

Detecção de áreas desmatadas utilizando redes neurais artificiais associados a métodos para melhoria da generalização

Joel P. Oliveira¹, Marly G. F. Costa², Cícero F. F. Costa Filho³

¹Centro Gestor e Operacional do Sistema de Proteção da Amazônia ó Censipam
Avenida do Turismo, nº 1350 ó Tarumã ó Manaus ó AM, Brasil

²Universidade Federal do Amazonas ó UFAM
Av. General Rodrigo Octávio, nº 6200 ó Coroado I ó Manaus ó AM, Brasil
{joelparente,marlygfcosta,cffcfilho}@gmail.com

Abstract. *This study proposes a methodology to study deforesting areas using Landsat optical images obtained through remote sensing. The methodology proposes the association of methods for improving neural networks generalization, as early stopping and regularization, with techniques for characteristic extractions, as scalar selection technique, principal component analysis and linear discriminant analysis. The performance of the methodology is evaluated using measures as accuracy, sensitivity, specificity and area under ROC curve. The results shown that the best results are obtained with the early stop generalization method associated with the linear discriminant analysis technique. The study is carried out in three regions of the Amazon State, located near the municipalities of Apuí, Humaitá and Lábrea. An area under ROC curve and an accuracy as good as 0.997 and 0.97, respectively, are obtained.*

Resumo. *Este estudo propõe uma metodologia para o estudo de áreas de desmatamento utilizando imagens óticas Landsat obtidas por sensoriamento remoto. É proposta a associação de métodos para melhorar a generalização das redes neurais, como a parada antecipada e regularização, com técnicas de extração de características, como seleção escalar, análise de componentes principais e análise de discriminante linear. O desempenho da metodologia é avaliado utilizando medidas como precisão, sensibilidade, especificidade e área sob curva ROC. Os melhores resultados foram obtidos com o método de generalização parada antecipada associado à técnica de análise discriminante linear. O estudo foi realizado em três regiões do Estado do Amazonas, localizadas nos municípios de Apuí, Humaitá e Lábrea. Foi obtida uma área sob a curva ROC e uma precisão de 0,997 e 0,97 respectivamente.*

1. Introdução

Sensoriamento remoto é obtenção de dados sobre um objeto sem estar em contato físico direto com o mesmo [Jensen, 2009]. De forma mais específica, [Novo, 2008] define que sensoriamento remoto é a utilização de diversas tecnologias, como sensores,

equipamentos instalados a bordo de aeronaves, espaçonaves, ou outras plataformas, com o objetivo de estudar os fenômenos que ocorrem na superfície da Terra.

Para realizar o monitoramento do desmatamento na Amazônia, as imagens geradas a partir de sistemas de sensoriamento remoto possuem grande importância, pois segundo [Noma *et al.*, 2013], imagens de satélite permitem realizar o monitoramento do desmatamento em larga escala e compreender a dinâmica da paisagem. Neste sentido, desde 1988, o Instituto Nacional de Pesquisas Espaciais (INPE) é o principal responsável pelo monitoramento da Floresta Amazônica. Neste aspecto, [Noma *et al.*, 2013] destacam dois projetos: Programa de Monitoramento do Desflorestamento na Amazônia Legal (PRODES) e TerraClass. O PRODES fornece dados por meio de mapas anuais de desmatamento na região Amazônica. Já o projeto TerraClass utiliza os dados gerados pelo PRODES para realizar uma classificação de uso e cobertura de solo.

Na literatura, diversos trabalhos propõem metodologias de classificação automática de imagens para monitoramento do solo. [Pimentel, 2014], utilizou redes neurais artificiais para classificar padrões temporais de uso do solo e cobertura da terra, utilizando séries temporais de índices de vegetação. [Reis, 2014] avaliou o potencial de imagens SAR, óticas e a combinação das duas para detectar mudanças em uma área da floresta nacional do Tapajós. [Zanotta, 2014] propôs uma nova metodologia para detecção semi-supervisionada de desflorestamento na Amazônia brasileira utilizando imagens Landsat. Os trabalhos apresentados não utilizaram estratégias contra o sobre ajustamento (*overfitting*), fenômeno que ocorre quando uma rede neural é excessivamente treinada, trazendo como consequência o sobre ajustamento dos parâmetros na tarefa de reconhecimento dos padrões apresentados durante a fase de treinamento.

