




ISSN:1984-2295

Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Correção Atmosférica em Sensoriamento Remoto: Uma Revisão

William Gaida¹, Fábio Marcelo Breunig², Lênio Soares Galvão³, Flávio Jorge Ponzoni⁴

¹Mestre em Geografia, Universidade Federal de Santa Maria Campus Frederico Westphalen, BR 386 Km 40, s/n, CEP: 98400-000, Frederico Westphalen, Rio Grande do Sul. ufsm.william@gmail.com (autor correspondente). ²Doutor em Sensoriamento Remoto, Professor do Departamento de Engenharia Florestal, Universidade Federal de Santa Maria Campus Frederico Westphalen, BR 386 Km 40, s/n, CEP: 98400-000, Frederico Westphalen, Rio Grande do Sul. breunig@ufsm.br; ³Doutor em Geofísica, Pesquisador da Divisão de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, Avenida dos Astronautas, nº 1758, CEP: 12227-010, São José dos Campos, São Paulo. lenio.galvao@inpe.br; ⁴Doutor em Engenharia Florestal, Pesquisador da Divisão de Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, Avenida dos Astronautas, nº 1758, CEP: 12227-010, São José dos Campos, São Paulo. flavio.ponzoni@inpe.br.

Artigo recebido em 18/09/2019 e aceito em 01/03/2020

RESUMO

A correção atmosférica é um procedimento necessário em estudos de sensoriamento remoto com foco nas propriedades físicas, químicas e biológicas de alvos. Em abordagens multitemporais e/ou multisensor, a correção atmosférica é fundamental para a obtenção de medidas de reflectância de superfície representativas das características espectrais dos alvos. Embora de grande importância, este procedimento e seus conceitos ainda são pouco difundidos e estudados no âmbito da Geografia brasileira. O objetivo do estudo foi apresentar uma revisão dos principais métodos e parâmetros envolvidos no processo de correção atmosférica de imagens de sensoriamento remoto. Este procedimento visa minimizar os efeitos decorrentes da interação dos constituintes atmosféricos com a radiação eletromagnética, como a absorção provocada pelos gases e o espalhamento produzido por partículas de aerossóis. Sua eficiência depende de um conjunto de fatores, como o método de correção adotado e as características do sistema sensor. Diversos métodos têm sido propostos, sendo classificados em: métodos físicos, fundamentados em modelos de transferência radiativa; métodos empíricos, que estimam os efeitos atmosféricos a partir de alvos específicos da imagem; e métodos híbridos, que combinam informações físicas da atmosfera e estatísticas da cena. Embora os métodos empíricos sejam de fácil aplicação, eles são menos precisos do que os métodos físicos. Estes, por sua vez, necessitam *a priori* do conhecimento de alguns parâmetros atmosféricos que, dependendo da resolução espectral do sensor, podem ser obtidos da própria imagem. Os métodos híbridos constituem uma alternativa por demandarem um menor conhecimento de parâmetros atmosféricos. Um exemplo dos efeitos atmosféricos sobre o cálculo de índices de vegetação é apresentado.

Palavras-chave: processamento de imagens, efeitos atmosféricos, comportamento espectral, erros radiométricos.

Atmospheric Correction in Remote Sensing: A Review

ABSTRACT

Atmospheric correction is a necessary procedure in remote sensing studies focusing on the physical, chemical and biological properties of targets. In multi-temporal and/or multi-sensor approaches, the atmospheric correction is fundamental to obtain surface reflectance measurements representative of the spectral characteristics of targets. Although of great importance, this procedure and its concepts are still little diffused and studied in the scope of the Geography in Brazil. The objective of the study was to present an overview of the main methods and parameters involved in the process of atmospheric correction of remote sensing images. This procedure aims to minimize the effects of the interaction of atmospheric constituents with electromagnetic radiation, such as the absorption caused by gases and the scattering produced by aerosol particles. Its efficiency depends on a set of factors such as the selected correction method and the technical specifications of the sensor system. Several methods have been proposed. They are classified in physical methods, based on radiative transfer models; empirical methods, which estimate atmospheric effects from selected targets in the scene; and hybrid methods, which combine physical information from the atmosphere and scene statistics. Although empirical methods are easy to apply, they are less precise than physical methods. Physical approaches require a priori knowledge of some atmospheric parameters. However, depending on the spectral resolution of the sensor, these parameters can be estimated from the image itself. The hybrid methods are an alternative because they require less knowledge of atmospheric parameters. An example of the atmospheric effects on the determination of vegetation indices is presented.

Key-words: image processing, atmospheric effects, spectral behavior, radiometric errors.

Introdução

Aplicações de técnicas de sensoriamento remoto no estudo dos recursos naturais têm atingido diversificado grau de sofisticação, permitindo a extração de informações quantitativas mediante a caracterização espectral de objetos. No contexto das ciências que abordam o espaço geográfico, o sensoriamento remoto é uma ferramenta bastante utilizada nos diversos campos de estudo sobre a superfície terrestre, dada a versatilidade dos satélites, sua vasta cobertura espacial e a repetitividade das observações. Considerando o uso de imagens orbitais, as principais vantagens estão relacionadas à capacidade de cobertura de grandes áreas em intervalos temporais regulares, às qualidades geométrica e radiométrica dos dados e a facilidade de aquisição de imagens ao longo do tempo.

A partir das medidas de radiância detectadas por sensores remotos, podem ser estimados diversos parâmetros físicos/químicos e/ou biológicos importantes para o monitoramento de ambientes aquáticos (Brando et al., 2015; Barrett e Frazier, 2016), florestais (Majasalmi e Rautiainen, 2016; Wang et al., 2018) e agrícolas (Clevers et al., 2017; Gerstmann et al., 2018). A precisão dessas estimativas é dependente do grau de relação entre as medidas de radiância e as variáveis biofísicas em análise (Lantzanakis et al., 2017). No entanto, a radiância detectada pelos sistemas sensores ópticos é afetada pela presença dos diversos constituintes presentes na atmosfera terrestre. A radiação eletromagnética emitida pelo Sol, ao transpor a atmosfera, sofre diferentes alterações ocasionadas pela sua interação com partículas e moléculas de gás em suspensão na atmosfera. Trata-se de um processo seletivo que é dependente da composição da própria atmosfera e dos comprimentos de onda da radiação incidente, sendo o espalhamento e a absorção os principais fenômenos resultantes (Hilker, 2018). Esses efeitos podem levar a um aumento ou a uma redução da radiância detectada nos sensores orbitais.

A correção atmosférica é um procedimento necessário em estudos com foco nas propriedades físicas, químicas e biológicas dos alvos, tanto em abordagens multitemporais, quanto multisensor (Hagolle et al., 2015; Sola et al., 2018). A obtenção da denominada "reflectância de superfície" é importante, porque, ao contrário dos números digitais, este parâmetro traz um significado físico sobre o alvo e pode ser comparado ao longo do tempo e entre sistemas sensores (respeitadas as devidas limitações). O processamento de correção

atmosférica tem como objetivo minimizar a influência resultante da interação com os componentes atmosféricos no sinal detectado por um sistema sensor no topo da atmosfera (Mograne et al., 2019). A eficiência deste procedimento é altamente dependente do método de correção atmosférica e das especificações técnicas de cada sensor (Okin e Gu, 2015).

Diversos métodos têm sido propostos para a correção atmosférica de imagens de sensoriamento remoto (Doxani et al., 2018). Esses métodos dividem-se em três categorias principais, classificados de acordo com o tipo de abordagem: (a) métodos físicos ou fundamentados na Teoria da Transferência Radiativa; (b) métodos empíricos baseados na estimativa dos efeitos atmosféricos a partir de informações de alvos específicos contidos na própria imagem a ser processada; e (c) métodos híbridos, que incluem procedimentos que combinam informações físicas da atmosfera com métricas de estatística da cena (Lantzanakis et al., 2017; Moses et al., 2017).

Os métodos físicos de correção atmosférica, também conhecidos como correção absoluta, utilizam medidas ou estimativas físicas de parâmetros atmosféricos para a correção das imagens usando equações diferenciais e integrais. Os algoritmos utilizados normalmente se baseiam em códigos de transferência radiativa, que simulam a propagação da radiação eletromagnética pela atmosfera, como o *Second Simulation of the Satellite Signal in the Solar Spectrum* (6S) (Vermote et al., 1997) e nas compilações do código *MODerate resolution atmospheric TRANsmiission* (MODTRAN) (Berk et al., 2016). Exemplos deste último caso incluem os algoritmos *Atmospheric CORrection Now* (ACORN), *Atmospheric/Topographic CORrection* (ATCOR) (Richter e Schläpfer, 2015) e o *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) (Cooley et al., 2002). Na prática, estes algoritmos facilitam a correção atmosférica por meio da disponibilidade de uma interface gráfica, podendo utilizar para a modelagem atmosférica, dependendo da resolução espectral do sensor, informações da própria imagem e dos metadados fornecidos aos usuários.

Os métodos empíricos são simples e tendem a ser menos precisos, tendo como base a estimativa grosseira de parâmetros atmosféricos a partir da resposta espectral de alvos específicos da cena (por exemplo, corpos d'água ou áreas sombreadas). Podem utilizar também o valor mínimo dos histogramas de cada banda como uma forma de minimizar os efeitos aditivos do espalhamento

atmosférico. Uma vantagem deste tipo de método refere-se à ausência da necessidade de aquisição de informações de fontes externas, referentes aos parâmetros atmosféricos do momento da aquisição da imagem. Por outro lado, são menos precisos do que os métodos físicos. O método *Dark Object Subtraction* (DOS), proposto por Chavez (1988), é um exemplo de método empírico de correção atmosférica que deve ser utilizado apenas quando não for possível utilizar métodos físicos.

Os métodos híbridos para a correção atmosférica são construídos a partir da combinação de versões simplificadas dos códigos de transferência radiativa com informações de estatística da cena (Gao et al., 2009). A aplicação destes modelos necessita de uma menor quantidade de informações sobre os parâmetros atmosféricos do momento da aquisição da imagem. No entanto, alguns destes métodos utilizam medidas de reflectância de alvos *in situ* para a calibração da reflectância de superfície obtida com os códigos de transferência radiativa, eliminando eventuais erros residuais. Podem ser localmente úteis quando houver problemas de calibração de dados, como em algumas aplicações de imagem hiperespectrais reportadas na literatura (Ben-Dor et al., 2004). Um exemplo deste tipo de método é o algoritmo *Image CORrection for atmospheric effects* (iCOR) (VITO, 2017).

Apesar da importância da correção atmosférica, pouca atenção tem sido dada pela comunidade geográfica sobre esse procedimento. No entanto, diversos algoritmos de correção atmosférica têm sido disponibilizados para os usuários de imagens de satélite. Além disso, várias missões espaciais têm disponibilizado imagens e produtos atmosféricamente corrigidos, o que parece ser uma tendência nos próximos anos. No contexto da geografia brasileira, este tema ainda é pouco considerado pela comunidade acadêmica (mestrado e doutorado). A execução da correção atmosférica é um processo “obrigatório” para a obtenção de produtos robustos e de elevada acurácia relacionando propriedades dos alvos.

Neste sentido, o presente estudo tem como objetivo revisar os principais métodos e parâmetros utilizados no processo de correção atmosférica de imagens de sensoriamento remoto, buscando contribuir para a difusão do conhecimento sobre o assunto no contexto da geografia brasileira. Desta forma, pretende-se mostrar ao usuário de imagens de sensoriamento remoto a importância da realização desta correção ou de se utilizar produtos de satélites já atmosféricamente corrigidos, quando disponíveis, especialmente quando imagens de satélites de diferentes datas ou séries temporais de índices de vegetação forem considerados nas aplicações.

Os efeitos atmosféricos e sua influência nos dados de sensoriamento remoto

A radiação eletromagnética ao transpor a atmosfera interage com os seus diferentes constituintes em suspensão, afetando o fluxo radiante por meio de dois efeitos principais: espalhamento (ou dispersão) e absorção atmosférica.

