférica (kPa);

W = água precipitável na atmosfera (mm);

K_t = coeficiente de turbidez da atmosfera (adimensional);

θ_{hor} = ângulo zenital solar sobre uma superfície horizontal (rad).

Adotou-se $K_t = 1$, conforme recomendação de Allen et al. (2005) para predições rotineiras do saldo de radiação.

A partir dos dados provenientes da estação meteorológica, a pressão de saturação do vapor d'água sobre uma superfície plana de água pura e_w (kPa) foi calculada por (WMO, 2018):

$$e_w = 0,6112 \exp \left[\frac{17,62T_a}{243,12 + T_a} \right] \quad (11)$$

onde:

T_a = temperatura do ar (K), obtida da estação meteorológica.

Na sequência, a pressão real de vapor do ar e_a (kPa) foi obtida (WMO, 2018):

$$e_a = u_r e_w (1,0016 + 3,15 \times 10^{-5}P - 0,074P^{-1}) \quad (12)$$

onde:

P = pressão atmosférica (kPa);

u_r = umidade relativa do ar (adimensional).

Por sua vez, a quantidade de água precipitável na atmosfera W (mm) foi determinada pela equação (ALLEN et al., 2005; GARRISON; ADLER, 1990):

$$W = 0,14e_a P + 2,1 \quad (13)$$

A pressão atmosférica P (kPa) foi calculada pixel a pixel pela formulação simplificada da Lei Universal dos Gases dada pela equação (ALLEN et al., 2005):

$$P = 101,3 \left(\frac{293 - 0,0065z}{293} \right)^{5,26} \quad (14)$$

onde:

293 = temperatura padrão do ar (K);

z = altitude em relação ao nível do mar (m) obtida do modelo digital de elevação.

O cosseno do ângulo de incidência solar θ_{rel} (rad) foi obtido pela equação (DUFFIE; BECKMAN, 2013):

$$\begin{aligned} \cos \theta_{rel} = & \text{sen } \delta \text{ sen } \phi \text{ cos } \beta \\ & - \text{sen } \delta \text{ cos } \phi \text{ sen } \beta \text{ cos } \gamma \\ & + \text{cos } \delta \text{ cos } \phi \text{ cos } \beta \text{ cos } \omega \\ & + \text{cos } \delta \text{ sen } \phi \text{ sen } \beta \text{ cos } \gamma \text{ cos } \omega \\ & + \text{cos } \delta \text{ sen } \gamma \text{ sen } \beta \text{ sen } \omega \end{aligned} \quad (15)$$

onde:

δ = declinação solar (rad);

ϕ = latitude do pixel (rad);

β = declividade da superfície, entre 0 e $\pi/2$ (rad);

γ = orientação do relevo, entre sul = 0, leste = $\pi/2$, oeste = $-\pi/2$, norte = $\pm\pi$ (rad);

ω = ângulo horário (rad).

A declividade e a orientação do terreno foram derivadas do modelo digital de elevação NASADEM (NASA JPL, 2020).

Por sua vez, a declinação solar δ (rad) foi calculada pela primeira equação de Spencer (DUFFIE; BECKMAN, 2013):

$$\begin{aligned} \delta = & 0,006918 - 0,399912 \text{ cos } B + 0,070257 \text{ sin } B \\ & - 0,006758 \text{ cos } 2B + 0,000907 \text{ sin } 2B \\ & - 0,002697 \text{ cos } 3B + 0,00148 \text{ sin } 3B \end{aligned} \quad (16)$$

onde:

B = parâmetro obtido da equação (20).

O ângulo horário ω (rad) – nulo ao meio-dia, negativo pela manhã, positivo à tarde e variando 15° ($\pi/12$ rad) a cada hora – foi calculado por (VIANELLO; ALVES, 2012):

$$\omega = \frac{\pi}{12}(h_s - 12) \quad (17)$$

onde:

h_s = hora solar obtida da equação (18).

Conforme Duffie e Beckman (2013), a hora solar h_s se refere ao horário baseado no movimento angular aparente do Sol, cujo meio-dia coincide com o momento em que o Sol cruza o meridiano do observador. Seu cálculo utilizou a seguinte expressão:

$$h_s = h + 4(L_{st} - L_{loc}) + E \quad (18)$$

onde:

h = horário local;

L_{st} = longitude do meridiano padrão do fuso-horário local (entre 0 e 360° a oeste);

L_{loc} = longitude do local em questão (graus, a oeste);

E = obtido da equação (19).

Adotou-se L_{loc} igual à longitude (em valor absoluto) do centroide da região de estudo (48,447014 graus), por se tratar de uma área de pequena extensão. Para a região, L_{st} é igual a 45 graus.

O parâmetro E foi calculado pela segunda equação de Spencer (equação do tempo) e utiliza o parâmetro B que, por sua vez, é função do dia n do ano (DUFFIE; BECKMAN, 2013):

$$E = 2,292(0,0075 + 0,1868 \cos B - 3,2077 \sin B - 1,4615 \cos 2B - 4,089 \sin 2B) \quad (19)$$

onde:

$$B = (n - 1) \frac{2\pi}{365} \quad (20)$$

O cosseno do ângulo zenital solar sobre uma superfície plana, θ_{hor} (rad) foi calculado por (ALLEN; TASUMI; TREZZA, 2007):

$$\cos \theta_{hor} = \sin \delta \sin \phi + \cos \delta \cos \phi \cos \omega \quad (21)$$

onde:

δ = declinação solar (rad);

ϕ = latitude do pixel (rad);

ω = ângulo horário (rad).

3.5.2 Albedo da superfície

Adotou-se o modelo proposto por Angelini et al. (2021) para a obtenção do albedo da superfície α_s a partir de imagens Landsat 8 OLI com reflectância de superfície, dado pela expressão:

$$\alpha_s = 0,4739\rho_2 - 0,4372\rho_3 + 0,1652\rho_4 + 0,2831\rho_5 + 0,1072\rho_6 + 0,1029\rho_7 + 0,0366 \quad (22)$$

onde:

$\rho_2 - \rho_7$ = reflectância de superfície das bandas 2 a 7 do sensor Landsat 8 OLI.

3.5.3 Radiação de ondas longas incidente

A radiação de ondas longas incidente R_L^\downarrow foi obtida a partir da equação de Stefan-Boltzmann em função das características da atmosfera (ALLEN; TASUMI; TREZZA, 2007):

$$R_L^\downarrow = \varepsilon_a \sigma T_a^4 \quad (23)$$

onde:

ε_a = emissividade atmosférica (adimensional);

σ = constante de Stefan-Boltzmann ($5,67 \times 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$);

T_a = temperatura do ar próximo à superfície (K).

Neste estudo, T_a foi substituída pela temperatura da superfície T_s (obtida das imagens Landsat 8 TIRS) na equação (23), pressupondo que o fluxo de radiação de

ondas longas que incide sobre a superfície é proporcional à sua temperatura (ALLEN; TASUMI; TREZZA, 2007).

A emissividade da atmosfera ε_a , por sua vez, foi calculada pela equação (ALLEN; TASUMI; TREZZA, 2007):

$$\varepsilon_a = 0,85(-\ln \tau_{sw})^{0,09} \quad (24)$$

onde τ_{sw} é a transmissividade atmosférica (adimensional), da equação (10).

3.5.4 Radiação de ondas longas emitida

A radiação de ondas longas emitida pela superfície R_L^\uparrow (Wm^{-2}) foi obtida em função de suas características de temperatura e emissividade, também pela equação de Stefan-Boltzmann (ALLEN; TASUMI; TREZZA, 2007):

$$R_L^\uparrow = \varepsilon_s \sigma T_s^4 \quad (25)$$

onde:

ε_s = emissividade da superfície no domínio da banda larga;

σ = constante de Stefan-Boltzmann ($5,67 \times 10^{-8} \text{ Wm}^{-2}\text{K}^{-4}$);

T_s = temperatura da superfície (K), proveniente dos dados Landsat 8 TIRS.

A emissividade da superfície ε_s foi calculada a partir do modelo proposto por Tasumi (2003):

$$\varepsilon_s = 0,95 + 0,01LAI \quad (26)$$

onde:

LAI = índice de área foliar.

Conforme o autor, para superfícies aquáticas adota-se $\varepsilon_s = 0,985$.

O índice de área foliar LAI , por sua vez, foi derivado de (ALLEN; TASUMI; TREZZA, 2007; BASTIAANSEN, 1998):

$$LAI = -\frac{1}{0,91} \ln\left(\frac{0,69 - SAVI}{0,59}\right) \quad (27)$$

onde:

$SAVI$ = índice de vegetação ajustado ao solo.

Para pixels com $LAI > 3$, adotou-se $LAI = 3$ no cálculo de ε_s (TASUMI, 2003). O $SAVI$ foi calculado conforme Huete (1988):

$$SAVI = (1 + L) \frac{NIR - RED}{NIR + RED + L} \quad (28)$$

onde:

NIR = reflectância na faixa do infravermelho próximo;

RED = reflectância na faixa do vermelho;

L = fator para minimização da influência do solo (adotado 0,5).

3.6 TESTES ESTATÍSTICOS

No presente trabalho, buscou-se verificar a existência de diferenças significativas dos saldos de radiação (R_n^S , R_n^L e R_n) entre as diferentes estações do ano. Uma vez que os dados não seguem distribuição normal, foram aplicados, inicialmente, testes de Kruskal-Wallis em todas as classes de cobertura do solo analisadas.

O teste não paramétrico de Kruskal-Wallis permite a comparação de três ou mais amostras independentes, e seu resultado indica se ao menos dois grupos diferem entre si. A hipótese nula é de que as médias dos grupos são iguais (HELSEL et al., 2020).

Verificada a existência de diferenças significativas entre os grupos, aplicou-se sequencialmente o teste *post hoc* de Dunn com *p-values* ajustados pelo método de Bonferroni. O objetivo desse teste é a identificação de quais grupos diferem entre si por meio da realização de múltiplas comparações entre estes. Nesse caso, a hipótese nula é de que as diferenças entre os grupos são aleatórias (HELSEL et al., 2020).

De modo a mitigar a influência de *outliers* nos resultados, tanto os testes de Kruskal-Wallis quanto os testes de Dunn foram aplicados às medianas das amostras de cada imagem. Assim, os grupos “primavera”, “verão”, “outono” e “inverno” tiveram, respectivamente, 7, 13, 36 e 37 amostras. Em ambos os testes se adotou um nível de significância de 5%, isto é, a hipótese nula é rejeitada quando *p-value* < 0,05. Os resultados são apresentados nos apêndices C, D, E e F.

4 RESULTADOS E DISCUSSÃO

4.1 CARACTERÍSTICAS DAS AMOSTRAS

As amostras definidas para análise contemplam as principais classes de cobertura do solo da bacia hidrográfica da Lagoa da Conceição. Considerando todas as cenas do conjunto de dados selecionado, foram amostrados 91.344 *pixels* (resolução espacial de 30 m) em cada banda espectral, cuja distribuição entre as classes é apresentada na Tabela 3.

Tabela 3 – Número de pixels amostrados por classe e por estação

Classes	Verão	Outono	Inverno	Primavera	Total
DUN – Dunas	855	2.295	2.394	462	6.006
FOD – Floresta Ombrófila Densa	5.044	13.937	14.217	2.685	35.883
LCP – Lagoa da Conceição – Profunda	923	2.556	2.607	497	6.583
LCR – Lagoa da Conceição – Rasa	923	2.556	2.592	497	6.568
RAA – Restinga Arbustiva-Arbórea	1.963	5.436	5.565	1.057	14.021
SIL – Silvicultura	806	2.232	2.294	434	5.766
URB – Área Urbana	1.625	4.454	4.570	875	11.524
VHE – Vegetação Herbácea	688	1.944	1.984	378	4.994
Total	12.827	35.409	36.223	6.885	91.345

Fonte: elaborado pelo autor.

A partir dos dados de reflectância dos *pixels* amostrados foram definidas as assinaturas espectrais (medianas) características das classes de uso do solo. A Figura 8 traz a indicação das reflectâncias medianas e do intervalo de valores entre os percentis 2,5% e 97,5%, e a Tabela 4 resume as medianas ilustradas na figura. Os valores extremos foram removidos apenas da visualização, e não dos cálculos.

Verifica-se que as classes associadas a formações vegetais (FOD, RAA, SIL e VHE) apresentam, como esperado, típico comportamento de vegetação. Elas indicam um pico de reflectância no comprimento do infravermelho próximo (B5), cuja mediana é de cerca de 0,41 para Floresta Ombrófila Densa e inferior a 0,30 nas outras classes. Também são verificadas baixas reflectâncias nas bandas do visível (B2, B3 e B4), dentre as quais se destaca o verde (B3). Na classe de vegetação herbácea o vermelho (B4) se aproxima do verde, provavelmente devido à influência da reflectância do solo.

Figura 8 – Assinaturas espectrais das amostras selecionadas

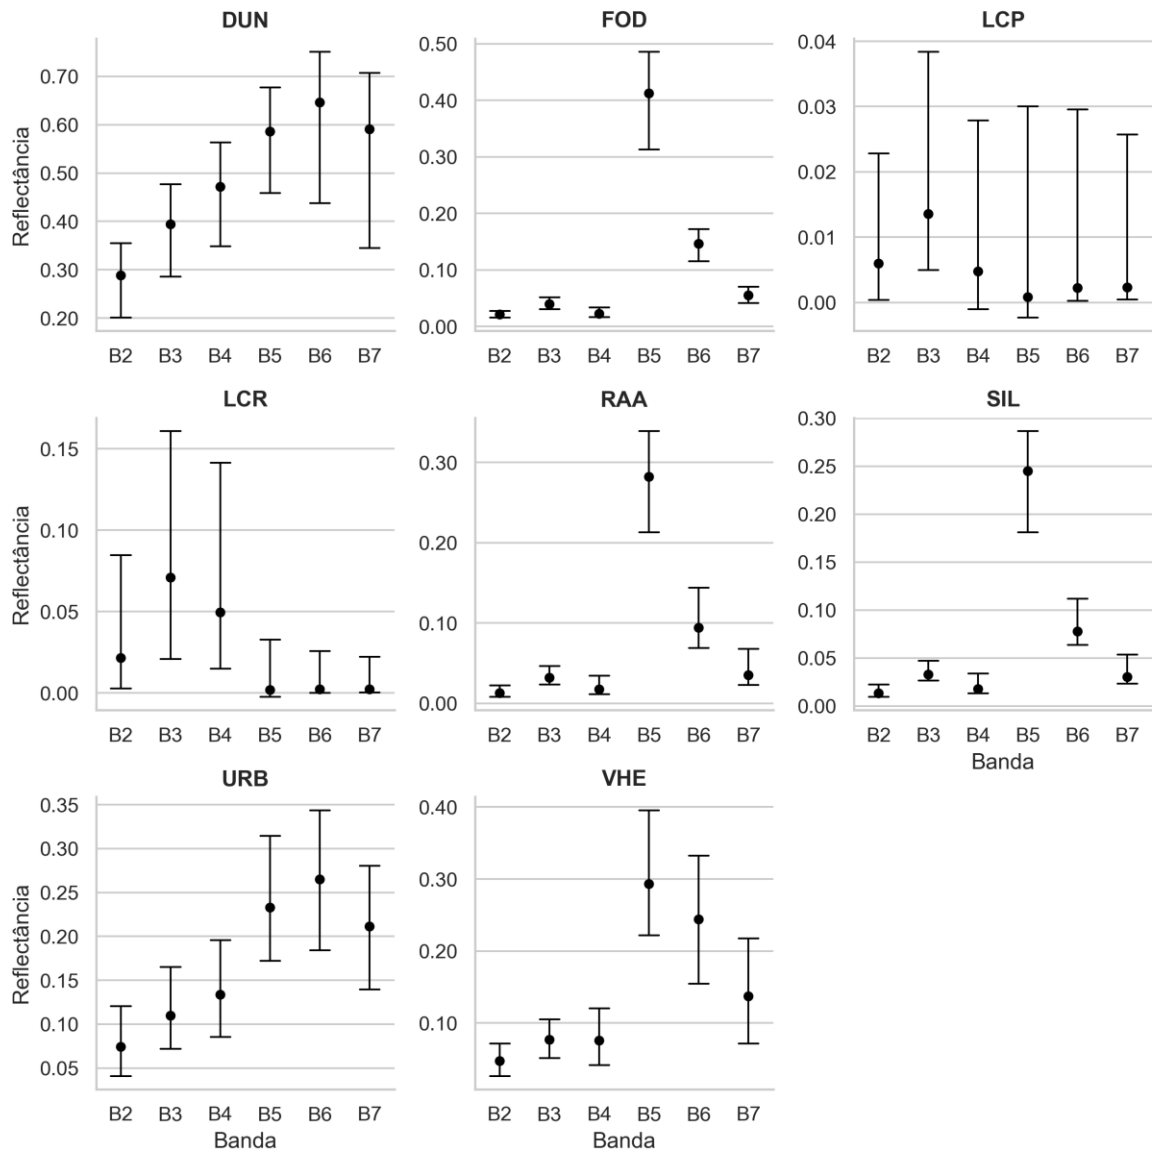


Tabela 4 – Reflectâncias medianas das amostras selecionadas

Classe	B2	B3	B4	B5	B6	B7
DUN – Dunas	0,288	0,394	0,471	0,586	0,646	0,591
FOD – Floresta Ombrófila Densa	0,021	0,039	0,022	0,412	0,146	0,055
LCP – Lagoa da Conceição – Profunda	0,006	0,014	0,005	0,001	0,002	0,002
LCR – Lagoa da Conceição – Rasa	0,021	0,071	0,049	0,002	0,002	0,002
RAA – Restinga Arbustiva-Arbórea	0,013	0,032	0,017	0,282	0,094	0,035
SIL – Silvicultura	0,013	0,033	0,017	0,245	0,078	0,030
URB – Área Urbana	0,074	0,110	0,133	0,233	0,265	0,211
VHE – Vegetação Herbácea	0,047	0,077	0,075	0,293	0,244	0,137

Fonte: elaborado pelo autor.

Outro ponto digno de nota é o comportamento espectral das classes que representam superfícies aquáticas. As reflectâncias medianas na região profunda da Lagoa da Conceição (LCP) são próximas de zero em todas as bandas, com um pico próximo a 0,01 na faixa do verde. Na região rasa (LCR) as reflectâncias na faixa do visível são maximizadas pela influência do fundo do corpo hídrico.

Em ambas as classes aquáticas, todavia, foram registrados alguns pixels com valores negativos – o que representa erro, dado que a reflectância só pode variar no intervalo de 0 a 1. Conforme o USGS (2019), esse tipo de situação se deve à inadequabilidade dos algoritmos de obtenção de reflectância e de correção atmosférica das imagens Landsat 8 para a água, em razão de suas baixas reflectâncias características.

4.2 ALBEDO DA SUPERFÍCIE

O albedo da superfície foi derivado das bandas espectrais caracterizadas anteriormente, conforme o modelo proposto por Angelini et al. (2021) – equação (22). Os valores médios obtidos para cada classe de cobertura do solo a partir de todos os *pixels* amostrados são apresentados na Tabela 5, enquanto a Figura 9 traz o mapa de albedo médio da área de estudo com detalhamento de algumas das amostras analisadas.

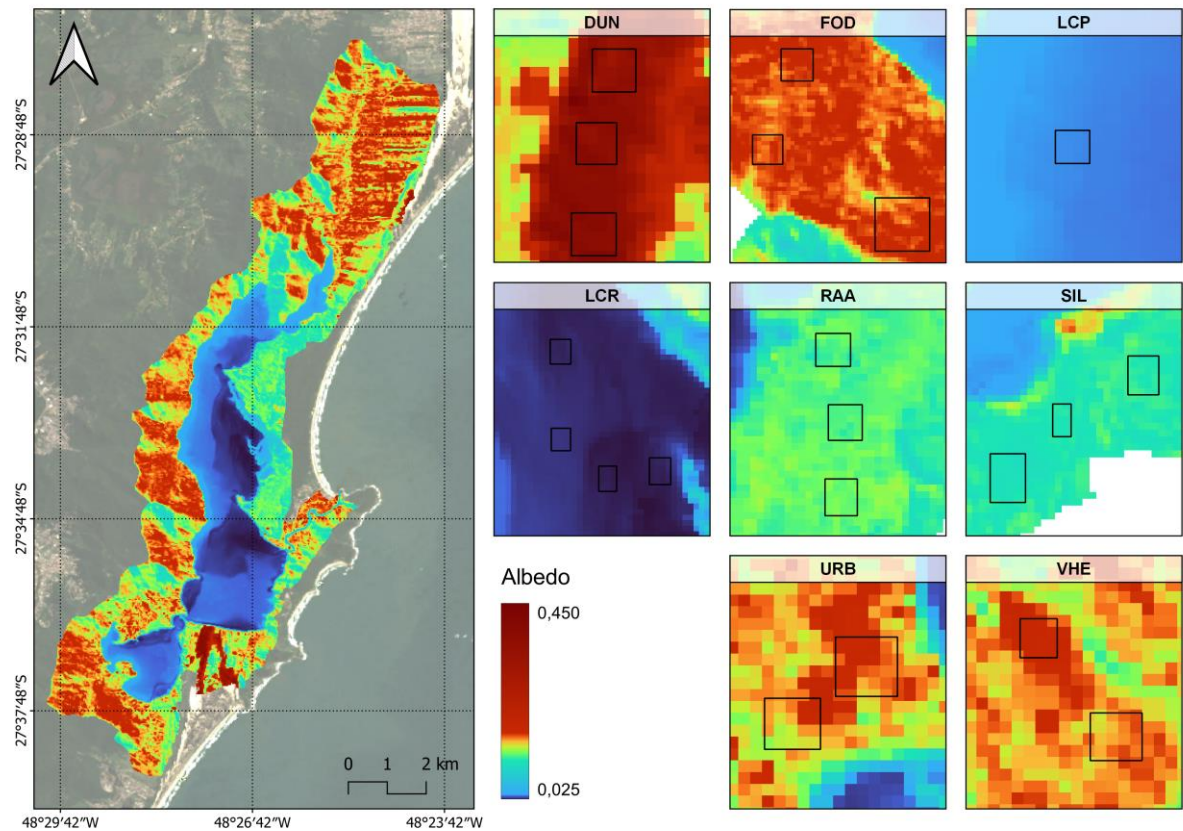
Tabela 5 – Albedos médios obtidos para as amostras analisadas

Classe	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Albedo	0,370	0,170	0,037	0,028	0,125	0,112	0,163	0,162
Desvio Padrão	0,039	0,015	0,005	0,006	0,009	0,007	0,021	0,017
Coef. de Variação	10,5%	8,6%	14,1%	22,6%	7,2%	5,9%	12,7%	10,5%

Fonte: elaborado pelo autor.

