

Remote Sensing vegetation index for processing images in the visible band (RGB)

Jadson Freire-Silva^{*}, Yenê M. Paz^{**}, Pedro P. Lima-Silva^{***}, João A. dos S. Pereira^{****}, Ana L. B. Candeias^{*****}

^{*} Doutorando em Desenvolvimento e Meio Ambiente - PRODEMA/UFPE. Email: jadsonfreireufpe@hotmail.com (autor correspondente)

^{**} Doutora em Desenvolvimento e Meio Ambiente - PRODEMA/UFPE. Email: yenepez@gmail.com

^{***} Mestrando em Desenvolvimento e Meio Ambiente - PRODEMA/UFPE. Email: pedroplsilva@protonmail.ch

^{****} Doutorando em Desenvolvimento e Meio Ambiente - PRODEMA/UFPE. Email: antoniopereira.278@gmail.com

^{*****} Professora da Universidade Federal de Pernambuco. Departamento de Engenharia Cartográfica e Agrimensura - DeCart/UFPE. Email: analucia@ufpe.br.

Received 16 September 2019; accepted 30 October 2019

Abstract

It is of extreme relevance to understand the behavior of vegetation for planning and decision-making regarding areas for planting, adequate use of water resources, irrigation and monitoring of vegetation dynamics, for example. In this sense, Remote Sensing (SR) has been a relevant support for the monitoring of ecosystems, since it is observed several researches involving the application of this technique through different mathematical algorithms titled indexes. The new satellites, unmanned vehicles and high-resolution cameras that maintains products in the visible (RGB) range bring new perspectives to RS's performance in vegetation, especially in agriculture. Thus, it was developed over the years indices that allowed the detection of vegetation in visible spectral bands and, thus, facilitating agropastoral processes, precision agriculture and the reduction of SR as a whole. Thus, this work aims to review vegetation indices for processing in the RGB range. From the review, the origin of fifteen RGB indices is verified, being designed by diverse needs and equipment, where all reach competitive satisfactory. It is important to note that the developed indexes have improved the RS analyzes, where these improvements have led to new learning that directly contributed to the study of ecosystems, especially vegetation environments. The RS's dynamism makes it an innovation gimmick, in which, through demands and demands, new indices can be created by contributing to the maintenance and provision of social, economic and ecological activities.

Keywords: Ecosystem, Environment, Agriculture, Decision-making, geoprocessing.

Índices de vegetação do Sensoriamento Remoto para processamento de imagens na faixa do visível (RGB)

Resumo

É de extrema relevância entender o comportamento da vegetação para o planejamento e tomada de decisão no que se refere as áreas para plantio, uso adequado de recursos hídricos, irrigação e acompanhamento de dinâmicas vegetacionais, por exemplo. Neste sentido, o Sensoriamento Remoto (SR) vem sendo um relevante suporte para o monitoramento de ecossistemas, uma vez que se observa diversas pesquisas envolvendo a aplicação desta técnica através de diferentes algoritmos matemáticos intitulados índices. Os novos satélites, os veículos não tripulados e as câmeras de alta resolução que mantêm produtos na faixa do visível (RGB) trazem novas perspectivas para a atuação do SR na vegetação, sobretudo na agricultura; assim, foi desenvolvido ao longo dos anos índices que possibilitasse a detecção da vegetação nas faixas espectrais visíveis e dessa forma, facilitando processos agropastoris, de agricultura de precisão e no barateamento do SR como um todo. Deste modo, este trabalho tem como objetivo uma revisão acerca dos índices de vegetação para o processamento na faixa RGB. A partir da revisão, verifica-se a procedência de quinze índices RGB, sendo concebidos por necessidades e equipamentos diversos, onde todos alcançam satisfatoriedade competida. Contata-se que os índices desenvolvidos melhoraram em significância as análises do SR, e que essas melhorias acarretaram novos aprendizados que contribuíram diretamente para o estudo dos ecossistemas, especialmente os ambientes vegetacionais. O dinamismo do SR o faz chamariz de inovação, em que, através das exigências e de demandas atuais, novos índices poderão ser criados contribuindo na manutenção e provimento de atividades sociais, econômicas e ecológicas.

Palavras-Chave: Ecossistemas, Meio Ambiente, Agricultura, Tomada de decisão, Geoprocessamento.

1. Introdução

É de extrema relevância entender o comportamento remoto da vegetação para o planejamento e tomada de decisão no que se refere a manutenção e aquisição de áreas para plantio, uso adequado de recursos hídricos, irrigação e acompanhamento de dinâmicas vegetacionais, entre outros. O estudo e monitoramento da vegetação de ambientes agrícolas ou áreas de preservação/conservação ambiental, por sua vez, vem sendo um dos temas mais abordados e discutidos no Sensoriamento Remoto (SR) quando o mesmo é tratado na temática ambiental. No que concerne ao SR, este pode ser definido como sendo uma ciência que tem como objetivo obter imagens da superfície terrestre através da detecção das interações da radiação eletromagnética com os diferentes materiais e mensuração quantitativa destas (Santos, 2013; Meneses e Almeida, 2012).

O uso de índices matemáticos relacionados aos intervalos espectrais das imagens de satélites como o do Landsat (MSS/TM/OLI) incentivaram e deram o devido suporte às primeiras pesquisas do SR, sendo essas complementadas por novos satélites e índices no século XXI, e desta forma abarcando especificidades regionais e aprimorando técnicas de detecções remotas.

As imagens oriundas de satélites comumente usadas em pesquisas possuem intervalos (ou bandas) espectrais variando na faixa do visível ao infravermelho termal. Esses intervalos espectrais podem ser caracterizados, segundo Meneses e Almeida (2012), como a divisão do espectro eletromagnético em intervalos de comprimentos de onda com base em mecanismos físicos de sua detecção. É de grande importância o pesquisador manter o domínio dos intervalos espectrais possíveis de se trabalhar no sensoriamento remoto; a partir deste domínio, a aplicação das bandas corretas e a combinação destas podem facilitar a discriminação e a explanação do produto a se apresentar na comunidade científica e/ou sociedade.

Os índices criados a partir da manipulação das bandas espectrais ilustram a relevância das imagens oriundas do sensoriamento para o acompanhamento e gestão dos ambientes de interesse. Por sua vez, os diversos níveis de coleta e instrumentos utilizados para obtenção de informações remotas, tais como satélites, aviões ou drones, estão em consonância com as variadas formas para a decodificação das imagens obtidas, que através de programas de realce visual e

equações matemáticas vêm promovendo para essa ciência elevado prestígio e credibilidade em seus produtos, como vem sendo observado ao longo dos anos.