As concentrações de aerossóis em suspensão são responsáveis pelo efeito de espalhamento atmosférico, que afeta principalmente os comprimentos de onda da faixa do visível (entre 380 nm e 700 nm) do espectro eletromagnético, ocasionando a redução da visibilidade atmosférica, influenciando também no balanço radiativo. A intensidade da dispersão é dependente da concentração e do tamanho das partículas e do comprimento de onda da radiação eletromagnética e da distância percorrida através da atmosfera. Neste sentido, Hagolle et al. (2015) enfatizam que o conhecimento sobre o tipo de aerossol predominante e a sua espessura óptica é de fundamental importância para a precisão dos processos de correção atmosférica, uma vez que o efeito de espelhamento provocado por este constituinte atmosférico, conduz a obtenção de medidas de reflectância superestimadas dos alvos terrestres.

Os aerossóis correspondem aos mais diversos tipos de partículas com composição, forma, dimensões e propriedades ópticas diferentes. Sua origem pode ser natural, como a poeira oriunda de desertos e a salinidade dos oceanos em suspensão, ou ser resultante de atividades antrópicas, como poluição industrial e queima de biomassa (Remer et al., 2004).

Ao contrário dos aerossóis, as moléculas gasosas ao interagirem com a radiação eletromagnética, absorvem parte da energia incidente. Esse efeito pode ocorrer em diferentes comprimentos de onda e em diferentes níveis de intensidade. Isto faz com que, em algumas faixas espectrais, a radiação eletromagnética seja quase inteiramente absorvida (Hagolle et al., 2015). Os comprimentos menos afetados por este efeito constituem as chamadas “janelas atmosféricas” (Figura 1), onde imagens de melhor qualidade radiométrica podem ser obtidas (Schowengerdt, 2007; Tso e Mather, 2009). A absorção é provocada principalmente pela interação da radiação eletromagnética com as moléculas de vapor de água (H₂O), oxigênio (O₂), ozônio (O₃) e dióxido de carbono (CO₂), ocorrendo em diversos comprimentos de onda ao longo das regiões do visível e infravermelho próximo e de ondas curtas.




Figura 1. Janelas atmosféricas e bandas de absorção espectral associadas a presença de vapor d'água, dióxido de carbono e oxigênio para os comprimentos de onda entre as faixas do visível, do infravermelho próximo e do infravermelho de onda curtas. Fonte: adaptado de Schowengerdt (2007).

Métodos físicos de correção atmosférica

Second Simulation of the Satellite Signal in the Solar Spectrum (6S)

O código 6S é fundamentado na teoria da transferência radiativa desenvolvida por Chandrasekhar (1960), sendo elaborado a partir do código *Simulation of the Satellite Signal in the Solar Spectrum (5S)* (Tanré et al., 1990). É um dos modelos mais consolidados na literatura, sendo utilizado por diversos grupos de pesquisa, tanto para avaliação de novos modelos, quanto para o desenvolvimento de produtos, como por exemplo, na correção atmosférica de imagens do sensor *MODerate-resolution Imaging Spectroradiometer (MODIS)* (Vermote e Kotchenova, 2008). Sua aplicação permite a simulação do sinal observado por um sistema sensor para um alvo Lambertiano (com reflexão difusa) ao nível do mar (Vermote et al., 1997).

Este código permite a simulação do modelo de transferência radiativa atmosférica na faixa do espectro óptico solar, entre 250 nm e 4000 nm. Diversos algoritmos internos são utilizados para o cálculo dos efeitos de espalhamento e de absorção provocados pela constituintes opticamente ativos da atmosfera (Vermote et al., 1997). O 6S considera os efeitos provocados pela absorção causada por dióxido de carbono (CO₂),

ozônio (O₃), óxido nitroso (N₂O), oxigênio (O₂), metano (CH₄) e vapor d'água (H₂O). O código considera ainda o espalhamento molecular por aerossóis, bem como a reflectância bidirecional de superfícies não uniformes (não Lambertianas), quando necessário (Vermote et al., 2006).

O código 6S foi inicialmente implementado em linguagem Fortran 77, sendo executado por meio de linhas de comando, o que exigia um conhecimento adicional do usuário na linguagem de programação (não usual no contexto da geografia brasileira). No entanto, uma versão com interface gráfica foi implementada no sistema de informações geográficas *Geographic Resources Analysis Support System (GRASS)* (GRASS Development Team, 2018) por meio da extensão *i.atcorr* (Zietsman et al., 2018).

Para a aplicação do código 6S faz-se necessária a aquisição de uma série de parâmetros referentes as condições atmosféricas (como visibilidade e profundidade óptica de aerossol) e características da imagem e sistema sensor (data e horário de detecção, altitude orbital, altitude topográfica média da área contida na imagem). Em função da arquitetura do código, os parâmetros são inseridos por meio de um arquivo de texto simples, no qual cada linha corresponde a um parâmetro. Outra característica do código 6S é que este permite a correção da imagem uma única banda do sensor por processo.

A nova versão deste código, *6S vector version (6SV)*, proposta por Kotchenova e Vermote

(2007), considera os efeitos causados pela polarização atmosférica, ao invés da antiga versão, baseada no método de ordens sucessivas de aproximações de dispersão. O 6SV foi também implementado em linguagem Fortran 77. No entanto, possui uma ferramenta com interface gráfica que auxilia o usuário na criação do arquivo de parâmetros, disponível no endereço eletrônico: <<http://6s.ltdri.org/pages/run6SV.html>>.

Atmospheric Correction Now (ACORN)

O algoritmo de correção atmosférica ACORN utiliza tabelas de consulta com parâmetros calculados pelo código de transferência radiativa MODTRAN. Estas tabelas, comumente utilizadas pelos métodos físicos de correção atmosférica, armazenam funções computadas pelos códigos de transferência radiativa necessárias para a modelagem da radiação detectada pelo sistema sensor no topo da atmosfera, estabelecendo a relação entre a geometria de visada e os parâmetros atmosféricos para a simulação da resposta do sinal na superfície.

Para a aplicação do ACORN, as imagens devem estar previamente processadas em valores de radiação de topo da atmosfera, antes de sua conversão para dados de reflectância de superfície. Este algoritmo pode ser aplicado a imagens de sistemas sensores hiperespectrais e multiespectrais, que operam nos comprimentos de onda entre 350 nm e 2500 nm (AIG, 2002). Os parâmetros a serem definidos pelo usuário compreendem a localização e a data da imagem, a altitude média da superfície, a altitude do sistema sensor, o modelo atmosférico e a visibilidade atmosférica.

No caso de imagens hiperespectrais, o ACORN apresenta como opções ao usuário obter a concentração de vapor d'água atmosférico e a visibilidade atmosférica a partir das bandas de absorção da água, presentes na própria imagem (AIG, 2002). Desta forma, dependendo da resolução espectral do sensor, os dados da própria imagem são usados para gerar a modelagem sem a necessidade de outras medições atmosféricas. O ACORN ainda tem outras funções para a supressão de artefatos espectrais decorrentes da correção atmosférica ou da baixa relação sinal/ruído de alguns sensores (filtragem de ruído).

Atmospheric/Topographic Correction for Satellite Imagery (ATCOR)

O algoritmo ATCOR foi desenvolvido pelo *Deutsches Zentrum für Luft-und Raumfahrt* (DLR), para aplicação de correção atmosférica em imagens de sistemas sensores com alta resolução

espectral. Sua aplicação é desenvolvida por meio de duas fases, sendo uma interativa e outra automática. Na primeira são realizados a definição dos parâmetros de entrada e a escolha dos modelos de atmosfera e tipo de aerossol, necessários ao processamento, enquanto que na segunda são executados os cálculos de visibilidade atmosférica e na sequência, estimados os efeitos atmosféricos (Vescovi e Minchella, 2017).

O ATCOR é distribuído comercialmente na forma de três versões independentes, dedicadas a correção atmosférica de imagens de sensores orbitais e aerotransportados (Richter e Schläpfer, 2015). Possui implementações desenvolvidas em linguagem IDL para os *softwares* de processamento digital de imagens ERDAS Imagine e PCI Geomatics, além de uma versão autônoma (Rese Applications, 2018).

As versões ATCOR-2 e ATCOR-3 foram desenvolvidas para aplicação em imagens de sistemas sensores orbitais (Richter e Schläpfer, 2012). A principal diferença entre estas versões refere-se à possibilidade de correção dos efeitos topográficos com o ATCOR-3, que deve ser aplicada apenas em áreas montanhosas. O ATCOR-2 (*Atmospheric Correction for Flat Terrain*) não permite essa correção. Portanto, o ATCOR-3 (*Atmospheric and Topographic Correction for Satellite Imagery*) pode ser aplicado a imagens de áreas com grande gradiente topográfico, possibilitando a correção dos efeitos de iluminação do terreno a partir da inserção de um modelo digital de elevação e dos ângulos azimutal e zenital solar, geralmente especificados nos metadados da imagem.

O algoritmo *Atmospheric and Topographic Correction for Airborne Imagery* (ATCOR-4) foi desenvolvido especialmente para sistemas sensores aerotransportados (Richter e Schläpfer, 2011). Possui dois módulos separados para o processamento de imagens de terrenos com topografia plana e acidentada. Esta versão permite a correção atmosférica de imagens no espectro óptico compreendido entre 350 nm e 2550 nm e o espectro termal entre 8000 nm e 14000 nm, apresentando como resultados a reflectância de superfície e a temperatura/emissividade de superfície, respectivamente (Richter e Schläpfer, 2011). As funções disponíveis no ATCOR-4 permitem a realização de correções topográficas, do efeito de adjacência espectral e dos efeitos bidirecionais. Além disso, possibilitam a filtragem espectral de ruídos e a atenuação de efeitos provocados por nevoeiro, nuvens do tipo cirros e sombra de nuvens (Markelin et al., 2012). Este modelo pode ser aplicado para a correção atmosférica de imagens de diversos sistemas sensores aerotransportados hiperespectrais (Rese Applications, 2018).

Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes (FLAASH)

O FLAASH é um algoritmo para correção atmosférica que se baseia no código de transferência radiativa MODTRAN (Cooley et al., 2002). Desenvolvido de forma colaborativa entre a *Spectral Sciences, Inc.* e o *Air Force Research Laboratory (AFRL)*, com assistência do *Spectral Information Technical Applications Center (SITAC)*, o algoritmo foi implementado em linguagem IDL e incorporado ao módulo de correção atmosférica do *software* de processamento de imagens ENVI (*ENvironment for Visualizing Images*) (Harris Geospatial Solutions, 2018).

O algoritmo FLAASH permite a correção atmosférica de imagens multiespectrais e hiperespectrais, possibilitando a inserção de diversos parâmetros pelo usuário como: tipo de sensor, data e horário da aquisição da imagem, localização do centro da imagem, altitude do sensor e do terreno, tamanho do pixel, modelo atmosférico (inverno subártico, inverno de média latitude, verão subártico, verão de média latitude, tropical e padrão norte americano), modelo de aerossol (rural, marítimo, urbano, troposférico e sem aerossol). Se o sensor for hiperespectral e operar entre 400 e 2.500 nm, a estimativa de vapor d'água atmosférico pode ser feita pixel-a-pixel usando os dados da própria imagem. Há procedimentos para a definição automática da visibilidade. O FLAASH ainda possui uma opção para a aplicação da técnica de polimento ou filtragem espectral (*spectral polishing*) para a redução de artefatos espectrais ou ruídos em dados hiperespectrais (Harris Geospatial Solutions, 2018).

Comparado com o ATCOR-3, algoritmo que também utiliza o código de transferência radiativa MODTRAN, o FLAASH não dispõe de um módulo de correção topográfica. Portanto, em áreas montanhosas, o usuário deverá escolher outras opções de métodos de correção topográfica para redução dos efeitos locais de iluminação no terreno.

Landsat Surface Reflectance Code (LaSRC)

O LaSRC (Vermote et al., 2016) consiste em um algoritmo fundamentado em princípios físicos desenvolvido para a correção atmosférica das imagens do sistema sensor multiespectral *Operational Land Imager (OLI)*, a bordo do satélite Landsat-8. Este algoritmo foi desenvolvido pelo *National Aeronautics and Space Administration (NASA) Goddard Space Flight*

Center (GSFC) para a correção atmosférica das imagens Landsat-8.