As variações nos valores de albedo são apresentadas em termos do coeficiente de variação, permitindo a comparação entre as diferentes classes. Dentre elas, aquelas representativas de superfícies aquáticas exibem as variações mais significativas. Esse comportamento pode ser atribuído em grande parte aos problemas que os produtos Landsat 8 OLI com reflectância de superfície têm em relação à água (como a presença de valores negativos e, por consequência, errôneos).

Figura 9 – Albedo médio na área de estudo



Na região rasa da Lagoa da Conceição (LCR) há ainda a influência da variação de profundidade, que provoca alterações na intensidade dos efeitos do fundo do corpo hídrico sobre as reflectâncias desses *pixels*. Outrossim, esperava-se que o albedo dessa classe fosse maximizado pela interferência do fundo arenoso em relação ao albedo na região profunda (LCP), o que não ocorreu. As regiões profundas (tons escuros de azul) e rasas (tons claros de azul) são facilmente distinguíveis na Figura 9.

Angelini et al. (2021) determinaram albedo médio de 0,07 em corpos d'água (baías de Chacororé e Siá Mariana) da região de transição dos biomas Cerrado/Pantanal, pelo mesmo modelo. Pela aplicação de uma formulação distinta em imagens Landsat 8 OLI com reflectância topo de atmosfera, Silva et al. (2016) obtiveram albedo médio de 0,05 para a água na região do semiárido brasileiro. Os valores usuais compilados por Pereira, Angelocci e Sentelhas (2002) e Vianello e Alves (2012) são de 0,05 para água, 0,02 para oceanos com incidência solar normal e 0,06 para oceanos com elevação solar de 60°.

Por sua vez, as dunas (DUN) apresentaram albedo médio característico de superfícies de areia, constituindo a classe mais refletiva dentre as analisadas (0,37). A bibliografia apresenta valores na faixa de 0,30 a 0,45 para areia seca e desertos, e 0,20 a 0,30 para areia úmida (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

Dentre as classes de vegetação, o maior albedo médio está associado à FOD, igual a 0,17. O menor valor, de 0,11, diz respeito à silvicultura (SIL). Para formações florestais, os valores médios característicos costumam variar de 0,07 a 0,15 (PEREIRA; ANGELOCCI; SENTELHAS, 2002; VIANELLO; ALVES, 2012).

Nas áreas de FOD da porção oeste da bacia hidrográfica é nítida a influência da orientação do relevo nos valores de albedo (Figura 9). As faces voltadas para sul são mais suscetíveis ao sombreamento, o que resultou em menores valores. As amostras analisadas, contudo, foram escolhidas de modo a evitar tais áreas.

A urbanização (URB) apresentou resultados muito semelhantes àqueles encontrados por Angelini et al. (2021) – albedo de 0,163 no presente estudo e de 0,162 no trabalho citado. Silva et al. (2016), contudo, encontraram albedo médio de áreas urbanas igual a 0,301, a partir de modelo para imagens Landsat 8 OLI sem correção atmosférica.

4.3 SALDO DE RADIAÇÃO DE ONDAS CURTAS

O saldo de radiação de ondas curtas apresentou médias anuais em um intervalo de aproximadamente 500 a 800 Wm^{-2} . A Tabela 6 resume as medianas por classe de cobertura do solo e por estação do ano.

Tabela 6 – Saldo de radiação de ondas curtas mediano (Wm^{-2})

Estação	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Verão	598,5	741,6	948,0	955,1	856,4	869,1	804,5	817,6
Outono	421,3	564,8	656,8	662,8	594,2	603,2	564,0	560,1
Inverno	409,4	567,8	629,6	633,3	574,5	582,7	547,6	539,0
Primavera	566,6	710,8	901,2	905,4	814,2	829,0	760,9	760,5
Média anual*	503,3	645,0	784,9	791,7	711,2	723,6	673,8	673,8

Fonte: elaborado pelo autor.

Legenda: *média anual ponderada pelo número de imagens em cada estação.

Os maiores saldos foram registrados nas classes representativas da superfície do corpo lagunar (LCP e LCR), com médias anuais em torno de 790 Wm^{-2} . Esse comportamento é ditado pelos baixos valores de albedo da água, cuja diminuição provoca um conseqüente aumento de R_n^S .

Em contraste, as dunas apresentaram R_n^S médio anual de 503 Wm^{-2} , constituindo o menor saldo entre as classes avaliadas. A grande capacidade da areia de refletir a radiação incidente faz com que a diferença entre as entradas e saídas de radiação diminua sensivelmente em relação às outras superfícies.

Nas classes de vegetação, RAA e SIL reportaram os maiores saldos de radiação de ondas curtas (711 e 724 Wm^{-2} , respectivamente). Já a floresta ombrófila densa apresentou R_n^S médio de 645 Wm^{-2} , isto é, a menor média dentre as classes de vegetação e a segunda menor média dentre todas as classes avaliadas.

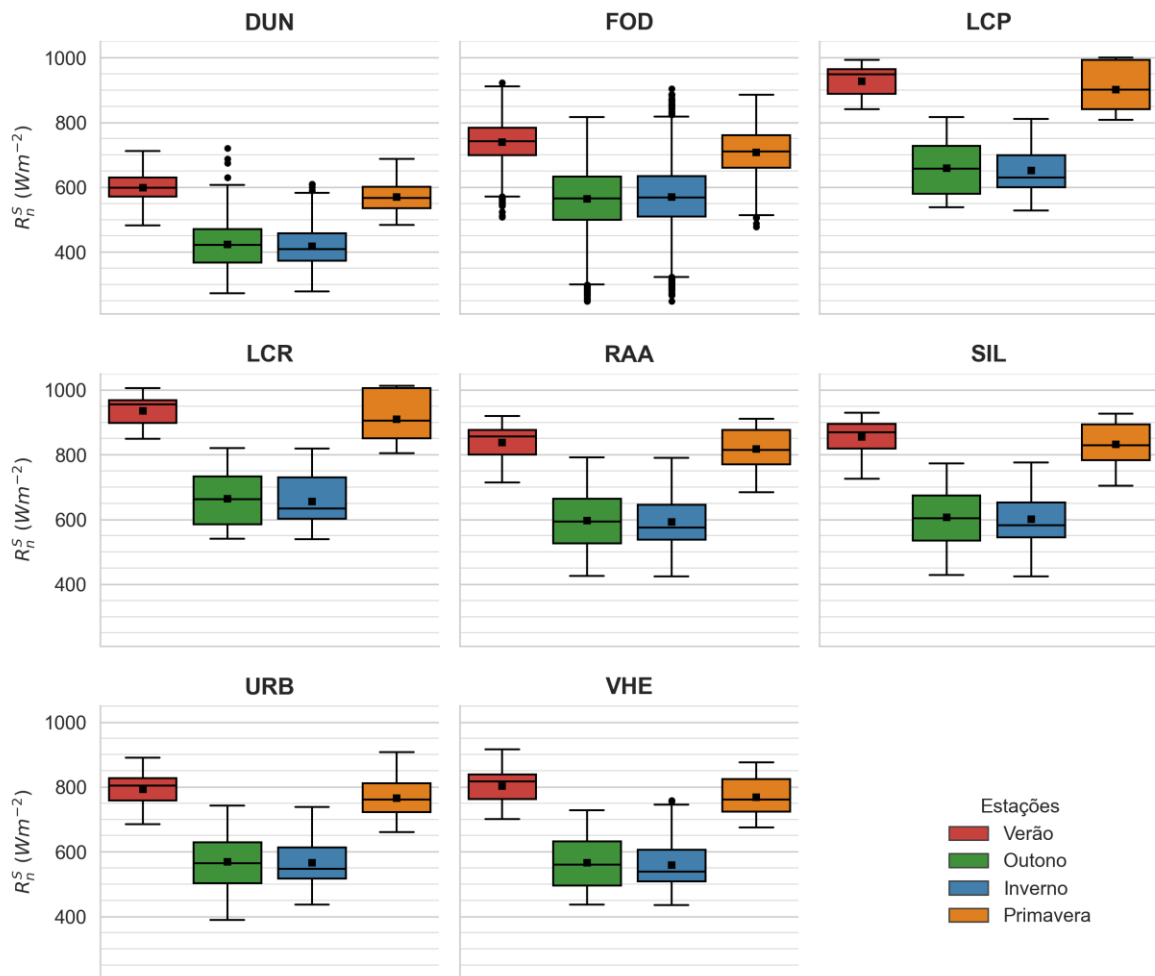
A vegetação herbácea, por sua vez, resultou em R_n^S igual àquele registrado nas áreas urbanas, de 674 Wm^{-2} . O albedo de ambas as classes é muito semelhante e suas características topográficas e de localização (VHE se encontra geralmente em meio a URB) também são análogas. A convergência desses fatores, por conseguinte, resulta na aproximação dos valores de R_n^S dessas classes de cobertura do solo.

O saldo de radiação de ondas curtas apresenta uma pronunciada tendência sazonal, como pode se observar na Figura 10. Em todas as classes de cobertura do solo, os valores da primavera se assemelham aos do verão e os valores do outono se assemelham aos do inverno. Essas características também podem ser observadas no mapa de R_n^S médio (Apêndice G) e no gráfico da série temporal (Apêndice H).

A aplicação de testes de Kruskal-Wallis aponta que há diferenças estatisticamente significativas de R_n^S entre as estações para todas as classes de cobertura do solo (*p-values* na ordem de 10^{-10} em todas as classes, vide Apêndice C).

Os testes *post-hoc* de Dunn, por sua vez, indicam as seguintes diferenças de R_n^S entre estações do ano: primavera > outono, primavera > inverno, verão > outono e verão > inverno. Esse padrão ocorre para todas as classes de cobertura do solo estudadas. Entre primavera e verão e entre outono e inverno não há diferenças significativas. Os resultados dos testes de Dunn estão disponíveis no Apêndice D.

Figura 10 – Saldo de radiação de ondas curtas por estação do ano



Fonte: elaborado pelo autor.

Legenda: Pontos quadrados = média; pontos circulares = outliers; linha central = mediana.

A dinâmica espacial da Terra em relação ao Sol é responsável pelas estações do ano, as quais estão associadas à quantidade de radiação solar que incide sobre a superfície. No verão, a radiação solar incidente atinge seus máximos, e o contrário ocorre no inverno – enquanto primavera e outono constituem estações de transição. O saldo de radiação de ondas curtas, conseqüentemente, responde à mesma medida, o que provoca as diferenças sazonais encontradas nas análises.

4.4 SALDO DE RADIAÇÃO DE ONDAS LONGAS

A compreensão do saldo de radiação de ondas longas requer que sejam levadas em consideração também a emissividade e a temperatura da superfície, cujas médias (de todos os pixels amostrados) são apresentadas na Tabela 7 e na Tabela 8, respectivamente.

Tabela 7 – Emissividade média das classes de cobertura do solo

Classe	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Emissividade	0,9502	0,9738	0,9850	0,9850	0,9621	0,9595	0,9515	0,9574
Desvio Padrão	0,0004	0,0055	0,0000	0,0000	0,0026	0,0018	0,0011	0,0031
Coef. de Variação	0,04%	0,56%	0,00%	0,00%	0,27%	0,18%	0,11%	0,32%

Fonte: elaborado pelo autor.

Nota: LCP e LCR têm desvio padrão igual a zero pois seus valores de ε_s são constantes.

Tabela 8 – Temperatura média de superfície (°C)

Classe	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Temperatura	27,60	23,74	22,29	22,07	24,27	24,17	28,90	28,59
Desvio Padrão	6,94	4,95	4,34	4,43	5,24	4,95	7,05	6,78
Coef. de Variação	25,1%	20,8%	19,5%	20,1%	21,6%	20,5%	24,4%	23,7%

Fonte: elaborado pelo autor.

As classes aquáticas possuem ε_s constante, conforme proposto por Tasumi (2003). Trata-se, inclusive, dos maiores valores de emissividade dentre as classes analisadas, embora a variação das emissividades seja muito pequena tanto entre classes – varia de 0,950 a 0,985 – quanto entre as observações de cada classe – todos os coeficientes de variação são inferiores a 1%.

Já no que diz respeito à temperatura, LCP e LCR apresentam as menores médias, na faixa de 22 °C. Os maiores valores médios foram registrados para as áreas urbanas (28,9 °C), vegetação herbácea (28,5 °C) e dunas (27,6 °C).

O saldo de ondas longas reportou médias anuais entre -111 e -102 Wm⁻². Além de apresentar valores muito menores e com menor variação em relação a R_n^S , o R_n^L é negativo em todas as estações e classes. Isso indica que R_L^\uparrow (parcelas emitida e refletida pela superfície) é maior que R_L^\downarrow , ou seja, a superfície emite mais radiação de ondas longas do que recebe (no momento de aquisição das imagens). A Tabela 9 sintetiza as medianas encontradas.

Em valores absolutos, LCP e LCR apresentam os menores saldos de radiação de ondas longas, na faixa de 102 Wm⁻². Por outro lado, os valores absolutos de R_n^L foram máximos nas áreas urbanas e na vegetação herbácea, com aproximadamente 111 Wm⁻². É evidente a menor variação do saldo de ondas longas entre classes quando comparado com o saldo de ondas curtas: para R_n^L , o saldo médio varia 9% entre o valor mínimo e o máximo, enquanto esse percentual é de 57% para R_n^S .

Tabela 9 – Saldo de radiação de ondas longas mediano (Wm^{-2})

Estação	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Verão	-120,1	-112,5	-111,7	-112,3	-113,0	-111,4	-123,2	-121,5
Outono	-99,3	-98,2	-97,4	-96,8	-96,6	-96,7	-101,1	-101,2
Inverno	-95,8	-95,8	-94,3	-93,9	-94,9	-94,9	-97,9	-98,5
Primavera	-116,4	-107,6	-105,5	-106,0	-109,1	-107,3	-119,5	-121,4
Média anual*	-108,4	-103,8	-102,2	-102,0	-103,5	-102,7	-110,8	-110,8

Fonte: elaborado pelo autor.

Legenda: *média anual ponderada pelo número de imagens em cada estação.

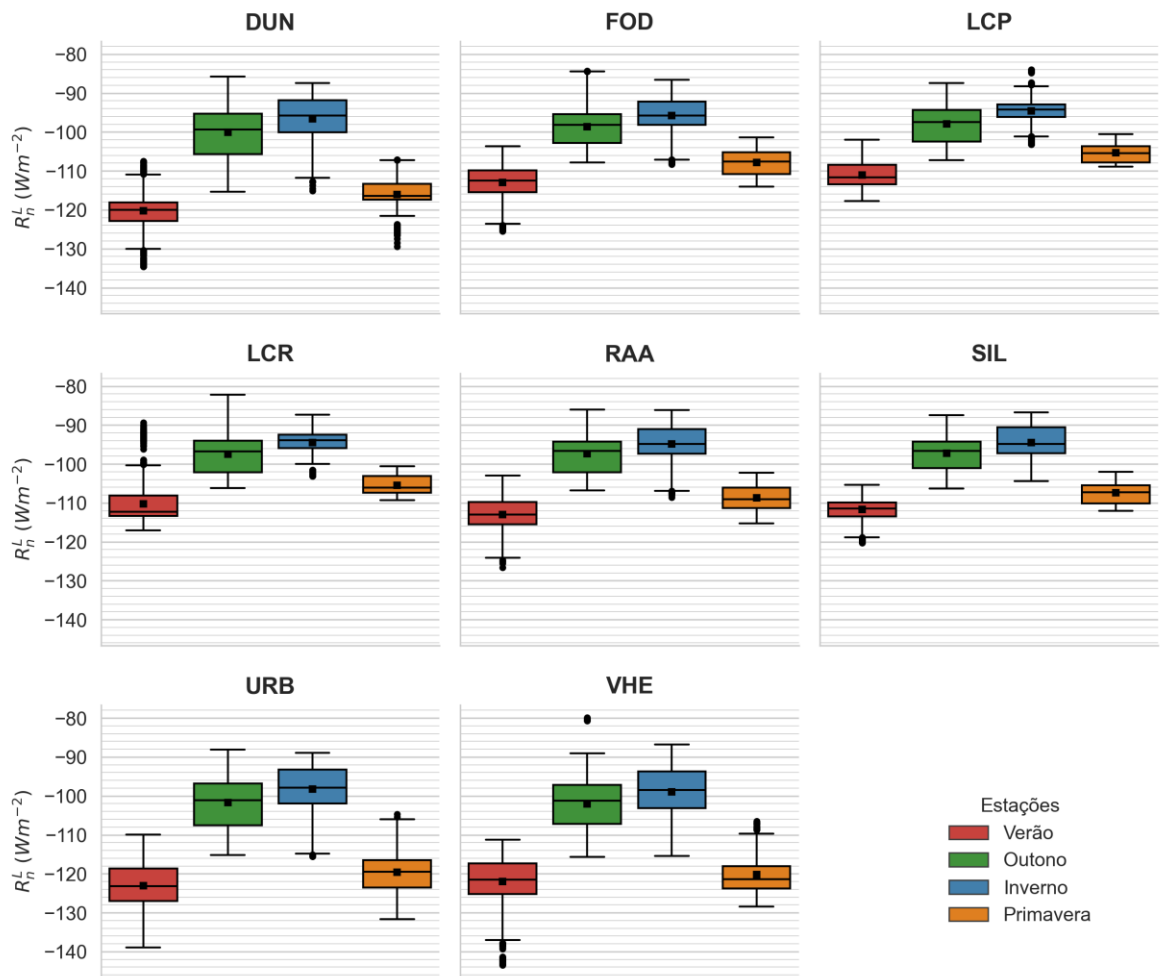
Em URB e VHE, onde se registram os maiores valores absolutos de R_n^L , são verificadas também as maiores temperaturas médias (acima de 28 °C). Esses resultados colaboram com a hipótese levantada anteriormente de que a vegetação herbácea sofre influência do solo, já que sua temperatura é cerca de 19% maior do que as outras três classes de vegetação. Pela sua característica de rápido aquecimento, as superfícies que constituem as áreas urbanas (como construções, asfalto, solo exposto e gramíneas) estão associadas a fenômenos como as ilhas de calor (KIM, 1992).

O rápido aquecimento também é uma característica das superfícies arenosas. Como consequência, as dunas apresentaram a terceira maior temperatura média (27,6 °C) e o terceiro maior saldo de radiação de ondas longas (108 Wm^{-2} em módulo).

Nas classes de vegetação – à exceção de VHE – foram registrados os menores valores absolutos de R_n^L referentes a superfícies terrestres. As três apresentaram temperaturas médias próximas a 24 °C e saldo de radiação de ondas longas médio anual no intervalo de -104 a -102 Wm^{-2} . Dentre as classes terrestres, a FOD tem a maior emissividade, sendo que o modelo de cálculo é baseado em índices de vegetação.

O saldo de radiação de ondas longas também apresenta comportamento sazonal, conforme se observa na Figura 11. Os valores de R_n^L na primavera e no verão são menores do que aqueles no outono e no inverno (na escala negativa). Todavia, é válida a consideração desses valores em termos absolutos, já que eles representam a diferença entre as entradas e saídas de radiação na superfície. Assim, as diferenças (R_n^L em módulo) são maiores na primavera e verão e menores no outono e no inverno. Essas diferenças podem ser visualizadas no mapa do Apêndice G e no gráfico do Apêndice I.

Figura 11 – Saldo de radiação de ondas longas por estação do ano



A avaliação das estações também foi realizada inicialmente em termos do teste de Kruskal-Wallis, que apontou diferenças significativas em todas as classes de uso do solo (p -values na ordem de 10^{-10} , vide Apêndice C).

Pelo gráfico da Figura 11 é possível notar que a aproximação primavera-verão em algumas classes (por exemplo, DUN, FOD e SIL) não é tão grande como aquelas verificadas no saldo de radiação de onda curtas (Figura 10). Não obstante, os testes *post hoc* de Dunn não apontaram diferenças significativas entre essas estações em nenhuma das classes.

