



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2020/01.07.11.40-PUD

ESTUDOS E TÉCNICAS DE MAPEAMENTO DE VEGETAÇÃO URBANA

Mayumi Cursino de Moura Hirye

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3UN44CH>>

INPE
São José dos Campos
2020

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2020/01.07.11.40-PUD

ESTUDOS E TÉCNICAS DE MAPEAMENTO DE VEGETAÇÃO URBANA

Mayumi Cursino de Moura Hirye

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3UN44CH>>

INPE
São José dos Campos
2020



Esta obra foi licenciada sob uma Licença Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada.

This work is licensed under a Creative Commons Attribution-NonCommercial 3.0 Unported License.

LISTA DE FIGURAS

Pág.

Figura 1 – Ano, tipo de imagem e de mapeamento da vegetação urbana em artigos selecionados para análise.	2
---	---

LISTA DE TABELAS

Pág.

Tabela 1 – Tipo de imagem, localização dos estudos, classes consideradas, método de classificação e resultados do mapeamento da vegetação urbana.....	4
Tabela 2 – Tipo de imagem e métodos para o mapeamento da fração de vegetação urbana.....	8
Tabela 3 – Tipo de imagem, métodos de classificação, espécies ou gêneros de vegetação urbana considerados e resultados obtidos.....	11
Tabela 4 – Característica física da vegetação urbana e tipo de imagem usada.....	14
Tabela 5 – Tipo de imagem e característica biológica da vegetação urbana.....	16

SUMÁRIO

	<u>Pág.</u>
1. A vegetação urbana e sua função na cidade	1
2. Estudos e métodos de mapeamento da vegetação urbana	2
2.1. Mapeamento da cobertura vegetal.....	3
2.2. Mapeamento da fração de vegetação.....	8
2.3. Mapeamento de espécies ou gêneros de vegetação	10
2.4. Mapeamento de características físicas da vegetação	14
2.5. Mapeamento de características biológicas da vegetação.....	16
3. Perspectivas futuras.....	19
Bibliografia.....	20

1. A VEGETAÇÃO URBANA E SUA FUNÇÃO NA CIDADE

A vegetação urbana abrange desde as espécies de vegetação rasteira, as trepadeiras e as árvores de pequeno, médio e grande porte. Abrange também toda vegetação localizada em parques e praças, unidades de conservação como as áreas de preservação permanente, jardins, cemitérios, campos de prática esportiva, hortas, calçadas e canteiros, tetos e paredes verdes, além de áreas abandonadas.

Do ponto de vista do planejamento urbano, interessam, não somente o tipo de feição da vegetação, mas também sua localização. Do ponto de vista ecológico, interessam também características biofísicas da vegetação e suas condições biológicas. Inventários de vegetação urbana, frequentemente identificam, além dessas características, a espécie ou o gênero da vegetação e as condições do ambiente onde ela se encontra.

Os benefícios da vegetação no meio urbano estão relacionados à redução do escoamento superficial das águas pluviais, à melhoria das condições microclimáticas (temperatura, vento, radiação solar e umidade) e a consequente redução do consumo de energia para aquecimento ou resfriamento dos edifícios, à melhoria da qualidade do ar, à diminuição da poluição sonora e ao sequestro de dióxido de carbono da atmosfera. Outros benefícios estão relacionados à possibilidade de abrigar a fauna, em especial a avifauna, e aumentar a diversidade biológica, além de proteger nascentes, mananciais e áreas de instabilidade geotécnica. Além disso, destacam-se benefícios de difícil mensuração como a melhoria do bem-estar psicológico ou da saúde humana, a valorização imobiliária e estética do entorno das áreas vegetadas.

2. ESTUDOS E MÉTODOS DE MAPEAMENTO DA VEGETAÇÃO URBANA

Os artigos selecionados para esta revisão bibliográfica foram identificados em revistas de indexadas, com revisão por pares, de temática vinculada ao sensoriamento remoto ou estudos urbanos. A partir de uma lista inicial de artigos, procedeu-se a seleção daqueles que apresentavam ou comparavam técnicas, novas metodologias para o mapeamento da vegetação urbana ou resultados com diferentes sensores. Os artigos selecionados referem-se à vegetação de distintas cidades do mundo e foram agrupados de acordo com o objeto do mapeamento: obtenção da fração de cobertura vegetal, classificação de diferentes feições de cobertura vegetal, identificação de espécies ou gêneros de vegetação, mapeamento de características físicas ou características biológicas da vegetação.

De uma maneira geral, os artigos mais recentes se concentram sobre o mapeamento de características biofísicas da vegetação, assim como o de espécies ou gêneros (Figura 1). A maioria desses mapeamentos são feitos com a maior resolução espectral (HIPER) ou com dados de sensores ativos (SAR e LiDAR), isoladamente ou conjuntamente. Alguns mapeamentos utilizam também dados LiDAR em conjunto com imagens multiespectrais de resolução espacial muito alta (VHR), com menos de 5m.

A vegetação como uma classe de cobertura do solo urbano é o tipo de mapeamento mais recorrente, feito com diferentes tipos de imagens, com destaque para as multiespectrais de resolução espacial muito alta (VHR). Imagens multiespectrais de resolução espacial fina (FR), de 5m a 100m, foram particularmente utilizadas para a obtenção da fração de vegetação; nos últimos dois anos, foram identificados dois estudos com imagens hiperespectrais (Figura 1).




Figura 1 – Ano, tipo de imagem e de mapeamento da vegetação urbana em artigos selecionados para análise.

2.1. Mapeamento da cobertura vegetal

O mapeamento da cobertura da vegetação é justificado pela sua importância para o planejamento urbano, para a tomada de decisões e para a aferição da qualidade urbana de distintos setores da cidade. A vegetação urbana é composta por diversas feições: vegetação arbórea, vegetação rasteira, arbustiva etc. Muitos dos estudos selecionados, adotam diversas classificações da vegetação para melhor caracterizá-la.

Os métodos utilizados podem ser divididos em: classificação não supervisionada, supervisionada, orientada a objetos e abordagens estatísticas (Tabela 1). Métodos de classificação *sub-pixel* também são utilizados e, nesses casos, as frações obtidas são reclassificadas para que cada elemento da cena corresponda a uma única classe de cobertura, à semelhança dos demais métodos citados anteriormente, de classificação *“hard”*.

Os estudos selecionados exploram três vertentes: a maior resolução espacial (imagens de resolução espacial muito alta, com menos de 5m e imagens de resolução espacial fina, de 5 a 100m), a maior resolução espectral (imagens hiperespectrais) ou a utilização de dados de LiDAR (Tabela 1).

Tabela 1 – Tipo de imagem, localização dos estudos, classes consideradas, método de classificação e resultados do mapeamento da vegetação urbana.

Tipo de imagem		Artigo	Local	Classes de vegetação mapeadas	Método de classificação	Precisão da classificação			
Sensor passivo	Multi-espectral	Videografia 3 VIS / 17cm 1 IVP / 17cm	Silva Filho <i>et al.</i> (2005)	Piracicaba (Brasil)	14 classes, dentre as quais: copa de árvores/ arbustos e gramíneas / herbáceas	Supervisionado (máxima verossimilhança)	EG de 83% e 92% em cada uma das 12 áreas testes		
		Foto aérea 3 VIS / 1m 1 IVP / 1m	Moskal <i>et al.</i> (2011)	Seattle (EUA)	Cobertura gramínea [G], de arbustos [ARB] e arbórea [A]	Classificação orientada a objetos	EG=79.7% [G] EU=67% e EP=64% [ARB] EU=100% e EP=9% [A] EU=64% e EP=86%		
			McGee <i>et al.</i> (2012)	Winchester (EUA)	Dossel arbóreo urbano	<i>Per-pixel</i> não supervisionada (ISODATA)	EG > 90%		
			Li e Shao (2013)	West Lafayette (EUA)	Gramados pequenos [GP], gramados médios [GM], gramados grandes [GG], vegetação arbustiva [ARB], árvores individuais [A], matas [M], plantação [P]	Classificação orientada a objetos	EG=90.5% [GP] EU=89% e EP=83% [GM] EU=100% e EP=96% [GG] EU=100% e EP=100% [ARB] EU=68% e EP=79% [A] EU=81% e EP=83% [M] EU=100% e EP=100% [P] EU=100% e EP=92%		
			Quickbird 3 VIS / 2.8m 1 IVP / 2.8 m 1 PAN / 0.6m	Li <i>et al.</i> (2012)	Oakland (EUA)	Cobertura gramínea [G], arbórea ou arbustiva [A] e áreas de não vegetação	Classificação orientada a objetos	EG= 97.37% [G] EU=91% e EP=97% [A] EU=99% e EP=98%	
		IKONOS 3 VIS / 2.8m 1 IVP / 2.8 m 1 PAN / 0.6m	Hetrick <i>et al.</i> (2013)	Altamira (Brasil)	5 classes, dentre as quais: cobertura herbácea [G] e dossel arbóreo [A]	Supervisionado (máxima verossimilhança)	EG= 94.33% [G] EU=95% e EP=90% [A] EU=92% e EP=100%		
			Bhaskaran <i>et al.</i> (2010)	Nova York (EUA)	8 classes, dentre as quais: vegetação [G] e árvores [A]	Supervisionado (máxima verossimilhança)	EG=85.21% [G] EU=80% e EP=88% [A] EU=94% e EP=83%		
			Pinho <i>et al.</i> (2012)	S. J. Campos (Brasil)	14 classes, dentre as quais: grama [G] e árvores [A]	Classificação orientada a objetos	[G] EU=100% e EP=98%		
		Sensor passivo	Multi-espectral	IKONOS 3 VIS / 2.8m	Mathieu <i>et al.</i> (2007)	Dunedin (Nova	6 classes, dentre as quais: jardins privados tipo 1 (mais de 70% da	Classificação orientada a objetos	EG=71.91% [G] EU=36% e EP=38% [A] EU=65% e EP=85%
									EG=77.50% [A1] EU=62% e EP=53%