Nos últimos anos, o desempenho das redes neurais sofreu uma melhoria substancial, com o desenvolvimento de novas técnicas de generalização, como parada antecipada e regularização [Hagan *et al.*, 2014], ensejando novos critérios de parada para o treinamento das redes neurais, que não o Erro Quadrático Médio (*Mean Square Error* ó MSE), tradicionalmente utilizado. Além disso, técnicas robustas de extração de características foram desenvolvidas, como Análise de Componentes Principais (*Principal Component Analysis* ó PCA), Análise Discriminante Linear (*Linear Discriminant Analysis* ó LDA) e Seleção Escalar de Características (SEC) [Theodoridis e Koutroumbas, 2008], que permitiram uma melhoria substancial na compactação e representatividade da informação. Nesse trabalho, pretende-se avaliar o desempenho dos métodos de generalização das redes neurais, quando associados aos métodos de extração de características anteriormente citados, para o reconhecimento de áreas desmatadas na região sul do estado do Amazonas. O texto está organizado da seguinte maneira. A Seção 2 apresenta o conjunto de dados e a metodologia. Na Seção 3, os resultados são exibidos e interpretados. Finalmente, algumas conclusões são exibidas na Seção 4.

2. Materiais e Métodos

2.1. Materiais

As imagens utilizadas nesse estudo foram imagens óticas Landsat8 retiradas do *site*: <http://earthexplorer.usgs.gov>. As bases de imagens utilizadas foram dos municípios de Apuí, Humaitá, Lábrea localizados no sul do estado do Amazonas, conforme mostrado

na Figura 1. Os dados de entrada do classificador foram extraídos do projeto PRODES, do ano de 2015, disponibilizado por [Inpe, 2017]. Foram extraídas amostras de feições correspondentes a áreas desmatadas e áreas não desmatadas (floresta e outros tipos de vegetação denominados de não-floresta segundo [Inpe, 2017]). Para cada uma das três regiões foram selecionadas 2000 amostras, 1000 amostras pertencentes a áreas não desmatadas e 1000 amostras pertencentes a áreas desmatadas. A metodologia utilizada neste estudo foi comparada com a abordagem metodológica adotada nos trabalhos de [Reis, 2014], [Pimentel, 2014] e [Zannota, 2014]. Esses trabalhos foram escolhidos para comparação, pois os mesmos também utilizaram imagens óticas da região Amazônica.

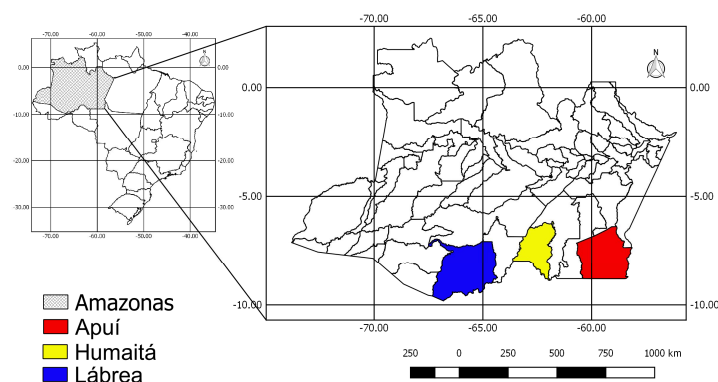


Figura 1. Mapa do Amazonas delimitando as regiões utilizadas nesse estudo

2.2. Métodos

2.2.1. Sistema de Reconhecimento

As etapas do método de reconhecimento de padrões utilizadas foram: extração de características, seleção de características e classificação.

O conjunto de características utilizados neste trabalho compreende características de textura. Com base na revisão da literatura, as características de textura mais utilizadas e que empregamos neste trabalho foram: média, variância, desvio padrão, homogeneidade, energia, correlação, contraste e entropia. Segundo [Usgs, 2017], para detecção da vegetação, as bandas de imagem sugeridas são: 2, 3, 4, 5, 6, 7. A essas bandas citadas anteriormente, acrescentamos mais duas bandas calculadas a partir dessas primeiras, conforme sugerido por [Huete *et al.*, 2002]: NVDI e EVI. As características foram numeradas de 1 a 64. A característica 1 corresponde a média da banda 2, a característica 2 corresponde a variância a banda 2, e assim sucessivamente, até a característica 64, que corresponde a entropia da banda EVI.