Importantes estudos sobre a temática, tais como as primeiras aplicações do índice de área foliar - IAF (Jordan, 1969), a distribuição espectral da luz na floresta (Federer e Tanner, 1966), o índice de vegetação por diferença normalizada - NDVI (Rouse et al., 1974), o índice de vegetação ajustado ao solo - SAVI (Huete, 1988), os índices de água por diferença normalizada - NDWI (Gao, 1996; McFeeters, 1996), o índice de área construída por diferença normalizada - NDBI (Zha et al., 2003), a modificação do índice de água por diferença normalizada - MNDWI (Xu, 2006) e o de inundações desérticas - DFI (Wang, 2007) estão em concomitância com escritos envolvendo análises ecossistêmicas, uma vez que, observa-se monitoramentos via sensoriamento em agricultura (Rouse, 1974; Epiphanyo et al., 1996; Goergen et al., 2016), dossel de vegetação (Tucker e Maxwell, 1976; Rosa et al., 2015), perímetros irrigados (Epiphanyo e Vitorello, 1983; Silva et al., 2012), uso e ocupação do solo (Borges et al., 1993; Menke et al., 2009; Silva et al., 2015), áreas litorâneas (Moraes et al., 2015) e ações antrópicas (Alves e Skole, 1996; Grecchi et al., 2016).

Neste sentido, verificam-se diversos trabalhos que realizaram revisões de literatura acerca de índices de vegetação (Batten, 1997; Burns e Ciurczak, 2007; Mulla, 2013; Chang et al., 2016; Xue e Su, 2017), contudo levantamentos acerca de índices que utilizam apenas as bandas do visível RGB não foram identificados, sobretudo no Brasil.

As bandas RGB (abreviação dos nomes vermelho, verde e azul, em inglês) são referentes as faixas do espectro eletromagnético que para o olho humano é possível de observar. Máquinas fotográficas comuns, acopladas em drones e/ou sensores oriundos de satélites em órbita mantêm estas faixas a disposição. Também se conhece essas faixas como sensores passivos, isto é, aqueles que utilizam apenas a luz do sol como fonte de captação da radiação eletromagnética (Figueiredo, 2005). As novas tecnologias e a facilidade em adquirir veículos não tripulados, máquinas fotográficas profissionais e drones para o monitoramento de ambientes específicos, abrem um novo espaço para as análises do Sensoriamento Remoto como um todo.

Diante do exposto, esse trabalho tem como objetivo uma revisão dos índices de vegetação para o processamento de imagens na faixa visível (RGB).

2. Material e métodos

A revisão de literatura é uma técnica utilizada por diversos acadêmicos, onde seu objetivo principal é unir, compilar, condensar e assim, exibir um novo manuscrito, este com novas informações e reflexões contidas que não distorcem as ideias das pesquisas anteriores; pelo contrário, a revisão de literatura fornece uma nova perspectiva de um determinado assunto contribuindo em relevância para a pesquisa científica (Iglesias e Gomes, 2004). Essa técnica foi utilizada nessa pesquisa para levantamento e discussão de trabalhos científicos com foco nos índices de vegetação.

Esta revisão de literatura avaliou artigos, relatórios e documentos publicados nos últimos 40 anos, onde consultou-se plataformas científicas de credibilidade, tal como as bases de dados *Science Direct*, *Scopus*, *Latindex*, *ResearchGate*, *Elsevier* – *Open Science* e *Google Scholar*. Para tal foram utilizadas como palavras chave de busca os termos em português e em inglês: índices de vegetação, índice RGB e índices de sensoriamento remoto. Estes termos foram utilizados para a identificação de diferentes índices de vegetação utilizando a banda do visível. A revisão abarca pontuações acerca da importância dos índices do sensoriamento remoto para os monitoramentos ecossistêmicos. Também são apresentados os índices identificados e a possibilidade de processamento na banda do visível, isto é, na banda R (vermelho/red), G (verde/green) e B (azul/blue), tal como os motivos específicos para seu desenvolvimento e a sua formulação.

3. Resultados e discussão

A importância do Sensoriamento Remoto para os monitoramentos ecossistêmicos

Lacunas no conhecimento das relações que ocorrem nos ecossistemas têm limitado a tomada de decisão das políticas públicas. Estas relações são de grande complexidade devido as interações físicas, químicas e biológicas contidas. Sabe-se que a partir do entendimento de mecanismos que possam gerir com eficiência os ambientes de interesse, a consequência direta desse entendimento é a máxima conservação dos recursos naturais e biodiversidade, estas sendo diariamente alvo das ações antrópicas. Neste cenário, segundo Barbosa e Vecchia (2009) e Cunha et al. (2012), o sensoriamento remoto mostra-se em destaque nas pesquisas de cunho ambiental, ajudando a estabelecer condições de uso e ocupações de solo

sustentáveis através do monitoramento dos parâmetros biofísicos das áreas em estudo.

Observa-se aplicações do sensoriamento remoto nos trabalhos de Alexakis et al. (2014) no que diz respeito às inundações; Li et al. (2014), Ha et al. (2017) e Herman et al. (2018) com modelos hidrológicos; Pohl, Gloaguen e Seiler (2015) no comportamento de precipitações; Khan et al. (2016) para bacias hidrográficas, dentre outros temas que envolvem a hidrologia. Entretanto, a atuação do SR não se restringe apenas ao hidrológico.

O acompanhamento de mudanças no uso do solo e da terra em grandes áreas e em regiões específicas têm recebido o auxílio do SR em diversos âmbitos. As pesquisas de Weng (2002), Chen et al. (2006), Xiao et al. (2006), Picón-Feliciano et al. (2009), Mohan e Kandya (2015), Rawat e Kumar (2015), Fallati et al. (2017) e Cui et al. (2018) onde as atuações compreenderam ambientes tropicais e temperados, zonas urbanas e rurais, avaliação de impactos e resiliência de territórios, respectivamente, podem ser tomadas como exemplos. Acerca da compreensão da atuação das mudanças climáticas na terra, o sensoriamento remoto deu suporte em trabalhos que monitoraram a regressão das geleiras (Bolch, 2007) e ecossistemas localizados na tundra (Stow et al. 2004), mantendo desta forma, um potencial e relevante espaço nestas esferas de estudo (Yang et al. 2013).

Na agricultura, o SR provou sua importância na utilização em perímetros irrigados (Bastiaanssen et al., 2000), agricultura de precisão (Mulla, 2013; Rokhmana, 2015), avaliação de secas em polos agrícolas (Dutta et al., 2015) e grandes coberturas de policulturas e monoculturas (Atzberger, 2013; Steele-Dunne et al., 2017). As diversas particularidades que satisfatoriamente o SR colabora possibilita que aspectos econômicos, sociais e ambientais sejam conservados e cultivados, incentivando a continuidade da combinação desta técnica e proporcionando inovações.

