



ISSN:1984-2295

Revista Brasileira de Geografia Física

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



Classificação de Imagens hiperespectrais utilizando redes neurais convolucionais para caracterização da ocupação desordenada do solo sobre um recorte do Parque Nacional da Tijuca, RJ

Italo Guimarães do Vale¹, Angel Ramon Sanchez Delgado², Robson Mariano Silva³

¹Doutorando do Programa de Pós-graduação em Ciência, Tecnologia e Inovação em Agropecuária da Universidade Federal Rural do Rio de Janeiro, BR 465, Km 7, Seropédica, RJ, CEP RJ, 23890-000. italovale@ufrj.br (autor correspondente). ²Professor Titular do Departamento de Matemática do Instituto de Ciências Exatas da Universidade Federal Rural do Rio de Janeiro, BR 465, Km 7, Seropédica, RJ, 23890-000. a.sanchez@ufrj.br. ³Professor Adjunto do Departamento de Matemática do Instituto de Ciências Exatas da Universidade Federal Rural do Rio de Janeiro, BR 465, Km 7, Seropédica, RJ, 23890-000. robsonms@ufrj.br.

Artigo recebido em 15/06/2021 e aceito em 03/02/2022

RESUMO

O Parque Nacional da Tijuca (PNT) é uma área florestal localizada no município do Rio de Janeiro, no Estado do Rio de Janeiro sendo um importante fragmento do domínio da Mata Atlântica, presta diversos serviços ambientais tais como proteção do solo por erosão evitada e captura de carbono por desmatamento evitado, além de ser uma importante área para pesquisas ambientais. O PNT é dividido em quatro setores: Setor Floresta da Tijuca, Pedra Bonita/Pedra da Gávea, Pretos Forros/Covanca e Serra da Carioca. Para este estudo foi utilizado um recorte de uma cena, de uma imagem hiperespectral do sensor Hyperion sobre o setor Serra da Carioca e uma área urbana sobre o bairro de Botafogo buscando caracterizar as coberturas florestais e urbanas, objetos da pesquisa. Este estudo teve como objetivo: Aplicar uma metodologia baseada em Redes Neurais Convolucionais (RNCs) e algoritmos de aprendizado profundo na implementação de um modelo computacional para classificação de imagens hiperespectrais por reconhecimento de padrões para mapeamento da cobertura e uso da terra. Os resultados alcançados pelas configurações utilizadas nas RNCs mostraram que o emprego da abordagem sem aumento de dados alcançou 0,88 de acurácia geral enquanto que a abordagem com aumento de dados alcançou 0,92 de acurácia geral. Logo, pode-se concluir que o emprego de RNCs e algoritmos de aprendizado profundo na classificação de imagens hiperespectrais podem ser amplamente utilizados no mapeamento da cobertura e uso da terra com a finalidade de monitoramento de ocupações desordenadas da terra, sobre tudo em locais de difícil acesso como o PNT.

Palavras-chave: Imagens hiperespectrais. Redes Neurais Convolucionais. Uso e ocupação do solo.

Classification of hyperspectral images using convolutional neural networks to characterize disorganized soil occupation on a Cutting of Tijuca National Park, RJ

ABSTRACT

Tijuca National Park (TNP) is a forest area located in the municipality of Rio de Janeiro, in the State of Rio de Janeiro, being an important fragment of the Atlantic Forest domain, it provides several environmental services such as soil protection by avoided erosion and carbon capture through avoided deforestation, in addition to being an important area for environmental research. The PNT is divided into four sectors: Tijuca Forest Sector, Pedra Bonita/Pedra da Gávea, Pretos Forros/Covanca and Serra da Carioca. For this study, a cut-out of a scene was used, of a hyperspectral image of the Hyperion sensor over the Serra da Carioca sector and an urban area over the Botafogo neighborhood, seeking to characterize forest and urban

coverings, objects of the research. This study aimed to: Apply a methodology based on Convolutional Neural Networks (CNNs) and deep learning algorithms in the implementation of a computational model for classification of hyperspectral images by pattern recognition for mapping the coverage and use of land. The results achieved configurations in the CNNs by which the use of the approach without data increase reached 0.88 general accuracy while the approach with data increase reached 0.92 general accuracy. Therefore, it CNNs be demanded that the use of CNNs and deep learning algorithms utilization in the classification of hyperspectral images can be used in the mapping of land cover and use with a high monitoring of disordered land occupations, above all in places of difficult access like the TNP.

Keywords: Hyperspectral images. Convolutional Neural Networks. Soil use and occupation.

Introdução

Entre os anos de 2016 e 2018, cerca de 1% do território brasileiro sofreu alguma mudança na cobertura e uso da terra. De maneira geral, prossegue a substituição das áreas de vegetação natural por áreas antrópicas e o avanço das áreas agrícolas sobre áreas de pastagem. O processo de perda da cobertura natural já ocasionou a redução de 7,6% da área de vegetação florestal e de 10% da vegetação campestre entre 2000 e 2018 (IBGE, 2020).