Para o treinamento das redes neurais foram selecionados conjuntos de 10, 20, 30, 40, 50 e 64 características. A seleção das mesmas deu-se através da utilização das técnicas PCA, LDA e SEC. Na técnica SEC a medida de separação de classes utilizada foi a Razão Discriminante de Fisher (*Fisher Discriminant Ratio* ó FDR) [Theodoridis e Koutroumbas, 2008].

O classificador empregado foi uma rede neural, com arquitetura X-11-1, em que X pode assumir os valores de 64, 50, 40, 30, 20 ou 10, em função do número de variáveis de entrada. Os critérios de parada empregados para o treinamento da rede neural foram MSE, Parada Antecipada e Regularização. O limite máximo de iterações fixado para um

treinamento foi de 1000. Os valores mínimos para os critérios MSE e Regularização que determinaram o final do treinamento foi de 10^{-6} . O treinamento da rede neural utilizando Parada Antecipada termina quando, no conjunto de validação, o MSE aumentar por mais de 6 épocas consecutivas. Para acelerar o treinamento da rede neural foi utilizado o método de Levenberg-Marquardt [Hagan *et al.*, 2014].

2.2.2. Metodologia de Treinamento e Teste

Para o treinamento da rede neural com o critério MSE e Regularização, a metodologia de treinamento e teste utilizada foi a de validação cruzada com 5 pastas [Blum *et al.*, 1999]. Nesse trabalho, utilizou-se um conjunto de 2000 amostras para treinamento e teste (1000 amostras de regiões de desmatamento e 1000 amostras de regiões de áreas não desmatadas). Esse total de amostras foi dividido em 5 grupos de 400 amostras cada (200 de áreas desmatadas e 200 de áreas não desmatadas). A rede foi treinada com os dados de 4 grupos e testada com o quinto grupo. Como tem 5 grupos, esse processo foi repetido 5 vezes e uma média do desempenho foi calculada. Para o critério de Parada Antecipada, o conjunto de dados foi dividido em três partes iguais, treinamento, validação e teste. Três classificadores neurais distintos foram treinados e testados. Um deles foi treinado com amostras da região de Apuí. O segundo, com amostras da região de Humaitá. O terceiro, com amostras da região de Lábrea.

3. Resultados

A Tabela 1 mostra as características selecionadas para as regiões de Apuí, Humaitá e Lábrea utilizando a técnica SEC. Para a região de Apuí, a característica variância da Banda B4 foi a que apresentou um maior valor para a razão FDR, que foi de 1,32. Para a região de Humaitá, a característica variância da Banda B2 foi a que apresentou um maior valor para a razão FDR, que foi de 2,25. Para a região de Lábrea, a característica média da Banda B2 foi a que apresentou um maior valor para a razão FDR, que foi de 0,64.

Nas tabelas 2, 3 e 4 são apresentados dados de desempenho dos classificadores. Esses dados são resultados médios para acurácia, Área sob a curva de ROC (*Area Under ROC Curve* ó AUC) [Hanley e Mcneil, 1982], sensibilidade e especificidade, para os métodos de treinamento MSE, Parada Antecipada e Regularização, combinados com as técnicas de extração de características SEC, PCA e LDA, para as regiões de Apuí, Humaitá e Lábrea, respectivamente.

3.1. Análise dos Resultados

A partir da Tabela 1 observa-se que as características 63 (Contraste, Banda EVI) e 62 (Correlação, Banda EVI) sempre estão presentes nos conjuntos de características selecionados. Isso pode ser justificado pelo fato da banda EVI ser formada a partir do cálculo do índice de vegetação EVI. Índices de vegetação foram desenvolvidos para explorar as propriedades espectrais de vegetação e, portanto, ressaltam o comportamento espectral da vegetação em relação ao solo e a outros alvos da superfície terrestre.

Os principais parâmetros utilizados para avaliação de um método de classificação são a AUC e a acurácia do método. Observando as Tabelas 2, 3 e 4, com respeito a AUC, derivam-se algumas conclusões importantes.