Tipo de imagem		Artigo	Local	Classes de vegetação mapeadas	Método de classificação	Precisão da classificação	
		1 IVP / 2.8 m 1 PAN / 0.6m	Zelândia)	área com cobertura arbórea ou arbustiva) [A1], tipo 2 (de 30% a 70% com cobertura arbórea ou arbustiva) [A2] e tipo 3 (menos de 30%) [A3]		[A2] EU=49% e EP=51% [A3] EU=64% e EP=63%	
			Zhang <i>et al.</i> (2010)	Nanjing (China)	Grama plantada [G], vegetação de folha larga [AL], vegetação de folha estreita [AE], áreas de cultivo [P], vegetação aquática emergente [VA] e áreas impermeabilizadas	Supervisionado (máxima verossimilhança)	EG=75.43% [G] EU=65% e EP=92% [AL] EU=76% e EP=92% [AE] EU=85% e EP=92% [P] EU=68% e EP=92% [VA] EU=100% e EP=92%
		LANDSAT 3 VNIR / 30m 1 NIR / 30m 2 SWIR / 30m	Liu e Yang (2013)	Atlanta (EUA)	11 classes, dentre as quais: grama [G], mata perenifólia [AP], mata decídua [AD], mata mista [AM], áreas alagáveis com vegetação lenhosa [VA], pastagem [PAST], áreas de cultivo [P]	Classificação orientada a objetos	EG=89.42% [G] EU=92% e EP=81% [AL] EU=96% e EP=89% [AE] EU=79% e EP=100% [P] EU=68% e EP=96% [VA] EU=100% e EP=100%
						Análise de mistura espectral com múltiplos <i>endmembers</i> (MESMA)	EG=80.55% [G] EU=76% e EP=87% [AP] EU=77% e EP=92% [AD] EU=81% e EP=72% [AM] EU=70% e EP=68% [VA] EU=74% e EP=70% [PAST] EU=82% e EP=63% [P] EU=70% e EP=85%
						Supervisionado (máxima verossimilhança)	EG=71.27% [G] EU=74% e EP=42% [AP] EU=85% e EP=92% [AD] EU=81% e EP=72% [AM] EU=67% e EP=62% [VA] EU=74% e EP=67% [PAST] EU=82% e EP=67% [P] EU=72% e EP=84%
Sensor passivo	Hiper-espectral	DAIS 7915 32 VNIR / 7m 8 SWIR I / 7m	Roessner <i>et al.</i> (2001)	Dresden (Alemanha)	7 classes, dentre as quais: vegetação rasteira [G] e arbórea [A]	Análise de mistura espectral (com seleção iterativa de <i>endmembers</i> orientada a pixels)	[G] EG=100% [A] EG=82%

Tipo de imagem		Artigo	Local	Classes de vegetação mapeadas	Método de classificação	Precisão da classificação
	32 SWIR II / 7m				Análise de mistura espectral	[G] EG=87% [A] EG=78%
					Supervisionado (máxima verossimilhança)	[G] EG=98% [A] EG=74%
Sensor ativo	LiDAR 50 pts/m ²	Höfle <i>et al.</i> (2012)	Viena (Áustria)	3 classes, dentre as quais: vegetação arbórea	Árvore de Decisão	Precisão com atributos geométricos entre 0.97 e 0.98 Precisão com atributos <i>full-waveform</i> entre 0.63 e 0.95
					Rede Neural Artificial	Precisão com atributos geométricos entre 0.97 e 0.99 Precisão com atributos <i>full-waveform</i> entre 0.72 e 0.99
Combinação passivo e ativo	Foto Aérea e LiDAR	Haala e Brenner (1999)	Karlsruhe (Alemanha)	5 classes, dentre as quais: grama e árvores	<i>Per-pixel</i> não supervisionada (ISODATA)	-
		Zhou e Troy (2008)	Baltimore (EUA)	5 classes, dentre as quais: vegetação de textura fina (gramínea) [G] e vegetação de textura grossa (arbórea) [A]	Classificação orientada a objetos	EG= 92.30% [G] EU=95% e EP=89% [A] EU=98% e EP=94%
		MacFaden <i>et al.</i> (2012)	Nova York (EUA)	7 classes, dentre as quais: cobertura gramínea/ arbustiva [G] e dossel arbóreo [A]	Classificação orientada a objetos	EG= 96.00% [G] EU=93% e EP=89% [A] EU=98% e EP=97%
		Lehbrass e Wang (2012)	London (Canadá)	Cobertura arbórea	Classificação orientada a objetos	EG=96.98%
	Quickbird e LiDAR	Tooke <i>et al.</i> (2009)	Vancouver (Canadá)	vegetação rasteira aparada [G], vegetação rasteira mista [GM], vegetação perenófila [AP], vegetação decídua [AD]	Análise de mistura espectral e árvore de decisão	[G] 100% [GM] 73% [AP] 80% [AD] 67%

Observações:

VIS é a região do espectro do visível, IVP é o infravermelho próximo e SWIR é o infravermelho de ondas curtas. PAN, refere-se às imagens pancromáticas.

EG é a Exatidão Global, EU é a Exatidão do Usuário e EP é a Exatidão do Produtor.

Na diferenciação de vegetação arbórea e vegetação rasteira, os melhores resultados foram os apresentados por Li *et al.* (2012), com a classificação orientada a objetos de imagens de resolução espacial muito alta (exatidão global de 97.37%). Esses resultados foram obtidos com 4 níveis de segmentação e a utilização de atributos espectrais, de tamanho, de forma e de contexto na classificação. MacFaden *et al.* (2012) obtiveram resultados ligeiramente inferiores, também com a classificação orientada a objetos, porém com a adição de informações de LiDAR, assim como Zhou e Troy (2008). Com maior resolução espectral e procedimentos complexos de seleção de *endmembers* para a análise de mistura espectral, que pressupõem a existência de uma biblioteca espectral dos alvos urbanos da área de estudo, Roessner *et al.* (2001) também apresentaram bons resultados.

Na classificação mais detalhada de feições e tipos da vegetação, as imagens mais utilizadas são as de resolução espacial muito alta (menos de 5m). A classificação orientada a objetos produziu os melhores resultados. Li e Shao (2013) obtiveram 90.5% de exatidão global com uma estratégia que incluiu a segmentação com 4 níveis hierárquicos e a utilização de atributos espectrais, de tamanho, contexto e forma. Zhang *et al.* (2010) obtiveram resultados ligeiramente inferiores utilizando segmentação com 2 níveis hierárquicos e atributos espectrais, de contexto e forma. Merece destaque o trabalho de Liu e Yang (2013) que, com imagens de resolução espacial fina (30m), apresentou exatidão global de 80.55% com a classificação das frações obtidas com a análise de mistura espectral com múltiplos *endmembers*. O único estudo que explorou a combinação de dados de sensor ativo com imagens de resolução espacial muito altas, não obteve melhores resultados que os que utilizaram apenas as imagens.

Utilizando exclusivamente dados de LiDAR de pequena área de impressão, Höfle *et al.* (2012) classificaram a vegetação arbórea com alta acurácia, tanto na abordagem de árvore de decisão quanto na de rede neural artificial.

O método de classificação mais utilizado e também o que produziu os melhores resultados foi a classificação orientada a objetos. Em estudos comparativos, Bhaskaran *et al.* (2010) e Zhang *et al.* (2010) confirmam que a segmentação necessária para a classificação orientada a objetos produz melhores resultados que as classificações *per-pixel*.