No Ano de 2019 a fundação SOS Mata Atlântica e Instituto Nacional de Pesquisas Espaciais (INPE) realizaram um levantamento sobre o total de desflorestamento identificado nas áreas dos 17 Estados da Mata Atlântica no período 2018 a 2019 foi de 14.502 hectares (ha). Comparando a supressão da floresta nativa nos mesmos 17 estados mapeados no período 2017 a 2018, houve aumento de 27,2% na taxa de desmatamento (FUNDAÇÃO SOS MATA ATLÂNTICA, 2020; IBGE, 2020).

Segundo Salles et al. (2013) com o processo de dominação, expansão e urbanização, o homem transformou e transforma ambientes naturais, para criar os ambientes artificiais, ou seja, o meio ambiente urbano, para o atendimento das suas necessidades como ser social. Com isso temos a importância de estudar, conceituar e caracterizar as relações do ambiente urbano, para que se possa contribuir para a discussão da melhoria da qualidade de vida dentro das aglomerações urbanas e dos problemas socioeconômicos e ambientais existentes. A ocupação da terra de maneira ordenada e planejada é de extrema importância para a preservação dos recursos naturais e para o desenvolvimento sustentável.

O Brasil passou nas últimas seis décadas por um processo intenso e descontrolado de urbanização, provocado em grande medida pela industrialização e pelo êxodo rural, isso provou diversos problemas sócias e ambientais em todo território nacional (Crispin et al., 2014).

Conforme Lee et al. (2015) o mapeamento da cobertura do solo fornece informações para gestão e planejamento da conservação de recursos naturais e serviços ambientais, além da avaliação de agentes induzidos por humanos e por causas naturais de mudanças na terra. Os impactos sociais de classificar com precisão as áreas de terra se estendem ao monitoramento urbano, à observação fisiológica funcional e mudanças sazonais dentro de uma paisagem.

A classificação da cobertura do solo é uma das tarefas mais comuns para aplicações de sensoriamento remoto e o desenvolvimento de

estratégias de classificação adequadas é pesquisa contínua nesse campo. Neste contexto as Imagens Hiperespectrais (IHS) são provavelmente as mais valiosas, bem como a única. Sensores hiperespectrais fornecem informações espectrais espacialmente contínua e detalhada, permitindo a discriminação entre as classes de cobertura do solo espectralmente parecidas (Roscher, 2016).

Neste sentido uma alternativa que vem tornando-se cada vez mais viável é a utilização de tecnologias livres em conjunto com técnicas de aprendizado profundo e o uso das Redes Neurais Convolucionais (RNCs) no auxílio à classificação de diferentes tipos de classes de paisagens por reconhecimento de padrões.

O aprendizado profundo permite que modelos computacionais compostos por várias camadas de processamento aprendam representações de dados com vários níveis de abstração. Esses métodos melhoraram drasticamente o estado da arte em reconhecimento de fala, reconhecimento de objeto visual, detecção de objeto e muitos outros domínios (Lecun et al., 2015).

As RNCs em conjunto com as IHS têm sido utilizadas em um grande número de pesquisas na área de classificação do uso e cobertura da terra, utilizando diferentes abordagens com emprego de variáveis espaciais e espectrais (Vithana et al., 2017; Windrin et al., 2018; Kumar et al., 2019; Kayet et al., 2019).

Guidici e Clark (2017) propôs uma arquitetura de RNC utilizada para classificar uma única cena para três estações climáticas distintas (primavera, verão, outono) de imagens hiperespectrais sobre a área da baía de São Francisco, Califórnia, no ano de 2015. A RNC forneceu uma precisão geral de classificação de 89,9%, que foi comparável à precisão geral de 89,5% para Máquina de Vetores de Suporte *Support Vector Machine* (SVM).

Kayet et al. (2019) avaliaram a saúde florestal para planejamento e gestão geoambiental em áreas de mineração em topo de morro usando dados dos sensores *Hyperion* e *Landsat*, submetendo estes dados em uma RNC e obtiveram uma precisão de geral de 81,52% e estatística kappa 0,79, maior do que a do Mapeador de Ângulo Espectral (*Spectral Angle Mapper*) com uma precisão geral 79,99%, estatística kappa 0,75, bem como SVM com precisão geral 76,53%, kappa estatística 0,71.

Chen et al. (2019) utilizaram um modelo para a classificação de IHS, mais especificamente um modelo híbrido que combinava duas arquiteturas convolucionais, uma unidimensional e uma tridimensional de maneira automática, usando

informações espectrais e espaciais de quatro conjuntos de dados hiperespectrais amplamente usados (Salinas, Pavia University, Kennedy Space Center e Indiana Pines) e obtiveram uma acurácia geral superior 90% em todos os conjuntos de dados.