Tabela 1. Conjunto de Características selecionados pela técnica seleção escalar de características para as regiões de Apuí, Humaitá e Lábrea

Número de Características	Conjunto de Características		
	Apuí	Humaitá	Lábrea
10	A1= {18,19,2,63,5,62,26,61,3,53}	H1= {26,27,63,53,62,55,25,5,31,54}	H1= {1,5,17,62,9,63,61,54,47,41}
20	A2=A1+{55,30,13,42,31,6,50,21,58,15}	H2=H1+{13,7,35,15,21,34,6,23,29,19}	H2=H1+{13,49,30,57,21,39,33,14,29,23}
30	A3=A2+{14,29,27,7,54,33,45,43,23,37}	H3=H2+{47,14,39,45,33,30,37,11,22,18}	H3=H2+{6,15,37,7,22,45,31,38, 53,55}
40	A4=A3+{22,51,59,39,46,57,47,49,38,41}	H4=H3+{46,61,38,40,56,48,64,51,52,59}	H4=H3+{60,46,44,2,36,25,28,20,52,12}
50	A5=A4+{17,34,60,35,52,9,44,36,20,10}	H5=H4+{16,24,43,32,8,60,44,36,10,20}	H5=H4+{26,18,4,27,40,56,3,48,64,16}

Tabela 2. Resultados médios para acurácia, AUC, sensibilidade e especificidade, para os métodos de treinamento MSE, parada antecipada e regularização para a região de Apuí

Região	Métodos de parada do treinamento	N. de Caract.	Técnica de Seleção de Características											
			SEC				PCA				LDA			
			Acur.	AUC	Sens	Esp	Acur.	AUC	Sens	Esp	Acur.	AUC	Sens	Esp
Apuí	MSE	10	99,80	0,998 ± 0,0022	99,80	99,80	95,90	0,959 ± 0,0102	95,60	96,20	99,95	0,999 ± 0,0011	99,90	100,00
		20	99,85	0,998 ± 0,0019	99,70	99,90	94,95	0,950 ± 0,0114	94,30	95,60	99,85	0,998 ± 0,0019	99,90	99,80
		30	99,80	0,998 ± 0,0022	99,70	99,90	93,15	0,931 ± 0,0132	92,40	93,90	99,95	0,998 ± 0,0019	99,90	100,00
		40	99,85	0,998 ± 0,0019	99,80	99,90	93,70	0,937 ± 0,0127	94,30	93,10	99,95	0,999 ± 0,0011	99,90	100,00
		50	99,85	0,998 ± 0,0019	99,70	100,00	92,60	0,926 ± 0,0138	91,20	94,00	99,95	0,999 ± 0,0011	99,90	100,00
		64	99,85	0,998 ± 0,0019	99,80	99,90	99,85	0,998 ± 0,0019	99,80	99,90	99,85	0,998 ± 0,0011	99,80	99,90
	Parada Antecipada	10	99,90	0,999 ± 0,0016	99,85	99,95	97,33	0,973 ± 0,0082	97,35	97,30	99,93	0,999 ± 0,0014	99,85	99,99
		20	99,93	0,999 ± 0,0014	99,85	100,00	98,63	0,986 ± 0,0059	98,70	98,55	99,90	0,999 ± 0,0016	99,85	100,00
		30	99,93	0,999 ± 0,0014	99,85	100,00	95,78	0,958 ± 0,0104	95,70	95,85	99,93	0,999 ± 0,0014	99,85	99,95
		40	99,93	0,999 ± 0,0014	99,85	100,00	93,78	0,938 ± 0,0126	93,60	93,95	99,93	0,999 ± 0,0014	99,85	100,00
		50	99,90	0,999 ± 0,0016	99,80	100,00	95,48	0,955 ± 0,0107	95,80	95,15	99,93	0,999 ± 0,0014	99,85	100,00
		64	99,93	0,999 ± 0,0014	99,85	100,00	99,93	0,999 ± 0,0014	99,85	100,00	99,93	0,999 ± 0,0014	99,85	100,00
	Regularização	10	99,80	0,998 ± 0,0022	99,70	99,90	96,40	0,964 ± 0,0096	96,10	96,70	99,95	0,999 ± 0,0011	99,90	100,00
		20	99,90	0,999 ± 0,0016	99,80	100,00	84,25	0,843 ± 0,0199	81,30	87,20	99,95	0,999 ± 0,0011	99,90	100,00
		30	99,85	0,988 ± 0,0019	99,80	99,90	85,20	0,852 ± 0,0170	87,30	83,10	99,95	0,999 ± 0,0011	99,90	100,00
		40	99,85	0,988 ± 0,0019	99,80	99,90	86,10	0,861 ± 0,0162	81,30	90,90	99,95	0,999 ± 0,0011	99,90	100,00
		50	99,95	0,999 ± 0,0011	99,90	100,00	87,20	0,872 ± 0,0155	82,30	92,10	99,95	0,999 ± 0,0011	99,90	100,00
		64	99,85	0,999 ± 0,0011	99,90	100,00	99,95	0,995 ± 0,0014	99,90	99,90	99,95	0,999 ± 0,0011	99,90	100,00