A análise comparativa dos estudos aponta que a adição de dados de sensores ativos não produzem melhorias significativas nos mapeamentos. Aguilar *et al.* (2013), para o mapeamento vegetação, sem diferenciar feições ou tipos, concluíram que a adição de atributos derivados do modelo digital normalizado de superfície, obtidos a partir de dados LiDAR (1.61 pts/m²), estatisticamente não melhoram a classificação de imagens de satélites GeoEye-1 e WorldView-2.

Além disso, a análise mostrou que com imagens de sensores passivos de resolução espacial muito alta, mas com bandas na região do infravermelho, além da região do visível é possível chegar a resultados bastante satisfatórios de classificação da vegetação, distinguindo feições e tipos de vegetação.

2.2. Mapeamento da fração de vegetação

A fração de vegetação corresponde ao percentual de cobertura vegetal de cada elemento da imagem ou da cena como um todo e é obtida por modelagem empírica ou por decomposição de pixels (YAN *et al.*, 2012). A abordagem mais comum encontrada nos artigos selecionados é a de decomposição de pixels, que pressupõe que a resposta espectral de cada elemento da cena (pixels ou objetos) é resultado da mistura da resposta espectral dos componentes daquele elemento.

Os modelos usualmente empregados para descrever a composição da cena urbana consideram uma classe vegetação, que abrange todas as suas diferentes feições, como um componente, a exemplo dos modelos vegetação, impermeabilização e solo (RIDD, 1995), alto albedo, baixo albedo e vegetação (SMALL, 2003) ou solo/impermeabilização, sombra e vegetação (LU e WENG, 2004). Alguns estudos selecionados obtiveram frações que diferenciam as diferentes feições da vegetação (Tabela 1).

Em geral, a fração de vegetação das cenas urbanas é obtida pela decomposição espectral de imagens de média resolução, nas quais os objetos são menores que a resolução do pixel. Assim, os estudos selecionados utilizaram imagens multiespectrais de resolução fina (mais, embora tenham sido identificados artigos com imagens de alta resolução e imagens hiperespectrais (Tabela 2).

Tabela 2 – Tipo de imagem e métodos para o mapeamento da fração de vegetação urbana.

Tipo de imagem	Sensor passivo					
	Multiespectral			Hiperespectral		
Método	IKONOS (4m)	ASTER (15m)	LANDSAT (30m)	HyMap (3.6m / 9m)	EnMap (30m)	HYPERION (30m)
Modelo Linear de Mistura Espectral	Small (2003) Song (2005)		Phinn <i>et al.</i> (2002) Wu e Murray (2003) Lu e Weng (2004) Song (2005) Small e Lu (2006) Weng e Lu (2009) Tang e Wang (2012)		Okujeni <i>et al.</i> (2015)	
Análise de mistura espectral com múltiplos <i>endmembers</i> (MESMA)			Powell <i>et al.</i> (2007) Powell e Roberts (2008) Powell e Roberts (2010)			Zhang (2016)
IMAGINE <i>sub-pixel analysis</i> e sistema de regras baseado em expertise			Myint (2006)*			

Tipo de imagem	Sensor passivo					
	Multiespectral			Hiperespectral		
Método	IKONOS (4m)	ASTER (15m)	LANDSAT (30m)	HyMap (3.6m / 9m)	EnMap (30m)	HYPERION (30m)
Decomposição de pixels com algoritmo não linear (rede neural artificial)	Pu <i>et al.</i> (2008)			Okujeni <i>et al.</i> , (2014) **		
Decomposição de pixels com modelos de regressão				Okujeni <i>et al.</i> , (2014) **		
Modelagem empírica	Nichol e Lee (2005)					

Observações:

A imagem hiperespectral EnMap foi simulada a partir das imagens do sensor aerotransportado HyMap.

Os estudos obtiveram a fração de vegetação, exceto em:

* frações obtidas: grama natural, grama plantada, árvores, vegetação ripária e áreas de agricultura.

** frações obtidas: telhados, pavimentos, vegetação gramínea, vegetação arbórea e outros.

A análise de mistura espectral pressupõem um modelo físico para prever como e quais materiais no solo serão expressos em imagens espectrais (ADAMS e GILLESPIE, 2006) A análise de mistura espectral linear considera que a resposta de cada elemento de resolução da imagem (pixel) em qualquer banda espectral é a combinação linear das respostas dos alvos que compõem a unidade de resolução no solo (SHIMABUKURO e SMITH, 1991). A análise não linear considera a múltipla interação dos fótons que chegam ao sensor. Small (2003) observou que, em cenas urbanas decompostas em três componentes, alto albedo, baixo albedo e vegetação, a mistura espectral é predominantemente linear, com mistura não linear no eixo dos componentes alto e baixo albedo, que abrangem a diversidade de materiais de cobertura e pavimentação urbana. Sem discutir especificamente a não-linearidade da mistura espectral, Pu *et al.* (2008) afirmam que a decomposição da cena urbana em três componentes, vegetação, impermeabilização e solo, foi mais bem-sucedida com a aplicação de rede neural artificial não-linear do que com a aplicação de um modelo linear.

A variabilidade espectral dos componentes da cena urbana é tratada pelo modelo de análise de mistura espectral com múltiplos componentes (*Multiple Endmember Spectral Mixture Analysis* - MESMA), proposto por Roberts *et al.* (1998). O MESMA pressupõe a linearidade da mistura, mas admite que a mistura pode ser variável em relação ao número de componentes e ao espectro que representam cada componente – uma biblioteca de espectros para o MESMA é composta de centenas de espectros.

A partir de uma abordagem empírica, Nichol e Lee (2005) mapeiam a fração de cobertura vegetal a partir de relações lineares e polinomiais do percentual de área coberta por vegetação identificada em parcelas de campo e índices de vegetação derivados de imagens de satélite IKONOS. No mesmo estudo, os autores calculam a densidade de vegetação, que é a soma ponderada da área de cada tipo de vegetação (grama baixa, grama alta, vegetação arbustiva, árvores de pequeno porte e árvores de grande porte). Os resultados apontam que as regressões polinomiais expressam

melhor as relações entre os índices de vegetação e a fração e densidade da vegetação, e que os melhores resultados são obtidos com a remoção das áreas de sombras. Para a cobertura de vegetação, a melhor relação foi com a banda vermelha: R^2 de 0.82 para as imagens aéreas e 0.67 para a imagem de satélite. Para a densidade de vegetação, o melhor índice é o da razão entre as bandas verde e vermelho, com R^2 igual para as duas imagens (0.81).

2.3. Mapeamento de espécies ou gêneros de vegetação

O inventário das espécies é pré-requisito para o manejo da vegetação, para a tomada de decisões de planejamento urbano e análise de custo-benefício, considerando a distribuição espacial dos serviços ecológicos em relação às atividades e à infraestrutura humana. A identificação de espécies da vegetação urbana por sensoriamento remoto tem atraído a atenção de pesquisadores, que exploraram imagens de alta resolução espacial e/ou espectral isoladamente ou em conjunto não com dados de sensor ativo (Tabela 3).

Os trabalhos de Xiao *et al.* (2004) e Alonzo *et al.* (2014 e 2016) classificaram o maior número de espécies e obtiveram bons resultados, aferidos pela exatidão global, o que mostra a importância da informação de alta resolução, tanto espectral como espacial. Os resultados alcançados por Alonzo *et al.* (2014 e 2016) com a adição de dados LiDAR são superiores aos obtidos por Xiao *et al.* (2004), que utilizaram somente a informação hiperespectral. De acordo com Alonzo *et al.* (2014), a adição dos dados de LiDAR aumentaram a exatidão global em 4.2% e foram importantes, sobretudo, na identificação de copas que eram pequenas ou morfologicamente únicas: a exatidão do mapeamento da palmeira *Washingtonia robusta*, por exemplo, aumentou de 29% para 71% com a informação de LiDAR.

Gu *et al.* (2015), utilizando a regressão linear em dados também de alta resolução espacial e espectral em conjunto com dados LiDAR obteve resultados para o mapeamento de gêneros inferiores aos de Alonzo *et al.* (2014 e 2016), com a análise discriminante canônica, o que sugere que essa abordagem seria superior na separação de classes com alta sobreposição de atributos.

Considerando apenas os gêneros, Zhang e Hu (2012) obtiveram exatidão global de 85% com fotos aéreas. Tigges *et al.* (2013) obtiveram o mesmo resultado com dados multi-temporais de menor resolução espacial (imagens do satélite RapidEye).

A individualização das copas das árvores foi feita com diferentes abordagens: algoritmos de segmentação multi-resolução (PU e LANDRY, 2012), de segmentação de bacias (ALONZO *et al.* 2014; 2016) e de crescimento de regiões (IOVAN *et al.*, 2008), além da utilização de máscaras construídas a partir de índices de vegetação (ZHANG e HU, 2012) e em combinação com dados de altura (TIGGES *et al.*, 2013). A utilização da segmentação e a precisão no delineamento das copas das árvores contribui para a minimização dos erros na classificação da vegetação (ALONZO *et al.* 2014; IOVAN *et al.*, 2008).