Portanto o objetivo deste estudo foi aplicar uma RNC e um algoritmo de aprendizado profundo na implementação de um modelo computacional para classificação de imagens por reconhecimento de padrões, para o mapeamento da cobertura e uso da terra, de um recorte de uma cena do sensor hiperespectral Hyperion a bordo do satélite *Earth Observing-1* (EO-1) sobre o Parque Nacional da Tijuca (PNT) visando caracterizar a ocupação desordenada da terra.

Material e métodos

Área de estudo

O PNT é uma área de florestal localizada no município do Rio de Janeiro, no Estado do Rio de Janeiro - Brasil. É um importante fragmento do domínio da Mata Atlântica, coberto por floresta ombrófila densa secundária em avançado estágio de regeneração (ICMbio, 2008).

O PNT contém um fragmento florestal de Mata Atlântica, inserido na zona urbana da cidade do Rio de Janeiro e presta diversos serviços ambientais tais como proteção do solo por erosão evitada e captura de carbono por desmatamento (Coelho, 2016).

O PNT é dividido em quatro setores: Setor Floresta da Tijuca, Pedra Bonita/Pedra da Gávea, Pretos Forros/Covanca e Serra da Carioca. Contudo para o presente trabalho foi utilizado um recorte sobre o setor Serra da carioca e uma área urbana sobre o bairro de Botafogo, buscando caracterizar as coberturas florestais e urbanas, objetos do estudo (Figura 1).

Imagens orbitais

Foram utilizadas duas cenas de imagens orbitais dos satélites Hyperion- OE-1, lançado em novembro de 2020 como parte do projeto NASA's *New Millennium Program* (NMP) da Agência Espacial Norte-americana (NASA). O sensor Hyperion representou por anos umas das fontes de imagens hiperespectrais mais utilizadas em pesquisas de SR com IHS (Silva et al., 2015; Liu et al., 2015; Kumar et al., 2019).




Figura 1. Área de estudo (A) Cena do sensor Hyperion - EO-1 de 26 de fevereiro 2014. (B) Localização do setor Serra da Carioca no PNT. (C) Recorte sobre o setor Serra da carioca e uma área urbana sobre o bairro de Botafogo.

As imagens do sensor *Hyperion* foram tomadas às 12 horas, 04 minutos e 08 segundos do dia 26 de fevereiro 2014 que foram adquiridas através do *site* do Serviço de Geologia dos Estados Unidos (USGS) nos formatos georreferenciado (1GST) e radiometricamente corrigido (L1R), cada imagem possui 242 bandas, nos comprimentos de onda de 356 nm a 2577 nm e sua resolução espacial é de 30 metros, com largura de 7,5 km por 100 km.

A metodologia empregada neste estudo foi realizada em quatro fases distintas (Figura 2) a abordagem proposta teve o objetivo de classificar imagens hiperespectrais oriundas do sensor Hyperion por meio de uma RNC, que e teve sua arquitetura implementada usando técnicas de aprendizagem profunda. Esta rede foi treinada para classificar, mais precisamente os espectros que são obtidos para cada *pixel* da imagem a, os resultados

obtidos após a classificação foram comparados a uma imagem de referência denominada mapa de referência, com a finalidade de avaliar o desempenho do modelo proposto.

Na primeira fase os dados de imageamento foram adquiridos por adquiridos através do *site* do USGS nos formatos georreferenciado (1GST) e radiométricamente corrigido (L1R).

Na segunda fase imagens passaram pelas seguintes correções: remoção de bandas anômalas, correção atmosférica, correção geométrica, redução de ruídos e por fim foram normalizadas. Todas as etapas de pré-processamento foram feitas com o auxílio do *software* ENVI versão 5.1.

Na terceira fase a RNC, foi implementada e os dados corrigidos, padronizados e normalizados na fase anterior foram submetidos a ela, estes dados foram divididos em duas partes, o conjunto de

treinamento e validação e conjunto de teste, para as duas classes definidas, floresta e urbano, a implementação contou com duas abordagens distintas em relação ao conjunto de treinamento, que teve o seu número de amostras ampliado através de da técnica de regularização de aumento de dados.

Na quarta fase os gráficos de treinamento foram interpretados e os mapas de classificação foram gerados, com a finalidade de avaliar os resultados alcançados pelo modelo. Por fim métricas como a matriz de confusão, a acurácia geral, a precisão, a revocação ou sensibilidade e a *F-score* foram utilizadas para medir o desempenho do modelo proposto.

Anotação do conjunto de dados




Figura 2 – Organograma de sequência de fases da abordagem proposta

Esta etapa consistiu na criação do mapa de referência e na anotação do conjunto de dados. Em primeiro lugar foi feito um recorte da região de interesse (ROI) da imagem no formato radiométricamente corrigida (L1R) sobre a Serra da Carioca pertencente ao PNT e uma área urbana sobre o bairro de Botafogo, com o objetivo de caracterização das classes, pois a cobertura florestal e a urbana estão uma ao lado da outra neste recorte da imagem e da diminuição dos custos computacionais devido à diminuição da área total

da imagem.