Os testes de Dunn aplicados em relação a R_n^L por estação do ano apresentaram resultados análogos àqueles vistos em R_n^S , isto é: primavera > outono, primavera > inverno, verão > outono e verão > inverno (considerando R_n^L em módulo). Apesar de ter sido determinado p -value = 0,06 para LCP entre primavera e outono, a

observação da Figura 11 mostra que as diferenças entre essas estações são importantes. Os resultados dos testes podem ser verificados no Apêndice E.

4.5 SALDO DE RADIAÇÃO

A partir da integração dos saldos de radiação de ondas curtas e de ondas longas define-se o saldo de radiação. A Tabela 10 apresenta a mediana de R_n para cada estação do ano por classe de cobertura do solo.

Nota-se que as classes de cobertura do solo analisadas se apresentam na seguinte sequência, em ordem crescente de R_n médio anual: DUN, FOD, VHE, URB, RAA, SIL, LCP e LCR. Essa é a mesma ordem verificada para R_n^S , que tem predominância no saldo de radiação por ser, em média, 6,5 vezes maior que R_n^L (no momento de aquisição das imagens).

Tabela 10 – Saldo de radiação mediano (Wm^{-2})

Estação	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Verão	475,9	628,3	833,1	843,0	739,8	756,4	679,4	689,9
Outono	321,2	466,7	558,9	565,3	495,3	504,5	461,1	457,0
Inverno	313,2	472,2	535,0	540,4	480,9	488,7	451,3	442,3
Primavera	451,7	602,3	795,1	799,4	705,9	722,7	642,0	640,2
Média anual*	394,9	541,3	682,6	689,7	607,7	620,8	563,1	563,0

Fonte: elaborado pelo autor.

Legenda: *média anual ponderada pelo número de imagens em cada estação.

As medianas de R_n para DUN variaram de 313 a 476 Wm^{-2} entre o inverno e o verão, o que constitui a classe com menores saldos de radiação. O intervalo estimado é condizente com Gusmão et al. (2012), que obtiveram médias inferiores a 375 Wm^{-2} para bancos de areia no Tocantins, e com Uda, Corseuil e Kobiyama (2013), que encontraram saldo médio de 404 Wm^{-2} para solo exposto claro na bacia do Rio Negro (divisa entre Santa Catarina e Paraná).

As classes de vegetação nativa apresentaram medianas de 467 a 628 Wm^{-2} (FOD) e 481 a 740 Wm^{-2} (RAA). Os valores mais elevados de RAA estão associados ao seu menor albedo – 0,125 para RAA e 0,170 para FOD – e à topografia do terreno (influência em θ_{rel}), que é plana nas regiões de restinga e composta por morros na região de floresta ombrófila densa.

Comparativamente, Miranda et al. (2022) encontraram R_n entre 400 e 500 Wm^{-2} no inverno e 600 a 800 Wm^{-2} no verão para vegetação no Rio de Janeiro. No Tocantins, Gusmão et al. (2012) estimaram valores de 500 a mais de 575 Wm^{-2} para vegetação nativa, enquanto Silva et al. (2015) obtiveram saldos de radiação entre 377 e 745 Wm^{-2} em savanas florestadas no estado de São Paulo. Para a região Sul, trabalhos apontam valores médios de R_n entre 526 Wm^{-2} no início do outono (UDA; CORSEUIL; KOBİYAMA, 2013) e 590 Wm^{-2} na primavera (DEBASTIANI et al., 2018) para florestas nativas.

A classe de silvicultura, por sua vez, apresenta saldo de radiação mediano entre 504 e 756 Wm^{-2} . Trata-se de um intervalo sensivelmente maior do que aquele observado na FOD e próximo de RAA. De fato, SIL e RAA compartilham semelhanças no que diz respeito ao albedo (0,112 e 0,125, respectivamente) e às características de relevo, o que contribui para a aproximação dos valores de R_n . Uda, Corseuil e Kobiyama (2013) estimaram R_n médio igual a 532 Wm^{-2} sobre áreas de reflorestamento no início do outono – próximo da mediana de 504 Wm^{-2} no presente estudo. Já Silva et al. (2015) encontraram valores entre 400 e 700 Wm^{-2} sobre plantações de eucalipto – na presente pesquisa, a classe de SIL representa plantações de pinus.

Ainda dentre as classes de vegetação, VHE tem saldos de radiação medianos compreendidos em um intervalo de 442 a 690 Wm^{-2} . No outono, o R_n mediano foi de 457 Wm^{-2} , valor que se aproxima da média de 451 Wm^{-2} obtida por Uda, Corseuil e Kobiyama (2013) sobre pastagem.

Por outro lado, as médias de diferentes tipos de pastagem avaliados por Fausto et al. (2014) no estado do Mato Grosso foram inferiores a 500 Wm^{-2} , ante média anual de 563 Wm^{-2} encontrados para VHE neste trabalho. Não obstante, os mesmos autores encontraram médias entre 525 e 604 Wm^{-2} no período úmido e entre 391 e 432 Wm^{-2} no período seco. Como a bacia hidrográfica da Lagoa da Conceição encontra-se em uma região de clima caracterizado por ausência de período seco, é possível que VHE sustente médias mais elevadas, equivalentes àsquelas do período úmido do trabalho supracitado.

As áreas urbanas têm medianas de R_n na faixa de 451 a 679 Wm^{-2} , bastante próximo do observado para VHE. Além das características topográficas análogas e do fato da vegetação herbácea se localizar geralmente nas proximidades das áreas urbanas, VHE e URB apresentam albedos médios praticamente iguais (0,162 e 0,163,

respectivamente). Os valores de R_n de áreas urbanas obtidos por Miranda et al. (2022) na região metropolitana do Rio de Janeiro variam de 300 a 600 Wm^{-2} . Já Uda, Corseuil e Kobiyama (2013) estimaram média de 429 Wm^{-2} no outono, enquanto a mediana de outono do presente estudo foi de 461 Wm^{-2} .

Por fim, as classes representativas da Lagoa da Conceição mostram R_n próximo entre si, variando de 535 a 843 Wm^{-2} entre o inverno e o verão. O albedo médio de LCP mostrou-se maior do que aquele de LCR (0,037 e 0,028, respectivamente), embora a diferença entre o saldo de radiação médio de ambas seja muito pequena.

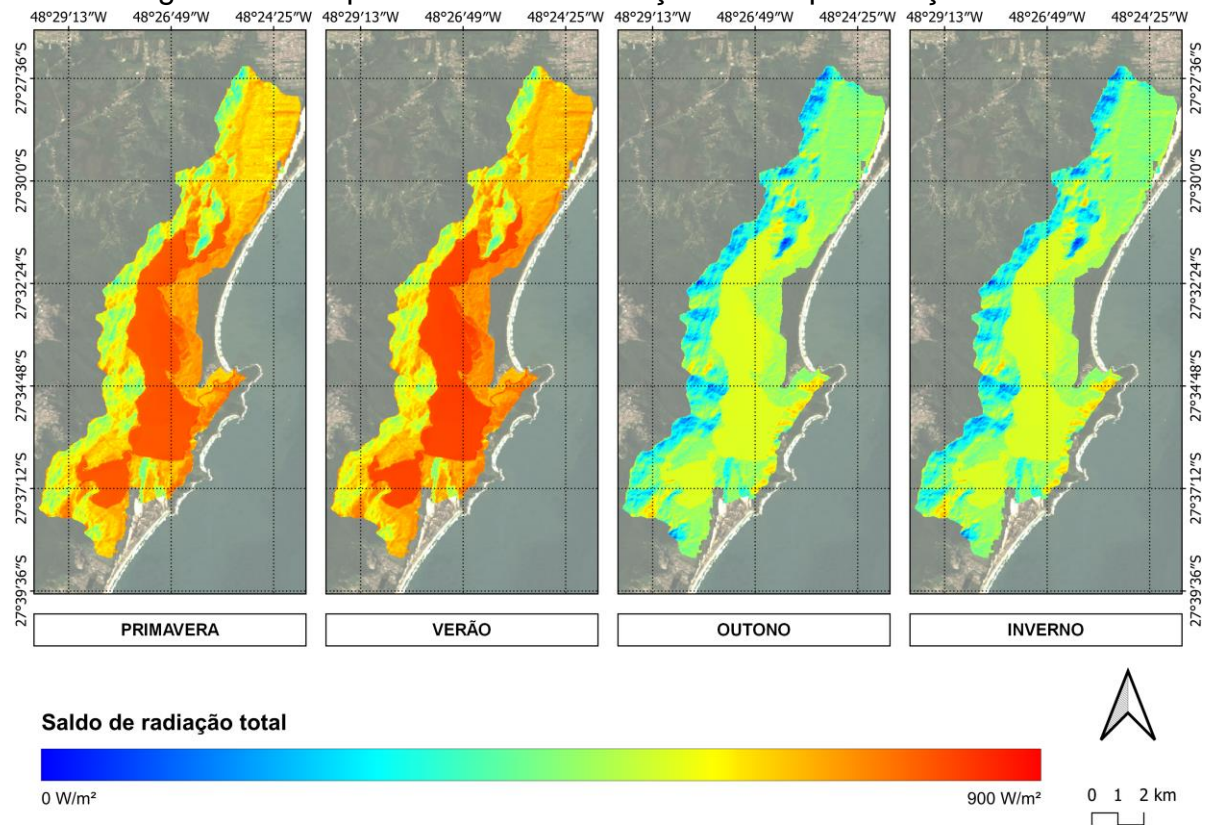
As classes de água apresentaram os maiores valores de R_n . Silva, Lopes e Azevedo (2005) estimavam R_n da ordem de 750 Wm^{-2} para águas do Lago de Sobradinho, na Bahia. A média obtida por Uda, Corseuil e Kobiyama (2013) foi de 610 Wm^{-2} no outono, e Debastiani et al. (2018) encontraram média de 592 Wm^{-2} na primavera. Em todos esses trabalhos, os valores de R_n referentes à água também foram os maiores dentre as classes de cobertura do solo analisadas.

A Figura 12 mostra o saldo de radiação médio de cada estação do ano sobre a área de estudo. Nela, são nítidas as semelhanças primavera-verão e outono-inverno e o simultâneo distanciamento entre esses dois grupos. Já a Figura 13 apresenta a variação temporal de R_n mediano ao longo do período analisado (sobre as amostras).

Entre a primavera e o verão há um aumento geral de R_n de 5,4% (36 Wm^{-2}) em média. Esse aumento é mais significativo para VHE (49,7 Wm^{-2} , 7,8%), URB (37,4 Wm^{-2} , 5,8%), LCR (43,6 Wm^{-2} , 5,5%) e DUN (24,2 Wm^{-2} , 5,3%). Nas outras classes o aumento é inferior a 4%. Na sequência, há uma queda geral do R_n médio de aproximadamente 32% (227 Wm^{-2}) com a chegada do outono. A floresta ombrófila densa diminui 25,7% (162 Wm^{-2}) nessa transição, sendo a única classe cuja diminuição de R_n entre verão e outono é inferior a 30%.

Entre o outono e o inverno se registram as menores variações de R_n , cuja média gira em torno de 2,8% (13,2 Wm^{-2}). Contudo, a chegada da primavera provoca as maiores diferenças percentuais registradas: 44% (204 Wm^{-2}) em média. A FOD tem aumento de 27,5% (130,0 Wm^{-2}), constituindo mais uma vez a menor variação percentual dentre todas as classes, sendo a única inferior a 40%.

Figura 12 – Mapas de saldo de radiação médio por estação do ano

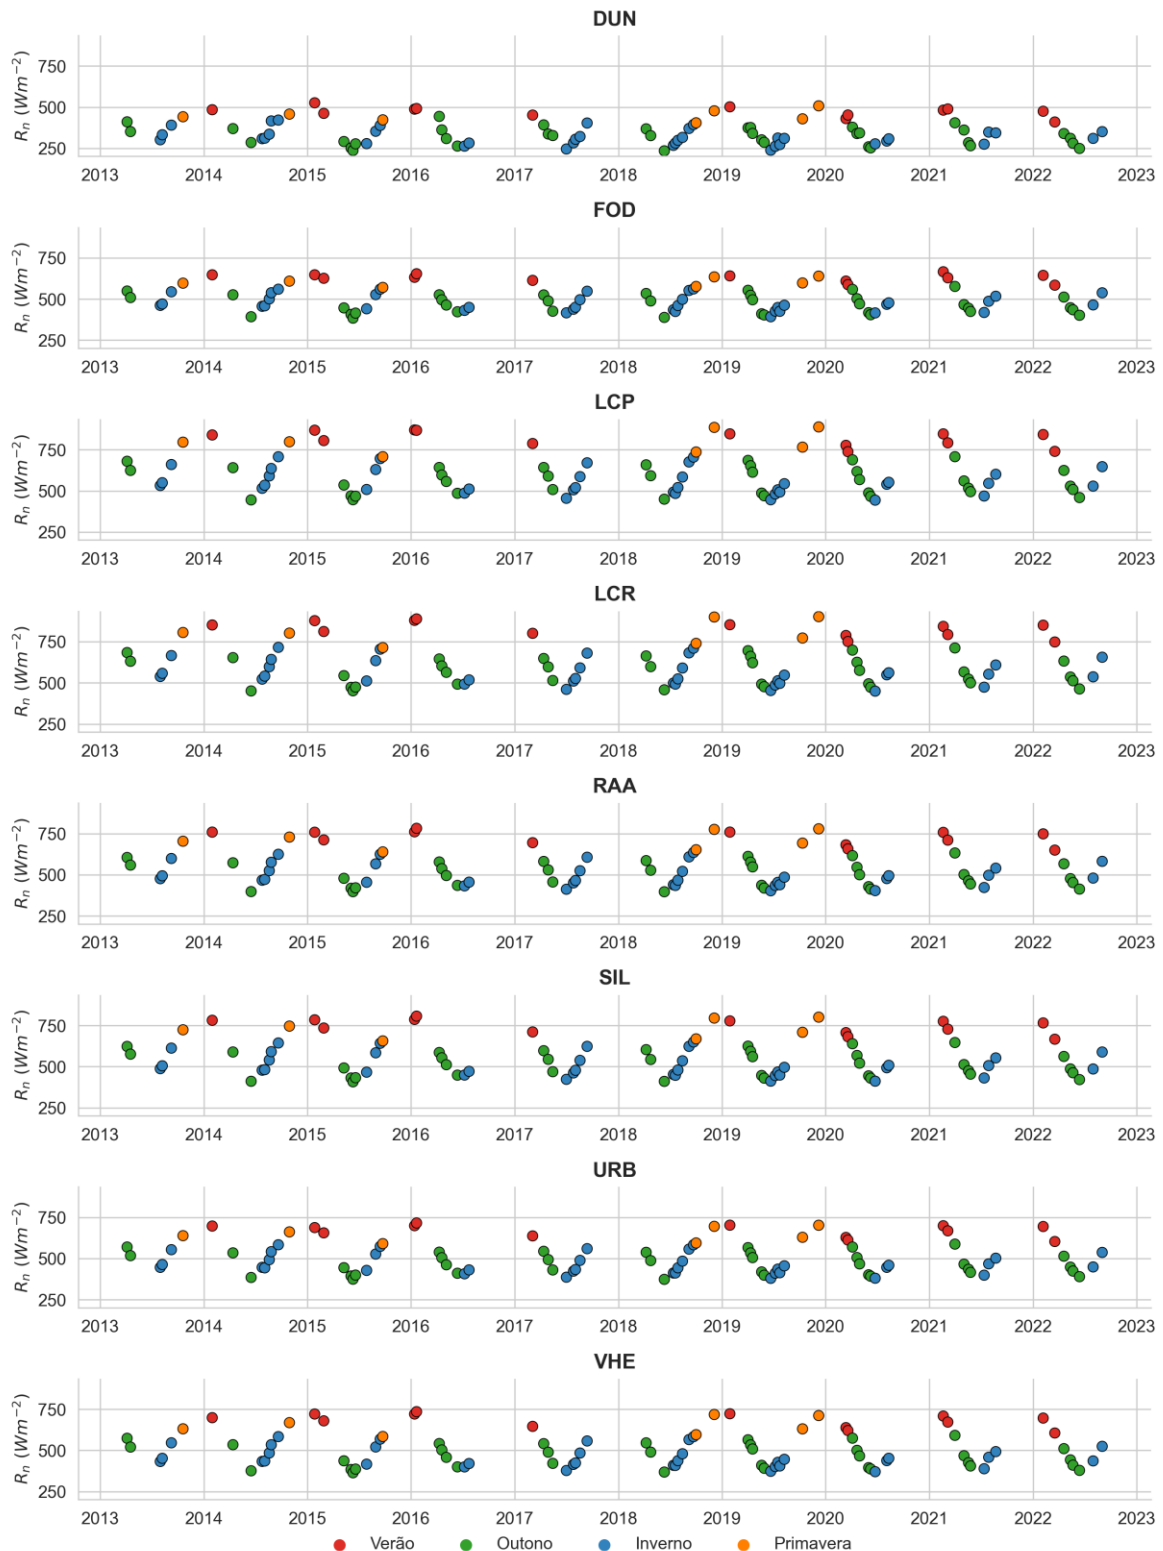


Fonte: elaborado pelo autor.

Por estar majoritariamente situada na região de morros da bacia hidrográfica da Lagoa da Conceição, o saldo de radiação da FOD é intensamente afetado pelas variações de θ_{rel} . É possível notar na Figura 12, nas porções junto ao limite oeste, a alternância entre saldos de radiação maiores e menores, que variam conforme a orientação do relevo da região. Essas variações, todavia, não são avaliadas pelas amostras, cuja seleção se restringiu às regiões com maior incidência solar (faces norte e nordeste).

Assim como nos saldos de radiação de ondas curtas e de ondas longas, os testes de Kruskal-Wallis aplicados mostraram que existem diferenças significativas nos saldos de radiação entre as estações do ano em todas as classes de cobertura do solo (p -values na ordem de 10^{-10} , conforme Apêndice C). Semelhantemente, os testes *post hoc* de Dunn confirmaram que, para todas as classes, apenas primavera-verão e outono-inverno não diferem significativamente (resultados apresentados no Apêndice F).

Figura 13 – Série temporal do saldo de radiação mediano



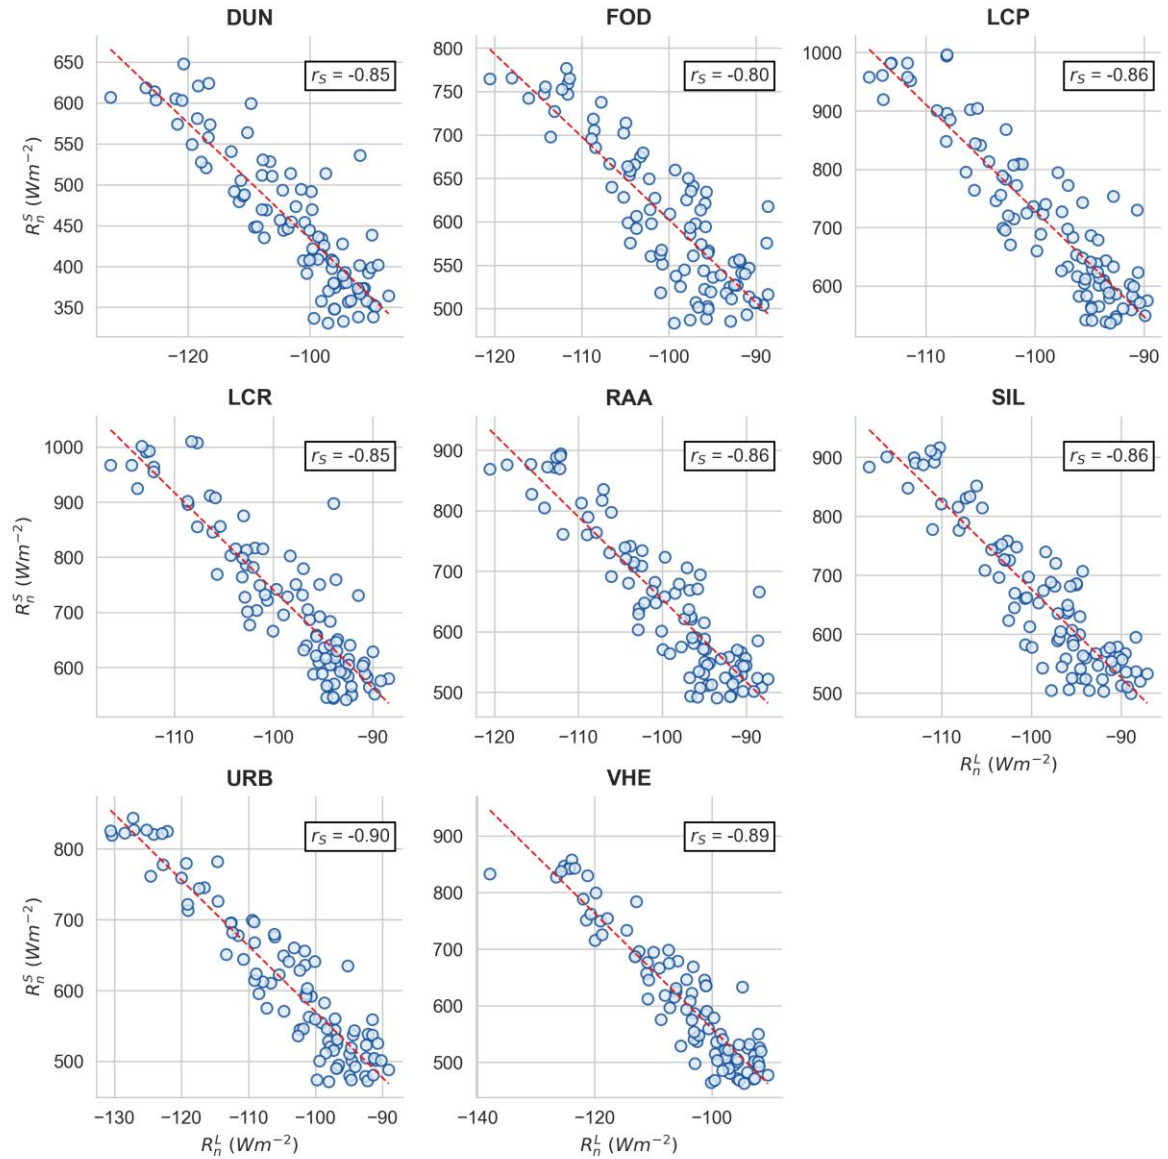
Desprezando-se os efeitos da advecção e do armazenamento de calor, parte da radiação de ondas curtas absorvida pela atmosfera provoca um aumento da temperatura do ar, que se traduz na maximização de R_L^\downarrow . Já a absorção da radiação

de ondas curtas pela superfície é responsável pela maximização de R_L^\uparrow em função do aumento da temperatura da superfície. A Figura 14 mostra que as medianas de R_n^S e R_n^L sobre as amostras em cada imagem variam linearmente, de forma que o saldo de ondas longas aumenta em módulo com o aumento do saldo de ondas curtas.