Tabela 3 – Tipo de imagem, métodos de classificação, espécies ou gêneros de vegetação urbana considerados e resultados obtidos.

Tipo de imagem		Artigo	Local e latitude	Método de classificação	Espécies ou gêneros classificados	Exatidão obtida	
Sensor passivo	Multi-espectral	Foto aérea 3 VIS / 0.6m 1 IVP / 0.6m	Zhang e Hu (2012)	Toronto (Canadá) 43°42'N	Árvore de decisão	6 gêneros: <i>maple, ash, birch, oak, spruce, pine</i>	Exatidão global de 84% e 85% para as duas árvores de decisão analisadas.
		World View-2 6 VIS / 2.0m 2 IVP / 2.0 m 1 PAN / 0.5m	Pu et al. (2014)	Tampa (EUA) 27°57'N	Árvore de classificação e regressão (CART) / Análise discriminante linear (LDA)	12 espécies: <i>redmaple (Acer rubrum), slash pine (Pinus elliottii), long leaf pine (Pinus palustris), laurel oak (Q. laurifolia), live oak (Q. virginiana), cabbage palmetto (Sabal palmetto), brazilian pepper (Schinus terebinthifolius), bald cypress (Taxodium distichum), american elm (Ulmus Americana), sand live oak (Quercus geminata), camphor (Cinnamomum camphora)</i> e magnólia (<i>Magnolia grandiflora</i>)	O classificador não paramétrico CART resultou em uma exatidão global de 48%, enquanto que o classificador paramétrico LDA atingiu 55%.
		World View-2 6 VIS / 2.0m 2 IVP / 2.0 m 1 PAN / 0.5m e Ikonos 3 VIS / 2.8m 1 IVP / 2.8 m 1 PAN / 0.6m	Pu e Landry (2012)	Tampa (EUA) 27°57'N	Árvore de classificação e regressão (CART) / Análise discriminante linear (LDA)	5 espécies: <i>sand live oak (Quercus geminata), laurel oak (Q. laurifolia), live oak (Q. virginiana), camphor (Cinnamomum camphora)</i> e magnólia (<i>Magnolia grandiflora</i>) 2 grupos: pinheiros e palmeiras	Os melhores resultados são os obtidos com as imagens WorldView 2, com exatidão global de 56.02% e 54.53% para os classificadores LDA e CART, respectivamente.
		RapidEye multi-temporal 3 VIS / 6.5m 2 IVP / 6.5 m	Tigges et al. (2013)	Berlim (Alemanha) 52°31'N	Support Vector Machine (SVM)	8 gêneros: <i>pinus, aesculus, platanus, tilia, acer, populus, fagus</i> e <i>quercus</i>	Exatidão global de 85.5%. Apenas 1 gênero não obteve exatidão de usuário e produtor maior que 75%, sendo que 3 gêneros obtiveram exatidão do usuário e produtor maior que 90%.

Tipo de imagem		Artigo	Local e latitude	Método de classificação	Espécies ou gêneros classificados	Exatidão obtida	
Sensor passivo	Hiper-espectral	AVIRIS 3.5m	Xiao et al. (2004)	Modesto (EUA) 37°38'N	Análise de mistura espectral (SMA)	<p>22 espécies: <i>silver maple</i> (<i>Acer saccharinum</i>), <i>birch</i> (<i>Betula pendulata</i>), <i>chinese hackberry</i> (<i>Celtis sinensis</i>), <i>camphor</i> (<i>Cinnamomum camphora</i>), <i>hess ash</i> (<i>Fraxinus excelsior 'Hessii'</i>), <i>moraine ash</i> (<i>Fraxinus x Moraine</i>), <i>raywood ash</i> (<i>Fraxinus oxycarpa 'Raywood'</i>), <i>marshal ash</i> (<i>Fraxinus pennsylvanica 'Marshall'</i>), <i>modesto ash</i> (<i>Fraxinus velutina 'Modesto'</i>), <i>gingko</i> (<i>Gingko biloba</i>), <i>honey locust</i> (<i>Gleditsia triacanthos</i>), <i>goldenrain tree</i> (<i>Koelreutaria paniculata</i>), <i>crape myrtle</i> (<i>Lagerstroemia indica</i>), <i>sweetgum</i> (<i>Liquidambar styraciflua</i>), <i>magnolia grandiflora</i> (<i>Southern Magnolia</i>), <i>chinese pistachio</i> (<i>Pistacia chinensis</i>), <i>japanese black pine</i> (<i>Pinus thunbergii</i>), <i>london plane</i> (<i>Plantanus x acerifolia</i>), <i>flowering plum</i> (<i>Prunus cerasifera</i>), <i>callery pear</i> (<i>Pyrus calleryana 'Bradford'</i>), <i>holly oak</i> (<i>Quercus ilex</i>), <i>zilkova</i> (<i>Zelkova serrata</i>)</p> <p>3 tipos: decídua de folhas largas, perenifólia de folhas largas e coníferas</p>	<p>No nível do tipo de árvore, a exatidão global foi de 94%.</p> <p>No nível das espécies, a exatidão global foi de 70%.</p>
Combinação de sensor passivo e ativo		AVIRIS 3.7m e LiDAR 22pts/m ²	Alonzo et al. (2014)	Sta. Barbara (EUA) 34°25'N	Análise discriminante canônica	<p>29 espécies: <i>Archontophoenix cunninghamiana</i>, <i>Cinnamomum camphora</i>, <i>Cupressus macrocarpa</i>, <i>Eucalyptus ficifolia</i>, <i>Eucalyptus globulus</i>, <i>Ficus microcarpa</i>, <i>Geijera parviflora</i>, <i>Jacaranda mimosifolia</i>, <i>Liquidambar styraciflua</i>, <i>Lophostemon confertus</i>, <i>Magnolia grandiflora</i>, <i>Metrosideros excelsa</i>, <i>Olea europaea</i>, <i>Phoenix canariensis</i>, <i>Pinus canariensis</i>, <i>Pinus pinea</i>, <i>Pittosporum undulatum</i>, <i>Platanus racemosa</i>, <i>Podocarpus gracilior</i>, <i>Pyrus kawakamii</i>, <i>Quercus agrifolia</i>, <i>Schinus molle</i>, <i>Schinus terebinthifolius</i>, <i>Stenocarpus sinuatus</i>, <i>Syzygium australe</i>, <i>Syagrus romanzoffiana</i>, <i>Tipuana tipu</i>, <i>Ulmus parvifolia</i>, <i>Washingtonia robusta</i></p> <p>3 tipos: folhas largas, coníferas e palmeiras</p>	<p>A exatidão global para o nível do tipo de árvore foi de 93.5%.</p> <p>Para o nível de espécies, a exatidão global foi de 83.4%.</p>

Tipo de imagem		Artigo	Local e latitude	Método de classificação	Espécies ou gêneros classificados	Exatidão obtida
Combinação de sensor passivo e ativo	AVIRIS 3.7m e LiDAR 22pts/m ²	Alonzo <i>et al.</i> (2016)	Sta. Barbara (EUA) 34°25'N	Análise discriminante canônica	25 espécies: <i>Archontophoenix cunninghamiana</i> , <i>Cupressus macrocarpa</i> , <i>Eucalyptus globulus</i> , <i>Ficus microcarpa</i> , <i>Jacaranda mimosifolia</i> , <i>Liquidambar styraciflua</i> , <i>Lophostemon confertus</i> , <i>Magnolia grandiflora</i> , <i>Metrosideros excelsa</i> , <i>Olea europaea</i> , <i>Phoenix canariensis</i> , <i>Pinus canariensis</i> , <i>Pinus pinea</i> , <i>Pittosporum undulatum</i> , <i>Platanus racemosa</i> , <i>Podocarpus gracilior</i> , <i>Pyrus kawakamii</i> , <i>Quercus agrifolia</i> , <i>Schinus molle</i> , <i>Schinus terebinthifolius</i> , <i>Syzygium australe</i> , <i>Syagrus romanzoffiana</i> , <i>Tipuana tipu</i> , <i>Ulmus parvifolia</i> , <i>Washingtonia robusta</i>	Das 25 espécies mapeadas, apenas 3 obtiveram exatidão de usuário e de produtor menor que 75%. 5 espécies obtiveram exatidão de usuário e de produtor maior que 90%.
	AVIRIS 11.8m e LiDAR 1pts/m ²	Gu <i>et al.</i> (2015)	Madison (EUA) 43° 07'N	Regressão linear	6 gêneros: <i>oak</i> , <i>cherry</i> , <i>maple</i> , <i>ash</i> , <i>pine</i> , <i>buckthorn</i>	Os dois modelos preditivos do gradiente de composição dos gêneros alcançaram R ² =0.67 e R ² =0.47.
	Foto Aérea 3 VIS / 0.2m 1 IVP / 0.2m e nDSM	Iovan <i>et al.</i> (2008)	Marseille (França) 43°18'N	Support Vector Machine (SVM)	2 espécies: <i>lime trees (Tilia)</i> e <i>plane trees (Platanus Hispanica)</i> .	Nos testes efetuados, considerando abordagem por pixel e por região e diferentes espaços de cores, a exatidão global variou entre 95.84% e 100%.