Com dimensão 20 *pixels* de altura x 60 *pixels* de comprimento totalizando 1.200 *pixels*, como de cada *pixel* se extraiu um espectro tivemos 1.200 espectros, que foram categorizados em duas classes anotadas manualmente: floresta com 799 *pixels* e urbano com 401 *pixels*.

O mapa de referência foi obtido usando o método de extração de características baseado em objeto através do módulo *Feature Extraction* do *software* e depois corrigido manualmente para as classes adequadas (Figura 3).



Figura 3. Mapa de referência em cor verdadeira (à esquerda) mapa de referência para a classe floresta (meio) e para classe urbano (direita).

A extração de características baseado em objeto é uma metodologia de classificação por segmentação orientada ao objeto para extração de alvos de interesse, sendo aplicado em métodos supervisionados e não supervisionados para o agrupamento de *pixels* de uma imagem dentro de uma classe (Miqueles e Centeno, 2005). A imagem foi segmentada utilizando um conjunto de parâmetros como nível de escala = 90 e *Merge level* = 40.

Implementação da rede neural convolucional

Para implementação da RNC foi utilizada uma máquina Intel processador Core i5-8265U Quad Core. 3.50 GHz, 6 GB de RAM, sistema operacional Linux Ubuntu 16 e o *framework* de código aberto *Tensorflow* 2.0 lançado em 2017 pelo *Google*, à biblioteca de ML *Keras* e linguagem de programação *python* 3.2. A figura 4 é apresenta a arquitetura da rede profunda com seis camadas empilhadas.

A primeira é camada de entrada que recebe as imagens dos espectros e tem a dimensão do tamanho das imagens de originais que é de 282x417 *pixels* (em três canais de padrão de cor RGB).

A segunda camada é uma camada convolucional unidimensional (1D) que recebe a camada de entrada e ficando com a seguinte dimensão (282x417X16). A convolução é realizada entre o produto escalar de uma região da imagem chamada campo receptivo e o próprio filtro. No




Figura 4. Arquitetura da RNC.

No presente trabalho foi utilizada a função de perda chamada entropia cruzada. A entropia cruzada foi definida para calcular e perda no

presente estudo foram utilizados 16 filtros convolucionais com tamanho 3x3, estes filtros convolucionais enxergam pequenos quadros que se deslocam por toda a imagem com um movimento chamado de *stride* que é o parâmetro que define o tamanho deste deslocamento, neste trabalho adotamos o *stride* com o tamanho 1.

Esta camada conta ainda com uma função de ativação do tipo Unidade Linear Retificada (*Rectified Linear Unit* - ReLU) a função ReLU, em geral possui grande vantagem em relação a outras funções tradicionalmente utilizadas, devido à sua capacidade de não saturar. As funções de ativação introduzem um componente não linear nas RNs, o que faz com que elas possam aprender mais do que relações lineares entre as variáveis, uma RN sem função de ativação é um modelo de regressão linear. Existem diversas funções de ativação, contudo mais indicada para as RNCs é a RELU por ser mais eficiente computacionalmente sem grandes diferenças de acurácia quando comparada a outras funções (Agostinelli e Hoffman, 2014; Pacheco, 2019; Siegel e Xu, 2020).

A terceira camada é uma camada de sub amostragem (*MaxPooling*) bidimensional (2D), que reduz a dimensão da imagem pela metade, ou seja, a imagem fica a partir desta camada com seguinte dimensão (141x208x16). A quarta camada é uma de achatamento (*flatten*), que faz a vetorização da camada anterior, ficando com seguinte dimensão vetorial (469248). A quinta camada é uma camada densa totalmente conectada com 128 unidades. E por fim a sexta é a camada de saída, que também é uma camada densa e totalmente conectada, com duas saídas para as classes floresta e urbano.

processo de aprendizagem da RNC comparando a probabilidade entre o rótulo verdadeiro e rótulo predito. Foi adota a metodologia para criação dos

rótulos das classes de saída, tendo considerado o domínio do problema atacado pela RNC, que é um problema de classificação binária a denominada codificação quente, onde cada rótulo é mapeado para um vetor binário, o método de otimização utilizado foi à descida de gradiente estocástica do inglês *Stochastic gradient descent* (SGD), com ritmo de aprendizagem de 0,001.

A abordagem implantada trata-se de um modelo de aprendizagem supervisionada, sendo assim inicialmente a RNC foi treinada usando um conjunto de treinamento e validação com 700 espectros das classes predefinidas. Posteriormente o modelo proposto foi utilizado para classificar 500 espectros do conjunto de teste, que foram submetidos à abordagem onde cada um desses espectros é submetido um a um à RNC e classificado de acordo com uma das duas classes floresta e urbano.

