

Aplicação de aeronaves remotamente pilotadas e fotogrametria para avaliação e monitoramento de áreas em processo de restauração florestal

*Rafael Walter Albuquerque
Carlos Henrique Grohmann*

Resumo

Diversas atividades humanas acarretam a supressão de vegetação nativa acima dos limites legais, tornando necessária a Restauração Florestal (RF). No campo das geotecnologias, câmeras convencionais acopladas a *drones*, ou *Remotely Piloted Aircrafts* (RPAs), podem aprimorar o processo de monitoramento da RF. O objetivo desta pesquisa é estudar a aplicação de RPA e fotogrametria para avaliação e monitoramento de quatorze áreas em processo de RF, sendo sete na Amazônia e sete na Mata Atlântica. Seguindo o Protocolo de Monitoramento da RF da Mata Atlântica, dois importantes aspectos da vegetação foram obtidos por RPA e fotogrametria: (i) estrutura, que consistiu no uso de dados altimétricos, algoritmo Máxima Local, índice de vegetação e *machine learning* para medir cobertura de dossel, densidade de árvores, cobertura de gramíneas e altura de dossel; e (ii) biodiversidade, que consistiu no uso de *deep learning* na identificação de espécies relevantes para a RF e no delineamento das copas das árvores, que foram avaliadas quanto ao grau de heterogeneidade frente a dados de campo. RPA e fotogrametria mostraram êxito na medição

de todos os indicadores, mas trabalhos futuros devem coletar mais dados acerca de biodiversidade para criação de modelos com maior capacidade de generalização.

Palavras-chaves: Restauração de Ecossistemas; Drone; Machine Learning; Deep Learning; Governança.

1. INTRODUÇÃO

Diversas são as atividades humanas que acarretam a supressão de vegetação nativa, em muitas vezes excedendo os limites legais, bem como o próprio limite de resiliência natural, tornando necessária a Restauração Florestal (RF) (Aronson; Durigan; Brancalion, 2011). No campo das geotecnologias existem frentes de trabalho que se utilizam de imagens obtidas por Aeronaves Remotamente Pilotadas, ou *Remotely Piloted Aircraft* (RPAs), popularmente conhecidos como *drones*. No entanto, o uso destas imagens é ainda bastante incipiente.

Dentre os diferentes sensores possíveis de serem acoplados aos RPA como plataforma de voo, este trabalho trata de câmeras digitais operantes no espectro visível *Red-Green-Blue* (RGB). Os RPA portadores de sensores RGB são considerados RPA de baixo custo (Tarolli, 2014), sendo que tais equipamentos possibilitam o registro detalhado de paisagens em visão panorâmica/tridimensional através da tecnologia *Structure from Motion and Multi-View-Stereo* (SfM-MVS) (Colomina; Molina, 2014).

Diante deste contexto, urge a necessidade de estudar possíveis contribuições que o uso de RPA e SfM-MVS (RPA-SfM) pode proporcionar ao monitoramento de projetos de RF. O objetivo do presente trabalho não é detalhar os métodos científicos aplicados na pesquisa, porque tais detalhes já se encontram publicados em periódicos científicos e foram objeto de tese defendida no Programa de Pós-graduação em Ciência Ambiental (Procam) da USP. O objetivo do presente trabalho é, portanto, divulgar de forma sucinta os métodos científicos utilizados na pesquisa.

2. MATERIAIS E MÉTODOS

2.1 Área de estudo

A figura 1 mostra os municípios das quatorze áreas de estudo: dois municípios situam-se na Amazônia e três na Mata Atlântica. Todas essas áreas de estudo, em ambos os biomas, foram selecionadas de forma a abranger diferentes técnicas de RF.

Na Amazônia, todas as quatro áreas de estudo no município de Apuí (AM), detalhadas em Albuquerque *et al.* (2020), eram pastagem, mas cada uma passou por diferentes métodos de RF. No município de Jirau (RO), as três áreas de estudo, detalhadas em Albuquerque *et al.* (2022b), diferiam entre si quanto aos métodos de RF, mas as três fazem parte de Área de Preservação Permanente de represa hidrelétrica.

Dentre os municípios situados na Mata Atlântica, a área de estudo em Miguel Pereira (RJ), detalhada em Albuquerque *et al.* (2021), era uma pastagem, sendo o projeto de RF considerado referência na região. As três áreas de estudo do município de Extrema (MG), detalhada em Albuquerque *et al.* (2022a) eram todas pastagens, mas possuíam diferentes métodos de RF. As três áreas de estudo em São José dos Campos (SP), também detalhadas em Albuquerque *et al.* (2022a), são experimentos de RF monitorados por grupos de pesquisa.