O LaSRC calcula a reflectância de superfície e a temperatura de brilho a partir dos parâmetros de calibração contidos nos metadados da imagem (Vermote et al., 2016). A correção atmosférica é aplicada a partir do uso de parâmetros atmosféricos auxiliares, como as concentrações de vapor de água, ozônio e espessura óptica de aerossol, obtidos de forma indireta a partir do produto *MODIS/Terra Aerosol Optical Thickness Daily L3 Global 0.05Deg CMA (MOD09CMA)*. A concentração de ozônio é obtida por meio do produto (*MOD09CMG*) (Vermote, 2015), ambos derivados de dados do sensor *MODIS/Terra*. Além dos parâmetros atmosféricos, o LaSRC utiliza o modelo digital de elevação *GTOPO* no cálculo da pressão atmosférica, utilizada para a definição das concentrações de aerossóis e detecção de nuvens do tipo cirros.

O LaSRC é implementado na linguagem FORTRAN, o que torna dificultosa a sua aplicação, devido a necessidade de conhecimento em programação computacional. No entanto, o usuário pode adquirir as imagens do sensor *OLI* processadas em nível L2, a partir do serviço de aquisição sob demanda disponibilizados por meio dos repositórios *Earth Explorer* e *EROS Science Processing Architecture (ESPA)* da *United States Geological Survey (USGS)*, disponíveis nos endereços eletrônicos: <https://earthexplorer.usgs.gov/> e <https://espa.cr.usgs.gov/>, respectivamente.

Multi-Angle Implementation of Atmospheric Correction (MAIAC)

O MAIAC (Lyapustin et al., 2011a; Lyapustin et al., 2011b; Lyapustin et al., 2012) consiste em um dos mais avançados algoritmos para a correção atmosférica e recuperação de medidas de concentração de aerossol, sendo desenvolvido com o objetivo de corrigir as limitações encontradas pelos algoritmos tradicionais na derivação de medidas de aerossol em observações realizadas fora do nadir e sobre alvos não-Lambertianos (Zhang et al., 2019).

Este algoritmo é baseado na abordagem desenvolvida por Martonchik et al. (1998), que consiste na incorporação da variação da geometria de visada do sistema sensor e iluminação a partir da reflectância bidirecional de superfície no algoritmo, de forma a permitir recuperações de parâmetros da função de distribuição da reflectância bidirecional e albedo. Desta forma, o algoritmo utiliza um método de janelas móveis para a recuperação da função de reflectância bidirecional a partir de um conjunto acumulado de

observações de quatro (nas regiões de alta latitude) a dezesseis dias (para latitudes próximas ao Equador). Desta forma, a função de reflectância bidirecional é recuperada por meio de observações de múltiplos ângulos, o que possibilita a detecção de mudanças sazonais e rápidas na superfície (Hilker, 2018).

O MAIAC utiliza o método de consulta de tabelas (*Look-up Table* – LUT) para a determinação da influência dos efeitos atmosféricos. Os valores das tabelas de consulta são calculados a partir do código de transferência radiativa *Spherical Harmonics code* (SHARM) (Lyapustin, 2005). São considerados os efeitos provocados pelo espalhamento por aerossóis e a absorção por seis tipos de gases atmosféricos (H₂O, CO₂, CH₄, NO₂, CO, N₂O), tendo como referência a base de parâmetros espectroscópicos atmosféricos *High-resolution TRANsmision molecular absorption database* (HITRAN 2000) (Rothman et al., 2003).

Este algoritmo tem sido amplamente adaptado para a correção atmosférica e correção dos efeitos bidirecionais em nível global de imagens da coleção 6 dos sensores MODIS (Lyapustin et al., 2018). Desta forma, três produtos derivados das observações desses sensores são disponibilizados: reflectância de superfície (*Land Surface BRF Daily L2G Global 500m and 1km SIN Grid* (MCD19A1)), propriedades atmosféricas (*Land Aerosol Optical Thickness Daily L2G Global 1km SIN Grid* (MCD19A2)) e parâmetros de função de distribuição da reflectância bidirecional e albedo (*BRDF Model Parameters 8-Day L3 Global 1km SIN Grid* (MCD19A3)), distribuída a partir de composições temporais de oito dias (Lyapustin e Wang, 2018). Dado que o MAIAC é um modelo genérico, pode ser aplicado para a correção de dados de outros sensores.

Métodos empíricos e híbridos de correção atmosférica

Dark Object Subtraction (DOS)

O DOS é um método essencialmente empírico que utiliza a resposta espectral de alvos específicos da imagem (Chavez, 1988). Este método não paramétrico, parte do pressuposto de que a imagem contenha alvos escuros (por exemplo, corpos d'água profundos, sombras de nuvens). Nos pixels correspondentes a estas áreas, assume-se que a radiância detectada pelo sistema sensor possui valor igual a zero em todos os comprimentos de onda, sendo as medidas de radiância não nulas atribuídas aos efeitos de espalhamento atmosférico (Moses et al., 2017). Esta condição é utilizada para estimar de forma

empírica o efeito aditivo da atmosfera, não corrigindo, portanto, o efeito multiplicativo da absorção atmosférica (Gupta, 2003). Uma alternativa para este procedimento é buscar o valor mínimo do histograma em cada banda e subtraí-lo da imagem. Embora o DOS seja um procedimento empírico simples, estudos têm mostrado que este método apresenta baixa precisão para aquisição de medidas de reflectância de superfície (Chavez, 1996; Gupta, 2003). O DOS corrige apenas os efeitos aditivos provocados pelo espalhamento atmosférico, não considerando a absorção atmosférica e diversas outras incógnitas como propriedades dos aerossóis e efeitos bidirecionais da superfície (Hilker, 2018). No entanto, o DOS tem apresentando um bom desempenho na correção de efeitos aditivos provocados por condições de neblina nas imagens (Zhang et al., 2014). Desta forma, Chavez (1996) propôs uma modificação no método, denominando-o de DOS2. Nesta adaptação, a transmitância da atmosfera é estimada por meio do cosseno do ângulo zenital solar.

O método DOS foi bastante difundido quando não havia ampla disponibilidade de *softwares* com métodos físicos (Zhang et al., 2010). A eficiência do DOS foi avaliada e os resultados permitiram concluir que este método muitas vezes apresentava medidas de reflectância de superfície inconsistentes, quando comparadas com as obtidas com uso de modelos físicos (Bernardo et al., 2017). Uma das limitações do DOS é a dependência da escolha de um objeto escuro que seja representativo das condições atmosféricas contidas na imagem, o que restringe sua eficiência à interpretação da cena pelo usuário. É importante destacar que o modelo DOS pode ser inadequado para estudos sobre corpos hídricos, visto que a água apresenta uma reflectância muito baixa, o que requer um melhor controle de qualidade no processo de correção atmosférica dos dados.

Image correction for atmospheric effects – iCOR

O algoritmo híbrido de correção atmosférica iCOR (VITO, 2017), anteriormente denominado de *OPERational Atmospheric correction for land and water* (OPERA) (Sterckx et al., 2015a), utiliza um procedimento bastante elaborado de tabelas baseadas no código MODTRAN para a remoção da contribuição dos efeitos atmosféricos na imagem (De Keukelaere et al., 2018). O iCOR pode ser aplicado para a correção dos efeitos atmosféricos tanto em ambientes terrestres, quanto em aquáticos, incluindo águas costeiras. Este modelo permite a correção dos efeitos de adjacência a partir da recuperação de informações da própria imagem por meio do

algoritmo *Similarity Environmental Correction* (SIMEC) (Sterckx et al., 2015b; De Keukelaere et al., 2018).

O algoritmo iCOR foi desenvolvido para aplicação de correção das imagens dos sensores orbitais *MultiSpectral Instrument* (MSI), abordo dos satélites Sentinel-2, e *Operational Land Imager* (OLI), abordo do satélite Landsat-8, sendo disponibilizado de forma gratuita para os usuários, como uma extensão da *Sentinel-2 Toolbox* integrada no *software* de processamento de imagens *Sentinel Application Platform* (SNAP) (VITO, 2017; ESA, 2018).

Embora o processamento seja realizado considerando dados recuperados da própria imagem, sua aplicação pode ser refinada a partir do ajuste das medidas de coluna de vapor d'água e profundidade óptica de aerossol. É recomendável a consulta de fontes externas de dados para a obtenção desses parâmetros para a data e o local da imagem.

Estudos de avaliação, como o *Atmospheric Correction Inter-comparison Exercise* (ACIX) (Doxani et al., 2018), têm mostrado que o iCOR apresenta um desempenho satisfatório na correção atmosférica. O algoritmo também tem bom desempenho na recuperação de medidas de profundidade óptica de aerossol, que mostraram boa concordância em relação a medidas obtidas por métodos diretos, considerando diversos tipos de uso e cobertura da terra e condições atmosféricas.

Quick Atmospheric Correction (QUAC)

O algoritmo híbrido QUAC inclui uma abordagem empírico-estatística, que utiliza as informações obtidas por meio da resposta espectral de alvos contidos na imagem para estimar a contribuição dos efeitos atmosféricos nas medidas de reflectância (Bernstein et al., 2012). Desta forma, a sua aplicação não requer conhecimento prévio das condições atmosféricas do momento da aquisição da cena. Este algoritmo parte do princípio de que o valor médio da reflectância obtido por meio de diversos espectros de um determinado alvo não é necessariamente dependente de cada imagem (Bernstein et al., 2012).

O QUAC foi implementado em linguagem IDL no *Atmospheric Correction Module* do *software* ENVI, juntamente com o algoritmo FLAASH (Harris Geospatial Solutions, 2018). Embora este modelo seja de fácil e rápida aplicação, não exigindo grande intervenção do usuário ou inserção de parâmetros atmosféricos de fontes externas, seus resultados podem ser pouco precisos. Apesar de bem elaborado, é muito dependente das características espectrais dos componentes de cena.

Sentinel-2 Correction – Sen2Cor

O algoritmo híbrido Sen2Cor foi desenvolvido pela *Telespazio VEGA Deutschland GmbH* a pedido da *European Space Agency* (ESA), para aplicação exclusiva no processamento de imagens dos sensores MSI abordo da constelação de satélites Sentinel-2 do programa *Global Monitoring for Environment and Security* (GMES) (Gascon et al., 2017; Main-Knorn et al., 2017). Este complexo algoritmo executa o processamento das imagens Sentinel-2, disponibilizadas pela ESA, convertendo-as de valores de reflectância de topo da atmosfera (nível de processamento 1C) para valores de reflectância de superfície (nível de processamento 2A) (Main-Knorn et al., 2017). Assim como o modelo iCOR descrito anteriormente, o Sen2Cor está implementado como uma extensão da *Sentinel-2 Toolbox* integrada ao *software* de processamento de imagens SNAP, sendo distribuído livremente pela ESA (Sola et al., 2018).

O Sen2Cor consiste em um método empírico-estatístico, no qual a contribuição dos efeitos atmosféricos é calculada a partir de informações extraídas dos metadados das imagens e das medidas de reflectância aparente dos alvos da imagem. Os parâmetros atmosféricos são estimados pelo modelo usando tabelas geradas a partir do código de transferência radiativa *libRadtran* (Emde et al., 2016). Os modelos para estimativa do aerossol (rural ou marítimo), atmosférico (verão de latitudes médias) e da concentração de ozônio são determinados de acordo com a localização geográfica e as condições climáticas no momento da detecção da radiação pelo sistema sensor (Richter et al., 2012).

A espessura óptica de aerossol é estimada com o uso do algoritmo *Dark Dense Vegetation* proposto por Kaufman e Sendra (1988), que se baseia na correlação entre as medidas de reflectância em comprimento de onda do infravermelho de ondas curtas e do visível, especialmente sobre áreas de vegetação densa. As medidas de coluna de vapor d'água atmosférica são obtidas por meio do algoritmo *Atmospheric Pre-corrected Differential Absorption* (APDA) (Schläpfer et al., 1998). Além destas correções, o Sen2Cor executa a redução dos efeitos causados por nuvens cirros, efeitos topográficos e de adjacência espectral, permitindo correções simplificadas da função de distribuição de reflectância bidirecional.