Avaliação de desempenho da classificação

A avaliação de um modelo de classificação foi feita a partir da comparação entre as classes preditas pelo modelo e as classes verdadeiras para cada amostra. Para avaliar o resultado das abordagens propostas quanto ao desempenho da sua classificação, foram utilizadas cinco métricas de avaliação: A matriz de confusão, acurácia geral, precisão, revocação ou sensibilidade e o *F-score*.

Uma matriz de confusão resume o desempenho de um classificador em relação a algum conjunto de teste. É uma matriz bidimensional indexada em uma dimensão pela verdadeira classe de um objeto e na outra pela classe que o classificador atribuiu.

Um caso especial da matriz de confusão é o utilizado em modelos de classificação binária, onde se tem somente duas classes, uma definida como classe positiva e a outra como classe negativa. Neste contexto, as quatro células da

$$F - score = \frac{2 * (revocação * precisão)}{(revocação + precisão)} \quad (5)$$

matriz são designadas como Verdadeiros Positivos (VP), Falsos Positivos (FP), Verdadeiros Negativos (VN) e Falsos Negativos (FN).

A acurácia geral é uma métrica para avaliar modelos de classificação, ela resume quantas de nossas amostras foram de fato classificados corretamente, independente da classe (Bishop, 2006; Ting et al., 2017; Li et al 2019), através da seguinte equação:

Para a classificação binária, acurácia geral pode ser calculada em termos de positivos e negativos, conforme mostra a equação abaixo:

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (2)$$

Onde VP é Verdadeiro Positivo, VN é Verdadeiro Negativo, FP é Falso Positivo e FN é Falso Negativo.

A análise de precisão (*precision*) e sensibilidade ou revocação (*recall*) são abundantes em aplicações de classificação binária onde os verdadeiros negativos não agregam valor e, portanto, não devem afetar a avaliação do desempenho do classificador. Existe ainda a métrica denominada medida F ou *F-score* que é a média harmônica entre precisão e revocação (Flack e Kull, 2017).

Em modelos de classificação, a precisão

$$Acurácia\ geral = \frac{Número\ de\ predições\ corretas}{Número\ total\ predições} \quad (1)$$

de uma classe é o número de itens preditos corretamente como pertencentes a essa classe, dividido pelo número total de amostras previstas como pertencentes à classe dada por:

$$Precisão = \frac{VP}{VP + FP} \quad (3)$$

Enquanto a análise de sensibilidade ou revocação de uma classe é o número de amostras preditas corretamente como pertencentes a essa classe dividido pelo número total de amostras que realmente pertencem à classe, conforme apresentado na seguinte equação:

$$Revocação = \frac{VP}{VP + FN} \quad (4)$$

Por fim foi utilizada a medida F (*F-score*) é uma métrica que combina é média ponderada dos resultados obtidos pela precisão e pela revocação através da seguinte equação:

Resultados e discussão

Os resultados foram avaliados quanto a sua acurácia geral de classificação e também quanto à sensibilidade da abordagem com respeito às duas classes submetidas ao modelo proposto, foi realizada uma comparação entre as duas configurações empregadas nas RNCs, sem aumento de dados e com aumento de dados, a fim de avaliar o impacto sobre o treinamento da rede ao que refere ao tempo de execução, perda de

treinamento e validação e acurácia de treinamento e validação, através dos mapas de classificação gerados.

Resultados obtidos pela RNC sem aumento de dados

Abordagem de classificação de imagens hiperespectrais por meio de uma RNC adotou duas configurações diferentes no que se refere ao treinamento da mesma, a primeira configuração da rede utilizada não contou com a técnica de regularização de aumento de dados. Um problema central no aprendizado de máquina é como fazer um algoritmo que ter um bom desempenho não apenas nos dados de treinamento, mas também em novo conjunto de dados de entrada. Muitas estratégias usadas no aprendizado de máquina são explicitamente projetadas para reduzir o erro de teste, essas estratégias são conhecidas como regularização, uma maneira muito utilizada para fazer um modelo de aprendizado de máquina generalizar é treiná-lo em mais dados, na prática, quando se tem uma quantidade de dados limitada uma das formas de contornar este problema é criar dados artificiais através de uma técnica denominada aumento de dados do inglês *data augmentation* e adicioná-los ao conjunto de treinamento (Goodfellow et al., 2015; Devries e Taylor, 2017).

Na segunda configuração adotou-se a técnica de aumento de dados, com objetivo de contornar o problema de sobreajuste comum em RNCs treinadas com um conjunto de treinamento com poucas amostras. É importante ressaltar que as duas abordagens usaram o mesmo conjunto de dados, sendo treinadas pela mesma quantidade de épocas, visando caracterizar o impacto do uso da técnica de regularização aplicada. A Tabela 1 exibe as configurações de entrada da RNC sem aumento de dados.