Tabela 3. Resultados médios para acurácia, AUC, sensibilidade e especificidade, para os métodos de treinamento MSE, parada antecipada e regularização para a região de Humaitá

Região	Método de parada do treinamento	N. de Caract.	Técnica de Seleção de Características											
			SEC				PCA				LDA			
			Acur.	AUC	Sens	Esp	Acur.	AUC	Sens	Esp	Acur.	AUC	Sens	Esp
Humaitá	MSE	10	94,25	0,943 ± 0,0121	94,00	94,50	97,05	0,971 ± 0,0087	97,50	96,60	99,55	0,996 ± 0,0034	99,20	99,90
		20	95,05	0,950 ± 0,0112	94,20	95,90	97,75	0,977 ± 0,0076	97,90	97,60	99,35	0,994 ± 0,0040	99,00	99,70
		30	98,85	0,988 ± 0,0054	98,60	99,10	98,00	0,980 ± 0,0071	97,80	98,20	99,60	0,996 ± 0,0032	99,30	99,90
		40	98,70	0,987 ± 0,0057	98,10	99,30	96,85	0,969 ± 0,0089	96,80	96,90	99,60	0,996 ± 0,0032	99,30	99,90
		50	98,80	0,988 ± 0,0055	98,40	99,20	95,25	0,953 ± 0,0110	95,40	95,10	99,50	0,995 ± 0,0035	99,30	99,70
		64	99,25	0,993 ± 0,0043	98,60	99,90	99,25	0,993 ± 0,0043	98,60	99,90	99,25	0,993 ± 0,0043	98,60	99,90
	Parada Antecipada	10	94,10	0,941 ± 0,0122	94,30	93,95	99,43	0,994 ± 0,0038	99,20	99,65	99,65	0,996 ± 0,0030	99,45	99,85
		20	97,00	0,970 ± 0,0087	96,25	97,75	98,98	0,990 ± 0,0051	98,95	99,00	99,68	0,997 ± 0,0029	99,45	99,90
		30	99,45	0,995 ± 0,0037	99,20	99,70	98,88	0,989 ± 0,0053	98,70	99,05	99,73	0,997 ± 0,0026	99,50	99,95
		40	99,53	0,995 ± 0,0035	99,30	99,75	99,08	0,991 ± 0,0048	99,15	99,00	99,73	0,997 ± 0,0026	99,50	99,95
		50	99,33	0,993 ± 0,0041	99,05	99,60	98,48	0,985 ± 0,0062	98,45	98,50	99,68	0,997 ± 0,0029	99,45	99,90
		64	99,60	0,996 ± 0,0032	99,40	99,80	99,60	0,986 ± 0,0032	98,40	99,80	99,60	0,996 ± 0,0032	99,40	99,80
	Regularização	10	93,10	0,931 ± 0,0133	92,00	94,20	98,25	0,982 ± 0,0067	98,40	98,10	99,50	0,995 ± 0,0035	99,30	99,70
		20	95,50	0,955 ± 0,0107	94,80	96,20	98,20	0,982 ± 0,0068	97,60	98,80	99,50	0,995 ± 0,0035	99,10	99,90
		30	99,15	0,991 ± 0,0046	98,70	99,60	97,20	0,977 ± 0,0076	97,70	97,70	99,60	0,996 ± 0,0032	99,30	99,90
		40	98,95	0,990 ± 0,0051	98,40	99,50	96,60	0,966 ± 0,0093	96,80	96,80	99,65	0,996 ± 0,0030	99,30	100,00
		50	98,75	0,988 ± 0,0056	98,10	99,40	96,25	0,963 ± 0,0098	96,10	96,40	99,65	0,996 ± 0,0030	99,30	100,00
		64	99,45	0,995 ± 0,0037	99,00	99,90	99,45	0,995 ± 0,0037	99,00	99,00	99,45	0,995 ± 0,0037	99,00	99,90