Embora seja bastante utilizado para a correção das imagens MSI do satélite Sentinel-2, alguns estudos têm apontado a ocorrência de limitações na recuperação da profundidade óptica

de aerossol em alguns tipos de superfícies, como regiões áridas (Doxani et al., 2018).

Simplified Method for Atmospheric Correction in the solar spectrum (SMAC)

O algoritmo SMAC, proposto por Rahman e Didieu (1994), consiste em um método híbrido para a correção atmosférica de imagens obtidas por sistemas sensores orbitais. Este algoritmo possibilita a correção atmosférica de imagens adquiridas sob as mais variadas condições atmosféricas.

Este método consiste em uma sequência de equações semi-empíricas com coeficientes associados às bandas do sistema sensor. A partir destas equações são estimadas as diferentes interações da radiação eletromagnética com os componentes atmosféricos, como os efeitos da absorção gasosa e a dispersão por aerossóis. Os coeficientes específicos de cada sistema sensor são definidos com uso de um código de transferência radiativa, sendo atualmente utilizada uma versão simplificada do código 6S (Proud et al., 2010). O código de transferência radiativa é utilizado para o cálculo da radiação solar retro-espalhada pelo sistema Terra-atmosfera na altitude do satélite, considerando as mais diversas condições de incidência da radiação eletromagnética e observação.

Embora menos preciso quando comparado a aplicações mais complexas, como o código 6S, o SMAC tem sido utilizado por diversos grupos de pesquisadores devido sua aplicação ser mais rápida, com menor exigência computacional e a necessidade de poucos parâmetros atmosféricos provenientes de fontes externas (Proud et al., 2010). Estas características fazem com que este algoritmo mostre um bom desempenho para a correção de grandes volumes de dados, além de permitir a correção atmosférica de imagens obtidas por sistemas sensores com amplo campo de visada e alta repetitividade (Proud et al., 2010).

A partir dos coeficientes calculados por meio do código 6S, o SMAC possui suporte para a correção atmosférica de imagens de uma grande variedade sistemas sensores, como os sensores *MultiSpectral Instrument (MSI)*, *Operational Land Imager (OLI)*, *Thematic Mapper (TM)*, *Enhanced Thematic Mapper plus (ETM+)*, *Advanced Very High Resolution Radiometer (AVHRR)*, *Advanced Wide Field Sensor (AWiFS)*, *Linear Imaging Self-Scanner (LISS-3)*, *Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER)*, *Multi-angle Imaging Spectro Radiometer (MISR)*, *Moderate-resolution Imaging Spectroradiometer (MODIS)*, *High Resolution Geometric (HRG)*, *VEGETATION*,

Spinning Enhanced Visible and Infrared Imager (SEVIRI), entre outros (CESBIO, 2019).

Embora o SMAC tenha sido desenvolvido com o objetivo de otimizar a correção atmosférica de grandes volumes de imagens, sua aplicação requer um conhecimento amplo do usuário, tanto no que se refere ao processamento, quanto na aplicação do algoritmo. O SMAC é implementado nas linguagens C e Python, possuindo uma versão integrada à biblioteca de ferramentas de processamento digital de imagens *Orfeo Toolbox (OTB)* (OTB Development Team, 2018).

Principais parâmetros utilizados na correção atmosférica

Embora não seja um requisito para a aplicação do processo de correção atmosférica, o conhecimento por parte do usuário dos principais elementos e processos que ocorrem na atmosfera e como estes afetam a imagem, corrobora com o aspecto da avaliação final dos produtos resultantes (reflectância de superfície). Desta forma, uma discussão dos principais parâmetros atmosféricos necessários para a aplicação de métodos de correção atmosférica é apresentada.

Visibilidade atmosférica e profundidade óptica de aerossol

A visibilidade atmosférica tem grande importância para o processo de correção atmosférica de imagens por meio de métodos físicos (por exemplo, 6S, MODTRAN e algoritmos relacionados). A visibilidade atmosférica é um parâmetro indicativo da presença de partículas em suspensão, servindo de suporte para a estimativa de concentrações de aerossóis, os quais interferem na transparência atmosférica (Zhang et al., 2020). Este parâmetro é controlado por fatores naturais, como a nebulosidade, neblina e aerossóis, e por fatores antropogênicos provenientes de queima de biomassa e combustíveis fósseis (Liang et al., 2020).

Medidas de visibilidade podem ser obtidas de forma direta a partir de observações em campo, estações meteorológicas e ainda disponibilizadas por serviços de aviação. No entanto, ressalta-se que medidas realizadas *in situ*, embora sejam mais precisas e confiáveis do que as obtidas de forma indireta, em muitos casos, devido ao seu caráter de cobertura pontual, podem não ser representativas das condições de uma área mais ampla. Na prática, o procedimento mais comum é usar dados da própria imagem e métodos como o *Dark Dense Vegetation* para estimar medidas de profundidade

óptica de aerossol utilizadas no cálculo da visibilidade. Os aplicativos normalmente permitem a estimativa automática de visibilidade ou a inserção manual dos valores, com base em alguma medida pré-existente.

A profundidade óptica do aerossol é uma das propriedades ópticas fundamentais que pode quantificar a quantidade de cargas de aerossol em suspensão na atmosfera (Zhang et al., 2016a; Zhang et al., 2017). A sua concentração pode ser obtida a partir de estações meteorológicas ou por meio da rede terrestre de monitoramento atmosférico *AEROSOL ROBOTIC NETWORK* (AERONET) (Holben et al., 1998). Esta rede mundial de fotômetros solares automáticos, disponibiliza medidas de profundidade óptica de aerossol no comprimento de onda de 550 nanômetros obtidas pela interpolação de medidas de expoente de Ångström, parâmetro relacionado à distribuição média de tamanhos dos aerossóis presentes na atmosfera (Doxani et al., 2018) e medidas de profundidade óptica do aerossol nos comprimentos de onda de 670 nm e 440 nm (Tao et al., 2015). As medidas de aerossol provenientes da rede AERONET são geralmente utilizadas para a validação de medidas derivadas a partir de modelos de correção atmosférica (Obregón et al., 2018). Embora as medidas de aerossol obtidas por meio de instrumentos terrestres demonstrem elevado nível de acurácia, problemas associados a aquisição de observações pontuais e restritas pelo número limitado de estações têm restringido à sua aplicação ao processamento de imagens próximas a localização dessas estações.

Uma alternativa à limitação espacial das estações e redes de monitoramento é a utilização de medidas de profundidade óptica de aerossol obtidas de forma indireta a partir de sistemas sensores orbitais, que possuem bandas espectrais em faixas específicas que permitem a derivação de parâmetros atmosféricos. Os sensores MODIS são uns dos instrumentos mais utilizados para a recuperação de concentrações de aerossol em suspensão na atmosfera terrestre por meio de técnicas de sensoriamento remoto (Ghotbi et al., 2016; Zhang et al., 2019).

As medidas de concentração de aerossol são obtidas por meio da aplicação dos algoritmos *Dark Target* (Levy et al., 2010) e *Deep Blue* (Hsu et al., 2013). O primeiro algoritmo separa a contribuição do aerossol e da superfície terrestre ao estabelecer a relação empírica da reflectância de superfície entre as bandas nos comprimentos de onda do infravermelho próximo e de ondas curtas. Este algoritmo mostra um bom desempenho para a recuperação das concentrações de aerossóis sobre áreas de vegetação densa. O segundo algoritmo foi

desenvolvido para a recuperação de medidas de aerossol sobre superfícies brilhantes utilizando uma base de dados de superfície pré-calculada. A partir da aplicação destes algoritmos sobre os dados dos sensores MODIS é obtido o produto *MODIS Aerosol 5-Min L2 Swath 10km* (MOD/MYD04) (Levy et al., 2015; Wei et al., 2019).

No entanto, efeitos como ruído de detectores, dependência do tipo de superfície, geometrias de iluminação e visada, podem contribuir para a incerteza das medidas obtidas (Bhatia et al., 2018). Assim, recentemente, a implementação do algoritmo MAIAC teve por objetivo reduzir as fontes de incerteza relacionadas a efeitos provocados pela reflectância bidirecional em observações MODIS. Diversos estudos, como os realizados por Martins et al. (2017) e Superczynski et al. (2017), têm comprovado o potencial de recuperação de medidas de profundidade óptica de aerossóis por meio da aplicação do algoritmo MAIAC, o que tem possibilitado a sua utilização, inclusive, em estudos atmosféricos (Tang et al., 2017; Xiao et al., 2017; Zhang et al., 2019).

Vapor d'água atmosférico

O vapor d'água atmosférico influencia o balanço radiativo, atuando como regulador da temperatura (AMS, 2018). Sua ocorrência é predominante nas camadas mais baixas da troposfera, onde aproximadamente 90% de seu volume concentra-se entre a superfície até uma altitude de seis quilômetros (Richter et al., 2011). Em relação a interação com a radiação eletromagnética, o vapor d'água é um dos componentes opticamente ativos da atmosfera, sendo responsável pelo efeito de absorção do fluxo radiante nos comprimentos de onda da faixa do visível do espectro eletromagnético, refletindo parte da radiação na faixa do infravermelho próximo, enquanto que as nuvens espalham basicamente toda a radiação na faixa do visível (Su et al., 2011).

As bandas de absorção molecular originadas pelo vapor d'água provocam duas importantes feições próximas a 1,4 e 1,9 micrômetros. Nestes comprimentos de onda, a transmitância da atmosfera é praticamente zero, o que dificulta a geração de imagens por sensores remotos. Estas faixas espectrais podem ser utilizadas, no entanto, para a detecção de nuvens do tipo cirros (Schowengerdt, 2007). Outras feições secundárias, mas importantes para fins de correção atmosférica, são observadas em 0,83, 0,94 e 1,14 micrômetros. Com dados hiperespectrais, estas três feições espectrais podem ser usadas para calcular a

quantidade de vapor d'água precipitado, pixel-a-pixel, facilitando a correção atmosférica. Medidas de concentração de vapor d'água atmosférico podem ser obtidas in situ ou da derivação de medidas de umidade absoluta atmosférica realizadas desde a superfície até o topo da coluna de vapor d'água. Outra alternativa inclui medidas de radiação solar direta em superfície, usando radiossondas ou radiômetros (Campanelli et al., 2018). Alternativamente, a profundidade da coluna de vapor d'água pode ser obtida de forma indireta a partir de dois produtos do sensor MODIS: *Precipitable Water Product* (MOD/MYD05) (Gao e Kaufman, 2003) e *Atmospheric Profiles Product* (MOD/MYD07) (Seemann et al., 2003).

Modelos atmosféricos

Os modelos atmosféricos utilizados pelos códigos de transferência radiativa são

representações hipotéticas de possíveis cenários de condições atmosféricas e de sua distribuição vertical, incluindo variáveis como umidade, temperatura, visibilidade, pressão e densidade atmosférica (Berk et al., 2016). A definição do modelo adequado a ser utilizado para correção atmosférica deve considerar a latitude, hora do dia e a época do ano em que foi adquirida a imagem, podendo ser consideradas as medidas de vapor d'água atmosférico e de temperatura média da superfície no momento da aquisição da cena.

Os modelos atmosféricos disponíveis no código de transferência radiativa MODTRAN (Quadro 1) foram desenvolvidos considerando as concentrações pré-definidas dos seguintes constituintes atmosféricos: coluna de vapor d'água atmosférica (H₂O); ozônio (O₃); dióxidos de carbono (CO₂), de nitrogênio (NO₂) e enxofre (SO₂); metano (CH₄); oxigênio (O₂); óxido nitroso (N₂O); amônia (NH₃) e ácido nítrico (HNO₃) (SSI, 2018).