2.4. Mapeamento de características físicas da vegetação

Aspectos da configuração física da vegetação urbana, como a dimensões e densidade da copa arbórea e do tronco, a altura total e até a modelagem tridimensional da vegetação, podem ser derivados de dados de sensoriamento remoto, especialmente dados de sensores ativos (Tab. 4).

Tabela 4 – Característica física da vegetação urbana e tipo de imagem usada.

Tipo de imagem	Sensor passivo		Sensor ativo		Combinação passivo e ativo
	Hiperespectral AISA (2m)	Multiespectral LANDSAT (30m)	LIDAR	TanDEM-X (12×12m)	Foto aérea e nDSM
Característica física					
Área da copa da árvore			Shrestha e Wynne (2012)*		
Altura da árvore			Shrestha e Wynne (2012)*	Schreyer <i>et al.</i> (2016)	
Diâmetro na altura do peito			Shrestha e Wynne (2012)*		
Índice de área foliar (LAI)	Jensen <i>et al.</i> (2012)	Tang e Tang (2013)	Alonzo <i>et al.</i> (2015)**		
Árvore em 3D				Schmitt <i>et al.</i> (2015)	Iovan <i>et al.</i> (2014)
Densidade de área foliar (LAD)					Oshio <i>et al.</i> (2015)

* LiDAR com 8pts/m².

** LiDAR com 22pts/m².

A altura, a área da copa das árvores e o diâmetro do tronco são propriedades físicas importantes para a caracterização da vegetação por que são altamente correlacionadas com as funções ecológicas e a biodiversidade e complexidade dos ecossistemas (SUN *et al.*, 2012; SHRESTHA e WYNNE, 2012; SCHREYER *et al.*, 2016). Shrestha e Wynne (2012) utilizaram mensuraram essas propriedades a partir de dados LIDAR de pequena área de impressão, com alta acurácia: na comparação com dados de campo, a altura das árvores obteve um $R^2 = 0.89$, o diâmetro na altura do peto, $R^2 = 0.82$ e o diâmetro da copa, $R^2 = 0.90$. Para a estimativa da biomassa, os autores concluíram que a área da copa é a característica de maior importância. Schreyer *et al.* (2016) desenvolveram técnica de filtragem de dados de radar obtidos pela missão TanDEM-X, com resolução espacial de 12m, para obter o modelo normalizado de dossel (*normalized Canopy Model* – nCM). Os resultados, ainda que inéditos para esse tipo de dado, ainda não são muito precisos: para os maciços arbóreos do tipo florestal, a altura média foi do nCM foi 9.16 m, inferior ao dado de validação, 13.55m; para as árvores pulverizadas pela malha urbana, a diferença foi maior, 4.17m para 9.61m, da validação.

O índice de área foliar (*Leaf Area Index* – LAI) relaciona a área total das folhas, considerando apenas um dos seus lados, e uma unidade de superfície no terreno. É uma característica chave da vegetação, devido ao papel que as folhas desempenham no controle de processos biológicos e físicos do dossel (CHEN *et al.*, 1997). Processos de interceptação do dossel, evapotranspiração e fotossíntese bruta são diretamente proporcionais ao LAI (FANG *et al.*, 2012). O LAI é um parâmetro de entrada em diversos modelos ecológicos, climáticos e microclimáticos. A estimativa do LAI é feita por métodos diretos, pelo corte das folhas e sua mensuração em laboratório, e indiretos, que incluem relações alométricas, métodos ópticos, com a utilização de fotografias hemisféricas, e radiométricos, com a utilização de instrumentos específicos (ceptômetros) ou de modelos inversos de transferência radiativa e regressões e modelos lineares e não-lineares que correlacionam a resposta espectral ao parâmetro físico. Utiliza-se o termo LAI efetivo ou PAI (*Plant Area Index*) quando a estimativa é feita a partir da fração de não vegetação (*gap fraction*) obtida com ceptômetros ou fotografias hemisféricas. Trata-se de uma aproximação do LAI, que tem como pressuposto a distribuição aleatória das folhas, o que nem sempre ocorre na natureza (CHEN *et al.*, 1997).

Jensen *et al.* (2012) testaram relações lineares e não lineares entre o LAI e feições espectrais (índices espectrais, resultado de análise de principais componentes e valores de reflectância calibrados) obtidas com sensor aerotransportado hiperespectral. O melhor resultado foi obtido com o método não linear de rede neural ($R^2 = 0.65$), treinado com um pequeno número índices espectrais e amostras de campo, obtidas com ceptômetro. Os autores alertam para a influência que o tipo de pavimento sob as árvores exerce na estimativa de árvores de folhagem não densa e, de maneira mais geral, para a influência das especificidades de cada espécie.

Tang e Tang (2013) calcularam o LAI a partir de sua relação com a razão simples de banda obtida de imagens do sensor LANDSAT para o corredor entre Washington e Baltimore. Foram utilizadas equações distintas para cada tipo de folha, larga, estreita e grama, sendo que, nos dois primeiros casos, as equações foram propostas por Fernandes *et al.* (2003) para as florestas do Canadá, e, no último caso, utilizou-se equação proposta por Sellers *et al.* (1997), no âmbito do estudo das respostas biofísicas do sistema global às mudanças climáticas.

Alonzo *et al.* (2015) exploraram dados de LiDAR para obter o LAI, testando distintas abordagens: por meio de métricas de penetração do laser (*Laser Penetration Metrics* – LPM) e por meio de relações alométricas entre altura, altura da base da copa e área de segmento de copa. Em ambas as abordagens, o coeficiente R^2 obtido foi alto, 0.82 e 0.84. Os autores afirmam que a utilização de dados com menor densidade (2 pontos/m², ao invés de 22 pontos/m², como utilizado no estudo) podem produzir resultados semelhantes com as LPMs. Além disso, os autores alertam para os erros não conhecidos derivados da utilização de relações alométricas não específicas das espécies e condições urbanas.

Técnicas mais complexas e ainda experimentais foram utilizadas para a estimativa das propriedades físicas de árvores em ambientes urbanos e sua reconstrução tridimensional por Iovan *et al.* (2014), Oshio *et al.* (2015) e Schmitt *et al.* (2015). No

primeiro caso, foram utilizadas imagens aéreas ortoretificadas e um modelo de superfície normalizado (*normalized Digital Surface Model – nDSM*) na obtenção de parâmetros – localização de cada árvore e sua altura, o diâmetro das copas e os espaços livres entre elas, além de identificação das espécies – para um modelo arquitetural de crescimento das árvores, com o qual se pode simular o desenvolvimento das árvores ao longo dos anos (IOVAN *et al.*, 2014). No segundo caso, os autores utilizaram dados LiDAR (16 pontos/m²) para estimar o LAD (*Leaf Area Density*), que relaciona a área das folhas com uma unidade de volume, com resultados restritos às duas espécies investigadas. Os autores sugerem testes com espécies de diferentes densidades de folhagens e estrutura de copa para analisar a robustez do método proposto, considerando também a inclinação das folhas e a diferenciação entre a densidade de folhas e de plantas. E, finalmente, no terceiro caso, dados InSAR (*Interferometric Synthetic Aperture Radar*) obtidos em uma única passagem, por sistema de multi-antenas com diferentes ângulos, foram utilizados para a geração de nuvem de pontos livre de sobreposições e sombras por processo de tomografia de SAR. A nuvem de pontos segmentada e agrupada em possíveis copas de árvores foi ajustada a um modelo elipsoidal e, a partir disso, foram extraídos parâmetros geométricos relevantes para a reconstrução tridimensional das árvores. Os autores reportam que 74% das árvores foram segmentadas e reconstruídas (SCHMITT *et al.*, 2015).

2.5. Mapeamento de características biológicas da vegetação

Informações espectrais e características físicas da vegetação, obtidas por sensores ativos, são relacionadas a características biológicas da vegetação. Na pesquisa bibliográfica, foram encontrados estudos sobre a biomassa, a fração de radiação fotossinteticamente ativa (*fraction of Photosynthetically Active Radiation - fPAR*) e o nível de clorofila da vegetação, conhecido como *greenness* (Tab. 5).

Tabela 5 – Tipo de imagem e característica biológica da vegetação urbana.