Tabela 4. Resultados médios para acurácia, AUC, sensibilidade e especificidade, para os métodos de treinamento MSE, parada antecipada e regularização para a região de Lábrea

Região	Métodos de parada do treinamento	N. de Caract.	Técnica de Seleção de Características											
			SEC				PCA				LDA			
			Acur.	AUC	Sens	Esp	Acur.	AUC	Sens	Esp	Acur.	AUC	Sens	Esp
Lábrea	MSE	10	92,10	0,921 ± 0,0142	92,30	91,90	98,50	0,985 ± 0,0062	98,40	98,60	99,50	0,995 ± 0,0035	99,50	99,50
		20	93,80	0,938 ± 0,0126	94,20	93,40	97,20	0,972 ± 0,0084	97,00	97,40	99,60	0,996 ± 0,0032	99,70	99,50
		30	96,40	0,964 ± 0,0096	95,70	97,10	95,85	0,958 ± 0,0103	96,20	95,50	99,50	0,996 ± 0,0034	99,50	99,60
		40	97,75	0,977 ± 0,0076	97,20	98,30	94,75	0,948 ± 0,0116	94,90	94,60	99,65	0,996 ± 0,0030	99,60	99,70
		50	99,50	0,995 ± 0,0035	99,30	99,70	93,90	0,939 ± 0,0125	93,70	94,10	99,70	0,997 ± 0,0027	99,60	99,80
		64	99,60	0,996 ± 0,0032	99,30	99,90	99,60	0,996 ± 0,0032	99,30	99,90	99,60	0,996 ± 0,0032	99,30	99,90
	Parada Antecipada	10	95,13	0,951 ± 0,0112	95,10	95,15	98,88	0,989 ± 0,0053	98,80	98,95	99,70	0,997 ± 0,0027	99,60	99,80
		20	95,85	0,959 ± 0,0103	96,00	95,70	98,75	0,987 ± 0,0056	98,90	98,60	99,75	0,998 ± 0,0025	99,65	99,85
		30	97,90	0,979 ± 0,0073	97,55	98,25	97,65	0,976 ± 0,0077	97,25	98,05	99,75	0,997 ± 0,0025	99,65	99,85
		40	98,53	0,985 ± 0,0061	98,35	98,70	98,03	0,980 ± 0,0071	97,95	98,10	99,73	0,997 ± 0,0026	99,70	99,75
		50	99,68	0,997 ± 0,0029	99,60	99,75	95,55	0,956 ± 0,0107	94,95	96,15	99,80	0,998 ± 0,0022	99,80	99,80
		64	99,68	0,997 ± 0,0029	99,60	99,75	99,68	0,997 ± 0,0029	99,60	99,75	99,68	0,997 ± 0,0029	99,60	99,75
	Regularização	10	93,50	0,935 ± 0,0129	92,50	94,50	94,50	0,985 ± 0,0062	95,00	94,00	99,50	0,995 ± 0,0035	99,60	99,40
		20	93,45	0,935 ± 0,0129	94,00	92,90	95,50	0,955 ± 0,0104	95,50	95,50	99,85	0,998 ± 0,0019	99,80	88,90
		30	95,65	0,956 ± 0,0105	95,80	95,50	96,70	0,967 ± 0,0083	97,00	96,40	99,75	0,998 ± 0,0025	99,70	99,80
		40	97,60	0,976 ± 0,0078	97,30	97,90	96,80	0,968 ± 0,0081	96,20	97,40	99,70	0,997 ± 0,0027	99,60	99,80
		50	99,65	0,996 ± 0,0030	99,40	99,90	97,50	0,975 ± 0,0076	97,10	97,90	99,70	0,997 ± 0,0027	99,80	99,60
		64	99,55	0,996 ± 0,0034	99,60	99,50	99,55	0,996 ± 0,0034	99,60	99,50	99,55	0,996 ± 0,0034	99,60	99,50

