

Comparação de métodos de classificação da cobertura do solo urbano utilizando imagens IKONOS II com e sem o auxílio de dados LiDAR

Leonardo Rodrigues de Deus¹

Rafael Santos¹

Leila Maria G. Fonseca¹

¹Instituto Nacional de Pesquisas Espaciais

ldedeus@dpi.inpe.br; rafael.santos@lac.inpe.br; leila@dpi.inpe.br

Abstract

This study aims to use remote sensing data, comprising images of the IKONOS sensor II and LiDAR data, to classify urban land cover, and to evaluate whether LiDAR data can provide more precise classification results. We used three different classification methods implemented in the Weka software: IBK, J48, and MLP to process the data. The results showed that, for all classifiers, the use of IKONOS II images in association with LiDAR data enabled the urban land cover be classified more accurately, improving the accuracy by 5% for the study area.

1. Introdução

Os dados de sensoriamento remoto de alta resolução são uma fonte importante de informação a respeito das áreas urbanas, visto que as imagens produzidas possuem alta resolução espacial, o que permite uma melhor discriminação das feições presentes na cena.

No processo de extração de informações, as imagens de sensoriamento remoto, normalmente, são classificadas utilizando métodos automáticos para distinção entre as classes de cobertura do solo que são de interesse em cada aplicação.

Contudo, as imagens de alta resolução espacial possuem baixa resolução espectral, compreendendo apenas a faixa de comprimento de onda do visível e infravermelho próximo o que, segundo Pinho et al. (2007), dificulta a distinção de uma série de alvos urbanos que apresentam comportamento espectral semelhante para estes comprimentos de onda, como é o caso de ruas pavimentadas com asfalto e edificações com cobertura de amianto escuro.

Dessa forma, é necessário que novos métodos sejam desenvolvidos para auxiliar nos processos de classificação automática das imagens.

Nesse contexto, o uso combinado de imagens multiespectrais IKONOS II com dados LiDAR, pode melhorar a precisão da classificação da cobertura do solo, uma vez que os dados LiDAR fornecem informação de

altura dos objetos. Esta informação pode favorecer a discriminação entre alvos que apresentam respostas espectrais semelhantes, mas possuem diferença de altura, como telhado e solo exposto.

LiDAR (Light Detection and Ranging) é um sistema topográfico que se baseia na emissão de milhares de pulsos laser de luz infravermelha por segundo, e no registro do retorno do sinal. O sistema realiza tarefas como: medir as distâncias até os alvos, a intensidade da energia refletida pelo objeto e os parâmetros de atitude do feixe (azimute e elevação), podendo assim determinar com precisão as elevações da superfície (JENSEN, 2009).

O objetivo deste estudo consiste em utilizar imagens do sensor IKONOS II e dados LiDAR para classificar a cobertura do solo urbano e avaliar se a informação de altura fornecida pelo dado LiDAR possibilita uma melhora dos resultados da classificação. Além disso, três métodos de classificação baseados em técnicas de mineração de dados são analisados.

2. Metodologia

A área de estudo deste trabalho consiste de uma porção central da cidade de Uberlândia-MG, a qual coincide com a região da cidade que apresenta a maior aglomeração de edificações verticalizadas (TÓMAS, 2010), onde foram selecionadas diversas amostras para testar os classificadores.

Foram utilizados dois tipos de dados para a realização do trabalho: imagens multiespectrais do sensor IKONOS II e dados LiDAR.

A imagem IKONOS II é uma imagem óptica, fusionada, com 1 metro de resolução espacial e composta por 4 bandas espectrais, correspondentes às faixas do azul (0,45 – 0,52 μ , Banda 1), verde (0,52 – 0,60 μ , Banda 2), vermelho (0,63 – 0,69 μ , Banda 3) e infravermelho próximo (0,76 – 0,90 μ , Banda 4). A Figura 1 mostra a imagem IKONOS II, composição colorida, da área de estudo.

