



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E
TECNOLOGIA DA GEOINFORMAÇÃO

RHASSANNO CARACCIOLLO PATRIOTA

**IMAGENS DE SENSORES EMBARCADOS EM AERONAVES REMOTAMENTE
PILOTADAS NA LOCALIZAÇÃO DE CULTIVOS ILÍCITOS - *CANNABIS***

Recife

2020

RHASSANNO CARACCIOLLO PATRIOTA

**IMAGENS DE SENSORES EMBARCADOS EM AERONAVES REMOTAMENTE
PILOTADAS NA LOCALIZAÇÃO DE CULTIVOS ILÍCITOS - CANNABIS**

Dissertação apresentado ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologia da Geoinformação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciências Geodésicas e Tecnologia da Geoinformação.

Área de concentração: Ciências Geodésicas e Tecnologias da Geoinformação.

Orientadora: Prof^a. Dr^a. Lucilene Antunes Correia Marques de Sá.

Coorientadora: Prof^a. Dr^a. Simone Sayuri Sato.

Recife

2020

Catálogo na fonte
Bibliotecário Gabriel Luz, CRB-4 / 2222

- P314i Patriota, Rhassanno Caracciollo.
Imagens de sensores embarcados em aeronaves remotamente pilotadas na localização de cultivos ilícitos - cannabis / Rhassanno Caracciollo Patriota – Recife, 2020.
119 f.: figs., tabs., abrev. e siglas.
- Orientadora: Profa. Dra. Lucilene Antunes Correia Marques de Sá.
Coorientadora: Profa. Dra. Simone Sayuri Sato.
Dissertação (Mestrado) – Universidade Federal de Pernambuco.
CTG. Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, 2020.
Inclui referências e anexos.
1. Ciências Geodésicas. 2. Cannabis. 3. RPA. 4. UAV. 5. Fotogrametria. 6. Aprendizado de máquina. 7. Redes neurais convolucionais. I. Sá, Lucilene Antunes Correia Marques de (Orientadora). II. Sato, Simone Sayuri (Coorientadora). III. Título.

UFPE

526.1 CDD (22. ed.)

BCTG / 2020-142

RHASSANNO CARACCIOLLO PATRIOTA

**IMAGENS DE SENSORES EMBARCADOS EM AERONAVES REMOTAMENTE
PILOTADAS NA LOCALIZAÇÃO DE CULTIVOS ILÍCITOS - CANNABIS**

Dissertação apresentado ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologia da Geoinformação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciências Geodésicas e Tecnologia da Geoinformação.

Área de concentração: Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovada em: ____/____/____.

BANCA EXAMINADORA

Prof^a. Dr^a. Lucilene Antunes Correia Marques de Sá
Universidade Federal de Pernambuco

Prof. Dr. José Luiz Portugal
Universidade Federal de Pernambuco

Prof. Dr. Irineu, da Silva
Universidade de São Paulo

RESUMO

No Brasil, a partir dos anos oitenta, foi iniciado o combate de forma sistêmica ao cultivo de *Cannabis* no *Polígono da Maconha*, o qual está situado, parcialmente, no estado de Pernambuco e inclui as ilhas do rio São Francisco localizadas entre Pernambuco e Bahia. O aprimoramento das técnicas de localização dos plantios levou os órgãos responsáveis pela repressão desta prática ilícita ao uso de Tecnologia da Geoinformação. Por meio de aparelhos receptores GPS e, posteriormente, com coletores de dados com receptor GNSS embarcado, foram desenvolvidos métodos de aquisição, análise e armazenamento de dados espaciais com informações de cultivos erradicados no estado de Pernambuco, criando uma base de dados geoespacial cujas informações de posicionamento geográfico dos plantios foram colhidas por policiais federais. Nesta pesquisa foram estudadas e testadas técnicas de reconhecimento de cultivos de *Cannabis*, por meio de imagens adquiridas por mapeamentos aéreos usando sensores embarcados em aeronaves remotamente tripuladas. Estas imagens foram submetidas à duas formas de classificação supervisionadas, mediante: amostra de *pixels* de reflectância de espécimes de *Cannabis* e aprendizado de máquina, usando redes neurais convolucionais. Quando comparados os dois métodos de reconhecimento, pôde-se constatar que o uso de aprendizado de máquina apresentou melhores resultados do que o método de classificação usando *pixels* de reflectância. O método de aprendizado de máquina foi dividido em três níveis de procedimentos, sendo o segundo nível o que primeiro atingiu precisão de 100%, quando excluídos os dados falsos positivos, demonstrando que as técnicas de reconhecimento de padrões por algoritmos são promissoras para localização de cultivos ilícitos, por intermédio de imagens de sensores embarcados em aeronaves remotamente pilotadas.

Palavras-chave: *Cannabis*. RPA. UAV. Fotogrametria. Aprendizado de máquina. Redes neurais convolucionais.

ABSTRACT

In Brazil, from the 1980s, the fight against cannabis cultivation in the *Polígono da Maconha* was initiated, which is partially located in the state of Pernambuco and includes the islands of the São Francisco River located between Pernambuco and Bahia. The improvement of planting location techniques led the agencies responsible for the repression of this illegal practice to use Geoinformation Technology. Through GPS receiver devices and, later, with data collectors with embedded GNSS receiver, methods of acquisition, analysis and storage of spatial data with information from eradicated crops in the state of Pernambuco were developed, creating a geospatial database whose information of geographical positioning of the plantations were collected by federal police. In this research, techniques for recognizing cannabis crops were studied and tested, using images acquired by aerial mapping using sensors embedded in remotely manned aircraft. These images were submitted to two forms of supervised classification, through: sample of reflectance pixels from *Cannabis* specimens and machine learning, using convolutional neural networks. When comparing the two recognition methods, it was found that the use of machine learning showed better results than the classification method using reflectance pixels. The machine learning method was divided into three levels of procedures, with the second level reaching the first 100% precision, when false positive data were excluded, demonstrating that algorithm pattern recognition techniques are promising for crop location illicit, by means of images of sensors embedded in remotely piloted aircraft.

Keywords: *Cannabis*. RPA. UAV. Photogrammetry. Machine learning. Convolutional neural networks.

LISTA DE FIGURAS

Figura 1 – RPA de asas rotativas.....	16
Figura 2 – RPA de asas fixas.....	16
Figura 3 – Plano de voo para o mapeamento de área de 0,16 km ²	18
Figura 4 – Assinaturas espectrais.....	20
Figura 5 – Capitais do Nordeste.....	33
Figura 6 – Distribuição espacial de plantios de <i>Cannabis</i> em Pernambuco.....	39
Figura 7 – Fluxograma da metodologia.....	41
Figura 8 – Distribuição espacial de plantios erradicados em ilhas.....	42
Figura 9 – Sobreposição de pontos erradicados à imagens orbitais.....	43
Figura 10 – Cálculo da distância entre as linhas de voo.....	44
Figura 11 – Exemplo de plano de voo.....	45
Figura 12 – Localização de cultivo no mosaico de ortofoto.....	48
Figura 13 – Localização de cultivo no mosaico de ortofoto – Orocó B04-2017. ...	49
Figura 14 – Plantios de <i>Cannabis</i>	52
Figura 15 – localização dos cultivos ilícitos do ortomosaico Ibó 07-2017.	55
Figura 16 – Resultado nas áreas A, B, C e D do ortomosaico Ibó 07-2017.....	56
Figura 17 – Ilhas do Município de Belém de São Francisco/PE.....	57
Figura 18 – Sementeiras e respectivas classificações.....	57
Figura 19 – Imagem adquirida durante o voo Ibó 04_05.....	60
Figura 20 – Imagem adquirida durante o voo Ilha Aracapé B03.....	60
Figura 21 – Imagem adquirida durante o voo Remanso 01.....	61
Figura 22 – Imagem adquirida durante o voo Remanso 02.....	61
Figura 23 – Imagem adquirida durante o voo Remanso 02.....	62
Figura 24 – Resultado no nível 1 de classificação – Orocó B04 - 2017.....	62
Figura 25 – Resultado no nível 1 de classificação – Ibó 07 – 2017.....	64
Figura 26 – Área J do mosaico de ortofotos Ibó 07 – 2017.....	64
Figura 27 – Área H do mosaico de ortofotos Ibó 07 – 2017.....	65
Figura 28 – Área D do mosaico de ortofotos Ibó 07 – 2017.....	65

LISTA DE TABELAS

Tabela 1 – Padrões dos plantios no continente e nas ilhas.	40
Tabela 2 – Características dos sensores e parâmetro de voo.	44
Tabela 3 – Planos de voos elaborados.	46
Tabela 4 – Pontos indicados pela análise de imagens.	53
Tabela 5 – Pontos localizados por meio de helicóptero.	53
Tabela 6 – Covas – Ibó 07-2017	56
Tabela 7 – Resultados das métricas avaliadas.	67
Tabela 8 - Resultados para classificação Nível 1.	76
Tabela 9 - Resultados para classificação Nível 2.	77
Tabela 10 - Resultados para classificação Nível 3.	78

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizado de Máquina
ANAC	Agência Nacional de Aviação Civil
BIL	Busca de Cultivos Ilícitos
CBD	Canabidiol
ESRI	<i>Esri World Imagery</i>
ExG	<i>Green Excess Index</i>
GCP	<i>Ground Control Point</i>
GNSS	<i>Global Navigation Satellite System</i>
GPS	<i>Global Positioning System</i>
GSD	<i>Ground Sample Distance</i>
IA	Inteligência Artificial
IDH	Índice de Desenvolvimento Humano
IMU	<i>Inertial Measurement Unit</i>
INPE	Instituto Nacional de Pesquisas Espaciais
ISO	Integrated Sensor Orientation
NDVI	<i>Normalized Difference Vegetation Index</i>
OACI	Organização da Aviação Civil Internacional
ROI	<i>Region of Interest</i>
RPA	Aeronave Remotamente Pilotada
RTK	<i>Real Time Kinematic</i>
SCP	<i>Semi-Automatic Classification Plugin</i>
SfM	<i>Structure-from-Motion</i>
SIFT	<i>Scale Invariant Feature Transform</i>
SINARD	Sistema Nacional de Políticas Públicas sobre Drogas
SUDENE	Superintendência do Desenvolvimento do Nordeste
SVM	<i>Support Vector Machine</i>
THC	Tetra-Hidrocanabinol

SUMÁRIO

1	INTRODUÇÃO	11
1.1	FORMULAÇÃO DO PROBLEMA	12
1.2	HIPÓTESE DA PESQUISA	12
1.3	OBJETIVOS DA PESQUISA	12
1.3.1	Objetivo geral	13
1.3.2	Objetivos específicos	13
2	GEOTECNOLOGIAS DIRECIONADAS À IDENTIFICAÇÃO DA <i>CANNABIS</i>	14
2.1	RPA – AERONAVE REMOTAMENTE PILOTADA	15
2.1.1	Integração de sistemas e sensores	16
2.1.2	Sistemas de gestão de voo	18
2.1.3	Sensores imageadores	19
2.1.4	Aprendizado de máquina – AM	22
2.1.5	Processamento fotogramétrico	26
2.2	AÇÕES DA POLÍCIA FEDERAL NA LOCALIZAÇÃO DA <i>CANNABIS</i>	27
2.2.1	Experiências com Aeronaves Remotamente Pilotadas	29
3	ORIGEM E CARACTERÍSTICAS DA <i>CANNABIS</i>	31
3.1	PRODUÇÃO E CONSUMO	32
3.2	ASPECTOS SOCIAIS DO CULTIVO DE <i>CANNABIS</i>	34
3.3	<i>CANNABIS</i> NO BRASIL	35
3.3.1	Aspectos da Importância do rio São Francisco	36
3.4	REPRESSÃO AO CULTIVO DE <i>CANNABIS</i>	38
3.5	COMBATE AO TRÁFICO DE <i>CANNABIS</i> EM PERNAMBUCO	38
4	METODOLOGIA DA PESQUISA	39
4.1	ÁREA DE ESTUDO	39
4.2	PROCEDIMENTOS METODOLÓGICOS	41
4.2.1	Definição de áreas suspeitas	41
4.2.2	Planos de voo	43
4.2.3	Aquisição de imagens	46
4.2.4	Classificação supervisionada	47
4.2.5	Métricas de avaliação	51
4.2.6	Mapas temáticos	51
4.2.7	Exame de local	52
5	RESULTADOS	54

5.1	Classificação supervisionada com <i>pixel</i> de treinamento	54
5.2	Classificação supervisionada por meio de aprendizado de máquina	58
5.2.1	Classificação Nível 1	58
5.2.2	Classificação Nível 2	59
5.2.3	Classificação Nível 3	59
5.2.4	Classificação de ortomosaicos por meio de aprendizado de máquina	62
6	CONCLUSÃO	66
	REFERÊNCIAS	69
	ANEXO A – RESULTADOS DO APRENDIZADO DE MÁQUINA	76
	ANEXO B – PLANOS DE VOO	79

1 INTRODUÇÃO

Desde a década de 1980, cultivos ilícitos na região conhecida como *Polígono da Maconha*, em parte formado por municípios do estado de Pernambuco, é alvo de operações policiais destinadas à repressão dessa prática criminal. Naquela época, o planejamento operacional e a mobilização de efetivo eram realizados por intermédio de informações obtidas com colaboradores.

O aprimoramento das técnicas de plantio e a extensão da área de ocorrência de cultivo de *Cannabis* na região conduziram à necessidade de reforço nas operações de policiais e ao uso de plataforma aérea para sobrevoar a área e localizar o crime. Geralmente os locais do plantio de *Cannabis* são ilhas do rio São Francisco, proximidades de adutoras, entorno de açudes e locais de difícil acesso, como topos e encostas de serras, regiões para as quais o uso de veículos aéreos é apropriado às investigações policiais.

As equipes policiais destinadas a identificar o local de cultivo ilícito são formadas pela tripulação do helicóptero (piloto, copiloto e operador) e por um policial especialista na identificação de plantio de *Cannabis*. Quando a indicação é positiva para cultivo suspeito, são coletadas as coordenadas geográficas usando receptores GNSS de navegação. Os dados adquiridos são repassados às equipes responsáveis pelo trabalho de erradicação do cultivo, conforme determina o Art. 32, combinado com o Art. 50-A da Lei nº 11.343, de 23 de agosto de 2006 (BRASIL).

O ciclo de crescimento da *Cannabis* é de aproximadamente três meses, portanto, periodicamente são programadas operações visando à erradicação dos plantios, antes de as plantas se tornarem adultas e florescerem. No entanto, nem sempre na ocasião há disponibilidade de helicópteros para a execução dos trabalhos. Outros fatores limitantes desse tipo de veículo é o alto custo operacional e a necessidade de uma tripulação específica. Uma das alternativas viáveis, e proposta nesta pesquisa, é o uso de tecnologias de baixo custo disponíveis atualmente, como as Aeronaves Remotamente Pilotadas – RPAs.

As RPAs tornaram-se instrumentos importantes para a aquisição de dados espaciais usando as técnicas fotogramétricas, inclusive oferecem possibilidades de uso de diferentes tipos de sensor para o imageamento. Trazem, como benefício, custo baixo quando comparadas ao uso de aeronaves tripuladas, como os helicópteros,

usados nas operações de segurança pública, que envolvem alto custo de aquisição, manutenção e treinamento da tripulação.

Nesta pesquisa, verificou-se a viabilidade do uso de RPAs, de técnicas de mapeamento fotogramétrico na aquisição das imagens e aprendizado de máquina na localização de lavouras ilícitas. No decorrer do estudo, foram testados e avaliados métodos de classificação supervisionada para identificação de cultivos de *Cannabis*, a partir de uma base de dados existente a respeito de ocorrência de lavouras ilícitas e imagens adquiridas por meio de RPA nos anos de 2017 e 2019.

1.1 FORMULAÇÃO DO PROBLEMA

O *Polígono da Maconha* envolve vários municípios, com locais de difícil acesso, a exemplo de áreas de serra e de dezenas de ilhas distribuídas em mais de 100 km de extensão da calha do rio São Francisco. Tradicionalmente, o helicóptero tem sido o principal instrumento usado para localizar plantios ilícitos.

A proposta formula a questão: é possível distinguir o cultivo da *Cannabis* de outras culturas e da vegetação nativa empregando técnicas fotogramétricas com imagens adquiridas empregando RPAs? Neste estudo serão empregadas imagens adquiridas com sensores RGB (*Red, Green, Blue*) embarcados em RPAs.

Assim, considerando a possibilidade de localizar cultivos ilícitos com RPA, verifica-se que a pesquisa se reveste de importância significativa, tanto do ponto de vista da redução de custos operacionais quanto da inserção da tecnologia RPA no combate à criminalidade, trazendo benefícios imediatos para a sociedade.

1.2 HIPÓTESE DA PESQUISA

Por meio de imagens adquiridas com sensores embarcados em RPA, é possível localizar cultivos de *Cannabis* situados em ilhas do rio São Francisco.

1.3 OBJETIVOS DA PESQUISA

Para dar andamento à pesquisa, foram definidos objetivos com apresentado nas duas seções seguintes.

1.3.1 Objetivo geral

Propor uma metodologia para a localização de plantios de *Cannabis* usando soluções de mapeamento fotogramétrico apoiada em sensores embarcados em RPAs.

1.3.2 Objetivos específicos

O presente trabalho foi desenvolvido objetivando alcançar os seguintes objetivos específicos:

- a) definir padrões individualizadores do plantio de *Cannabis* em relação às demais culturas locais e à vegetação nativa;
- b) estabelecer procedimentos metodológicos de levantamento aerofotogramétrico em ilhas no rio São Francisco usando RPAs;
- c) elaborar e padronizar métodos de geração de mapas temáticos, de modo a serem eficientes e eficazes nas operações policiais de erradicação de cultivos ilícitos.

2 GEOTECNOLOGIAS DIRECIONADAS À IDENTIFICAÇÃO DA CANNABIS

No que se refere às Tecnologias da Geoinformação na aquisição de dados espaciais a distância, conhecidas como *sensoriamento remoto*, houve significativa evolução das técnicas, dos equipamentos e dos sensores de imageamento. Assim, quem trabalha com Tecnologias da Geoinformação passou a ter à disposição diversas plataformas, a exemplo de satélites imageadores, aeronaves pilotadas, RPAs, veículos terrestres e bases estáticas (JÓZKÓW e TOTH, 2015).

Ao mesmo tempo, a fotogrametria também apresentou ganho significativo, como o desenvolvimento de novos algoritmos de processamento de imagens digitais. Os algoritmos estão dispensando cada vez mais a intervenção de operadores para atingir o seu objetivo, que é a reconstrução de elementos tridimensional, por intermédio de um conjunto de imagens bidimensionais.

As rotinas de visão computacional vêm influenciando no desenvolvimento da Fotogrametria Digital. Um exemplo é o algoritmo SIFT – *Scale Invariant Feature Transform*, que permite o reconhecimento de objetos a partir de pontos característicos invariantes em relação a alteração de escala, iluminação, rotação e ruídos de imagem (LOWE, 1999). O produto gerado pelo algoritmo é uma matriz de pontos homólogos encontrados entre duas ou mais imagens. Esses pontos também são conhecidos como *pontos-chave*.

Nesse contexto, os parâmetros de orientação interior da câmera, que antes exigiam procedimentos específicos de laboratório ou de campo para serem identificados, podem ser obtidos de forma automática por meio de rotinas computacionais, como a SfM – *Structure-from-Motion*, sem que seja necessário usar um conjunto de alvos locados (BRASINGTON, GLASSER, *et al.*, 2012), mas usando a matriz de pontos homólogos obtidos com o SIFT.

Apesar de atuar sob princípios básicos da fotogrametria estereoscópica, o SfM caracteriza-se pelo baixo custo para a coleta de dados espaciais, contrastando com a fotogrametria tradicional por possibilitar a reconstrução automática da cena, a partir de uma série de imagens com sobreposição adequada (CHANDLER, LANE e MICHELETTI, 2015).

Por outro lado, para a aquisição de dados espaciais usando técnicas de fotogrametria digital, os parâmetros de orientação exterior são essenciais para o posicionamento das feições adquiridas durante o levantamento. Considerando a

tecnologia possível de embarcar em uma RPA, diversos são os meios para obtenção de parâmetros de orientação exterior, sendo o de maior precisão o método conhecido como ISO – *Integrated Sensor Orientation*, que combina o georreferenciamento direto com o georreferenciamento indireto, usando pontos de controle e navegação baseada em imagens (JÓZKÓW e TOTH, 2015).

Na pesquisa, foi usada a solução de georreferenciamento direto com sistemas GNSS de navegação e Unidade de Medição Inercial – IMU, pelos quais os dados de posicionamento e atitude do sensor de imageamento foram registrados e armazenados nos arquivos de imagens como metadados, no momento da aquisição realizada pelo imageador.

2.1 RPA – AERONAVE REMOTAMENTE PILOTADA

RPA – *Remotely Piloted Aircraft* é a nomenclatura padronizada pela OACI – Organização da Aviação Civil Internacional e adotada no Brasil pela ANAC – Agência Nacional de Aviação Civil como RPA – Aeronave Remotamente Pilotada, para toda aeronave não tripulada pilotada a partir de uma estação remota com finalidade diversa de recreação (BRASIL, 2017).

As RPAs não foram inicialmente projetadas para a fotogrametria. Entretanto, as novas gerações de RPAs com a inclusão de diferentes sensores embarcados e o desenvolvimento de *softwares* específicos de processamento das imagens adquiridas pela plataforma aérea possibilitaram levantamentos aerofotogramétricos com qualidade adequada à produção de modelos digitais de superfície e mosaicos de ortofotos (DALL'ASTRA, DI CELLA, et al., 2017). Dependendo do sensor embarcado, é possível classificar espécies vegetais em áreas heterogêneas (HE e LU, 2016), auxiliar a agricultura de precisão e realizar fenotipagem de plantas (SAGAN, MAIMAITIJIANG, et al., 2019), por exemplo.

No mercado, há diversos tipos de RPAs, desde modelos com peso de algumas gramas até aeronaves com mais de 10 toneladas (BIGS - BRANDENBURG INSTITUTE, 2012). As RPAs podem ser divididas em dois grandes grupos, quais sejam: aeronaves de asas fixas e aeronaves de asas rotativas, como ilustrado nas figuras 1 e 2.

Figura 1 – RPA de asas rotativas.



Figura 2 – RPA de asas fixas.



Fontes: (DJI, 2019) e (BIGS - BRANDENBURG INSTITUTE, 2012)

As aeronaves de asas fixas possuem autonomia de voo superior, mas necessitam de maiores áreas para pouso e decolagem em relação as de asas rotativas. Portanto, para o uso desse tipo de aeronave, há a necessidade de se identificar ou criar locais com maior infraestrutura, a fim de tornar seguro o uso desses equipamentos, sobretudo no que diz respeito aos procedimentos de pouso (BRECKENRIDGE, DAKINS, *et al.*, 2011).

A vantagem das RPAs de asas rotativas é permitir pousos e decolagens verticais em áreas reduzidas, minimizando a necessidade de área específica para esses procedimentos, além de proporcionarem levantamentos com maior precisão, agilidade e mudanças de direção com mais facilidade (AYAZ, IQBAL, *et al.*, 2015), fazendo com que haja boa adaptação à atividade agrícola, apesar de exigir do operador um número maior de voos quando comparado com RPAs de asas fixas (SENTHILNATH, DOKANIA, *et al.*, 2017).

No quesito resistências às intempéries climáticas, em decorrência de possuírem maior área de contato, as asas fixas são mais sensíveis às rajadas de vento, como as que ocorrem na área de estudo (AGOSTINI, 2015), as quais atingem picos de 25% acima da média anual, principalmente entre os meses de julho e outubro (PERNAMBUCO, 2017).

2.1.1 Integração de sistemas e sensores

A estabilidade e o posicionamento das RPAs são mantidos por intermédio da integração de sensores que podem ser embarcados na aeronave, como IMU – *Inertial Measurement Unit*, e receptores GNSS (JÓZKÓW e TOTH, 2015), possibilitando o

planejamento de voos automáticos para cobertura de áreas previamente estabelecidas.

As IMU são compostas por MEMS – *MicroElectroMechanical Systems*, e têm como principais sensores o acelerômetro e o giroscópio, os quais não só permitem a estabilidade da aeronave, mas também auxiliam na referência direcional.

A unidade inercial é considerada o principal componente de navegação, fornecendo dados de posição e atitude quase contínuos (JÓZKÓW e TOTH, 2015), tendo em vista que o acelerômetro é usado para detectar movimentos translacionais; e o giroscópio, para controlar rotações diferenciais nos eixos X, Y e Z, mantendo a estabilidade da RPA.

Além disso, a possibilidade de acesso aos diversos sistemas globais de posicionamento por satélite – incluindo o Galileo, da Europa; o Compass, da China; e o GLONASS, da Rússia – trouxe robustez às soluções de navegação, cujos dados associados às informações obtidas com a IMU, proporcionaram voos automáticos com discrepância de poucos metros em relação à rota planejada.

Destaca-se, ainda, a possibilidade de ter embarcado receptor GNSS que possibilite a realização de posicionamento cinemático em tempo real (RTK – *Real-Time Kinematic*), fazendo com que a discrepância posicional da RPA seja inferior a 1 metro em relação ao plano de voo planejado (DJI, 2019).

O receptor GNSS, os controladores eletrônicos de velocidade, os rádios e a placa controladora formam o sistema de controle e pilotagem automática das RPAs. A placa controladora é o sistema que governa os movimentos e as atitudes da aeronave, por meio das informações coletadas pelos sensores embarcados e dos comandos recebidos da estação de pilotagem remota (KONG, HU, *et al.*, 2017).

Os rádios são responsáveis por manter o enlace de pilotagem, também conhecido como *link de comando e controle*, entre a aeronave e a estação de pilotagem remota (BRASIL). São fundamentais para a condução segura do voo, pois é por meio deles que o piloto remoto pode intervir na aeronave e recebe os dados de telemetria, que podem incluir velocidade, distância, modo de voo, número de satélites visíveis e estado da bateria da RPA (DJI, 2019).

Para a pesquisa, o conjunto de sistemas e sensores controlando a navegação e o posicionamento adequado da aeronave foi essencial, pois os aerolevantamentos planejados necessitam de RPAs capazes de realizar voos sobre o rio São Francisco, na modalidade automática, cujas missões atingiram distâncias de mais de 2 km em

relação à estação de comando, consumindo até 25 minutos do momento da decolagem até o pouso.

2.1.2 Sistemas de gestão de voo

Para um aerolevante fotogramétrico, é exigido um planejamento de voo específico. Atualmente, têm-se utilizado aplicativos para *smartphones* e *tablets*, dedicados à elaboração de planos de voo para mapeamentos 2D e 3D. Para tanto, os parâmetros de voo e suas funcionalidades devem ser previamente configurados. Entre eles, estão: a altura de voo que altera o GSD (*ground sample distance* – distância correspondente do terreno) da imagem a ser adquirida, valores de sobreposição entre as imagens (transversal e lateral), velocidade e outros parâmetros de voo adequados à geração de produtos fotogramétricos.

Na Figura 3, é mostrado um plano de voo elaborado no aplicativo DroneDeploy para o mapeamento de uma área de 0,16 km² e aquisição de imagens com GSD de 2,2 cm, voando a 75 m de altura em relação ao ponto de decolagem. A definição dessas informações, incluindo os valores de sobreposição entre as imagens e entre as linhas de voo, é importante para a estimativa do tempo de voo, pois as RPAs possuem autonomia de voo limitada.

Figura 3 – Plano de voo para o mapeamento de área de 0,16 km².



Fonte: o autor, 2020.

O Litchi é outro aplicativo que permite elaborar planos de voo. Diferencia-se dos demais por permitir maior intervenção do operador. Nele, é possível configurar velocidade da RPA; espaço de tempo entre aquisição de imagens, pontos de interesse

e parada; mais de uma altura para um mesmo plano de voo; ângulo de inclinação da câmera; e rotas lineares com curvas acentuadas. Na pesquisa, foi utilizado o Litchi para controlar o voo da aeronave e adquirir imagens com sensores RGB.

Um plano de voo deve ser cuidadosamente planejado considerando a posição e atitude da câmera, a trajetória de voo, os blocos de imagens, as sobreposições entre as imagens e a escala referente ao GSD, expressa em milímetros ou centímetros, sendo o valor teórico do GSD para a resolução geométrica dado por:

$$GSD = \frac{\text{Tamanho do Pixel}}{\text{Distância Focal}} \times H_{voo}$$

Sendo: H_{voo} a altura de voo ou distância entre a câmera e o objeto a ser fotografado (GUO, SENTHILNATH, *et al.*, 2019).

2.1.3 Sensores imageadores

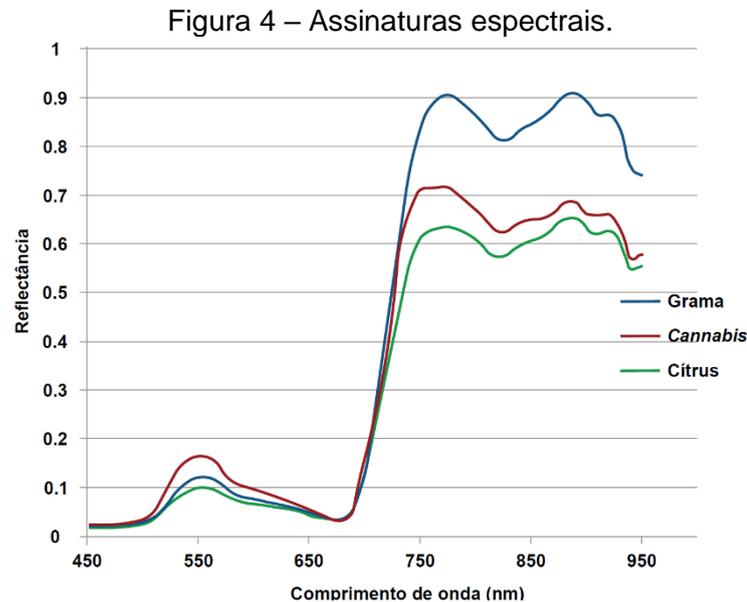
Os sensores imageadores empregados em RPAs também vêm sendo aprimorados, principalmente as câmeras ópticas, que estão disponíveis em pequenos formatos, leves e de baixo custo. As câmeras não métricas estão fornecendo imagens de alta resolução espacial, GSD milimétricos ou centimétricos, proporcionando nuvens densas de pontos derivadas, modelos digitais de superfície (MDS) e, conseqüentemente, mosaicos de ortofotos ricos em detalhes (JÓZKÓW e TOTH, 2015).

Entre os diversos tipos de imageador que podem ser embarcados em RPAs, para a aquisição de dados espaciais, têm-se os sensores: RGB, multiespectrais, hiperespectrais e termográficos.

Os sensores hiperespectrais e os termais, apesar de produzirem excelentes resultados para a agricultura de precisão, são ainda caros e excessivamente pesados para as RPAs, além de produzirem dados difíceis de processar e analisar (DENG, MAO, *et al.*, 2018).

Ressalta-se que o sensor de imagens é a carga mais importante quando se fala de RPAs usadas na agricultura. O tamanho e o peso do imageador são fatores consideráveis e determinantes para viabilizar voos seguros, considerando a capacidade de carga da aeronave (SENTHILNATH, DOKANIA, *et al.*, 2017).

A utilidade de sensores hiperespectrais para discriminação de vegetais foi confirmada por Azaria, Goldschleger e Ben-Dor (2012). Os autores desenvolveram uma pesquisa que resultou na composição das assinaturas espectrais contínuas para dosséis de *Cannabis*, cítrus e grama verde, como apresentado na Figura 4. A tomada das imagens foi realizada no alto de um edifício de 30 m, perfazendo uma distância de até 70 m da área de cultivo.



Fonte: (AZARIA, GOLDSCHLEGER e BEN-DOR, 2012)

No estudo de Azaria, Goldschleger e Ben-Dor (2012), foi constatado que a região do visível é confiável para a discriminação entre *Cannabis*, cítrus e grama, não obstante 15% dos cítrus tenham sido classificados como *Cannabis*. Além disso, identificaram que a reflectância da *Cannabis* tem pico máximo próximo dos 705 nm e que, na região do visível, entre 512 e 580 nm, a reflectância média é superior à dos cítrus e da grama.

Em Deng, Mao, *et al.* (2018), é apresentada a comparação de performance de dois sensores multiespectrais: câmeras Sequoia e Mini-MCA6. A aplicação principal é a agricultura de precisão. Nesta pesquisa, constatou-se que, quando aplicados métodos apropriados de calibração radiométrica, os resultados de assinaturas espectrais são mais precisos.

As câmeras multiespectrais embarcáveis em RPAs se tornam aplicáveis e viáveis à agricultura de precisão. No entanto, ainda é necessário aprimorar o desenvolvimento das técnicas de pós-processamento e dos diferentes métodos para cada uma das fases fenológicas e seus diferentes cultivos. Salienta-se que esse desenvolvimento deve abranger a acessibilidade tanto de usabilidade quanto de

custos técnicos, de flexibilidade dos aplicativos e da qualidade dos dados (DENG, MAO, *et al.*, 2018).

Além disso, a aquisição de dados multiespectrais é revestida de algumas limitações, tendo em vista que a resposta espectral dos alvos varia de acordo com a calibração radiométrica da câmera e das condições climáticas. No momento da aquisição das imagens, a obtenção e o processamento de dados multiespectrais demandam relevante qualificação técnica da mão de obra (DENG, MAO, *et al.*, 2018).