Em primeiro lugar, observa-se que a técnica LDA, para as três regiões, apresenta o melhor desempenho em relação a esses dois parâmetros. Por exemplo, para a região de Lábrea, para o método de regularização e para 30 variáveis, a área sob a curva de ROC e o desvio padrão obtidos para as técnicas SEC, PCA e LDA foram, respectivamente, $0,956 \pm 0,0105$, $0,967 \pm 0,0083$ e $0,998 \pm 0,0025$. Para esse exemplo, avaliando a significância da diferença entre as duas curvas ROC [Hanley e Mcneil, 1982] das técnicas LDA e SEC, encontramos que $P = 0,000052 < 0,00001$. Então, a hipótese nula deve ser rejeitada (isto é, o desempenho da técnica LDA é superior ao da técnica SEC, ao nível de significância de 0,001%). Para esse exemplo, avaliando a significância da diferença entre as duas curvas ROC das técnicas LDA e PCA, encontramos que $P = 0,000506 < 0,0001$. Então, a hipótese nula deve ser rejeitada (isto é, o desempenho da técnica LDA é superior ao da técnica PCA, ao nível de significância de 0,01%).

Em segundo lugar, com respeito aos métodos de parada da rede neural, observa-se, nas três regiões, uma leve superioridade no desempenho da técnica de parada antecipada frente as outras duas, em relação aos dois parâmetros citados. Por exemplo, para a região de Humaitá, para a técnica PCA e para 50 variáveis a área sob a curva de ROC e o desvio padrão obtidos para os métodos MSE, parada antecipada e regularização foram, respectivamente, $0,953 \pm 0,0110$, $0,985 \pm 0,0062$ e $0,963 \pm 0,0062$. Para esse exemplo, avaliando a significância da diferença entre as duas curvas ROC dos métodos parada antecipada e MSE, encontramos que $P = 0,0054 < 0,01$. Então, a hipótese nula deve ser rejeitada (isto é, o desempenho do método parada antecipada é superior ao do método SEC, ao nível de significância de 1%). Para esse exemplo, avaliando a significância da diferença entre as duas curvas ROC dos métodos parada antecipada e regularização, encontramos que $P = 0,0278 > 0,01$. Então, a hipótese nula não deve ser rejeitada (isto é, o desempenho do método parada antecipada não é superior ao do método regularização, ao nível de significância de 1%).

Em terceiro lugar, observa-se, com respeito ao número de características, que para os métodos SEC e PCA, via de regra o desempenho com 64 características é melhor do que o desempenho com um número menor de características, em relação as variáveis anteriormente citadas. Por exemplo, para a região de Apuí, para a técnica PCA e parada o método de parada antecipada, a área sob a curva de ROC e o desvio padrão obtidos para 10 e 64 variáveis foram, respectivamente, $0,973 \pm 0,0082$ e $0,999 \pm 0,0014$. Para esse exemplo, avaliando a significância da diferença entre as duas curvas ROC dos métodos parada antecipada e MSE, encontramos que $P = 0.00102 < 0,01$. Então, a hipótese nula deve ser rejeitada (isto é, o desempenho com 64 variáveis é superior ao desempenho com 10 variáveis, ao nível de significância de 1%).

O método proposto nesse trabalho foi comparado com: [Reis, 2014], [Pimentel, 2014] e [Zanotta, 2014]. Na mesma região utilizada por [Reis, 2014], o melhor desempenho foi obtido utilizando-se o método regularização associado à técnica LDA e 64 características, com uma acurácia média de 96,97%. Esse resultado foi superior àquele obtido pelo referido autor, uma acurácia de 84,2%. O autor trabalhou com oito características e utilizou o classificador de Mínima Distância Estocástica. Na região utilizada por [Pimentel, 2014], o melhor desempenho foi obtido utilizando-se o método de regularização associado à técnica LDA e com 64 características, com uma acurácia média de 96,94%. Esse resultado foi ligeiramente melhor que aquele obtido pelo referido autor, uma acurácia de 96,05%. O autor trabalhou com 1300 amostras e utilizou redes neurais como classificador. Na região utilizada por [Zanotta, 2014], o melhor desempenho foi obtido utilizando-se regularização associado à técnica LDA e com 64 características, com uma acurácia média de 96,95%. Esse resultado foi bem superior àquele obtido pelo referido autor, uma acurácia de 82%. O autor trabalhou com apenas 3 características e com o classificador baseado na análise do vetor de mudanças.

