

Introdução – Caracterização do tema

Em vista da necessidade de obter mais informações precisas sobre o meio agrícola, urbano e do meio ambiente, o desenvolvimento de técnicas para um mapeamento em larga escala resultou no uso de sensores remotos que permitem estimar potencialmente componentes da produção vegetal (Barros et al., 2021), planejamento e infraestrutura civil (Ayala et al., 2021) e conservação do meio (Jensen, 2009). A partir da radiação eletromagnética refletida coletada por estes sensores remotos (imageadores e não imageadores), é possível adquirir informações relacionadas aos meios: 1- Agricultura (tipo de cultura, condições fenológicas ou nutricionais da cultura e produtividade, ocorrência de doenças e pragas); 2- Urbano (cadastramento imobiliário, mapeamento de redes elétricas e de rodovias); 3-Ambiental (detecção de áreas de supressão vegetal e desmatamento; identificação de queimadas e estudos geológicos).

Existem, no entanto, diversas dificuldades que envolvem o processo de derivar informações úteis a partir de imagens de Sensoriamento Remoto. Um dos complicadores é a heterogeneidade de paisagens dos ambientes tropicais que, conseqüentemente, aumenta a complexidade das cenas retratadas nas imagens, em termos de elementos registrados. Essa complexidade, por sua vez, aumenta a confusão espectral entre os diferentes tipos de cobertura da terra com respostas espectrais semelhantes, como é o caso das áreas cobertas culturas agrícolas e por remanescentes de vegetação nativa, ou até mesmo regiões de solo exposto com manchas urbanas (Canty, 2019).

Dada a variabilidade das classes espectrais, para aumento da acurácia do mapeamento de classificações, atualmente, técnicas avançadas de aprendizagem de máquinas têm sido empregadas com o objetivo de desenvolver modelos, utilizando diferentes variáveis, com a capacidade de relacionar a radiometria de imagens a classes de informações de variáveis da superfície física. Estas técnicas associadas a dados adquiridos por sensores remotos, tem abrangido estudos em diversas perspectivas no monitoramento e estimativas de parâmetros agrônômicos, urbanísticos e ambientais. Como exemplo, em diversos estudos, algoritmos de aprendizagem de máquina, como Redes Neurais Artificiais (RNAs), Máquinas Vetor de Suporte (MVS), Florestas Aleatórias (FAs), mostraram bons resultados na acurácia do mapeamento de culturas agrícolas e variáveis ambientais. Alguns estudos também têm incorporado variáveis geométricas e texturais para auxiliar o mapeamento de áreas agrícolas e áreas urbanas, onde estas variáveis são eficientes para distinguir culturas e feições de outros tipos de uso da terra (Vali et al., 2020).

Dinâmica dos principais algoritmos de aprendizado de máquinas aplicado a classificação de dados radiométricos – Classificação de Imagens

O processo de classificação é definido pela associação de um rótulo (Classe de Informação ou espectral) a cada pixel ou conjuntos de pixels da imagem. Assim, a classificação busca interpretar uma imagem, detectando os padrões contidos nela. A

classificação divide-se em dois tipos principais: supervisionada e não-supervisionada. Na classificação supervisionada, o algoritmo utiliza exemplos de treinamento previamente rotulados para aprender a distinguir as classes. Depois, o classificador associa cada pixel a uma das classes designadas na fase de treinamento. Dentre os principais algoritmos de classificação supervisionadas não paramétricos, têm-se: RNAs, MVS e RFs.

As RNAs são formadas por uma camada de entrada, camada de saída e uma ou mais camadas ocultas, denominadas de unidades setoriais ou neurônios, por onde o sinal de entrada percorre, camada por camada. Redes neurais deste tipo utilizam um algoritmo baseado em regra de retropropagação de erro, conhecido como algoritmo de retropropagação de erro, ou error back-propagation.

Em casos onde as RNAs possuem muitas camadas de neurônios, o processo de treinamento e ajuste da rede é chamado aprendizado profundo, ou seja, nesses casos têm-se a Rede Neural Convolucional (RNC), a qual é um tipo específico de rede de aprendizado profundo que tem sido muito eficaz na detecção de objetos, reconhecimento visual e classificação de imagens. As RNCs aprendem conceitos complexos dividindo-os hierarquicamente em componentes simples. Dessa forma, uma RNC pode aprender características altamente abstratas através de suas camadas. A extração de características é feita a partir de camadas convolucionais, camadas de ativação e de amostragem máxima de recursos, campos receptivos locais e compartilhamento de pesos entre neurônios.

Especificamente para processo de classificação de imagens, a RNC aproveita-se das características intrínsecas de uma imagem (valores radiométricos e quantitativos de índices derivados) ao mesmo tempo em que reduz a complexidade e redundância dos dados. A vantagem do processo é que o custo computacional diminui, o que torna as RNCs aplicáveis.