Atualmente um excelente exemplo da inovação do Sensoriamento Remoto é a automatização dos processos de monitoramento denominado projeto EEFlux – *Earth Engine Evapotranspiration Flux*. O EEFlux, projeto oriundo do consórcio entre o Google, a Universidade de Nebraska-Lincoln, do Instituto de Pesquisa do Deserto (EUA) e a Universidade de Idaho que iniciou-se em 2012 e consiste no processamento automático das imagens Landsat e a exposição de tais produtos como imagens brutas, composições verdadeiras, composições falsas, albedo, NDVI, Modelo digital de elevação DEM – (*Digital Elevation*

Model), mapas de uso e cobertura da terra, temperatura da superfície, Evapotranspiração real – ETr (referência da alfafa), Evapotranspiração – ET₀ (referência da grama), Fração da referência ET (ETrF) e a Evapotranspiração – ET, sendo explanada em plataforma virtual vinculada ao *Google Earth Engine system* (EEFLUX, 2015). Facilitando, dessa forma, a aplicação dos índices em tempo hábil para desenvolvimento de políticas sociais, ambientais e econômicas, caso necessário.

Diante do multiverso de oportunidades proporcionadas pelo SR, a quantificação das áreas de interesse a partir dos algoritmos desenvolvidos amplifica e permite que esta ciência avance a especificidades e complexidades antes não conquistadas; isso resguarda o que já foi implementando e projeta modelos para aplicação futuras, desde que se revelem novas necessidades.

Índices de vegetação do Sensoriamento Remoto para o processamento nas bandas RGB

Observando o comportamento de índices do SR oriundos de uma análise de dados coletados em solo através de espectrorradiômetro, Tucker (1979) as relacionou com as faixas do infravermelho/vermelho e as comparou com faixas do verde/vermelho junto as suas respostas na vegetação. Na sua pesquisa nota-se a primeira aparição do índice denominado *Normalized Green Red Difference Index* - NGRDI (traduzido como Índice verde/vermelho por diferença normalizada) que consiste na Equação 1:

$$NGRDI = \frac{G-R}{G+R} \quad (1)$$

Onde G e R são as bandas verde e vermelho, respectivamente.

Contudo, quando Tucker (1979), em sua conclusão, avaliou as respostas vegetacionais com a utilização do NGRDI e índices que envolviam o infravermelho próximo (NIR - *Near-infrared*), constatou a superioridade e a importância dos índices NIR.

Vale ressaltar que outros algoritmos envolvendo as bandas do verde/vermelho foram apresentadas pelo autor (Tabela 1). Além do NGRDI, observa-se outros índices desenvolvidos nas bandas RGB no século XX, sobretudo na década de 1990, tal qual nota-se por exemplo, o *Redness Index* - RI e o *Excess Green* – ExG.

Tabela 1 – Variáveis das bandas verde / vermelho observadas em Tucker (1979).

Outras variáveis observadas
Verde / Vermelho
Verde + Vermelho
(Verde-Vermelho) / (Verde + Vermelho)
(Verde + Vermelho) / (Verde - Vermelho)
Raiz (Verde -Vermelho) / (Verde + Vermelho) + 0.5

Escadafal e Huete (1991) verificando a dificuldade em detectar a vegetação dispersa nos ambientes andinos e áridos via NDVI (ROUSE et al. 1974) e SAVI (Huete, 1988) devido as propriedades específicas dos solos, lançam a equação denominada *Redness Index* – RI, traduzida para o português como Índice de vermelhidão (Equação 2). Uma correlação significativa entre o SAVI e o RI ($r^2=0,74$) faz dele uma nova perspectiva de análise do SR, uma vez que o RI consiste numa razão simples entre bandas, facilitando a aplicação.

$$RI = \frac{R-G}{R+G} \quad (2)$$

Onde G e R são as bandas verde e vermelho, respectivamente.

Identificando a presença de ervas daninhas em colheitas sob a presença de iluminação/sombreamento, resíduos e solos distintos, Woebbecke et al. (1995) testaram índices de vegetação que resultaram na distinção do material vegetativo de outros materiais não-vivos. Estes apresentaram um produto imageado próximo a binarização, onde os valores representam e delinham as regiões de interesse das plantas. Os pesquisadores denominaram a descoberta de *Excess Green Index*– ExG (Equação 3).

$$ExG = 2g - r - b \quad (3)$$

Onde g, r e b são os valores das bandas normalizadas verde, vermelho e azul, respectivamente (Equações 3.1, 3.2; 3.3) (Ponti, 2013).

$$g = \frac{G}{(R+G+B)} \quad (3.1); \quad r = \frac{R}{(R+G+B)} \quad (3.2);$$

$$b = \frac{B}{(R+G+B)} \quad (3.3)$$

Onde R, G e B são as bandas do vermelho, verde e azul, respectivamente.

Woebbecke et al. (1995) finalizam pontuando a satisfatoriedade do índice para áreas sombreadas e não protegidas; indicando a utilização do ExG em monitoramentos agrícolas de pragas no plantio para sua eliminação posterior.

Meyer et al. (1998) também desenvolveu um índice com denominação semelhante ao de Woebbecke et al. (1995); o qual foi intitulado *Excess Red Vegetative Index* – ExR (Equação 4), sendo aplicado no estudo de Meyer e Camargo-Neto (2008), e posteriormente em Srestasathiern e Rakwatin (2014) e Castro et al. (2015) (Equação 4).

$$\text{ExR} = 1.4r - g \quad (4)$$

Onde r e g são as bandas do vermelho e verde, respectivamente.

Novos índices emergiram no século XXI e junto a estas novas alternativas para o processamento na faixa visível do espectro. Louhaichi et al. (2001) observando a necessidade de monitoramento das áreas da cultura do trigo devido ao aumento da população de gansos e seus impactos nos campos de plantação na cidade de Oregon (EUA), propuseram a partir de aerofotografias a formulação do Ground Level Image Analysis – GLI (Equação 5). Este índice também foi trabalhado no estudo de Hunt et al. (2011), mantendo pequenas diferenciações (Equação 6).

$$\text{GLI} = \frac{((G-R)+(G-B))}{(G+R+G+B)} \quad (5)$$

Onde G, R e B são os números digitais (0 – 255) das bandas verde, vermelho e azul, respectivamente.

$$\text{GLI} = \frac{(2R_g - R_r - R_b)}{(2R_g + R_r + R_b)} \quad (6)$$

Onde R_g , R_r e R_b são as reflectâncias das bandas verde, vermelho e azul, respectivamente.

Segundo Louhaichi et al. (2001), o GLI mostrou-se eficiente no acompanhamento de ambientes através de imagens de alta resolução, sejam elas oriundas de drones, aerofotografias georreferenciadas ou satélites comerciais, podendo ser aplicada sua metodologia para outros interesses, tal como outras culturas ou vegetação em pastagens.