Em relação aos dados LiDAR, foram utilizados dois arquivos raster, com tamanho de pixel de 1 metro. O primeiro, mostrado na Figura 2, corresponde ao Modelo

Digital de Altura (MDA) da área de estudo, o qual é resultado da subtração entre o Modelo Digital de Superfície (MDS), primeiro retorno do pulso laser, e o Modelo Digital de Terreno (MDT), último retorno do pulso laser, obtidos a partir da nuvem de pontos LiDAR. Nesse arquivo raster cada pixel da imagem apresenta um valor de altitude referente aos alvos que foram atingidos pelos pulsos emitidos pelo equipamento. O segundo arquivo, Figura 3, é uma imagem Intensidade, que corresponde à intensidade da energia refletida pelos objetos atingidos pela luz infravermelha emitida pelo equipamento.



Figura 1. Imagem IKONOS II da área de estudo.




Figura 2. Imagem MDA da área de estudo.

Dois experimentos, com diferentes grupos de dados foram realizados: (1) utilizando quatro bandas do sensor IKONOS II; (2) utilizando quatro bandas do sensor IKONOS II em conjunto com as imagens MDA e Intensidade, geradas a partir da nuvem de pontos do sistema LiDAR.




Figura 3. Imagem Intensidade da área de estudo.

Para realizar a classificação da cobertura do solo urbano foi utilizado o software Weka (Waikato Environment for Knowledge Analysis), o qual é uma coleção de algoritmos de aprendizagem de máquina para realizar tarefas de mineração de dados, que contem várias ferramentas para pré-processamento dos dados e visualização, além de algoritmos para regressão, classificação, agrupamentos, mineração de regras de associação e seleção de atributos (HALL et al., 2009).

Os classificadores utilizados neste estudo foram: IBK, que é um algoritmo de aprendizagem baseado em instâncias (Instance-Based Learning – IBL); J48, que é um classificador na forma de uma árvore de decisão, baseado no algoritmo C4.5; e o classificador *Multi-Layer Perceptron* (MLP), que é um tipo de rede neural artificial que usa um sistema de aprendizado supervisionado por correção de erros (retropropagação) para prever a classificação das instâncias analisadas.

Para o classificador IBK, foram utilizados valores de K iguais a 1,3,5,8,11,15. O parâmetro K corresponde ao número de vizinhos mais próximos utilizados no processo. Em relação ao classificador MLP, o mesmo foi executado utilizando 1, 5, 10, 25 e 50 neurônios em uma camada escondida para avaliar sua eficiência na classificação.

Devido ao grande número de alvos urbanos, foram selecionadas amostras de 12 classes de cobertura do solo: asfalto, edifício, piscina, solo exposto, sombra, telhado azul, telhado branco, telhado escuro, telhado marrom, telhado marrom escuro, vegetação e vegetação rasteira. A Figura 4 mostra uma das amostras selecionadas para cada uma das 12 classes.

Com base no conjunto de amostras das classes de cobertura do solo uma tabela de dados foi gerada, onde cada pixel das amostras refere-se a uma instância e o valor associado a cada pixel, em cada uma das imagens, IKONOS II e LiDAR, refere-se a um atributo da tabela, bem como a classe de cobertura do solo determinada para as amostras selecionadas. A Figura 5 mostra parte da

tabela gerada, contendo as instâncias e os atributos utilizados para prever a classificação da cobertura do solo.