Latitude	Janeiro	Março	Maió	Julho	Setembro	Novembro
80	SAW	SAW	SAW	MLW	MLW	SAW
70	SAW	SAW	MLW	MLW	MLW	SAW
60	MLW	MLW	MLW	SAS	SAS	MLW
50	MLW	MLW	SAS	SAS	SAS	SAS
40	SAS	SAS	SAS	MLS	MLS	SAS
30	MLS	MLS	MLS	T	T	MLS
20	T	T	T	T	T	T
10	T	T	T	T	T	T
0	T	T	T	T	T	T
-10	T	T	T	T	T	T
-20	T	T	T	MLS	MLS	T
-30	MLS	MLS	MLS	MLS	MLS	MLS
-40	SAS	SAS	SAS	SAS	SAS	SAS
-50	SAS	SAS	SAS	MLW	MLW	SAS
-60	MLW	MLW	MLW	MLW	MLW	MLW
-70	MLW	MLW	MLW	MLW	MLW	MLW
-80	MLW	MLW	MLW	MLW	MLW	MLW

Quadro 1. Modelos atmosféricos utilizados pelo código MODTRAN em função da latitude e época do ano. Onde: MLS – verão de média latitude, MLW – inverno de média latitude, SAS – verão subártico, SAW – inverno subártico e T – tropical. Fonte: Harris Geospatial Solutions (2018).

Exemplo dos efeitos atmosféricos sobre o cálculo de índices de vegetação

Para demonstrar a importância da correção dos efeitos atmosféricos nas imagens de sensoriamento remoto e seus produtos derivados, um exemplo foi desenvolvido considerando uma série temporal de quatro imagens MSI/Sentinel-2 para as datas de 14 de março, 23 de maio, 26 de agosto e 09 de dezembro de 2018. A partir das bandas correspondentes aos canais do vermelho e do infravermelho próximo do MSI foi calculado o

Normalized Difference Vegetation Index (NDVI) (Rouse et al., 1973) (Equação 1):

$$NDVI = \frac{(\rho_{NIR} - \rho_{red})}{(\rho_{NIR} + \rho_{red})} \quad (1)$$

Onde: ρ_{NIR} representa a reflectância da banda correspondente à região do infravermelho próximo, enquanto ρ_{red} representa a reflectância da banda correspondente à região do vermelho do espectro eletromagnético.

Os índices de vegetação são muito utilizados para os mais diversos estudos sobre ambientes florestais e cultivos agrícolas, servindo como base para diversas aplicações e produtos. Estes índices permitem a estimativa de diversos parâmetros biofísicos, como biomassa e índice de área foliar (Dong et al., 2019; Zheng et al., 2019; Breunig et al., 2020). No entanto, a capacidade destes índices em mostrar resultados representativos das condições reais da vegetação é diretamente afetada pela presença de erros de ordem radiométrica como os efeitos atmosféricos associados as medidas de reflectância. De acordo com Hadjimitsis et al. (2010), os efeitos atmosféricos podem conduzir a uma diferença média de até 18% nos valores nos valores de NDVI.

O índice NDVI foi calculado para as imagens em dois níveis de processamento, referentes a reflectância do topo da atmosfera e de superfície. O nível 1C corresponde ao nível de processamento no qual as imagens são disponibilizadas pela *Agência Espacial Europeia*

(ESA, repositório *Copernicus*, disponível em: <https://scihub.copernicus.eu/dhus/#/home>), com pixels em valores de reflectância de topo da atmosfera (sem correção atmosférica). O segundo nível, o 2A, corresponde as imagens com pixels em valores de reflectância de superfície (com correção atmosférica). Neste exemplo, a correção dos efeitos atmosféricos das imagens foi realizada por meio da aplicação do algoritmo ATCOR-3, descrito anteriormente na seção 2.3.

Para o processo de correção atmosférica fez-se necessária a aquisição de medidas de profundidade óptica de aerossol e expoente de Angstrom, utilizadas para a estimativa da visibilidade média para a área das imagens (Tabela 1). Estas medidas foram obtidas a partir do produto *MOD04 MODIS/Terra Aerosol 5-Min L2 Swath 10km V006*, do sensor MODIS a bordo do satélite *Terra*. Além da determinação da visibilidade média para cada imagem, foram definidos o modelo de aerossol como marítimo e o modelo atmosférico para verão de média latitude.

Tabela 1. Parâmetros atmosféricos externos adquiridos para o processo de correção atmosférica das imagens Sentinel-2/MSI e respectiva visibilidade média obtida para cada uma das datas.

Data	AOD 550 nm	Expoente de Angstrom	Visibilidade (km)
14/03/2018	0,036	1,5	55,97
23/05/2018	0,047	1,5	51,97
26/08/2018	0,093	1,5	41,74
09/12/2018	0,046	1,5	52,30

Analisando os dados de NDVI obtidos para as quatro datas avaliadas (Figura 2) é possível identificar que os valores deste índice, calculados a partir de medidas de reflectância de topo da atmosfera, apresentam uma menor capacidade de distinção e representação do vigor vegetativo dos alvos. Resultado semelhante foi encontrado por Marcello et al. (2016), no qual os autores destacam a baixa capacidade de discriminação de índices de vegetação, quando aplicados em imagens sem correção dos efeitos atmosféricos.

No exemplo, estudou-se um cultivo comercial de *Pinus elliottii* var. *elliottii*, localizado no Litoral Sul do Estado do Rio Grande do Sul. Enquanto que o índice obtido a partir de medidas de reflectância de superfície capturou as variações sazonais da floresta comercial, o NDVI calculado a partir da reflectância do topo da atmosfera não apresentou grandes variações ao longo do ano.

Os comprimentos de onda da região do visível do espectro eletromagnético são mais afetados pelos efeitos de espalhamento atmosférico. Desta forma, o espalhamento atmosférico nos comprimentos de onda do vermelho tende a elevar a reflectância aparente desta banda, o que tende a provocar uma redução nos valores de NDVI (diminui o contraste entre o vermelho e infravermelho próximo). Este exemplo mostra como o cálculo de índices de vegetação, a partir de medidas de reflectância de topo da atmosfera (sem correção atmosférica), produz resultados imprecisos ao longo do tempo, levando o usuário a uma interpretação errônea. A falta de correção atmosférica tem forte impacto nas análises de séries temporais de índices de vegetação derivadas de imagens de satélite.

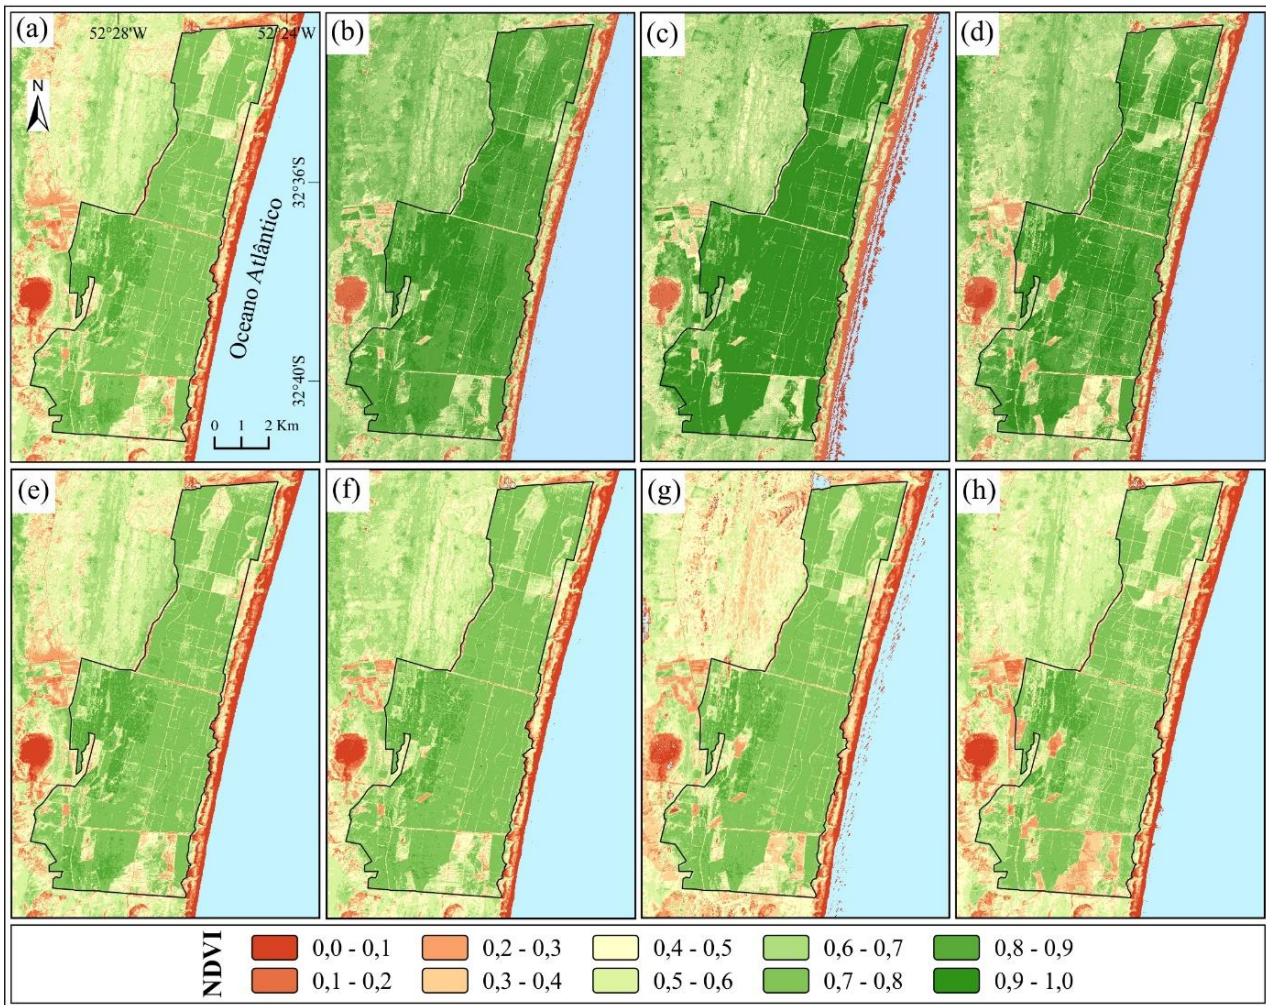


Figura 2. Imagens NDVI, obtidas a partir de valores de reflectância de superfície (com correção atmosférica) do sensor orbital MSI/Sentinel-2, para as datas de (a) 14 de março, (b) 23 de maio, (c) 26 de agosto e (d) 9 de dezembro de 2018. Os resultados para datas correspondentes, obtidos a partir de valores de reflectância do topo da atmosfera (sem correção atmosférica), são mostrados entre (e) e (h). A correção atmosférica realça as áreas de *Pinus elliottii* var. *elliottii* no Estado do Rio Grande do Sul e suas diferenças fenológicas e de manejo.

A comparação das imagens NDVI corrigidas atmosféricamente para as datas de 23 de maio e 26 de agosto de 2018 (Figuras 2b e 2c) com os respectivos dados sem correção dos efeitos atmosféricos (Figuras 2f e 2g) mostrou uma maior variação em relação aos demais pares de datas. Esta ocorrência pode estar associada não apenas ao manejo dos povoamentos florestais, mas ao menor ângulo de elevação solar ocorrido no período das imagens (outono e inverno), provocando um aumento de sombreamento interno do dossel. A influência provocada pela variação da iluminação em dosséis florestais de *Pinus* é discutida por Rautiainen et al. (2018), no qual os autores observaram por meio de medidas radiométricas, que a porção de folhas em condição de sombreamento no dossel, em geral, apresenta maior transmitância do que as folhas expostas diretamente à condição de iluminação, na região espectral entre 400 nm e 2400 nm. Desta forma, o

maior espalhamento das folhas de *Pinus* provoca um acréscimo substancial nas medidas de reflectância nos comprimentos de onda do infravermelho próximo (Hovi et al., 2017). Portanto, variações sazonais na geometria de iluminação podem introduzir mudanças na quantidade de sombras presentes nas cenas e vistas pelos satélites.