Os valores positivos de R_n indicam que a superfície apresenta um ganho líquido de energia. Essa energia fica disponível aos processos que ocorrem na superfície, podendo ser utilizada no aquecimento dos seus componentes – solo, plantas, construções etc. – e do ar (calor sensível), na fotossíntese e na evapotranspiração (calor latente) (PEREIRA; ANGELOCCI; SENTELHAS, 2002).

A partir de medições de campo, Oliveira et al. (2019) obtiveram uma proporção média de 13% para H/R_n e de 7% para G/R_n na floresta amazônica. Na ausência de advecção, a parcela restante de 80% corresponde à LE/R_n (evapotranspiração). De maneira semelhante, Schirmbeck, Fontana e Roberti (2018) encontraram relação LE/R_n em áreas agrícolas do Rio Grande do Sul iguais a 76%, 61% e 42% para culturas de verão, inverno e áreas parcialmente vegetadas, respectivamente. Em pastagens no Cerrado, Alves et al. (2022) demonstraram haver grande influência da chuva nas proporções da energia na superfície: a ocorrência de precipitação provocou aumento de LE/R_n e diminuição de H/R_n . Já Miranda et al. (2022) mostraram que, enquanto o fluxo de calor latente predomina em áreas florestadas (69% de R_n no inverno e 78% no verão), a maior parte de R_n em áreas urbanas está associada ao fluxo de calor sensível e do solo (juntos, representam 70% de R_n no verão e 57% no inverno). Os estudos citados acima demonstram que as características da superfície exercem influência não só na quantidade de energia, mas também na forma como ela se encontra. Assim, nas superfícies bem umedecidas (como vegetação) há predominância do calor latente, enquanto as superfícies com baixa disponibilidade de água (como dunas, áreas urbanas e pastagem) respondem por proporções elevadas de calor sensível. Esse mecanismo contribui com o entendimento dos resultados obtidos para T_s e R_n^L (em módulo), que são maiores em DUN, URB e VHE.

Figura 14 – Relação entre os saldos de ondas curtas e ondas longas



Fonte: elaborado pelo autor.

Nota: r_s se refere ao coeficiente de correlação de Spearman.

5 CONCLUSÃO

Os resultados obtidos mostram que a utilização de sensoriamento remoto na estimativa dos saldos de radiação é viável e leva a resultados condizentes com estudos semelhantes, apesar da ausência de medições em campo para validação.

O saldo de radiação é influenciado majoritariamente pelos fluxos radiativos de ondas curtas que, por sua vez, estão intimamente associados ao albedo. Dessa forma, o menor R_n médio foi registrado nas dunas (395 Wm^{-2}). Na sequência, em ordem crescente, vêm a floresta ombrófila densa (541 Wm^{-2}), as áreas urbanas e a vegetação herbácea (ambas com média de 563 Wm^{-2}), a restinga arbustiva-arbórea (608 Wm^{-2}), a silvicultura (621 Wm^{-2}) e as classes que representam água (683 e 690 Wm^{-2}).

Verifica-se que o saldo de radiação médio não varia significativamente entre a primavera e o verão e entre o outono e o inverno, para todas as classes de cobertura do solo avaliadas. Todavia, há uma pronunciada tendência sazonal de aumento de R_n nos meses de primavera e verão e de diminuição nos meses de outono e inverno.

O saldo de radiação de ondas curtas predomina sobre o saldo de radiação de ondas longas no momento de aquisição das imagens, e ambos possuem forte correlação linear. Este último apresentou valores negativos em todas as classes e cenas avaliadas, indicando que a quantidade de radiação de ondas longas emitida pela superfície supera a quantidade recebida, e essa diferença se acentua nos meses mais quentes (primavera e verão).

A resolução temporal dos dados Landsat 8 impõe um desafio ao monitoramento contínuo do saldo de radiação na bacia hidrográfica da Lagoa da Conceição. Sobretudo na primavera e no verão, a cobertura por nuvens frequentemente impede a obtenção de imagens adequadas.

Os valores extremos de R_n^S , R_n^L , R_n e α estimados para as classes aquáticas – embora de acordo com outros estudos sobre esse tipo de superfície – indicam que a avaliação do comportamento da água deve ser foco de futuras investigações na referida bacia hidrográfica. Estudos posteriores também podem avaliar a variação de R_n da floresta ombrófila densa em função da orientação do relevo, que é bastante variável na área de estudo. Além disso, a influência da ocorrência de precipitação próxima do momento de aquisição das imagens nos resultados obtidos é passível de ser investigada em trabalhos subsequentes.

REFERÊNCIAS

ALLEN, R. G. et al. **The ASCE Standardized Reference Evapotranspiration Equation**. Reston, VA: American Society of Civil Engineers, 2005.

ALLEN, R. G.; TASUMI, M.; TREZZA, R. Satellite-Based Energy Balance for Mapping Evapotranspiration with Internalized Calibration (METRIC)—Model. **Journal of Irrigation and Drainage Engineering**, v. 133, n. 4, p. 380-394, 2007. DOI: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2007\)133:4\(380\)](https://doi.org/10.1061/(ASCE)0733-9437(2007)133:4(380)).

ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. DOI: <https://doi.org/10.1127/0941-2948/2013/0507>.

ALVES, J. D. N. et al. Energy balance and surface decoupling factor of a pasture in the Brazilian Cerrado. **Agricultural and Forest Meteorology**, v. 319, p. 108912, 2022. DOI: <https://doi.org/10.1016/j.agrformet.2022.108912>.

ANGELINI, L. P. et al. Surface albedo and temperature models for surface energy balance fluxes and evapotranspiration using sebal and landsat 8 over cerrado-pantanal, brazil. **Sensors**, v. 21, n. 21, 2021. DOI: <https://doi.org/10.3390/s21217196>.

BASTIAANSEN, W. G. M. **Remote sensing in water resources management: The state of the art**. Colombo, Sri Lanka: International Water Management Institute, 1998. Disponível em: <https://publications.iwmi.org/pdf/H022865.pdf>. Acesso em: 18 set. 2022.

BASTIAANSEN, W. G. M. et al. A remote sensing surface energy balance algorithm for land (SEBAL): 1. Formulation. **Journal of Hydrology**, v. 212-213, n. 1-4, p. 198-212, 1998. DOI: [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4).

BASTIAANSEN, W. G. M. et al. SEBAL Model with Remotely Sensed Data to Improve Water-Resources Management under Actual Field Conditions. **Journal of Irrigation and Drainage Engineering**, v. 131, n. 1, p. 85-93, 2005. DOI: [https://doi.org/10.1061/\(ASCE\)0733-9437\(2005\)131:1\(85\)](https://doi.org/10.1061/(ASCE)0733-9437(2005)131:1(85)).

CORSEUIL, C. W. et al. **Spatial estimation of potential evapotranspiration of Itacorubi watershed, through correlation with the NDVI**. VIII Seminário de Atualização em Sensoriamento Remoto e Sistemas de Informações Geográficas Aplicados à Engenharia Florestal. **Anais...** Curitiba: FUPEF, 2008. Disponível em: <https://bit.ly/3EzFAXY>. Acesso em: 23 nov. 2022.

COURAULT, D.; SEGUIN, B.; OLIOSO, A. Review on estimation of evapotranspiration from remote sensing data: From empirical to numerical modeling approaches. **Irrigation and Drainage Systems** 2005 19:3, v. 19, n. 3, p. 223–249, 2005. DOI: <https://doi.org/10.1007/s10795-005-5186-0>.

- DEBASTIANI, A. B. et al. Mapeamento do saldo de radiação no Parque Nacional de São Joaquim – SC. **Advances in Forestry Science**, v. 5, n. 3, p. 363-367, 2018. Disponível em: <https://bit.ly/3EGyH77>. Acesso em: 23 nov. 2022.
- DUFFIE, J. A.; BECKMAN, W. A. **Solar Engineering of Thermal Processes**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2013. Disponível em: <https://bit.ly/3EICyk2>. Acesso em: 07 set. 2022.
- FAUSTO, M. A. et al. Net radiation estimated by remote sensing in Cerrado areas in the Upper Paraguay River Basin. **Journal of Applied Remote Sensing**, v. 8, n. 1, p. 83541, 2014. DOI: <https://doi.org/10.1117/1.JRS.8.083541>.
- FERREIRA, T. R. et al. The use of remote sensing for reliable estimation of net radiation and its components: a case study for contrasting land covers in an agricultural hotspot of the Brazilian semiarid region. **Agricultural and Forest Meteorology**, v. 291, p. 108052, 15 set. 2020. DOI: <https://doi.org/10.1016/j.agrformet.2020.108052>.
- GARRISON, J. D.; ADLER, G. P. Estimation of precipitable water over the United States for application to the division of solar radiation into its direct and diffuse components. **Solar Energy**, v. 44, n. 4, p. 225–241. DOI: [https://doi.org/10.1016/0038-092X\(90\)90151-2](https://doi.org/10.1016/0038-092X(90)90151-2).
- GOERGEN, G. **Utilização do Índice de Área Foliar obtido por sensoriamento remoto para a estimativa da evapotranspiração de referência na bacia do Prata**. Dissertação (Mestrado em Meteorologia) – Centro de Ciências Naturais e Exatas, Universidade Federal de Santa Maria, Santa Maria, 2010. Disponível em: <https://repositorio.ufsm.br/handle/1/10252>. Acesso em: 25 nov. 2022.
- GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18-27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>.
- GUSMÃO, A. C. V. L. et al. Determination of the net radiation in Bananal Island, TO with orbital images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 10, p. 1107–1114, 2012. DOI: <https://doi.org/10.1590/S1415-43662012001000011>.
- HELSEL, D. R. et al. **Statistical methods in water resources**: U.S. Geological Survey Techniques and Methods, book 4, chap. A3. Reston, VA: USGS, 2020. DOI: <https://doi.org/10.3133/tm4A3>.
- HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, ago. 1988. DOI: [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).
- INMET. **Normais Climatológicas do Brasil 1991-2020**. Brasília: INMET, 2022. Disponível em: <https://portal.inmet.gov.br/normais#>. Acesso em: 14 out. 2022.
- KIM, H. H. Urban heat island. **International Journal of Remote Sensing**, v. 13, n. 12, p. 2319–2336, 3 ago. 1992. DOI: <https://doi.org/10.1080/01431169208904271>.

LAZAROTE, L. M. **Estimativa espacial de evapotranspiração por meio de correlação com índice de vegetação normalizado**. Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2007. Disponível em: <https://repositorio.ufsc.br/xmlui/handle/123456789/124366>. Acesso em: 24 nov. 2022.

LOPES, M. N. et al. Trends in aquatic ecology research associated with urbanization evolution during three decades in Santa Catarina Island/SC. **Acta Limnologica Brasiliensia**, v. 32, p. e205, 2020. DOI: <https://doi.org/10.1590/S2179-975X7719>.

MARQUES, H. O. et al. Estimated net radiation in an Amazon-Cerrado transition forest by Landsat 5 TM. **Journal of Applied Remote Sensing**, v. 11, n. 04, p. 1, 2017. DOI: <https://doi.org/10.1117/1.JRS.11.046020>.

MARTINS, N. R.; FERRETTI, O. E. **Análise e monitoramento dos impactos, fragmentação e a conectividade das Unidades de Conservação na Ilha de Santa Catarina, Brasil**. Florianópolis: UFSC, 2019.

MIRANDA, V. F. V. V. et al. Urbanization-induced impacts on heat-energy fluxes in tropical South America from 1984 to 2020: The Metropolitan Area of Rio de Janeiro/Brazil. **Building and Environment**, v. 216, p. 109008, 2022. DOI: <https://doi.org/10.1016/j.buildenv.2022.109008>.

NASA JPL. **NASADEM Merged DEM Global 1 arc second V001**. Pasadena: NASA EOSDIS Land Processes DAAC, 2020. DOI: https://doi.org/10.5067/MEaSURES/NASADEM/NASADEM_HGT.001.

NOVO, E. M. L. M. **Sensoriamento remoto: Princípios e aplicações**. 3. ed. São Paulo: Blucher, 2008.

NREL. **Reference Air Mass 1.5 Spectra**. Disponível em: <https://www.nrel.gov/grid/solar-resource/spectra-am1.5.html>. Acesso em: 22 out. 2022.

OLIVEIRA, G. et al. Effects of land-cover changes on the partitioning of surface energy and water fluxes in Amazonia using high-resolution satellite imagery. **Ecohydrology**, v. 12, n. 6, 2019. DOI: <https://doi.org/10.1002/eco.2126>.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Agrometeorologia: Fundamentos e Aplicações Práticas**. Guaíba: Agropecuária, 2002.

SCHIRMBECK, J.; FONTANA, D. C.; ROBERTI, D. R. Evaluation of OSEB and SEBAL models for energy balance of a crop area in a humid subtropical climate. **Bragantia**, v. 77, n. 4, p. 609-621, 2018. DOI: <https://doi.org/10.1590/1678-4499.2017208>.

SILVA, B. B. DA; LOPES, G. M.; AZEVEDO, P. V. DE. Balanço de radiação em áreas irrigadas utilizando imagens Landsat 5 - TM. **Revista Brasileira de**

Meteorologia, v. 20, n. 2, p. 243–252, 2005. Disponível em: <https://bit.ly/3VbWS4D>. Acesso em: 24 nov. 2022.

SILVA, B. B. et al. Determination of instantaneous and daily net radiation from TM - Landsat 5 data in a subtropical watershed. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 135, p. 42-49, 2015. DOI: <https://doi.org/10.1016/j.jastp.2015.09.020>.

SILVA, B. B. et al. Procedures for calculation of the albedo with OLI-Landsat 8 images: Application to the Brazilian semi-arid. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 20, n. 1, p. 3-8, 2016. DOI: <https://doi.org/10.1590/1807-1929/agriambi.v20n1p3-8>.

SILVA, C. F. et al. **Analysis of actual evapotranspiration in lagoon by SEBAL model**. XXII Simpósio Brasileiro de Recursos Hídricos. **Anais...** Florianópolis: ABRH, 2017. Disponível em: <http://www.dgi.inpe.br/CDSR/>. Acesso em: 23 nov. 2022.

SILVA, C. F. **Estimativa da evapotranspiração na bacia da Lagoa da Conceição**. Trabalho de Conclusão de Curso (Graduação em Engenharia Sanitária e Ambiental) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2013. Disponível em: <https://repositorio.ufsc.br/handle/123456789/124964>. Acesso em: 24 nov. 2022.

SILVA, J. B. et al. Temporal variability in evapotranspiration and energy partitioning over a seasonally flooded scrub forest of the Brazilian Pantanal. **Agricultural and Forest Meteorology**, p. 108559, 2021. DOI: <https://doi.org/10.1016/j.agrformet.2021.108559>.

SILVA, J. C. **Análise numérica da influência dos aportes fluviais e antrópicos sobre a hidrodinâmica residual e a qualidade da água da Lagoa da Conceição – Florianópolis-SC**. 2013. 134 f. Dissertação (Mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós Graduação em Engenharia Ambiental. Florianópolis, 2013. Disponível em: <https://bit.ly/3G9kYbd>. Acesso em: 20 dez. 2022.

TASUMI, M. **Progress in operational estimation of regional evapotranspiration using satellite imagery**. Tese (Doutorado em Biological and Agricultural Engineering) – College of Graduate Studies, University of Idaho, Moscow (ID), 2003. Disponível em: <https://bit.ly/3u38hrj>. Acesso em: 18 set. 2022.

UDA, P. K. **Avaliação da evapotranspiração real da bacia do Alto Rio Negro, região Sul brasileira, por meio do modelo SEBAL**. Dissertação (Mestrado em Engenharia Ambiental) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2012. Disponível em: <https://repositorio.ufsc.br/handle/123456789/99340>. Acesso em: 24 nov. 2022.

UDA, P. K. **Evapotranspiração real da bacia do rio Iguaçu por meio do modelo METRIC**. Tese (Doutorado em Engenharia Ambiental) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2016. Disponível em: <https://repositorio.ufsc.br/handle/123456789/168192>. Acesso em: 24 nov. 2022.

UDA, P. K.; CORSEUIL, C. W.; KOBAYAMA, M. Mapeamento do Saldo de Radiação da Bacia do Alto Rio Negro, Região Sul Brasileira. **Revista Brasileira de Recursos Hídricos**, v. 18, p. 249–258, 2013. Disponível em: <https://lume.ufrgs.br/handle/10183/236969>. Acesso em: 24 nov. 2022.

UDA, P. K.; CORSEUIL, C. W.; KOBAYAMA, M. Evapotranspiração real da bacia do Alto Rio Negro, região Sul brasileira, por meio do SEBAL (Surface Energy Balance Algorithm for Land) e balanço hídrico. **Revista Brasileira de Recursos Hídricos**, v. 19, n. 1, p. 205–217, 2014. Disponível em: <https://lume.ufrgs.br/handle/10183/250710>. Acesso em: 24 nov. 2022.

USGS. **Why are negative values observed over water in some Landsat Surface Reflectance products?** 2019. Disponível em: <https://on.doi.gov/3EzXcd4>. Acesso em: 9 nov. 2022.

USGS. **Landsat 8-9 Collection 2 (C2) Level 2 Science Product (L2SP) Guide**. Sioux Falls, South Dakota: USGS, 2022. Disponível em: <https://bit.ly/3AP7LkB>. Acesso em: 15 out. 2022.

VAREJÃO-SILVA, M. A. **Meteorologia e Climatologia**. Versão Digital, 2 ed. Recife: [s.n.]: 2006. Disponível em: <https://bit.ly/3i3HFDR>. Acesso em: 26 out. 2022.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. 2. ed. Viçosa: Editora UFV, 2012.

WMO. **Guide to Instruments and Methods of Observation (WMO-No. 8)**. Genebra: WMO, 2018. Disponível em: <https://bit.ly/3EFK5QX>. Acesso em: 26 set. 2022.

ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. São Paulo: Oficina de Textos, 2019.

APÊNDICE A – Lista de imagens utilizadas

Abaixo são listadas as informações das imagens Landsat 8 utilizadas no estudo. O atributo “Identificação” pode ser lido como: LC08_PPPRRR_AAAAMMDD, para P = *path*, R = *row*, A = ano, M = mês e D = dia. A “Cobertura de nuvens” se refere à parcela contida nos limites da área de estudo.