Para contornar os problemas com condições meteorológicas adversas e com regulação da câmera, Deng, Mao, *et al.* (2018) recomendam a calibração radiométrica antes de cada voo. Para tanto, o sensor usado para aquisição de dados multiespectrais deve ser integrado a um sensor solar, capaz de adquirir informações de iluminação durante o voo inteiro, realizando o ajuste radiométrico das imagens em tempo real.

A calibração radiométrica do sensor multiespectral possibilita obter índices de vegetação capazes de fornecer informações fenotípicas de (1) a exemplo do NDVI (1) do reNDVI (2). O reNDVI é menos impactado pelo solo exposto, quando esses dois índices são calculados pelas fórmulas a seguir (DENG, MAO, *et al.*, 2018):

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

$$reNDVI = \frac{NIR - RE}{NIR + RE} \quad (2)$$

Sensores de três bandas, popularmente conhecidos como *RGB*, podem ser utilizados para aquisição de dados a baixo custo e com poucas horas de treinamento da mão de obra, a fim de realizar medições rápidas não destrutivas. Duas ou as três bandas são suficientes para a implementação de índices simples, a exemplo do *NDI_{gr}*, e do *Green Excess Index (ExG)*, cujas fórmulas de cálculo são apresentadas nas equações 3 e 4 (BARESSEL, RISCHBECK, *et al.*, 2017).

$$NDI_{gr} = \frac{G - R}{G + R} \quad (3)$$

$$ExG = \frac{2G - (R + B)}{R + G + B} \quad (4)$$

No estudo de Castilla, Feduck e Mcdemid (2018), foi demonstrado que é possível detectar coníferas com copas entre 5 cm e 30 cm de diâmetro, usando imagens de alta resolução espacial, adquiridas com sensor RGB embarcado em RPA. O acerto neste caso foi de 75,8%, na época do ano mais favorável, não obstante as distorções e artefatos digitais contidos nas imagens.

No entanto, sensores RGB têm como desvantagem possuírem apenas bandas espectrais do visível, não trazendo informações do espectro eletromagnético referentes ao *red-edge* (RE) e ao *near-infrared* (NIR), que são regiões espectrais usadas para o monitoramento da vegetação, por fornecerem informações importantes sobre a folhagem (DENG, MAO, *et al.*, 2018).

A detecção de ervas daninhas em plantações de beterraba-açucareira é possível utilizando tanto imagens RGB como imagens RGB combinadas com imagens NIR, por meio da classificação da vegetação usando o ExG (*Excess Green Index*, dado por $I_{\text{ExG}} = 2I_{\text{GREEN}} - I_{\text{RED}} - I_{\text{BLUE}}$), NDVI (*Normalized Difference Vegetation Index*) e as características geométricas da cultura, tendo em vista que as lavouras de beterraba têm distribuição espacial regular (LOTTESS, KHANNA, *et al.*, 2017).

2.1.4 Aprendizado de máquina – AM

O aprendizado de máquina surgiu com uma subclasse da inteligência artificial, caracterizada por ser uma técnica de desenvolvimento de algoritmos que permite a computadores desenvolver habilidades de aprender por meio de dados de treinamento.

Problemas para os quais não há boa solução ou a solução exige listas complexas de procedimentos, assim como em situações com grande quantidade de dados, vêm sendo resolvidos com o uso de algoritmos de aprendizado de máquina. O AM pode ser classificado em *aprendizado supervisionado*, quando é fornecido um conjunto de dados rotulados para treinamento – e *não supervisionado*, quando os dados não são rotulados e o algoritmo aprende sem o direcionamento de uma pessoa (GERON, 2019).

Um tipo específico de algoritmo de aprendizado de máquina se mostrou muito mais fácil de treinar: as redes neurais convolucionais. Inspiradas na estrutura do sistema visual, alcançaram um extraordinário sucesso e têm sido amplamente

utilizadas por grupo de trabalho da comunidade de visão computacional (LECUN, BENGIO e HINTON, 2015).

Inúmeras são as possibilidades de aplicação de redes neurais convolucionais. Por exemplo, esta técnica de AM foi usada para: segmentar estruturas danificadas, detritos, estradas, terrenos e veículos após a passagem do furacão Harvey, no Texas (MOHAMMADI, WATSON e WOOD, 2019); realizar o reconhecimento aéreo de ação humana (PERERA, LAW e CHAHL, 2019); e extrair edificações de imagens de alta resolução adquiridas com RPA (LIU, YANG, *et al.*, 2019).

Ademais, por representar um método de baixo custo, bem-sucedido e promissor na identificação de árvores em ambientes agrícolas, a aquisição de imagens com RPA associada a métodos de aprendizado de máquina está sendo usada para resolver problemas comuns de análise de grandes conjuntos de dados de sensoriamento remoto, por meio de detecção, classificação e segmentação de imagens de alta resolução (CSILLIK, CHERBINI, *et al.*, 2018).

Recorrendo a um algoritmo de aprendizado de máquina supervisionado, conhecido como *Support Vector Machine* (SVM), Wang, Zhu e Wu (2018) desenvolveram um método automático para detecção de palmeiras de óleo em imagens de RPA. Os autores criaram duas estâncias de processamento. Na primeira, foi separado o que é vegetação do que **não** é vegetação; e, na segunda, as palmeiras foram identificadas. Nos dois momentos, foi usado um classificador supervisionado, que requer amostras de referência para treinamento. Dos quatro lugares onde a metodologia foi testada, em três a acurácia foi superior a 99%; e no quarto, onde as palmeiras estavam misturadas a outras árvores ou parcialmente cobertas, foi de 94,63%.

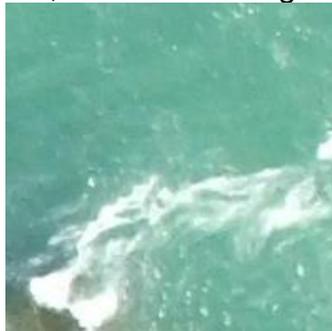
Também usando aprendizado de máquinas para classificar imagens adquiridas com RPA, Csillik, Chebini, *et al.* (2018) mostraram que é possível obter precisão superior a 96% para identificação de cítricos em imagens de veículos aéreos não tripulados, usando métodos simples de redes neurais convolucionais, apesar de o campo de teste ser formado por árvores cítricas em mais de um estágio de crescimento.

Silva e Nascimento (2019) implementaram algoritmo de classificação de padrão em imagens batizado de **BIL – Busca de cultivos ILícitos**, a fim de reconhecer cultivos de *Cannabis* em ilhas do Rio São Francisco, no sertão pernambucano, aplicando técnicas de aprendizado de máquina disponíveis para linguagem Python.

O aplicativo desenvolvido por Silva e Nascimento (2019) foi escrito em Python, apoiado nas bibliotecas *Keras* e *Tensoflow*, que são plataformas de código aberto disponíveis para o desenvolvimento de algoritmos de aprendizagem de máquinas. A primeira permite criar ambiente de rotinas de alto nível, para montar redes neurais profundas. A segunda é amplamente utilizada em trabalhos de Inteligência Artificial – IA (SILVA e NASCIMENTO, 2019), e na criação e treinamento de redes neurais para detectar e decifrar padrões, da mesma forma como as pessoas aprendem e raciocinam (GERON, 2019).

Para realizar o treinamento do algoritmo, Silva e Nascimento (2019) utilizaram uma base de dados de imagens adquiridas pela Polícia Federal, ao longo dos anos de 2017 e 2018, usando sensores RGB embarcados em RPAs. Foram criadas seis classes de imagens, a partir de um conjunto de 9.810 segmentos de imagens, com largura e altura de 100 x 100 *pixels*, correspondente a aproximadamente 25 m² do solo. As classes criadas estão ilustradas nas imagens a seguir:

a) Classe 1: Rio São Francisco, com 1.996 imagens.



b) Classe 2: Vegetação ribeirinha, com 1.566 imagens.



c) Classe 3: Solo, pedras e vegetação seca, com 1.790 imagens.



d) Classe 4: Vegetação nativa e cultivos lícitos, com 1.912 imagens.



e) Classe 5: Cultivos ilícitos com indivíduos jovens, com 668 imagens.



f) Classe 6: Cultivos ilícitos com indivíduos adultos, com 1.878 imagens.



Fonte: (SILVA e NASCIMENTO, 2019).

Usando essas classes para treinamento e janela de varredura de 150 x 150 *pixels*, o algoritmo de reconhecimento atingiu acurácia de 89% quando aplicado ao grupo de imagens de validação empregado no teste realizado com a finalidade de avaliar a performance do método de AM empregado para se separar cultivos ilícitos de outras feições (SILVA e NASCIMENTO, 2019).

2.1.5 Processamento fotogramétrico

Por meio da integração dos sensores imageadores com outros sensores embarcados na RPA, como receptor GNSS e IMU, é possível obter os dados de posicionamento e atitude das aeronaves no momento da aquisição dos dados. A recuperação dessas informações é realizada pela leitura dos metadados contidos nos arquivos de imagens, automaticamente, por *software* de processamento fotogramétrico.

O controle da variação de iluminação em áreas amplas levantadas por RPAs é um aspecto fundamental para a detecção da presença de plantas, minimizando erros devido às características do sensor e mudanças na reflectância por causa de alterações da luz solar sobre os alvos (STROPPIANA, PEPE, *et al.*, 2019). Portanto, alguns cuidados que antecedem a execução do voo devem ser seguidos no fluxo de trabalho de mapeamento para se obter resultados de sucesso no processamento fotogramétrico.

A segunda etapa do processamento consiste em criar uma nuvem densa de pontos e, posteriormente, um modelo 3D formado por uma malha triangular que represente a modelagem do espaço objeto. Por último, deve-se construir o mosaico

de ortofotos e exportá-lo em formato de imagem *raster*, para ser trabalhado no QGIS (CONGEDO, 2018).

Na pesquisa, foram usados sensores RGB embarcados em RPAs para obter imagens de áreas de interesse, por intermédio de voos previamente planejados, de forma que atendessem a requisitos para confecção de mosaicos de ortofotos com resolução espacial próximo a 3,5 cm. O posicionamento geográfico dos cultivos ilícitos foi realizado por meio de mosaicos de ortofotos, os quais foram georreferenciados mediante dados de posicionamento e atitude obtidos no instante da aquisição de cada imagem, por receptor GNSS de navegação e IMU embarcados nas RPAs.

2.2 AÇÕES DA POLÍCIA FEDERAL NA LOCALIZAÇÃO DA *CANNABIS*

Os helicópteros empregados pela Polícia Federal, desde 1987, trouxeram ganhos relevantes para as operações policiais de combate ao plantio de *Cannabis* em Pernambuco, tanto para localizar cultivos ilegais quanto para dar celeridade aos trabalhos desenvolvidos durante os procedimentos de sua erradicação.

Como ponto negativo, além da presença ostensiva, os helicópteros apresentam altos custos de aquisição e manutenção, pois, além da tripulação para operar a aeronave, há necessidade de mecânico qualificado para pronto emprego em situações emergenciais, assim como logística específica para o transporte de combustível, exigindo deslocamento de caminhões-tanques até as bases operacionais, acompanhados de escoltas policiais para garantir a segurança.

Entre os anos de 1997 e 2000, também foram utilizadas aeronaves do tipo ultraleve, pilotadas por policiais para auxiliar na localização de plantios ilícitos, durante operações de erradicação de *Cannabis*. No entanto, essa forma de atuar não prosperou devido à insegurança envolvida nos voos.

Uma das primeiras tentativas de evolução das técnicas de localização de cultivos de *Cannabis* ocorreu ainda no ano de 1983, quando uma equipe de pesquisadores do Instituto Nacional de Pesquisas Espaciais – Inpe, realizou um sobrevoo nos municípios de Araripina, Estado de Pernambuco, e Simões, no Estado do Piauí, com a finalidade de avaliar a eficiência da utilização do filme infravermelho colorido (falsa-cor), na localização de cultivos de *Cannabis* (CREPANI, DOS SANTOS e SANTOS, 1983).

Apesar de ficar comprovada a viabilidade da metodologia, a falsa-cor não foi incorporada às técnicas de levantamento usadas pela Polícia Federal. Um dos fatos impeditivos foi o lapso temporal entre o sobrevoo e a obtenção dos resultados dos trabalhos de campo. Segundo Crepani, dos Santos e Santos (1983), os produtos levaram oito dias para ficar prontos.

A partir da década de 2000, o uso de GPS promoveu mais avanços para as operações destinadas a erradicar plantios de *Cannabis*, pois, além de auxiliar equipes de levantamento na geolocalização de atividades criminosas, tornou-se importante para equipes terrestres e fluviais encarregadas de erradicar as culturas ilícitas, assim como para os grupos de perícia de local de crime.

Com esse novo instrumento, as operações passaram a disponibilizar informações mais acuradas da localização dos plantios para as equipes encarregadas da erradicação. Tanto os policiais que atuavam com viaturas por terra quanto os que utilizavam barcos para acessar ilhas no Rio São Francisco passaram a utilizar GPS embarcados para navegar e escolher as melhores rotas de acesso aos pontos de interesse.

Além disso, as equipes de peritos passaram a ter informação importantíssima para confecção de seus laudos, pois a perícia não está comprometida apenas com a confirmação da existência de lavoura ilícita no local apontado, mas é responsável também pelo posicionamento espacial preciso do cultivo, tendo em vista que a propriedade pode ser objeto de expropriação, conforme o artigo 243, *caput*, da Constituição Federal, regulamentado pela Lei nº 8.257/1991 (BRASIL).

Outra inovação ocorreu no segundo semestre de 2010, quando a Delegacia de Polícia Federal de Salgueiro adquiriu e passou a usar coletores de dados espaciais, Juno SB, equipados com receptor GPS e sensor RGB, com a finalidade de acelerar o processo de coleta de dados pela perícia e a elaboração dos expedientes necessários à instrução de inquéritos policiais, através de processamentos computacionais dos dados coletados em campo.

Após oito anos do uso desses coletores, os dados adquiridos formam uma importante base de dados espaciais, referentes à ocorrência de cultivos ilícitos nos municípios de Pernambuco, que vem sendo usada no aprimoramento do combate ao cultivo de *Cannabis* no Estado.

Imagens orbitais também foram usadas com sucesso para localizar plantações de *Cannabis*. O primeiro trabalho de que se tem notícia a respeito dessa possibilidade

se deu através do emprego do Índice de Vegetação por Diferença Normalizada – NDVI, derivado de séries temporais do satélite SPOT-5 *High Resolution Geometric* – HRG (LISITA, 2011).

A tecnologia, durante a pesquisa, permitiu a erradicação de plantios ilícitos, por ocasião da Operação Prometeu, realizada pela Polícia Federal em junho de 2007, evidenciando que a metodologia poderia contribuir para detecção de cultivos de *Cannabis*, na região conhecida como *Polígono da Maconha* (LISITA, 2011).

2.2.1 Experiências com Aeronaves Remotamente Pilotadas

Em março de 2014, servidores da Superintendência da Polícia Federal de Mato Grosso do Sul e das delegacias da Polícia Federal de Juazeiro, Bahia, e Salgueiro, Pernambuco, realizaram testes usando uma RPA, do tipo asas fixas, modelo de *airframe* conhecido como X8, com controladora de voo, GPS e três sensores RGB embarcados. Os resultados foram promissores, apesar de, na ocasião, a taxa de acerto ter sido de apenas 28% (AGOSTINI, 2015).

Nesse experimento, a identificação e o georreferenciamento de áreas suspeitas foram realizados por meio da análise visual das imagens capturadas por um dos sensores RGB embarcados na aeronave, em ordem cronológica, usando dois monitores, com um mostrando imagens de satélites da área sobrevoada (AGOSTINI, 2015). A equipe registrou que as correntes de vento sobre o Rio São Francisco foram um fator limitador para o uso da RPA.

Por ocasião da Operação Expurgo IV, realizada em agosto de 2015, policiais federais utilizaram um multirrotor para tentar localizar cultivos de *Cannabis* em ilhas do Rio São Francisco, previamente definidas, por um dos policiais envolvidos na missão. Na oportunidade, foram realizadas filmagens com um sensor embarcado na aeronave e posicionado obliquamente em relação ao solo. Posteriormente, as imagens foram analisadas a fim de verificar a existência de plantios ilegais (MUNIZ, FILHO e DA SILVA, 2015).

No final do ano de 2015, uma nova experiência foi realizada com RPA de asas fixas. Dessa vez, além de imagens capturadas com o sensor a 90º em relação ao solo, foi utilizado um *software* para processamento de imagens e montagem de ortomosaicos. Apesar de não ter sido encontrado nenhum plantio na área sobrevoada,

foi possível constatar que imagens com resolução espacial de 5 cm poderiam ser adequadas para identificar uma lavoura de *Cannabis*.

Com essa constatação e prosseguimento dos testes, também ficou patente que uma RPA de asas fixas tinha maior dificuldade para superar as correntes de ventos, além de exigir destreza dos pilotos e espaços consideráveis para decolagem e, principalmente, para o pouso. A este último requisito nem sempre é possível atender, pois não se encontra com facilidade áreas adequadas na caatinga.

Em agosto de 2016, em decorrência da indisponibilidade de helicóptero, foi realizada a Operação Carcará Branco, utilizando dados adquiridos exclusivamente por RPA de asas rotativas. Nessa operação, foi possível confirmar que imagens com 5 cm de resolução espacial permitem distinguir as lavouras de *Cannabis* das lavouras comumente encontradas na região, assim como da vegetação nativa.

A partir de 2017, as RPAs de asas rotativas passaram a ser utilizadas sistematicamente para adquirir dados espaciais, utilizando sensores RGB. Com as imagens obtidas, são produzidos ortomosaicos, com a finalidade de gerar informações com a localização espacial e a estimativa do número de espécies em plantios conhecidos popularmente como *roças de maconha*.

3 ORIGEM E CARACTERÍSTICAS DA CANNABIS

França (2015) afirma que há evidências do uso da *Cannabis* como fibra no Neolítico, inclusive a disseminação deve ter acontecido por povos nômades antes mesmo da revolução agrícola. Inicialmente, era usada como fonte de fibras obtidas com variedades atualmente conhecidas como *cânhamo* ou *cânhamo industrial*, que contêm baixo teor do princípio ativo intoxicante (CHERNEY e SMALL, 2016).

No entanto, a *Cannabis* não é apenas fonte de fibra, mas de diversas substâncias químicas conhecidas como *canabinoides* ou fitocanabinoides, cujas propriedades farmacológicas foram comprovadas por diversas pesquisas (CHIEN e PETERS, 2018). Há registros de que, no século II a.C., a *Cannabis* era usada na medicina chinesa como analgésico, antiespasmódico e sedativo, assim como por antigos persas, gregos, romanos, indianos e assírios, no período conhecido como Antiguidade Clássica (COHEN, 1988).

Dentre os canabinoides, o tetra-hidrocanabinol – THC, e o canabidiol – CBD, são os mais importantes e os mais utilizados na preparação de medicamentos. Todavia, ao contrário do THC, o CBD não possui efeitos psicoativos, mas tem propriedades antipsicóticas, ansiolíticas, anticonvulsivas e anti-inflamatórias (RONG, LEE, *et al.*, 2017).

O THC é a principal substância psicoativa presente no gênero *Cannabis* e as primeiras espécies com elevado teor de THC foram selecionadas no Sul da Ásia (CHERNEY e SMALL, 2016). A partir da década de 1970, foram desenvolvidas cepas com o teor de THC até cinco vezes maior do que o das espécies existentes na década de 1960, cujos teores variavam entre 1% e 5% em peso (CHIEN e PETERS, 2018).

Do ponto de vista taxonômico, desde que o botânico Lineu descreveu o gênero em 1753, a *Cannabis sativa* era tida como espécie única, apesar de não ser pacífica essa posição. No entanto, a partir do trabalho de outros botânicos, a *Cannabis indica* e a *Cannabis ruderalis* passaram a ser aceitas também como espécies do gênero *Cannabis* (SMALL, 2015).

Atualmente o cultivo não se restringe às plantas das três espécies nativas, há, no mercado, diversas variedades híbridas, resultantes do melhoramento genético, objetivando produção de plantas com teor diferenciado de canabinoides e fibras, de acordo com a finalidade a que se destinam (CAMARGO *et al.*, 2018).

Nos países que permitem o cultivo de *Cannabis*, o que importa é distinguir as variedades lícitas das ilícitas, de acordo com a concentração de THC. A União Europeia, por exemplo, permite o plantio de *Cannabis* para fins medicinais e industriais desde que a espécie cultivada não apresente teor de TCH superior a 0,2% (CHERNEY e SMALL, 2016).

No Brasil, desde 1938, o cultivo de *Cannabis* é considerado ilegal, independentemente do percentual de THC que a planta apresente. A legislação não menciona teores do princípio ativo e se limita a proibir o plantio, a cultura, a colheita e a exploração por particulares (BRASIL, 1938).

No entanto, à luz da lei que instituiu o Sistema Nacional de Políticas Públicas sobre Drogas – Sinard, de 23 de agosto de 2006, a União pode permitir o plantio, a cultura e a colheita de *Cannabis*, desde que, seja para usos, exclusivamente, medicinal ou científico e que tenha prazo e local determinados, assim como fiscalização adequada (BRASIL).

3.1 PRODUÇÃO E CONSUMO

Apesar de o número de apreensões de *Cannabis* ter diminuído no mundo todo, o número de usuários vem aumentando. Em 2016, existiam 192 milhões de usuários dessa droga ilícita, levando-a a ser a mais traficada e produzida na atualidade, muito provavelmente, pelas liberações ocorridas em alguns países tanto para uso medicinal quanto para o uso recreativo. Nos Estados Unidos, em 2016, após a liberação, ocorreu o menor nível de apreensão desde o ano 2000, não obstante ser o país responsável por 21% de tudo que foi apreendido mundialmente (UNODC, 2018).

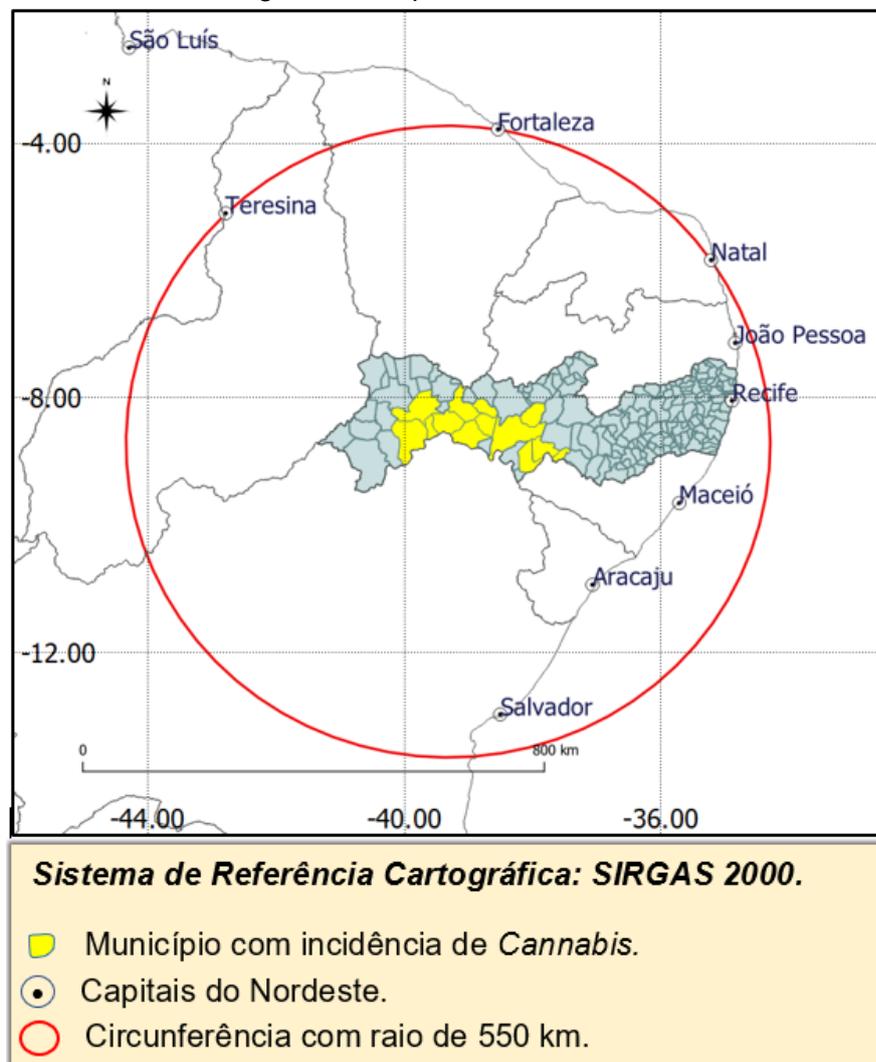
Outra peculiaridade do mercado de *Cannabis* é a comercialização predominantemente na região em que é produzida. Essa situação se tornou explícita com a propagação do cultivo em ambientes fechados, reduzindo ainda mais o tráfico internacional (UNODC, 2018).

A *Cannabis* produzida na América do Sul, no Caribe e na América Central é consumida nas Américas, sendo Colômbia, Paraguai e Jamaica os países mais citados como fornecedores. Na América do Norte, os Estados Unidos é o maior receptor, cujo mercado é abastecido pela droga cultivada no próprio país, em todos os 50 estados, no México e no Canadá (UNODC, 2018).

A exceção ocorre com a *Cannabis* produzida na Ásia Central e em alguns países africanos (Nigéria, Gana, África do Sul e Zâmbia). No primeiro caso, o cultivo é destinado ao abastecimento da Europa Oriental, sobretudo ao da Rússia; e, no segundo, o destino é principalmente o Reino Unido, os Países Baixos e a Itália. No entanto, esse volume representa pequena fatia do consumo europeu, pois, em quase todos os países da União Europeia, há ocorrência do cultivo de *Cannabis* (UNODC, 2018).

A região conhecida como *Polígono da Maconha* é a maior produtora de *Cannabis* no Brasil, mas o que é produzido no semiárido nordestino abastece apenas as regiões Norte e Nordeste. Os grandes centros consumidores, a exemplo de São Paulo e Rio de Janeiro, são supridos pela erva cultivada no Paraguai (FRAGA e IULIANELLI, 2011).

Figura 5 – Capitais do Nordeste.



Fonte: o autor, 2020.

Destaque-se que a proximidade entre a região produtora de Cannabis e as capitais do Nordeste é a principal causa de o Polígono da Maconha ser o fornecedor desses centros consumidores (OLIVEIRA, JORGE e ERNANI, 2009; P. C. FRAGA, 2007; FRAGA e IULIANELLI, 2011). A distância da produção ao consumo é igual ou inferior a 550 km, entre oito das nove capitais da região. Na Figura 5, está ilustrada a distribuição espacial das capitais nordestinas e as cidades pernambucanas do Polígono da Maconha.

3.2 ASPECTOS SOCIAIS DO CULTIVO DE CANNABIS

As motivações que levam o homem do campo a migrar para lavouras de Cannabis são diversas, tanto no Brasil como em outras partes do mundo. Em Lesoto, a Cannabis está incorporada à cultura do País, e o surgimento de novos mercados consumidores impulsionou o cultivo da erva, após o esgotamento do solo da região pelo cultivo de grãos para exportação durante dois séculos (FRAGA e IULIANELLI, 2011).

Em muitos casos, o agricultor vislumbra na cultura ilícita uma forma de compensar os prejuízos da lavoura lícita, contornando momentos de dificuldades e até melhorando a situação financeira da família. No norte do Marrocos, foi constatada a melhoria do Índice de Desenvolvimento Humano – IDH, com o cultivo da Cannabis, que se converteu na principal fonte de renda em uma região com precária infraestrutura (FRAGA e IULIANELLI, 2011).

Em Pernambuco, no conhecido *Polígono da Maconha*, a motivação do envolvimento de agricultores com cultivos ilícitos também é variada, e não há um motivo que se destaque dos demais. Inclusive baixos IDH e renda da população dos municípios inseridos na região não explicam esse fato social por completo, sobretudo por haver outros municípios nas proximidades em igual situação ou até pior (OLIVEIRA, JORGE e ERNANI, 2009).

Na realidade, um conjunto de fatores faz com que o *Polígono da Maconha* seja uma região com altos índices de cultivo de Cannabis, a começar pela falta de infraestrutura para o agricultor escoar a safra de produtos agrícolas (OLIVEIRA, JORGE e ERNANI, 2009). O fato é considerado um paradoxo, uma vez que as terras localizadas em áreas de infraestrutura deficitárias são as preferidas pelos plantadores de Cannabis, por dificultarem a repressão estatal (FRAGA e IULIANELLI, 2011).

Todavia, apesar da precária infraestrutura para o escoamento de produtos agrícolas, o *Polígono da Maconha* fica em uma localização privilegiada em relação às Regiões Metropolitanas do Nordeste, principais destinatárias da erva produzida (FRAGA e IULIANELLI, 2011; OLIVEIRA, JORGE e ERNANI, 2009).

Além disso, a *Cannabis* pronta para o consumo é um produto de alto valor agregado, fazendo com que algumas dezenas de quilos, facilmente transportáveis, correspondam ao preço de toneladas de produtos agrícolas lícitos. Tomando o valor em dólares americanos, em 2011, no Brasil o preço típico do quilo da *Cannabis* pronta para consumo era de US\$417,00 (UNODC, 2018).

A quantidade de terras aptas para o cultivo da erva evita que ocorram conflitos relativos a disputas por áreas para o plantio (OLIVEIRA, JORGE e ERNANI, 2009). As margens do Rio São Francisco foram apontadas como propícias para o cultivo do cânhamo para a obtenção de fibras, ainda no século XIX, pelo explorador inglês Richard Burton (FRAGA e IULIANELLI, 2011). Nessa situação, enquadram-se as ilhas do Rio São Francisco existentes entre os estados de Pernambuco e da Bahia.

No que se refere a programas governamentais para o Vale do São Francisco e região, houve um grande avanço relacionado à agricultura irrigada para produção de culturas com alto valor agregado, mas no que se refere à agricultura familiar poucos avanços ocorreram, inclusive do ponto de vista salarial (FRAGA e IULIANELLI, 2011).

Diante desse fato, grupos que dominam outras etapas da produção e comercialização da droga, além de incentivar agricultores fornecendo sementes de *Cannabis*, pagam diárias até cinco vezes maiores do que a remuneração costumeira da agricultura de produtos lícitos (FRAGA e IULIANELLI, 2011).

Nesse contexto, antigas disputas entre famílias nos municípios pernambucanos de Belém do São Francisco e Floresta levaram membros de grupos familiares a investirem em atividades criminosas para conseguir recursos financeiros, com o objetivo de se protegerem dos rivais e adquirir armas. Dentre essas atividades, estavam o cultivo de *Cannabis* e o assalto a bancos (OLIVEIRA, JORGE e ERNANI, 2009).

3.3 CANNABIS NO BRASIL

A introdução da *Cannabis* no Brasil não está conexas a um fato social isolado. Pelo menos três possibilidades são reconhecidas como responsáveis pela chegada

dessa cultura na América portuguesa e estão associadas a motivações comerciais, medicinais e recreativas. Esta última é tratada por alguns autores como *canabismo*, para se referir ao uso da erva ou do haxixe para obter efeitos inebriantes.

A corrente que tem maior documentação está relacionada com o incentivo da Coroa Portuguesa para que a *Cannabis* fosse produzida na Colônia a fim de fornecer fibras para a produção de cordas e tecidos de alta qualidade (BRANDÃO, 2014; FRANÇA, 2015).

Após experiências do cultivo da *Cannabis* no Sul do Brasil e no Rio de Janeiro, foi criada a Real Feitoria do Linho Cânhamo, com a finalidade de constituir um centro de pesquisa sobre o produto e ajudar agricultores locais (BRANDÃO, 2014). Entretanto, as dificuldades com a mão de obra escrava utilizada na lavoura (BRANDÃO, 2014) e outras adversidades, além da má administração, da falta de interesse dos colonos pela cultura e de dificuldades com as sementes, levaram a companhia a encerrar os trabalhos em 1824, não obstante ter sido a tentativa mais bem planejada para introduzir o cultivo em grande escala no País (FRANÇA, 2015; MENZ, 2005).

A segunda forma de chegada da *Cannabis* ao Brasil se deu através da farmacologia, haja vista que era utilizada para combater diversas enfermidades em outros países da Europa, da África e do Oriente Médio. No século XIX, o uso medicinal era bem amplo, indo de digestivos a cigarros para asma, inclusive com teses defendidas nas faculdades de Medicina de Salvador e do Rio de Janeiro, além de haver propagandas em revistas e jornais da época (FRANÇA, 2015).

No que se refere ao canabismo, dois grupos foram os principais vetores dessa forma de uso no Brasil: os marinheiros portugueses, notadamente os que participaram de expedições pela rota da Índia, e os escravos vindos da África para o Brasil, a partir do século XVI. Naquela época o continente africano já possuía povos que faziam uso recreativo da erva e do haxixe, muito provavelmente introduzidos por caravanas árabes no norte africano, pela península Arábica (FRANÇA, 2015).

3.3.1 Aspectos da Importância do rio São Francisco

A Capitania de Pernambuco foi doada a Duarte Coelho ainda na primeira metade do século XVI e teve importante significado econômico para a Colônia, decorrente da riqueza gerada pelos engenhos de cana-de-açúcar, instalados nas

proximidades do litoral, nas atuais regiões de desenvolvimento: Mata Norte, Mata Sul e Metropolitana.

Assim, o início do uso hedonista da *Cannabis* em Pernambuco está associado à mão de obra da monocultura canavieira, formada por escravos de origem africana, que tinham como prática o canabismo em festas religiosas (DÓRIA, 1915).

Por seu turno, os limites da Capitania de Pernambuco foram estabelecidos na Carta de Doação, e, como marco, foi usada a margem direita do Rio São Francisco, atualmente Estado de Sergipe. As terras da Capitania tinham largura de 60 léguas e contemplavam todo o rio, da foz até sua nascente (MARTINS, 2010).