Tipo de imagem	Sensor passivo		Sensor ativo
	Multiespectral		LIDAR
Característica biológica	IKONOS (4m)	LANDSAT (30m)	
Biomassa	Shrestha e Wynne (2012)	Myeong <i>et al.</i> (2006)	Shrestha e Wynne (2012)* Alonzo <i>et al.</i> (2016)** Raciti <i>et al.</i> (2014)
fPAR		Tang e Tang (2013)	
<i>Greenness</i>		Zhu <i>et al.</i> (2016)	

* LiDAR com 8pts/m².

** LiDAR com 22pts/m².

A biomassa, acima ou abaixo do solo, é uma variável crítica para a análise do ciclo de carbono, da alocação de nutrientes do solo, do acúmulo de combustível e dos próprios habitats (SUN *et al.*, 2012). As estimativas de biomassa da vegetação em cidades são feitas, em geral, com dados de campo e equações alométricas derivadas de estudos

florestais, como nos trabalhos de Hutyra *et al.* (2011) e Nowak *et al.* (2013). Os estudos que determinam relações alométricas específicas para a vegetação urbana são poucos e restritos. Pillsbury *et al.* (1998) analisaram a alometria de 14 espécies de árvores encontradas nas cidades californianas. Não há certeza de que a utilização de relações alométricas derivadas de estudos não-urbanos seja adequada à estimativa de biomassa urbana. McHALE *et al.* (2009) encontraram uma variação de 60% a 300% na estimativa da biomassa estimada por equações derivadas de estudos florestais e dados de campo, dependente da escala da estimativa, das espécies e das características da população e comunidade.

Além da escassez de medições específicas para a vegetação de áreas urbanas, a estimativa por alometria tem como desvantagem os erros induzidos por amostragens deficientes (ALONZO *et al.*, 2016). A vantagem de estimar a biomassa por dados de sensoriamento remoto está na sua facilidade de obtenção (menor utilização de recursos humanos e possibilidade de mapear áreas privadas), na possibilidade de maior cobertura territorial com alta resolução espacial e temporal. Por outro lado, a conversão dos dados de sensoriamento remoto em estimativas de biomassa está sujeita aos erros da interpretação dos dados e da extrapolação da relação entre os dados de campo e de satélite (ALONZO *et al.*, 2016; SUN *et al.*, 2012).

Dos estudos selecionados, Myeong *et al.* (2006) utilizaram imagens de média resolução e o *Normalized Difference Vegetation Index* (NDVI) e Alonzo *et al.* (2016) e Raciti *et al.* (2014) utilizaram dados LIDAR de pequena área de impressão. Shrestha e Wynne (2012) conduziram um estudo comparativo entre dados de LiDAR de pequena área de impressão e índices de vegetação calculados a partir de imagens de alta resolução espacial.

Os resultados de Shrestha e Wynne (2012) mostram que os dados de LIDAR têm melhor desempenho na estimativa da biomassa com regressões lineares. O resultado não chega a ser surpreendente, já que existe uma relação muito forte entre as características físicas da árvore e sua biomassa. Adicionalmente, a utilização de regressões lineares tem pressupostos que podem não ser totalmente satisfeitos, a saber: a linearidade da relação entre as variáveis e a independência delas, em especial para os dados espectrais (SUN; SUN *et al.*, 2012). Dos artigos analisados, apenas Alonzo *et al.* (2016) apresentam relações não lineares para a estimativa da biomassa.

Outro aspecto investigado é o da escala da estimativa. Shrestha e Wynne (2012) obtiveram a maior variância dos dados explicada pelas equações de regressão para espécies específicas ($R^2=0.68$ para *Juniperus virginiana* a 0.84 para *Ulmus parviflora*), maior do que para os grupos taxonômicos considerados (decíduas de folhas largas, $R^2=0.63$ e coníferas, $R^2=0.45$) ou do que para a totalidade das amostras analisadas ($R^2=0.67$). Entretanto, Alonzo *et al.* (2016) concluiu que os erros na classificação das espécies feita a partir dos dados de sensoriamento remoto introduzem incertezas que tornam preferível a utilização de um modelo genérico, que não discrimina espécies. McHALE *et al.* (2009) também recomendou a utilização de modelos genéricos devido à falta de dados alométricos específicos para espécies urbanas.

A fração de radiação fotossinteticamente ativa (fPAR) corresponde a radiação solar, compreendida no espectro de 400nm a 700nm, absorvida pela vegetação e é utilizada para estimar a produtividade primária e a absorção de dióxido de carbono da vegetação e descrever o estado do crescimento e evolução da vegetação (FAN e TAO, 2012). O estudo de Tang e Tang (2013) procurou investigar as mudanças nas características biofísicas da vegetação devido a mudanças espaciais, captadas por duas métricas de paisagens (fragmentação e percentual de área *core*). Os resultados mostram uma correlação relativamente baixa entre o fPAR e as métricas, que os autores atribuem ao grande número de fragmentos de vegetação. Os autores não comentam, mais uma fonte de erro que impactaria os resultados seria a estimativa do fPAR, feita a partir do NDVI, segundo relação linear proposta por Myneni e Williams (1994). Para que essa relação seja válida, é preciso corrigir os efeitos atmosféricos e bidirecionais e considerar a contribuição do terreno onde a vegetação está assentada (MYNENI e WILLIAMS, 1994).

A relação entre características biológicas da vegetação e mudanças espaciais foi também investigada por Zhu *et al.* (2016), com a utilização do *Enhanced Vegetation Index* (EVI) e do NDVI para expressar o *greenness* da vegetação. Embora o termo *greenness* não seja incomum na literatura de sensoriamento remoto, seu conceito não está formalizado – entende-se que o *greenness* está associado à presença de clorofila na vegetação, sendo um indicador de sua capacidade fotossintética. Zhu *et al.* (2016) afirmam que as tendências de modificação do *greenness* ao longo do tempo podem ser analisadas como um indicador da resposta do ecossistema às mudanças climáticas e aos efeitos da atividade humana sobre o território. Os resultados obtidos são o oposto do esperado: observou-se o aumento do *greenness* a despeito do processo massivo de urbanização que ocorreu na área de estudo entre 2000 e 2014. O acréscimo gradual e lento do *greenness* sobrepujou os decréscimos, que ocorreram de maneira abrupta e associados a mudanças de uso e cobertura do solo.

3. PERSPECTIVAS FUTURAS

A diversidade de feições de vegetação já classificadas, com variados métodos e tipos de dados de sensoriamento remoto, parece apontar para o esgotamento desse tipo de estudo. Entretanto, para a realidade brasileira, no domínio conceitual da paisagem urbana ou mesmo da legislação urbanística ou ambiental, foram desenvolvidas tipologias que mereceriam ser especializadas. Por exemplo, a arborização urbana na cidade de São Paulo é regida pela Portaria Intersecretarial nº 05/SMMA-SIS/02, de 27 de julho de 2002, que estabelece uma classificação própria: a) árvores nativas ou exóticas de pequeno porte (até 5 m de altura) ou arbustivas; b) árvores nativas ou exóticas de porte médio (5 a 10 m de altura); e c) nativas ou exóticas de grande porte (maior que 10 m de altura).

A identificação de espécies ou gêneros por meio de sensoriamento remoto, embora menos custosa que os inventários de campo e adequadas ao mapeamento de áreas extensas ou inacessíveis, ainda apresenta dificuldades relacionadas à complexidade, densidade e diversidade da vegetação urbana (IOVAN *et al.*, 2008). Não foi encontrado nenhum artigo que tenha se detido no mapeamento das espécies existentes em cidades brasileiras ou espécies da vegetação tropical, o que mostra que os desafios, considerando a realidade brasileira, são ainda maiores.

As características físicas da vegetação, com destaque para o LAI, são parâmetros de entrada em modelos microclimáticos urbanos. Assim, a maior precisão e rapidez, além da automatização do mapeamento dessas características é altamente desejável, possibilitando a integração de dados de sensoriamento remoto aos modelos físicos de microclima urbano.

O mapeamento da biomassa, bastante explorado nos estudos florestais, começa a aparecer nos estudos de áreas urbanas. Porém, é necessário relativizar a importância do sequestro de carbono pelas árvores nas cidades: segundo dados das cidades norte-americanas, o total sequestrado anualmente foi estimado em 25.6 milhões de toneladas (NOWAK *et al.*, 2013), valor irrisório perto das emissões, medidas em gigatoneladas (U.S. GEOLOGICAL SURVEY, 2008).

Por fim, vale a pena mencionar o estudo de Zhu *et al.* (2016), que, apesar de basear-se em um conceito controverso, o de *greenness*, chama a atenção a perspectiva do estudo: a interação entre urbanização e vegetação, em escala regional.

BIBLIOGRAFIA

ADAMS, J. B.; GILLESPIE, A. R. **Remote sensing of landscapes with spectral images: a physical modeling approach**. 1a. ed. Cambridge: Cambridge University, 2006.