(continua)

Identificação	Hora	Estação	Cobertura de nuvens	Declinação solar (rad)	Distância Terra-Sol (UA)
LC08_219079_20130405	13:08	Outono	0,00%	0,1008	1,0006
LC08_220079_20130417	13:13	Outono	0,00%	0,1779	1,0040
LC08_219079_20130731	13:07	Inverno	3,09%	0,3223	1,0150
LC08_220079_20130807	13:13	Inverno	1,27%	0,2906	1,0141
LC08_220079_20130908	13:13	Inverno	0,01%	0,1047	1,0074
LC08_219079_20131019	13:07	Primavera	0,17%	-0,1692	0,9959
LC08_220079_20140130	13:12	Verão	0,40%	-0,3122	0,9852
LC08_219079_20140413	13:05	Outono	1,51%	0,1529	1,0027
LC08_219079_20140616	13:05	Outono	0,04%	0,4072	1,0158
LC08_220079_20140725	13:11	Inverno	0,00%	0,3462	1,0157
LC08_219079_20140803	13:05	Inverno	1,20%	0,3092	1,0147
LC08_219079_20140819	13:05	Inverno	0,16%	0,2275	1,0120
LC08_220079_20140826	13:11	Inverno	0,00%	0,1866	1,0106
LC08_219079_20140920	13:05	Inverno	0,00%	0,0247	1,0043
LC08_220079_20141029	13:11	Primavera	0,37%	-0,2304	0,9933
LC08_219079_20150126	13:05	Verão	0,01%	-0,3303	0,9846
LC08_219079_20150227	13:05	Verão	0,00%	-0,1507	0,9903
LC08_220079_20150509	13:10	Outono	0,00%	0,2991	1,0095
LC08_219079_20150603	13:04	Outono	0,16%	0,3878	1,0143
LC08_220079_20150610	13:10	Outono	0,00%	0,4007	1,0152
LC08_219079_20150619	13:04	Outono	0,03%	0,4088	1,0161
LC08_220079_20150728	13:11	Inverno	0,00%	0,3347	1,0154
LC08_220079_20150829	13:11	Inverno	0,00%	0,1683	1,0099
LC08_220079_20150914	13:11	Inverno	0,95%	0,0650	1,0060
LC08_219079_20150923	13:05	Primavera	0,02%	0,0043	1,0035
LC08_219079_20160113	13:05	Verão	0,00%	-0,3772	0,9835
LC08_220079_20160120	13:11	Verão	0,12%	-0,3543	0,9840
LC08_220079_20160409	13:11	Outono	0,26%	0,1271	1,0018
LC08_219079_20160418	13:05	Outono	0,07%	0,1841	1,0043

(continuação)

Identificação	Hora	Estação	Cobertura de nuvens	Declinação solar (rad)	Distância Terra-Sol (UA)
LC08_219079_20160504	13:05	Outono	0,00%	0,2745	1,0085
LC08_220079_20160612	13:11	Outono	0,00%	0,4033	1,0156
LC08_219079_20160707	13:05	Inverno	0,02%	0,3959	1,0167
LC08_219079_20160723	13:05	Inverno	0,84%	0,3534	1,0159
LC08_219079_20170304	13:05	Verão	0,02%	-0,1175	0,9917
LC08_220079_20170412	13:11	Outono	0,00%	0,1465	1,0025
LC08_220079_20170428	13:11	Outono	0,00%	0,2425	1,0069
LC08_220079_20170514	13:11	Outono	0,01%	0,3217	1,0107
LC08_220079_20170701	13:11	Inverno	0,00%	0,4045	1,0167
LC08_219079_20170726	13:05	Inverno	0,05%	0,3424	1,0156
LC08_220079_20170802	13:11	Inverno	3,79%	0,3137	1,0148
LC08_220079_20170818	13:11	Inverno	0,00%	0,2331	1,0122
LC08_219079_20170912	13:05	Inverno	2,91%	0,0783	1,0063
LC08_219079_20180408	13:04	Outono	0,00%	0,1206	1,0013
LC08_219079_20180424	13:04	Outono	0,02%	0,2198	1,0057
LC08_219079_20180611	13:04	Outono	0,00%	0,4021	1,0154
LC08_219079_20180713	13:04	Inverno	0,02%	0,3832	1,0166
LC08_220079_20180720	13:10	Inverno	0,68%	0,3634	1,0161
LC08_219079_20180729	13:04	Inverno	0,01%	0,3307	1,0153
LC08_219079_20180814	13:04	Inverno	0,02%	0,2550	1,0130
LC08_220079_20180906	13:11	Inverno	3,49%	0,1177	1,0080
LC08_220079_20180922	13:11	Inverno	0,01%	0,0111	1,0037
LC08_219079_20181001	13:05	Primavera	1,16%	-0,0500	1,0012
LC08_219079_20181204	13:05	Primavera	0,01%	-0,3864	0,9856
LC08_220079_20190128	13:11	Verão	1,61%	-0,3214	0,9848
LC08_220079_20190402	13:11	Outono	0,58%	0,0808	0,9995
LC08_219079_20190411	13:05	Outono	1,80%	0,1401	1,0021
LC08_220079_20190418	13:11	Outono	0,63%	0,1841	1,0040
LC08_220079_20190520	13:11	Outono	0,02%	0,3457	1,0119
LC08_219079_20190529	13:05	Outono	0,00%	0,3752	1,0136
LC08_220079_20190621	13:11	Inverno	0,00%	0,4093	1,0162
LC08_220079_20190707	13:11	Inverno	0,02%	0,3959	1,0167
LC08_219079_20190716	13:05	Inverno	0,01%	0,3754	1,0164
LC08_220079_20190723	13:11	Inverno	0,00%	0,3534	1,0160
LC08_220079_20190808	13:11	Inverno	0,00%	0,2857	1,0140
LC08_220079_20191011	13:12	Primavera	0,21%	-0,1172	0,9983
LC08_219079_20191207	13:05	Primavera	0,06%	-0,3931	0,9852

(conclusão)

Identificação	Hora	Estação	Cobertura de nuvens	Declinação solar (rad)	Distância Terra-Sol (UA)
LC08_219079_20200312	13:05	Verão	1,24%	-0,0632	0,9938
LC08_220079_20200319	13:11	Verão	0,00%	-0,0149	0,9957
LC08_220079_20200404	13:11	Outono	0,00%	0,0942	1,0003
LC08_220079_20200420	13:11	Outono	0,41%	0,1962	1,0049
LC08_219079_20200429	13:05	Outono	0,01%	0,2480	1,0072
LC08_219079_20200531	13:05	Outono	0,00%	0,3806	1,0140
LC08_220079_20200607	13:11	Outono	0,00%	0,3959	1,0150
LC08_220079_20200623	13:11	Inverno	2,69%	0,4093	1,0165
LC08_219079_20200803	13:05	Inverno	0,01%	0,3092	1,0146
LC08_220079_20200810	13:11	Inverno	0,00%	0,2757	1,0136
LC08_220079_20210218	13:11	Verão	0,00%	-0,2079	0,9884
LC08_220079_20210306	13:11	Verão	0,20%	-0,1041	0,9922
LC08_219079_20210331	13:05	Outono	0,10%	0,0673	0,9990
LC08_219079_20210502	13:05	Outono	4,52%	0,2641	1,0079
LC08_219079_20210518	13:05	Outono	0,01%	0,3381	1,0116
LC08_220079_20210525	13:11	Outono	0,00%	0,3631	1,0129
LC08_220079_20210712	13:11	Inverno	0,00%	0,3856	1,0166
LC08_220079_20210728	13:11	Inverno	0,00%	0,3347	1,0154
LC08_219079_20210822	13:05	Inverno	4,48%	0,2103	1,0113
LC08_220079_20220205	13:11	Verão	0,00%	-0,2823	0,9860
LC08_219079_20220318	13:05	Verão	0,01%	-0,0218	0,9952
LC08_219079_20220419	13:05	Outono	3,89%	0,1902	1,0043
LC08_220079_20220512	13:11	Outono	0,00%	0,3129	1,0102
LC08_219079_20220521	13:05	Outono	0,02%	0,3494	1,0121
LC08_220079_20220613	13:11	Outono	0,00%	0,4045	1,0155
LC08_220079_20220731	13:12	Inverno	0,00%	0,3223	1,0151
LC08_220079_20220901	13:12	Inverno	0,00%	0,1496	1,0092

Fonte: elaborado pelo autor.

APÊNDICE B – Dados Meteorológicos

Abaixo são apresentados os valores de temperatura do ar (T_a) e umidade relativa do ar (u_r) da hora mais próxima do momento de aquisição das imagens.

(continua)

Data	Hora	Estação	Temperatura do ar (°C)	Umidade relativa do ar
05/04/2013	14:00	Outono	30,7	44%
17/04/2013	14:00	Outono	24,7	56%
31/07/2013	14:00	Inverno	18,4	71%
07/08/2013	14:00	Inverno	22,0	54%
08/09/2013	14:00	Inverno	23,8	66%
19/10/2013	14:00	Primavera	25,8	60%
30/01/2014	14:00	Verão	31,3	64%
13/04/2014	14:00	Outono	23,9	71%
16/06/2014	14:00	Outono	24,9	66%
25/07/2014	14:00	Inverno	17,3	57%
03/08/2014	14:00	Inverno	29,9	41%
19/08/2014	14:00	Inverno	23,4	67%
26/08/2014	14:00	Inverno	22,8	35%
20/09/2014	14:00	Inverno	22,5	78%
29/10/2014	14:00	Primavera	26,6	57%
26/01/2015	14:00	Verão	31,6	55%
27/02/2015	14:00	Verão	28,1	66%
09/05/2015	14:00	Outono	26,2	47%
03/06/2015	14:00	Outono	24,4	52%
10/06/2015	14:00	Outono	28,3	50%
19/06/2015	14:00	Outono	17,0	56%
28/07/2015	14:00	Inverno	22,6	68%
29/08/2015	14:00	Inverno	24,8	54%
14/09/2015	14:00	Inverno	22,9	56%
23/09/2015	14:00	Primavera	25,2	72%
13/01/2016	14:00	Verão	31,8	60%
20/01/2016	14:00	Verão	29,0	54%
09/04/2016	14:00	Outono	32,2	63%
18/04/2016	14:00	Outono	33,2	57%
04/05/2016	14:00	Outono	21,9	69%
12/06/2016	14:00	Outono	16,6	28%
07/07/2016	14:00	Inverno	20,9	34%

(continuação)

Data	Hora	Estação	Temperatura do ar (°C)	Umidade relativa do ar
23/07/2016	14:00	Inverno	20,1	58%
04/03/2017	14:00	Verão	34,0	53%
12/04/2017	14:00	Outono	24,0	59%
28/04/2017	14:00	Outono	23,2	43%
14/05/2017	14:00	Outono	24,0	69%
01/07/2017	14:00	Inverno	19,9	67%
26/07/2017	14:00	Inverno	22,4	68%
02/08/2017	14:00	Inverno	23,4	63%
18/08/2017	14:00	Inverno	23,0	60%
12/09/2017	14:00	Inverno	23,1	74%
08/04/2018	14:00	Outono	29,8	53%
24/04/2018	14:00	Outono	29,1	48%
11/06/2018	14:00	Outono	22,5	77%
13/07/2018	14:00	Inverno	19,0	51%
20/07/2018	14:00	Inverno	23,4	66%
29/07/2018	14:00	Inverno	19,1	75%
14/08/2018	14:00	Inverno	22,1	54%
06/09/2018	14:00	Inverno	21,4	49%
22/09/2018	14:00	Inverno	25,7	67%
01/10/2018	14:00	Primavera	30,3	56%
04/12/2018	14:00	Primavera	28,6	42%
28/01/2019	14:00	Verão	32,0	64%
02/04/2019	14:00	Outono	29,4	53%
11/04/2019	14:00	Outono	29,7	48%
18/04/2019	14:00	Outono	26,7	59%
20/05/2019	14:00	Outono	25,3	67%
29/05/2019	14:00	Outono	23,3	72%
21/06/2019	14:00	Inverno	22,0	61%
07/07/2019	14:00	Inverno	16,2	49%
16/07/2019	14:00	Inverno	18,7	36%
23/07/2019	14:00	Inverno	25,8	57%
08/08/2019	14:00	Inverno	24,8	66%
11/10/2019	14:00	Primavera	26,6	55%
07/12/2019	14:00	Primavera	26,7	46%
12/03/2020	14:00	Verão	29,2	58%
19/03/2020	14:00	Verão	30,3	59%
04/04/2020	14:00	Outono	26,7	44%
20/04/2020	14:00	Outono	27,3	45%

(conclusão)

Data	Hora	Estação	Temperatura do ar (°C)	Umidade relativa do ar
29/04/2020	14:00	Outono	29,4	52%
31/05/2020	14:00	Outono	28,0	31%
07/06/2020	14:00	Outono	24,1	43%
23/06/2020	14:00	Inverno	25,7	57%
03/08/2020	14:00	Inverno	22,5	62%
10/08/2020	14:00	Inverno	23,8	65%
18/02/2021	14:00	Verão	29,0	44%
06/03/2021	14:00	Verão	27,8	59%
31/03/2021	14:00	Outono	24,5	54%
02/05/2021	14:00	Outono	26,2	54%
18/05/2021	14:00	Outono	21,1	54%
25/05/2021	14:00	Outono	20,0	53%
12/07/2021	14:00	Inverno	22,6	64%
28/07/2021	14:00	Inverno	14,6	31%
22/08/2021	14:00	Inverno	22,3	70%
05/02/2022	14:00	Verão	33,4	55%
18/03/2022	14:00	Verão	30,6	66%
19/04/2022	14:00	Outono	25,7	51%
12/05/2022	14:00	Outono	22,4	50%
21/05/2022	14:00	Outono	20,3	65%
13/06/2022	14:00	Outono	20,0	62%
31/07/2022	14:00	Inverno	20,4	57%
01/09/2022	14:00	Inverno	22,2	58%

Fonte: INMET (2022).

APÊNDICE C – Testes de Kruskal-Wallis

Abaixo são listadas as estatísticas-teste e os *p-values* obtidos da aplicação do teste de Kruskal-Wallis com ajuste de Bonferroni para verificação da existência de diferenças significativas nos saldos de radiação entre estações do ano.

Saldo	Parâmetro	DUN	FOD	LCP	LCR	RAA	SIL	URB	VHE
Ondas curtas	Estatística	46,23	46,93	46,39	46,38	46,62	46,64	46,66	46,50
	<i>p-value</i> (10^{-10})	5,1	3,6	4,7	4,7	4,2	4,1	4,1	4,4
Ondas longas	Estatística	47,93	48,95	49,70	44,57	48,87	49,38	48,86	47,48
	<i>p-value</i> (10^{-10})	2,2	1,3	0,9	11,4	1,4	1,1	1,4	2,7
Total	Estatística	45,29	47,05	46,50	46,49	46,61	46,61	46,66	46,59
	<i>p-value</i> (10^{-10})	8,0	3,4	4,4	4,5	4,2	4,2	4,1	4,2

Fonte: elaborado pelo autor.

APÊNDICE D – Teste post-hoc de Dunn: Saldo de ondas curtas

Abaixo são listados os *p-values* obtidos da aplicação do teste *post-hoc* de Dunn com ajuste de Bonferroni para verificação de diferenças de R_n^S entre estações.

Classe	Estação	Primavera	Verão	Outono
DUN	Verão	1,0000		
	Outono	0,0010	< 0,0001	
	Inverno	0,0004	< 0,0001	1,0000
FOD	Verão	1,0000		
	Outono	0,0005	< 0,0001	
	Inverno	0,0014	< 0,0001	1,0000
LCP	Verão	1,0000		
	Outono	0,0004	< 0,0001	
	Inverno	0,0002	< 0,0001	1,0000
LCR	Verão	1,0000		
	Outono	0,0004	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
RAA	Verão	1,0000		
	Outono	0,0003	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
SIL	Verão	1,0000		
	Outono	0,0004	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
URB	Verão	1,0000		
	Outono	0,0004	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
VHE	Verão	1,0000		
	Outono	0,0007	< 0,0001	
	Inverno	0,0004	< 0,0001	1,0000

Fonte: elaborado pelo autor.

Legenda: valores em vermelho indicam *p-value* < 0,05, isto é, há diferença entre os grupos.

APÊNDICE E – Teste post-hoc de Dunn: Saldo de ondas longas

Abaixo são listados os *p-values* obtidos da aplicação do teste *post-hoc* de Dunn com ajuste de Bonferroni para verificação de diferenças de R_n^L entre estações.

Classe	Estação	Primavera	Verão	Outono
DUN	Verão	1,0000		
	Outono	0,0092	< 0,0001	
	Inverno	0,0001	< 0,0001	0,3687
FOD	Verão	1,0000		
	Outono	0,0193	< 0,0001	
	Inverno	0,0003	< 0,0001	0,2843
LCP	Verão	1,0000		
	Outono	0,0622	< 0,0001	
	Inverno	0,0004	< 0,0001	0,0852
LCR	Verão	1,0000		
	Outono	0,0356	0,0002	
	Inverno	0,0002	< 0,0001	0,0966
RAA	Verão	1,0000		
	Outono	0,0070	< 0,0001	
	Inverno	0,0002	< 0,0001	0,5957
SIL	Verão	1,0000		
	Outono	0,0095	< 0,0001	
	Inverno	0,0002	< 0,0001	0,4148
URB	Verão	1,0000		
	Outono	0,0036	< 0,0001	
	Inverno	0,0001	< 0,0001	0,5151
VHE	Verão	1,0000		
	Outono	0,0017	< 0,0001	
	Inverno	0,0001	< 0,0001	0,9360

Fonte: elaborado pelo autor.

Legenda: valores em vermelho indicam *p-value* < 0,05, isto é, há diferença entre os grupos.

APÊNDICE F – Teste post-hoc de Dunn: Saldo total

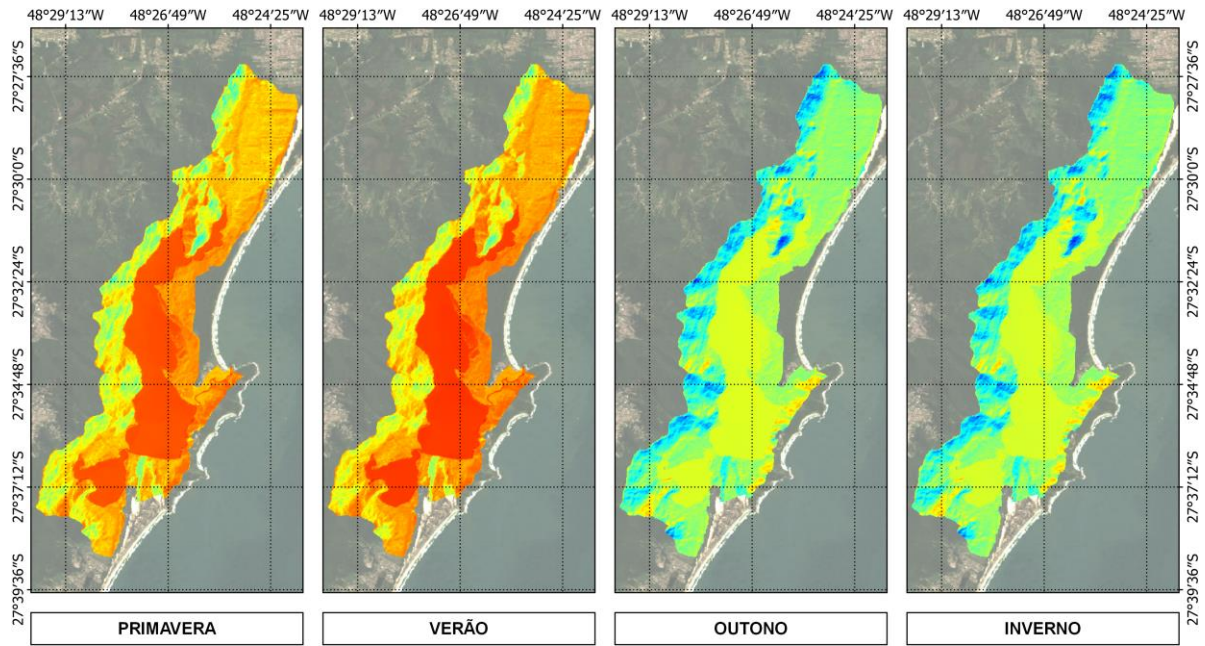
Abaixo são listados os *p-values* obtidos da aplicação do teste *post-hoc* de Dunn com ajuste de Bonferroni para verificação de diferenças de R_n entre estações.

Classe	Estação	Primavera	Verão	Outono
DUN	Verão	1,0000		
	Outono	0,0011	< 0,0001	
	Inverno	0,0006	< 0,0001	1,0000
FOD	Verão	1,0000		
	Outono	0,0004	< 0,0001	
	Inverno	0,0017	< 0,0001	1,0000
LCP	Verão	1,0000		
	Outono	0,0003	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
LCR	Verão	1,0000		
	Outono	0,0003	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
RAA	Verão	1,0000		
	Outono	0,0003	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
SIL	Verão	1,0000		
	Outono	0,0003	< 0,0001	
	Inverno	0,0003	< 0,0001	1,0000
URB	Verão	1,0000		
	Outono	0,0004	< 0,0001	
	Inverno	0,0004	< 0,0001	1,0000
VHE	Verão	1,0000		
	Outono	0,0006	< 0,0001	
	Inverno	0,0005	< 0,0001	1,0000


Fonte: elaborado pelo autor.

Legenda: valores em vermelho indicam *p-value* < 0,05, isto é, há diferença entre os grupos.