Em 2002 dois relevantes índices de vegetação foram apresentados a comunidade científica. Gitelson et al. (2002) baseando-se em índices anteriores: ARVI -

Atmospherically Resistant Vegetation Index (Kaufman e Tanre, 1992), GARI - *Green Atmospherically Resistant Index* (Gitelson et al., 1996), SAVI (Huete, 1988) e NDVI (Rouse et al., 1974), propuseram o *Visible Atmospherically Resistant Index* – VARI (Equação 7), índice que mesmo estando nas faixas do visível, foi projetado nele a introdução de uma correção atmosférica para melhoramento dos respectivos produtos.

$$\text{VARI}_{\text{green}} = \frac{(R_g - R_r)}{(R_g + R_r - R_b)} \quad (7)$$

Onde R_g , R_r e R_b são as reflectâncias das bandas verde, vermelho e azul, respectivamente.

Apesar da inserção da correção atmosférica através do VARI, os autores corroboram com a afirmativa de Tucker (1979), onde as melhores respostas ainda são obtidas através de índices que considerem em suas fórmulas a faixa do infravermelho próximo (NIR). Dessa forma, o VARI serve de complemento para as pesquisas que utilizam o NDVI, SAVI ou outros índices que mantêm em suas fórmulas a faixa do NIR, estes amplamente aplicados no geoprocessamento.

Ainda em 2002, Marchant e Onyango (2002) tendo como base modelos físicos de compensação de sombras iluminadas pela luz do dia, aplicam a premissa da lei do corpo negro e as relaciona com as bandas azul, verde e vermelho dos filtros da câmera. Desta forma, o resultado que os pesquisadores encontraram para as imagens RGB foi a possibilidade da classificação e transformação das mesmas em histogramas bimodais; derivando em produtos com relevância satisfatória para a premissa utilizada. A literatura denomina esse índice de *Vegetative* – VEG (Equação 8) (Hague et al., 2006; Torres-Sánchez et al., 2014).

$$\text{VEG} = \frac{g}{r^a b^{(1-a)}} \quad (8)$$

Onde g, r e b são as bandas verde, vermelho e azul, respectivamente. O “a” é uma constante de valor experimental ($a = 0,667$) (Marchant e Onyango, 2002).

Kataoka et al. (2003) entendendo a importância do acompanhamento dos plantios mediante a filosofia de gerenciamento da agricultura de precisão, desenvolveu um sistema experimental de estimativa do estado das culturas utilizando imagens de câmera RGB. Os pesquisadores intitularam o projeto de CIVE - *Color Index of Vegetation Extraction* (Equação 9).

$$\text{CIVE} = \frac{0,441 * R - 0,811 * G + 0,385 * B + 18,78745}{(9)}$$

Onde G, R e B são as bandas verde, vermelho e azul, respectivamente.

Tendo como material de análise os cultivares de soja e beterraba, os resultados do CIVE para a área experimental em estudo apresentaram discordância na detecção das plantas como um todo, conseguindo este apenas detectar algumas amostras de plantas. Essa consequência fez considerar o índice “aceitável” para o objetivo da pesquisa, todavia, a generalização e replicação para grandes áreas podem resultar em significativas imprecisões.

Um ano após a apresentação do CIVE, Camargo-Neto (2004) em sua tese descreve um algoritmo baseado nos índices ExG e ExR, denominando-o de ExGR - *Excess green minus Excess red* (também encontrado na literatura como ExGExR) (Equação 10).

$$\text{ExGR} = \text{ExG} - \text{ExR} \quad (10)$$

Onde ExG é o Excess Green Index (Equação 3) e o ExR é o Excess Red Vegetative Index (Equação 4), respectivamente.

Durante a validação do ExGR esse foi considerado satisfatório. O índice conseguiu classificar e mapear espécies vegetais usando imagens de cores na faixa do visível em sistemas de plantio. Nas folhas de amendoim, Abutilon (velvetleaf) e milho o algoritmo realizou boa separação no que se refere as plantas e o solo, obtendo uma taxa de sucesso superior aos 75%. Esse resultado pode ser considerado bom para um índice de classificação não supervisionada (Camargo-Neto, 2004).

A segunda década dos anos 2000 é marcada pela perpetuação de satélites consolidados e o lançamento de novos; destacando-se os satélites de alta resolução e a popularização dos drones, em que essas características remodelaram e deram novos caminhos para o SR e os estudos ecossistêmicos.

Desafios em detectar a vegetação com câmeras comerciais por intermédio de índices do SR fizeram Hunt Jr. et al. (2011) desenvolver, a partir das bandas RGB, e testar em amostras de sorgo, milho, dentes-de-leão e outros tipos de flores, o *Triangular Greenness Index* (TGI), fórmula que identifica a vegetação no histograma a partir de uma triangulação (Equação 11).

$$\text{TGI} = -0,5 [(\lambda r - \lambda b)(Rr - Rg) - (\lambda r - \lambda g)(Rr - Rb)] \quad (11)$$

Onde λ é o comprimento (nm) da onda e R é a reflectância das bandas. O r corresponde a banda do vermelho, b do azul e g do verde, respectivamente.

Hunt Jr. et al. (2011) admite haver índices de vegetação com uma resposta mais positiva que o TGI, todavia, o mesmo pode ser utilizado aliado a outros índices, devido a capacidade em detectar a presença da vegetação em câmeras comerciais e a agilidade/facilidade de aplicação em satélites que disponibilizam seus produtos gratuitamente. Um ano após a apresentação do TGI, Guerrero et al. (2012) compila uma série de índices com o principal objetivo da automatização e segmentação das regiões onde há a existência ou não de plantas em ambientes de agricultura de precisão. Assim, os pesquisadores resgataram estudos com objetivos semelhantes e, por reajustes, desenvolvem o índice denominado *Combination* (COM) (Equação 12).

$$\text{COM} = 0,36\text{ExG} + 0,47\text{CIVE} + 0,17\text{VEG} \quad (12)$$

Onde ExG é o *Excess Green Index* (Equação 3), CIVE é o *Color Index of Vegetation Extraction* (Equação 9) e VEG é o índice *Vegetative* (Equação 8), respectivamente.

Validando o *Combination* nos campos de milho, os autores afirmam que o método é capaz de identificar as plantas (daninhas ou não) mesmo com contaminação destas ao solo (mistura proveniente da soma de água mais solo) comumente observadas devido as chuvas e/ou irrigação artificial no período de plantio. A utilização do COM no período de pós colheita também é possível, visto a capacidade de monitoramento das ervas daninhas e áreas remanescentes. Sendo assim possível o acompanhamento do cultivo, por parte do gestor do território, através de imagens.

Discussões acerca do uso de drones e outros veículos não tripulados (VANTs) para o monitoramento de áreas agricultáveis fizeram Wang et al. (2015) estudarem as imagens provenientes destes e, baseando-se no NDVI, apresentarem o VDVI - (*Visible-band Difference Vegetation Index*), índice fundamentado pelas bandas RGB (Equação 13).

$$\text{VDVI} = \frac{(2 * \rho_g - \rho_r - \rho_b)}{(2 * \rho_g + \rho_r + \rho_b)} \quad (13)$$

Onde ρ corresponde a faixa espectral; g, r e b corresponde ao verde, vermelho e azul, respectivamente.