Tipo de camada	Corpo	camadas
Camada de entrada	(282, 417, 3)	0
Conv1D	(282, 417, 16)	160
Sub amostragem	(141, 208, 16)	0
Achatada	(469248)	0
Densa	(128)	60063872
Saída	(2)	258
Total de parâmetros		60,064,290
Parâmetros treináveis		60,064,290
Parâmetros não treináveis		0

O modelo da RNC treinada sem aumento de dados teve acurácia de treinamento de 0.5018 e tempo de execução total de 4900 segundos com 4000 épocas de treinamento. É possível observar na Figura 5, que há uma diferença enorme entre a precisão e treinamento e de validação, as curvas de treinamento e validação estão totalmente separadas o que caracteriza um sinal de sobreajuste (*overfitting*) que impactou negativamente a capacidade de generalizar para esta configuração da RNC.

No aprendizado de máquina supervisionado há um problema frequente o modelo não generaliza bem de dados observados para dados não vistos, o que é chamado de sobreajuste. Por conta da existência de sobreajuste o modelo tem um desempenho perfeito no conjunto de treinamento, mas se encaixa mal no conjunto de teste. Isso acontece pelo fato do modelo com sobreajuste ter dificuldade em lidar com partes das informações no conjunto de teste, que podem ser diferentes daqueles no conjunto de treinamento. Por outro lado, os modelos com sobreajuste tendem a memorizar todos os dados, incluindo ruído inevitável no conjunto de treinamento, em vez de aprender as características intrínsecas dos dados (Ying, 2019; Rice et al., 2020).

Tabela 1. Configurações da RNC sem aumento de dados:




Figura 5. Gráficos de acurácia e perda para o treinamento e a validação da RNC sem aumento de dados.

O desempenho geral, bem como a capacidade de generalizar desta configuração da RNC pode ser comprovado pelas métricas aplicada, apresentadas na Tabela 2. A acurácia geral que é à medida que determina o desempenho do modelo de maneira geral foi de 0,88 enquanto que a precisão foi de 0,88 para classe floresta e 0,00 para classe urbano o que confirma o sobreajuste do modelo também foi possível observar pelos resultados numéricos que o problema de generalização do modelo ocorre especificamente para classe urbano e que classe floresta garante um bom desempenho para o modelo com um todo.

Tabela 2. Avaliação do desempenho para a abordagem sem aumento de dados.

	Precisão	Revocação	F-Score	Support
Urbano	0,00	0,00	0,00	59
Floresta	0,88	1,00	0,94	441
Acurácia geral			0,88	500

A matriz de confusão com os Verdadeiros Positivos (VP), Verdadeiros Negativos (VN), Falsos Positivos (FP), Falsos Positivos (FP) para a abordagem sem aumento de dados são exibidos na Tabela 3. Através da matriz de confusão foi possível observar que mesmo esta configuração tendo atingido uma acurácia geral de 0,88 a mesma classificou todas as amostras do conjunto de teste como da classe floresta.

Tabela 3. Matriz de confusão para abordagem sem aumento de dados.

		Classe Predita	
		Urbano	Floresta
Classe Real	Urbano	59	59
	Floresta	0	441

Verifica-se na Figura 6 a semelhança entre o mapa de classificação obtido pela abordagem da RNC sem aumento de dados e o mapa de referência, contudo também é possível notar pelos resultados visuais a incapacidade de generalizar da abordagem especificamente para à classe urbano.

Resultados obtidos pela RNC com aumento de dados

A acurácia de treinamento foi de 0,9536 com 4000 épocas de treinamento e tempo de execução total de 9341 segundos. É possível observar na Figura 7 que a acurácia de treinamento e validação veem crescendo se estabiliza próximo a 0.9 enquanto a acurácia de validação ao chegar a 0.9 começa a decresce, o que demonstra que ainda há uma diferença entre acurácia de treinamento e de validação. Também foi possível observar que depois de aplicação da técnica de aumento de dados, que a acurácia de treinamento e de validação estão alinhadas e próximas o que caracteriza uma diminuição quase que total do *overfitting*.




Figura 6. Mapa de referência (à esquerda) mapa de classificação para abordagem sem aumento de dados (direita).




Figura 7. Gráficos de acurácia e perda para o treinamento e a validação da RNC com aumento de dados.

O desempenho geral desta configuração da RNC, assim como o impacto positivo da técnica de aumento de dados usada nesta configuração para contornar o problema do sobre ajuste pode ser vista na Tabela 6. Contudo é possível observar que apesar desta configuração ter conseguido uma

acurácia de 0,92 a precisão pra classe urbano foi de apenas 0,69 o que pode ter sido ocasionado pelo fato do conjunto de validação ter apenas 59 amostras da classe urbano, enquanto que para classe floresta possui 441 amostras.

Tabela 6. Avaliação do desempenho para a abordagem com aumento de dados.