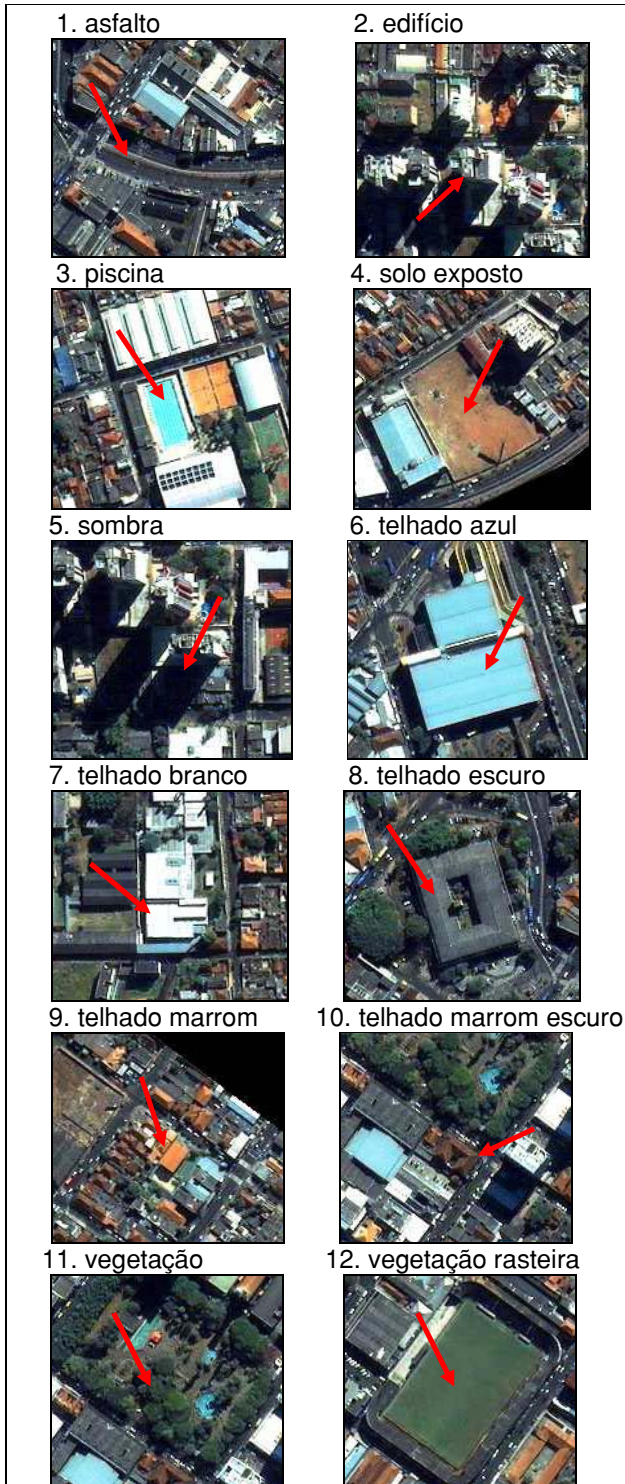


Figura 4. Amostras dos alvos considerados

No.	ikonos_b1 Numeric	ikonos_b2 Numeric	ikonos_b3 Numeric	ikonos_b4 Numeric	mda Numeric	intensidade Numeric	classe Nominal
2266	581.0	629.0	741.0	740.0	4.34082	37.596031	TELHADO_MARROM_ESCURO
2274	301.0	316.0	362.0	378.0	5.312073	37.596031	TELHADO_MARROM_ESCURO
462	670.0	750.0	750.0	634.0	0.050049	37.596367	SOLO_EXPOSTO
522	565.0	630.0	627.0	533.0	0.046997	37.596367	SOLO_EXPOSTO
582	640.0	713.0	708.0	585.0	0.051697	37.596367	SOLO_EXPOSTO
29371	557.0	564.0	434.0	343.0	40.494873	37.599899	EDIFICIO
29376	568.0	548.0	421.0	355.0	42.724548	37.599899	EDIFICIO
25778	524.0	533.0	571.0	608.0	3.283081	37.607563	TELHADO_MARROM_ESCURO
25798	395.0	398.0	416.0	468.0	3.447083	37.607563	TELHADO_MARROM_ESCURO
2545	359.0	232.0	153.0	145.0	1.717651	37.60828	SOMBRA
2563	367.0	234.0	155.0	151.0	2.863647	37.60828	SOMBRA
2581	364.0	230.0	154.0	155.0	4.410095	37.60828	SOMBRA
1115	647.0	722.0	645.0	586.0	-0.016235	37.616226	SOLO_EXPOSTO
31891	474.0	376.0	293.0	327.0	4.877686	37.61623	TELHADO_ESCURO
13651	1512.0	1597.0	1491.0	1332.0	3.368652	37.616688	TELHADO_BRANCO
13712	1490.0	1569.0	1458.0	1259.0	3.440918	37.616688	TELHADO_BRANCO
20700	681.0	832.0	835.0	713.0	-0.045959	37.618652	SOLO_EXPOSTO
20783	699.0	865.0	867.0	749.0	-0.010559	37.618652	SOLO_EXPOSTO
29563	712.0	789.0	633.0	461.0	70.72052	37.619015	EDIFICIO
29571	677.0	717.0	602.0	462.0	70.886719	37.619015	EDIFICIO
29579	689.0	705.0	607.0	474.0	70.995605	37.619015	EDIFICIO
31071	595.0	528.0	399.0	397.0	4.628723	37.62077	TELHADO_ESCURO
26410	331.0	231.0	158.0	588.0	2.87793	37.623207	VEGETACAO
26411	512.0	406.0	278.0	866.0	-0.110107	37.623207	VEGETACAO

Figura 5. Amostras da tabela de atributos.