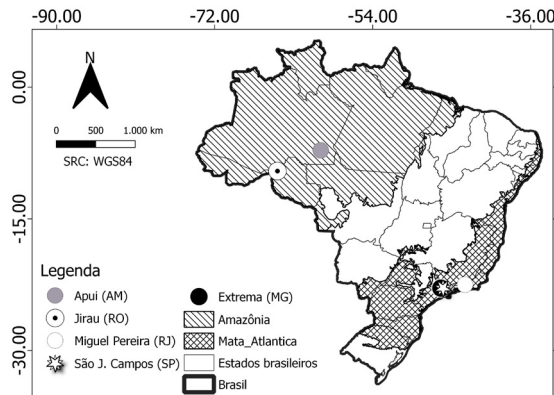


Figura 1 – Áreas de estudo do presente trabalho.

Fonte: Elaborada pelos autores.

2.2 Materiais

O RPA utilizado foi o Phantom 4 Pro embarcado com sensor RGB 1”CMOS 20MP. *Ground Control Points* (GCP), ou pontos de controle foram coletados pelo *Global Navigation Satellite System* (GNSS) geodésico Spectra Precision SP60. O planejamento de voo foi feito utilizando-se o software *Map Pilot*. O Modelo Digital de Superfície (MDS), Modelo Digital de Terreno (MDT), *Canopy Height Model* (CHM), que é a diferença entre MDS e MDT, e ortomosaico foram gerados no software *Agisoft Metashape*.

Os procedimentos de machine learning (*Random Forest*), regressão linear e gráficos foram realizados em R versão 3.6. O *Deep Learning* foi feito utilizando a linguagem de programação Python versão 3.5. Os índices de vegetação e layouts dos mapas foram feitos no software QGIS versão 3.12.

2.3 Métodos

• Parâmetros estruturais

O monitoramento da RF neste trabalho seguiu a abordagem de duas fases utilizada no protocolo de monitoramento da RF do Pacto pela Restauração da Mata Atlântica (PACTO): estruturação do dossel; e trajetória ecológica (Viani *et al.*, 2013).

Para obter alguns dos indicadores relevantes da primeira fase da RF via RPA-SfM, uma análise da estrutura da vegetação ocorreu por contagem automática de árvores na área de estudo de Apui (AM). Conforme descrito em Albuquerque *et al.* (2020), foi analisado se o algoritmo Máxima Local gera resultados mais acurados quando aplicado sobre o MDS ou sobre o CHM.

Em Albuquerque *et al.* (2021), além do indicador densidade de árvores, foram avaliados também o dossel (copas das árvores no estrato superior da floresta) e a ocorrência de gramíneas. Assim, os indicadores estruturais avaliados na área de estudo em Miguel Pereira (RJ) foram: cobertura de dossel, altura de dossel e infestação de gramíneas. A altura do dossel foi calculada extraíndo-se os valores CHM das árvores identificadas automaticamente (Albuquerque *et al.*, 2020). A cobertura de dossel poderia ser medida utilizando-se apenas o CHM, mas para incluir algumas árvores pequenas em regiões íngremes, também foram utilizadas: uma camada de dados do índice *Triangular Greenness Index* (TGI) chamada neste trabalho por TGIveg; uma camada contendo dados de desvio padrão do MDS, chamada neste trabalho de SDdsm; e uma camada de classificação *Random Forest* envolvendo três classes (vegetação, sem-vegetação, sombra). A equação 1 mostra como essas camadas foram utilizadas no cálculo da cobertura de dossel. Na equação 1, a expressão maior que zero é utilizada para possibilitar a execução do processo com uma linha de código ao invés de duas. Afinal, valores negativos nesse caso não são considerados como cobertura de dossel.

$$\text{CoberturaDossel} = [(TGIveg + SDdsm + CHM) - (3 * Sombra) > 0] \quad (1)$$

Com relação ao indicador estrutural infestação de gramíneas, ele foi obtido conforme equação 2. No caso, a classe vegetação da camada *Random Forest* envolve árvores e gramíneas, então a cobertura apenas de gramíneas foi obtida pela diferença entre toda a vegetação e a cobertura de dossel.

$$\text{Gramíneas} = \text{Vegetação} - \text{CoberturaDossel} \quad (2)$$

O método utilizado para obter a cobertura de dossel em Albuquerque *et al.* (2021) buscou um aprimoramento da acurácia do indicador cobertura de dossel porque pequenas árvores em regiões íngremes não foram incluídas no CHM. Entretanto, o ganho de acurácia não foi significativo, sendo que é possível obter a cobertura de dossel de forma acurada lançando-se mão de metodologia mais simples. Neste método, descrito em Albuquerque *et al.* (2022a) e utilizado nas áreas de estudo em Extrema (MG) e São José dos Campos (SP), basta selecionar o intervalo de altura do CHM que separa árvores de gramíneas. Este método é o mais recomendado para mapeamento do indicador cobertura de dossel devido à sua praticidade e acurácia.