De forma a exemplificar os efeitos da interação atmosférica com a radiância detectada por um sistema sensor e suas implicações na resposta espectral de alvos, medidas de reflectância de topo da atmosfera e de superfície foram extraídas por amostragem de diferentes alvos contidos na imagem MSI/Sentinel-2 de 14 de março de 2018. Destaca-se que não foram realizadas análises comparativas de desempenho dos métodos utilizados, uma vez que o objetivo foi apenas enfatizar a necessidade do processo de

correção atmosférica para a eliminação de incertezas da resposta espectral.

Foram amostrados 500 pixels para cada tipo de alvo na cena MSI (água, campos, silvicultura, cultivos agrícolas e solo exposto). Calculou-se então a resposta espectral média, considerando as bandas

das faixas do visível, borda do vermelho, infravermelho próximo e infravermelho de ondas curtas, correspondentes às bandas com resoluções espaciais de 10 e 20 metros do sensor MSI (Figura 3).

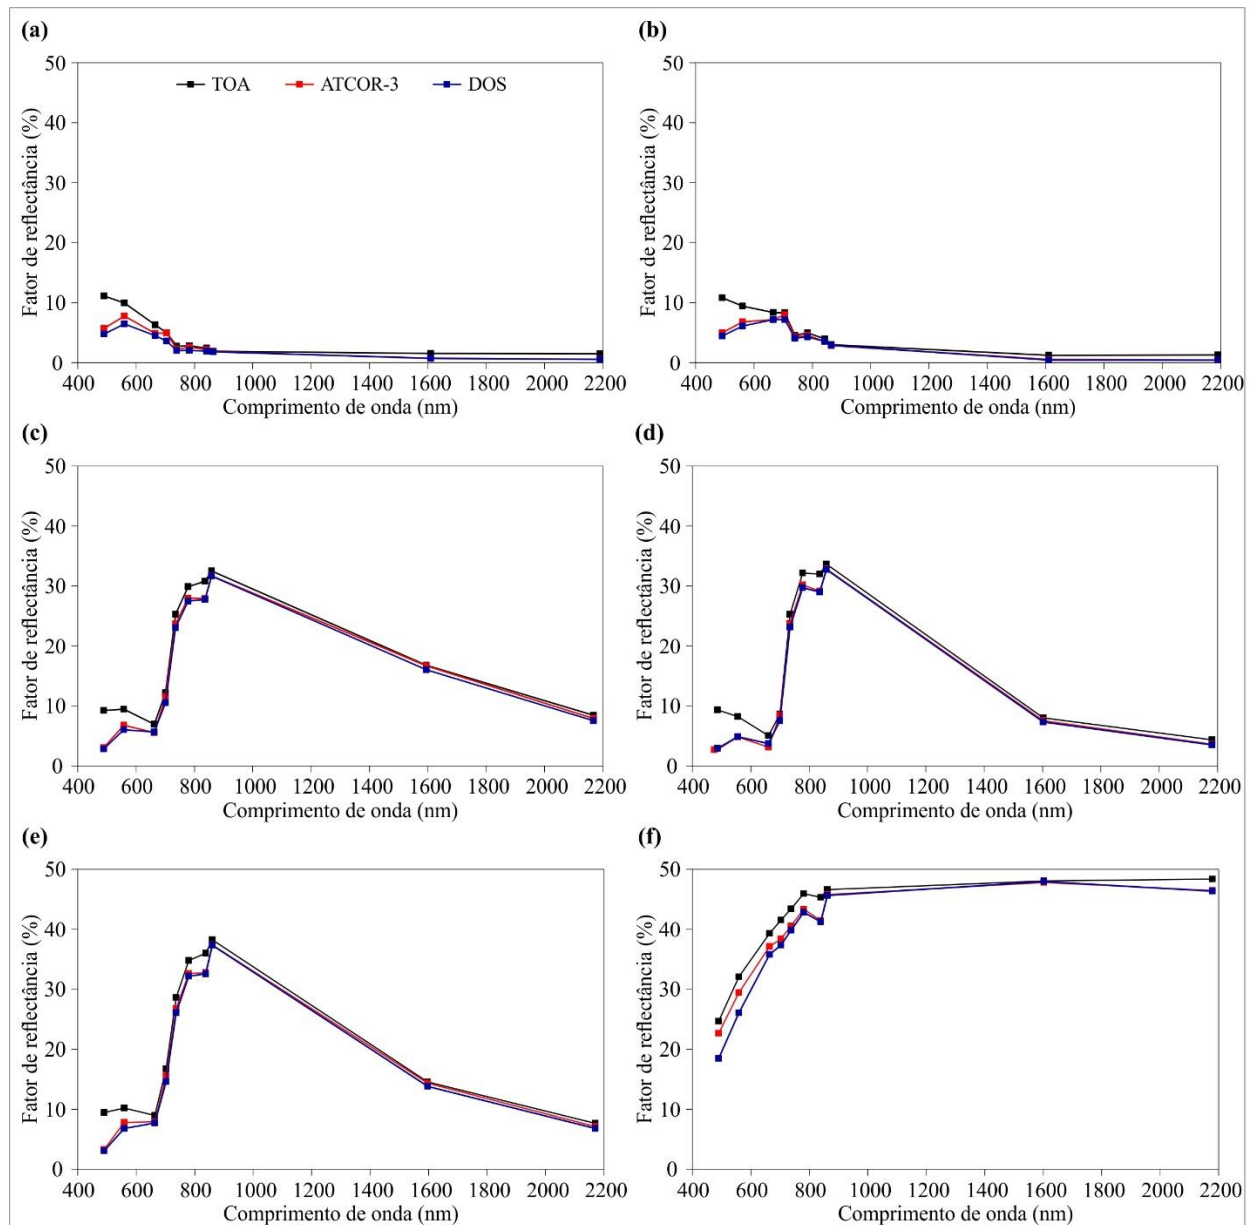


Figura 3. Respostas espectrais de (a) águas caso I, (b) águas caso II, (c) campos, (d) silvicultura, (e) cultivos agrícolas e (f) solo exposto (dunas de areia), obtidas a partir de medidas de refletância no topo da atmosfera (TOA) e de superfície com a aplicação dos métodos DOS1 e ATCOR-3. As curvas de refletância aparente (sem correção atmosférica) do sensor MSI/Sentinel-2 também são apresentadas.

A análise das respostas espectrais dos diferentes alvos mostrou que os comprimentos de onda mais curtos, correspondentes as faixas do azul e do verde, são os mais afetados pelos efeitos de espalhamento atmosférico. A resposta espectral de águas caso I (com maior concentração de

pigmentos fotossintetizantes) (Figura 3a) e caso II (com maior concentração de sedimentos e suspensão) (Figura 3b) foi mais afetada pelos efeitos atmosféricos, com destaque para o elevado espalhamento nas faixas do azul e verde. Os efeitos atmosféricos também foram responsáveis pela

elevação das medidas de reflectância nos comprimentos de onda das faixas do infravermelho próximo, onde a água caracteristicamente apresenta reflectância muito baixa, com valores próximos a zero.

Para os alvos de cobertura vegetal, como campos (Figura 3c), silvicultura (Figura 3d) e cultivos agrícolas (Figura 3e), a aplicação dos dois métodos de correção atmosférica resultou em valores de reflectância bastante próximos. Os comprimentos de onda correspondentes a faixa da borda do vermelho também foram bastante afetados pelos efeitos provocados pelo espalhamento atmosférico, ocorrendo uma mudança significativa na curva espectral após a aplicação dos processos de correção atmosférica.

Dentre os alvos avaliados, as áreas de solo exposto (Figura 3f), constituídas por dunas de areia, apresentaram as medidas de reflectância mais elevadas em sua resposta espectral. Como o MSI/Sentinel-2 opera em janelas atmosféricas bem definidas no infravermelho próximo e de ondas curtas, as principais diferenças de reflectância observadas após a correção atmosférica foram produzidas nas faixas do visível e da borda vermelha devido principalmente aos efeitos de espalhamento atmosférico e, secundariamente, aos efeitos de absorção atmosférica.

Conclusões

Considerando as diferentes abordagens expostas para a correção dos efeitos atmosféricos, os métodos físicos, baseados em códigos de transferência radiativa, são os que tendem a apresentar resultados mais precisos. Felizmente, diversos algoritmos, de fácil interação e uso (com interface gráfica do usuário), estão disponíveis para a comunidade. Além disso, uma tendência que se consolida é a disponibilização de produtos "reflectância de superfície" diretamente ao usuário final, portanto, contendo imagens corrigidas dos efeitos atmosféricos de espalhamento e absorção. Outras missões têm disponibilizado pacotes de aplicativos para correção atmosférica, embora nem sempre de fácil interação.

Do ponto de vista das aplicações, a correção atmosférica é importante para a adequada representação da reflectância de superfície dos alvos. Assim, deve-se evitar o cálculo de índices de vegetação e a análise de séries temporais usando números digitais (ND) ou valores de radiância não atmosféricamente corrigidos. NDs não têm significado físico e não podem ser comparados ao longo do tempo ou entre sensores. A conversão das imagens para reflectância de superfície, portanto, corrigidas dos efeitos da atmosfera, é fundamental

para a análise quantitativa de dados de satélites obtidos em diferentes datas.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (processos 113769/2018-0 e 309030/2017-0) pelo auxílio financeiro. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Referências

- AIG. Analytical Imaging & Geophysic. 2002. ACORN 4.0 tutorial: stand-alone version. Boulder: ImSpec LLC, 56.
- AMS. American Meteorological Society, 2018. Glossary of meteorology: water vapor. Disponível: http://glossary.ametsoc.org/wiki/Main_Page. Acesso: 23 out. 2018.
- Barrett, D. C.; Frazier, A. E. 2016. Automated method for monitoring water quality using Landsat imagery. *Water* 8, 2016.
- Ben-Dor, E., Kindel, B., Goetz, A. F. H. 2004. Quality assessment of several methods to recover surface reflectance using synthetic imaging spectroscopy data. *Remote Sensing of Environment* 90, 389-404.
- Berk, A., Conforti, P., Hawes, F., Perkins, T., Guiang, C., Acharya, P., Kennett, R., Gregor, B., Van Den Bosch, J. 2016. Next generation MODTRAN® for improved atmospheric correction of spectral imagery. Burlington: Spectral Sciences, Inc. AFRL-RV-PS-TR-2016-0105, 64 p.
- Bernardo, N., Watanabe, F., Rodrigues, T., Alcântara, E. 2017. Atmospheric correction issues for retrieving total suspended matter concentrations in inland waters using OLI/Landsat-8 image. *Advances in Space Research* 59, 2335-2348.
- Bernstein, L. S., Jin, X., Gregor, B., Adler-Golden, S. 2012. Quick Atmospheric Correction Code: algorithm description and recent upgrades. *Optical Engineering* 51, 111719-1-111719-11.
- Bhatia, N.; Tolpekin, V. A.; Stein, A.; Reusen, I. 2018. Estimation of AOD under uncertainty: an approach for hyperspectral airborne data. *Remote Sensing* 10, 6, 1-30.
- Brando, V. E.; Braga, F.; Zaggia, L.; Giardino, C.; Bresciani, M.; Matta, E.; Bellafiore, D.; Ferrarin, C.; Maicu, F.; Benetazzo, A.; Bonaldo, D.; Falcieri, F. M.; Coluccelli, A.; Russo, A.; Carniel, S. 2015. High-resolution satellite