O algoritmo de MVS se baseia na minimização de erros estruturais. Este algoritmo objetiva criar, a partir de um conjunto de dados, um hiperplano de espaçamento equidistante dos dados mais próximos de cada classe para atingir uma margem máxima em cada lado do hiperplano, sendo considerado para cada hiperplano, apenas os dados de treinamento de cada classe que se enquadram na borda dessas margens. Os dados são denominados de vetores de suporte.

O algoritmo RF permite a modelagem de dados com flexibilidade de interações em altas dimensões, construindo um grande número de árvores de regressão e calcular as médias de suas previsões. Seus processamentos utilizam kernels e métodos de vizinho mais próximo, pois fazem ponderações de previsões fundamentadas na média ponderada de observações próximas, porém, diferente de outros métodos, o algoritmo se baseia em dados para determinar quais observações próximas receberão mais peso. Em contrapartida as RNAs e MVS, as pesquisas em sensoriamento remoto com uso de FAs mostram que o algoritmo é mais intuitivo, não sofre sobreajuste, tem estimativas de erro enviesada, possui processamento mais rápido, e é capaz de fazer diferentes análises em grandes conjuntos de dados, de forma mais eficiente (Vali et al., 2020).

Aplicação em Atividades Agrícolas

Nos últimos anos, o uso do sensoriamento remoto tornou-se imprescindível no monitoramento agrícola, principalmente por propiciar o acompanhamento e o desenvolvimento da cultura ao longo do tempo, previsão de safra, determinação de novas áreas de cultivo, determinação da quantidade e da localização da área cultivada, entre outras possibilidades, como, uma forma alternativa para identificação de áreas agrícolas afetadas por patógenos.

A integração de diferentes tipos de dados de sensoriamento remoto obtidos em multiescala, com vistas ao monitoramento e mapeamento de culturas agrícolas infectadas por parasitas encontra-se em constante avanço. Isso ocorre devido à grande quantidade de dados obtidos por intermédio de plataformas terrestres, aeronaves e orbitais, disponibilizando produtos radiométricos oriundos de fontes diversas. Assim, a partir de informações agronômicas e de sensores é possível automatizar o processamento e a classificação de dados relativos à variável em campo com técnicas de aprendizado de máquina (Barros et al., 2021).

Aplicações em Meio Urbano

Um dos desafios do Sensoriamento Remoto e da Fotogrametria é extração automática de elementos que compõem a paisagem urbana através do processamento digital de imagens. Os edifícios e vias urbanas são uma parte essencial da paisagem e são elementos básicos da infraestrutura humana, onde a detecção automática de telhados e estradas é um tema em constante estudo. Mapear variáveis urbanas de forma adequada possibilita análises espaciais socioeconômicas, auxilia no planejamento urbano e no desenvolvimento sustentável, além de permitir a atualização periódica de dados cadastrais, a criação de modelos digitais, entre outras aplicações (Jensen, 2000).

Para que seja possível realizar os processamentos referentes à detecção e classificação de telhados e estradas em ambientes urbanos, primeiro deve-se tratar a imagem (multi/hiperespectral) utilizando procedimentos de processamento digital de imagens (PDI). Os principais procedimentos são: calibração radiométrica, correção atmosférica, realce, transformação e classificação. As correções podem ser direcionadas a degradações atmosféricas ou a distorções planimétricas. O realce busca melhorar a qualidade visual das imagens, facilitando a discriminação entre objetos, enquanto a transformação procura derivar novas imagens através do tratamento matemático de uma imagem bruta transformado em índices de vegetação espectrais.

Em (Ayala et al., 2021) foi utilizada uma segmentação semântica baseada em CNN, chamada de Fully Convolutional Network (FCN), com dados do Sentinel 1 e 2 (SAR, RGB + IR). Para a verdade em campo (ruas e edifícios), foram utilizadas as feições do Open Street Map e os resultados mostraram a viabilidade do mapeamento dessas feições (ruas e prédios) com Deep Learning.

Referências

AYALA, C.; SESMA, R.; ARANDA, C.; GALAR, M. A Deep Learning Approach to an Enhanced Building Footprint and Road Detection in High-Resolution Satellite Imagery. *Remote Sens.* 2021, 13(16), 3135

BARROS, P. P. DA S.; ROSALEN, D. L.; IOST FILHO, F. H.; MARTINS, G. D.; DI LEO, N. Monitoring Plant Health Using Remote Sensing: Advances and Challenges. *Revista Brasileira de Cartografia*, v. 73, n. 2, p. 489-515, 6 Apr. 2021.

CANTY, M. J. Image analysis, classification and change detection in remote sensing: with algorithms for Python. CRC Press/Taylor & Francis Group, 2019.

JENSEN, J.R. Remote Sensing of the Environment: An Earth Resource Perspective. New Jersey: Prentice HALL, 2000. 544p.

VALI, A.; COMAI, S.; MATTEUCCI, M. Deep Learning for Land Use and Land Cover Classification Based on Hyperspectral and Multispectral Earth Observation Data: A Review. *Remote Sensing*, vol. 12, n. 15, 2020.