Os resultados do VDVI para imagens de VANT foram consideravelmente satisfatórios. Os autores encontraram através de um relatório de

precisão um índice acima de 90% de precisão. O índice de kappa, que classifica a confiabilidade e concordância de um algoritmo, por sua vez, alcançou números próximos aos de 0,82. Desta forma a aplicação do VDVI para drones e outros veículos não tripulados é amplamente recomendada. Todavia, necessita-se de mais trabalhos para maiores comparações e constatações.

Utilizando dados IAF/LAI - MOD09GA, Miranda (2017) em sua tese observou a necessidade da calibração destes elementos para região de Caatinga, bioma endêmico da região do nordeste do Brasil. Suas informações de campo para calibração foram obtidas através de uma torre meteorológica e instrumentos de medições especializados, mediante área de Caatinga preservada. Desta forma, o autor desenvolveu três equações, no qual duas destas estão exclusivamente no campo do visível (Equação 14, 15, 16).

$$IAF = -25,838(\sqrt{p_r} + p_b^2 - \sqrt{p_g}) + 2,354 \quad (14)$$

$$IAF = -0,2013 \left(e^{p_b} + \frac{\log_2 p_g}{\log_{10} p_r} \right) + 3,8408 \quad (15)$$

$$IAF = -3,8673 \left(\frac{p_r / \sqrt{p_{NIR}}}{\sqrt{p_g}} \right) + 4,3275 \quad (16)$$

Onde P_r , P_b , P_g e P_{NIR} são as bandas do vermelho, azul, verde e infravermelho próximo, respectivamente.

Os coeficientes de determinação (r^2) para as equações do IAF de Miranda (2017) (Equação 14, $r^2=0,75$; Equação 15, $r^2=0,73$; Equação 16, $r^2=0,75$) superam os coeficientes encontrados para outras equações na literatura para a mesma região de interesse quando processados para as imagens MOD09GA (IAF_{Galvício (2013)} $r^2 = 0,64$; IAF_{Machado (2014)} $r^2=0,65$; IAF_{Bastiaanssen (1998)} $r^2=0,59$). O autor recomenda dentre as três formulações, a equação 16 para aplicação nas imagens de satélite, principalmente nos produtos MODIS. A relação vermelho-verde-infravermelho próximo é o principal motivo da recomendação, devido a boa resposta do infravermelho próximo na detecção da vegetação. Ademais, a possibilidade de monitoramento das áreas foliares através de fórmulas que envolvem a conjectura RGB para o ambiente do bioma Caatinga eleva as perspectivas de cenários que estimulam a gestão eficiente, a agricultura de precisão, a preservação e a conservação.

Sumário de índices de vegetação

Todos os índices discutidos e levantados no trabalho podem ser encontrados na Tabela 2 junto as suas denominações, referências e estrutura de fórmula.

Tabela 2 – Sumário dos índices de vegetação.

Índice	Tipo*	Fórmula	Referência
Normalized Difference Vegetation Index	NIR	$NDVI = \frac{\rho_{NIR} - \rho_R}{\rho_{NIR} + \rho_R}$	Rouse et al. (1974)
Normalized Green Red Difference Index	RGB	$NGRDI = \frac{G - R}{G + R}$	Tucker (1979)
Soil-adjusted vegetation index	NIR	$SAVI = \frac{\rho_{NIR} - \rho_R}{(\rho_{NIR} + \rho_R + L)} * (1 + L)$	Huete (1988)
Redness Index	RGB	$RI = \frac{R - G}{R + G}$	Escadafal e Huete (1991)
Atmospherically Resistant Vegetation Index	NIR	$ARVI = \frac{(\rho_{NIR} - \rho_{rb})}{(\rho_{NIR} + \rho_{rb})}$	Kaufman e Tanre, (1992)
Excess Green Index	RGB	$ExG = 2G - R - B$	Woebbecke et al. (1995)
Green Atmospherically Resistant Index	NIR	$GARI = \frac{\{(\rho_{NIR} - [\rho_{green} - \lambda(\rho_{blue} - \rho_{red})])\}}{\{(\rho_{NIR} + [\rho_{green} - \lambda(\rho_{blue} - \rho_{red})])\}}$	Gitelson et al. (1996)

Normalized difference water index	NIR	$NDWI_{(McFeeters\ 1996)} = \frac{(\rho_g - \rho_{NIR})}{(\rho_g + \rho_{NIR})}$	McFeeters (1996)
Normalized difference water index	NIR	$NDWI_{(Gao,1996)} = \frac{(\rho_{NIR} - \rho_{SWIR})}{(\rho_{NIR} + \rho_{SWIR})}$	Gao (1996)
Excess Red Vegetative Index	RGB	$ExR = 1.4r - g$	Meyer et al. (1998)
IAF/LAI	NIR	$-\frac{\ln\left[\frac{(0,69 - SAVI)}{0,59}\right]}{0,91}$	Bastiaanssen (1998)
Ground Level Image Analysis	RGB	$GLI = \frac{((G - R) + (G - B))}{(G + R + G + B)}$	Louhaichi et al. (2001)
Ground Level Image Analysis	RGB	$GLI = \frac{(2R_g - R_r - R_b)}{(2R_g + R_r + R_b)}$	Hunt et al. (2011)
Visible Atmospherically Resistant Index	RGB	$VARI_{green} = \frac{(R_g - R_r)}{(R_g + R_r - R_b)}$	Gitelson et al. (2002)
Vegetative	RGB	$VEG = \frac{g}{r^a b^{(1-a)}}$	Marchant e Onyango (2002)
Color Index of Vegetation Extraction	RGB	$CIVE = 0,441 * R - 0,811 * G + 0,385 * B + 18,78745$	Kataoka et al. (2003)
Normalized Difference Built-up Index	NIR	$NDBI = \frac{(\rho_{SWIR} - \rho_{NIR})}{(\rho_{SWIR} + \rho_{NIR})}$	Zha et al. (2003)
Excess green minus Excess red	RGB	$ExGR = ExG - ExR$	Camargo-Neto (2004)
Modification of Normalized Difference Water Index	SWIR	$MNDWI = \frac{(\rho_g - \rho_{SWIR})}{(\rho_g + \rho_{SWIR})}$	Xu (2006)
Desert Flood Index	NIR	$DFI = \frac{(\rho_g - \rho_{SWIR} + 0.1)}{[(\rho_g + \rho_{SWIR}) \cdot (NDVI + 0.5)]}$	Wang (2007)
Triangular Greenness Index	RGB	$TGI = -0,5 [(\lambda r - \lambda b)(Rr - Rg) - (\lambda r - \lambda g)(Rr - Rb)]$	Hunt et al. (2011)
Combination	RGB	$COM = 0,36ExG + 0,47CIVE + 0,17VEG$	Guerrero et al. (2012)
IAF _{Galvıncio (2013)}	NIR	$IAF = e^{1,426 + \frac{-0,542}{NDVI}}$	Galvıncio et al. (2013)
IAF _{Machado (2014)}	NIR	$IAF = 0,102e^{5,341 * NDVI}$	Machado (2014)
Visible-band Difference Vegetation Index	RGB	$VDVI = \frac{(2 * \rho_g - \rho_r - \rho_b)}{(2 * \rho_g + \rho_r + \rho_b)}$	Wang et al. (2015)
IAF _{Miranda (2017)}	RGB	$IAF = -25,838(\sqrt{p_r} + p_b^2 - \sqrt{p_g}) + 2,354$	Miranda (2017)
IAF _{Miranda (2017)}	RGB	$IAF = -0,2013 \left(e^{p_b} + \frac{\log_2 p_g}{\log_{10} p_r} \right) + 3,8408$	Miranda (2017)