Acontece que, o Velho Chico, também conhecido como Rio da Integração Nacional, teve papel fundamental, não apenas na ocupação das terras pernambucanas, mas como meio de ligação entre o litoral e as terras do Centro-Oeste brasileiro, sobretudo através do comércio realizado pelas fazendas de gado instaladas em suas margens. Os conhecidos currais do São Francisco mantinham relações comerciais com a região das Minas, desde o século XVIII, por causa da troca de ouro em pó, com alta lucratividade (MARTINS, 2010).

Dessa maneira, o próprio rio serviu de caminho para a penetração da *Cannabis* no Sertão do São Francisco Pernambucano, através dos costumes dos povos ribeirinhos, cuja prática do canabismo foi registrada pelo médico e político Rodrigues Dória, quando participou do *Segundo Congresso Científico Pan-Americano*, ocorrido em Washington, em 27 de dezembro de 1915 (DÓRIA, 1915).

Em sua palestra, o médico descreveu a forma como a *Cannabis* era fumada pela população ribeirinha do Rio São Francisco, usuária de um dispositivo formado por uma garrafa comum ou uma cabaça, ao qual ele se referiu como *arremedo do narguilé* ou *cachimbo turco*. O artefato era um companheiro inseparável dos canoeiros e barceiros do São Francisco; os fumantes davam ao cachimbo o nome de *maricas* (DÓRIA, 1915).

Essa forma de fumar a *Cannabis*, usando um cachimbo semelhante ao narguilé, também foi relatada pelo sociólogo Donald Pierson, após dois meses de trabalhos no Vale do São Francisco, no início da década de 1950, quando o pesquisador e sua equipe presenciaram o uso da erva por grupos de pessoas reunidas em rodas. O cachimbo, preparado com *Cannabis*, era passado de mão em mão, ao mesmo tempo que se entoava uma canção conhecida como *loa* (BOMFIM, 2006).

3.4 REPRESSÃO AO CULTIVO DE *CANNABIS*

A *Cannabis* com elevado teor de THC teve o cultivo proibido em todo o mundo ao longo do século XX, principalmente com a aprovação da Convenção Única sobre Entorpecentes, em 1961, na qual foram estabelecidos padrões de controle internacional para substâncias psicotrópicas, deixando de fora apenas o cultivo de *Cannabis* para fins industriais ou hortícolas (ONU, 1961).

Em terras brasileiras, a repressão ao uso da *Cannabis* teve início através de normas publicadas por câmaras municipais, como a do Rio de Janeiro e a de Santos, que procuravam coibir as condutas indesejadas dos escravos praticantes do canabismo, pois tinham seus comportamentos supostamente alterados em decorrência dessa prática (FRANÇA, 2015).

No entanto, a repressão de forma mais severa teve início no começo do século XX, após diversos trabalhos publicados relacionando o uso da *Cannabis* a distúrbios sociais e da saúde dos usuários, especialmente aos da população mais pobre, que fazia uso recreativo da erva com maior frequência (BRANDÃO, 2014).

3.5 COMBATE AO TRÁFICO DE *CANNABIS* EM PERNAMBUCO

Órgão constitucionalmente responsável pela prevenção e repressão do tráfico ilícito de entorpecentes e de drogas afins (BRASIL, 1988), a Polícia Federal atua de diversas formas para reprimir o tráfico de *Cannabis*, sobretudo com a manutenção de operações periódicas destinadas a conter o cultivo da erva, principalmente no *Polígono da Maconha*, desde os anos 1980.

Inicialmente, a erradicação de plantios dependia em grande parte da atuação de equipes de investigação e de dados fornecidos por informantes, para localizar cultivos ilícitos. Em seguida, era feita a destruição das roças onde se encontrava a droga.

No entanto, os meios usados para a localização e para o planejamento operacional vêm sendo aprimorados. A cada operação de erradicação de plantio de *Cannabis*, são testadas novas metodologias e equipamentos, para o melhor êxito e cumprimento da tarefa de combate e controle do tráfico.

4 METODOLOGIA DA PESQUISA

A metodologia adotada na pesquisa está apresentada nos tópicos seguintes.

4.1 ÁREA DE ESTUDO

A área objeto de estudo está localizada no estado de Pernambuco, no perímetro conhecido como *Polígono da Maconha*, nas mesorregiões Sertão Pernambucano e São Francisco Pernambucano, e esta última engloba as ilhas do rio São Francisco localizadas entre Pernambuco e Bahia, Figura 6.

Figura 6 – Distribuição espacial de plantios de *Cannabis* em Pernambuco.



Fonte: www.ibge.gov.br e Polícia Federal.

As duas mesorregiões fazem parte do semiárido brasileiro, cujos critérios técnicos de definição, estabelecidos pela Superintendência do Desenvolvimento do Nordeste – Sudene, são: precipitação pluviométrica média anual igual ou inferior a 800 mm, índice de Aridez de Thorntwaite igual ou inferior a 0,50, percentual diário de déficit hídrico igual ou superior a 60%, considerando todos os dias do ano (SUDENE).

Não há consenso sobre quais municípios fazem parte do *Polígono da Maconha* (OLIVEIRA, JORGE e ERNANI, 2009); portanto, para definir objetivamente quais municípios de Pernambuco compõem a região, foram utilizados os dados espaciais

levantados por policiais federais em operações de erradicação de cultivos de *Cannabis*, entre novembro de 2010 e junho de 2018.

Nesse período, foram registrados 2.227 pontos de ocorrência de *Cannabis sativa* na forma de lavoura em desenvolvimento, sementeiras, mudas, material secando e produto pronto para comercialização, nos municípios de: Belém de São Francisco, Betânia, Cabrobó, Carnaubeira da Penha, Floresta, Inajá, Manari, Mirandiba, Orocó, Parnamirim, Salgueiro, Santa Maria da Boa Vista e Tacaratu. Na Figura 6, é ilustrada a distribuição espacial da incidência de plantios de *Cannabis* no estado de Pernambuco.

A distribuição espacial dos pontos registrados, no período supracitado, mostra que 1.620 pontos, ou seja, 72,74%, ocorreram em ilhas do rio São Francisco, nos municípios de Santa Maria da Boa Vista, Orocó, Cabrobó e Belém do São Francisco. As demais ocorrências foram apontadas no continente e representam 28,86%. Dessa maneira, verifica-se que há duas grandes áreas de eventos, as quais são tradicionalmente referenciadas pela Polícia Federal como **ilhas e continente**.

A continuidade da análise dessas informações revela também que, na área conhecida como **continente**, a presença de cultivos ilícitos se dá, predominantemente, em lugares próximos a adutoras, cursos de água intermitentes, reservatórios de água públicos e particulares, além de áreas de serras com pequenos acumuladores de águas pluviais.

Uma primeira constatação é de que o cultivo de *Cannabis* está diretamente ligado a fontes de água para irrigação da lavoura, tendo em vista que o *Polígono da Maconha* está inserido em uma região cujo déficit hídrico anual é igual ou superior a 60%.

Além disso, os dados demonstram que os plantios de *Cannabis* mantêm padrões, em relação à densidade de plantas e ao espaçamento entre covas, apesar de haver pequena variação entre ilhas e continente, *vide* Tabela 1.

Tabela 1 – Padrões dos plantios no continente e nas ilhas.

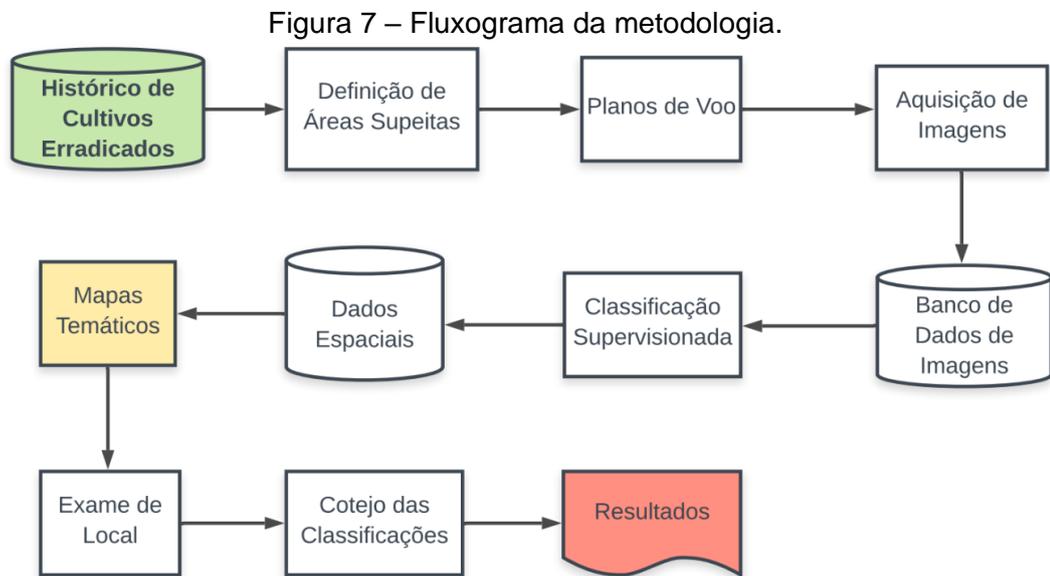
Local	Pés/cova (un.)	Pé/m ² (un.)	covas/m ² (un.)	Espaçamento (m)
Continente	4,08	1,71	1,76	1,33
Ilhas	2,88	1,53	1,89	1,37

Fonte: o autor, 2020.

4.2 PROCEDIMENTOS METODOLÓGICOS

A

Figura 7 expõe as etapas da pesquisa.

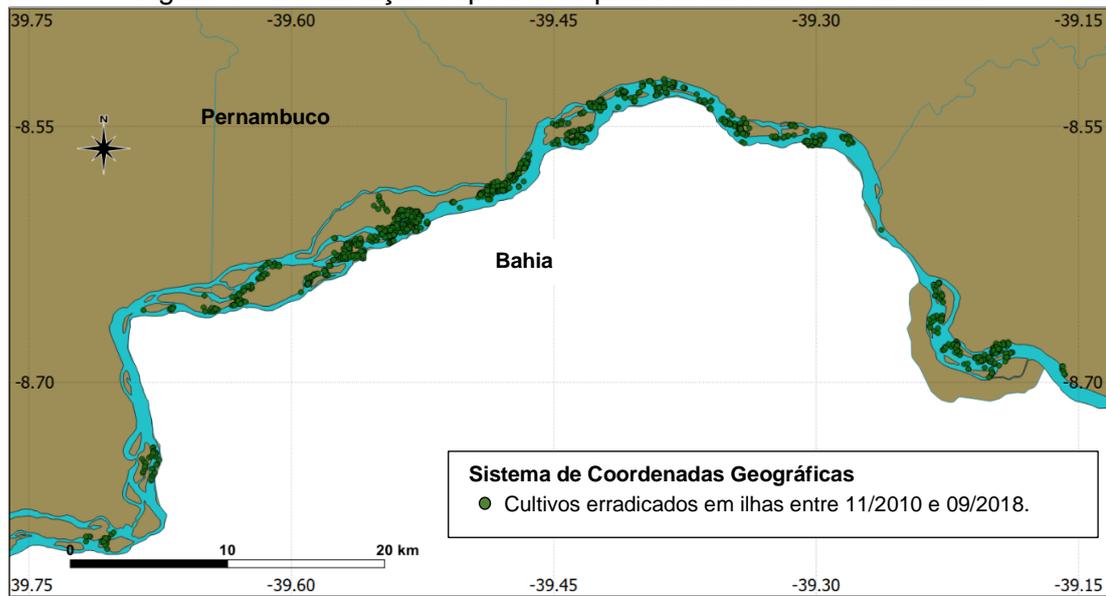


Fonte: o autor, 2020.

4.2.1 Definição de áreas suspeitas

As áreas a serem sobrevoadas foram definidas levando-se em conta a distribuição espacial dos eventos registrados na base de dados produzida pela Polícia Federal, referente a cultivos de *Cannabis* erradicados em operações policiais, entre novembro de 2010 e setembro de 2018.

Figura 8 – Distribuição espacial de plantios erradicados em ilhas.

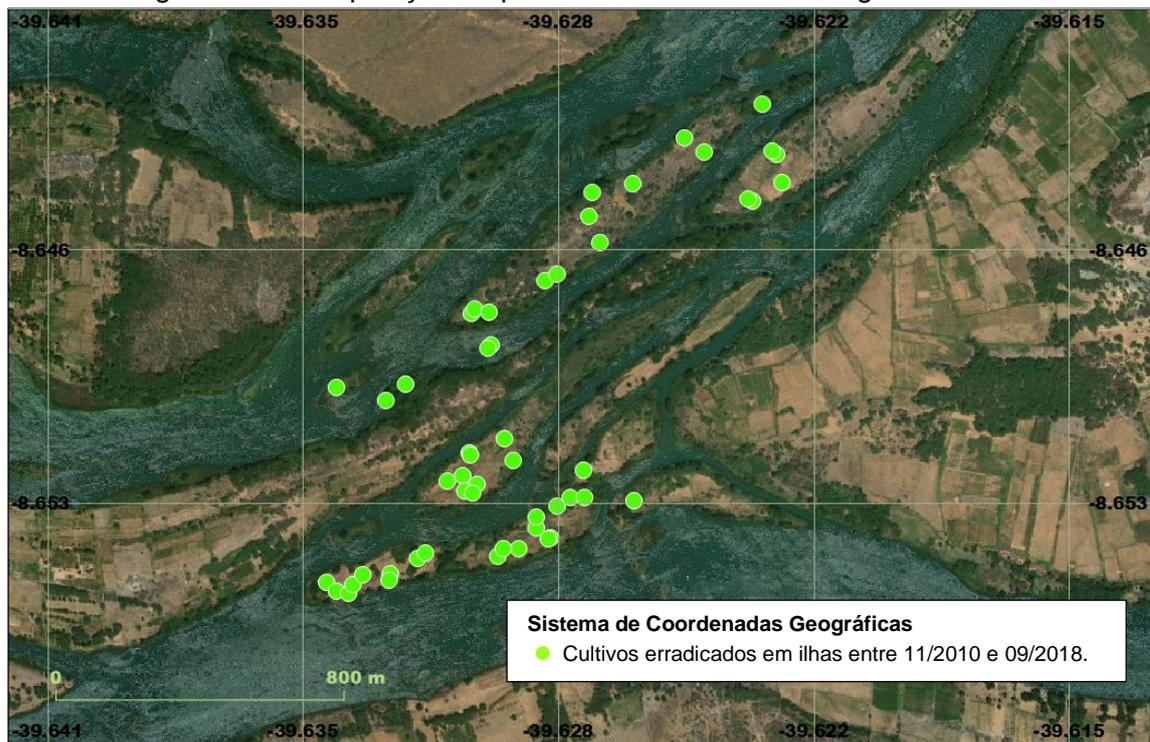


Fonte: www.ibge.gov.br e Polícia Federal.

As ilhas com possível existência de plantios ilícitos foram identificadas tendo como pressuposto que, se uma ilha foi utilizada no passado para fins ilícitos, é possível seja utilizada novamente para uma outra lavoura de *Cannabis*, uma vez que há água em abundância e as áreas pertencem à União, ou seja, não há preocupação com possível desapropriação da terra usada para o plantio.

Assim, para definir exatamente quais ilhas precisariam ser contempladas nos planos de voo, os pontos de plantios erradicados pela Polícia Federal em operações passadas foram sobrepostos a imagens orbitais fornecidas pelo *Esri World Imagery* (ESRI, 2019), da forma ilustrada na Figura 9.

Figura 9 – Sobreposição de pontos erradicados em imagens orbitais.



Fonte: Esri World Imagery e Polícia Federal.

4.2.2 Planos de voo

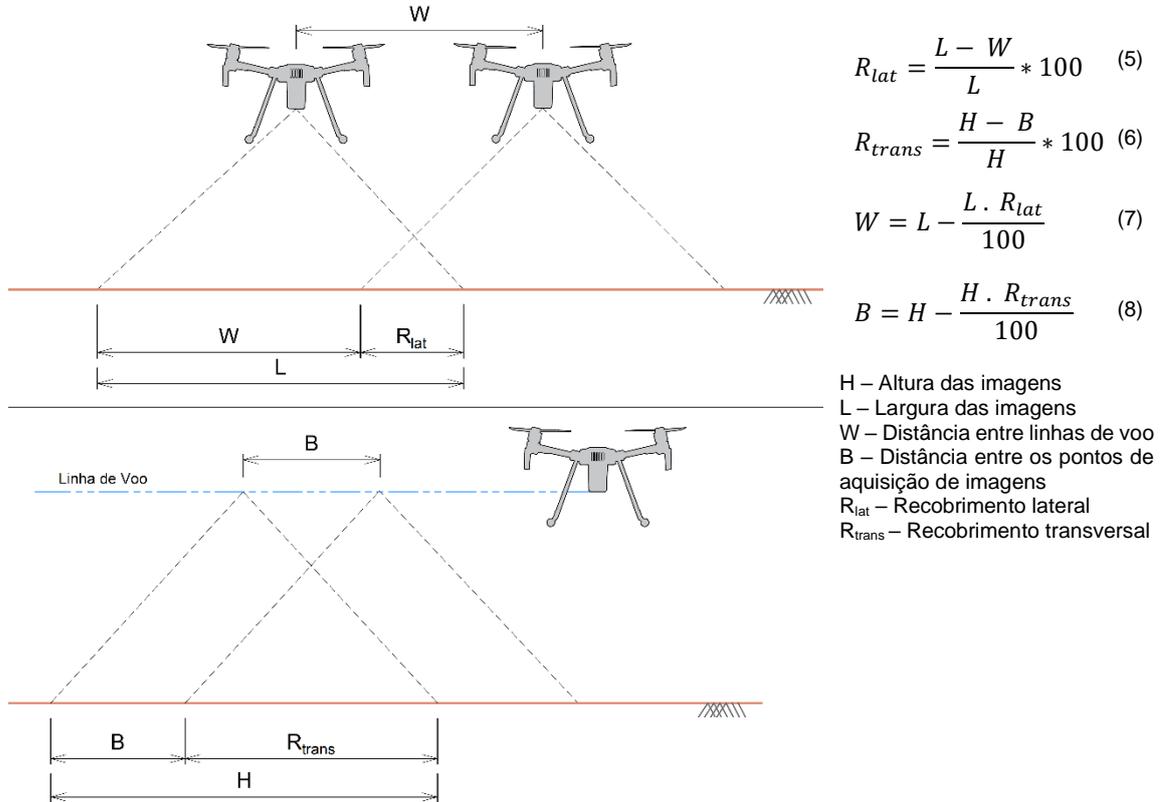
Para realizar voos automáticos de mapeamento, foi utilizado um aplicativo específico como, já citado anteriormente. Uma das principais preocupações foi a compatibilização do tempo de voo com a autonomia das RPAs empregadas no levantamento. Na pesquisa, foram utilizadas as RPAs Matrice 200 V2, Mavic 2 PRO, Phantom 4 PRO, Mavic PRO e Inspire 1, todas fabricadas pela DJI e mantidas com suas características originais de fábrica.

Para dar segurança aos trabalhos de mapeamento, tendo em vista possíveis ocorrências de ventos desfavoráveis, os planos de voo foram elaborados com duração, de no máximo, 70% da autonomia das RPAs, a fim de que as aeronaves pousassem no ponto de decolagem com carga de bateria igual ou superior a 30% da capacidade nominal máxima indicada pelo fabricante.

A altura de voo foi definida em 120 m, e os valores dos recobrimentos laterais e transversais do voo foram definidos conforme as equações (5) e (6), sendo de 30% e 70% respectivamente. As distâncias entre as linhas de voo e entre os pontos de aquisição de imagens foram calculadas usando as equações (7) e (8), conforme ilustrado na Figura 10. Ressalta-se, no entanto, que nem sempre é necessário o

recobrimento lateral, uma vez que parte das ilhas tem menos de 154 metros de largura, ou seja, a dimensão lateral da imagem projetada no terreno é maior do que a largura de parcela relevante das ilhas.

Figura 10 – Cálculo da distância entre as linhas de voo.



Fonte: o autor, 2020.

Para as RPAs utilizadas, recorrendo às equações apresentadas na Figura 10, foram encontrados os parâmetros para subsidiar a elaboração dos planos de voo de acordo com as características de cada sensor e autonomia das aeronaves. Os resultados encontrados, considerando a velocidade máxima de 15 m/s (54 km/h), são os apresentados na Tabela 2.

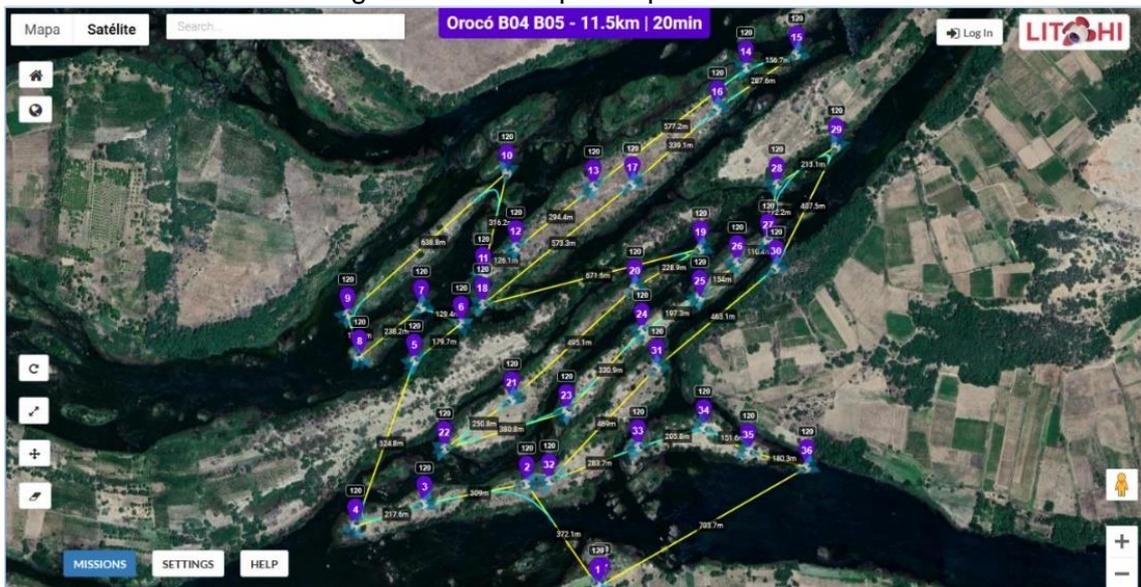
Tabela 2 – Características dos sensores e parâmetro de voo.

Aeronave	Sensor	f (mm)	Pixel (μm)	Formato Sensor		GSD (cm)	Imagem no solo		Distâncias (m)		Intervalo (s)
							L(m)	H(m)	W	B	
Matrice 200 V2	FC6510	8,80	2,412280E-06	5.472	3.648	3,29	180,00	120,00	126,00	36,00	2,40
Mavic 2 PRO	L1D-20c	10,26	2,410710E-06	5.472	3.648	2,82	154,29	102,86	108,00	30,86	2,06
Phantom 4 PRO	FC6310	8,80	2,412280E-06	5.472	3.648	3,29	180,00	120,00	126,00	36,00	2,40
Mavic PRO	FC220	4,73	1,574240E-06	4.000	3.000	3,99	159,75	119,82	111,83	35,94	2,40
Inspire 1	FC350	3,61	1,561920E-06	4.000	3.000	5,19	207,68	155,76	145,38	46,73	3,12

Fonte: o autor, 2020.

O aplicativo utilizado para elaborar os planos de voo foi o Litchi, por permitir maior flexibilidade aos planos de voos, curvas suaves e a possibilidade de voar apenas sobre as ilhas-alvo, excluindo as áreas que não são do interesse da pesquisa, a exemplo da superfície do rio São Francisco. Dessa forma, uma área de 70 ha pode ser mapeada em apenas 20 minutos, como é o caso do plano de voo ilustrado na Figura 11, elaborado para mapear parte das ilhas da Figura 9.

Figura 11 – Exemplo de plano de voo.



Fonte: o autor, 2020.

No total, foram organizados 43 planos de voo para o lançamento de RPAs de 28 bases operacionais. Os voos planejados totalizaram aproximadamente 8 horas de tempo de sobrevoo e 302 km percorridos pelas RPAs. Na Tabela 3, estão listados, resumidamente, os planos de voos elaborados; e, no Anexo I, as respectivas ilustrações.

Tabela 3 – Planos de voos elaborados.

Missão	Margem	Tempo	Percurso	Ponto de Lançamento		
		Estim. (min)	(m)	Base	Latitude	Longitude
Cabrobó P01	PE	00:09:00	6.300	CB P01	-8,539615	-39,443835
Cabrobó P02	PE	00:10:40	6.630			
Cabrobó P03	PE	00:11:11	7.380	CB P02	-8,535147	-39,428837
Cabrobó P04	PE	00:08:11	4.990			
Cabrobó P05	PE	00:10:00	6.060	CB P03	-8,524689	-39,403480
Cabrobó P06	PE	00:06:52	3.900			
Cabrobó P07	PE	00:09:00	5.800	CB P04	-8,522459	-39,380950
Cabrobó P08	PE	00:12:13	8.100			
Cabrobó P09	PE	00:10:00	6.800	CB P05	-8,528183	-39,360406
Cabrobó P10	PE	00:06:00	3.600			
Cabrobó P11	PE	00:11:00	8.000	CB P07	-8,544550	-39,344255
Cabrobó P12	PE	00:10:00	6.600			
Cabrobó P13	PE	00:08:30	4.800	CB P08	-8,546618	-39,327258
Cabrobó P14	PE	00:08:45	4.700	CB P09	-8,541151	-39,311780
Cabrobó P15	PE	00:11:00	7.500	CB P10	-8,549779	-39,294705
Cabrobó P16	PE	00:09:00	5.800			
Ibó 01-02	PE	00:23:00	7.000	Ibó 01	-8,666412	-39,221841
Ibó 03	PE	00:14:00	9.100			
Ibó 04-05	PE	00:19:00	12.500	Ibó 03	-8,678771	-39,204955
Ibó 06-07	PE	00:22:00	14.400			
Ilha Aracapé B01	BA	00:12:00	7.363	IA B01	-8,622419	-39,541232
Ilha Aracapé B02	BA	00:10:00	6.500			
Ilha Aracapé B03	BA	00:11:00	7.500	IA B02	-8,614044	-39,531694
Ilha Aracapé B04	BA	00:06:00	3.900			
Ilha Aracapé B05	BA	00:05:00	2.930	IA B03	-8,603855	-39,503681
Ilha Redonda B01 B02	BA	00:23:00	15.300	IR B01	-8,630518	-39,564527
Ilha Redonda B03	BA	00:06:00	4.100			
Ilha Redonda B04	BA	00:11:00	6.500	IR B02	-8,621650	-39,555147
Ilha Redonda B05	BA	00:10:00	6.600			
Orocó B01	BA	00:03:00	1.900	Oro B01	-8,663283	-39,686305
Orocó B02	BA	00:04:00	2.700	Oro B02	-8,662567	-39,666996
Orocó B03	BA	00:09:00	6.200	Oro B03	-8,662885	-39,643138
Orocó B04-05	BA	00:20:00	11.500	Oro B04	-8,656486	-39,627554
Orocó B06	BA	00:09:30	5.800	Oro B05	-8,641807	-39,579239
Orocó P01 P02	PE	00:23:00	15.000	Oro P01	-8,627134	-39,615500
Pedra Branca P01 P02	PE	00:21:00	13.800	PB P01	-8,545056	-39,454962
Remanso B01	BA	00:12:00	8.350	RE B01	-8,594201	-39,482369
Remanso B02	BA	00:10:00	7.250			
Remanso B03	BA	00:10:00	7.100	RE B02	-8,585700	-39,464646
Remanso P01	BA	00:10:00	6.500	Balsa	-8,562474	-39,464650
SM 01	PE	00:12:00	8.200	SM 01	-8,784046	-39,698600
SM 02	PE	00:11:00	7.400	SM 02	-8,780852	-39,715758
Totais		07:57:52	302.353			

Fonte: o autor, 2020.

4.2.3 Aquisição de imagens

Nos dias 26 e 27 de novembro de 2019, usando uma RPA modelo Matrice 200 V2, o autor realizou os voos Ibó 01-02, Ibó 03, Ibó 04-05, Ibó 06-07, no município de Belém de São Francisco/PE, Orocó P01-P02, em Orocó/PE. Os voos SM 01 e SM 02, em Santa Maria da Boa Vista, foram efetivados com Mavic 2 PRO. Os demais voos foram realizados por terceiros, nos dias 27 e 28 de novembro, usando Mavic PRO e Phantom 4 PRO. Todas as aeronaves estavam equipadas com sensor RGB.

A aquisição de imagens foi realizada entre as 9h e as 15h, de forma que a iluminação foi adequada para a aquisição de imagens de boa qualidade, não obstante no dia 26 o céu estivesse parcialmente nublado. Os sensores das RPAs foram ajustados para disparar de acordo com o intervalo de tempo previsto na Tabela 2, a fim de garantir o recobrimento transversal mínimo de 70% com o menor número de imagens possível.

No total, foram adquiridas 8.289 imagens em 42 voos. O voo Remanso P01 não foi realizado, e, no voo Cabrobó P09, as imagens não ficaram adequadas para o processamento digital. Assim, com um voo não realizado e a exclusão de outro, o total de imagens a ser submetido à classificação ficou em 8.099.

Também foram usadas, na pesquisa, imagens adquiridas pelo autor em operações policiais realizadas no ano de 2017, fruto de levantamentos aerofotogramétricos realizados com uma aeronave remotamente pilotada, modelo Inspire 1, fabricado pela DJI.

4.2.4 Classificação supervisionada

Duas formas de classificação supervisionada foram utilizadas: classificação de mosaico de ortofotos usando *pixels* de treinamento e classificação por meio de algoritmo de aprendizado de máquina aplicado diretamente nas imagens adquiridas.

4.2.4.1 Classificação de ortomosaico no QGIS

Inicialmente, as imagens adquiridas com RPAs foram submetidas à classificação visual com a finalidade de identificar possíveis pontos com cultivo de *Cannabis*, definidos pelas características da vegetação presente na área, pelo posicionamento em relação a pontos erradicados em operações passadas, pela morfologia dos indivíduos e pelas características do plantio.

As imagens com indício de plantios ilícitos foram separadas em pastas distintas, para posteriormente serem usadas na identificação do local, sobretudo em áreas com grande número de ilhas de pequeno porte. Para tanto, uma vez que há o registro do mesmo plantio em mais de uma imagem, a seleção foi realizada de forma que o centro do cultivo estivesse mais próximo do centro da imagem, visto que a coordenada presente nos metadados refere-se a este ponto.

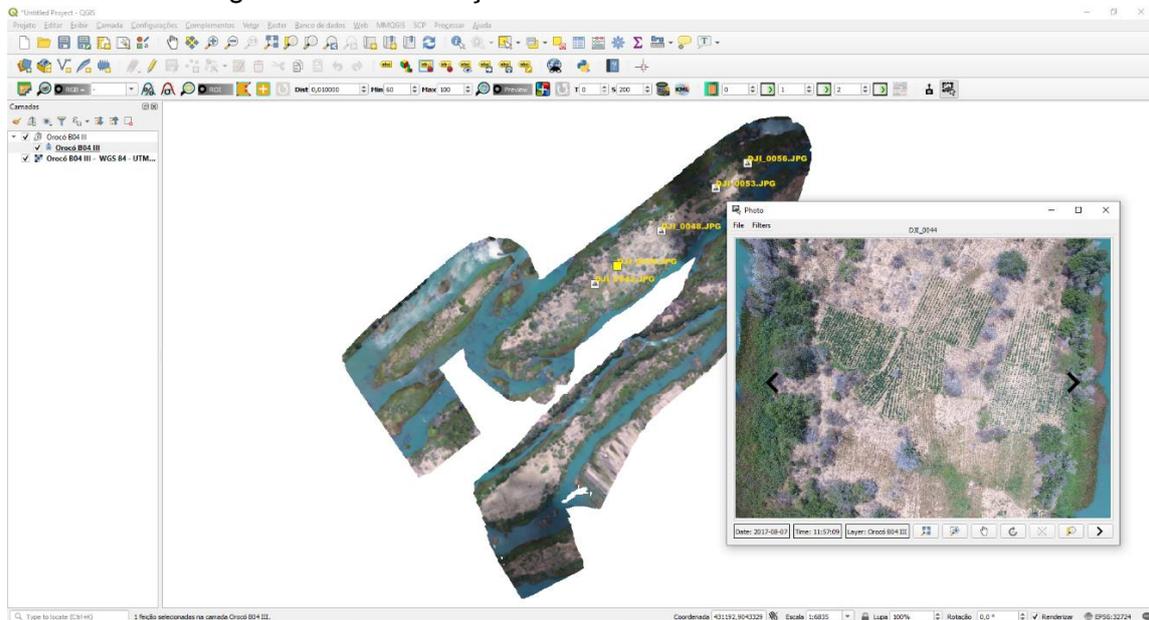
Os voos que tiveram o registro de possíveis cultivos ilícitos tiveram as imagens adquiridas processadas em um microcomputador com processador Intel Xeon E5-1650 v3, 28 GB de memória RAM, disco rígido de armazenamento com 2 TB e memória sólida com 480 GB de espaço. O *software* utilizado foi o *Agisoft Metashape*, a fim de criar mosaico de ortofotos no formato GeoTIFF, para que fosse possível,

posteriormente, realizar a classificação supervisionada da vegetação com o QGIS e obter as coordenadas do centro dos plantios suspeitos identificados nas imagens.