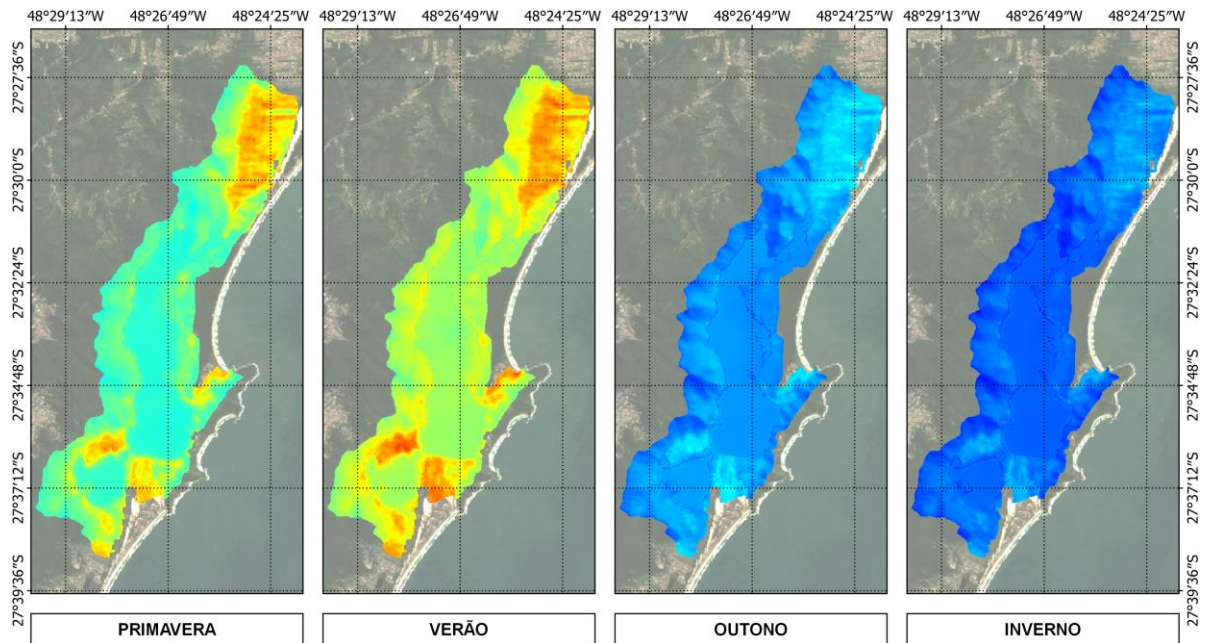
APÊNDICE G – Mapas do saldo de radiação



Saldo de radiação de ondas curtas



0 1 2 km



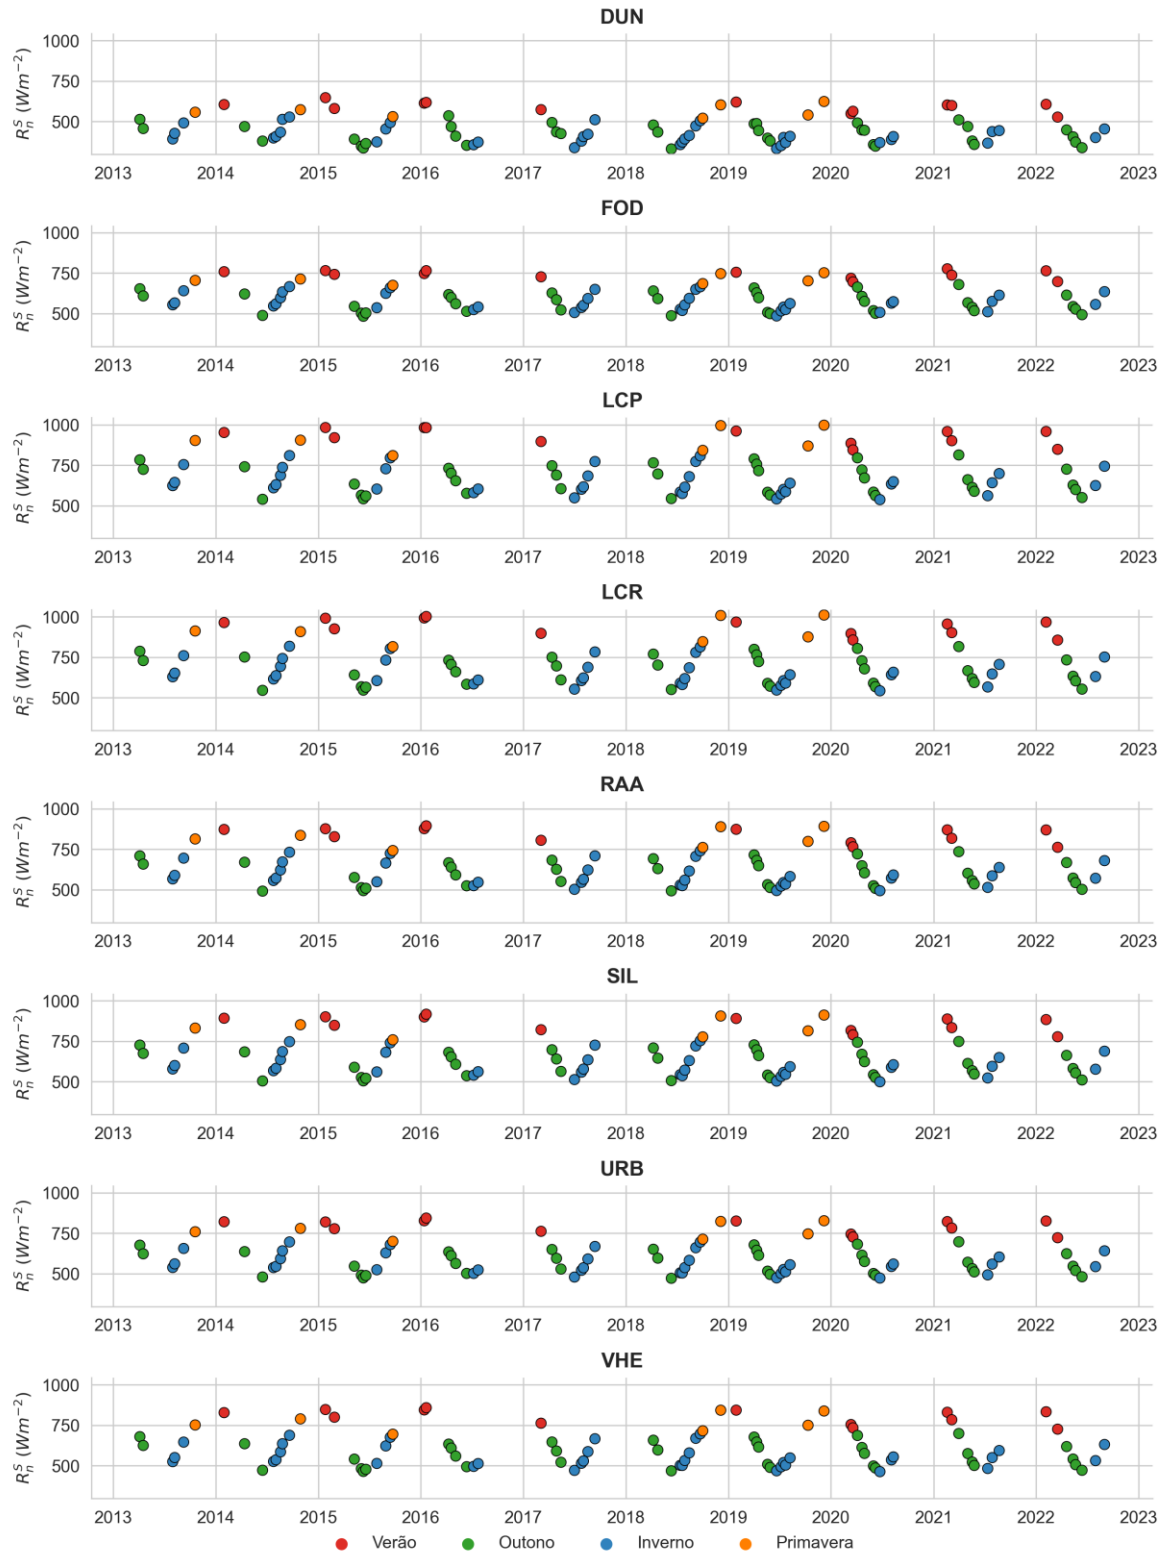
Saldo de radiação de ondas longas



0 1 2 km

APÊNDICE H – Série temporal: Saldo de radiação de ondas curtas

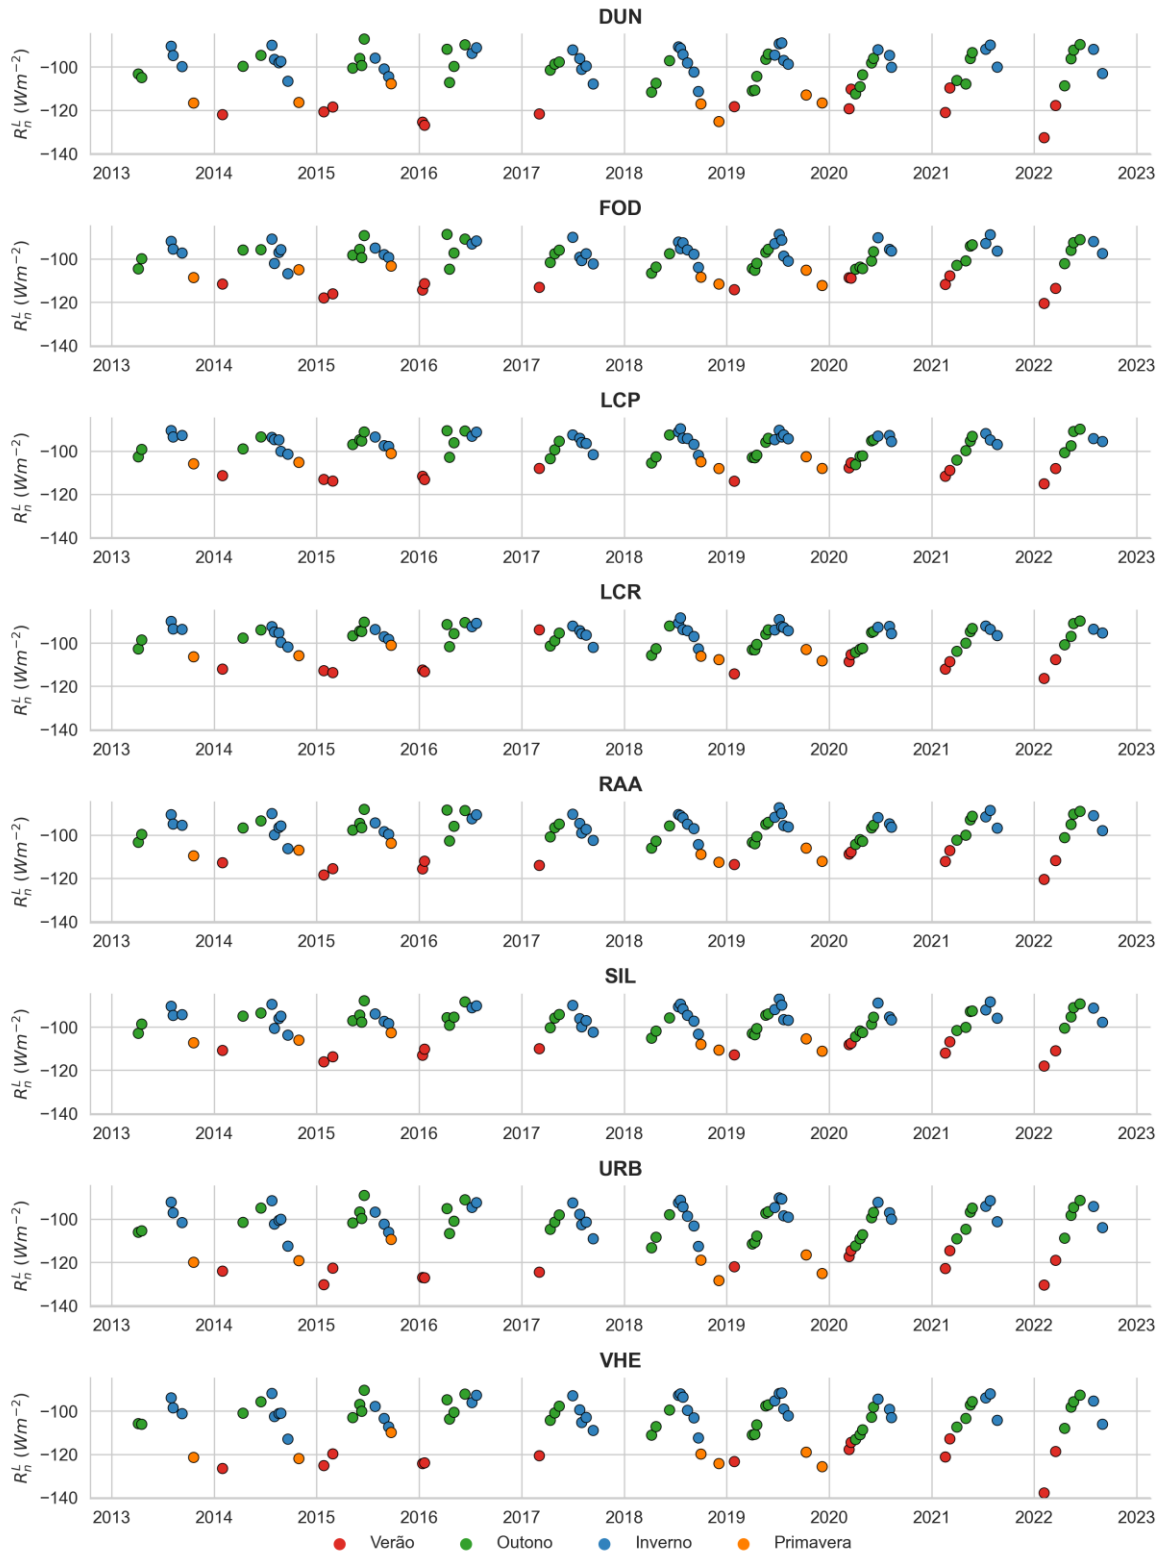
Gráfico com o R_n^S mediano de cada imagem avaliada para cada classe de cobertura do solo.



Fonte: elaborado pelo autor.

APÊNDICE I – Série temporal: Saldo de radiação de ondas longas

Gráfico com o R_n^L mediano de cada imagem avaliada para cada classe de cobertura do solo.



Fonte: elaborado pelo autor.

APÊNDICE J – Código 1/3: funções auxiliares

Este código pode ser encontrado no repositório do GitHub sob o nome *user_functions.py* (https://github.com/b-rech/net_radiation).

```
# %% INITIALIZATION

# Required libraries
import ee
import pandas as pd
import numpy as np

# GEE initialization
ee.Initialize()

# %% CLOUD MASK

def cloud_mask(image):

    # Select cloud band
    # It is assigned 1 to the selected pixels and 0 to the others
    # Bit 6: 1 to clear sky and 0 to cloud or dilated cloud
    clear = image.select('QA_PIXEL').bitwiseAnd(1<<6)

    return image.updateMask(clear)

# %% APPLY SCALE AND OFFSET FACTORS

def scale_L8(image):

    # Scale and offset optical bands
    optical_bands = image.select('SR_B.').multiply(0.0000275).add(-0.2)

    # Scale and offset thermal band (LST)
    thermal_band = image.select('ST_B10').multiply(0.00341802).add(149)

    return (image.addBands(optical_bands, overwrite=True)
            .addBands(thermal_band, overwrite=True))

# %% CREATE PIXEL LAT/LONG BANDS

def pixels_coords(image):

    # Generate a band with pixel coordinates (radians)
    coords = image.pixelLonLat().multiply(np.pi/180).rename(['long', 'lat'])

    return image.addBands(coords)

# %% RETRIEVE DAY OF YEAR B, E AND DECLINATION

def declination(image):

    # Retrieve month
    month = image.date().get('month')

    # Retrieve day
    day = image.date().get('day')

    # Calculate day of year (generates ee.Number)
    day_of_year = ee.List(
        [ee.Algorithms.If(month.eq(1), day),
         ee.Algorithms.If(month.eq(2), day.add(31)),
         ee.Algorithms.If(month.eq(3), day.add(59)),
         ee.Algorithms.If(month.eq(4), day.add(90)),
         ee.Algorithms.If(month.eq(5), day.add(120)),
```

```

        ee.Algorithms.If(month.eq(6), day.add(151)),
        ee.Algorithms.If(month.eq(7), day.add(181)),
        ee.Algorithms.If(month.eq(8), day.add(212)),
        ee.Algorithms.If(month.eq(9), day.add(243)),
        ee.Algorithms.If(month.eq(10), day.add(273)),
        ee.Algorithms.If(month.eq(11), day.add(304)),
        ee.Algorithms.If(month.eq(12), day.add(334))]
    ).getNumber(month.subtract(1))

# Calculate B (in radians)
B = day_of_year.subtract(1).multiply(2*np.pi/365)

# Calculate E (in minutes)
E = ee.Number(229.2).multiply(
    ee.Number(0.000075)
    .add(B.cos().multiply(0.001868))
    .subtract(B.sin().multiply(0.032077))
    .subtract(B.multiply(2).cos().multiply(0.014615))
    .subtract(B.multiply(2).sin().multiply(0.04089)))

# Calculate declination (Spencer Equation, in radians)
declination = (ee.Number(0.006918)
    .subtract(B.cos().multiply(0.399912))
    .add(B.sin().multiply(0.070257))
    .subtract(B.multiply(2).cos().multiply(0.006758))
    .add(B.multiply(2).sin().multiply(0.000907))
    .subtract(B.multiply(3).cos().multiply(0.002697))
    .add(B.multiply(3).sin().multiply(0.00148)))

# Set metadata
return image.set({'DAY_OF_YEAR':day_of_year, 'B':B, 'E':E,
    'DECLINATION':declination})

# %% RETRIEVE SOLAR ZENITH ANGLE COSINE OVER A HORIZONTAL SURFACE

def cos_theta_hor(image):

    # Band with pixel latitudes (radians)
    lat = image.select('lat')

    # Declination
    declination = image.getNumber('DECLINATION')

    # Hour angle
    hour_angle = image.getNumber('HOUR_ANGLE')

    # Calculate cosine of theta
    cos_theta_hor = (lat.sin().multiply(declination.sin())
        .add(lat.cos()
            .multiply(declination.cos())
            .multiply(hour_angle.cos())))

    return image.addBands(cos_theta_hor.rename('cos_theta_hor'))

# %% RETRIEVE SOLAR INCIDENCE ANGLE COSINE

def cos_theta_rel(image):

    # Band with pixel latitudes (radians)
    lat = image.select('lat')

    # Declination
    declination = image.getNumber('DECLINATION')

    # Hour angle
    hour_angle = image.getNumber('HOUR_ANGLE')

    # Slope band

```

```

slope = image.select('slope')

# Aspect band
aspect = image.select('aspect')

# Calculate cos_theta_rel
cos_theta_rel = ((lat.sin().multiply(slope.cos()).multiply(declination.sin()))
                 .subtract(lat.cos().multiply(slope.sin())
                           .multiply(aspect.cos()).multiply(declination.sin()))
                 .add(lat.cos().multiply(slope.cos()).multiply(hour_angle.cos())
                      .multiply(declination.cos()))
                 .add(lat.sin().multiply(slope.sin()).multiply(aspect.cos())
                      .multiply(hour_angle.cos()).multiply(declination.cos()))
                 .add(aspect.sin().multiply(slope.sin())
                      .multiply(hour_angle.sin()).multiply(declination.cos())))

return image.addBands(cos_theta_rel.rename('cos_theta_rel'))

# %% RETRIEVE ATMOSPHERIC PRESSURE
def atm_pressure(image):

    # Select elevation band
    elev = image.select('elevation')

    # Calculate pressure (kPa)
    atm_pressure = ((elev.multiply(-0.0065).add(293))
                   .divide(293)).pow(5.26)).multiply(101.3)

    return image.addBands(atm_pressure.rename('p_atm'))

# %% PRECIPITABLE WATER
def prec_water(image):

    # Retrieve saturation vapor pressure and relative humidity
    sat_vp = image.getNumber('SAT_VP')
    rel_hum = image.getNumber('REL_HUM')

    # Retrieve atmospheric pressure
    p = image.select('p_atm')

    # Calculate actual vapor pressure
    act_vp = (p.multiply(3.15E-5)
              .add(p.pow(-1).multiply(-0.074))
              .add(1.0016)
              .multiply(sat_vp).multiply(rel_hum))

    # Calculate precipitable water (mm)
    prec_w = act_vp.multiply(p).multiply(0.14).add(2.1)

    # Add band 'prec_water' to the image
    return image.addBands(prec_w.rename('prec_water'))

# %% ATMOSPHERIC TRANSMISSIVITY
def atm_trans(image):

    # Retrieve required parameters:

    # Atmospheric pressure
    p = image.select('p_atm')

    # Precipitable water
    w = image.select('prec_water')

    # Cosine of solar zenith angle over a horizontal surface
    c_theta_hor = image.select('cos_theta_hor')

```

```

# Turbidity coefficient assumed to be 1
kt = 1

# Retrieve atmospheric transmissivity
atm_trans = ((p.multiply(-0.00146).divide(c_theta_hor.multiply(kt))
              .add(w.divide(c_theta_hor).pow(0.4).multiply(-0.075))).exp()
              .multiply(0.627)).add(0.35)

# Add calculated band to image
return image.addBands(atm_trans.rename('atm_trans'))

# %% DOWNWARD SHORTWAVE RADIATION

def dw_sw_rad(image):

    # Solar constant
    G = 1367 # W/m2

    # Cosine of solar incidence angle
    c_theta_rel = image.select('cos_theta_rel')

    # Atmospheric transmissivity
    trans = image.select('atm_trans')

    # Earth-Sun distance
    d = image.getNumber('EARTH_SUN_DISTANCE')

    # Calculate incident radiation
    dw_sw_rad = c_theta_rel.multiply(trans).multiply(G).divide(d.pow(2))

    return image.addBands(dw_sw_rad.rename('dw_sw_rad'))

# %% ALBEDO RETRIEVAL

# Calculate albedo using model proposed by Angelini et al. (2021)
def get_albedo(image):

    # Select required bands
    b2 = image.select('SR_B2')
    b3 = image.select('SR_B3')
    b4 = image.select('SR_B4')
    b5 = image.select('SR_B5')
    b6 = image.select('SR_B6')
    b7 = image.select('SR_B7')

    # Apply model (equation)
    albedo = (b2.multiply(0.4739)
              .add(b3.multiply(-0.4372))
              .add(b4.multiply(0.1652))
              .add(b5.multiply(0.2831))
              .add(b6.multiply(0.1072))
              .add(b7.multiply(0.1029))
              .add(0.0366))

    return image.addBands(albedo.rename('albedo'))

# %% UPWARD SHORTWAVE RADIATION

def up_sw_rad(image):

    # Retrieve reflected radiation
    up_sw_rad = image.select('dw_sw_rad').multiply(image.select('albedo'))

    return image.addBands(up_sw_rad.rename('up_sw_rad'))