$$IAF_{\text{Miranda (2017)}} \quad \text{NIR} \quad IAF = -3,8673 \left(\frac{p_r / \sqrt{p_{\text{NIR}}}}{\sqrt{p_G}} \right) + 4,3275 \quad \text{Miranda (2017)}$$

*RGB = Índices que mantém as faixas RGB (vermelho, verde, azul); NIR = Índices que mantém relação com o infravermelho próximo; SWIR= Índices que mantém relação com o infravermelho médio.

4. Conclusões

Índices simples e complexos foram desenvolvidos e melhoraram em significância as análises do sensoriamento remoto ao longo dos anos. Essas melhorias trouxeram novas perspectivas que contribuíram diretamente para o estudo e monitoramento dos ecossistemas no geral, especialmente os ambientes de vegetação.

Constatou-se através dos índices pesquisados e da revisão de literatura realizada, que os índices de vegetação que utilizam a banda do visível (RGB) constituem-se de importantes ferramentas do sensoriamento remoto para monitoramento da vegetação. Isso se dá também pela adaptação dos índices a câmeras comerciais, estas isentas de sensores mais complexos que demandam elevado poder aquisitivo, permitindo uma maior difusão e aplicação para fins mais específicos.

Nos dias atuais, a partir dos lançamentos de satélites multiespectrais, hiperespectrais e de drones, novas necessidades e especificidades poderão surgir, logo, inéditos ajustes, combinações e o desenvolvimento de índices alternativos podem ser apresentados, ampliando desta forma, o sensoriamento remoto como pesquisa nas esferas micro e macro no globo.

Agradecimentos

Ao laboratório Análise e Processamento de Imagens APRIM/UFPE; laboratório de Sensoriamento Remoto e Geoprocessamento – SERGEO/UFPE; e ao Núcleo Avançado de Estudos do Meio Ambiente - NUVEM, pelo total apoio a pesquisa acadêmica. À Fundação de Amparo à Ciência e Tecnologia de Pernambuco – FACEPE pela bolsa cedida ao primeiro autor.

Referências

Alexakis, D.D., Grillakis, M.G., Koutroulis, A.G., Agapiou, A., Themistocleous, K., Tsanis, I.K., Michaelides, S., Pashiardis, S., Demetriou, C., Aristeidou, K., Retalis, A., Tymvios, F., Hadjimitsis, D.G., 2014. GIS and remote sensing

techniques for the assessment of land use change impact on flood hydrology: the case study of Yialias basin in Cyprus. *Natural Hazards and Earth System Sciences* 14, 413–426.

Alves, D.S., Skole, D.L., 1996. Characterizing land cover dynamics using multi-temporal imagery. *International Journal of Remote Sensing* 17, 835-839.

Atzberger, C., 2013. Advances in Remote Sensing of Agriculture: Context Description, Existing Operational Monitoring Systems and Major Information Needs. *Remote Sensing* 5, 949-981.

Barbosa, R.V.R., Vecchia, F.A.S., 2009. Estudos de ilha de calor urbana por meio de imagens do Landsat 7 ETM+: estudo de caso em São Carlos (SP). *Revista Minerva* 6, 273-278.

Batten, G.D., 1997. Plant analysis using near infrared reflectance spectroscopy: the potential and the limitations. *Australian Journal of Experimental Agriculture* 38, 697–706.

Bastiaanssen, W., 1998. Remote sensing in water resources management: the state of the art. IX ed. International Water Management Institute (IWMI), Colombo.

Bastiaanssen, W.G.M., Molden, D.J., Makin, I.W., 2000. Remote sensing for irrigated agriculture: examples from research and possible applications. *Agricultural Water Management* 46, 137-155.

Bolch, T., 2007. Climate change and glacier retreat in northern Tien Shan (Kazakhstan/Kyrgyzstan) using remote sensing data. *Global and Planetary Change* 56, 1–12.

Borges, M.H., Pfeifer, R.M., Demattê, J.A.M., 1993. Evolução e mapeamento do uso da terra, através de imagens aerofotogramétricas e orbitais em santa bárbara d'oeste (SP). *Scientia agrícola* 50, 365-371.

Burns, D.A., Ciurczak, E.W., 2007. *Handbook of Near-Infrared Analysis*, CRC Press.

Camargo-Neto, J. A., 2004. Combined Statistical—Soft Computing Approach for Classification and Mapping Weed Species in Minimum Tillage Systems. University of Nebraska, Lincoln.

Castro, A.I., Ehsani, R., Ploetz, R.C., Crane, J.H., Buchanon, S., 2015. Detection of Laurel Wilt Disease in Avocado Using Low Altitude Aerial