3. Resultados e Discussões

3.1 Resultados para o Classificador IBK

A Tabela 1 sintetiza os resultados da precisão com que os dados amostrais foram classificados utilizando o classificador IBK com os diferentes valores de K.

Tabela 1: Resultados para o Classificador IBK

K	Precisão das Instâncias Classificadas Corretamente (%)	
	IKONOS II	IKONOS II + LiDAR
1	100	100
3	97,0635	99,6853
5	96,6326	99,5478
8	96,0918	99,3644
11	95,7801	99,2605
15	95,5448	99,1658

Analisando a Tabela 1 observa-se que, para os dois experimentos, a aplicação do classificador IBK com K igual a 1 foi perfeita, apresentando 100% de precisão para as instâncias classificadas.

A Tabela 1 mostra ainda que, à medida que o valor de K aumenta, a precisão das instâncias classificadas corretamente diminui, e que o uso do dado LiDAR melhora os resultados da classificação.

Esse resultado indica que o conjunto de amostras apresenta uma grande mistura de informações, visto que o classificador com K igual a 1 apresentou os melhores resultados, e independe de quanto se aumente este valor, os resultados são sempre piores, indicando que os dados amostrais não se caracterizam pela presença de *outliers*,

que podem ser ruído no espaço amostral do conjunto de dados.

As matrizes de confusão geradas na predição da classificação com diferentes valores de K, para o segundo experimento, o qual apresentou os melhores resultados, mostraram, como pode ser visto na Figura 6, que as classes piscina, sombra e vegetação rasteira tiveram 100% de acerto independente do número de vizinhos mais próximo utilizados, mostrando que os atributos utilizados foram excelentes para distinguir estes 3 tipos de alvos com a aplicação deste classificador.

Para leitura das figuras que mostram matrizes de confusão deve-se considerar:

- . a = asfalto
- . b = piscina
- . c = solo exposto
- . d = sombra
- . e = edifício
- . f = telhado azul
- . g = telhado branco
- . h = telhado escuro
- . i = telhado marrom
- . j = telhado marrom escuro
- . k = vegetação
- . l = vegetação rasteira

Valor de K	a	b	c	d	e	f	g	h	i	j	k	l	<-- Classificado como
1	0	652	0	0	0	0	0	0	0	0	0	0	b = piscina
3	0	652	0	0	0	0	0	0	0	0	0	0	
5	0	652	0	0	0	0	0	0	0	0	0	0	
8	0	652	0	0	0	0	0	0	0	0	0	0	
11	0	652	0	0	0	0	0	0	0	0	0	0	
15	0	652	0	0	0	0	0	0	0	0	0	0	
1	0	0	0	1830	0	0	0	0	0	0	0	0	d = sombra
3	0	0	0	1830	0	0	0	0	0	0	0	0	
5	0	0	0	1830	0	0	0	0	0	0	0	0	
8	0	0	0	1830	0	0	0	0	0	0	0	0	
11	0	0	0	1830	0	0	0	0	0	0	0	0	
15	0	0	0	1830	0	0	0	0	0	0	0	0	
1	0	0	0	0	0	0	0	0	0	0	0	5751	l = vegetacao rasteira
3	0	0	0	0	0	0	0	0	0	0	0	5751	
5	0	0	0	0	0	0	0	0	0	0	0	5751	
8	0	0	0	0	0	0	0	0	0	0	0	5751	
11	0	0	0	0	0	0	0	0	0	0	0	5751	
15	0	0	0	0	0	0	0	0	0	0	0	5751	

Figura 6. Matriz de confusão das classes piscina, sombra e vegetação rasteira - Classificador IBK

Outra classe que também foi muito bem discriminada foi a classe Telhado Azul, que só não teve 100% de acerto para todos os valores de K utilizados porque para K igual a 3, uma única instância foi classificada como Telhado Branco.

Para as demais classes de cobertura do solo, os resultados mostraram que à medida que o valor de K aumentou as confusões entre as classes também aumentaram. A maior parte das confusões observadas refere-se a alvos que possuem características espectrais semelhantes, como asfalto e telhado escuro ou solo exposto e telhado marrom escuro, por exemplo, como mostra a Figura 7.