AGUILAR, M. A.; SALDAÑA, M. M.; AGUILAR, F. J. GEOEYE-1 and WORLDVIEW-2 pan-sharpened imagery for object-based classification in urban environments. **INTERNATIONAL Journal of Remote Sensing**, v. 34, n. 7, p. 2583–2606, 2013.

ALONZO, M.; BOOKHAGEN, B.; MCFADDEN, J. P.; SUN, A.; ROBERTS, D. A. Mapping urban forest leaf area index with airborne lidar using penetration metrics and allometry. **Remote Sensing of Environment**, v. 162, p. 141–153, 2015.

ALONZO, M.; BOOKHAGEN, B.; ROBERTS, D. A. Urban tree species mapping using hyperspectral and LiDAR data fusion. **Remote Sensing of Environment**, v. 148, p. 70–83, 2014.

ALONZO, M.; MCFADDEN, J. P.; NOWAK, D. J.; ROBERTS, D. A. Mapping urban forest structure and function using hyperspectral imagery and LiDAR data. **Urban Forestry & Urban Greening**, v. 17, p. 135–147, 2016.

BHASKARAN, S.; PARAMANANDA, S.; RAMNARAYAN, M. Per-pixel and object-oriented classification methods for mapping urban features using IKONOS satellite data. **Applied Geography**, v. 30, n. 4, p. 650–665, 2010.

CHEN, J. M.; RICH, P. M.; GOWER, S. T.; NORMAN, J. M.; PLUMMER, S. Leaf area index of boreal forests: theory, techniques, and measurements. **Journal of Geophysical Research Atmospheres**, v. 102, p. 429–443, 1997.

DA SILVA FILHO, D. F.; PIVETTA, K. F. L.; DO COUTO, H. T. Z.; POLIZEL, J. L. Indicadores de floresta urbana a partir de imagens aéreas multiespectrais de alta resolução. **Scientia Forestalis/Forest Sciences**, n. 67, p. 88–100, 2005.

FAN, W.; TAO, X. Fraction of absorbed photosynthetically active radiation by green vegetation. In: LIANG, S.; LI, X.; WANG, J. (Org.). **Advanced Remote Sensing**. 1a. ed.: Elsevier, 2012. 383–414p.

FANG, H.; XIAO, Z.; QU, Y.; SONG, J. Leaf area index. In: LIANG, S.; LI, X.; WANG, J. (Org.). **Advanced remote sensing**. 1a. ed. Oxford: Elsevier, 2012. 347–381 p.

FERNANDES, R.; BUTSON, C.; LEBLANC, S.; LATIFOVIC, R. LANDSAT-5 Tm and LANDSAT-7 ETM+ based accuracy assessment of leaf area index products for Canada derived from spot-4 vegetation data. **Canadian Journal of Remote Sensing**, v. 29, n. 2, p. 241–258, 2003.

GU, H.; SINGH, A.; TOWNSEND, P. A. Detection of gradients of forest composition in an urban area using imaging spectroscopy. **Remote Sensing of Environment**, v. 167, p. 168–180, 2015.

HAALA, N.; BRENNER, C. Extraction of buildings and trees in urban environments. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2-3, p. 130–137, 1999.

HETRICK, S.; CHOWDHURY, R.; BRONDIZIO, E.; MORAN, E. Spatiotemporal patterns and socioeconomic contexts of vegetative cover in Altamira city, Brazil. **Land**, v. 2, p. 774–796, 2013.

HÖFLE, B.; HOLLAUS, M.; HAGENAUER, J. Urban vegetation detection using radiometrically calibrated small-footprint full-waveform airborne LiDAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 67, n. 1, p. 134–147, 2012.

HUTYRA, L. R.; YOON, B.; ALBERTI, M. Terrestrial carbon stocks across a gradient of urbanization: a study of the Seattle, WA region. **Global Change Biology**, v. 17, n. 2, p. 783–797, 2011.

IOVAN, C.; BOLDO, D.; CORD, M. Detection, characterization, and modeling vegetation in urban areas from high-resolution aerial imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 1, n. 3, p. 206–213, 2008.

IOVAN, C.; COURNEDE, P.; GUYARD, T.; BAYOL, B.; BOLDO, D.; CORD, M. Model-based analysis-synthesis for realistic tree reconstruction and growth simulation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 2, p. 1438–1450, 2014.

JENSEN, R. R.; HARDIN, P. J.; HARDIN, A. J. Estimating urban leaf area index (LAI) of individual trees with hyperspectral data. **Photogrammetric Engineering & Remote Sensing**, n. 5, p. 495–504, 2012.

LEHBRASS, B.; WANG, J. Urban tree cover mapping with relief-corrected aerial imagery and LiDAR. **Photogrammetric Engineering & Remote Sensing**, v. 78, n. 5, p. 473–484, 2012.

LI, W.; RADKE, J.; LIU, D.; GONG, P. Measuring detailed urban vegetation with multisource high-resolution remote sensing imagery for environmental design and planning. **Environment and Planning B: Planning and Design**, v. 39, n. 3, p. 566–585, 2012.

LI, X.; SHAO, G. Object-based urban vegetation mapping with high-resolution aerial photography as a single data source. **International Journal of Remote Sensing**, v. 34, n. 3, p. 771–789, 2013.

LIU, T.; YANG, X. Mapping vegetation in an urban area with stratified classification and multiple endmember spectral mixture analysis. **Remote Sensing of Environment**, v. 133, p. 251–264, 2013.

LU, D.; WENG, Q. Spectral mixture analysis of the urban landscape in indianapolis with LANDSAT ETM+ imagery. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 9, p. 1053–1062, 2004.

MACFADEN, S. W.; O'NEIL-DUNNE, J. P. M.; ROYAR, A. R.; LU, J. W. T.; RUNDLE, A. G. High-resolution tree canopy mapping for New York city using lidar and object-based image analysis. **Journal of Applied Remote Sensing**, v. 6, n. 1, 2012.

MATHIEU, R.; FREEMAN, C.; ARYAL, J. Mapping private gardens in urban areas using object-oriented techniques and very high-resolution satellite imagery. **Landscape and Urban Planning**, v. 81, p. 179–192, 2007.

MCGEE, J. A.; DAY, S. D.; WYNNE, R. H.; WHITE, M. B. Using geospatial tools to assess the urban tree canopy: decision support for local governments. **Journal of Forestry**, 2012.

MCHALE, M. R.; BURKE, I. C.; LEFSKY, M. A.; PEPPER, P. J.; MCPHERSON, E. G. Urban forest biomass estimates: is it important to use allometric relationships developed specifically for urban trees? **Urban Ecosystems**, v. 12, n. 1, p. 95–113, 2009.

MOSKAL, L. M.; STYERS, D. M.; HALABISKY, M. Monitoring urban tree cover using object-based image analysis and public domain remotely sensed data. **Remote Sensing**, v. 3, n. 10, p. 2243–2262, 2011.

MYEONG, S.; NOWAK, D. J.; DUGGIN, M. J. A temporal analysis of urban forest carbon storage using remote sensing. **Remote Sensing of Environment**, v. 101, n. 2, p. 277–282, 2006.

MYINT, S. W. Urban vegetation mapping using subpixel analysis and expert system rules: a critical approach. **International Journal of Remote Sensing**, v. 27, p. 2645–2665, 2006.

MYNENI, R. B.; WILLIAMS, D. L. On the relationship between FaPAR and NDVI. **Remote Sensing of Environment**, v. 49, n. 3, p. 200–211, 1994.

NICHOL, J.; LEE, C. M. Urban vegetation monitoring in Hong Kong using high resolution

multispectral images. **International Journal of Remote Sensing**, v. 26, n. 5, p. 903–918, mar. 2005.

NOWAK, D. J.; GREENFIELD, E. J.; HOEHN, R. E.; LAPOINT, E. Carbon storage and sequestration by trees in urban and community areas of the united states. **Environmental Pollution**, v. 178, p. 229–236, 2013.

OKUJENI, A.; LINDEN, S. VAN DER; HOSTERT, P. Remote sensing of environment extending the vegetation – impervious – soil model using simulated enmap data and machine learning. **Remote Sensing of Environment**, v. 158, p. 69–80, 2015.

OKUJENI, A.; VAN DER LINDEN, S.; JAKIMOW, B.; RABE, A.; VERRELST, J.; HOSTERT, P. A comparison of advanced regression algorithms for quantifying urban land cover. **Remote Sensing**, v. 6, n. 7, p. 6324–6346, 2014.

OSHIO, H.; ASAWA, T.; HOYANO, A.; MIYASAKA, S. Estimation of the leaf area density distribution of individual trees using high-resolution and multi-return airborne LiDAR data. **Remote Sensing of Environment**, v. 166, p. 116–125, 2015.