- Imaging. PLoS One 10. doi: 10.1371/journal.pone.0124642
- Chang, L., Peng-Sen, S., Shi-Rong, L., 2016. A review of plant spectral reflectance response to water physiological changes. *Chinese Journal of Plant Ecology* 40, 80–91.
- Chen, X.L., Zhao, H.M., Li, P.X., Yin, Z.Y., 2006. Remote sensing image-based analysis of the relationship between urban heat island and land use/cover changes. *Remote Sensing of Environment* 104, 133–146.
- Cui, W., Zheng, Z., Zhou, Q., Huang, J., Yuan, Y., 2018. Application of a parallel spectral–spatial convolution neural network in object oriented remote sensing land use classification. *Remote Sensing Letters* 9, 334–342.
- Cunha, John E. de B. L., Rufino, Iana A. A., Silva, Bernardo B. da., Chaves, Iêde de B., 2012. Dinâmica da cobertura vegetal para a Bacia de São João do Rio do Peixe, PB, utilizando-se sensoriamento remoto. *Revista Brasileira de Engenharia Agrícola e Ambiental* 16, 539–548.
- Dutta, D., Kundu, A., Patel, N.R., Saha, S.K., Siddiqui, A.R., 2015. Assessment of agricultural drought in Rajasthan (India) using remote sensing derived Vegetation Condition Index (VCI) and Standardized Precipitation Index (SPI). *The Egyptian Journal of Remote Sensing and Space Sciences* 18, 53–63.
- EEFLUX - Google Earth Engine Evapotranspiration Flux., 2015. What is EEFlux? *International Workshop on Evapotranspiration Mapping–Sept.*
- Epiphânio, J.C.N., Gleriani, J.M., Formaggio, A.R., Rudorff, B.F.T., 1996. Índices de vegetação no sensoriamento remoto da cultura do feijão. *Pesquisa Agropecuária Brasileira* 31, 445–454.
- Epiphânio, J.C.N., Vitorello, I., 1983. Áreas irrigadas: monitoramento por sensoriamento remoto. *Revista Irrigação e Tecnologia Moderna* 14, 20.
- Escadafal, R., Huete, A., 1991. Étude des propriétés spectrales des sols arides appliquée à l'amélioration des indices de végétation obtenus par télédétection. *Comptes Rendus de l'Académie des Sciences* 312, 1385–1391.
- Fallati, L., Savini, A., Sterlacchini, S., Galli, P., 2017. Land use and land cover (LULC) of the Republic of the Maldives: first national map and LULC change analysis using remote-sensing data. *Environmental Monitoring and Assessment* 189, 417.
- Figueiredo, D., 2005. Conceitos Básicos do Sensoriamento Remoto. Disponível: http://www.conab.gov.br/conabweb/download/SIG_ABRASIL/manuais/conceitos_sm.pdf. Acesso: 1 mar.2018.
- Federer, C.A., Tanner, C.B., 1966. Spectral distribution of light in the forest. *Ecology* 47, 555–560.
- Galvêncio, J.D., Moura, M.S.B., Silva, T.G., Silva, B.B., Naue, C.R., 2013. LAI Improved to Dry Forest in Semiarid of the Brazil. *International Journal of Remote Sensing Application* 3, 193.
- Gao, B.C., 1996. NDWI—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment* 58, 257–266.
- Gitelson, A., Kaufman, Y., Merzlyak, M., 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment* 58, 289–298.
- Gitelson, A.A., Kaufman, Y.J., Stark, R., Rundquist, D., 2002. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment* 80, 76–87.
- Goergen, Ç.L.C., Kilca, R.deV., Narvaes, I.daS., Silva, M.N., Silva, E.A., Pereira, R.S.P., Adami, M., 2016. Distinção de espécies de eucalipto de diferentes idades por meio de imagens TM/Landsat 5. *Pesquisa Agropecuária Brasileira* 51, 53–60.
- Grecchi, R.C., Bertani, G., Trabaquini, K., Shimabukuro, Y.E., Formaggio, A.R., 2016. Análise espaço-temporal da conversão do cerrado em áreas agrícolas na região de sapezal, mato grosso, entre os anos de 1981 e 2011. *Revista Brasileira de Cartografia* 68, 91–107.
- Guerrero, J.M., Pajares, G., Montalvo, M., Romeo, J., Guijarro, M., 2012. Support vector machines for crop/weeds identification in maize fields. *Expert Systems with Applications* 39, 11149–11155.
- Ha, L.T., Bastiaanssen, W.G.M., Griensven, A., Dijk, A.I.J.M., Senay, G.B., 2017. SWAT-CUP for Calibration of Spatially Distributed Hydrological Processes and Ecosystem Services in a Vietnamese River Basin Using Remote Sensing. *Hydrol. Earth Syst. Sci. Discuss (Manuscript under review for journal Hydrol. Earth Syst. Sci.)*.
- Hague, T., Tillett, N.D., Wheeler, H., 2006. Automated crop and weed monitoring in widely spaced cereals. *Precision Agriculture* 7, 21–32.
- Herman, M.R., Nejadhashemi, A.P., Abouali, M., Hernandez-Suarez, J.S., Daneshvar, F., Zhang, Z., Anderson, M.C., Sadeghi, A.M., Hain, C.R., Sharifi, A., 2018. Evaluating the role of evapotranspiration remote sensing data in improving hydrological modeling predictability. *Journal of Hydrology* 556, 39 – 49.

- Huete, A.R., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* 25, 295–309.
- Hunt, E.R., Daughtry, C.S.T., Eitel, J.U.H., Long, D.S., 2011. Remote sensing leaf chlorophyll content using a visible band index. *Agronomy Journal* 103, 1090–1099.
- Iglesias, M.E.D., Gómez, A.M.M., 2004. Análisis documental y de información: dos componentes de un mismo proceso. *ACIMED* 12, 1-5.
- Jordan, C.F., 1969. Derivation of leaf-area index from quality of light on the forest floor. *Jordan Source: Ecology* 50, 663-666.
- Kataoka, T., Kaneko, T., Okamoto, H., Hata, S., 2003. Crop growth estimation system using machine vision. *IEEE/ASME International Conference on Advanced Intelligent Mechatronics*.
- Kaufman, Y.J., Tanre, D., 1992. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing* 30, 261–270.
- Khan, A.A., Muhammad, J., Khan, G.D., Ijaz, M., Adnan, M., 2016. Quantitative Analysis of Watershed Hydrology for Kandar Dam (Kohat) using Remote Sensing and Geographic Information System (GIS) Techniques. *Pakistan Journal of Meteorology* 12.
- Li, Y., Zhou, Q., Zhou, J., Zhang, G., Chen, C., Wang, J., 2014. Assimilating remote sensing information into a coupled hydrology-crop growth model to estimate regional maize yield in arid regions. *Ecological Modelling* 291, 15–27.
- Louhaichi, M., Borman, M.M., Johnson, D.E., 2001. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. *Geocarto International* 16, 65–70.
- Machado, C.C.C., 2014. Alterações na superfície do Parque Nacional do Catimbau (PE-Brasil): consolidação dos aspectos biofísicos na definição dos indicadores ambientais do bioma Caatinga. Tese (Doutorado). Recife, UFPE.
- Marchant, J.A., Onyango, C.M., 2002. Shadow-invariant classification for scenes illuminated by daylight. *Journal of the Optical Society of America* 17, 1952–1961.
- Mcfeeters, S.K., 1996. The use of normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing* 17, 1425–1432.
- Meneses, P.R., Almeida, T., 2012. Introdução ao Processamento de Imagens de Sensoriamento Remoto. Universidade de Brasília, Brasília.
- Menke, A.B., Carvalho Junior, O.A.deC., Gomes, R.A.T., Martins, E.deS., Oliveira, S.N.de., 2009. Análise das mudanças do uso agrícola da terra a partir de dados de sensoriamento remoto multitemporal no Município de Luís Eduardo Magalhães (BA – Brasil). *Sociedade & Natureza* 21, 315-326.
- Meyer, G.E., Camargo-Neto, J., 2008. Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture* 63, 282-293.
- Meyer, G.E., Hindman, T.W., Lakshmi, K., 1998. Machine vision detection parameters for plant species identification, in: Meyer, G.E., DeShazer, J.A. (Eds.), *Precision Agriculture and Biological Quality* 3543, 327–335.
- Miranda, R.Q., 2017. Avaliação integrada da variação espacial e temporal do balanço hídrico na Caatinga. Tese (Doutorado). Recife, UFPE.
- Mohan, M., Kandy, A., 2015. Impact of urbanization and land-use/land-cover change on diurnal temperature range: A case study of tropical urban airshed of India using remote sensing data. *Science of the Total Environment* 506-507, 453–465.
- Moraes, M., Freire, G., Manso, V., Costa, S., 2016. Variações temporais da linha de costa do município de Acaraú – Ceará – Brasil (Multi-temporal analysis of Coastline of Acaraú - Ceará – Brasil). *Revista Brasileira de Geografia Física* 8, 981-989.
- Mulla, D.J., 2013. Twenty five years of remote sensing in precision agriculture: key advances and remaining knowledge gaps. *Biosystems Engineering* 114, 358–371.
- Picón-Feliciano, A. J., Vásquez, R., González, J., Luvall, J., Rickman, D., 2009. Use of Remote Sensing Observations to Study the Urban Climate on Tropical Coastal Cities. *Revista Umbral* 1, 218-232.
- Pohl, E., Gloaguen, R., Seiler, R., 2015. Remote sensing based assessment of the variability of winter and summer precipitation in the Pamirs and their effects on hydrology and hazards using harmonic time series analysis. *Remote Sensing* 7, 9727-9752.
- Ponti, M., 2013. Segmentation of Low-Cost Remote Sensing Images Combining Vegetation Indices and Mean Shift. *Geoscience and Remote Sensing Letters* 10, 67-70.
- Rawat, J.S., Kumar, M., 2015. Monitoring land use/cover change using remote sensing and GIS techniques: A case study of Hawalbagh block, district Almora, Uttarakhand, India. *The Egyptian Journal of Remote Sensing and Space Sciences* 18, 77–84.