Valor de K	a	b	c	d	e	f	g	h	i	j	k	l	<-- Classificado como
1	291	0	0	0	0	0	0	0	0	0	0	0	a = asfalto
3	284	0	0	0	0	0	0	7	0	0	0	0	
5	277	0	0	0	0	0	0	14	0	0	0	0	
8	276	0	0	0	0	0	0	15	0	0	0	0	
11	271	0	0	0	0	0	0	20	0	0	0	0	
15	265	0	0	0	0	0	0	26	0	0	0	0	
1	0	0	2566	0	0	0	0	0	0	0	0	0	c = solo exposto
3	0	0	2561	0	0	0	0	0	1	4	0	0	
5	0	0	2560	0	0	0	0	0	0	6	0	0	
8	0	0	2559	0	0	0	0	0	0	7	0	0	
11	0	0	2558	0	0	0	0	0	0	8	0	0	
15	0	0	2557	0	0	0	0	0	0	9	0	0	

Figura 7. Matriz de confusão das classes asfalto e solo exposto - Classificador IBK

Mas algumas confusões não eram esperadas, como é caso da confusão da classe asfalto e telhado escuro, mostrada na Figura 7, e vegetação e vegetação rasteira, Figura 8, visto que com a utilização Modelo Digital de Altura (MDA) os alvos com alturas diferentes deveriam ser bem discriminados. Isto indica que o MDA utilizado deve ser revisto no intuito de avaliar se não existem áreas com erros de altitudes.

Valor de K	a	b	c	d	e	f	g	h	i	j	k	l	<-- Classificado como
1	0	0	0	0	0	0	0	0	0	0	3000	0	k = vegetacao
3	0	0	0	0	0	0	0	1	0	0	2997	2	
5	0	0	0	1	0	0	0	1	0	0	2993	5	
8	0	0	0	4	0	0	0	1	0	0	2987	8	
11	0	0	0	4	0	0	0	0	0	0	2986	10	
15	0	0	0	7	0	0	0	0	0	0	2981	12	

Figura 8. Matriz de confusão da classe vegetação - Classificador IBK

Contudo, de maneira geral, os resultados obtidos com a utilização do classificador IBK mostraram que a utilização de imagem óptica em conjunto com dados LiDAR, embora tenha apresentado algumas confusões, inclusive entre alvos de alturas diferentes, favorece para que se obtenha uma classificação da cobertura do solo urbano com alto grau de precisão, visto que a classificação das amostras de teste sempre alcançou resultados acima de 99% de precisão, como mostrado na Tabela 1.

3.2 Resultados para o Classificador J48

A Tabela 2 apresenta os resultados gerais obtidos com o classificador J48.

Os resultados apresentados na Tabela 2 indicam que o uso das imagens IKONOS II juntamente com os dados LiDAR é a melhor opção para classificar a cobertura do

solo urbano, obtendo um ganho de aproximadamente 3% na precisão da classificação.

Tabela 2: Resultados para o Classificador J48

Atributos	Precisão das Instâncias Classificadas Corretamente (%)	Número de Folhas	Tamanho da Árvore
IKONOS II	96,984	453	905
IKONOS II + LiDAR	99,6639	230	459

Com mais atributos para classificar a cobertura do solo, o número de folhas da árvore de decisão diminui e conseqüentemente o tamanho da árvore também, indicando uma menor necessidade de recursos computacionais no processo.

A análise das matrizes de confusão, utilizando o classificador J48, mostrou também que quando se utiliza apenas as bandas do satélite IKONOS II para predição da classificação da cobertura do solo urbano, o grau de confusão entre as classes analisadas é maior, diminuindo com a utilização dos dados LiDAR no processo.