• Parâmetros de biodiversidade

A avaliação da biodiversidade, descrita em Albuquerque *et al.* (2022b), foi realizada nas áreas de estudo situadas em Jirau (RO). Foram utilizadas técnicas de *deep learning* (Mask-RCNN) e análises de regressão.

Dois espécies chave para a gestão da RF na Amazônia (*Cecropia* sp. e *Vismia* sp.) foram mapeadas utilizando-se *deep learning*. Também via *deep learning* realizou-se o delineamento das copas de todas as árvores. Após delineadas as copas, uma análise de regressão avaliou a relação de suas medidas de heterogeneidade estrutural com as medidas de diversidade de espécies. Considerou-se na regressão, como variável independente (dado que conseguimos medir), as medidas de heterogeneidade nas imagens obtidas via RPA de baixo custo, e como variável dependente (dado que queremos estimar), a medida de riqueza de espécies obtida em trabalhos convencionais de campo.

• Avaliação de acurácia

Para avaliação da acurácia, os erros de omissão (Falso-Negativo; FN), comissão (Falso Positivo; FP) e Acurácia Geral (Congalton, 1991) (equação 3) permitem o cálculo dos índices Recall (percentual dos alvos existentes devidamente identificados), Precisão (probabilidade de uma previsão estar correta) e F1 (média harmônica de Recall e Precisão) conforme as equações 4, 5 e 6, respectivamente. Tais índices variam de 0 (zero) a 1 (um), sendo que o valor 1 (um) indica totalmente acurado. Erros de comissão e omissão também permitem a avaliação de acurácia através de matriz de confusão (CONGALTON, 1991), que mostra para todas as classes os valores dos erros (FN e FP) e dos acertos (Verdadeiro-Positivo – VP; e Verdadeiro-Negativo – VN).

$$\text{AcuráciaGeral} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3)$$

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

$$p = \frac{VP}{VP + FP} \quad (5)$$

$$F1 = \frac{2 * (r * p)}{(r + p)} \quad (6)$$

Onde: VP = Verdadeiro Positivo, FN = Falso Negativo, FP = Falso Positivo, r = recall, p = precisão

Conforme explicado em Albuquerque *et al.* (2022b), a acurácia de alvos mapeados por *deep learning* também envolveu os índices Acurácia Geral, Recall, Precisão e F1,

mas neste caso considerando toda a área das amostras de testes, sendo que as amostras de teste devidamente identificadas são aquelas em que mais de 50% de sua área é mapeada. A detecção de alvos por *deep learning* também avaliou a acurácia do delimitamento dos alvos, mas neste caso medida pelo índice *Intersection over Union* (IoU) (equação 4), onde árvores corretamente delimitadas apresentam $\text{IoU} \geq 0,5$ (ALBUQUERQUE *et al.*, 2022b).

$$\text{IoU}(\text{AmostraTeste}, \text{MapeamentoAutomático}) = \frac{\text{AmostraTeste} \cap \text{MapeamentoAutomático}}{\text{AmostraTeste} \cup \text{MapeamentoAutomático}} \quad (4)$$

3. RESULTADOS

3.1 Parâmetros estruturais

A figura 2 mostra os resultados na área de estudo em Apui (AM). Já a tabela 1 mostra que a contagem automática de árvores via algoritmo Máxima Local, para obter o indicador densidade de árvores, é mais precisa utilizando-se o MDS do que o CHM, pois os valores de r, p e F1 são maiores em quase todas as situações. Mais detalhes sobre esses resultados em Albuquerque *et al.* (2020).

Em relação à medição dos indicadores estruturais de RF na área de estudo em Miguel Pereira (RJ), os resultados em parte da área são mostrados na Figura 3. A contagem automática de árvores para obtenção do indicador densidade de árvores apresentou Recall, Precision, F-score, e Acurácia geral equivalentes a 0,93, 0,90, 0,92 e 0,87, respectivamente. A altura de dossel média prevista (via CHM obtido por RPA-SfM) e medida em campo (referência) foi equivalente a, respectivamente, 1,68 m e 1,93 m, considerada acurada porque imagens de RPA de baixo custo subestimam alturas de árvores de 2 metros de altura em aproximadamente 13% (neste caso, superestimar seria problema porque errar para mais sugeriria que a RF está melhor do que a realidade). Sobre os indicadores cobertura de dossel e infestação de gramíneas, a tabela 2 traz os resultados da acurácia.

Sobre o método apontado como o mais indicado para medição da cobertura de dossel via RPA de baixo custo, método este aplicado nas áreas de estudo de Extrema (MG) (Figura 4.a, 4.b e 4.c) e São José dos Campos (SP) (Figura 4.d, 4.e e 4.f), a tabela 3 mostra que há alta acurácia. Todos os valores F1 foram maiores que 0,9, enquanto as médias de Acurácia Geral, Precision, Recall e F1 dos estudos de caso foram equivalentes a 0,97, 0,96, 0,98, e 0,97, respectivamente, reforçando a robustez do método.