- turbidity and sea surface temperature observations of river plume interactions during a significant flood event. *Ocean Science* 11, 909-920.
- Breunig, F. M.; Galvão, L. S.; Dalagnol, R.; Dauve, C. E.; Parraga, A.; Santi, A. L.; Della Flora, D. P.; Chen, S. 2020. Delineation of management zones in agricultural fields using cover-crop biomass estimates from PlanetScope data. *International Journal of Applied Observation and Geoinformation* 85, 102004.
- Campanelli, M.; Mascitelli, A.; Sanò, P.; Diémoz, H.; Estellés, V.; Federico, S.; Iannarelli, A. M.; Fratarcangeli, F.; Mazzoni, A.; Realini, E.; Crespi, M.; Bock, O.; Martínez-Lozano, J. A.; Dietrich, S. 2018. Precipitable water vapour content from ESR/SKYNET sun-skyradiometers: validation against GNSS/GPS and AERONET over three different sites in Europe. *Atmospheric Measurement Techniques* 11, 81-94.
- CESBIO. Centre d'Études Spatiales de la Biosphère. 2019. New satellites added to SMAC atmospheric correct. Disponível em: <http://www.cesbio.ups-tlse.fr/multitemp/?p=2956>. Acesso em: 09 jun 2019.
- Chandrasekhar, S. 1960. Radiative transfer. New York: Dover Publications, Inc. 415.
- Chavez, P. S. 1988. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. *Remote Sensing of Environment* 24, 459-479.
- Chavez, P. S. 1996. Image-based atmospheric corrections revisited and improved. *Photogrammetric Engineering and Remote Sensing* 62, 1025-1036.
- Clevers, J. G. P. W.; Kooistra, L.; Van den Brande, M. M. M. 2017. Using Sentinel-2 data for retrieving LAI and leaf and canopy chlorophyll content of a potato crop. *Remote Sensing* 9.
- De Keukelaere, L.; Sterckx, S.; Adriaensen, S.; Knaeps, E.; Reusen, I.; Giardino, C.; Bresciani, M.; Hunter, P.; Neil, C.; Van Der Zande, D.; Vaiciute, D. 2018. Atmospheric correction of Landsat-8/OLI and Sentinel-2/MSI data using iCOR algorithm: validation for coastal and inland waters. *European Journal of Remote Sensing* 51, 525-542.
- Dong, T. F.; Liu, J.; Shang, J.; Qian, B.; Ma, B.; Kovacs, J. M.; Walters, D.; Jiao, X.; Geng, X.; Shi, Y. 2019. Assessment of red-edge vegetation indices for crop leaf area index. *Remote Sensing of Environment* 222, 133-143.
- Doxani, G.; Vermote, E.; Roger, J. C.; Gascon, F.; Adriaensen, S.; Frantz, D.; Hagolle, O.; Hollstein, A.; Kirches, G.; Li, F.; Louis, J.; Mangin, A.; Pahlevan, N.; Pflug, B.; Vanhellemont, Q. 2018. Atmospheric correction intercomparison exercise. *Remote Sensing* 10, 352.
- Emde, C.; Buras-Schnell, R.; Kylling, A.; Mayer, B.; Gasteiger, J.; Hamann, U.; Kylling, J.; Richter, B.; Pause, C.; Dowling, T.; Bugliaro, L. 2016. The libRadtran software package for radiative transfer calculations (version 2.0.1). *Geoscientific Model Development* 9, 1647-1672.
- ESA. European Space Agency. 2018. Sentinel Application Platform (SNAP). Version 6.0. Science Toolbox Exploitation Platform, SNAP Development Team.
- Gao, B. C.; Montes, M. J.; Davis, C. O.; Goetz, A. F. H. 2009. Atmospheric correction algorithms for hyperspectral remote sensing data of land and ocean. *Remote Sensing of Environment* 113, S17-S24.
- Gascon, F.; Bouzinac, C.; Thépaut, O.; Jung, M.; Francesconi, B.; Louis, J.; Lonjou, V.; Lafrance, B.; Massera, S.; Gaudel-Vacaresse, A.; Languille, F.; Alhammoud, B.; Viallefont, F.; Pflug, B.; Bieniarz, J.; Clerc, S.; Pessiot, L.; Trémas, T.; Cadau, E.; De Bonis, R.; Isola, C.; Martimort, P.; Fernandez, V. 2017. Copernicus Sentinel-2A calibration and products validation status. *Remote Sensing* 9, 584.
- Gerstmann, H.; Glasses, C.; Thurkow, D.; Moller, M. 2018. Detection of phenology-defined data acquisition time frames for crop type mapping. *PFG-Journal of Photogrammetry Remote Sensing and Geoinformation Science* 86, 15-27.
- Ghotbi, S.; Sotoudeheian, S.; Arhami, M. 2016. Estimating urban ground-level PM₁₀ using MODIS 3km AOD product and meteorological parameters from WRF model. *Atmospheric Environment* 141, 333-346.
- Grass Development Team. 2018. Geographic Resources Analysis Support System (GRASS) software, version 7.4.1. Open Source Geospatial Foundation.
- Gupta, R. P. 2003. Digital image processing of multispectral image. In: Gupta, R. P. *Remote sensing geology*. 2 ed. New York: Springer-Verlang, cap. 10.
- Hadjimitsis, D. G.; Papadavid, G.; Agapiou, A.; Themistocleous, K.; Hadjimitsis, M. G.; Retalis, A.; Michaelides, S.; Chrysoulakis, N.; Toullos, L.; Clayton, C. R. I. 2010. Atmospheric correction for satellite remotely sensed data intended for agricultural applications: impact on vegetation indices. *Natural Hazards and Earth System Sciences* 10, 89-95.
- Hagolle, O.; Huc, M.; Pascual, D. V.; Dedieu, G. 2015. A multi-temporal and multi-spectral method to estimate aerosol optical thickness over land, for the atmospheric correction of Formosat-

- 2, Landsat, VENUS and Sentinel-2 images. *Remote Sensing* 7, 2668-2691.
- Harris Geospatial Solutions. 2018. Environment for Visualizing Images - ENVI. version 5.4. Melbourne: Harris Geospatial Solutions, Inc.
- Hilker, T. 2018. Surface reflectance/bidirectional reflectance distribution function. In: Liang, S. (Ed.). *Comprehensive remote sensing* 3, 2-8.
- Holben, B. M.; Eck, T. F.; Slutsker, I.; Tanré, D.; Buis, J. P.; Setzer, A.; Vermote, E.; Reagan, J. A.; Kaufman, Y. J.; Nakajima, T.; Lavenue, F.; Jankowiak, I.; Smirnov, A. 1998. AERONET – A federated instrument network and data archive for aerosol characterization. *Remote Sensing of Environment* 66, 1-16.
- Hovi, A.; Raitio, P.; Rautiainen, M. 2017. A spectral analysis of 25 boreal tree species. *Silva Fennica* 51, 1-16.
- Hsu, N. C.; Jeong, M. J.; Bettenhausen, C.; Sayer, A. M.; Hansell, R.; Seftor, C. S.; Huang, J.; Tsay, S. C. 2013. Enhanced Deep Blue aerosol retrieval algorithm: the second generation. *Journal of Geophysical Research: Atmospheres* 118, 405, 9296-9315.
- Kaufman, Y. J., Sendra, C. 1988. Algorithm for automatic atmospheric corrections to visible and near-IR satellite imagery. *International Journal of Remote Sensing* 9, 1357-1381.
- Kotchenova, S. Y.; Vermote, E. F. 2007. A vector version of the 6S radiative transfer code for atmospheric correction of satellite data: an overview. AGU Fall Meeting Abstracts.
- Lantzanakis, G.; Mitraka, Z.; Chrysoulakis, N. 2017. Comparison of physically and image based atmospheric correction methods for Sentinel-2 satellite imagery. In: Karacostas, T. S.; Bais, A. F.; Nastos, P. T. (Eds.). *Perspectives on atmospheric sciences*. Basel: Springer International Publishing, 255 – 261.
- Levy, R. C.; Hsu, C.; 2015. MODIS Atmosphere L2 Aerosol Product. NASA MODIS Adaptive Processing System, Goddard Space Flight Center, USA: http://dx.doi.org/10.5067/MODIS/MOD04_L2.006.
- Levy, R. C.; Remer, L. A.; Kleidman, R. G.; Mattoo, S.; Ichoku, C.; Kahn, R.; Eck, T. F. 2010. Global evaluation of the Collection 5 MODIS dark-target aerosol products over land. *Atmospheric Chemistry and Physics* 10, 10399-10420.
- Liang, L.; Engling, G.; Cheng, Y.; Liu, X.; Du, Z.; Ma, Q.; Zhang, X.; Sun, J.; Xu, W.; Liu, C.; Zhang, G.; Xu, H. 2020. Biomass burning impacts on ambient aerosol at a background site in East China: insights from a yearlong study. *Atmospheric Research* 231, 104660.
- Lyapustin, A. I. 2005. Radiative transfer code SHARM for atmospheric and terrestrial applications. *Applied Optics* 44, 36, 7764-7772.
- Lyapustin, A. I.; Wang, Y.; Laszlo, I.; Hilker, T.; Hall, F. G.; Sellers, P. J.; Tucker, C. J.; Korkin, S. V. 2012. Multi-angle implementation of atmospheric correction for MODIS (MAIAC): 3. Atmospheric correction. *Remote Sensing of Environment* 127, 385-393.
- Lyapustin, A.; Martonchik, J.; Wang, Y. J.; Laszlo, I.; Korkin, S. 2011a. Multiangle implementation of atmospheric correction (MAIAC): 1. Radiative transfer basis and look-up tables. *Journal of Geophysical Research: Atmospheres* 116, 1-9.
- Lyapustin, A.; Wang, Y. 2018. MODIS Multi-Angle Implementation of Atmospheric Correction (MAIAC) data user's guide. 2.0. NASA EOSDIS Land Processes DAAC.
- Lyapustin, A.; Wang, Y.; Korkin, S.; Huang, D. 2018. MODIS Collection 6 MAIAC algorithm. *Atmospheric Measurement Techniques* 11, 5741-5765.
- Lyapustin, A.; Wang, Y.; Laszlo, I.; Kahn, R.; Korkin, S.; Remer, L.; Levy, R.; Reid, J. S. 2011b. Multiangle implementation of atmospheric correction (MAIAC): 2. Aerosol algorithm. *Journal of Geophysical Research: Atmospheres* 116, 1-15.
- Main-Knorn, M.; Pflug, B.; Louis, J.; Debaecker, V.; Muller-Wilm, U.; Gascon, F. 2017. Sen2Cor for Sentinel-2. In: *Conference on Image and Signal Processing for Remote Sensing*, 23., 2017, Warsaw, Poland. Proceedings... Bellingham: SPIE.
- Majasalmi, T.; Rautiainen, M. 2016. The potential of Sentinel-2 data for estimating biophysical variables in a boreal forest: a simulation study. *Remote Sensing Letters* 7, 427-436.
- Marcello, J.; Eugenio, F.; Perdomo, U.; Medina, A. 2016. Assessment of atmospheric algorithms to retrieve vegetation in natural protected areas using multispectral high resolution imagery. *Sensors* 16, 1624.
- Markelin, L.; Honkavaara, E.; Schläpfer, D.; Bovet, S.; Korpela, I. 2012. Assessment of radiometric correction methods for ADS40 imagery. *Photogrammetrie Fernerkundung Geoinformation* 3, 251-266.
- Martins, V. S.; Lyapustin, A.; de Carvalho, L. A. S.; Barbosa, C. C. F.; Novo, E. M. L. M. 2017. Validation of high-resolution MAIAC aerosol product over South America. *Journal of Geophysical Research Atmospheres* 122, 7537-7559.
- Martonchik, J. V.; Diner, D. J.; Kahn, R. A.; Ackerman, T. P.; Verstraete, M. M.; Pinty, B.;