PHINN, S.; STANFORD, M.; SCARTH, P.; MURRAY, A. T.; SHYY, P. T. Monitoring the composition of urban environments based on the vegetation-impervious surface-soil (VIS) model by subpixel analysis techniques. **International Journal of Remote Sensing**, v. 23, n. 20, p. 4131–4153, jan. 2002.

PILLSBURY, N.; REIMER, J. L.; THOMPSON, R. Tree volume equations for fifteen urban species in california. **USDA Forest Service Gen. Tech. Rep.** PSW-GTR-160. 1998.

PINHO, C. M. D. DE; FONSECA, L. M. G.; KORTING, T. S.; ALMEIDA, C. M. DE; KUX, H. J. H. Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. **International Journal of Remote Sensing**, v. 33, n. 19, p. 5973–5995, 10 out. 2012.

POWELL, R. L.; ROBERTS, D. A. Characterizing urban land-cover change in Rondônia, Brazil: 1985 to 2000. **Journal of Latin American Geography**, v. 9, n. 3, p. 183–211, 2010.

POWELL, R. L.; ROBERTS, D. A. Characterizing variability of the urban physical environment for a suite of cities in Rondônia, Brazil. **Earth Interactions**, v. 12, n. 13, p. 1–32, ago. 2008.

POWELL, R.; ROBERTS, D.; DENNISON, P.; HESS, L. Sub-pixel mapping of urban land cover using multiple endmember spectral mixture analysis: Manaus, Brazil. **Remote Sensing of Environment**, v. 106, n. 2, p. 253–267, 30 jan. 2007.

PU, R.; GONG, P.; MICHISHITA, R.; SASAGAWA, T. Spectral mixture analysis for mapping abundance of urban surface components from the Terra/ASTER data. **Remote Sensing of Environment**, v. 112, n. 3, p. 939–954, 2008.

PU, R.; LANDRY, S. A comparative analysis of high spatial resolution IKONOS and WORLDVIEW-2 imagery for mapping urban tree species. **Remote Sensing of Environment**, v. 124, p. 516–533, 2012.

PU, R.; LANDRY, S.; ZHANG, J. Evaluation of atmospheric correction methods in identifying urban tree species with WORLDVIEW-2 imagery. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 8, n. 5, p. 1–12, 2014.

RACITI, S. M.; HUTYRA, L. R.; NEWELL, J. D. Mapping carbon storage in urban trees with multi-source remote sensing data: relationships between biomass, land use, and demographics in boston neighborhoods. **Science of the Total Environment**, v. 500-501, p. 72–83, 2014.

RIDD, M. K. Exploring a v-i-s model for urban ecosystem through remote sensing: a comparative anatomy for cities. **International Journal of Remote Sensing**, v. 16, n. 12, p.

2165–2185, 1995.

ROBERTS, D. A.; GARDNER, M.; CHURCH, R.; USTIN, S.; SCHEER, G. Mapping chaparral in the Santa Monica mountains using multiple endmember spectral mixture models. **Remote Sensing of Environment**, v. 65, p. 267–279, 1998.

ROESSNER, S.; SEGL, K.; HEIDEN, U.; KAUFMANN, H. Automated differentiation of urban surfaces based on airborne hyperspectral imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v. 39, n. 7, p. 1525–1532, 2001.

SCHMITT, M.; SHAHZAD, M.; ZHU, X. X. Reconstruction of individual trees from multi-aspect TOMOSAR data. **Remote Sensing of Environment**, v. 165, p. 175–185, 2015.

SCHREYER, J.; GEIS, C.; LAKES, T. TANDEM-X for large-area modeling of urban vegetation height: evidence from Berlin, Germany. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 9, n. 5, 2016.

SELLERS, P. J.; DICKINSON, R. E.; RANDALL, D. A.; BETTS, A. K.; HALL, F. G.; BERRY, J. A.; COLLATZ, G. J.; DENNING, A. S.; MOONEY, H. A.; NOBRE, C. A.; SATO, N.; FIELD, C. B.; HENDERSON-SELLERS, A. Modeling the exchanges of energy, water, and carbon between continents and the atmosphere. **Science**, v. 275, n. 5299, p. 502–509, 1997.

SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 29, n. 1, p. 16–20, 1991.

SHRESTHA, R.; WYNNE, R. H. Estimating biophysical parameters of individual trees in an urban environment using small footprint discrete-return imaging lidar. **Remote Sensing**, v. 4, n. 2, p. 484–508, 2012.

SMALL, C. High spatial resolution spectral mixture analysis of urban reflectance. **Remote Sensing of Environment**, v. 88, n. 1-2, p. 170–186, 2003.

SMALL, C.; LU, J. W. T. Estimation and vicarious validation of urban vegetation abundance by spectral mixture analysis. **Remote Sensing of Environment**, v. 100, n. 4, p. 441–456, 2006.

SONG, C. Spectral mixture analysis for subpixel vegetation fractions in the urban environment: how to incorporate endmember variability? **Remote Sensing of Environment**, v. 95, n. 2, p. 248–263, 2005.

SUN, G.; PANG, Y.; NI, W.; HUANG, W.; LI, Z. Vegetation height and vertical structure. In: LIANG, S.; LI, X.; WANG, J. (Org.). **Advanced Remote Sensing**. 1a. ed. Oxford: Elsevier, 2012. 439–466 p.

SUN, G.; SUN, W.; LIANG, S.; ZHANG, Z.; CHEN, E. Above-ground biomass. In: LIANG, S.; LI, X.; WANG, J. (Org.). **Advanced Remote Sensing**. 1a. ed. Oxford: Elsevier, 2012. 467–499 p.

TANG, J.; TANG, J. Linking spatial pattern and biophysical parameters of urban vegetation by multitemporal landsat imagery. **IEEE Geoscience and Remote Sensing Letters**, v. 10, n. 5, p. 1263–1267, 2013.

TANG, Q.; WANG, L. Urban land-use, land-cover classification through watershed segmentation in the v-i-s feature space. **Remote Sensing Letters**, v. 3, n. 8, p. 677–685, 20 dez. 2012.

TIGGES, J.; LAKES, T.; HOSTERT, P. Urban vegetation classification: benefits of multitemporal RapidEye satellite data. **Remote Sensing of Environment**, v. 136, p. 66–75, 2013.

TOOKE, T. R.; COOPS, N. C.; GOODWIN, N. R.; VOOGT, J. A. Extracting urban vegetation characteristics using spectral mixture analysis and decision tree classifications. **Remote**

Sensing of Environment, v. 113, n. 2, p. 398–407, 2009.

U.S. GEOLOGICAL SURVEY. **Carbon sequestration to mitigate climate change**. 2008.

WENG, Q.; LU, D. Landscape as a continuum: an examination of the urban landscape structures and dynamics of indianapolis city, 1991–2000, by using satellite images. **International Journal of Remote Sensing**, v. 30, n. 10, p. 2547–2577, 2009.

WU, C.; MURRAY, A. T. Estimating impervious surface distribution by spectral mixture analysis. **Remote Sensing of Environment**, v. 84, n. 4, p. 493–505, 2003.

XIAO, Q.; USTIN, S. L.; MCPHERSON, E. G. Using aviris data and multiple-masking techniques to map urban forest tree species. **International Journal of Remote sensing**, v. 25, n. 24, p. 5637–5654, 2004.

YAN, G.; MU, X.; LIU, Y. In: LIANG, S.; LI, X.; WANG, J. Fractional vegetation cover. In: LIANG, S.; LI, X.; WANG, J. (Org.). **Advanced Remote Sensing**. 1a. ed. Oxford: Elsevier, 2012. 415–438 p.

ZHANG, C. Multiscale quantification of urban composition from EO-1/HYPERION data using object-based spectral unmixing. **International Journal of Applied Earth Observation and Geoinformation**, v. 47, p. 153–162, 2016.

ZHANG, K.; HU, B. Individual urban tree species classification using very high spatial resolution airborne multi-spectral imagery using longitudinal profile. **Remote Sensing**, n. 4, p. 1741–1757, 2012.

ZHANG, X.; FENG, X.; JIANG, H. Object-oriented method for urban vegetation mapping using IKONOS imagery. **International Journal of Remote Sensing**, v. 31, n. 1, p. 177–196, 2010.

ZHOU, W.; TROY, A. An object-oriented approach for analysing and characterizing urban landscape at the parcel level. **International Journal of Remote Sensing**, v. 29, n. 11, p. 3119–3135, 2008.

ZHU, Z.; FU, Y.; WOODCOCK, C. E.; OLOFSSON, P.; VOGELMANN, J. E.; HOLDEN, C. E.; WANG, M.; DAI, S.; YU, Y. Including land cover change in greenness trend analysis based on all available Landsat 5, 7, and 8 images: a case study from Guangzhou, China (2000-2014). **Remote Sensing of Environment**, v. In review, 2016.