4. Conclusões

Os resultados mostraram a importância de se avaliar o resultado da combinação de novos métodos de generalização com técnicas de seleção de características. A técnica de seleção LDA apresentou um melhor desempenho em relação às técnicas SEC e PCA. O método Parada Antecipada apresentou um desempenho levemente superior em relação aos métodos de Regularização e MSE. Em relação à técnica LDA, observamos que o número de características utilizadas não tem influência sobre o desempenho do classificador. Como principal conclusão desse trabalho, ressaltamos que, em função das altas taxas de acurácia e de AUC obtidas, recomenda-se fortemente a utilização de técnicas de extração de características, juntamente com métodos de generalização de redes neurais, para classificação de áreas desmatadas, obtidas a partir de imagens óticas. Em trabalhos futuros, propõe-se expandir a área geográfica de estudos, selecionando mais regiões do país, e utilizando-se classes de uso do solo mais variadas. Pretende-se também utilizar redes convolutivas para classificação das áreas desmatadas.

Referências

Blum, A., Kalai, A., Langford, J. (1999) "Beating the hold-out: Bounds for k-fold and progressive crossvalidation". In Proceedings of the twelfth annual conference on Computational learning theory, ACM, pages 203-208

- Hagan, M. T., Demuth, H. B., Beale, M. H. (1995) *Neural Network Design*. [S.l.]: PWS Pub., apud GIL, A. M. (2014) *Reconhecimento de dígitos manuscritos: busca de um classificador com máxima taxa de acerto*. In *Dissertação de Mestrado do Curso de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, Manaus*.
- Hanley, J. A and McNeil, B. J. (1982) *The meaning and Use of the Area under a Receiver Operating Characteristic (ROC) Curve*. *Radiology*; 143(1):29-36.
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., and Ferreira, L.G. (2002) *Overview of the radiometric and biophysical performance of the MODIS vegetation indices*, *Remote Sensing of Environment*, Volume 83, Issues 162, November, Pages 195-213.
- Inpe ó Instituto Nacional de Pesquisas Especiais. (2017) *Projeto PRODES*, <http://www.obt.inpe.br/prodes/index.php>, Janeiro.
- Jensen, J. R. (2009) *Sensoriamento Remoto do Ambiente. Uma perspectiva em recursos terrestres*. Tradução de José Carlos N. Epiphanyo, Antonio R. Formaggio, Athos R. Santos, Bernardo F. T. Rudorff, Cláudia M. Almeida, Lênio S. Galvão. São José dos Campos, SP. Editora Parêntese.
- Noma, A., Körting, T. S., Fonseca, L. M. G. (2013) *Uma Comparação entre Classificadores usando Regiões e Índices EVI para Agricultura*. In *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Foz do Iguaçu, PR, Brasil*.
- Novo, E. M. L. M. (2008) *Sensoriamento Remoto: Princípios e Aplicações*. 3ª edição. São Paulo: Editora Edgard Blücher Ltda. 363p.
- Pimentel, T. R. G. (2014) *Classificação de padrões temporais de uso do solo e cobertura da terra em séries temporais de índice de vegetação utilizando um sistema neuro-difuso*. São José dos Campos. 2014. *Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada do INPE, São José dos Campos*.
- Reis, M. (2014) *Detecção de mudanças de uso e cobertura da terra utilizando dados óticos e de micro-ondas em uma região da Amazônia Brasileira*. São José dos Campos. *Dissertação de Mestrado do Curso de Pós-Graduação em Sensoriamento Remoto do INPE, São José dos Campos*.
- Symeonakis, E. (2016) *Modelling land cover change in a mediterranean environment using random forests and a multi-layer neural network model*. In *Geoscience and Remote Sensing Symposium (IGARSS), IEEE International*.
- Theodoridis, S.; Koutroumbas, K. (2008) *Pattern Recognition*. San Diego, California: Academic Press. 984 pages.
- Usgs - United States Geological Survey (2017) *What are the best spectral bands to use for my study?*, <https://landsat.usgs.gov/what-are-best-spectral-bands-use-my-study>, Maio.
- Zanotta, D. C. (2014) *Uma metodologia adaptativa baseada em objetos para detecção semi-automática de desmatamento na Amazônia por imagens de sensoriamento remoto*. Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto do INPE, São José dos Campos.