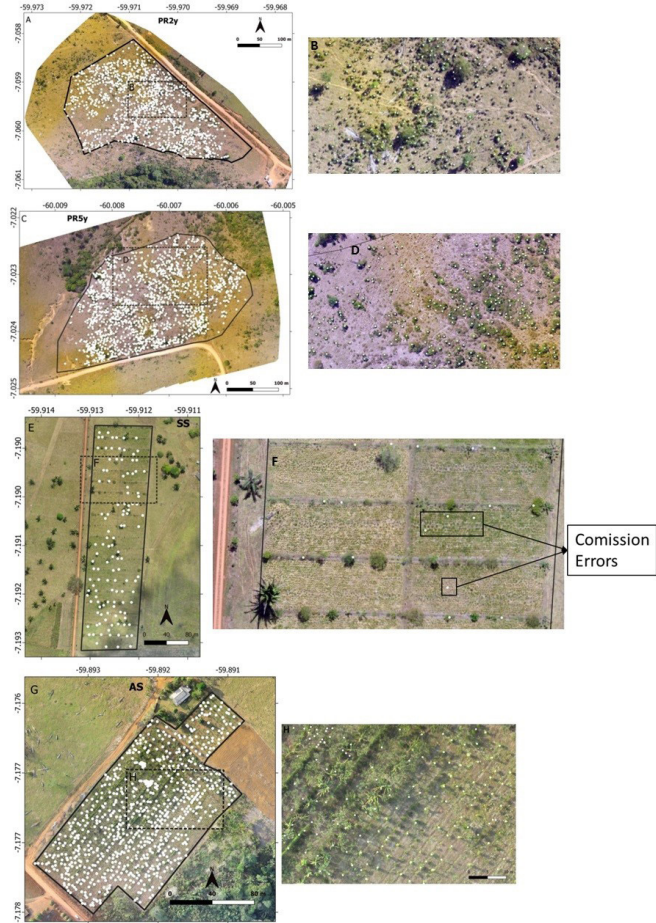


Figura 2 – Síntese dos resultados na área de estudo em Apui (AM). Cada ponto em branco representa uma árvore identificada automaticamente sobre a base MDS, que apresentou melhores resultados que a base CHM.

Fonte: Albuquerque *et al.* (2020).

Tabela 1 - Número de árvores identificadas automaticamente e acurácia dos resultados obtidos utilizando as bases MDS e CHM

Área de estudo	No. de árvores existentes	No. de árvores mapeadas automaticamente	VP	FP	FN	r	p	F1	Acurácia geral
RP2a base MDS	1.794	1.204	1.192	12	602	0,66	0,99	0,80	0,66
RP2a base CHM	1.794	1.075	1.047	28	747	0,58	0,97	0,73	0,58

Área de estudo	No. de árvores existentes	No. de árvores mapeadas automaticamente	VP	FP	FN	r	p	F1	Acurácia geral
RP5a base DSM	1.947	1.499	1.497	2	450	0,77	1,00	0,87	0,77
RP5a base CHM	1.947	1.288	1.268	20	679	0,65	0,98	0,78	0,65
SS base DSM	412	128	86	42	326	0,21	0,67	0,32	0,21
SS base CHM	412	204	100	104	312	0,24	0,49	0,32	0,24
SA base DSM	4.027	810	794	16	3.233	0,20	0,98	0,33	0,20
SA base CHM	4.027	1.015	841	174	3.186	0,21	0,83	0,33	0,21

Onde VP = Verdadeiro Positivo, FP = Falso Positivo, FN = Falso Negativo, r = *recall*, p = *precision* e F = *F1-score*, RP2a = Restauração Passiva com 2 anos de abandono, RP5a = Restauração Passiva com 5 anos de abandono, SS = Sistema Silvopastoril, SA = Sistema Agroflorestal.

Fonte: Elaborada pelos autores.