Usando dados LiDAR, o número de instâncias classificadas incorretamente é praticamente irrelevante frente ao número total de instâncias pertencentes a cada classe, como pode ser visto na Figura 9. Do total de 32.726 amostras, apenas 110 foram classificadas incorretamente, o que representa menos de 0,4% dos dados classificados.

a	b	c	d	e	f	g	h	i	j	k	l	<.. Classificado como
285	0	0	0	0	0	0	6	0	0	0	0	a = asfalto
0	652	0	0	0	0	0	0	0	0	0	0	b = piscina
0	0	2558	0	0	0	0	0	2	6	0	0	c = solo exposto
0	0	0	1829	0	0	0	0	0	0	1	0	d = sombra
0	0	0	0	1282	0	14	11	1	0	0	0	e = edifício
0	0	0	0	0	5637	1	0	0	0	0	0	f = telhado azul
0	0	0	0	2	3	4290	3	0	3	0	0	g = telhado branco
0	0	3	0	1	4	8	4864	1	1	1	0	h = telhado escuro
0	0	4	0	0	0	1	0	875	2	0	0	i = telhado marrom
0	0	13	0	0	0	0	10	4	1597	0	0	j = telhado marrom escuro
2	0	0	0	1	0	0	0	0	1	2996	0	k = vegetação
0	0	0	0	0	0	0	0	0	0	0	5751	l = vegetação rasteira

Figura 9. Matriz de confusão segundo grupo de atributos - Classificador J48

A Figura 9 mostra que, dentre as confusões que mais se destacam, tem-se a classe Edifício que foi classificada como Telhado Branco e Telhado Escuro, o que provavelmente deve-se ao fato de as amostras da classe Edifício conterem prédios que tem telhados compostos

por materiais diferentes, e a classe Telhado Marrom Escuro que teve algumas instâncias classificadas como Telhado Escuro e como Solo Exposto.

Mais uma vez observa-se que alvos com diferença de altitude, embora para um número bastante reduzido de instâncias, apresentaram confusões, ressaltando a necessidade de revisão do arquivo MDA utilizado.

A análise da árvore de decisão obtida com a utilização conjunta das imagens ópticas e dados LiDAR, apresentou no topo da árvore as bandas 1 e 4 do satélite IKONOS II, como mostra a Figura 10.




Figura 10. Topo da árvore de decisão gerada pelo Classificador J48 para o segundo grupo de atributos.

Conforme exposto por Sousa e Kux (2005), os alvos urbanos apresentam respostas espectrais diferentes para as faixas do azul e do infravermelho do espectro eletromagnético, justificando então o fato destas duas bandas estarem no topo da árvore de decisão.

Observou-se ainda, pela árvore gerada que o atributo MDA também aparece nas camadas mais altas da árvore distinguindo algumas instâncias da classe Edifício dos demais alvos.

Comparando os resultados obtidos pelo classificador J48 frente aos resultados obtidos pelo classificador IBK, observa-se que a diferença de precisão entre as instâncias classificadas corretamente considerando apenas o uso do segundo grupo de atributos pode ser considerada irrelevante, uma vez todos os resultados estiveram acima de 99% de precisão. Contudo, o classificador J48 leva uma grande vantagem na questão do tempo de processamento, apresentando o resultado em pouco mais de 5 segundos, enquanto o IBK levou aproximadamente 5 minutos para predizer a classificação para o mesmo grupo de atributos.

3.3 Resultados Classificador MLP

A Tabela 3 mostra os resultados das instâncias classificadas corretamente a partir da utilização do classificador MLP.

Analisando a Tabela 3, observa-se que à medida que o número de camadas escondidas aumenta a porcentagem de instâncias classificadas corretamente também aumenta. E da mesma forma que para os outros dois classificadores testados, o uso de dados IKONOS e LiDAR em conjunto melhora a precisão da classificação.

Tabela 3: Resultados Classificador MLP

Número de Camadas Escondidas	Precisão das Instâncias Classificadas Corretamente (%)	
	IKONOS II	IKONOS II + LiDAR
1	56,5576	59,2281
5	91,4838	97,6135
10	92,8008	99,0008
25	95,8504	99,3919
50	95,7679	99,4653

Em relação ao segundo experimento (IKONOS + LiDAR) observou-se que, ao se utilizar apenas uma camada escondida, o classificador não consegue distinguir as classes consideradas, classificando todas as instâncias em apenas 5 classes diferentes, Telha Azul, Telhado Branco, Telhado Escuro, Vegetação e Vegetação Rasteira, como mostra a Figura 11, obtendo 100% de erro para as instâncias pertencentes às demais classes.

À medida que o número de camadas escondidas aumenta a confusão entre as classes diminui gradativamente.