	Precisão	Revocação	F-Score	Suporte
Urbano	0,69	0,58	0,63	59
Floresta	0,94	0,97	0,96	441
Acurácia geral			0,92	500

A matriz de confusão para a abordagem com aumento dados pode ser vista na Tabela 7, através desta foi possível observar que a configuração da RNC com aumento de dados teve um ganho significativo no número de predições corretas para classe urbano, classificando corretamente 34 amostras de um total de 59


amostras do conjunto de dados de teste (suporte) enquanto que para classe floresta o desempenho manteve-se alto com 426 amostras classificadas corretamente para um total de 441 do conjunto do dados de teste (suporte).

Tabela 7. Matriz de confusão para abordagem com aumento de dados.

		Classe Predita	
		Urbano	Floresta
Classe Real	Urbano	59	59
	Floresta	0	441

Conforme mostra a Figura 8 há um aumento visível da semelhança entre o mapa de classificação obtido pela abordagem com aumento de dados e o mapa de referência, outro ponto relevante observado foi o aumento na capacidade de generalização desta abordagem da RNC, sendo possível notar um incremento significativo no

número de espectros da classe urbano classificados corretamente, isso ocorreu devido à diminuição do *overffiting* existente na RNC sem aumento de dados, diminuição que foi alcançada por meio da técnica de regularização de aumento de dados aplicada ao conjunto de treinamento.



Figura

8. Mapa de referência (à esquerda) mapa de classificação para abordagem com aumento de dados (direita).

Conclusões

As análises dos resultados alcançados pelas configurações utilizadas nas RNCs mostraram que o emprego da abordagem sem aumento de dados alcançou 0,88 de acurácia geral, enquanto a abordagem com aumento de dados alcançou 0,92 além de contornar o problema de sobre ajuste ocorrido na configuração da RNC sem aumento de dados. Logo, pode-se concluir que o emprego de RNCs e algoritmos de aprendizado profundo na classificação de imagens hiperespectrais podem ser amplamente utilizados no mapeamento da cobertura e uso da terra com a finalidade de monitoramento de ocupações desordenadas da terra sobre tudo em locais de difícil acesso como o PNT.

A RNC é uma solução atraente para classificação de espécies de árvores em ambientes altamente diversos, mesmo na presença de pequenos conjuntos de amostras, se aplicada à técnica de aumento de dados.

Nossos resultados são comparáveis aos resultados acima, contudo sugere-se para trabalhos futuros a aplicação desse estudo a outros conjuntos de dados de entrada e a utilização de outros parâmetros para as RNCs que possibilitem à redução de erros de classificação.

Agradecimentos

Os autores agradecem ao programa de pós-graduação em ciência, tecnologia e inovação em agropecuária por todo apoio à pesquisa e a CAPES pelo suporte financeiro.

Referências

- Agostinelli, F; Hoffman, M., 2014. Aprender funções de ativação para melhorar redes neurais profundas. pré-impressão arXiv arXiv: 1412.6830.
- Atlântica, SOS Mata. Fundação SOS Mata Atlântica e Instituto Nacional de Pesquisas Espaciais. 2009. Atlas da Mata Atlântica. São Paulo.
- Bishop, Christopher M., 2006. Pattern recognition and machine learning. Springer.
- Chen, Y.; Zhu, K.; Zhu, L.; He, X.; Ghamisi, P.; Benediktsson, J. A., 2019. Automatic design of convolutional neural network for hyperspectral image classification. IEEE Transactions on Geoscience and Remote Sensing, 57(9).
- Coelho, T. O. 2016. Valoração dos serviços ecossistêmicos do Parque Nacional da Tijuca. 2016. 70. Monografia - Instituto de Economia, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- Crispin, D. L.; DE Andrade, S. O.; De Meneses, J. A. D.; Chaves, A. D. C. G; Borges, M. D. G. B., 2014. Impactos ambientais decorrentes do uso e ocupação desordenada do espaço urbano: um estudo de caso da cidade de Baixo/CE. Revista Verde de Agroecologia e Desenvolvimento Sustentável, 9, 44-49.
- Devries, T.; Taylor, G. W., 2017. Dataset augmentation in feature space. arXiv preprint arXiv:1702.05538.
- Flach, P; kull, M., 2015. Precision-recall-gain curves: PR analysis done right. In: Advances in neural information processing systems. p. 838-846.
- Goodfellow, I. J.; Bengio, Y.; Courville, 2015. A. Deep learning book. An MIT Press book in preparation.