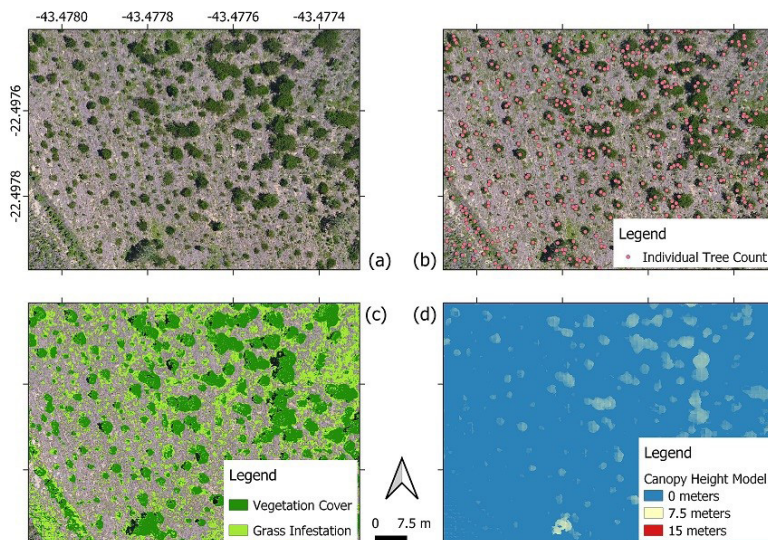


Figura 3 – Síntese dos resultados na área de estudo em Miguel Pereira (RJ): (a) ortomosaico; (b) coordenadas geográficas representando árvores identificadas automaticamente; (c) detecção automática de ocorrência de árvores e de gramíneas; (d) altura das árvores no terreno.

Fonte: Albuquerque *et al.* (2021).

Tabela 2 - Matriz de confusão do mapeamento de cobertura de dossel e infestação de gramíneas.

		Referência		
		Gramíneas	Dossel	Outras Classes
Previsão	Gramíneas	26 (52%)	5 (10%)	0 (0%)
	Dossel	1 (2%)	41 (82%)	4 (8%)
	Outras Classes	23 (46%)	4 (8%)	46 (92%)

Fonte: Elaborada pelos autores.

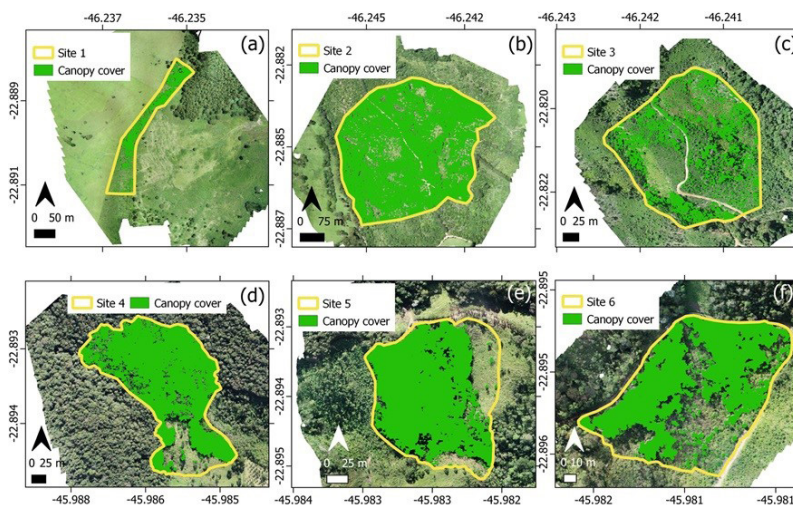


Figura 4 – Síntese dos resultados na área de estudo em Extrema (MG) e em São José dos Campos (SP).

Fonte: Albuquerque *et al.* (2022a).

3.2 Parâmetros de biodiversidade

A Figura 5 ilustra uma síntese dos resultados obtidos para os parâmetros de biodiversidade. Já a tabela 4 apresenta os valores de acurácia obtidos no mapeamento das espécies *Cecropia* sp. e *Vismia* sp., bem como no delineamento das copas de todas as árvores. Resultados foram acurados, exceto o delineamento de *Vismia* sp.

A Figura 6 mostra que a diversidade de espécies medida em campo possui relação com alguns atributos de heterogeneidade obtidos nas imagens adquiridas via RPA-SfM,

como área da copa, perímetro da copa e componente principal da transformada de Fourier. Apesar da regressão contar apenas com 5 amostras, esses atributos apresentaram p-valor < 0,05.

Tabela 3 - Valores de acurácia da cobertura de dossel dos estudos de caso em Extrema (MG) e em São José dos Campos (SP)

Acurácia da cobertura de dossel					
Área de RF	Cobertura dossel	Acurácia Geral	Precision	Recall	F1
FR ativa de 6 anos com trecho de FR ativa de 1 ano	0,417	0,935	0,892	0,99	0,938
RF ativa de 4 a 16 anos variando em diferentes trechos	0,735	0,97	0,99	0,95	0,969
RF ativa e passiva de 1 ano com trechos de floresta madura	0,353	0,965	1	0,93	0,964
RF ativa de 40 anos com trechos de gramíneas	0,698	0,985	0,98	0,99	0,985
Floresta madura com trechos de gramíneas	0,646	0,985	0,971	1	0,985
Floresta madura com trechos de RF ativa de 1 ano	0,518	0,975	0,952	1	0,976

Fonte: Elaborada pelos autores.