No projeto desenvolvido no QGIS, foram criados dois grupos de camadas: uma para abrigar os ortomosaicos e outra para guardar o endereço das imagens selecionadas com indícios de cultivos ilícitos. O projeto do QGIS foi ajustado para o mesmo sistema de coordenadas projetadas dos ortomosaicos, qual seja: SIRGAS 2000 / UTM zone 24S (EPSG:31984).

Os mosaicos de ortofotos foram inseridos no QGIS como camadas *raster*, e as posições das imagens com indicativo de plantios ilícitos foram incluídas no projeto usando o *plugin* ImportPhotos (KYRIAKOU, CHRISTOU e KOLIOS, 2019). A funcionalidade desse plugin, permitiu localizar os plantios e verificar a imagem fonte. A Figura 12 mostra uma cena da imagem-fonte com o mosaico ao fundo e o ícone correspondente.

Figura 12 – Localização de cultivo no mosaico de ortofoto



Fonte: o autor, 2020.

Além de conseguir localizar e identificar a imagem no mosaico de ortofotos, pode-se avaliar o entorno dos pontos indicados como plantios ilícitos no que diz respeito à existência de outros cultivos lícitos ou ilícitos, presença de animais, residências, caminhos de acesso aos pontos de cultivos, locais de coleta de água e portos para pequenas embarcações.

Ressalta-se que, no caso de ilhas com histórico de plantios erradicados, essas características presentes próximas ao ponto tido como lavoura ilícita são elementos

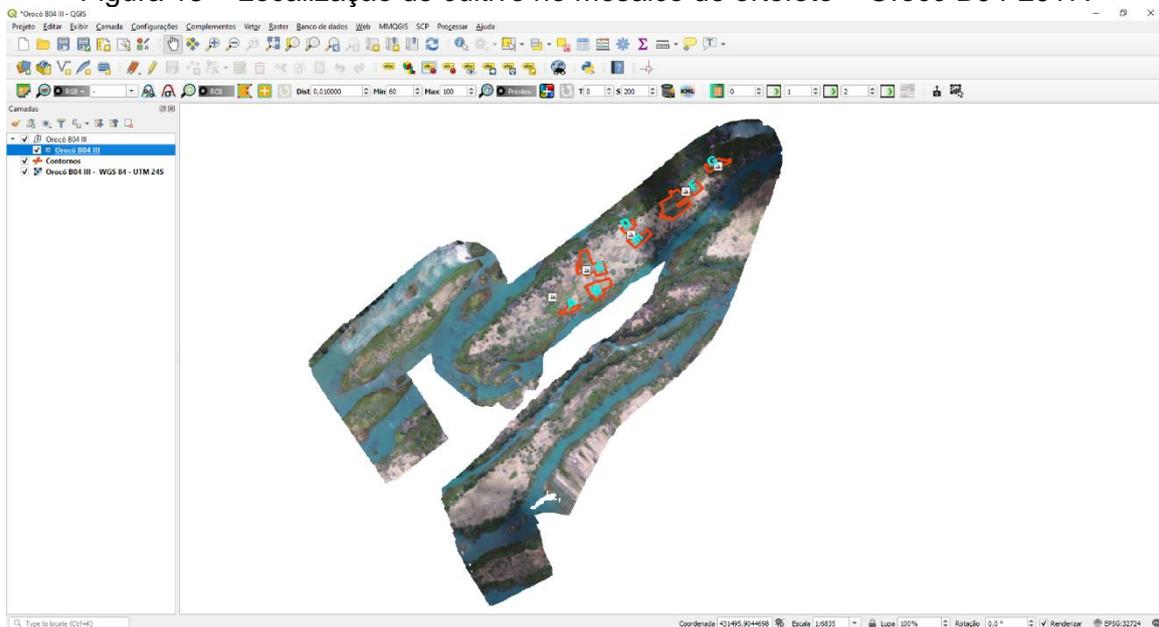
complementares à definição da natureza da plantação; inclusive é possível que um suposto plantio de *Cannabis* seja apenas vegetação nativa que germinou em covas de uma plantação ilícita, aproveitando o adubo existente no local, fazendo com que ocorra uma distribuição espacial da vegetação semelhante a cultivos de *Cannabis*.

Dessa maneira, a ausência de atividade humana ou a presença de animais na proximidade do suposto cultivo ilícito sugere que se trata de vegetação nativa, nascida em período chuvoso, em covas de plantio ilícito, preteritamente erradicado ou colhido.

Após a localização dos plantios suspeitos, as áreas foram delimitadas por polígonos irregulares, com o objetivo de obter amostra da reflectância de exemplares de *Cannabis*, assim como as coordenadas centrais do plantio. Na

Figura 13, é apresentado o ortomosaico Orocó B04-2017 com os polígonos projetados, um exemplo de um dos trabalhos de identificação visual de cultivos.

Figura 13 – Localização de cultivo no mosaico de ortofoto – Orocó B04-2017.



Fonte: o autor, 2020.

Mosaico de ortofotos resultante do processamento das imagens do voo Orocó B04, realizado em 2017, com uma RPA modelo Inspire 1, com GSD de 5 cm.

Após o tratamento dos ortomosaicos, foi realizada a classificação por meio do *plugin* Semi-Automatic Classification Plugin – SCP, que é um código-fonte aberto escrito para o QGIS (CONGEDO, 2018). Foram usados *pixels* de treinamento escolhidos em plantas identificadas como *Cannabis*. Na pesquisa, utilizaram-se os mosaicos de ortofotos dos voos Orocó B04 e Ibó 07, realizados em 2017, nos quais foram identificados cultivos posteriormente confirmados por análises no local.

4.2.4.2 *Aprendizado de máquina – AM*

A classificação auxiliada por algoritmo de aprendizado de máquinas foi subdividida em três níveis de classificação, a saber:

- a) Nível 1 – classificação exclusiva do algoritmo sem qualquer exclusão por classificação visual de falsos positivos e falsos negativos. Nesse nível, avalia-se o resultado da classificação supervisionada efetuada pelo algoritmo tendo como parâmetro apenas a base de dados de treinamento.
- b) Nível 2 – todo processo anterior do Nível 1 acrescido da classificação visual da base de dados das imagens rotuladas como ocorrências positivas de *Cannabis*. O objetivo é identificar visualmente os falsos positivos. Com esse procedimento, busca-se avaliar os benefícios e as perdas da interpretação efetuada, quando adicionada mais uma etapa no processo de classificação, uma vez que a ocorrência de falsos positivos não é bem-vinda e aumenta significativamente os custos da operação, especialmente quando se trata da mobilização de equipes para erradicar um cultivo inexistente.
- c) Nível 3 – classificação visual, interativa, da base de dados com imagens rotuladas como ocorrência negativa. A finalidade é identificar visualmente os falsos negativos.

Uma vez considerados os níveis de classificação, as 8.099 imagens adquiridas entre os dias 26 e 28 de novembro de 2019, resultantes dos 41 voos de levantamento aerofotogramétrico, foram submetidas à classificação supervisionada, por meio do algoritmo de aprendizado de máquina – usando técnicas de redes neurais convolucionais – desenvolvido por Silva e Nascimento (2019).

Posteriormente, os dados resultantes da classificação por meio de AM foram submetidos a uma nova classificação visual, a fim de eliminar os falsos positivos e os falsos negativos presentes na base de dados resultante, implementando os três níveis de classificação.

Além das imagens adquiridas em novembro de 2019, dois mosaicos de ortofotos produzidos com imagens dos voos Orocó B04 e Ibó 07 realizados em 2017 também foram submetidos à classificação Nível 1, a fim de comparar os resultados com a classificação supervisionada com o SCP.

Ao final, o resultado de cada nível de classificação foi comparado com as conclusões dos exames de local, realizados durante a Operação Facheiro V da Polícia Federal. Os resultados da classificação das 8.099 imagens foram avaliados pelas três métricas descritas na próxima seção.

4.2.5 Métricas de avaliação

Com o objetivo de avaliar o poder preditivo das classificações auxiliadas por aprendizado de máquina, três métricas de avaliação foram utilizadas para quantificar as performances dos modelos, quais sejam: Precisão, *Recall* e $F1_{score}$, cujas fórmulas de cálculo são apresentadas em (9), (10) e (11):

$$\text{Precisão} = \frac{PV}{(PV + FP)} \quad (9)$$

$$\text{Recall} = \frac{PV}{(PV + FN)} \quad (10)$$

$$F1_{score} = \frac{2(\text{Precisão} \times \text{Recall})}{(\text{Precisão} + \text{Recall})} \quad (11)$$

Onde:

- PV (*Positivo Verdadeiro*) – imagens corretamente marcadas como positivas.
- FP (*Falso Positivo*) – imagens incorretamente marcadas como positivas.
- FN (*Falso Negativo*) – imagens selecionadas incorretamente como negativas.

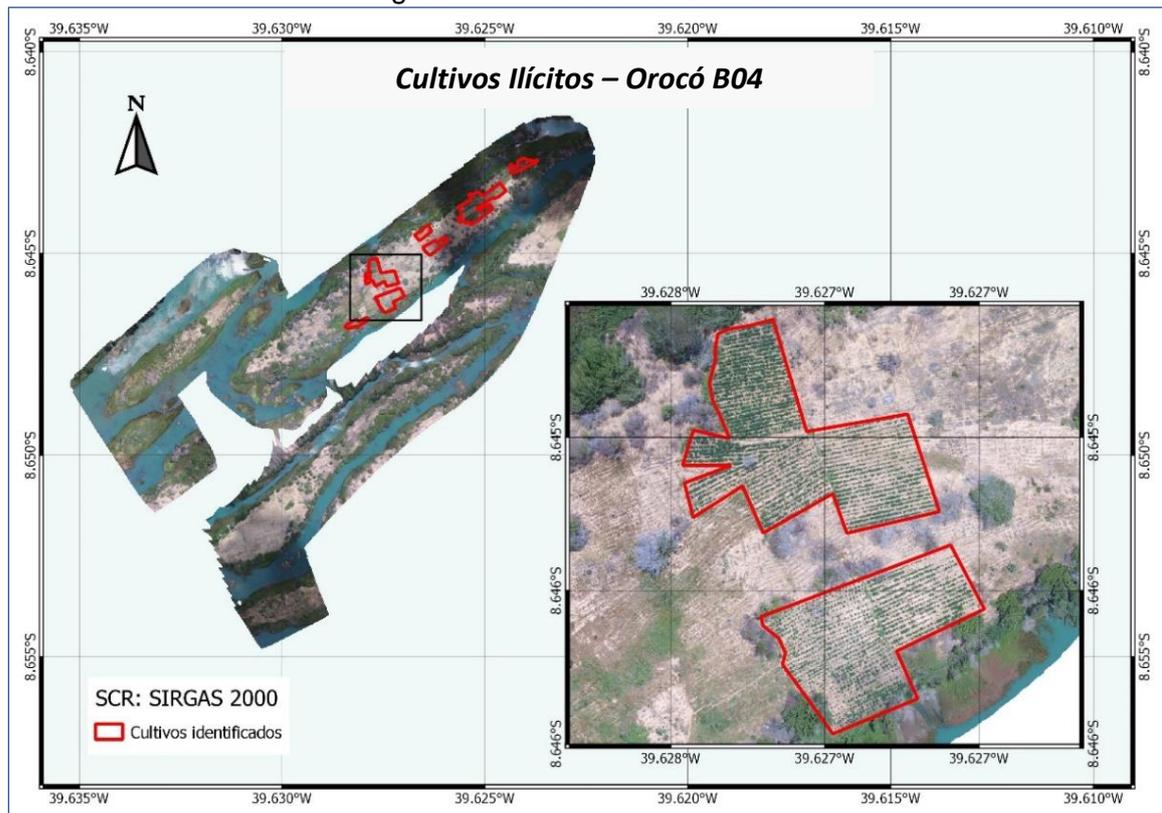
4.2.6 Mapas temáticos

Após o tratamento dado aos mosaicos de ortofotos, como descrito em 4.2.4.1, criou-se, no ambiente de projeto do *software* QGIS, uma camada no formato Geopackage, com a geometria de ponto, chamada *Cultivos Suspeitos*. Os campos criados foram: nome do ponto, descrição, latitude e longitude. A finalidade dessa camada era a de armazenar as informações dos plantios identificados e suas localizações, pontualmente, como lavoura ilícita e subsidiar com informações as equipes que realizaram os exames de local.

Os mapas temáticos são gerados conforme apresentado na

Figura 14. Neste exemplo, o mapa temático ilustra ilhas do rio São Francisco nas proximidades do município de Cabrobó, estado de Pernambuco. A composição do conteúdo desses mapas é formada por: ortomosaicos originados do processamento das imagens RGB e polígonos que delimitam as sete áreas de plantios de *Cannabis*. A área ampliada do mapa destaca duas áreas do cultivo; juntas somam 5.420 m².

Figura 14 – Plantios de *Cannabis*.



Fonte: o autor, 2020.

4.2.7 Exame de local

Concluída a classificação de imagens, foram indicados vinte e dois pontos com suspeitas de cultivos, listados na Tabela 4. Esses pontos estão localizados em ilhas do rio São Francisco e foram visitados em campo por equipes da Polícia Federal ou da Polícia Rodoviária Federal.

Tabela 4 – Pontos indicados pela análise de imagens.

Cultivo	Município	Latitude	Longitude
P002	Belém do São Francisco	-8°41'8.555"	-39°12'30.42"
P001	Belém do São Francisco	-8°38'34.65"	-39°13'47.60"
P004	Belém do São Francisco	-8°40'44.06"	-39°11'42.09"
P005	Cabrobó	-8°32'17.51"	-39°25'41.02"
P007	Cabrobó	-8°32'21.23"	-39°25'36.53"
P012	Cabrobó	-8°31'46.52"	-39°22'18.24"
P006	Cabrobó	-8°32'22.86"	-39°25'9.194"
P008	Cabrobó	-8°32'17.65"	-39°25'37.66"
P009	Cabrobó	-8°32'18.67"	-39°25'44.13"
P010	Cabrobó	-8°32'16.35"	-39°25'36.21"
P013	Cabrobó	-8°31'40.69"	-39°23'14.80"
P024	Cabrobó	-8°32'8.224"	-39°21'37.88"
P025	Cabrobó	-8°32'49.45"	-39°21'9.278"
P022	Orocó	-8°35'20.29"	-39°29'29.85"
P016	Orocó	-8°36'38.76"	-39°32'6.359"
P017	Orocó	-8°36'0.050"	-39°31'40.48"
P018	Orocó	-8°37'28.63"	-39°33'43.04"
P019	Orocó	-8°37'31.01"	-39°33'44.08"
P020	Orocó	-8°35'16.54"	-39°28'56.93"
P021	Orocó	-8°35'20.98"	-39°29'12.44"
P023	Orocó	-8°36'0.152"	-39°31'50.08"
P003	Santa Maria da Boa Vista	-8°47'20.24"	-39°42'9.019"

Fonte: Polícia Federal.

Além dos cultivos listados na Tabela 4, a equipe de identificação de cultivos ilícitos, por meio de sobrevoo com helicóptero, ainda localizou duas lavouras ilícitas, com indivíduos de *Cannabis* em estágio inicial do ciclo de vida. Esses dois cultivos estavam situados em pequenas ilhas do município de Orocó, próximo ao povoado de Remanso, nas coordenadas indicadas na

Tabela 5.

Tabela 5 – Pontos localizados por meio de helicóptero.

Cultivo	Município	Latitude	Longitude
P026	Orocó	-8°35'23.40"	-39°29'18.00"
P028	Orocó	-8°35'29.02"	-39°29'09.60"

Fonte: Polícia Federal.

Os pontos de cultivo definidos no mapa de classificação supervisionada quando visitados e reambulados serviram de base de dados para a validação da eficiência e eficácia da metodologia.

5 RESULTADOS

Para melhor compreensão os resultados foram subdivididos em dois grupos, a saber: classificação supervisionada com pixel de treinamento e Classificação supervisionada por meio de aprendizado de máquina

5.1 Classificação supervisionada com *pixel* de treinamento

Para o ortomosaico Orocó B04-2017, o melhor resultado conseguido com o SCP foi por meio de amostras da área C, ilustrada na

Figura 13. Resultou na seleção de espécimes nas áreas A, B, C, D e E. Não foi marcada qualquer planta nas áreas F e G, pois estavam totalmente sob a sombra de nuvens, e as áreas D e E estavam parcialmente cobertas.

Tabela 6 – Cultivos em Orocó B04-2017.

Cultivo	Área		
	m ²	PV	FN
A	803,35	803,35	-
B	2.720,20	2.720,20	-
C	3.623,28	3.623,28	-
D	879,69	879,69	-
E	1.548,43	1.548,43	-
F	5.917,27	-	2.629,90
G	1.270,82	-	423,61
Total	16.763,04	9.574,95	3.053,51

Fonte: o autor, 2020.

PV – Positivo Verdadeiro; FN – Falso Negativo.

Quando considerada a área total de 16.763,04 m² de cultivos ilícitos do ortomosaico Orocó B04-2017, detalhada na Tabela 6, a amostra espectral submetida à classificação de melhor resultado resultou na localização de cinco cultivos, que representam 57,12% dos plantios de *Cannabis* existentes na imagem. Sendo, o restante correspondente a 42,88% de área de cultivos não classificada; portanto, nenhum espécime foi marcado.

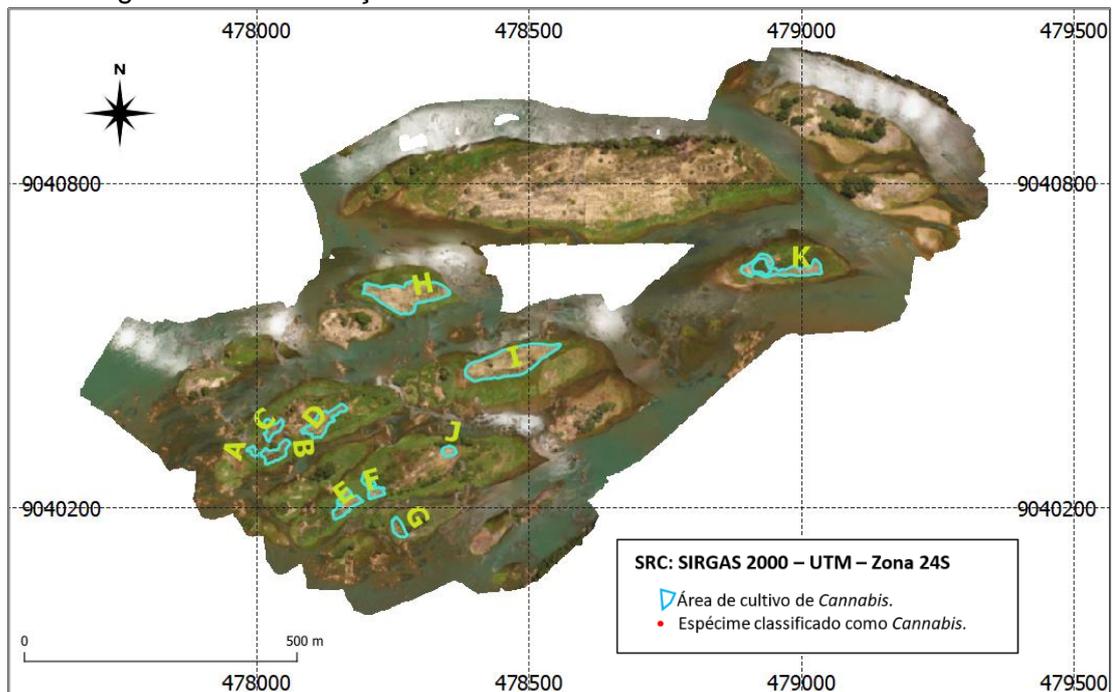
Para o ortomosaico Orocó B04-2017,

Figura 13, o baixo percentual de acerto de classificação do SCP referente à lavoura de *Cannabis* foi causado pela presença de áreas sombreadas por nuvens na imagem. Nas áreas D e E, o SCP assinalou apenas 8 e 3 covas de plantio, respectivamente; na primeira havia 390 covas; e na segunda, 776 covas com cultivo

ilícito. Nas áreas E e F, que estão totalmente cobertas pela sombra de nuvens, não foi identificada qualquer cova das 3.050 existentes no local.

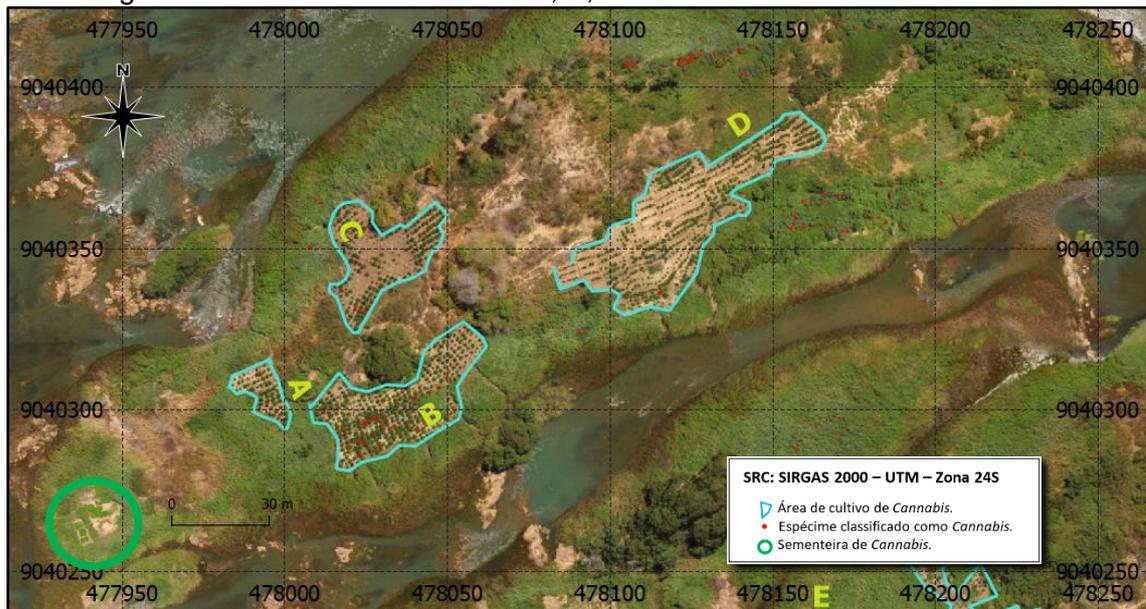
Em um segundo ortomosaico, Figura 15, a classificação supervisionada também não foi bem-sucedida devido, possivelmente, a problemas relacionados à quantidade de solo exposto em torno das plantas de *Cannabis*. Nesse caso, não houve a ocorrência de variação de iluminação nas imagens como caso do ortomosaico Orocó B04-2017. As imagens foram adquiridas entre as 10h45min e as 10h54min, horário matutino, sem a presença de sombras no local.

Figura 15 – Localização dos cultivos ilícitos do ortomosaico Ibó 07-2017.



Fonte: o autor, 2020.

Figura 16 – Resultado nas áreas A, B, C e D do ortomosaico Ibó 07-2017.



Fonte: o autor, 2020.

No ortomosaico Ibó 07-2017, a classificação resultou na localização de espécimes de *Cannabis* em 9 áreas de um total de 11. Levando-se em conta a soma das áreas desses locais, o SCP conseguiu indicar 87,49% da área total de plantios ilícitos. No entanto, em 5 áreas o SCP selecionou menos de 10 covas em cada uma. Contabilizando o número de total de marcações, verificou-se que o SCP selecionou 238 covas de um total de 9.070, ou seja, apenas 2,54% do total de covas foi identificado pelo SCP, como é detalhado na Tabela 7.

Tabela 7 – Covas – Ibó 07-2017.

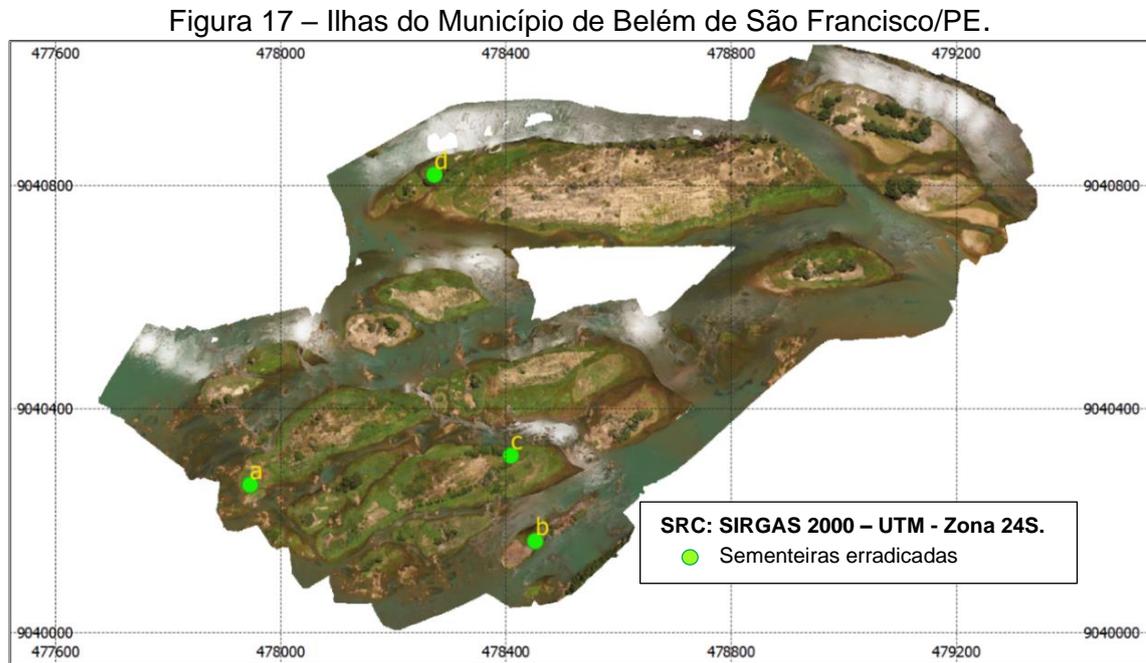
Cultivo	Área	Quantidade de Covas		
	Total	SCP	Real	%
A	198,40	2	88	2,27%
B	1.091,70	83	485	17,11%
C	769,68	25	342	7,31%
D	1.793,60	9	797	1,13%
E	1.286,92	5	572	0,87%
F	777,73	8	346	2,31%
G	608,00	3	270	1,11%
H	5.489,27	28	2.440	1,15%
I	6.423,30	75	2.855	2,63%
J	367,15	-	163	0,00%
K	2.269,74	-	1.009	0,00%
Total	21.075,49	238	9.367	2,54%

Fonte: o autor, 2020.

No que se refere a sementeiras, a classificação supervisionada realizada pelo SCP foi bem-sucedida. Os *pixels* de treinamento foram escolhidos no centro da

sementeira, a fim de minimizar as influências espectrais do solo e de outros alvos vizinhos. A

Figura 17 apresenta um mapa que permite a visualização da localização das sementeiras na área experimental da pesquisa.

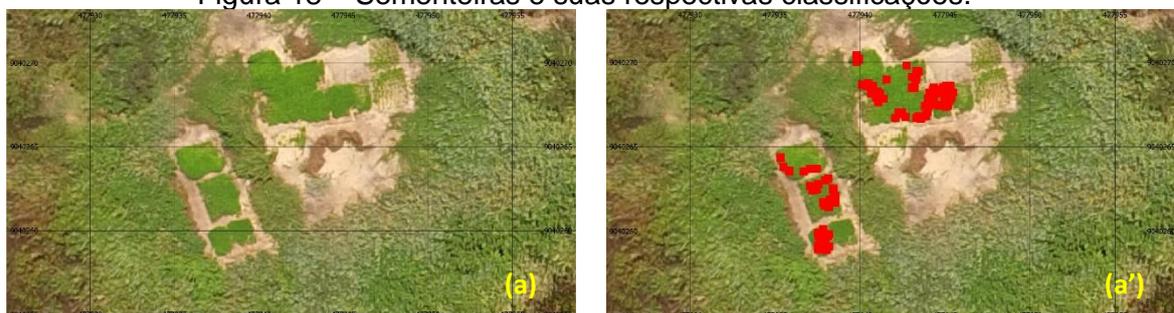


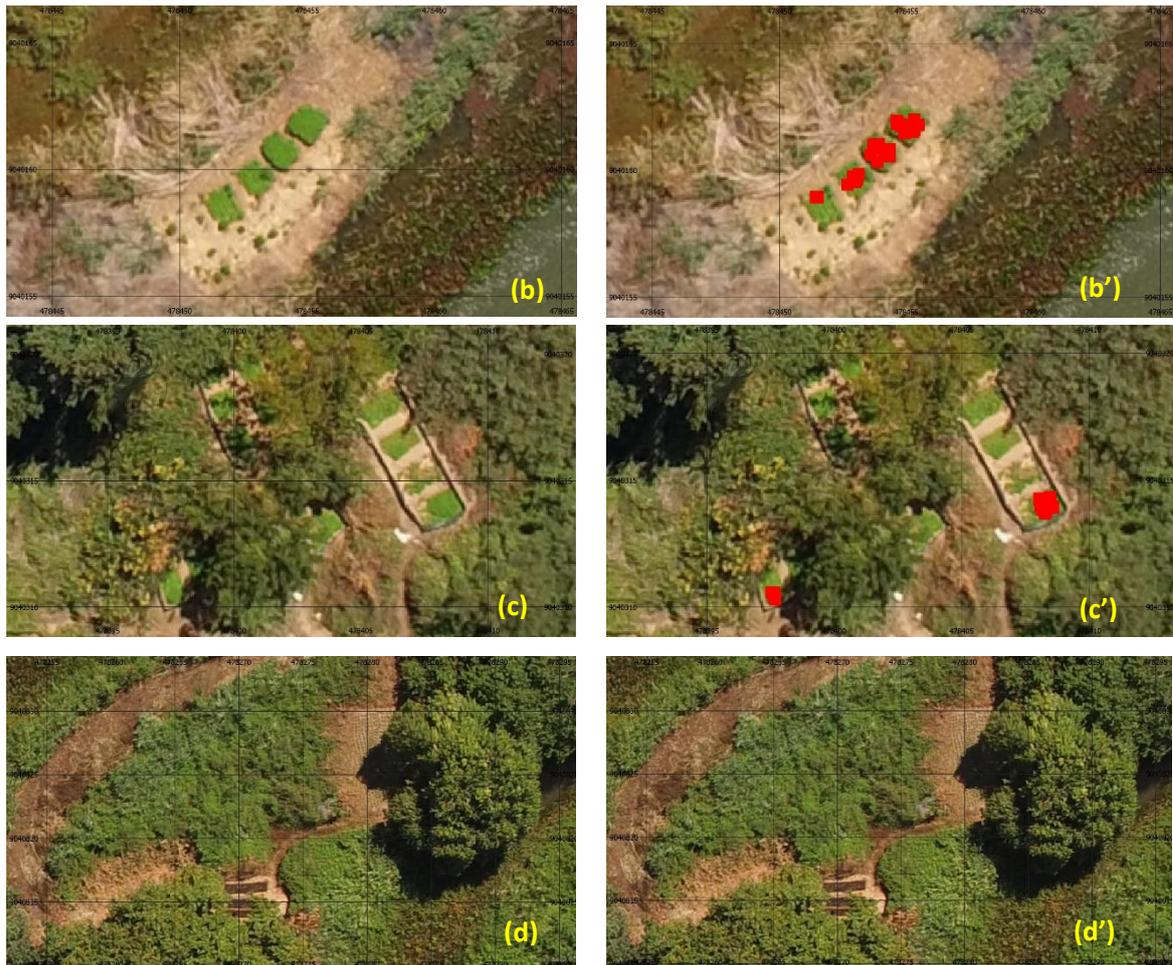
Fonte: o autor, 2020.

A

Figura 18 ilustra as sementeiras e a classificação realizada pelo SCP para cada uma. A quantidade de falsos positivos foi insignificante nesse caso. No ortomosaico, há três sementeiras com as mesmas características (a, b e c) que foram identificadas a partir de uma região de interesse (ROI) selecionada da sementeira (b). A quarta sementeira (d), plantada em saquinhos e com indivíduos muito jovens, não possui as mesmas características das outras três, plantadas diretamente no solo, sem espaçamento, motivo pelo qual não foi classificada pelo SCP.

Figura 18 – Sementeiras e suas respectivas classificações.





Fonte: o autor, 2020.

As imagens a, b, c e d são sementeiras antes da classificação e a', b', c' e d' são as mesmas sementeiras após a classificação, cujos pontos vermelhos representam os *pixels* identificados pelo SCP.

5.2 Classificação supervisionada por meio de aprendizado de máquina

Três níveis de classificação foram adotados para o AM.

5.2.1 Classificação Nível 1

O resultado da classificação realizada pelo algoritmo de aprendizado de máquinas gerou três conjuntos de imagens, armazenadas nas pastas Dúvidas, Negativos e Positivos. Das 8.099 imagens classificadas, 853 foram rotuladas como Positivo; 6.126, como Negativo e 1.120 como Dúvida.

Levando em conta os dados de campo, obtidos durante os exames de local realizados pela Polícia Federal, para as métricas consideradas, o Nível 1 de

classificação apresentou os seguintes resultados: Precisão de 3,17%, *Recall* de 79,41% e $F1_{score}$ 0,06, para uma escala que varia de 0 a 1.

A precisão conseguida com esse nível revela que há um número elevado de falsos positivos em relação aos positivos verdadeiros, motivo pelo qual foi necessário implementar o segundo nível.