- Goutte, C.; Gaussier, E. A., 2005. probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In: European conference on information retrieval. Springer, Berlin, Heidelberg. p. 345-359.
- Griffin, M. K.; Hsu, S. M.; Burke, H. H. K., Orloff, S. M.; Upham, C. A., 2005. Examples of EO-1 Hyperion data analysis. Massachusetts inst of tech lexington lincoln lab.
- Guidici, D.; Clark, M. L., 2017. One-Dimensional convolutional neural network land-cover classification of multi-seasonal hyperspectral imagery in the San Francisco Bay Area, California. *Remote Sensing*, 9, 629.
- ICMBio. Instituto Chico Mendes de Conservação da Biodiversidade. 2008. Plano de Manejo do Parque Nacional da Tijuca. Brasília [Online] Disponível:<http://www.icmbio.gov.br/parnatijuca/plano-de-manejo>. Acesso: 05 jan. 2020.
- Kayet, N.; Pathak, K.; Chakrabarty, A.; Singh, C. P.; Chowdary, V. M.; Kumar, S.; Sahoo, S., 2019. Forest health assessment for geo-environmental planning and management in hilltop mining areas using Hyperion and Landsat data. *Ecological Indicators*, 106,105471.
- Kumar, T.; Mandal, A.; Dutta, D.; Nagaraja, R.; Dadhwal, V. K., 2019. Discrimination and classification of mangrove forests using EO-1 Hyperion data: a case study of Indian Sundarbans. *Geocarto International*, 34, 415-442.
- Hartling, S.; Sagan, V.; Sidike, P.; Majmaitjiang, M.; Carron, J., 2019. Urban Tree Species Classification Using a WorldView-2/3 and LiDAR Data Fusion Approach and Deep Learning. *Sensors (Basel)* 19 (6): 1284.
- IBGE. Instituto Brasileiro de Geografia e Estatística, 2020. Monitoramento da cobertura e uso da terra do Brasil: 2016 - 2018, Rio de Janeiro.
- Lecun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature*, 521, 436-444, 2015.
- Lee, C. M.; Cable, M. L.; Hook, S. J.; Green, R. O.; Ustin, S. L.; Mandl, D. Middleton, E. M. An introduction to the NASA Hyperspectral InfraRed Imager (HyspIRI) mission and preparatory activities. *Remote Sensing of Environment*, 167, 6-19, 2015.
- Li, W.; Liu, H.; Wang, Y.; Li, Z.; Jia, Y.; Gui, G. 2019. Deep learning-based classification methods for remote sensing images in urban built-up areas. *IEEE Access*, 7, 36274-36284.
- Liu, Y.; Cao, G.; Sun, Q.; Siegel, M., 2015. Hyperspectral classification via learnt features. In: IEEE International Conference on Image Processing (ICIP). IEEE. p. 2591-2595.
- Miqueles, M.; Centeno, J., 2005. Extração de edificações em ambientes urbanos utilizando imagem de alta resolução e dados do laser scanner. Simpósio Brasileiro de Sensoriamento Remoto. XII Simpósio, Goiania: INPE, p. 4155-4162.
- Pacheco, A. G. C., 2019. Classificação de espécies de peixe utilizando redes neurais convolucionais. arXiv preprint arXiv: 1905.03642.
- Rice, L; Wong, E; Kolter, Z., 2020. Overfitting in adversarially robust deep learning. In: International Conference on Machine Learning. 8093-8104.
- Roscher, R; Waske, B., 2016. Shapelet-Based Sparse Representation for Landcover Classification of Hyperspectral Images. *IEEE Transactions on Geoscience and Remote Sensing*, 54, 1623-1634.
- Salles, M. C. T.; Grigio, A. M.; Da Silva, M. R. F., 2013. Expansão urbana e conflito ambiental: uma descrição da problemática do município de Mossoró, RN-Brasil. *Sociedade & Natureza*, 25(2), 281-290.
- Siegel, J. W.; XU, J., 2020. Taxas de aproximação de alta ordem para redes neurais com funções de ativação ReLU^k. pré-impressão arXiv: 2012.07205.
- Sothe, C.; Da Almeida, C. M.; Schimalski, M. B.; La rosa, L. E. C.; Castro, J. D. B.; Feitosa, R. Q.; Dalponte, M.; Lima, C. L.; Liesenberg, V; Miyoshi, G. T.; Tommaselli, A. M. G., 2020. Comparative performance of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data, *GIScience & Remote Sensing*, 57, 369-394.
- Ting, K. M., 2017. Confusion Matrix. *Encyclopedia of Machine Learning and Data Mining*, v. 260.
- Vithana, S. S. P.; Abeysekara A. M. R.; Orloff T. S. J.; Rupasinghe R. A. A; Herath H. M. V. R.; Godaliyadda G. M. R. I.; Ekanayake M. P. B.; 2017. Hyperspectral imaging based land cover mapping using data obtained by the Hyperion sensor." Seventeenth International Conference on Advances in ICT for Emerging Regions (ICTer). IEEE, 2017.
- Windrim, L.; Melkumyan, A.; Murphy, R. J.; Chlingaryan, A., 2019. Unsupervised feature-learning for hyperspectral data with autoencoders. *Remote Sensing*, 11, 864.
- Ying, X. 2019. An overview of overfitting and its solutions. In: *Journal of Physics: Conference Series*. IOP Publishing, p. 022-022.