- Gordon, H. R. 1998. Techniques for the retrieval of aerosol properties over land and ocean using multiangle imaging. *IEEE Transactions on Geoscience and Remote Sensing* 36, 4, 1212-1227.
- Mograne, A. M.; Jamet, C.; Loisel, H.; Vantrepotte, V.; Mériaux, X.; Cauvin, A. 2019. Evaluation of five atmospheric correction algorithms over french optically-complex waters for the Sentinel-3A OLCI ocean color sensor. *Remote Sensing* 11, 668.
- Moses, W. J.; Sterckx, S.; Montes, M. J.; De Keukelaere, L.; Knaeps, E. Atmospheric correction for inland water. In: Mishra, D. R.; Ogashawara, I.; Gitelson, A. A. (Eds.). 2017. *Bio-optical modeling and remote sensing of inland waters*. Amsterdam: Elsevier. 3, 69 – 94.
- Obregón, M. A.; Costa, M. J.; Silva, A. M.; Serrano, A. 2018. Impact of aerosol and water vapor on SW radiation at the surface: sensitivity study and applications. *Atmospheric Research* 213, 252-263.
- Okin, G. S.; Gu, J. 2015. The impact of atmospheric conditions and instrument noise on atmospheric correction and spectral mixture analysis of multispectral imagery. *Remote Sensing of Environment* 164, 130–141.
- OTB Development Team. 2018. *The Ofeo Tool Box software guide*. Centre National d'Études Spatiales, 714.
- Proud, S. R.; Rasmussen, M. O.; Fensholt, R.; Sandholt, I.; Shisanya, C.; Mutero, W.; Mbow, C.; Anyamba, A. 2010. Improving the SMAC atmospheric correction code by analysis of Meteosat Second Generation NDVI and surface reflectance data. *Remote Sensing of Environment* 114, 1687-1698.
- Rahman, H.; Dedieu, G. 1994. SMAC: a simplified method for the atmospheric correction of satellite measurements in the solar spectrum. *International Journal of Remote Sensing* 15, 1, 123-143.
- Rautiainen, M.; Lukeš, P.; Homolová, L.; Hovi, A.; Pisek, J.; Möttus, M. 2018. Spectral properties of coniferous forests: a review of in situ and laboratory measurements. *Remote Sensing* 10, 2071-20728.
- Remer, L. A.; Kaufman, Y. J.; Tanré, D.; Mattoo, S.; Chu, D. A.; Martins, J. V.; Li, R. R.; Ichoku, C.; Levy, R. C.; Kleidman, R. G.; Eck, T. F.; Vermote, E.; Holben, B. N. 2004. The MODIS aerosol algorithm, products and validation. *Journal of the Atmospheric Sciences* 62, 947-973.
- ReSe Applications. 2018. *ATCOR software versions*. Zurich: ReSe Applications GmbH. Disponível: <<https://www.rese-apps.com/software/atcor-3-satellites/index.html>>. Acesso: 25 jul. 2018.
- Richter, R., Louis, J., Muller-Wilm, U. 2012. *Sentinel-2 MSI level 2A products algorithm theoretical basis document*. S2PAD-ATBD-0001. Darmstadt: Telespazio VEGA Deutschland GmbH.
- Richter, R., Schläpfer, D. 2011. *Atmospheric/topographic correction for airborne imagery (ATCOR-4 user guide, version 6.0.2)*. DLR report DLR-IB 565-02/11, Wessling, Germany.
- Richter, R., Schläpfer, D. 2012. *Atmospheric/Topographic Correction for Satellite Imagery (ATCOR-2/3 user guide, version 8.2)*. DLR report DLR-IB 565-02/12, Wessling: Deutsches zentrum für Luft-und Raumfahrt.
- Richter, R., Wang, X., Bachmann, M., Schläpfer, D., 2011. Correction of cirrus effects in Sentinel-2 type of imagery. *International Journal of Remote Sensing* 32, 2931-2941.
- Richter, R.; Schläpfer, D. 2015. *Atmospheric/topographic correction for satellite imagery*. DLR report DLR-IB 565-02/15. Wessling: Deutsches zentrum für Luft-und Raumfahrt. 252.
- Rothman, L. S.; Barbe, A.; Benner, D. C.; Brown, L. R.; Camy-Peyret, C.; Carleer, M. R.; Chance, K.; Clerbaux, C.; Dana, V.; Devi, V. M.; Fayt, A.; Flaud, J. -M.; Gamache, R. R.; Goldman, A.; Jacquemart, D.; Jucks, K. W.; Lafferty, W. J.; Mandin, J. -Y.; Massie, S. T.; Nemtchinov, V.; Newnham, D. A.; Perrin, A.; Rinsland, C. P.; Schroeder, J.; Smith, K. M.; Smith, M. A. H.; Tang, K.; Toth, R. A.; Auwera, J. V.; Varanasi, P.; Yoshino, K. 2003. *The HITRAN Molecular Spectroscopic Database: Edition of 2000 including updates through 2001*. *Journal of Quantitative Spectroscopy and Radiative Transfer* 82, 1-4, 5-44.
- Rouse, J. W.; Haas, R. H.; Schell, J. A.; Deering, D. W., 1973. Monitoring vegetation systems in the Great Plains with ERTS. In: *Earth Resources Technology Satellite-1 Symposium*, 3, Washington- DC, Proceedings... Washington – DC.
- Schläpfer, D., Borel, C. C., Keller, J., Itten, K. I. 1998. Atmospheric precorrected differential absorption technique to retrieve columnar water vapor. *Remote Sensing of Environment* 65, 353-366.
- Schowengerdt, R. A. 2007. *Optical radiation models*. In: *Schowengerdt, R. A. Remote sensing: models and methods for image processing*. 3. ed. Amsterdam: Elsevier, 45-73.
- Seemann, S. W., Li, W., Menzel, P., Gumley, L. E. 2003. Operational retrieval of atmospheric temperature, moisture and ozone from MODIS infrared radiances. *Journal of Applied Meteorology* 42, 1072-1091.

- Sola, I.; García-Martín, A.; Sandonís-Pozo, L.; Álvarez-Mozos, J.; Pérez-Cabello, F.; González-Audifcana, M.; Llovería, R. M. 2018. Assessment of atmospheric correction methods for Sentinel-2 images in Mediterranean landscapes. *International Journal of Applied Earth Observation and Geoinformation* 73, 63-76.
- SSI. Spectral Sciences Incorporated. 2018. MODTRAN® atmospheric models. Disponível: http://modtran.spectral.com/static/modtran6/html/help_atmosphere_model.html?v=3. Acesso: 22 out. 2018.
- Sterckx, S., Knaeps, E., Adriaensen, S., Reusen, I., De Keukelaere, L., Hunter, P., Giardino, C., Odermatt, D. 2015a. OPERA: an atmospheric correction for land and water. In: *Sentinel-3 for Science Workshop, Venice, 2015. Proceedings...* ESA Special Publication.
- Sterckx, S., Knaeps, E., Kratzer, S., Ruddick, K. 2015b. SIMilarity Environment Correction (SIMEC) applied to MERIS data over inland and coastal waters. *Remote Sensing of Environment* 157, 96-110.
- Su, Z.; Roebeling, R. A.; Schulz, J.; Holleman, I.; Levizzani, V.; Timmermans, W. J.; Rott, H.; Mognard-Campbell, N.; De Jeu, R.; Wagner, W.; Rodell, M.; Salama, M. S.; Parodi, G. N.; Wang, L. 2011. Observations of hydrological processes using remote sensing. In: Wilderer, P. A. (Ed.). *Treatise on water science*. 1. ed. Oxford: Academic Press, 351-399.
- Superezynski, S.; Kondragunta, S.; Lyapustin, A. 2017. Evaluation of the Multi-Angle Implementation of Atmospheric Correction (MAIAC) Aerosol Algorithm through intercomparison with VIIRS aerosol products and AERONET. *Journal of Geophysical Research Atmospheres* 122, 3005-3022.
- Tang, C.; Coull, B.; Schwartz, J.; Lyapustin, A.; Di, Q.; Koutrakis, P. 2017. Developing particle emission inventories using remote sensing. *Journal of Air Waste Manage Association* 67, 53-63.
- Tanré, D., Deroo, C., Duhât, P., Herman, M., Morcrette, J. J., Perbos, J., Deschamps, P. Y. 1990. Technical note description of a computer code to simulate the satellite signal in the solar spectrum: the 5S code. *International Journal of Remote Sensing* 11, 659-668.
- Tao, M.; Chen, L.; Wang, Z.; Tao, J.; Che, H.; Wang, X.; Wang, Y. 2015. Comparison and evaluation of the MODIS Collection 6 aerosol data in China. *Journal of Geophysical Research: Atmospheres* 120, 6992-7005.
- Tso, B., Mather, P. M. 2009. Remote sensing in the optical and microwave regions. In: Tso, B.; Mather, P. M. *Classification methods for remotely sensed data*. 2 ed. Boca Raton: CRC Press, 1-38.
- Vermote, E. 2015. MOD09CMG V006 The MODIS/Terra Surface Reflectance Daily L3 Global 0.05Deg CMG V006. NASA EOSDIS LP DAAC. <http://doi.org/10.5067/MODIS/MOD09CMG.006>.
- Vermote, E. F., Tanre, D., Deuze, J. L., Herman, M., Morcrette, J. J. 1997. Second simulation of the satellite signal in the solar spectrum, 6S: an overview. *IEEE Transactions on Geoscience and Remote Sensing* 35, 675-686.
- Vermote, E. F.; Kotchenova, S. 2008. Atmospheric correction for the monitoring of land surfaces. *Journal of Geophysical Research* 113.
- Vermote, E., Tanré, D., Duzé, J. L., Herman, M., Morcrette, J. J., Kotchenova, S. Y. 2006. Second simulation of a satellite signal in the solar spectrum – vector (6SV). 6S user guide version 3. Laboratoire d'Optique Atmosphérique.
- Vermote, E.; Justice, C.; Claverie, M.; Franch, B. 2016. Preliminary analysis of the performance of the Landsat-8/OLI land surface reflectance product. *Remote Sensing of Environment* 185, 46-56.
- Vescovi, F. D.; Minchella, A. 2017. Copernicus data quality control: technical note atmospheric corrections. ESA 2.2, 22.
- VITO. Vlaams Instituut voor Technologisch Onderzoek. 2017. iCOR plugin for SNAP toolbox: software user manual. Version 1. Mol: VITO Remote Sensing Unit.
- Wang, J., Wu, C., Zhang, C., Ju, W., Wang, X., Chen, Z., Fang, B. 2018. Improved modeling of gross primary productivity (GPP) by better representation of plant phenological indicators from remote sensing using a process model. *Ecological Indicators* 88, 332-340.
- Wei, J.; Li, Z.; Peng, Y.; Sun, L. 2019. MODIS Collection 6.1 aerosol optical depth products over land and ocean: validation and comparison. *Atmospheric Environment* 201, 428-440.
- Xiao, Q. Y.; Wang, Y.; Chang, H. H.; Meng, X.; Geng, G.; Lyapustin, A.; Liu, Y. 2017. Full-coverage high-resolution daily PM2.5 estimation using MAIAC AOD in the Yangtze River Delta of China. *Remote Sensing of Environment* 199, 437-446.
- Zhang, J.; Dong, W.; Wang, J. X.; Liu, X. N. 2014. A method to enhance the fog image based on dark object subtraction. *Applied Mechanics and Materials* 543-547, 2484-2487.
- Zhang, S.; Wu, J.; Fan, W.; Yang, Q.; Zhao, D. 2020. Review of aerosol optical depth retrieval using visibility data. *Earth-Science Reviews* 200.

- Zhang, Z. Y.; Wong, M. S.; Lee, K. H. 2016a. Evaluation of the representativeness of ground-based visibility for analyzing the spatial and temporal variability of aerosol optical thickness in China. *Atmospheric Environment* 147, 31-45.
- Zhang, Z., He, G., Wang, X. 2010. A practical DOS model-based atmospheric correction algorithm. *International Journal of Remote Sensing* 31, 2837-2852.
- Zhang, Z.; Wu, W.; Fan, M.; Wei, J.; Tan, Y.; Wang, Q. 2019. Evaluation of MAIAC aerosol retrievals over China. *Atmospheric Environment* 202, 8-16.
- Zhang, Z.; Wu, W.; Wei, J.; Song, Y.; Yan, X.; Zhu, L.; Wang, Q. 2017. Aerosol optical depth retrieval from visibility in China during 1973–2014. *Atmospheric Environment* 171, 38-48.
- Zheng, H.; Cheng, T.; Zhou, M.; Li, D.; Yao, X.; Tian, Y.; Cao, W.; Zhu, Y. 2019. Improved estimation of rice aboveground biomass combining textural and spectral analysis of UAV imagery. *Precision Agriculture* 20, 611-629.