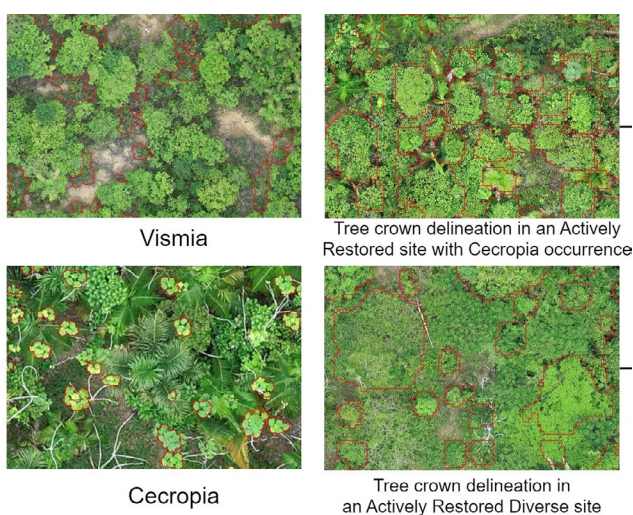


Figura 5 – Síntese dos resultados na área de estudo em Jirau (RO).

Fonte: Albuquerque *et al.* (2022b).

Tabela 4 - Acurácia quanto ao delineamento e distribuição de área da rede Mask-RCNN. RN é Regeneração Natural com ocorrência de *Vismia* sp., ARCEC é Área de Restauração ativa com *Cecropia* sp. e ARFD é área de Restauração Ativa em Floresta Diversa

		Cecropia: ARCEC	Vismia: RN	Árvores: ARCEC	Árvores: ARFD	Cecropia: ARD (apenas teste)
Parâmetro de Acurácia de delineamento	Árvores identificadas	91.25%	72.92%	72.00%	56.00%	80.00%
	Copas de árvores corretamente delineadas	0.918	0.086	0.667	0.607	1.000
	IoU Precisão Recall	0.772 0.937 0.820	0.202 0.221 0.888	0.563 0.730 0.764	0.558 0.764 0.738	0.790 0.989 0.798
	F1	0.875	0.354	0.746	0.751	0.883
Parâmetro de Acurácia de área	Acurácia Geral	0.993	0.926	0.902	0.642	0.981
	Precisão	0.976	0.760	0.893	0.932	0.943
	Recall	0.752	0.796	0.616	0.565	0.669
	F1	0.849	0.777	0.729	0.704	0.783

Fonte: Elaborada pelos autores.

4. DISCUSSÃO

Todos os parâmetros avaliados no presente estudo apresentaram boa acurácia. Com relação aos parâmetros estruturais, além dos resultados acurados, os métodos relatados, exceto para o indicador infestação de gramíneas, podem ser aplicados em outras imagens obtidas por RPA de baixo custo. Tal capacidade de generalização a outras imagens é possível porque a base de dados utilizada é a nuvem de pontos, que não sofre influência de luz solar (Albuquerque *et al.*, 2021; Albuquerque *et al.*, 2022a). Cabe ressaltar, entretanto, que o indicador Altura de Dossel pode ser medido por RPA de baixo custo, em condições de dossel fechado, somente se as imagens possuírem pontos de controle (Albuquerque *et al.*, 2021).