5.2.2 Classificação Nível 2

Ao submeter as imagens rotuladas como positivas à classificação visual, foram expurgadas do conjunto 704 imagens. Com a aplicação de mais esse nível de classificação, a métrica Precisão passou a ser de 100%, ou seja, foram eliminados todos os falsos positivos. O *Recall* permaneceu em 79,41%, e o $F1_{score}$ passou para 0,89.

Ressalta-se que a eliminação de todos os falsos positivos é relevante, pois o custo com a mobilização de equipes para realizar o trabalho de erradicação de cultivos ilícitos em ilhas é oneroso, tendo em vista que requer o deslocamento de equipes embarcadas em helicópteros ou em barcos.

Além disso, para realizar a classificação visual das imagens indicadas como Positivo pelo algoritmo foi preciso analisar 853, o que representa apenas 10,53% do conjunto total de imagens, reduzindo significativamente a quantidade de imagens para analisar.

5.2.3 Classificação Nível 3

Submetendo a base de dados ao terceiro nível de classificação, correspondente à análise das imagens rotuladas como Negativo, e, conseqüentemente, tendo realizado a classificação visual de mais 6.126 imagens, foram expurgadas cinco imagens falso negativo não identificadas pelo algoritmo de classificação supervisionada. As cinco imagens são referentes a três cultivos, denominados FN-1, FN-2 e FN3, apresentados nas figuras 19, 20 e 21.

Figura 19 – Imagem adquirida durante o voo Ibó 04-05.



Fonte: o autor, 2020.

Figura 20 – Imagem adquirida durante o voo Ilha Aracapá B03.



Fonte: o autor, 2020.

Figura 21 – Imagem adquirida durante o voo Remanso 01.



Fonte: o autor, 2020.

Com mais esse procedimento, os resultados passaram a apresentar as seguintes métricas: Precisão 100%, *Recall* 94,12% e $F1_{score}$ 0,97. Todavia, ainda restaram quatro imagens registrando dois cultivos ilícitos, **que não foram detectadas por meio da classificação visual da base de dados de imagens rotuladas como Negativo**. Os dois cultivos, FN-4 e FN-5, são mostrados nas figuras 22 e 23.

Figura 22 – Imagem adquirida durante o voo Remanso 02.



Fonte: o autor, 2020.

Figura 23 – Imagem adquirida durante o voo Remanso 02.

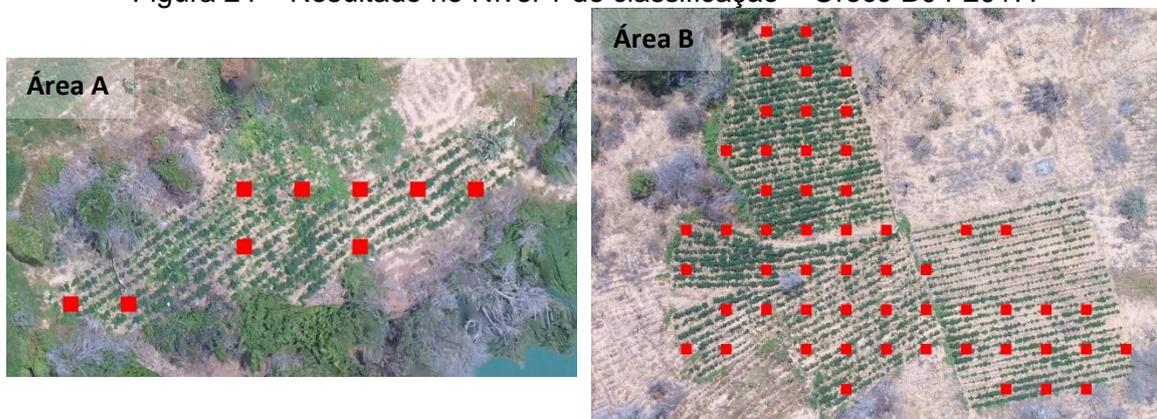


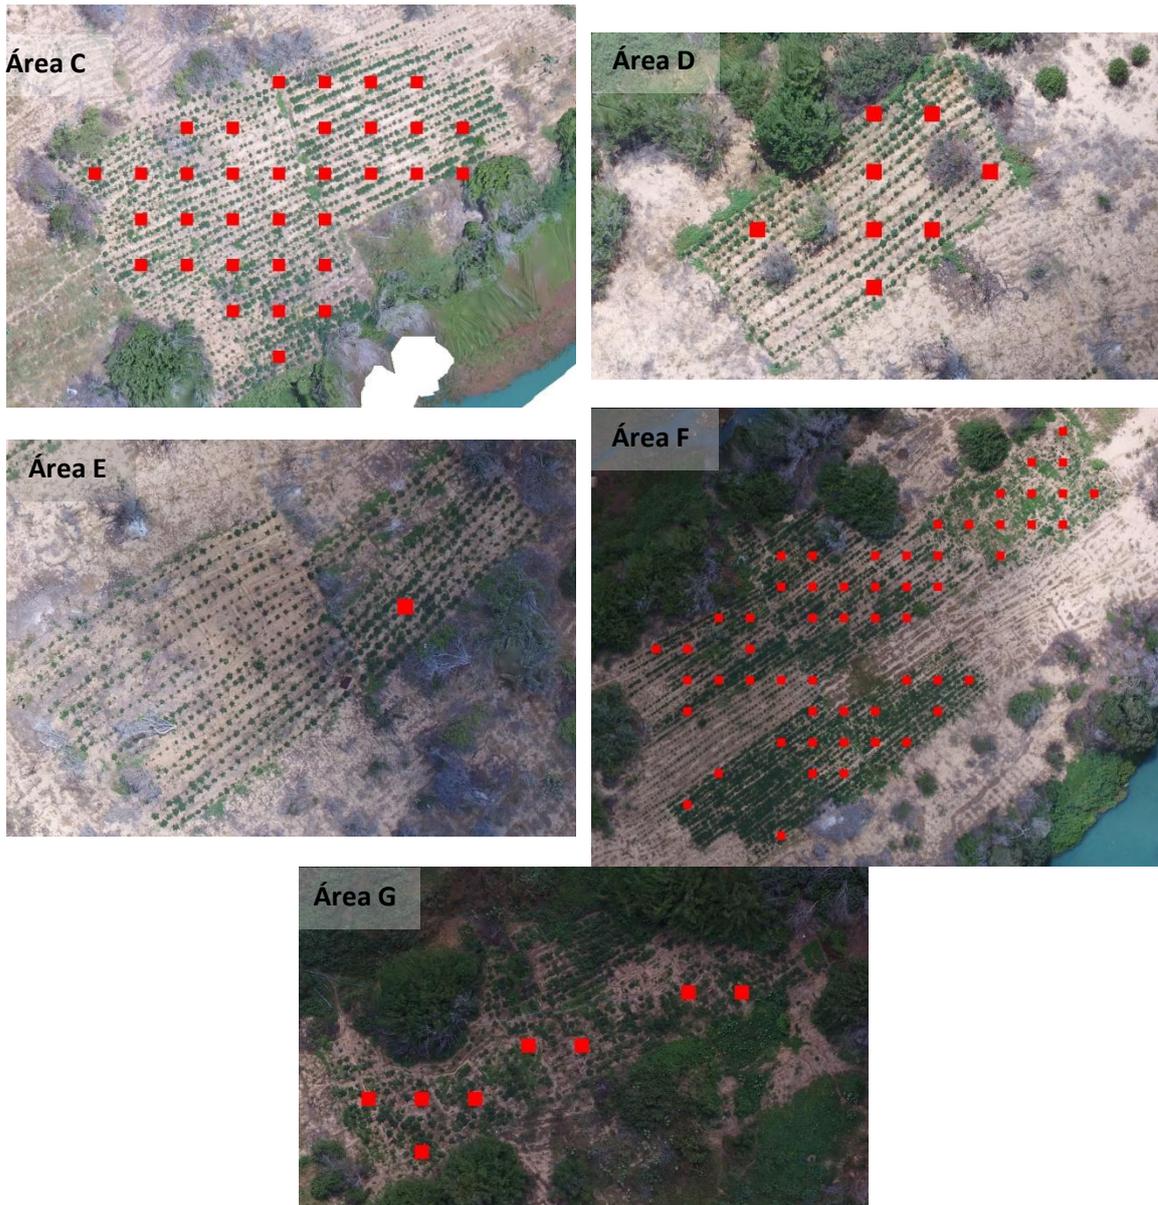
Fonte: o autor, 2020.

5.2.4 Classificação de ortomosaicos por meio de aprendizado de máquina

A classificação por AM do ortomosaico Orocó B04-2017 resultou na identificação das sete áreas de cultivos ilícitos existentes na imagem, denominadas A, B, C, D, E, F e G, conforme ilustradas na Figura 24. Na área E, houve apenas uma confirmação.

Figura 24 – Resultado no Nível 1 de classificação – Orocó B04-2017.



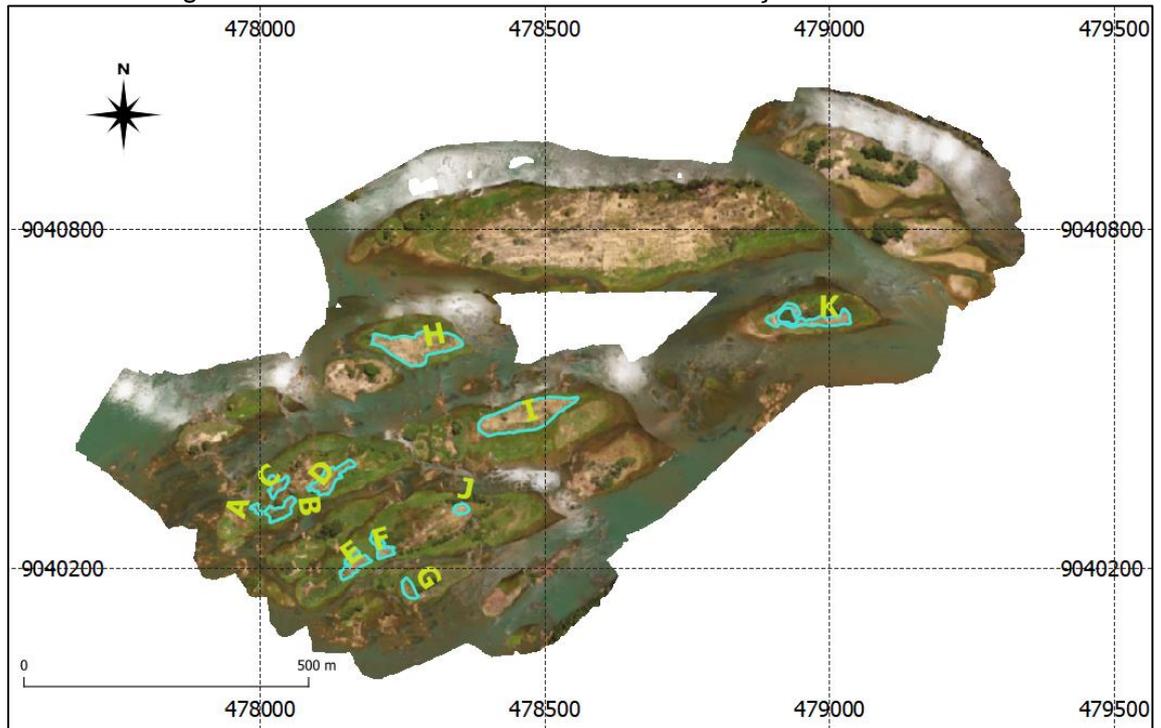


Fonte: o autor, 2020.

Ainda em relação ao ortomosaico Orocó B04-2017, observando as áreas F e G, percebe-se que não houve alteração no padrão de acerto do algoritmo de AM em locais sob a sombra de nuvens.

Em relação ao ortomosaico Ibó 07-2017, das onze áreas com cultivo de *Cannabis*, o algoritmo de aprendizado de máquina conseguiu identificar dez locais, existentes na imagem da Figura 25. A exceção foi a área J, mostrada na Figura 26. E, da mesma forma que aconteceu com uma área do ortomosaico Orocó B04-2017, a área G teve apenas uma marcação de positivo.

Figura 25 – Resultado no Nível 1 de classificação – Ibó 07-2017.



Fonte: o autor, 2020.

Figura 26 – Área J do mosaico de ortofotos Ibó 07-2017.



Fonte: o autor, 2020.

A análise dos resultados da classificação dessas duas imagens, revelou que o algoritmo utilizado cometeu erros de omissão nas regiões das áreas onde as covas de *Cannabis* estavam irregularmente espaçadas (

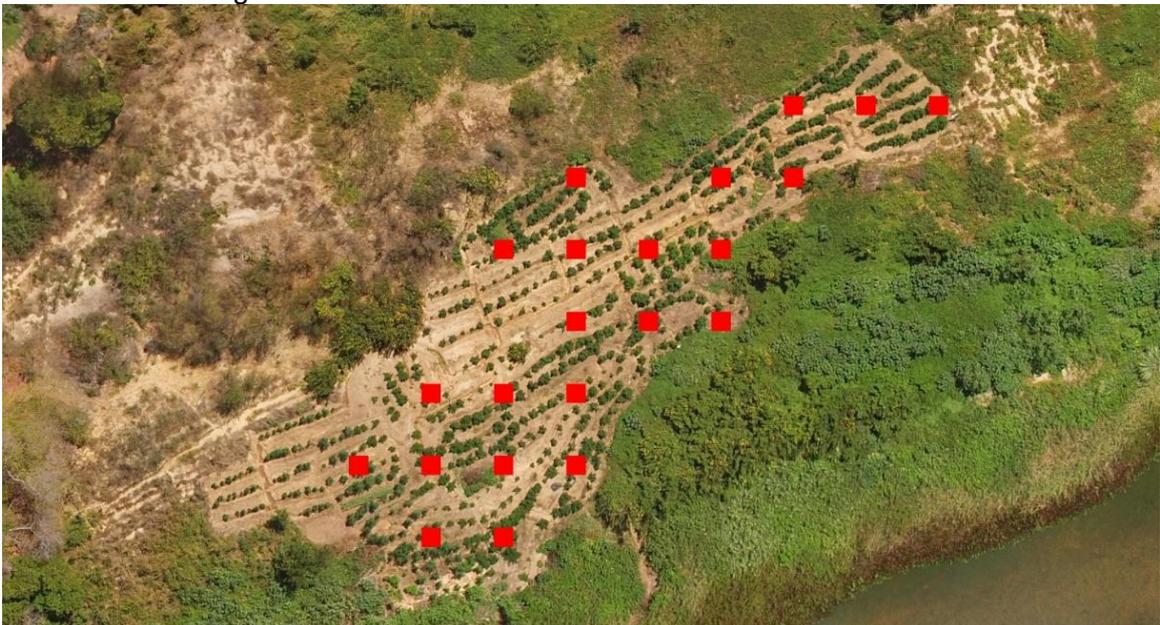
Figura 27), ou com indivíduos jovens misturados com plantas maduras (Figura 28), ou áreas onde plantas adultas de *Cannabis* recobrem a maior parte do solo entre fileiras de covas.

Figura 27 – Área H do mosaico de ortofotos Ibó 07-2017.



Fonte: o autor, 2020.

Figura 28 – Área D do mosaico de ortofotos Ibó 07-2017.



Fonte: o autor, 2020.

6 CONCLUSÃO

O combate sistêmico ao cultivo de *Cannabis* pela Polícia Federal remonta à década de 1980, e, nas últimas décadas, foram implementadas diversas melhorias às técnicas de repressão a esse tipo de crime, dentre elas, destaca-se a inserção de Tecnologias da Geoinformação, essenciais para compor base de dados geoespaciais, com as características das ocorrências de plantios ilícitos erradicados em um período de 9 anos e usada no presente trabalho.

Com as informações dessa base de dados, foi possível definir os municípios que formam o *Polígono da Maconha*, identificar as ilhas do rio São Francisco, que, historicamente, têm ocorrências de plantios ilícitos e, assim, elaborar os planos de voo para mapear as ilhas do rio entre Santa Maria da Boa Vista e Belém de São Francisco, numa extensão de aproximadamente 90 km.

Para tanto, foi necessário elaborar 43 planos de voo e definir 28 bases operacionais. No total, foram percorridos cerca de 300 km pelas RPAs, em 8 horas de voos, resultando na aquisição de 8.099 imagens com qualidade adequada para o processamento digital de imagem.

Foram estudados dois métodos de classificação. Um por meio do *Semi-Automatic Classification Plugin*, usando *pixels* de treinamento, e outro empregando algoritmo de aprendizado de máquina. Os dois métodos aplicados tiveram resultados distintos:

a) Quanto à classificação do SCP

A classificação usando o *Semi-Automatic Classification Plugin* e mosaicos de ortofotos conseguiu localizar 57,12% das áreas de plantios existentes no ortomosaico Orocó B04-2017; no ortomosaico Ibó 07-2017, o acerto foi de 87,49% das áreas de cultivo ilícito. Contudo, quando verificado pontualmente em relação ao número de covas, o classificador consegue identificar apenas 2,54% da quantidade total de covas existentes na área estudada.

Em relação às quatro sementeiras do ortomosaico Ibó 07-2017, o SCP conseguiu identificar as três sementeiras que estavam sendo cultivadas diretamente no solo, formando um padrão de tonalidade, textura e forma semelhante entre elas, típico de espécimes de *Cannabis* jovens plantados sem espaçamento. A quarta

sementeira estava sendo cultivada em saquinhos e os indivíduos de *Cannabis* eram muito jovens, motivo pelo qual não foi encontrada pelo SCP.

Para as áreas de cultivo com presença de sombras nas imagens e com solo exposto em torno das plantas de *Cannabis*, houve um decréscimo de identificação pelo classificador. A exemplo das áreas D e E, do ortomosaico Orocó B04-2017, em que o SCP marcou, respectivamente, apenas 8 e 3 covas dos cultivos ilícitos; na primeira havia 390 covas; e, na segunda, 776 covas, ambas com muita área de solo exposto e parcialmente cobertas por nuvens. Nas áreas F e G, as quais estão totalmente cobertas pela sombra da nuvem, não foi marcada qualquer cova das 3.050 existentes no local.

b) Quanto à classificação por AM

A classificação supervisionada auxiliada por aprendizado de máquina obteve melhores resultados para classificação de mosaicos de ortofotos do que o SCP. O algoritmo de redes neurais convolucionais identificou todas as **sete** áreas com cultivo de *Cannabis* no ortomosaico Orocó B04-2017 e **dez** das onze áreas existentes no ortomosaico Ibó 07-2017, enquanto o SCP encontrou **cinco** e **nove**, respectivamente.

No que se refere à classificação das 8.099 imagens brutas, adquiridas por meio das RPAs, considerando as métricas avaliadas, o algoritmo de AM associado à classificação visual atingiu os seguintes resultados, após os três níveis implementados:

Tabela 8 – Resultados das métricas avaliadas.

Nível	Métrica		
	Precisão	Recall	F1score
1	3,17%	79,41%	0,06
2	100,00%	79,41%	0,89
3	100,00%	94,12%	0,97

Fonte: o autor, 2020.

O exame dos resultados da classificação por aprendizado de máquinas revelou que o algoritmo utilizado na classificação cometeu erros de omissão na classificação das áreas onde: as covas de *Cannabis* estavam irregularmente espaçadas; havia indivíduos jovens misturados com plantas maduras; e a vegetação nativa ou plantas adultas de *Cannabis* recobriam a maior parte do solo entre fileiras e linhas de covas.

Os resultados alcançados com o Nível 1 não são satisfatórios para se manter exclusivamente essa classificação, tendo em vista o número de Falsos Positivos

remanescente na base de dados, tornando dispendiosos os trabalhos de erradicação de lavouras ilícitas, diante do elevado custo relacionado ao deslocamento de equipes para erradicar culturas ilícitas inexistentes.

Entretanto, o primeiro nível mostra-se de fundamental importância para a implementação do Nível 2, por reduzir em 89,47% a quantidade de imagens a serem avaliadas manualmente, ao selecionar 853 imagens de um total de 8.099.

Além disso, salienta-se que apenas cinco cultivos não foram identificados pelo classificador de AM. Destes plantios, três eram formados por espécimes em estágio inicial do ciclo de vida, ou seja, eram da Classe 5 das imagens de treinamento que possui apenas 668 segmentos, enquanto as demais classes possuem mais de 1.500 imagens cada uma. Já os outros dois cultivos, que correspondem às figuras 22 e 23, também não foram detectados pela classificação visual, devido ao reduzido tamanho das plantas de *Cannabis*.

O Nível 2 de classificação possibilitou a exclusão de todos os Falsos Positivos, elevando a precisão para 100%. Apesar de ainda restarem dois cultivos não identificados, os dados conseguidos são adequados ao planejamento de campanhas de erradicação de cultivos ilícitos sem desperdício de recursos, uma vez que haverá baixa ocorrência de Falsos Positivos e os falsos negativos, além de serem de lavouras iniciais, são passíveis de ser visualizados durante os trabalhos operacionais.

Ressalta-se, no entanto, que a base de dados de treinamento da rede neural convolucional pode ser aprimorada a cada nova campanha de erradicação, com a inserção de novas imagens, objetivando cobrir as mais diversas situações de ocorrência dos plantios ilícitos, no que se refere à distribuição espacial, à camuflagem e ao estágio de crescimento das plantas.

REFERÊNCIAS

- AGISOFT LLC. **Agisoft Metashape User Manual**. [S.l.]: [s.n.], 2019. 145 p. Disponível em: <<https://www.agisoft.com/downloads/user-manuals/>>. Acesso em: 01 set. 2019.
- AGOSTINI, M. A. V. **Parecer Técnico 001/2015-UTEC/DPF/JZO/BA**. Departamento de Polícia Federal. Juazeiro, p. 7. 2015.
- AYAZ, Y. et al. Selection of unmanned aerial system (UAS) for disaster relief operations: a comparison. **Science International**, v. 27, n. 4, julho 2015. 3199-3203. Disponível em: <<http://www.sci-int.com/pdf/636912058836056825.pdf>>. Acesso em: 25 nov. 2019.
- AZARIA, I.; GOLDSCHLEGER, N.; BEN-DOR, E. Identification of Cannabis Plantations Using Hyperspectral Technology. **Israel Journal of Plant Sciences**, v. 60, n. 1-2, 18 maio 2012. 77-83. Disponível em: <<https://www.journals.elsevier.com/computers-and-electronics-in-agriculture>>. Acesso em: 10 nov. 2018.
- BARESSEL, J. P. et al. Use of a digital camera as alternative method for non-destructive detection of the leaf chlorophyll content and the nitrogen nutrition status in wheat. **Computers and Electronics in Agriculture**, v. 140, n. 1, 26 maio 2017. 25-33. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169916309930>>. Acesso em: 01 jun. 2018.
- BIGS - BRANDENBURG INSTITUTE. Unmanned aircraft systems for civilian missions. **Policy Paper**, Brandemburgo, v. 1, n. 1, 1 fevereiro 2012. 4-27. Disponível em: <<https://www.bigs-potsdam.org/index.php/en/publications/policy-paper>>. Acesso em: 25 nov. 2018.
- BOMFIM, E. D. M. O homem no Vale do São Francisco: um legado de Doinald Pierson às ciências humanas e sociais no Brasil. **Psicologia & Sociedade**, Porto Alegre, v. 18, p. 81-85, 2006. ISSN ISSN 0102-7182. Disponível em: <<http://www.scielo.br/pdf/psoc/v18n1/a11v18n1.pdf>>. Acesso em: 6 Outubro 2018.
- BRANDÃO, M. D. Ciclos de atenção à maconha no Brasil. **Revista da Biologia**, São Paulo, v. 13, n. 1, p. 67, dezembro 2014. Disponível em: <<http://www.revistas.usp.br/revbiologia/article/view/109127/107632>>. Acesso em: 20 out. 2018.
- BRASIL. Constituição da República Federativa do Brasil. **Presidência da República**, Brasília, 1988. Disponível em: <http://www.planalto.gov.br/ccivil_03/Constituicao/ConstituicaoCompilado.htm>. Acesso em: 20 outubro 2018.

BRASIL. Presidência da República, 2006. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/l11343.htm>. Acesso em: 15 jan. 2019.

BRASIL. Agência Nacional da Aviação Civil. **Requisitos Gerais para Aeronaves não Tripuladas de Uso Civil**, Brasília, 3 maio 2017. Disponível em: <http://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94-emd-00/@@display-file/arquivo_norma/RBACE94EMD00.pdf>.

BRASIL. Decreto-Lei nº 891, de 25 de novembro de 1938. Aprova a lei de fiscalização de entorpecentes. **Câmara do Deputados**, Rio de Janeiro. Disponível em: <<https://www2.camara.leg.br/legin/fed/declei/1930-1939/decreto-lei-891-25-novembro-1938-349873-publicacaooriginal-1-pe.html>>. Acesso em: 30 jun. 2018.

BRASIL. Lei nº 11.343, de 23 de agosto de 2006. Institui o Sistema Nacional de Políticas Públicas sobre Drogas - Sisnad. **Presidência da República**, Brasília. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/l11343.htm>. Acesso em: 01 nov. 2018.

BRASIL. Lei nº 8.257, de 31 de dezembro de 1938. Aprova a Lei de fiscalização de entorpecentes. **Presidência da República**, Brasília. Disponível em: <http://www.planalto.gov.br/ccivil_03/Leis/L8257.htm>. Acesso em: 26 novembro 2018.

BRASIL. RBAC-94E, de 03 de janeiro de 2019. Aeronaves Não Tripuladas e o Acesso ao Espaço Aéreo Brasileiro. **DEPARTAMENTO DE CONTROLE DO ESPAÇO AÉREO**, Rio de Janeiro. Disponível em: <<https://publicacoes.decea.gov.br/?i=publicacao&id=4944>>. Acesso em: 16 novembro 2019.

BRASINGTON, J. et al. 'Structure-from-Motion' photogrammetry: A low-cost, effective tool for geoscience applications. **Geomorphology**, v. 1, n. 179, 6 setembro 2012. 300-3014. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0169555X12004217?via%3Dihub>>. Acesso em: 27 jun. 2019.

BRECKENRIDGE, R. P. et al. Comparison of Unmanned Aerial Vehicle Platforms for Assessing Vegetation Cover in Sagebrush Steppe Ecosystems. **Rangeland Ecology & Management**, v. 64, n. 5, setembro 2011. 521-532. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1550742411500582?via%3Dihub>>. Acesso em: 15 ago. 2019.

CAMARGO, F. A. O. et al. A Bibliometric Analysis of Cannabis Publications: Six Decades of Research and a Gap on Studies with the Plant. **Publications**, Basel, Switzerland, 21 Setembro 2018. 11. Disponível em: <<https://www.mdpi.com/2304-6775/6/4/40>>. Acesso em: 29 setembro 2018.

CASTILLA, G.; FEDUCK, C.; MCDERMID, G. J. Detection of coniferous seedlings in UAV imagery. **Forest**, v. 9, n. 432, 26 Junho 2018. 1-15. Disponível em: <<https://www.mdpi.com/1999-4907/9/7/432/pdf>>. Acesso em: 13 jun. 2019.

CHANDLER, J. H.; LANE, S. N.; MICHELETTI, N. Structure from Motion (SfM) Photogrammetry, London, p. 1-12, 2015. ISSN 2047-0371. Disponível em: <<https://dspace.lboro.ac.uk/dspace-jspui/handle/2134/17493>>. Acesso em: 15 mar. 2019.

CHERNEY, J. H.; SMALL, E. Industrial hemp in North America: production, politics and potencial. **Agronomy**, v. 6, n. 58, 12 novembro 2016. 24. Disponível em: <<https://www.mdpi.com/2073-4395/6/4/58/pdf>>. Acesso em: 28 set. 2019.

CHIEN, J.; PETERS, J. Contemporary routes of Cannabis consumption: a primer for clinicians, Chicago, v. 118, n. 2, fevereiro 2018. 67-70. Disponível em: <<https://jaoa.org/article.aspx?articleid=2671435>>. Acesso em: 15 nov. 2018.

COHEN, M. **Tudo Sobre Drogas - Maconha**. 1. ed. São Paulo: Nova Cultura, v. 1, 1988. 70 p.

CONGEDO, L. **Semi-Automatic Classification Plugin Documentation**. 6. ed. Rome: [s.n.], v. 1, 2018. 202 p. Disponível em: <https://www.researchgate.net/profile/Luca_Congedo/publication/307593091_Semi-Automatic_Classification_Plugin_Documentation_Release_6011/links/5a7f08314585154d57d72e53/Semi-Automatic-Classification-Plugin-Documentation-Release-6011.pdf?_sg%5B0%5D=6OBwbL8Yw>. Acesso em: 30 maio 2019.

CREPANI, E.; DOS SANTOS, A. P.; SANTOS, J. R. Mapeamento de áreas plantadas com "Cannabis sativa" através de transparências coloridas infreavermeho (falsa-cor), São José dos Campos, p. 10, maio 1983. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/marte@80/2009/04.13.12.56/doc/506-515.pdf?ibiurl.language=pt-BR>>. Acesso em: 29 setembro 2018.

CSILLIK, O. et al. Identification of Citrus Trees from Unmanned Aerial Vehicle Imagery Using Convolutional Neural Networks. **Drones — Open Access Journal**, Basel, v. 2, n. 4, p. 1-16, 20 Novembro 2018. ISSN 2504-446X. Acesso em: 05 dezembro 2019.

DALL'ASTRA, E. et al. Unmanned Aerial Systems and DSM matching for rock glacier. **ISPRS Journal of Photogrammetry and Remote Sensing**, 127, 17 fevereiro 2017. 102-114. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0924271616304233>>. Acesso em: 15 dez. 2018.

DENG, L. et al. UAV-based multispectral remote sensing for precision agriculture: A comparison between different cameras. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 1, n. 146, 06 set. 2018. 124-136. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0924271618302533>>. Acesso em: 16 dez. 2018.

DJI. MATRICE 200 SERIES. **DJI**, 2019. Disponível em: <<https://www.dji.com/matrice-200-series?site=brandsite&from=nav>>. Acesso em: 26 maio 2019.

DÓRIA, J. R. D. C. Os Fumadores de Maconha: efeitos e males do vício. In: SANITÁRIA, S. N. D. E. **Maconha**: coletânea de trabalhos brasileiros. 2. ed. Rio de Janeiro: [s.n.], v. 1, 1958. p. 1-14. Disponível em: <https://bvsms.saude.gov.br/bvs/publicacoes/maconha_coletania_trabalhos_brasileiros_2ed.pdf>. Acesso em: 20 nov. 2018.

ESRI, E. S. R. I., 2019. Disponível em: <http://services.arcgisonline.com/ArcGis/rest/services/World_Imagery/MapServer/tile/>

FRAGA, P. C. P. A geopolítica das drogas na América Latina. **Revista em Pauta**, Rio de Janeiro, n. 19, 2007. 67-88. Disponível em: <<http://www.e-publicacoes.uerj.br/index.php/revistaempauta/article/view/187/210>>. Acesso em: 15 nov. 2018.

FRAGA, P. C. P.; IULIANELLI, J. A. S. Plantios ilícitos de ‘cannabis’ no Brasil: desigualdade, alternativa de renda e cultivo de compensação. **Dilemas - Revista de Estudos de Conflito e Controle Social**, Rio de Janeiro, v. 4, n. 1, Março 2011. 11-39. Disponível em: <<https://revistas.ufrj.br/index.php/dilemas/article/view/7205/5798>>. Acesso em: 15 nov. 2018.

FRANÇA, J. M. C. **História da Maconha no Brasil**. São Paulo: Três Estrelas, 2015.

GERON, A. **Mãos Obra Apredizado de Máquina com Scikit-Learn & TensorFlow**: Conceitos Ferramentas e Técnicas Para a Construção de Sistemas Inteligentes. Tradução de Rafael Contatori. 1. ed. Rio de Janeiro: Alta Books, 2019. ISBN 978-85-508-0381-4.

GUO, Y. et al. Radiometric Calibration for Multispectral Camera of Different Imaging Conditions Mounted on a UAV Platform. **Sustainability — Open Access Journal**, Basel, Switzerland, v. 11, 14 Fevereiro 2019. 24. Disponível em: <<https://www.mdpi.com/2071-1050/11/4/978/pdf>>. Acesso em: 10 jan. 2020.

HE, Y.; LU, B. Species classification using Unmanned Aerial Vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, 28 novembro 2016. 73-85. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0924271616305688>>. Acesso em: 20 maio 2019.

JÓZKÓW, G.; TOTH, C. Remote sensing platforms and sensors: a survey. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 115, 5 junho 2015. 22-36. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0924271615002270>>. Acesso em: 20 out. 2018.

KONG, W. et al. Localization Framework for Real-Time UAV Autonomous Landing: An On-Ground Deployed Visual Approach. **Sensors — Open Access Journal**,

Basel, v. 17, n. 6, 31 março 2017. 17. Disponível em: <<https://www.mdpi.com/1424-8220/17/6/1437/pdf>>. Acesso em: 12 nov. 2018.

KYRIAKOU, M. S.; CHRISTOU, G. A.; KOLIOS, P. S. ImportPhotos 2.2.2, 2019. Disponível em: <<https://mariosmsk.com/2019/07/02/qgis-plugin-importphotos/>>. Acesso em: 18 jul. 2019.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature - International weekly journal of science**, n. 521, p. 436-444, Maio 2015. ISSN 1476-4687. Disponível em: <<https://www.nature.com/articles/nature14539>>. Acesso em: 11 jan. 2020.

LISITA, A. Mapeamento semiautomático de cultivos ilícitos de cannabis sativa no semiárido pernambucano mediante integração de imagens SPOT 5 – HRG, dados geográficos auxiliares e conhecimento de campo, Brasília, p. 215, 1º setembro 2011. Disponível em: <http://repositorio.unb.br/bitstream/10482/11382/3/2011_AlessandraLisita.pdf>. Acesso em: 27 setembro 2018. Tese de doutorado n.º 106.