- Rokhmana, C.A., 2015. The potential of UAV-based remote sensing for supporting precision agriculture in Indonesia. *Procedia Environmental Sciences* 24, 245–253.
- Rosa, H.J.A., Amaral, L.R.do., Molin, J.P., Cantarella, H., 2015. Sugarcane response to nitrogen rates, measured by a canopy reflectance sensor. *Pesquisa Agropecuária Brasileira* 50, 840-848.
- Rouse, J.W., 1974. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. *Texas A&M University Remote Sensing Center College Station Texas 77843. Type I Progress Report-Number 7.*
- Rouse, J.W., Haas, R.H., Schell, J.A., Deering, D.W., 1974. Monitoring vegetation systems in the Great Plains with ERTS, in: Freden, S.C., Mercanti, E.P., Becker, M. (Eds.), *Third Earth Resources Technology Satellite-1 Symposium. Technical Presentations, NASA SP-351. National Aeronautics and Space Administration, Washington.*
- Santos, A.R., 2013. *Apostila de Sensoriamento Remoto. Universidade Federal do Espírito Santo, Alegre.*
- Silva, B.B., Braga, A.C., Braga, C.C., Oliveira, L.M., Galvêncio, J.D., Montenegro, S.M.G.L., 2012. Evapotranspiração e estimativa da água consumida em perímetro irrigado do Semiárido brasileiro por sensoriamento remoto. *Pesquisa Agropecuária Brasileira* 47, 1218-1226.
- Silva, J.F., Ferreira, P.S., Gomes, V.P., Silva, E. R.A.C., Galvêncio, J.D., 2015. Climatic potential of pineapple fruit growing mapping in the micro region of Araripina - PE. *Revista Brasileira de Geografia Física* 8, 196-210.
- Srestasathirn, P., Rakwatin, P., 2014. Oil palm tree detection with high resolution multi-spectral satellite imagery. *Remote Sensing* 6, 9749-9774.
- Steele-Dunne, S., Mcnairn, H., Monsivais-Huertero, A., Judge, J., Liu, P.W., Papathanassiou, K., 2017. Radar remote sensing of agricultural canopies: a review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 2249-2273. doi.org/10.1109/JSTARS.2016.2639043
- Stow, D. A., Hope, A., Mcguire, D., Verbyla, D., Gamon, J. A., Huemrich, R., 2004. Remote sensing of vegetation and land-cover change in arctic tundra ecosystems. *Remote Sensing of Environment* 89, 281–308.
- Torres-Sánchez, J.J.M., Peña, A.I.C., Lopez- Granados, F., 2014. Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture* 103, 104–113.
- Tucker, C.J., 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* 8, 127–150.
- Tucker, C.J., Maxwell, E.L., 1976. Sensor design for monitoring vegetation Canopies. *Photogrammetric Engineering and Remote Sensing* 42, 1399-1410.
- Wang, S., 2007. *The Quantitative research on dynamic changes between flood and vegetation in Tarim river valley. Thesis (PhD). Beijing Normal University.*
- Wang, X., Wang, M., Wang, S., Wu, Y., 2015. Extraction of vegetation information from visible unmanned aerial vehicle images. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering* 31, 152–159.
- Weng, Q., 2002. Land use change analysis in the Zhujiang Delta of China using satellite remote sensing, GIS and stochastic modelling. *Journal of Environmental Management* 64, 273–284.
- Woebbecke, D.M., Meyer, G.E., Von Bargen, K., Mortensen, D.A., 1995. Color indices for weed identification under various soil, residue and lighting conditions. *Transactions of the ASAE* 38, 259–269.
- Xiao, J.Y., Shen, Y.J., Ge, J.F., Tateishi, R., Tang, C.Y., Liang, Y.Q., 2006. Evaluating urban expansion and land use change in Shijiazhuang, China, by using GIS and remote sensing. *Landscape and Urban Planning* 75, 69–80.
- Xu, H., 2006. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing* 27, 3025–3033.
- Xue, J., Su, B., 2017. Significant remote sensing vegetation indices: a review of developments and applications. *Journal of Sensors* 17. doi: <https://doi.org/10.1155/2017/1353691>
- Yang, J., Gong, P., Fu, R., Zhang, M., Chen, J., Liang, S., Xu, B., Shi, J., Dickinson, R., 2013. The role of satellite remote sensing in climate change studies. *Nature Climate Change* 3, 875–883.
- Zha, Y., Gao, J., Ni, S., 2003. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International Journal of Remote Sensing* 24, 583–594.