```

```

# %% NET SHORTWAVE RADIATION

def net_sw_rad(image):

    # Upward and downward fluxes
    up = image.select('up_sw_rad')
    down = image.select('dw_sw_rad')

    # Net shortwave radiation
    budget = down.subtract(up)

    return image.addBands(budget.rename('net_sw_rad'))

# %% ATMOSPHERIC EMISSIVITY

def atm_emiss(image):

    # Select atmospheric transmissivity
    trans = image.select('atm_trans')

    # Retrieve atmospheric emissivity
    atm_emiss = trans.log().multiply(-1).pow(0.09).multiply(0.85)

    return image.addBands(atm_emiss.rename('atm_emiss'))

# %% DOWNWARD LONGWAVE RADIATION

def dw_lw_rad(image):

    # Select temperature band (scaled to K)
    temp = image.select('ST_B10')

    # Select atmospheric emissivity band
    emiss = image.select('atm_emiss')

    # Apply Stefan-Boltzmann equation (W/m2)
    dw_lw_rad = temp.pow(4).multiply(emiss).multiply(5.67E-8)

    # Add band to scene
    return image.addBands(dw_lw_rad.rename('dw_lw_rad'))

# %% UPWARD LONGWAVE RADIATION

def up_lw_rad(image):

    # Select temperature band (scaled to K)
    temp = image.select('ST_B10')

    # Select emissivity band
    emiss = image.select('emiss')

    # Apply Stefan-Boltzmann equation (W/m2)
    up_lw_rad = temp.pow(4).multiply(emiss).multiply(5.67E-8)

    # Add band to scene
    return image.addBands(up_lw_rad.rename('up_lw_rad'))

# %% NET LONGWAVE RADIATION

def net_lw_rad(image):

    # Upward and downward fluxes
    up = image.select('up_lw_rad')
    down = image.select('dw_lw_rad')

    # Emissivity
    emiss = image.select('emiss')

```



```

# Net longwave radiation (W/m2)
budget = emiss.multiply(down).subtract(up)

return image.addBands(budget.rename('net_lw_rad'))

# %% ALL-WAVE NET RADIATION

def all_wave_rn(image):

    # Downward shortwave radiation
    dw_sw = image.select('dw_sw_rad')

    # Upward shortwave radiation
    up_sw = image.select('up_sw_rad')

    # Downward longwave radiation
    dw_lw = image.select('dw_lw_rad')

    # Upward longwave radiation
    up_lw = image.select('up_lw_rad')

    # Surface emissivity
    emiss = image.select('emiss')

    # Instantaneous all-wave net radiation (W/m2)
    Rn = dw_sw.subtract(up_sw).add(emiss.multiply(dw_lw)).subtract(up_lw)

    return image.addBands(Rn.rename('Rn'))

# %% SET SEASON

# Includes season in image metadata
def set_season(image):

    # Select month
    month = image.date().get('month')

    # Select day
    day = image.date().get('day')

    # Retrieve the season
    season = ee.List(
        [ee.Algorithms.If(month.eq(1), 'Summer'),
         ee.Algorithms.If(month.eq(2), 'Summer'),
         ee.Algorithms.If(month.eq(3).And(day.lt(21)), 'Summer', 'Fall'),
         ee.Algorithms.If(month.eq(4), 'Fall'),
         ee.Algorithms.If(month.eq(5), 'Fall'),
         ee.Algorithms.If(month.eq(6).And(day.lt(21)), 'Fall', 'Winter'),
         ee.Algorithms.If(month.eq(7), 'Winter'),
         ee.Algorithms.If(month.eq(8), 'Winter'),
         ee.Algorithms.If(month.eq(9).And(day.lt(23)), 'Winter', 'Spring'),
         ee.Algorithms.If(month.eq(10), 'Spring'),
         ee.Algorithms.If(month.eq(11), 'Spring'),
         ee.Algorithms.If(month.eq(12).And(day.lt(21)), 'Spring', 'Summer')]
    ).get(month.subtract(1))

    # Set to metadata
    return image.set({'SEASON':season})

# %% GENERATE METADATA DATAFRAME

def list_info_df(properties_list):

    # Variable initialization
    ids = []
    date = []
    time = []
    season = []

```

```

cloudiness = []
declination = []
earth_sun_dist = []
air_temp = []
rel_hum = []

# Information retrieval
for j in range(0, len(properties_list)):

    ids.append(
        properties_list[j]['properties']['system:index'])

    date.append(
        properties_list[j]['properties']['system:time_start'])

    time.append(
        properties_list[j]['properties']['SCENE_CENTER_TIME'])

    season.append(
        properties_list[j]['properties']['SEASON'])

    cloudiness.append(
        properties_list[j]['properties']['CLOUDINESS'])

    declination.append(
        properties_list[j]['properties']['DECLINATION'])

    earth_sun_dist.append(
        properties_list[j]['properties']['EARTH_SUN_DISTANCE'])

    air_temp.append(
        properties_list[j]['properties']['AIR_TEMP'])

    rel_hum.append(
        properties_list[j]['properties']['REL_HUM'])

# Dataframe's generation
infos = pd.DataFrame({
    'id':ids,
    'date':date,
    'time':time,
    'season':season,
    'cloudiness':cloudiness,
    'declination':declination,
    'earth_sun_dist':earth_sun_dist,
    'air_temp':air_temp,
    'rel_hum':rel_hum})

infos['date'] = pd.to_datetime(infos['date'], unit='ms')

return infos

# %% TRANSFORM SHAPEFILES TO EE.GEOMETRIES

def shape_to_feature_coll(shapefile):

    '''
    Transforms a multipolygon shapefile (geopandas Dataframe) into
    an ee.FeatureCollection
    The shapefile must have a field called "classes"
    '''

    # Empty list to save the polygons
    samples_list = ee.List([])

    # Iterate over each polygon
    for pol in range(0, len(shapefile)):

```

```
# Select the feature of interest
polygon = (np.dstack(shapefile.geometry[pol].geoms[0]
                    .exterior.coords.xy).tolist())

# Create a ee.Feature with the external coordinates
geometry = ee.Feature(ee.Geometry.Polygon(polygon))

geometry = geometry.set({'classes':shapefile.classes[pol]})

# Append the geometry to the list
samples_list = samples_list.add(geometry)

return ee.FeatureCollection(samples_list)
```

APÊNDICE K – Código 2/3: processamento das imagens

Este código pode ser encontrado no repositório do GitHub sob o nome *imagery_analyses.py* (https://github.com/b-rech/net_radiation).

```
# %% REQUIRED LIBRARIES AND SCRIPTS

# Required libraries
import ee
import numpy as np
import pandas as pd
import geopandas as gpd
import geemap

# Required scripts
# user_functions includes user-defined functions used in the analyses
from user_functions import *

# GEE authentication and initialization
# ee.Authenticate()
ee.Initialize()

#%% VECTOR LAYERS UPLOAD

# Upload contours of the basin and lagoon
basin = gpd.read_file('vectors\\vector_layers.gpkg', layer='basin_area')
lagoon = gpd.read_file('vectors\\vector_layers.gpkg', layer='lagoon')

# Extract coordinates
basin_coord = np.dstack(basin.geometry[0].geoms[0]
                        .exterior.coords.xy).tolist()

lagoon_coord = np.dstack(lagoon.geometry[0].geoms[0]
                        .exterior.coords.xy).tolist()

# Create ee.Geometry with external coordinates
basin_geom = ee.Geometry.Polygon(basin_coord)
lagoon_geom = ee.Geometry.Polygon(lagoon_coord)

# Create rectangle for clipping images
rect = ee.Geometry.Rectangle([-48.37428696492995, -27.68296346714984,
                             -48.56174151517356, -27.42983615496652])

# Upload samples
samples = gpd.read_file('vectors\\vector_layers.gpkg', layer='samples')

# Transform samples to ee.FeatureCollection (from user_functions)
samples_geom = shape_to_feature_coll(samples)

# %% METEOROLOGICAL DATA UPLOAD

# Upload meteorological data from weather station
met_data = pd.read_csv('data_station_inmet.csv', sep=';', decimal=',',
                      skiprows=10)

# Select and rename attributes
met_data = (met_data.iloc[:, [0, 1, 3, 7, 9, 18]]
            .dropna().reset_index(drop=True))
met_data.columns = ['date', 'hour', 'p_atm', 'rad', 'air_temp', 'rel_hum']

# Convert data
met_data['hour'] = met_data.loc[:, 'hour']/100 - 3
met_data['rel_hum'] = met_data.loc[:, 'rel_hum']/100
```

```

# Select dates between 11h and 15h only (L8 passes usually around 13h)
met_data = met_data[[11 <= h <= 15 for h in met_data.hour]]

# Atmospheric pressure from hPa to kPa
met_data['p_atm'] = met_data.loc[:, 'p_atm']/10

# Units: atmospheric pressure in kPa, global radiation in kJ/m²,
# air temperature (dry-bulb) in °C.

# %% SELECTION OF LANDSAT AND SRTM DATA

# Filter Landsat 8 imagery by:
# bounds;
# processing level (L2SP = both optical and thermal bands);
# sensors quality (0=worst, 9=best);
landsat8 = (ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
           .filterBounds(basin_geom)
           .filter(ee.Filter.contains('.geo', basin_geom))
           .filter(ee.Filter.eq('PROCESSING_LEVEL', 'L2SP'))
           .filter(ee.Filter.eq('IMAGE_QUALITY_OLI', 9))
           .filter(ee.Filter.eq('IMAGE_QUALITY_TIRS', 9))
           .filterDate(start='2013-01-01', opt_end='2022-09-30'))

# CLOUD COVER ASSESSMENT

# Function to retrieve cloud cover over the area of interest
def get_cloud_percent(image):
    """
    This function calculates the cloud cover proportion within the geometry and
    adds it to the metadata as a new attribute called CLOUDINESS.
    """

    # Select cloud band
    # It is assigned 1 to the selected pixels and 0 to the others
    # Bit 6: 1 to clear sky and 0 to cloud or dilated cloud
    cloud_band = (image.select(['QA_PIXEL']).bitwiseAnd(1<<6).eq(0))

    # Generate cloud proportion
    # Since the values are just 0 e 1, the mean is equal to the proportion
    # An ee.Dictionary is generated with the key renamed to "cloudiness"
    cloud_percent = cloud_band.reduceRegion(**{
        'reducer':ee.Reducer.mean(),
        'geometry':basin_geom,
        'scale':30}).rename(['QA_PIXEL'], ['CLOUDINESS'], True)

    # Add information to image metadata
    return image.set(cloud_percent)

# Map function over the collection
dataset1 = landsat8.map(get_cloud_percent)

# Filter images (cloudiness limit of 5%)
# Remove 3 bad images (manually detected)
# and apply cloud mask (from user_functions)
dataset2 = (dataset1.filter(ee.Filter.lte('CLOUDINESS', 0.05))
           .filter(ee.Filter.neq('system:index', 'LC08_219079_20151025'))
           .filter(ee.Filter.neq('system:index', 'LC08_219079_20210227'))
           .filter(ee.Filter.neq('system:index', 'LC08_220079_20140623'))
           .map(cloud_mask).sort('system:time_start'))

# ELEVATION DATA

# Digital elevation model from NASADEM
dem = ee.Image("NASA/NASADEM_HGT/001")

```

```

# Calculate slope. Units are degrees, range is [0, 90)
# Convert slope to radians
dem = dem.addBands(ee.Terrain.slope(dem).multiply(np.pi/180))

# Calculate aspect. Units are degrees where 0=N, 90=E, 180=S, 270=W
# Transform data to 0=S, -90=E, 90=W, -180=N by subtracting 180
# Convert to radians
dem = dem.addBands(ee.Terrain.aspect(dem).subtract(180).multiply(np.pi/180))

# FINAL SCENE ADJUSTMENTS

# Map functions:
# Scale the bands (from user_functions);
# Add DEM, slope and aspect;
# Add bands of lat and long coords (from user_functions);
# Clip to the rectangle;
# Reproject to SIRGAS 2000 UTM zone 22S
dataset3 = (dataset2
            .map(scale_L8)
            .map(lambda img : img.addBands(
                dem, names=['elevation', 'slope', 'aspect']))
            .map(pixels_coords)
            .map(lambda img : img.clip(rect))
            .map(lambda img : img.reproject(crs='EPSG:31982', scale=30)))

# %% SHORTWAVE RADIATION

# This part of the code provides the calculation of shortwave radiation.

# RETRIEVAL OF ANGULAR PARAMETERS

# Calculate declination, B, E and day of year (from user_functions)
dataset4 = dataset3.map(declination)

# Get centroid longitude (degrees absolute) for the area of interest (basin)
basin_long = basin_geom.centroid().coordinates().getNumber(0).abs()

# Function to calculate hour angle (assumed constant over each scene)
def hour_angle(image):
    """
    This function calculates the hour angle of the scene.
    """

    # Retrieve parameter E (convert to seconds)
    E = image.getNumber('E').multiply(60)

    # Retrieve local time (seconds)
    local_time = image.date().getRelative('second', 'day')

    # Local time zone standard meridian (degrees)
    # UTC -3, 15 degrees each hour
    meridian = ee.Number(3*15)

    # Calculate solar time (seconds)
    solar_time = local_time.add(
        ee.Number(4*60).multiply(meridian.subtract(basin_long))).add(E)

    # Calculate hour angle (radians)
    hour_angle = solar_time.subtract(60*60*12).divide(60*60).multiply(np.pi/12)

    # Calculate solar time in hours, minutes and seconds
    h = solar_time.divide(3600).floor().int()
    m = solar_time.mod(3600).divide(60).floor().int()
    s = solar_time.mod(3600).mod(60).floor().int()

    solar_hms = ee.Date(
        ee.String('0T').cat(ee.List([h, m, s]).join(':'))).format('HH:mm:ss')

```

```

# Set values to metadata
return image.set({'SOLAR_TIME':solar_hms, 'HOUR_ANGLE':hour_angle})

# Map function over collection
dataset5 = dataset4.map(hour_angle)

# Calculate solar zenith over a horizontal surface (cos_theta_hor) and solar
# incidence angle (cos_theta_rel) cosines (from user_functions)
dataset6 = dataset5.map(cos_theta_hor).map(cos_theta_rel)

# ATMOSPHERIC TRANSMISSIVITY

# Calculate atmospheric pressure from elevation (from user_functions)
dataset7 = dataset6.map(atm_pressure)

# Calculate vapor pressure from meteorological data (weather station):

# Generate yyyy-mm-dd-Hhh IDs for information matching
met_data['ids'] = met_data.date + '-H' + met_data.hour.astype(int).astype(str)

# Retrieve saturation vapor pressure (kPa)
met_data['sat_vp'] = (0.6112*np.exp(
    17.62*met_data.air_temp/(243.12+met_data.air_temp)))

# Create ee.Dictionary with date/hour ids and associated air temperature
ta_values = ee.Dictionary.fromLists(keys=met_data.ids.values.tolist(),
                                    values=met_data.air_temp.values.tolist())

# Create ee.Dictionary with date/hour ids and associated vapor pressure
vp_values = ee.Dictionary.fromLists(keys=met_data.ids.values.tolist(),
                                    values=met_data.sat_vp.values.tolist())

# Create ee.Dictionary with date/hour ids and associated relative humidity
hum_values = ee.Dictionary.fromLists(keys=met_data.ids.values.tolist(),
                                    values=met_data.rel_hum.values.tolist())

# Function to assign Ta, saturation vapor pressure and relative humidity
# values to each image
def vp_hum(image):

    # Image's hour after acquisition
    hour = (image.date().get('hour').add(1).format('%0f'))

    # ID in the format yyyy-mm-dd-Hhh
    date_hour = ee.String(
        image.get('DATE_ACQUIRED')).cat(ee.String('-H').cat(hour))

    return image.set({
        'AIR_TEMP':ta_values.getNumber(date_hour),
        'SAT_VP':vp_values.getNumber(date_hour),
        'REL_HUM':hum_values.getNumber(date_hour)})

# Map functions over the collection to retrieve:
# Saturation vapor pressure and relative humidity
# Precipitable water (from user_functions)
# Atmospheric transmissivity (from user_functions)
dataset8 = dataset7.map(vp_hum).map(prec_water).map(atm_trans)

# DOWNWARD SHORTWAVE RADIATION

# Retrieve downward shortwave fluxes (from user_functions)
dataset9 = dataset8.map(dw_sw_rad)

# UPWARD SHORTWAVE RADIATION

# Calculate albedo (from user_functions)
dataset10 = dataset9.map(get_albedo)

```

```

# Retrieve upward shortwave radiation (from user_functions)
dataset11 = dataset10.map(up_sw_rad)

# SHORTWAVE RADIATION BUDGET

# Calculate shortwave radiation budget (from user_functions)
dataset12 = dataset11.map(net_sw_rad)

# %% LONGWAVE RADIATION

# DOWNWARD LONGWAVE RADIATION

# Calculate atmospheric emissivity (from user_functions)
dataset13 = dataset12.map(atm_emiss)

# Retrieve downward longwave radiation (from user_functions)
dataset14 = dataset13.map(dw_lw_rad)

# UPWARD LONGWAVE RADIATION

# Calculate SAVI, LAI and emissivity
def savi_lai_emiss(image):

    # Water mask (using NDWI to identify water surfaces)
    water_mask = (dataset14.mean()
                  .normalizedDifference(['SR_B3', 'SR_B5']).lt(0))

    # Select required bands
    # Remove lagoon pixels
    red = image.select('SR_B4').updateMask(water_mask)
    nir = image.select('SR_B5').updateMask(water_mask)

    # Set the value for L
    L = 0.5

    # Calculate SAVI
    savi = (nir.subtract(red).divide(nir.add(red).add(L)).multiply(1 + L)
           .rename('savi'))

    # Calculate LAI
    raw_lai = savi.multiply(-1).add(0.69).divide(0.59).log().divide(-0.91)

    # LAI <= 3 mask
    lai_lte3 = raw_lai.lte(3)

    # Apply mask to keep the pixels <= 3 and attribute 3 to masked pixels
    # Due to unmask, all masked pixels are also replaced
    # Re-apply cloud and water mask
    lai = (raw_lai.updateMask(lai_lte3).unmask(3).rename('lai')
          .updateMask(image.select('QA_PIXEL').bitwiseAnd(1<<6))
          .updateMask(water_mask))

    # Calculate emissivity
    emiss_raw = lai.multiply(0.01).add(0.95)

    # Attribute emissivity = 0.985 to water pixels (Tasumi, 2003)
    emiss = (emiss_raw.unmask(ee.Image(0.985).updateMask(water_mask.eq(0)))
            .rename('emiss'))

    # Add bands to the image
    return image.addBands(ee.Image([savi, lai, emiss]))

# Map the function over the collection
dataset15 = dataset14.map(savi_lai_emiss)

# Calculate Upward Longwave Radiation (from user_functions)
dataset16 = dataset15.map(up_lw_rad)

```



```

# LONGWAVE RADIATION BUDGET

# Calculate longwave radiation budget (from user_functions)
dataset17 = dataset16.map(net_lw_rad)

# %% ALL-WAVE NET RADIATION

# Map function (from user_functions)
dataset18 = dataset17.map(all_wave_rn)

# Set season (from user_functions)
dataset19 = dataset18.map(set_season)

# %% GENERATE AND EXTRACT MEAN IMAGES

for season in ['Spring', 'Summer', 'Fall', 'Winter']:

    mean_image = (dataset19.filter(ee.Filter.eq('SEASON', season))
                  .select(['albedo', 'net_sw_rad', 'net_lw_rad', 'Rn'])
                  .mean())

    geemap.ee_export_image(mean_image,
                           filename=f'generated_data\\mean_{season}.tif',
                           region=basin_geom, scale=30, file_per_band=False)

# Extraction of general mean image
geemap.ee_export_image((dataset19
                        .select(['albedo', 'net_sw_rad', 'net_lw_rad', 'Rn'])
                        .mean()),
                       filename=f'generated_data\\mean_all_images.tif',
                       region=basin_geom, scale=30, file_per_band=False)

# %% IMAGES METADATA

# Retrieve collection metadata and selected meteorological data
info_list = dataset19.getInfo()['features']
images_metadata = list_info_df(info_list)

# Save to csv
images_metadata.to_csv('generated_data\\images_metadata.csv', sep=';',
                      decimal=',', index=False)

# %% SAMPLES SPECTRAL SIGNATURES

# Function to get spectral signatures
def get_spectral_signatures(img, lista):

    # Creates a list
    lista = ee.List(lista)

    # Sample images
    sampled = (img.select('SR_B[2-7]')
              .sampleRegions(collection=samples_geom, scale=30)
              .map(lambda ft : ft.set({'date':img.date().format()})))

    # Save sampled pixels to list
    return lista.add(sampled)

# Get collection of sampled pixels
spectral_coll = ee.FeatureCollection(
    ee.List(dataset19.iterate(get_spectral_signatures, [])).flatten())

# Get reflectances
spectral_info = ee.List([spectral_coll.aggregate_array('date'),
                        spectral_coll.aggregate_array('classes'),
                        spectral_coll.aggregate_array('SR_B2'),
                        spectral_coll.aggregate_array('SR_B3'),