LIU, W. et al. Accurate Building Extraction from Fused DSM and UAV Images Using a Chain Fully Convolutional Neural Network. **Remote Sensing — Open Access Journal**, Basel, v. 11, n. 24, 5 Dezembro 2019. 1-18. Disponível em: <<https://www.mdpi.com/2071-1050/11/4/978/pdf>>. Acesso em: 10 jan. 2020.

LOTTE, P. et al. **UAV-Based Crop and Weed Classification for Smart Farming**. International Conference on Robotics and Automation (ICRA). Singapore: IEEE. 2017. p. 3024-3031.

LOWE, D. G. **Object Recognition from Local Scale-Invariant Features**. Proceedings of the International Conference on Computer Vision. Corfu: [s.n.]. 1999. p. 1150-1157.

MARTINS, H. T. A retaliação de Pernambuco: o caso da Comarca do rio de São Francisco. **CLIO: Revista de Pesquisa História**, Recife, v. 28, n. 2, p. 16, 2010. Disponível em: <<https://periodicos.ufpe.br/revistas/revistaclio/article/view/24216/19652>>. Acesso em: 12 ago. 2018.

MENZ, M. M. Os escravos da feitoria do linho cânhamo: trabalho, conflito e negociação. **Afro-Ásia**, Salvador, n. 32, 2005. Disponível em: <<https://portalseer.ufba.br/index.php/afroasia/article/view/21090/13681>>. Acesso em: 02 nov. 2018.

MOHAMMADI, M. E.; WATSON, D. P.; WOOD, R. L. Deep Learning-Based Damage Detection from Aerial SfM Point Clouds. **Drones — Open Access Journal**, Basel, v. 3, n. 3, p. 1-20, 27 Agosto 2019. Disponível em: <<https://www.mdpi.com/2504-446X/3/3/68/pdf>>. Acesso em: 05 jan. 2020.

MUNIZ, R. M.; FILHO, S. D. S.; DA SILVA, W. C. **Levantamento através de drone**. Departamento de Polícia Federal. Salgueiro, p. 9. 2015.

OLIVEIRA, A.; JORGE, Z.; ERNANI, R. Polígono da Maconha: contexto sócioeconômico, homicídios e atuação do Ministério Público. **Coleção Segurança com Cidadania**, 1, 2009. 175-194. Disponível em: <<https://app.uff.br/riuff/handle/1/5796>>. Acesso em: 5 agosto 2018.

ONU. **Single convention on narcotic drugs**. Organização das Nações Unidas. New York. 1961.

PERERA, G. A.; LAW, Y. W.; CHAHL, J. Drone-Action: An Outdoor Recorded Drone Video Dataset for Action Recognition. **Drones — Open Access Journal**, Besel, v. 3, n. 4, p. 1-16, 28 Novembro 2019. ISSN 2504-446X. Disponível em: <<https://www.mdpi.com/2504-446X/3/4/82/pdf>>. Acesso em: 12 maio 2019.

PERNAMBUCO, G. D. E. D. **Atlas Eólico e Solar de Pernambuco**, 29 nov. 2017. Disponível em: <<http://www.atlaseolicosolar.pe.gov.br/>>. Acesso em: 17 jun. 2019.

RONG, C. et al. Cannabidiol in medical marijuana: research vistas and potential opportunities. **Pharmacological Research**, v. 121, p. 6, julho 2017. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1043661817303559?via%3Dihub>>. Acesso em: 11 nov. 2018.

SAGAN, V. et al. UAV-Based High Resolution Thermal Imaging for Vegetation Monitoring, and Plant Phenotyping Using ICI 8640 P, FLIR Vue Pro R 640, and thermoMap Cameras. **Remote Sensing**, Basel, v. 11, n. 3, p. 1-29, 07 fev. 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/3/330>>. Acesso em: 16 jun. 2019.

SENTHILNATH, J. et al. Application of UAV imaging platform for vegetation analysis based on spectral-spatial methods. **Computers and Electronics in Agriculture**, v. 140, n. 1, 03 jun. 2017. 8-24. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169916301867?via%3Dihub>>. Acesso em: 20 ago. 2018.

SILVA, H. D. A.; NASCIMENTO, K. Reconhecimento de Cultivos Ilícitos a Partir de Imagens Capturadas por Drones (UAV). **Perícia Federal**, Brasília, v. 1, n. 44, p. 46-53, Dezembro 2019. Disponível em: <https://apcf.org.br/horus/arquivos/revistas/revista_apcf_44_web_p.pdf>. Acesso em: 07 jan. 2020.

SMALL, E. Evolution and Classification of Cannabis sativa (marijuana, hemp) in relation to human utilization. **Bot. Rev.**, 81, n. 3, setembro 2015. 189-294. Acesso em: 30 setembro 2018.

STROPPIANA, D. et al. Estimating Crop Density From Multi-Spectral UAV Imagery in Maize Crop. **Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.**, Enschede, p. 619-624, 2019. Disponível em: <https://www.researchgate.net/publication/333639435_ESTIMATING_CROP_DENSITY_FROM_MULTI-SPECTRAL_UAV_IMAGERY_IN_MAIZE_CROP/fulltext/5cf868a5a6fdcc847508a63b>

/ESTIMATING-CROP-DENSITY-FROM-MULTI-SPECTRAL-UAV-IMAGERY-IN-MAIZE-CROP.pdf?_sg%5B0%5D=O4Z-pdYz3Kcoe5L>. Acesso em: 12 maio 2019.

SUDENE, C. D. D. S. D. D. D. N. RESOLUÇÃO N ° 107/2017, de 27 de julho de 2017. Estabelece critérios técnicos e científicos para. **Sudene**, Recife. Disponível em: <<http://sudene.gov.br/images/2017/arquivos/Resolucao-107-2017.pdf>>. Acesso em: 15 out. 2018.

UNODC. Drug Prices Report, New York, p. 1, 2018. Disponível em: <https://www.unodc.org/wdr2018/prelaunch/7.2_Cannabis.xlsx>. Acesso em: 14 outubro 2018.

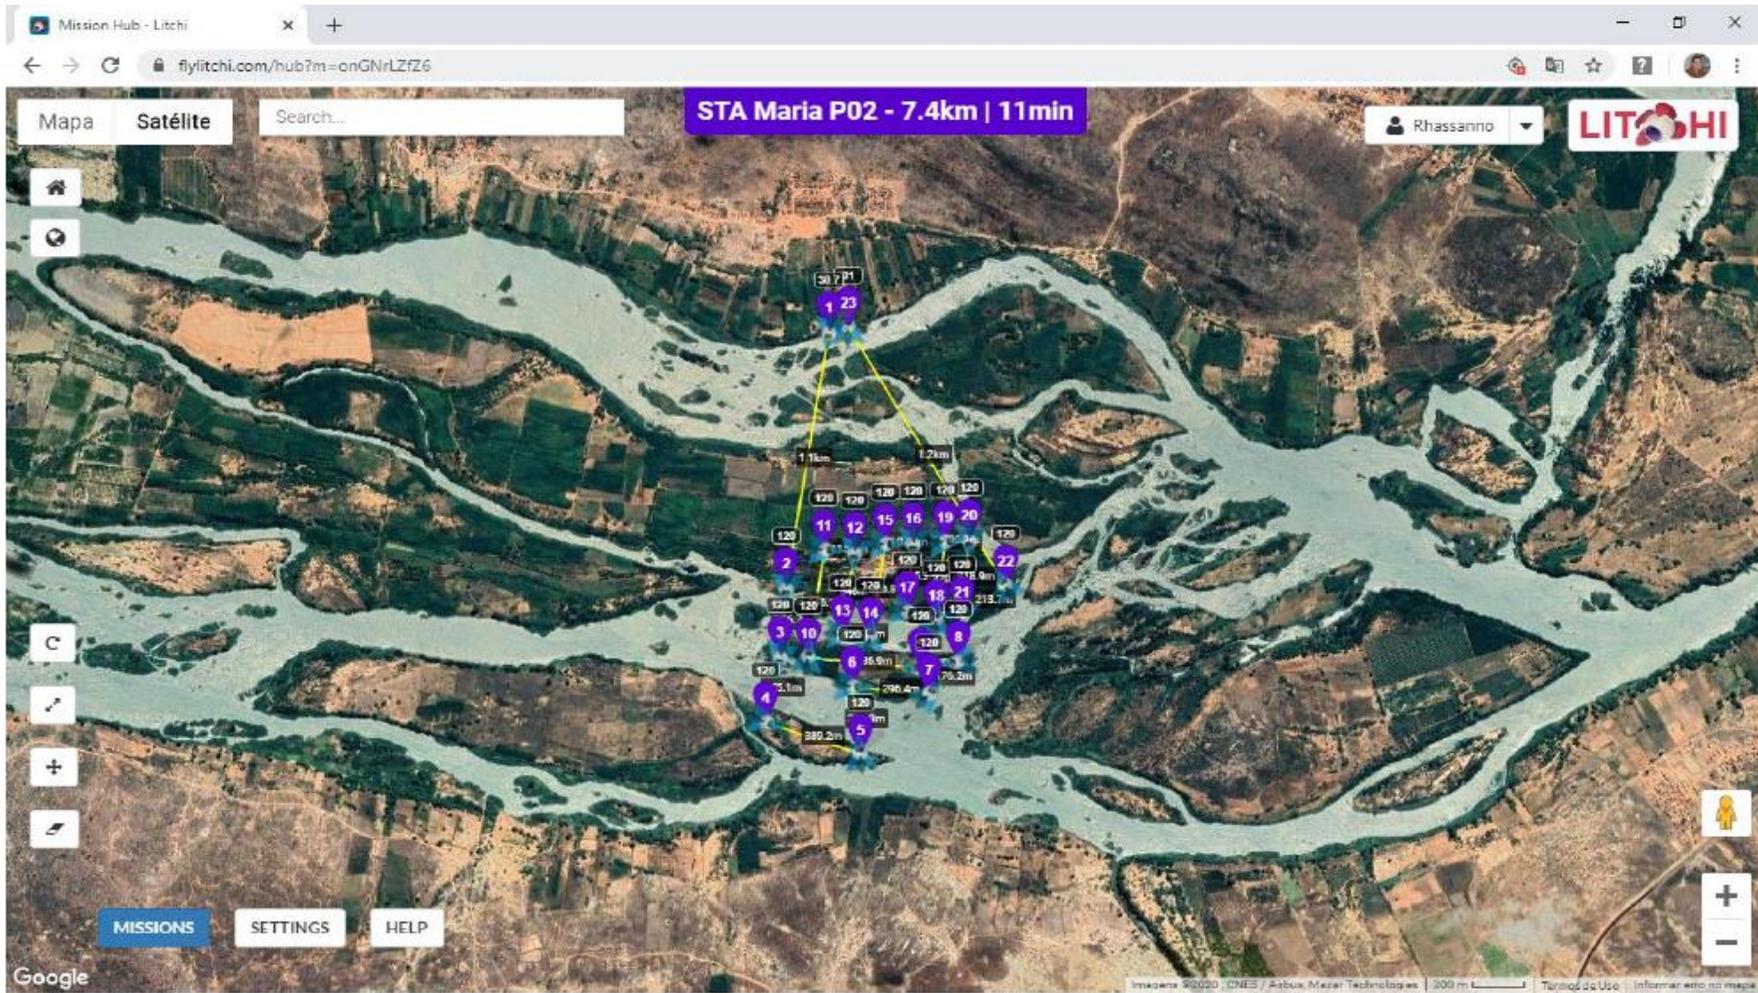
UNODC. World Drug Report 3, New York, p. 72, 2018. Disponível em: <<https://www.unodc.org/wdr2018>>. Acesso em: 14 outubro 2018.