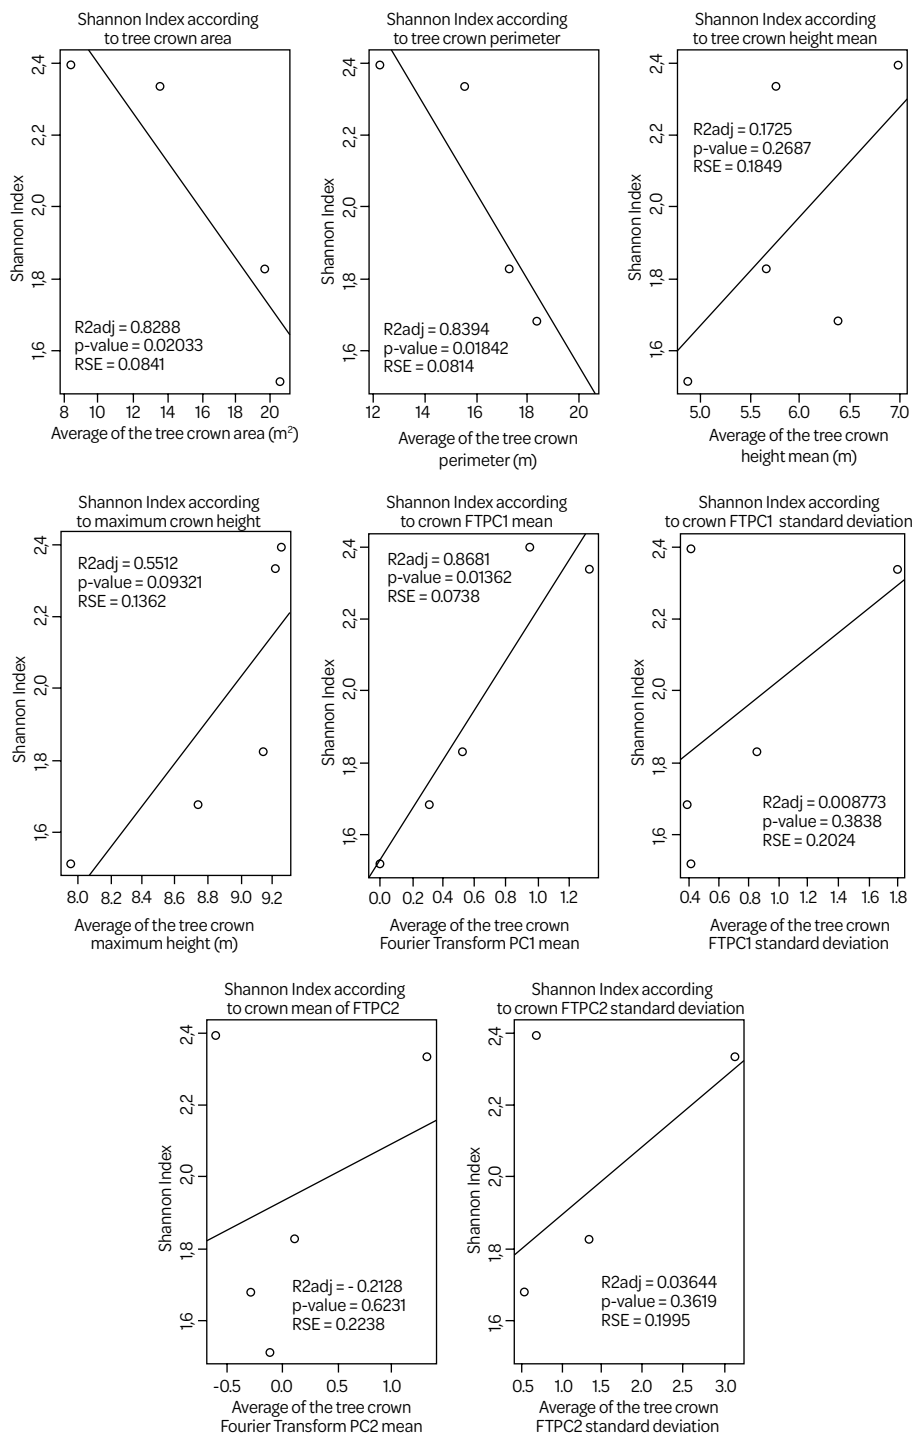


Figura 6 – Regressão linear entre atributos de heterogeneidade das imagens obtidas por sobrevoo de RPA de baixo custo e diversidade de espécies medida em campo.

Fonte: Albuquerque *et al.* (2022b).

Ainda sobre os parâmetros estruturais, o método de obtenção do indicador Infestação de Gramíneas não possui capacidade de generalização porque usa dados do ortomosaico, que sofre influência da luz solar (diferentes padrões de luz ao longo do dia e do ano). A ocorrência de gramíneas, entretanto, é um indicador de menor relevância frente aos demais parâmetros estruturais (Albuquerque *et al.*, 2021).

A falta de capacidade de generalização na identificação de alvos em imagens também se mostrou presente no método de medição de parâmetros de biodiversidade de RF. Apesar de ter apresentado boa acurácia em geral (exceto em *Vismia* sp., que apresentou desempenho satisfatório da distribuição das áreas, mas não no delimitamento), a tecnologia *deep learning* também foi aplicada sobre o ortomosaico. O efeito *data drift*, que mostra a capacidade de generalização do modelo, foi evidenciado no mapeamento de *Cecropia* sp. Na área utilizada para treinamento e mapeamento, o modelo obteve um desempenho melhor do que na área utilizada apenas para mapeamento. Logo, trabalhos futuros devem sobrevoar outras áreas e em diferentes horários do dia e estações do ano.

Sobre a regressão linear para estimar a riqueza de espécies, os atributos área da copa, perímetro da copa e componente principal da transformada de Fourier apresentaram resultados estatisticamente significativos (p -valor $< 0,05$). Entretanto, o total de 5 amostras, por si só, não pode ser considerado suficiente, fazendo com que o p -valor $< 0,05$ evidencie apenas a potencialidade do método, reforçando que trabalhos futuros colem mais dados para que seja atingida a suficiência amostral.

5. CONSIDERAÇÕES FINAIS

RPAs de baixo custo mostraram potencial no monitoramento de RF. Cobertura e altura do dossel podem ser mensuradas de forma generalizável utilizando-se a nuvem de pontos, sendo que a altura de dossel requer disponibilidade de MDT preciso em situações de dossel fechado. Já os parâmetros de biodiversidade, apesar de acurados neste estudo, requerem coleta de mais dados para se obter modelos generalizáveis. Tais modelos de biodiversidade devem ser capazes de apresentar bom desempenho em diferentes condições de luz, bem como diferentes fases de projetos de RF. Ou seja, os modelos de biodiversidade propostos devem ser estudados em imagens diferentes das avaliadas no presente trabalho.

6. FINANCIAMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (Capes) – Código de Financiamento 001. Este trabalho também teve contribuições financeiras da Embrapa Cenargen, TNC, WRI e WWF. Carlos Henrique Grohmann (proc. #311209/2021-1) é bolsista de produtividade de pesquisa CNPq.

7. AGRADECIMENTOS

À Capes pela concessão de bolsa nacional e internacional (PrIntUSP). À Sociedade Brasileira de Restauração Ecológica (SOBRE), Departamento de Ciência da Computação da Universidade de Copenhage (DIKU), Embrapa CENARGEN, Embrapa Meio Ambiente, The Nature Conservancy (TNC), World Wide Fund for Nature (WWF) e World Resources Institute (WRI) pelo apoio profissional e estímulo ao desenvolvimento desta pesquisa. Ao Instituto de Energia e Ambiente da Universidade de São Paulo (IEE-USP) pelo apoio institucional, ao Spatial Modelling Laboratory (SPAM Lab) e ao Laboratório de Processamento de Imagens e Geoprocessamento (Lapig), Programa Pro-Vant, pela infraestrutura e ambiente de trabalho.

REFERÊNCIAS

- ALBUQUERQUE, R. W.; COSTA, M. O.; FERREIRA, M. E.; CARRERO, G. C.; GROHMANN, C. H. Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the amazon. *Journal of Unmanned Vehicle Systems*, NRC Research Press 1840 Woodward Drive, Suite 1, Ottawa, ON K2C 0P7, v. 8, n. 3, p. 207–223, 2020.
- ALBUQUERQUE, R. W.; FERREIRA, M. E.; OLSEN, S. I.; TYMUS, J. R. C.; BALIEIRO, C. P.; MANSUR, H.; MOURA, C. J. R.; COSTA, J. V. S.; BRANCO, M. R. C.; GROHMANN, C. H. Forest restoration monitoring protocol with a low-cost remotely piloted aircraft: lessons learned from a case study in the brazilian atlantic forest. *Remote Sensing*, v. 13, n. 12, 2021. Disponível em: <https://www.mdpi.com/2072-4292/13/12/2401>.
- ALBUQUERQUE, R. W.; MATSUMOTO, M. H.; CALMON, M.; FERREIRA, M. E.; VIEIRA, D. L. M.; GROHMANN, C. H. A protocol for canopy cover monitoring on forest restoration projects using low-cost drones. *Open Geosciences*, v. 14, n. 1, p. 921–929, 2022. Disponível em: <https://doi.org/10.1515/geo-2022-0406>
- ALBUQUERQUE, R. W.; VIEIRA, D. L. M.; FERREIRA, M. E.; SOARES, L. P.; OLSEN, S. I.; ARAUJO, L. S.; VICENTE, L. E.; TYMUS, J. R. C.; BALIEIRO, C. P.; MATSUMOTO, M. H.; GROHMANN, C. H. Mapping key indicators of forest restoration in the amazon using a low-cost drone and artificial intelligence. *Remote Sensing*, v. 14, n. 4, 2022. ISSN 2072-4292. Disponível em: <https://www.mdpi.com/2072-4292/14/4/830>.
- ARONSON, J.; DURIGAN, G.; BRANCALION, P. Conceitos e definições correlatos à ciência e à prática da restauração ecológica. *IF Série Registros*, v. 44, p. 1–38, 2011. Disponível em: <http://www.lerf.esalq.usp.br/divulgacao/recomendados/artigos/aronson2011.pdf>. Acesso em: 20 out. 2016.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of photogrammetry and remote sensing*, Elsevier, v. 92, p. 79–97, 2014.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote sensing of environment*, v. 37, n. 1, p. 35–46, 1991.

- TAROLLI, P. High-resolution topography for understanding earth surface processes: Opportunities and challenges. *Geomorphology*, v. 216, p. 295–312, 2014.
- VIANI, R.; RODRIGUES, R.; PADOVEZI, A.; FARAH, F. T.; GARCIA, L.; SANGLADE, L.; BRANCALION, P.; CHAVES, R.; BARRETO, T.; STRASSBURG, B.; SCARAMUZZA, C. D. M. *Pacto pela restauração da Mata Atlântica - Protocolo de monitoramento para programas e projetos de restauração florestal*. [S.l.:s.n.], 2013. 61 p. Disponível em: https://www.researchgate.net/publication/304073085_Pacto_pela_restauracao_da_Mata_Atlantica_-_Protocolo_de_monitoramento_para_programas_e_projetos_de_restauracao_florestal. Acesso em: 17 jun. 2021.