Usando 50 camadas escondidas, a confusão entre as classes é mínima, e está relacionada com os alvos que possuem respostas espectrais semelhantes.

a	b	c	d	e	f	g	h	i	j	k	l	<-- Classificado como
285	0	0	0	1	0	0	5	0	0	0	0	a = asfalto
0	652	0	0	0	0	0	0	0	0	0	0	b = piscina
0	0	2556	0	0	0	0	0	1	9	0	0	c = solo exposto
0	0	0	1830	0	0	0	0	0	0	0	0	d = sombra
0	0	0	0	1246	0	51	11	0	0	0	0	e = edifício
0	0	0	0	0	5637	1	0	0	0	0	0	f = telhado azul
0	0	0	0	2	3	4273	15	2	6	0	0	g = telhado branco
4	0	0	1	1	0	3	4870	1	3	0	0	h = telhado escuro
0	0	5	0	0	0	0	0	871	6	0	0	i = telhado marrom
0	0	16	0	0	0	0	22	2	1584	0	0	j = telhado marrom escuro
0	0	0	0	0	0	0	1	0	0	2997	2	k = vegetação
0	0	0	0	0	0	0	0	0	0	1	5750	l = vegetação rasteira

Figura 11. Matriz de confusão Classificado MLP com 50 camadas escondidas.

Para analisar se a precisão do classificador MLP atingiria 100%, o classificador foi testado com números maiores de camadas escondidas, 100, 200 e 500.

Os resultados obtidos mostraram que de 10 até 200 camadas escondidas a precisão de instâncias classificadas corretamente é praticamente a mesma, com 99% de precisão, variando o valor apenas nas casas decimais. Com mais de 200 camadas escondidas o classificador perdeu a precisão, estando com 500 camadas escondidas com 97% de precisão.

O classificador MLP, em relação os dois classificadores empregados, apresentou uma desvantagem significativa relacionada ao custo computacional para

realizar a predição da classificação. O tempo de processamento ao utilizar este classificador é bem mais alto do que ao se utilizar o classificador IBK ou o J48.

4. Considerações Finais

Os resultados obtidos usando os três classificadores mostraram que as bandas do sensor IKONOS II são capazes de distinguir os alvos que compõem a cobertura do solo urbano. Porém, a utilização dos dados LiDAR propiciou uma melhora na precisão das instâncias classificadas corretamente da ordem de 5%.

Então, havendo a disponibilidade de dados LiDAR para realização da classificação da cobertura do solo urbano, estes devem ser empregados em conjunto com os dados de imagens ópticas para melhorar os resultados da classificação de áreas urbanas.

Em relação aos classificadores, o classificador J48 apresentou a melhor relação custo benefício, pois o tempo de processamento computacional foi bem inferior aos demais, e a precisão foi tão alta quanto qualquer outro. No entanto vale a pena ressaltar que o conjunto de regras gerado foi muito grande para ser interpretado.

5. Referências Bibliográficas

Pinho, C. M. D.; Almeida, C. M.; Kux, H. J. H.; Rennó, C. D.; Fonseca, L. M. G. Classificação de cobertura do solo de ambientes intra-urbanos utilizando imagens de alta resolução espacial e classificação orientada a objetos. In: Almeida, C. M.; Câmara, G.; Monteiro, A. M. V. (Ed.). **Geoinformação em urbanismo: cidade real x cidade virtual**. São Paulo: Oficina de Textos, 2007. cap. 8, p. 171-192.

Jensen, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. 2ª ed. São José dos Campos: Parêntese, 2009, 598 p.

Tomás, Livia Rodrigues. **Inferência populacional urbana baseada no volume de edificações residenciais usando imagens IKONOS-II e dados LiDAR**. 2010. 130p. (INPE-16712-TDI/1651). Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos. 2010.

Hall, M.; Frank, E.; Holmes, G.; Pfahringer, B.; Reutemann, P.; Witten, I. H. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v. 11, n. 1, p. 10-18, 2009.

Sousa, R. C. A.; Kux, H. J. H. Comportamento espectral e alvos urbanos: simulação com as bandas espectrais do satélite CBERS. SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12, 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p. 1-8. Disponível em: <http://www.obt.inpe.br/cbers/cbers_XIISBSR/351_comp_esp_urbano.pdf>. Acesso em: 05 Out 2010.