ANEXO B – PLANOS DE VOO

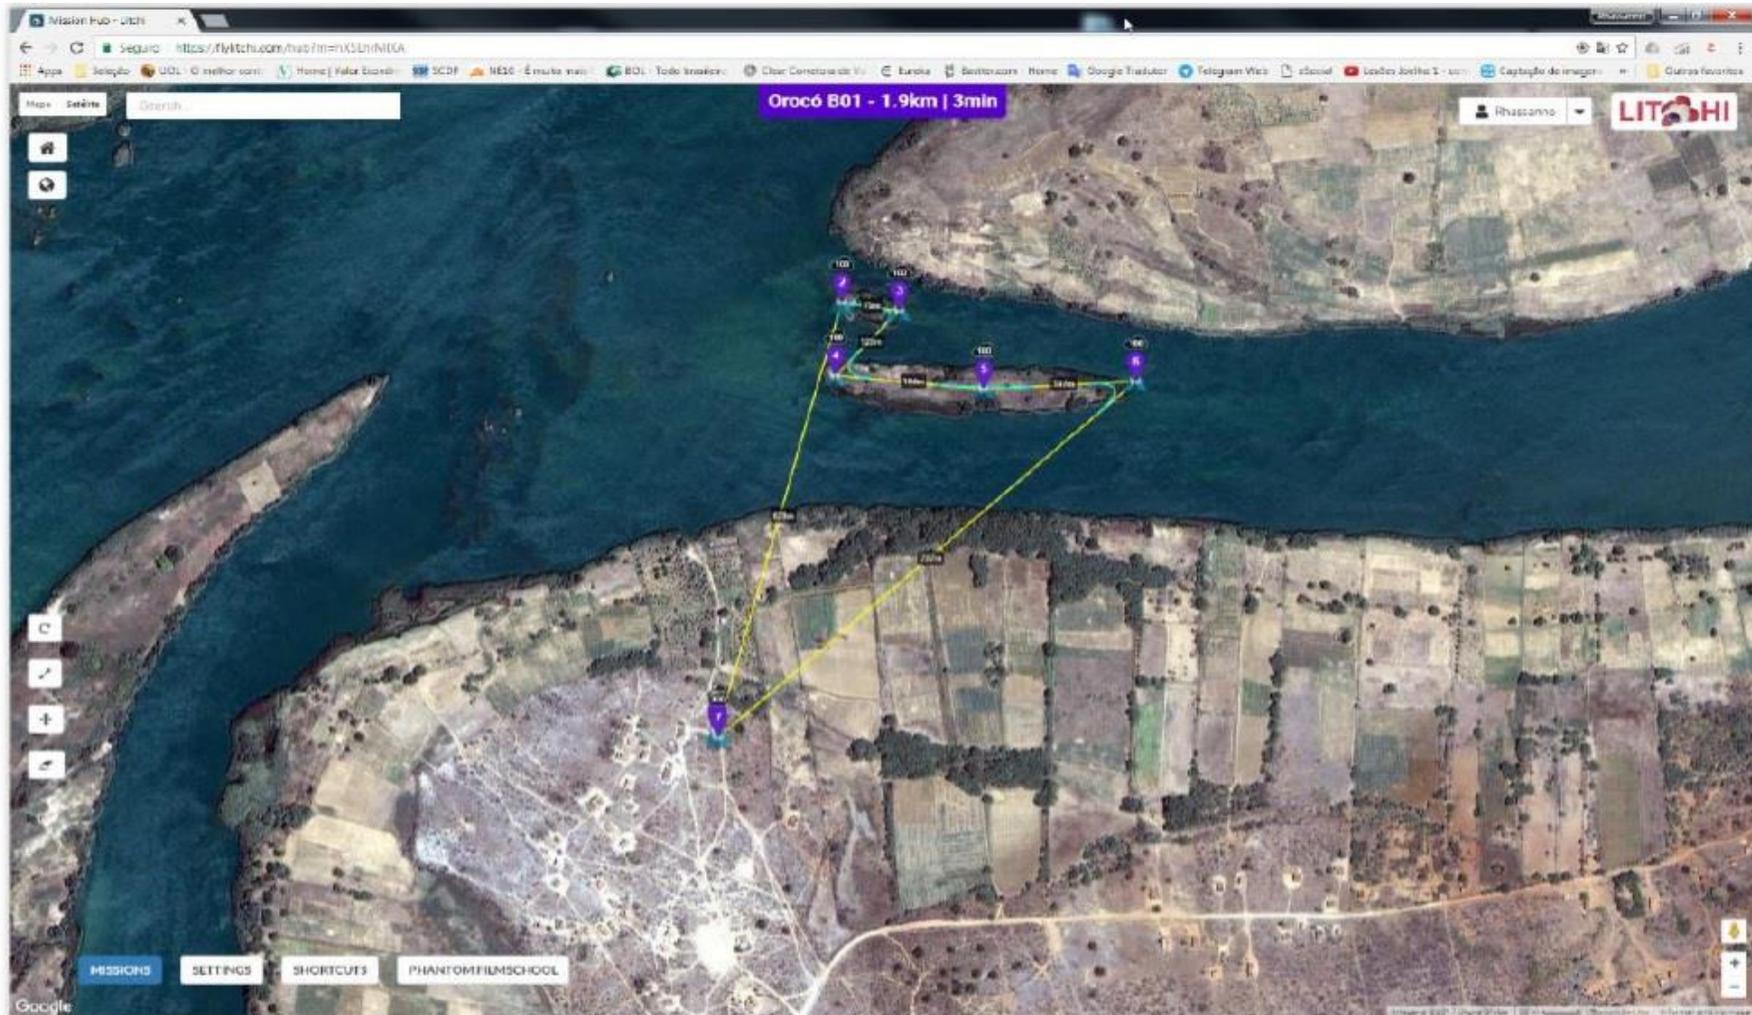
1) SM 01



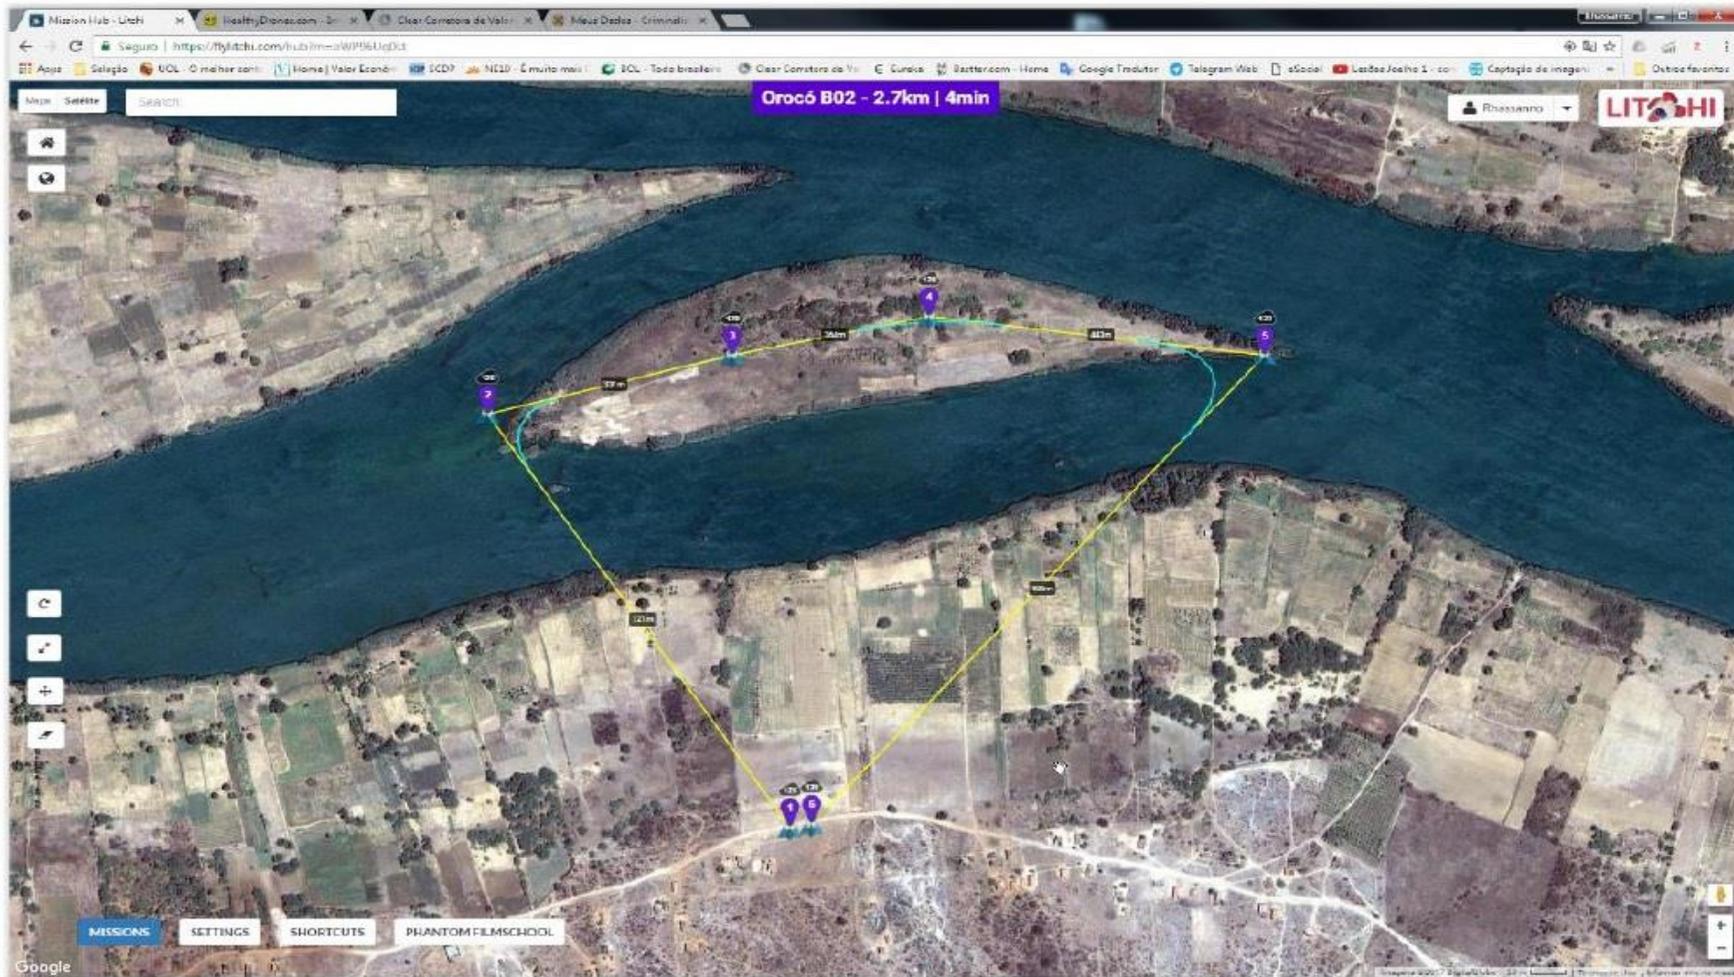
2) SM 02



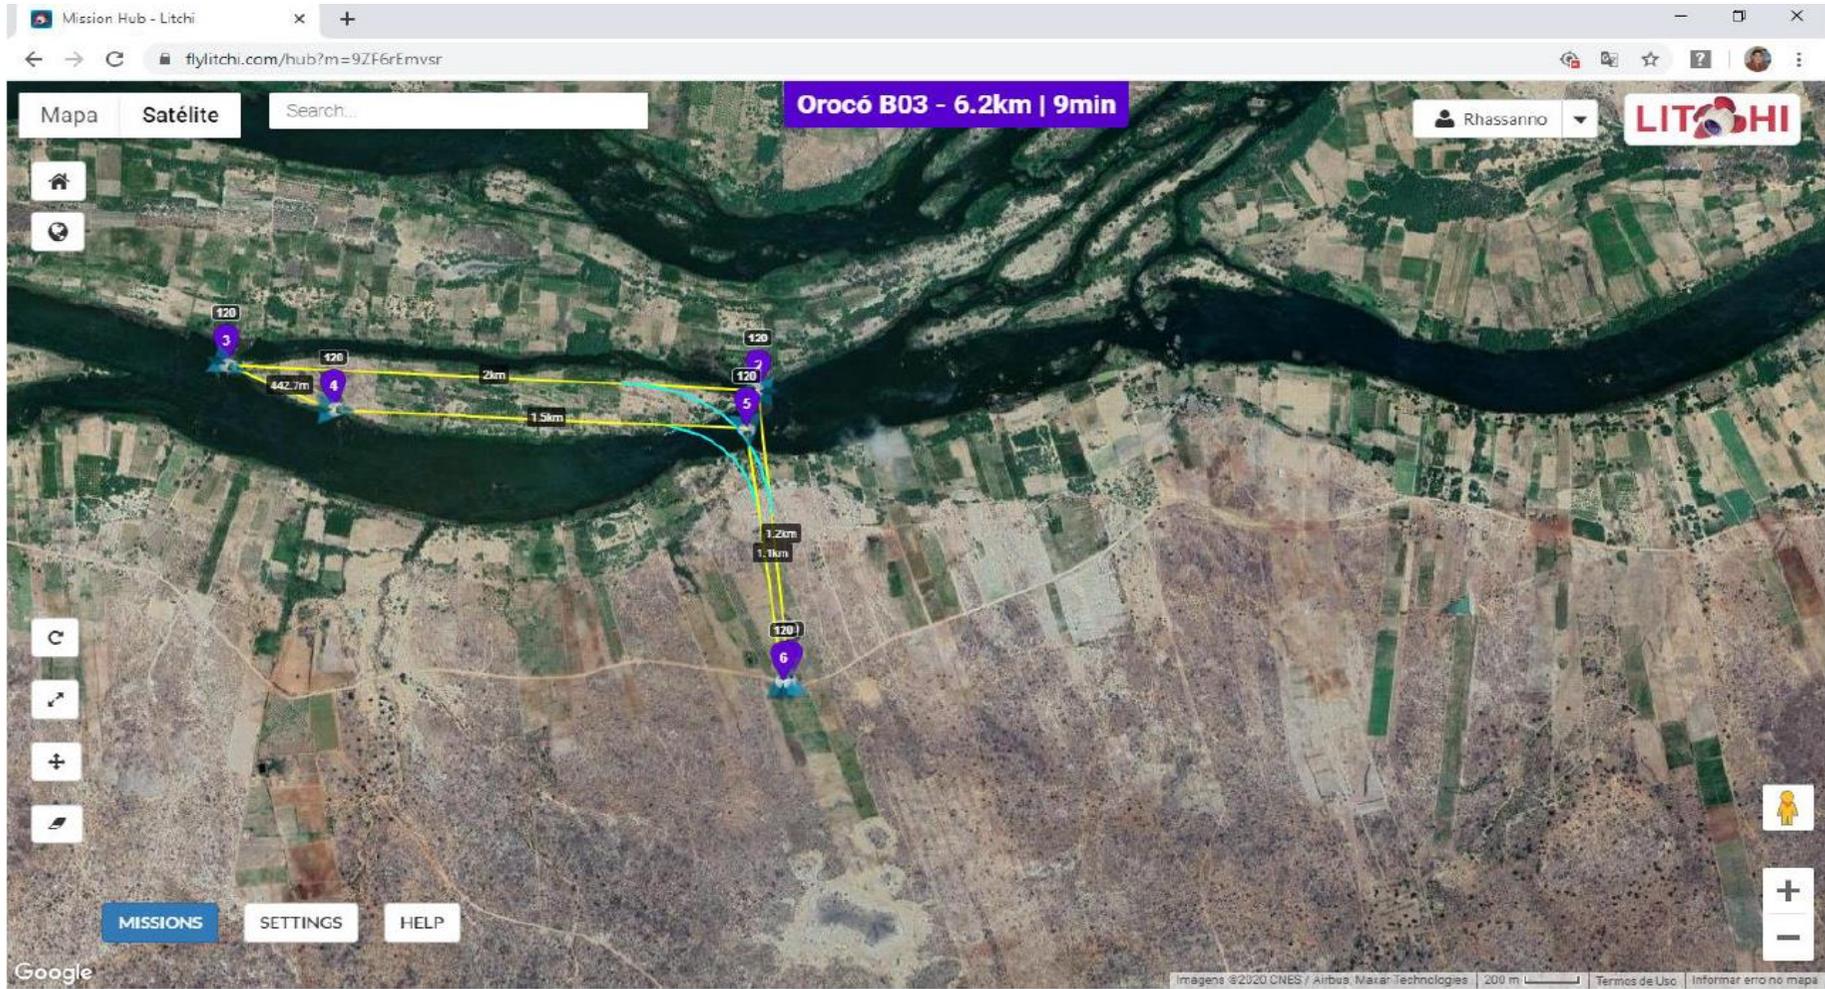
4) Orocó B01



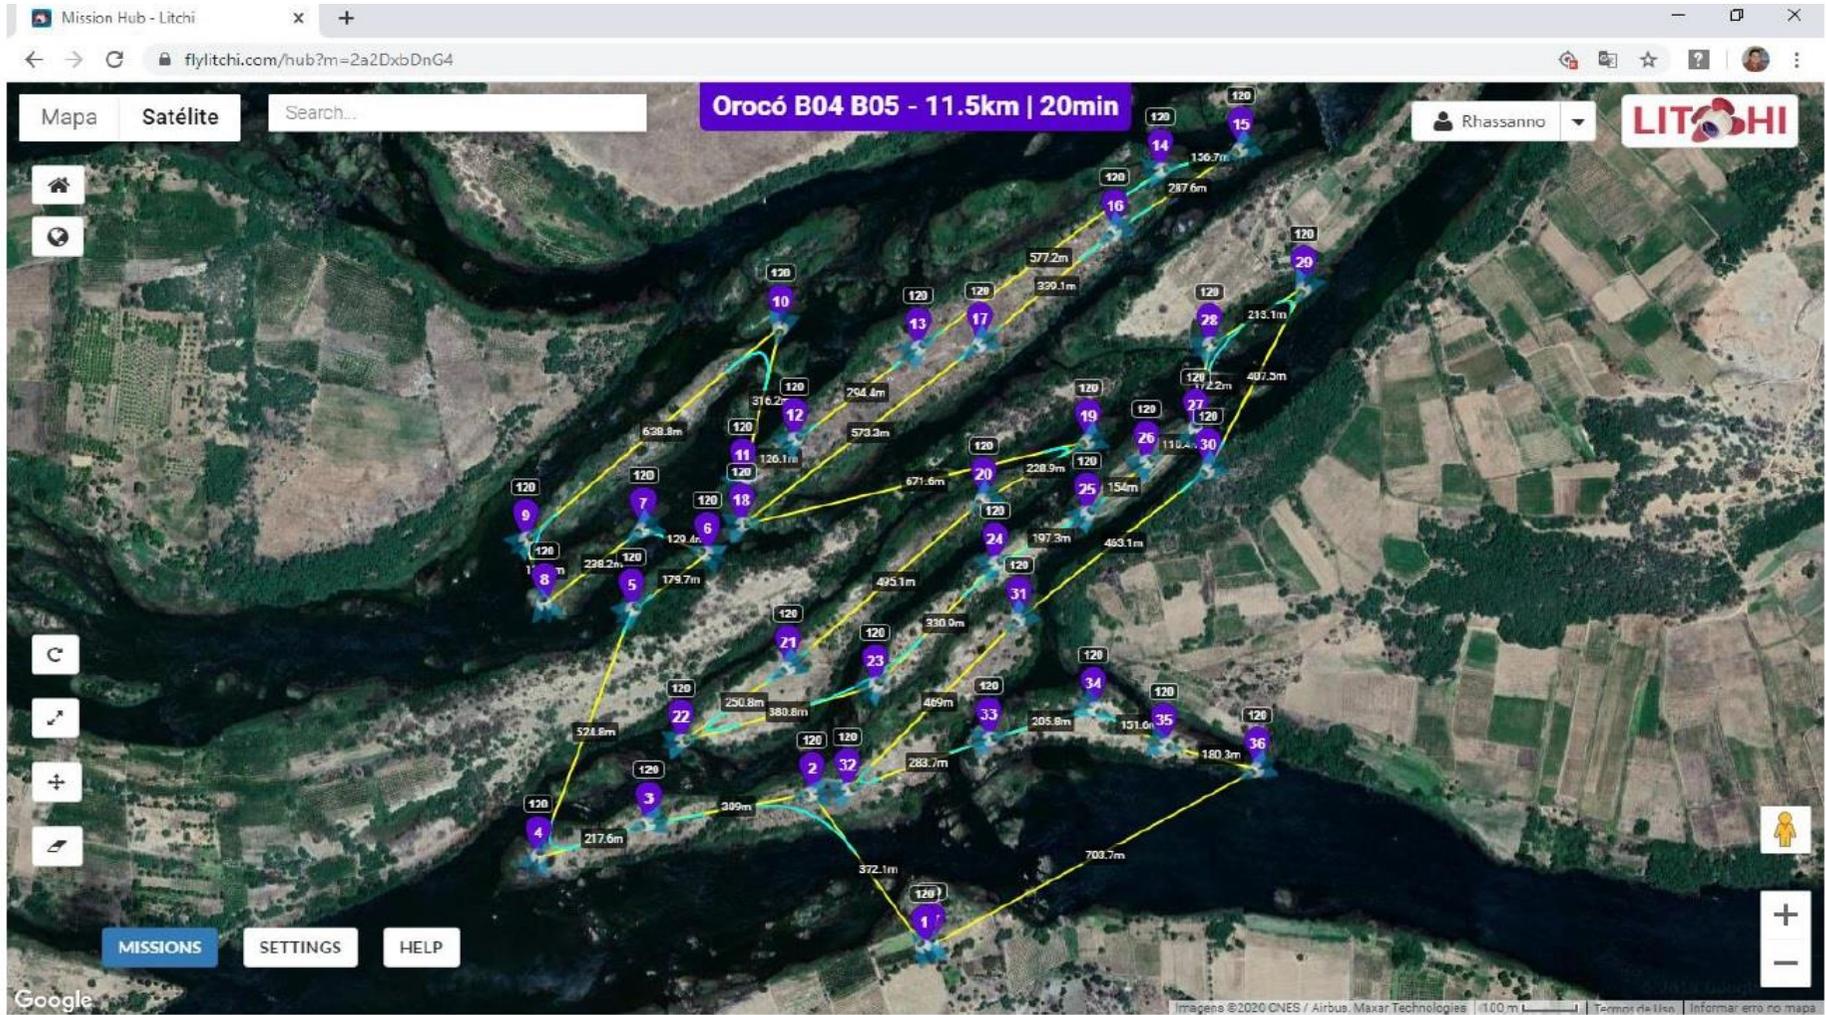
5) Orocó B02



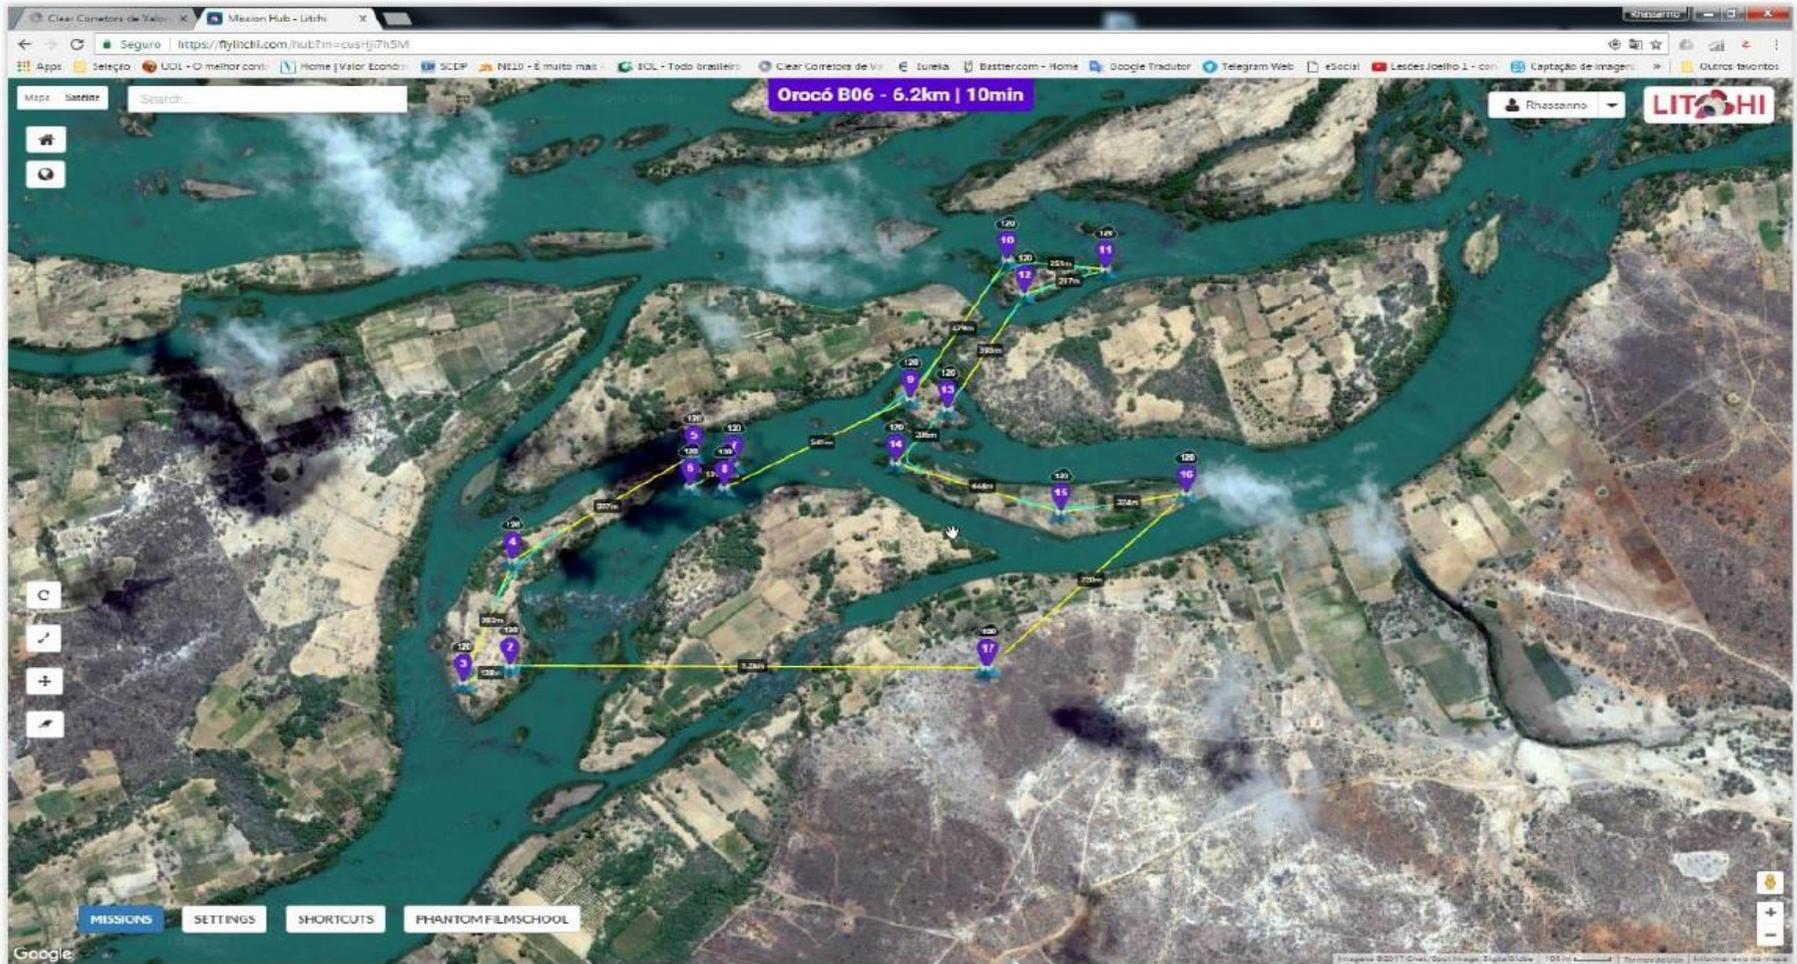
6) Orocó B03



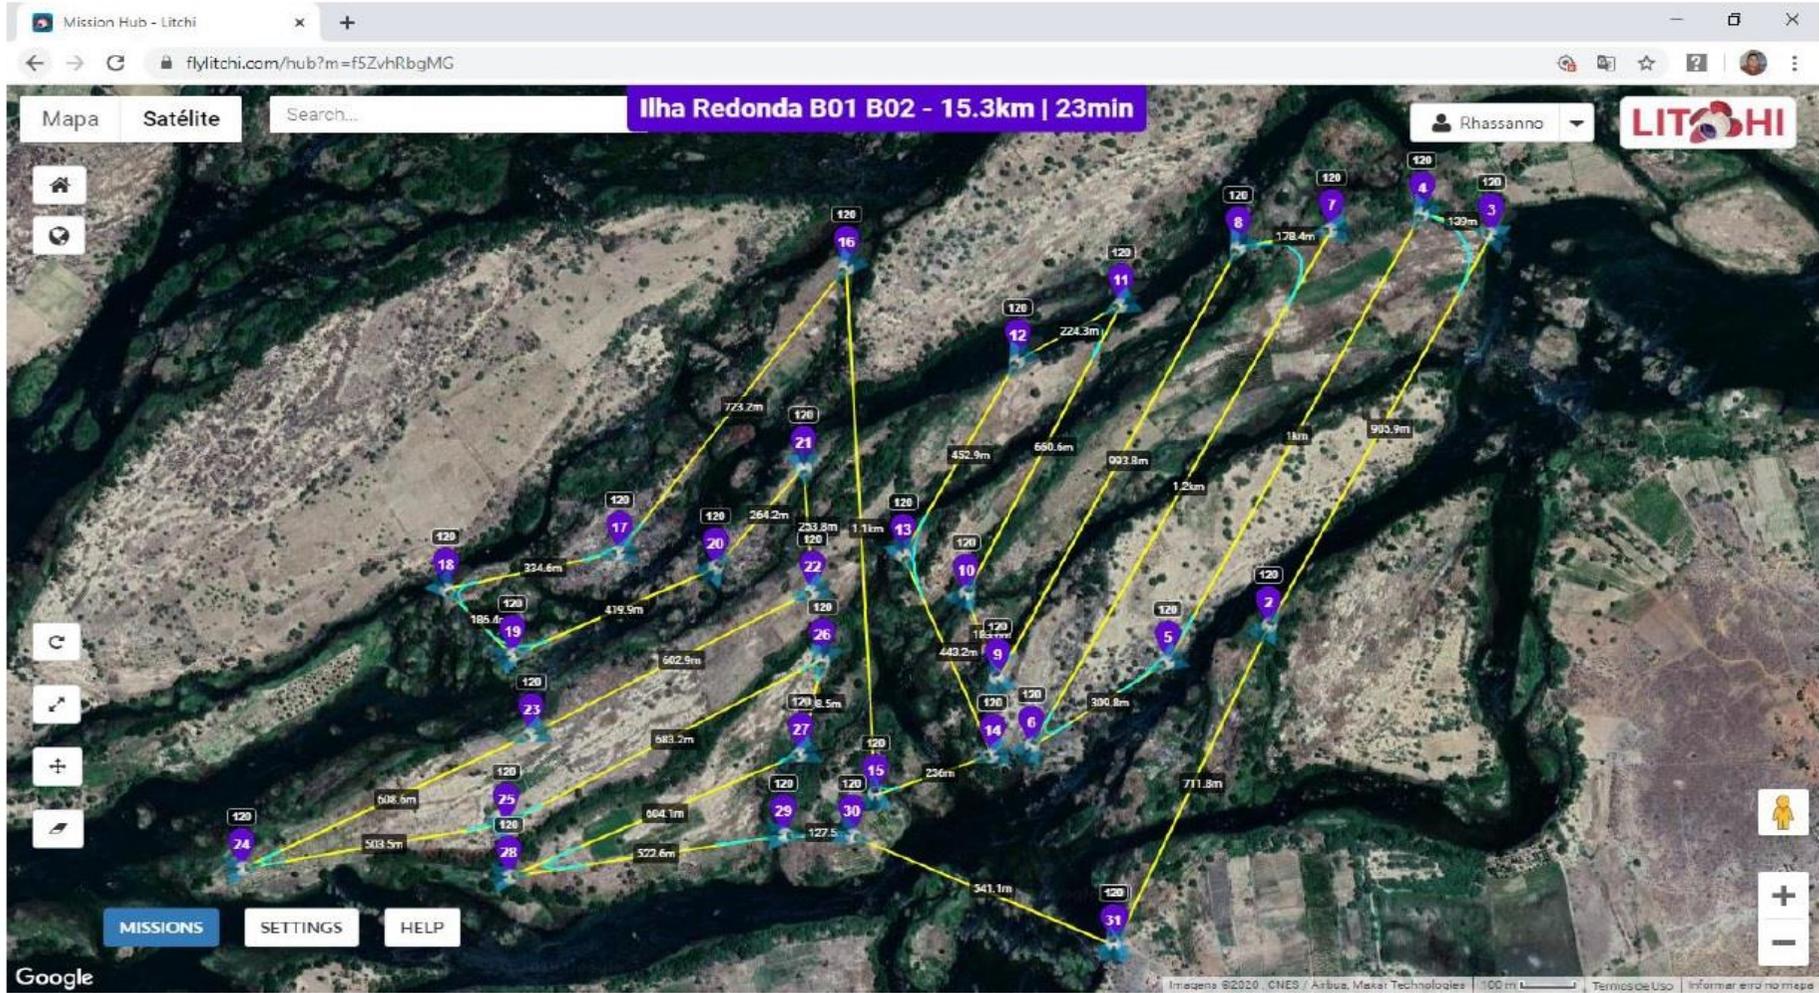
7) Orocó B04



8) Orocó B05



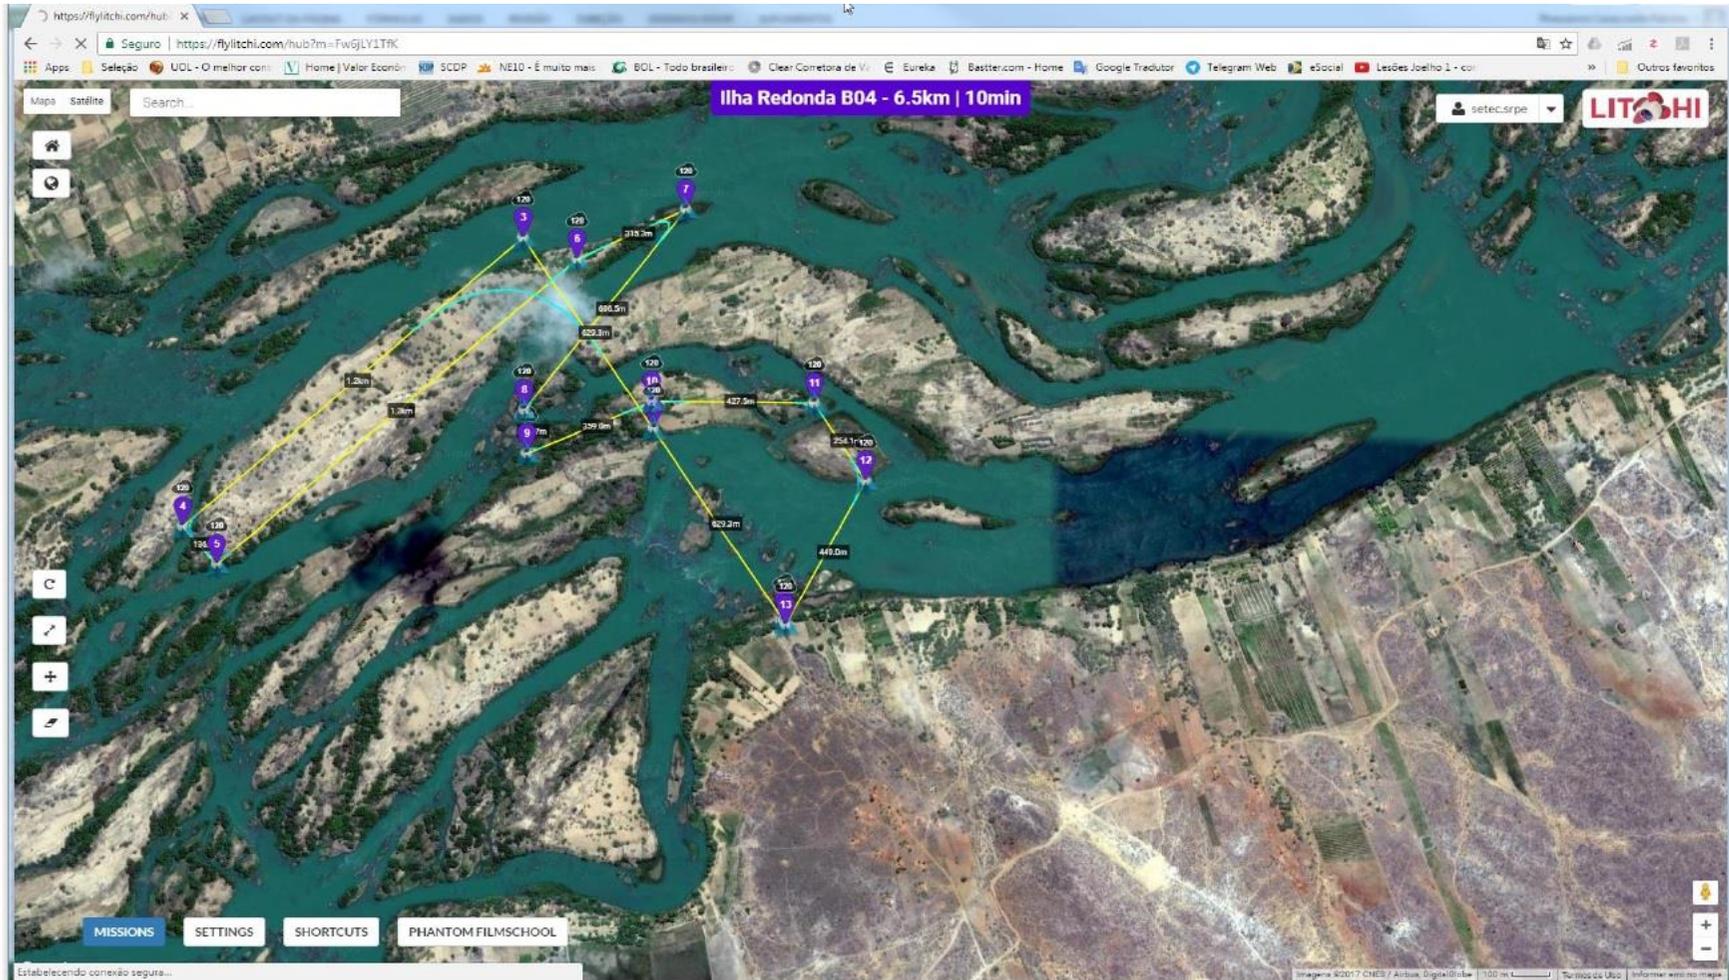
9) Ilha Redonda B01 B02



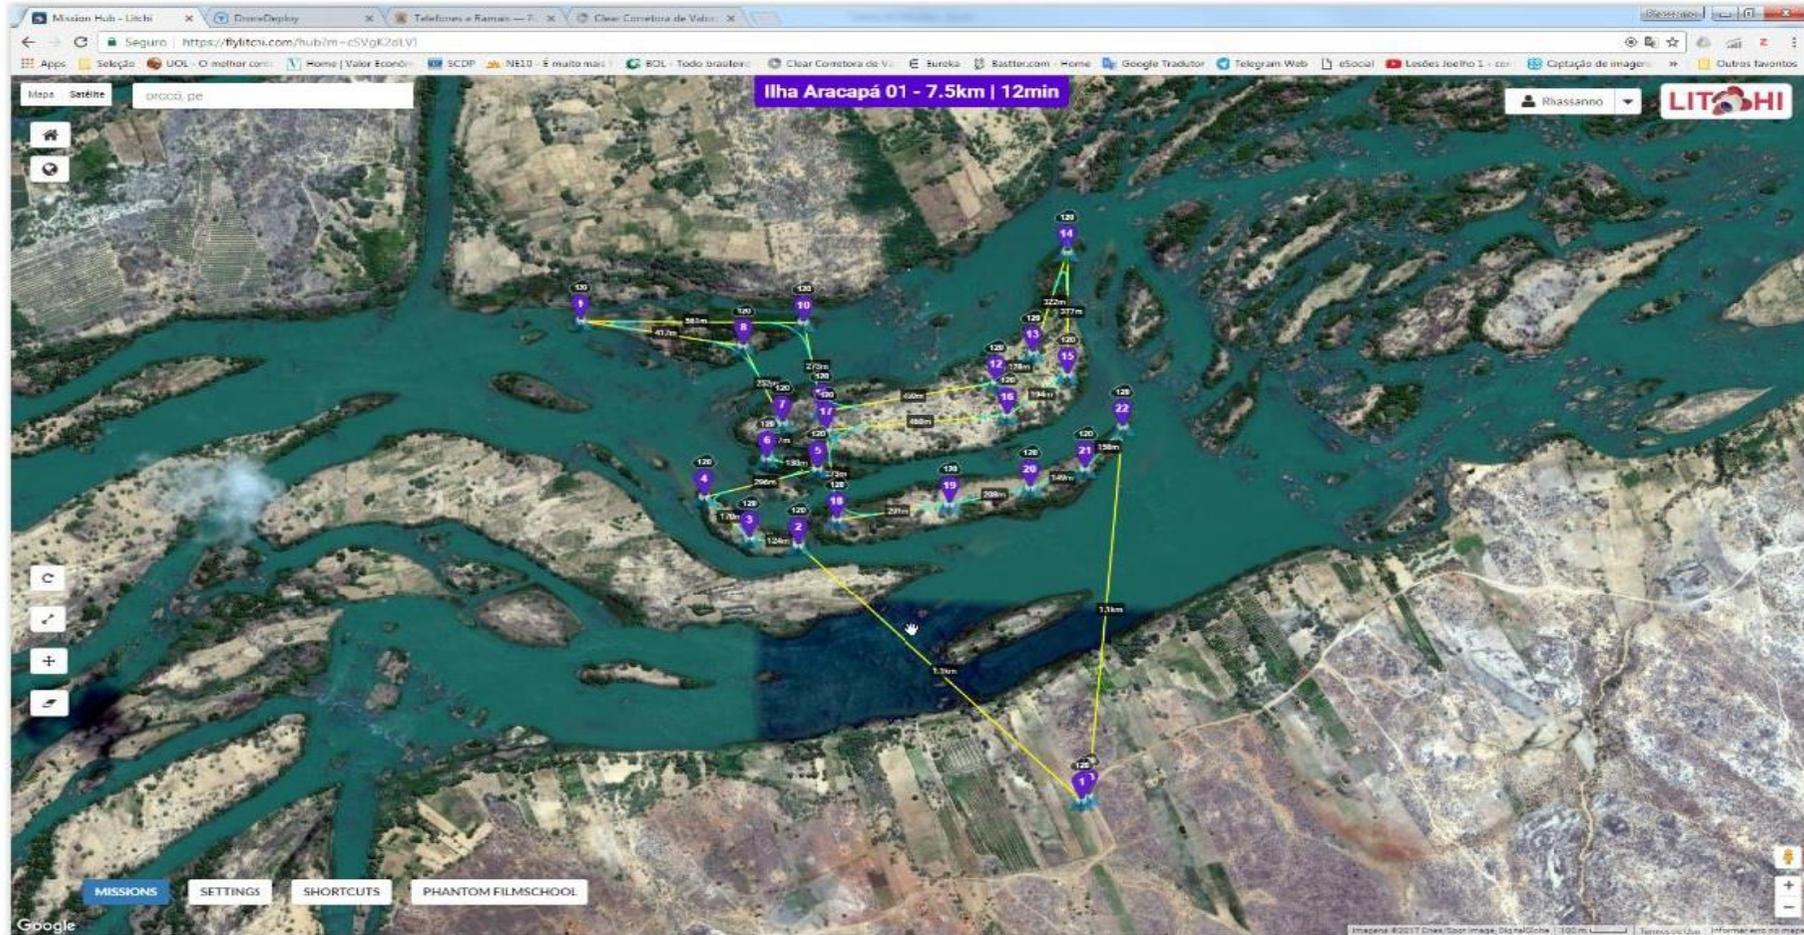
10) Ilha Redonda B03