```

```

        spectral_coll.aggregate_array('SR_B4'),
        spectral_coll.aggregate_array('SR_B5'),
        spectral_coll.aggregate_array('SR_B6'),
        spectral_coll.aggregate_array('SR_B7'])).getInfo()

# Create dataframe to populate with spectral information
spectral_dataframe = pd.DataFrame({'date':pd.to_datetime(spectral_info[0])})

# Name of columns
spectral_cols = ['classes', 'B2', 'B3', 'B4', 'B5', 'B6', 'B7']
count = 1

# Iterate to populate columns
for i in spectral_cols:

    spectral_dataframe[i] = spectral_info[count]

    count += 1

# Save to csv
spectral_dataframe.to_csv('generated_data\\spectral_data.csv',
                          decimal=',', sep=';', index=False)

# %% EXTRACTION OF PARAMETERS OF INTEREST

# Function to get parameter values
def get_params(img, lista):

    # Creates a list
    lista = ee.List(lista)

    # Sample images
    sampled = (img.select(['albedo', 'emiss', 'ST_B10',
                          'net_sw_rad', 'net_lw_rad', 'Rn'])
               .sampleRegions(collection=samples_geom, scale=30)
               .map(lambda ft : ft.set({'date':img.date().format(),
                                       'season':img.get('SEASON')})))

    # Save sampled pixels to list
    return lista.add(sampled)

# Get collection of sampled pixels
params_coll = ee.FeatureCollection(
    ee.List(dataset19.iterate(get_params, [])).flatten())

# Get values
params_info = ee.List([params_coll.aggregate_array('date'),
                       params_coll.aggregate_array('classes'),
                       params_coll.aggregate_array('season'),
                       params_coll.aggregate_array('albedo'),
                       params_coll.aggregate_array('emiss'),
                       params_coll.aggregate_array('ST_B10'),
                       params_coll.aggregate_array('net_sw_rad'),
                       params_coll.aggregate_array('net_lw_rad'),
                       params_coll.aggregate_array('Rn')]).getInfo()

# Create dataframe to populate with spectral information
params_dataframe = pd.DataFrame({'date':pd.to_datetime(params_info[0])})

# Name of columns
rad_cols = ['classes', 'season', 'albedo', 'emiss', 'temp', 'rns', 'rnl', 'rn']
count = 1

# Iterate to populate columns
for i in rad_cols:

    params_dataframe[i] = params_info[count]

```

```
count += 1

# Save to csv
params_dataframe.to_csv('generated_data\\radiation_data.csv', decimal=',',
                        sep=';', index=False)
```

APÊNDICE L – Código 3/3: análises estatísticas

Este código pode ser encontrado no repositório do GitHub sob o nome *statistic_analyses_plots.py* (https://github.com/b-rech/net_radiation).

```
# %% LIBRARIES AND SCRIPTS

# Required libraries
import numpy as np
import pandas as pd
from scipy import stats
import scikit_posthocs as sp
from matplotlib import pyplot as plt
from matplotlib.patches import Rectangle
import seaborn as sns
import matplotlib.ticker as tkr
plt.rcParams['figure.dpi'] = 300

# %% DATA UPLOAD

# Images metadata
metadata = pd.read_csv('generated_data\\images_metadata.csv', sep=';',
                      decimal=',')
metadata['date'] = pd.to_datetime(metadata.date)
metadata['year'] = metadata.date.dt.year

# Spectral data from samples
spectral_data = pd.read_csv('generated_data\\spectral_data.csv', sep=';',
                             decimal=',')

# Radiation data from samples
radiation_data = pd.read_csv('generated_data\\radiation_data.csv', sep=';',
                              decimal=',')
radiation_data['date'] = pd.to_datetime(radiation_data.date)

# Removal of a single observation with Rn < 0 (error)
radiation_data = radiation_data[radiation_data.rn > 0]

# %% PLOT - TEMPORAL DISTRIBUTION OF IMAGES

# Create figure
sns.set_style('white')
plot, ax = plt.subplots(nrows=10, figsize=(10, 6), dpi=300)

# Iterate on each axis (year)
for year, axis in zip(
    range(metadata.year.min(), metadata.year.max() + 1),
    range(0, 10)):

    # Styling
    ax[axis].set(xlim=(np.datetime64(f'{year}-01-01'),
                      np.datetime64(f'{year}-12-31')),
                ylim=(-0.1, 0.1),
                xticklabels=[], yticklabels=[],
                ylabel = year, xlabel=' ')
    ax[axis].grid(visible=True, which='major', axis='both')

    # Total available images (with good cloud cover)
    sns.scatterplot(x='date', y=0,
                   data=metadata[metadata.year == year],
                   ax=ax[axis], legend=False, marker='s', hue='season',
                   palette=['#de2d26', '#33a02c', '#3182bd', '#ff7f00'],
                   hue_order=['Summer', 'Fall', 'Winter', 'Spring'],
                   edgecolor='black')
```



```

# Save to csv
spectral_signatures.to_csv('generated_data\\spectral_signatures.csv', sep=';',
                           decimal=',', index=False)

# %% TABLE - NUMBER OF OBSERVATIONS

# Calculate the sum of observations
observations = (radiation_data
                .groupby(['classes', 'season'])
                .count()
                .reset_index())

# Format table (totals per season)
observations = observations.pivot(index='classes', columns='season',
                                 values='date')

# Totals
observations['total'] = observations.sum(axis=1)
observations['total_percent'] = 100*observations.total/observations.total.sum()

observations = observations.reset_index()

observations.to_csv('generated_data\\observations_count.csv', sep=';',
                   decimal=',', index=False)

# %% TABLE - MEAN ALBEDOS

# Calculate means
albedo = radiation_data.groupby('classes').mean()

# Calculate standard deviation
albedo['sd'] = radiation_data.groupby('classes').std()['albedo']

# Create dataframe
albedo = albedo[['albedo', 'sd']]

# Calculate coefficient of variation
albedo['var_coef'] = albedo.sd/albedo.albedo

# Save to csv
albedo.to_csv('generated_data\\albedo_means.csv', decimal=',',
              sep=';')

# %% TABLE - MEAN EMISSIVITY

# Calculate means
emiss = radiation_data.groupby('classes').mean()

# Calculate standard deviation
emiss['sd'] = radiation_data.groupby('classes').std()['emiss']

# Create dataframe
emiss = emiss[['emiss', 'sd']]

# Calculate coefficient of variation
emiss['var_coef'] = emiss.sd/emiss.emiss

# Save to csv
emiss.to_csv('generated_data\\emiss_means.csv', decimal=',',
             sep=';')

# %% TABLE - MEAN TEMPERATURE

# Calculate means
temp = radiation_data.groupby('classes').mean() - 273.15

# Calculate standard deviation
temp['sd'] = radiation_data.groupby('classes').std()['temp']

```

```

# Create dataframe
temp = temp[['temp', 'sd']]

# Calculate coefficient of variation
temp['var_coef'] = temp.sd/temp.temp

# Save to csv
temp.to_csv('generated_data\\temperature_means.csv', decimal=',',
            sep=';')

# %% SEASONAL BOXPLOT FUNCTION

# Define function
def boxplot_seasons(param, ylabel):

    sns.set_style('whitegrid')

    classes = ['DUN', 'FOD', 'LCP', 'LCR', 'RAA', 'SIL', 'URB', 'VHE']

    # Facecolor and edgecolor
    rn_boxplot_ec = 'black'

    # Create plot - boxplot by season
    season_boxplot = sns.FacetGrid(data=radiation_data, col='classes',
                                   sharex=True, sharey=True, col_wrap=3,
                                   col_order=classes, aspect=1, height=2.5)

    # Dictionary of colors for seasons
    season_colors = {'Spring': '#ff7f00', 'Summer': '#de2d26',
                    'Fall': '#33a02c', 'Winter': '#3182bd'}

    # Seasons in order to be displayed
    season_order = ['Summer', 'Fall', 'Winter', 'Spring']

    # Map plots to grid
    season_boxplot.map(sns.boxplot, 'season', param, 'season', showmeans=True,
                      hue_order=season_order, order=season_order, dodge=False,
                      palette=season_colors,
                      flierprops={'marker': '.',
                                   'markerfacecolor': rn_boxplot_ec,
                                   'markeredgecolor': rn_boxplot_ec},
                      boxprops={'edgecolor': rn_boxplot_ec, 'linewidth': 1},
                      whiskerprops={'color': rn_boxplot_ec, 'linewidth': 1},
                      capprops={'color': rn_boxplot_ec, 'linewidth': 1},
                      medianprops={'color': rn_boxplot_ec, 'linewidth': 1},
                      meanprops={'marker': 's',
                                   'markerfacecolor': rn_boxplot_ec,
                                   'markeredgecolor': rn_boxplot_ec,
                                   'markersize': 3})

    # Configure axes labels
    season_boxplot.set_xlabels(' ')
    season_boxplot.set_ylabels(ylabel, fontsize=10)

    # Add classes titles
    for ax, title in zip(season_boxplot.axes.flatten(), classes):
        ax.set_title(title, fontweight='bold')
        ax.get_yaxis().set_minor_locator(tkr.AutoMinorLocator())
        ax.grid(visible=True, which='minor', linewidth=0.4)

    # Set x tick labels
    season_boxplot.set_xticklabels([None]*4)

    season_boxplot.add_legend(ncol=1, loc=(.8, .10), title='Estações')

    new_labels = ['Verão', 'Outono', 'Inverno', 'Primavera']
    for t, l in zip(season_boxplot._legend.texts, new_labels):

```

```

t.set_text(1)

return season_boxplot

# %% SEASONAL BOXPLOTS

# Short wave radiation budget
boxplot_seasons(param='rns', ylabel='$R_n^S \sim (Wm^{-2})$')
plt.tight_layout()
plt.savefig('boxplot_rns.tif', dpi=300)

# Long wave radiation budget
boxplot_seasons(param='rnl', ylabel='$R_n^L \sim (Wm^{-2})$')
plt.tight_layout()
plt.savefig('boxplot_rnl.tif', dpi=300)

# All wave radiation budget
boxplot_seasons(param='rn', ylabel='$R_n \sim (Wm^{-2})$')
plt.tight_layout()
plt.savefig('boxplot_rn.tif', dpi=300)

# %% TABLE - SHORTWAVE NET RADIATION PER SEASON

# Get medians
rad_seasonal_medians = (radiation_data.groupby(['classes', 'season'])
                        .median().reset_index())

# Transform table
sw_rad_seasonal_medians = (rad_seasonal_medians[['classes', 'season', 'rns']]
                          .pivot(index='season', columns='classes',
                                values='rns'))

# # Save to csv
sw_rad_seasonal_medians.to_csv('generated_data\\median_net_shortwave.csv',
                              sep=';', decimal=',')

# %% TABLE - LONGWAVE NET RADIATION PER SEASON

# Get medians
rad_seasonal_medians = (radiation_data.groupby(['classes', 'season'])
                        .median().reset_index())

# Transform table
lw_rad_seasonal_medians = (rad_seasonal_medians[['classes', 'season', 'rnl']]
                          .pivot(index='season', columns='classes',
                                values='rnl'))

# Save to csv
lw_rad_seasonal_medians.to_csv('generated_data\\median_net_longwave.csv',
                              sep=';', decimal=',')

# %% TABLE - ALL-WAVE NET RADIATION PER SEASON

# Get medians
rad_seasonal_medians = (radiation_data.groupby(['classes', 'season'])
                        .median().reset_index())

# Transform table
rn_rad_seasonal_medians = (rad_seasonal_medians[['classes', 'season', 'rn']]
                          .pivot(index='season', columns='classes',
                                values='rn'))

# Save to csv
rn_rad_seasonal_medians.to_csv('generated_data\\median_net_allwave.csv',
                              sep=';', decimal=',')

```



```

# %% TABLE - ANNUAL WEIGHTED MEANS

# Define function
def weighted_means(data, param, weights):

    data['weight'] = [1/weights[x] for x in data.season]

    data['param_weighted'] = data[param]*data.weight

    rad_weight_means = (data.groupby(['classes']).sum().reset_index())

    rad_weight_means['weighted_mean'] = (rad_weight_means.param_weighted/
                                         rad_weight_means.weight)

    return rad_weight_means[['classes', 'weighted_mean']]

# Weights are the number os images
weights = {'Summer':13, 'Fall':36, 'Winter':37, 'Spring':7}

# Shortwave means
shortwave_means = weighted_means(radiation_data, 'rns', weights)

# Longwave means
longwave_means = weighted_means(radiation_data, 'rnl', weights)

# All wave means
allwave_means = weighted_means(radiation_data, 'rn', weights)

# Dataframe with all means
annual_means = pd.DataFrame({'classes':shortwave_means.classes,
                             'rns':shortwave_means.weighted_mean,
                             'rnl':longwave_means.weighted_mean,
                             'rn':allwave_means.weighted_mean})

# Save to csv
annual_means.to_csv('generated_data\\annual_weighted_means.csv',
                    sep=';', decimal=',')

# %% TIME SERIES

def time_series_plot(data, param, ylabel):

    sns.set_style('whitegrid')

    classes = ['DUN','FOD', 'LCP', 'LCR', 'RAA', 'SIL', 'URB', 'VHE']

    # Dataframe with median values
    radiation_medians = (data.groupby(['date', 'classes', 'season'])
                        .median().reset_index(drop=False))
    radiation_medians['date'] = pd.to_datetime(radiation_medians.date)

    # Dictionary of colors for seasons
    season_colors = {'Spring':'#ff7f00', 'Summer':'#de2d26',
                    'Fall':'#33a02c', 'Winter':'#3182bd'}

    # Seasons in order to be displayed
    season_order = ['Summer', 'Fall', 'Winter', 'Spring']

    # Crete grid
    rad_time_grid = sns.FacetGrid(data=radiation_medians, row='classes',
                                  aspect=3.5, sharey=True,
                                  sharex=False, height=1.6)

    # Scatterplot
    rad_time_grid.map(sns.scatterplot, 'date', param, 'season',
                     palette=season_colors, legend=True, edgecolor='black')

    rad_time_grid.add_legend(ncol=4, loc='lower center',

```

```

        label_order=season_order)

# Add classes titles
for ax, title in zip(rad_time_grid.axes.flatten(), classes):
    ax.set_title(title, fontweight='bold')

new_labels = ['Verão', 'Outono', 'Inverno', 'Primavera']
for t, l in zip(rad_time_grid._legend.texts, new_labels):
    t.set_text(l)

rad_time_grid.set_xlabel(' ')
rad_time_grid.set_ylabel(ylabel)

return rad_time_grid

# Data to long format
rad_plot = (radiation_data.melt(id_vars=['date', 'classes', 'season'],
                                value_vars=['rnl', 'rns', 'rn'],
                                var_name='type', value_name='rad'))

time_series_plot(data=radiation_data, param='rns',
                  ylabel='$R_n^S \sim (Wm^{-2})$')
plt.tight_layout()
plt.savefig('time_series_rns.tif', dpi=300)

time_series_plot(data=radiation_data, param='rnl',
                  ylabel='$R_n^L \sim (Wm^{-2})$')
plt.tight_layout()
plt.savefig('time_series_rnl.tif', dpi=300)

time_series_plot(data=radiation_data, param='rn',
                  ylabel='$R_n \sim (Wm^{-2})$')
plt.tight_layout()
plt.savefig('time_series_rn.tif', dpi=300)

# %% RELATION BETWEEN SHORT AND LONG BUDGETS

sns.set_style('whitegrid')

# Median values per scene
rad_image_medians = (radiation_data.groupby(['date', 'classes', 'season'])
                    .median().reset_index())

# Classes
classes = ['DUN', 'FOD', 'LCP', 'LCR', 'RAA', 'SIL', 'URB', 'VHE']

# List to save correlations
corr = []

# Spearman correlations
for classe in classes:

    # Select class
    data = rad_image_medians[rad_image_medians.classes==classe]

    # Append correlation to list
    corr.append(data[['rns', 'rnl']].corr(method='spearman').iloc[0, 1])

# Correlation grid
corr_grid = sns.FacetGrid(data=rad_image_medians, col='classes', col_wrap=3,
                           col_order=classes, sharex=False, sharey=False)

# Map plots
corr_grid.map(sns.regplot, 'rnl', 'rns', ci=None,
              line_kws={'color':'#e31alc', 'linewidth':1, 'linestyle':'--'},
              scatter_kws={'facecolor':'#deebf7', 'edgecolor':'#084594'})

# Set xy labels

```

```

corr_grid.set_xlabel('$R_n^L \sim (Wm^{-2})$')
corr_grid.set_ylabel('$R_n^S \sim (Wm^{-2})$')

# Add classes titles and correlation coefficients
for ax, title, cor in zip(corr_grid.axes.flatten(), classes, corr):
    ax.set_title(title, fontweight='bold')
    ax.annotate('$r_S$ = ' + str(format(cor, '.2f')),
                xy=(0.7, 0.85), xycoords='axes fraction',
                bbox=dict(boxstyle="square", fc="w", ec='black'))

plt.tight_layout()

plt.savefig('correlation_rad.tif', dpi=300)

# %% KRUSKAL-WALIS TESTS

# Function for Kruskal-Wallis test
def kruskal_wallis(input_data, param):

    # Classes
    classes = ['DUN', 'FOD', 'LCP', 'LCR', 'RAA', 'SIL', 'URB', 'VHE']

    # Radiation data medians per scene
    median_rad_data = (input_data.groupby(['date', 'classes', 'season'])
                       .median().reset_index())

    statistics = []
    pvalues = []

    for classe in classes:

        # Filtered data for the selected class
        data = median_rad_data[median_rad_data.classes==classe]

        # Spring samples
        spring = data[data.season=='Spring'][param].tolist()

        # Summer samples
        summer = data[data.season=='Summer'][param].tolist()

        # Fall samples
        fall = data[data.season=='Fall'][param].tolist()

        # Winter samples
        winter = data[data.season=='Winter'][param].tolist()

        # Performs test
        kw_test = stats.kruskal(spring, summer, fall, winter, nan_policy='raise')

        # Retrieve info
        statistics.append(kw_test.statistic)
        pvalues.append(kw_test.pvalue)

    # Create dataframe with results
    kw_test_results = pd.DataFrame({'classes':classes,
                                   'statistic':statistics,
                                   'pvalue':pvalues})

    return kw_test_results

# Function for Dunn test
def dunn_test(input_data, param):

    # Classes
    classes = ['DUN', 'FOD', 'LCP', 'LCR', 'RAA', 'SIL', 'URB', 'VHE']

    dunn_test_results = pd.DataFrame(
        columns=['Spring', 'Summer', 'Fall', 'Winter', 'classes'])

```

```

# Radiation data medians per scene
median_rad_data = (input_data.groupby(['date', 'classes', 'season'])
                  .median().reset_index())

for classe in classes:

    data = median_rad_data[median_rad_data.classes==classe]

    test_output = (sp.posthoc_dunn(data, val_col=param, group_col='season',
                                  p_adjust='bonferroni')
                  .reindex(['Spring', 'Summer', 'Fall', 'Winter'])
                  .reset_index())

    test_output['classes'] = [classe]*4

    dunn_test_results = pd.concat([dunn_test_results, test_output])

return dunn_test_results

# Kruskal-Wallis: shortwave radiation
kw_test_rns = kruskal_wallis(radiation_data, 'rns')
kw_test_rns.to_csv('generated_data\\kw_test_rns.csv', sep=';',
                  decimal=',', index=False)

# Dunn: shortwave radiation
dunn_test_rns = dunn_test(radiation_data, 'rns')
dunn_test_rns.to_csv('generated_data\\dunn_test_rns.csv', sep=';',
                    decimal=',', index=False)

# Kruskal-Wallis: longwave radiation
kw_test_rnl = kruskal_wallis(radiation_data, 'rnl')
kw_test_rnl.to_csv('generated_data\\kw_test_rnl.csv', sep=';',
                  decimal=',', index=False)

# Dunn: longwave radiation
dunn_test_rnl = dunn_test(radiation_data, 'rnl')
dunn_test_rnl.to_csv('generated_data\\dunn_test_rnl.csv', sep=';',
                    decimal=',', index=False)

# Kruskal-Wallis: allwave radiation
kw_test_rn = kruskal_wallis(radiation_data, 'rn')
kw_test_rn.to_csv('generated_data\\kw_test_rn.csv', sep=';',
                 decimal=',', index=False)

# Dunn: allwave radiation
dunn_test_rn = dunn_test(radiation_data, 'rn')
dunn_test_rn.to_csv('generated_data\\dunn_test_rn.csv', sep=';',
                   decimal=',', index=False)

```