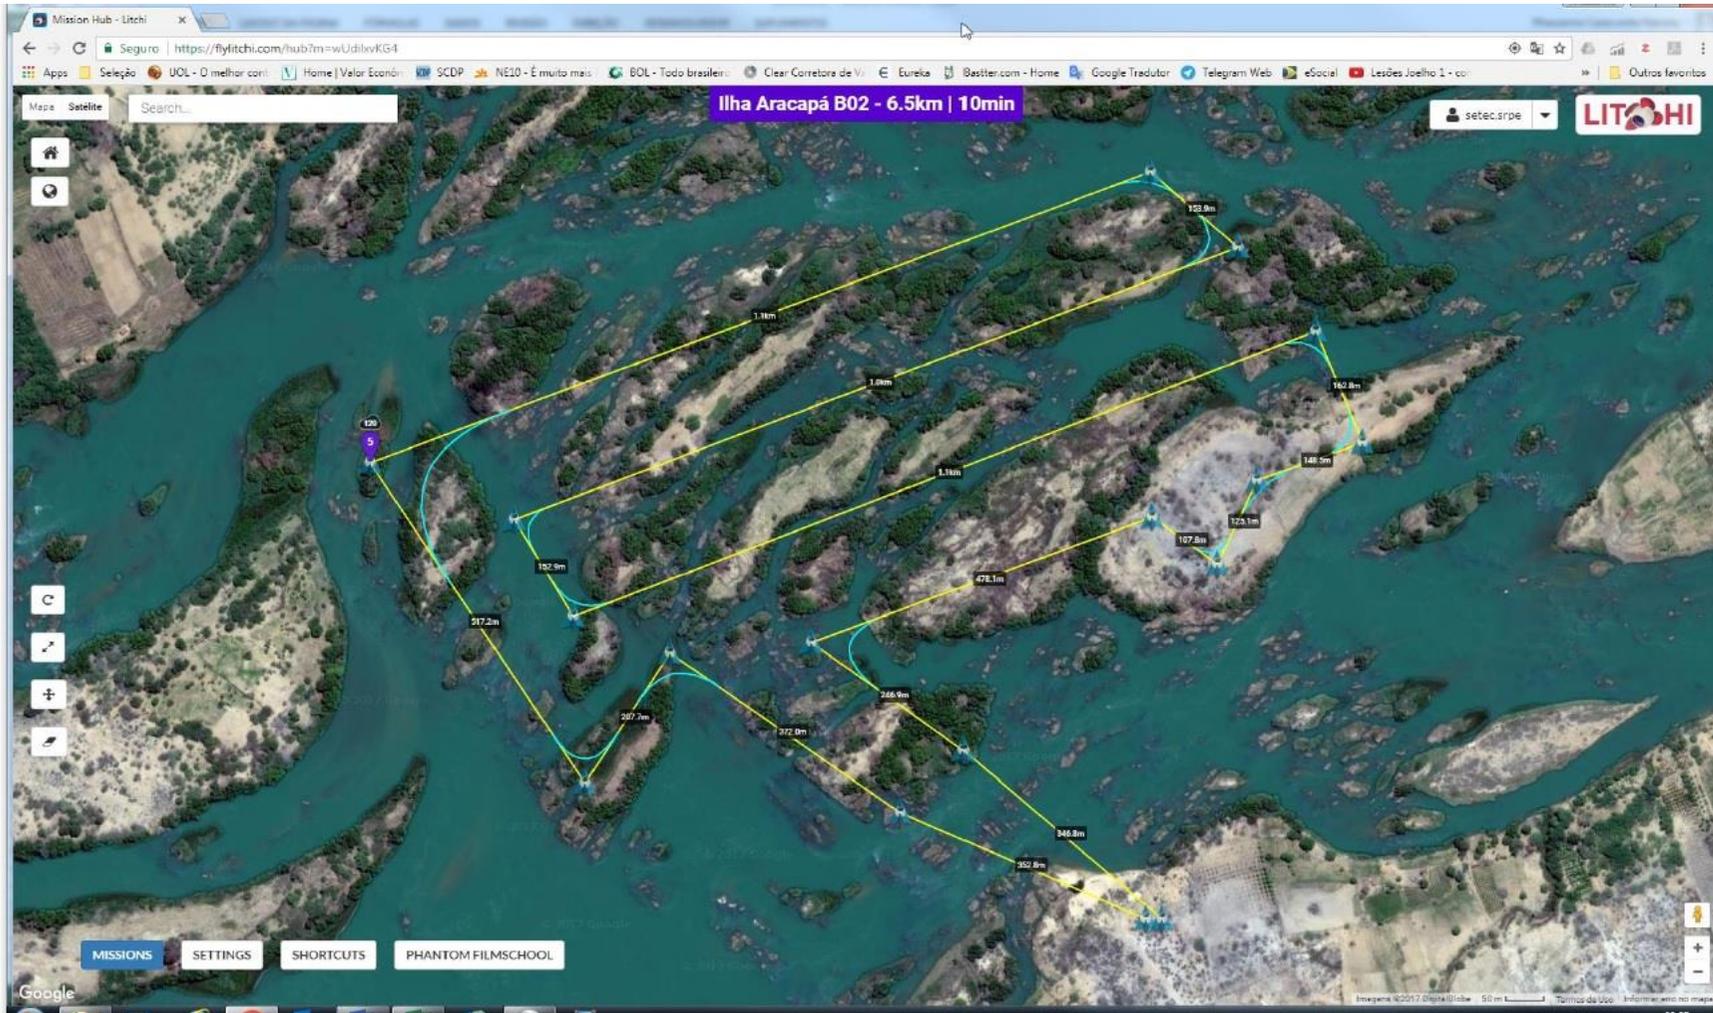
11) Ilha Redonda



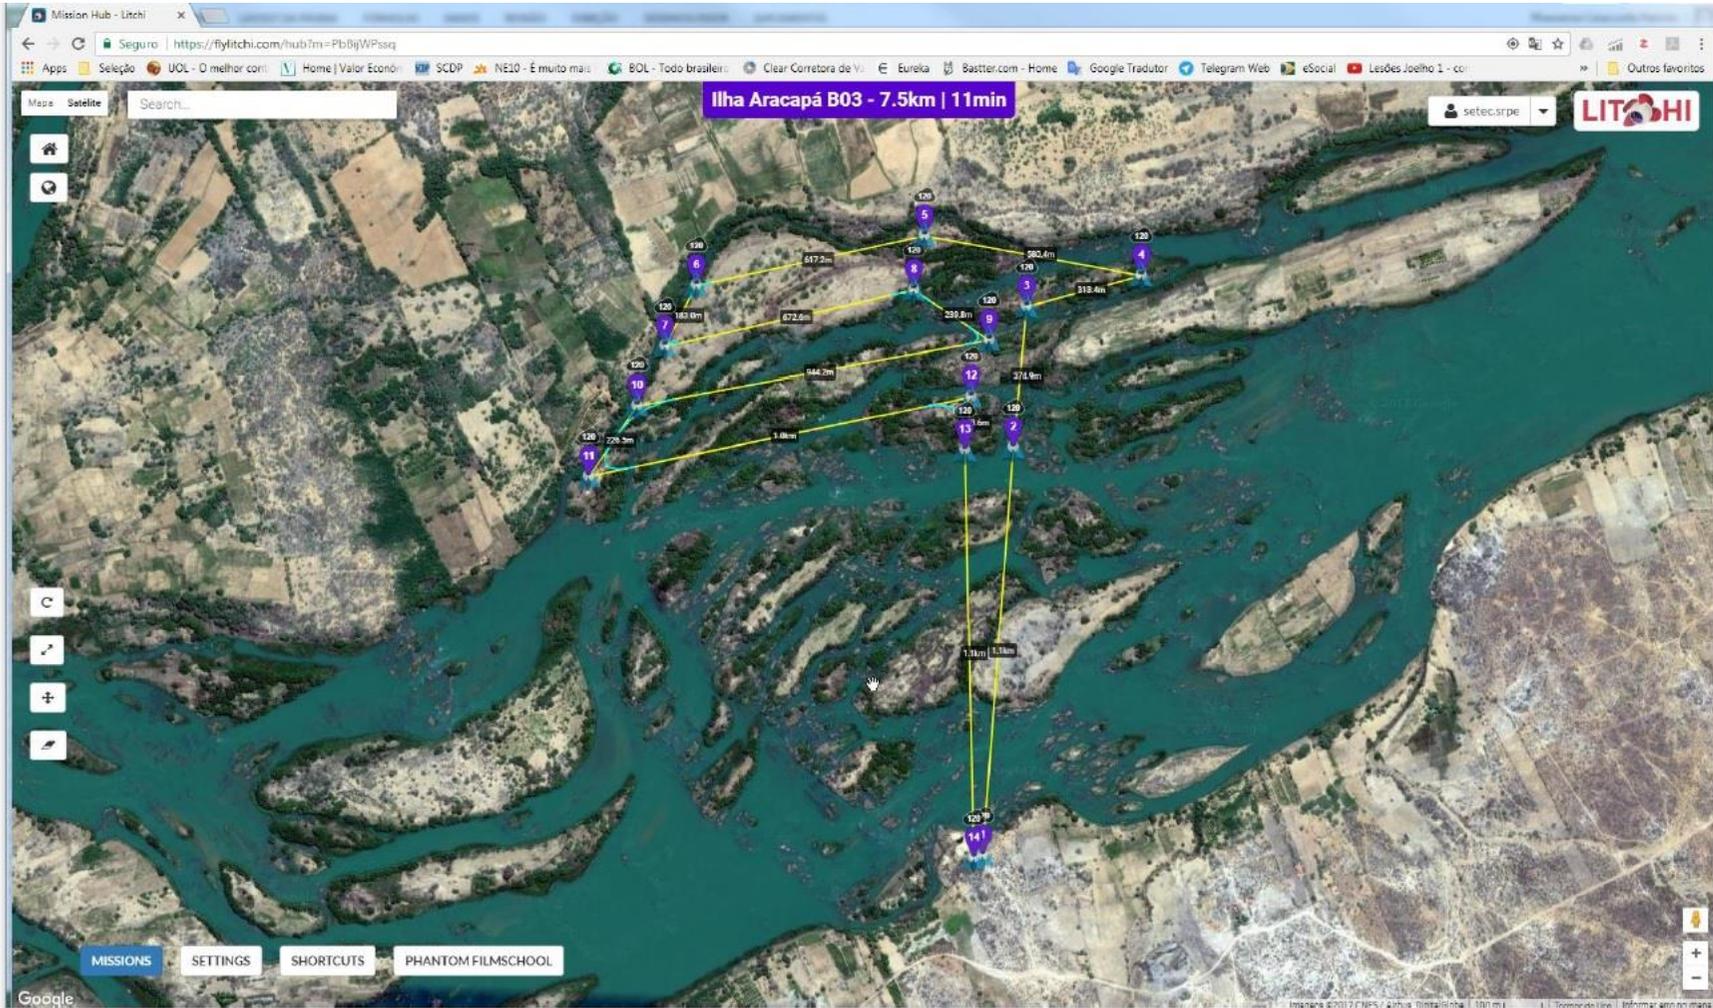
12) Ilha Aracapé



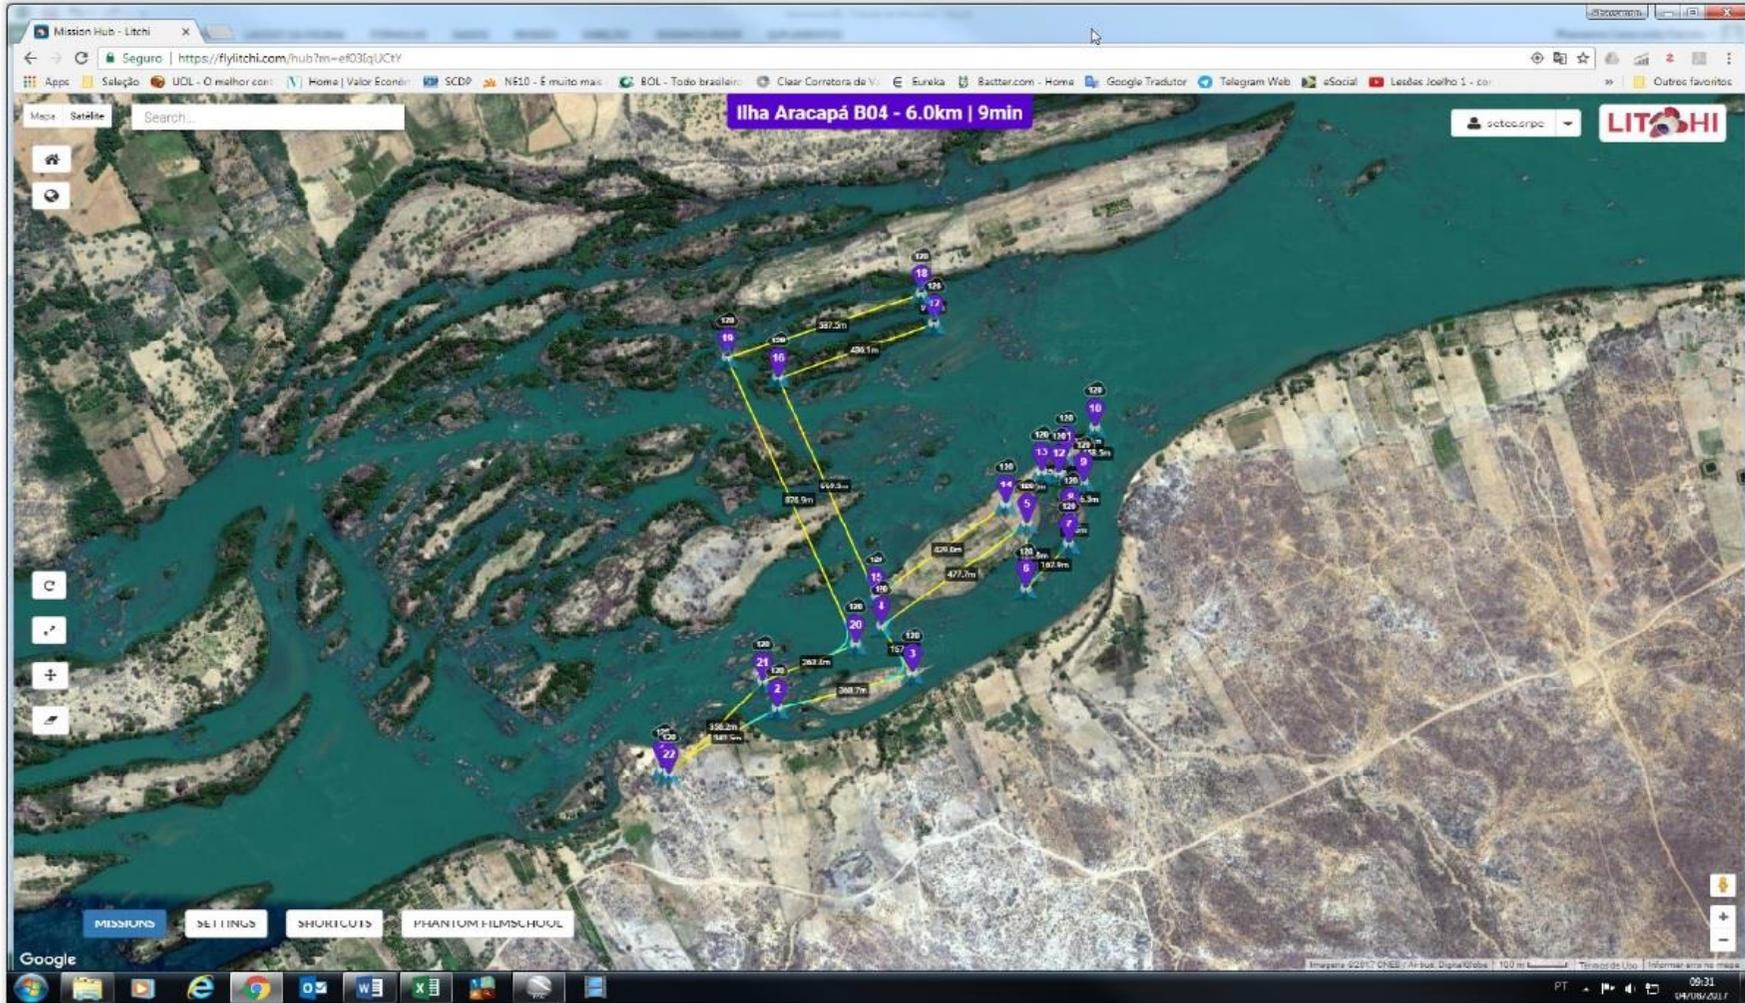
13) Ilha Aracapé B02



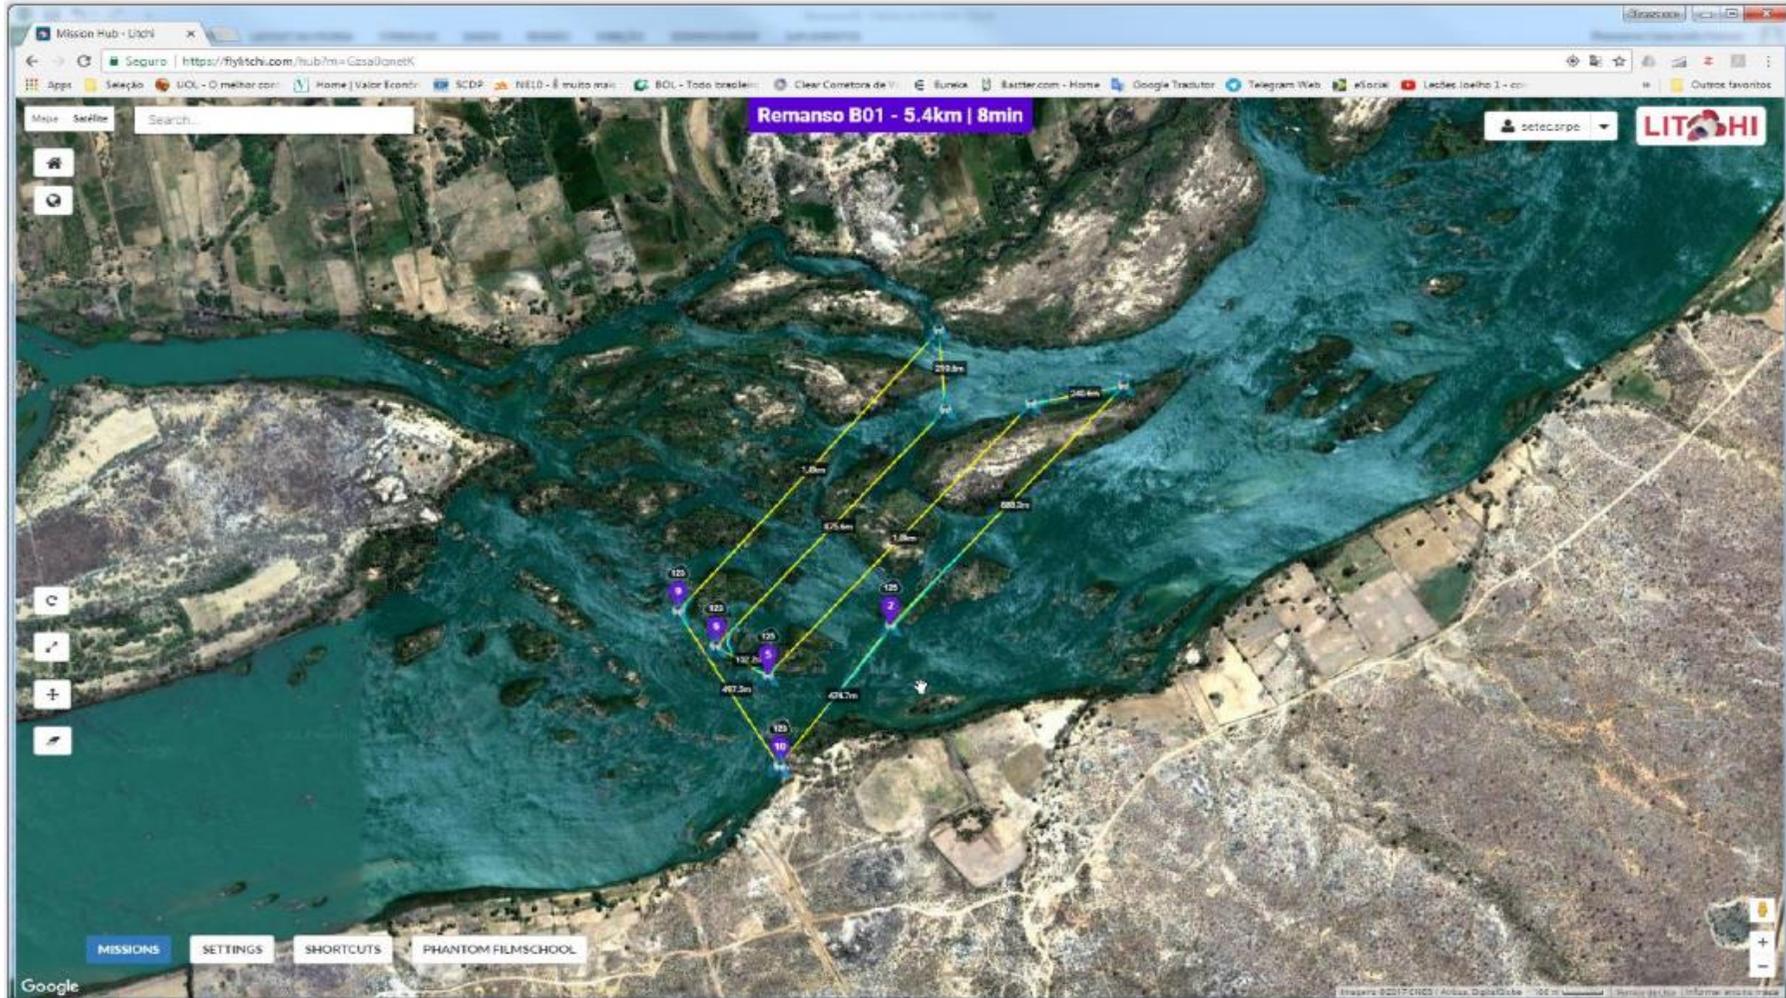
14) Ilha Aracapé B03



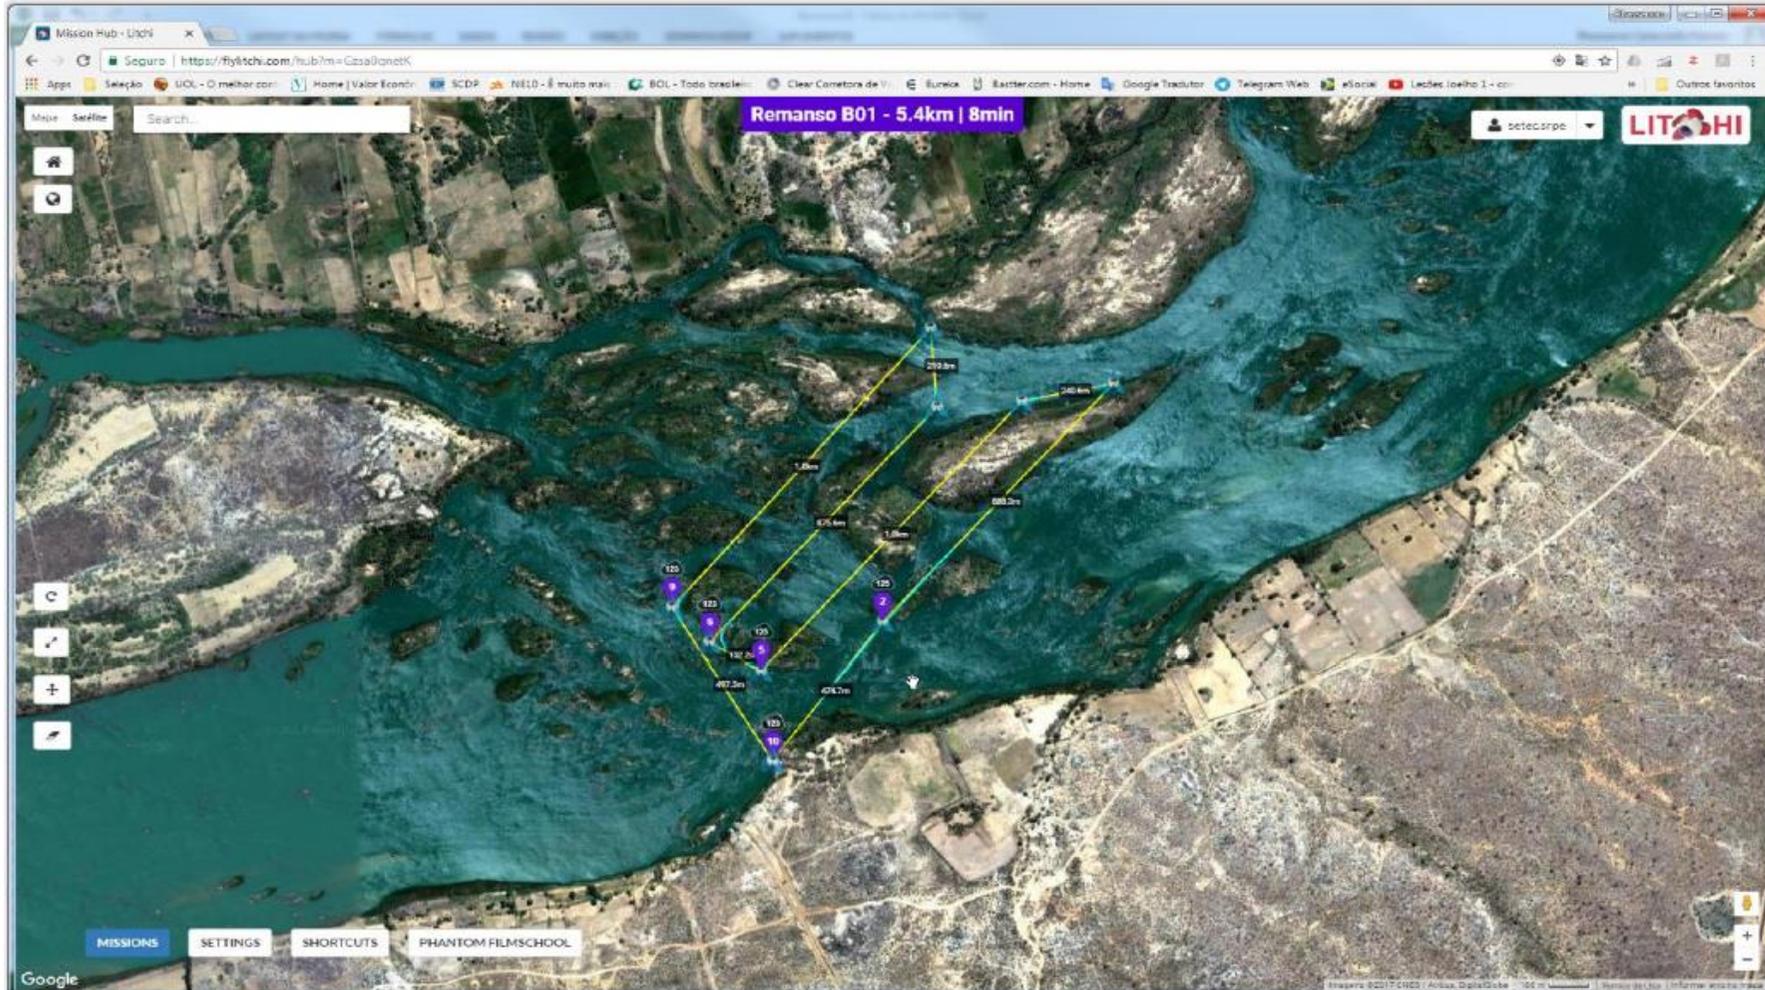
15) Ilha Aracapé B04



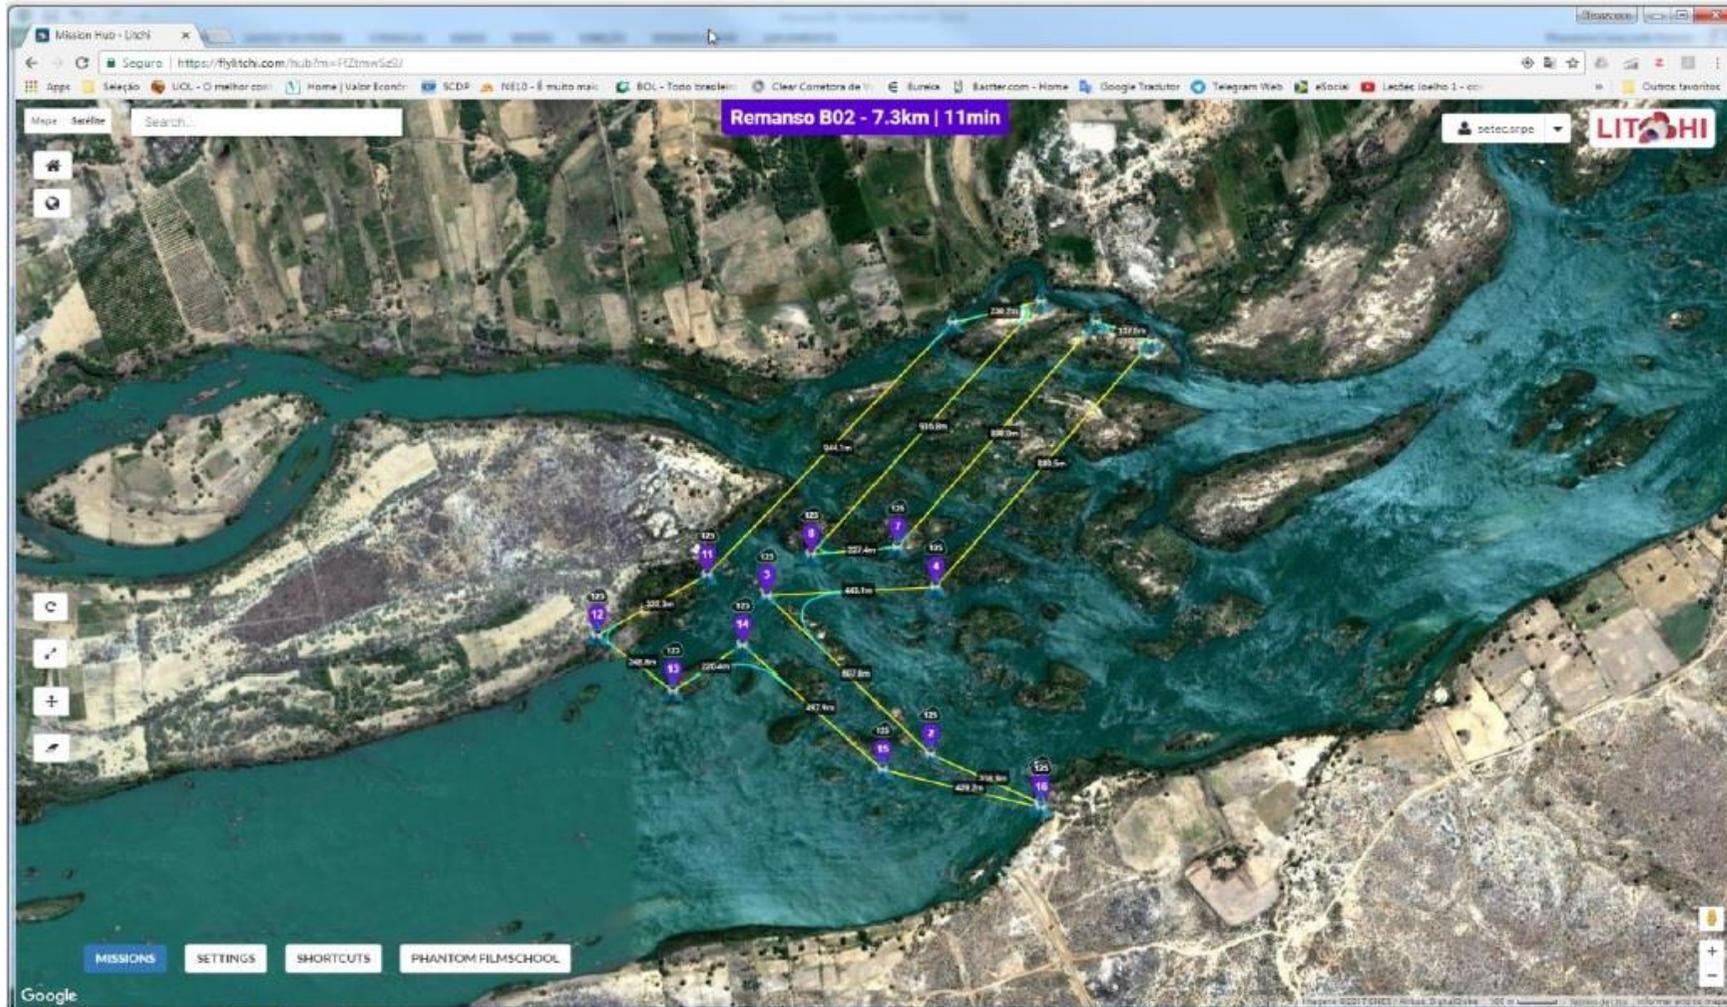
16) Ilha Aracapé B05



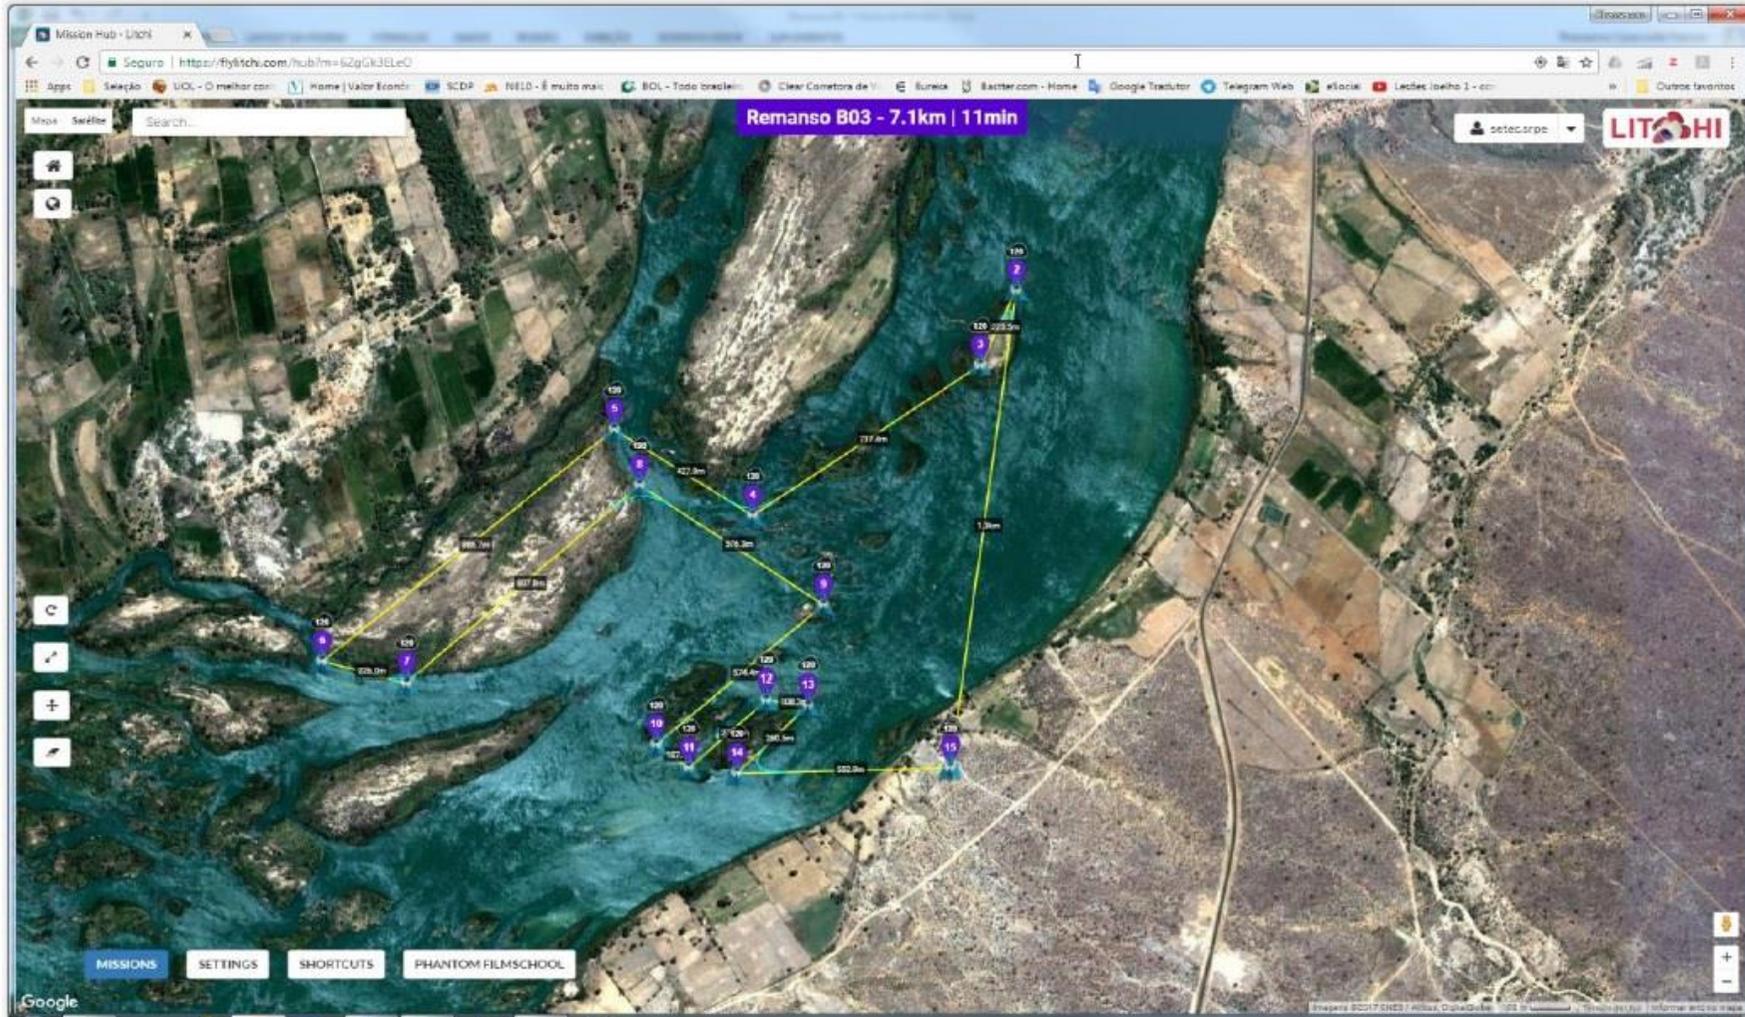
17) Remanso B01 (Drone Deploy)



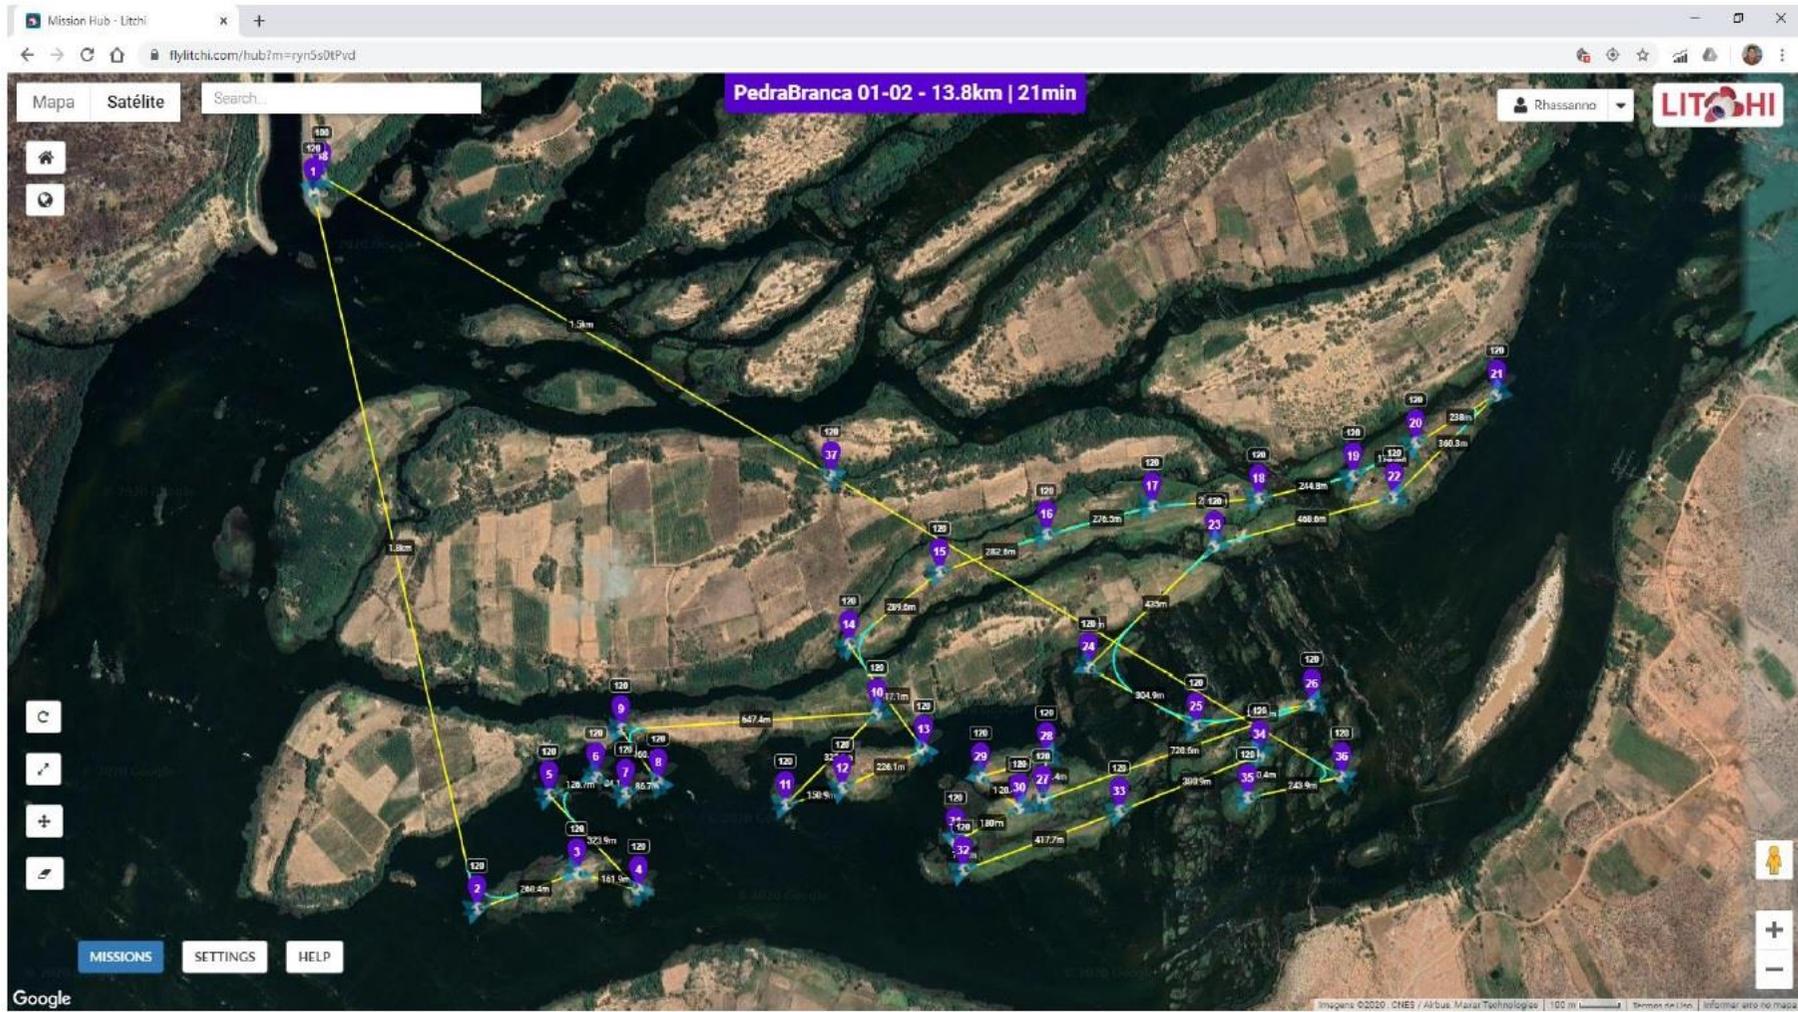
18) Remanso B02



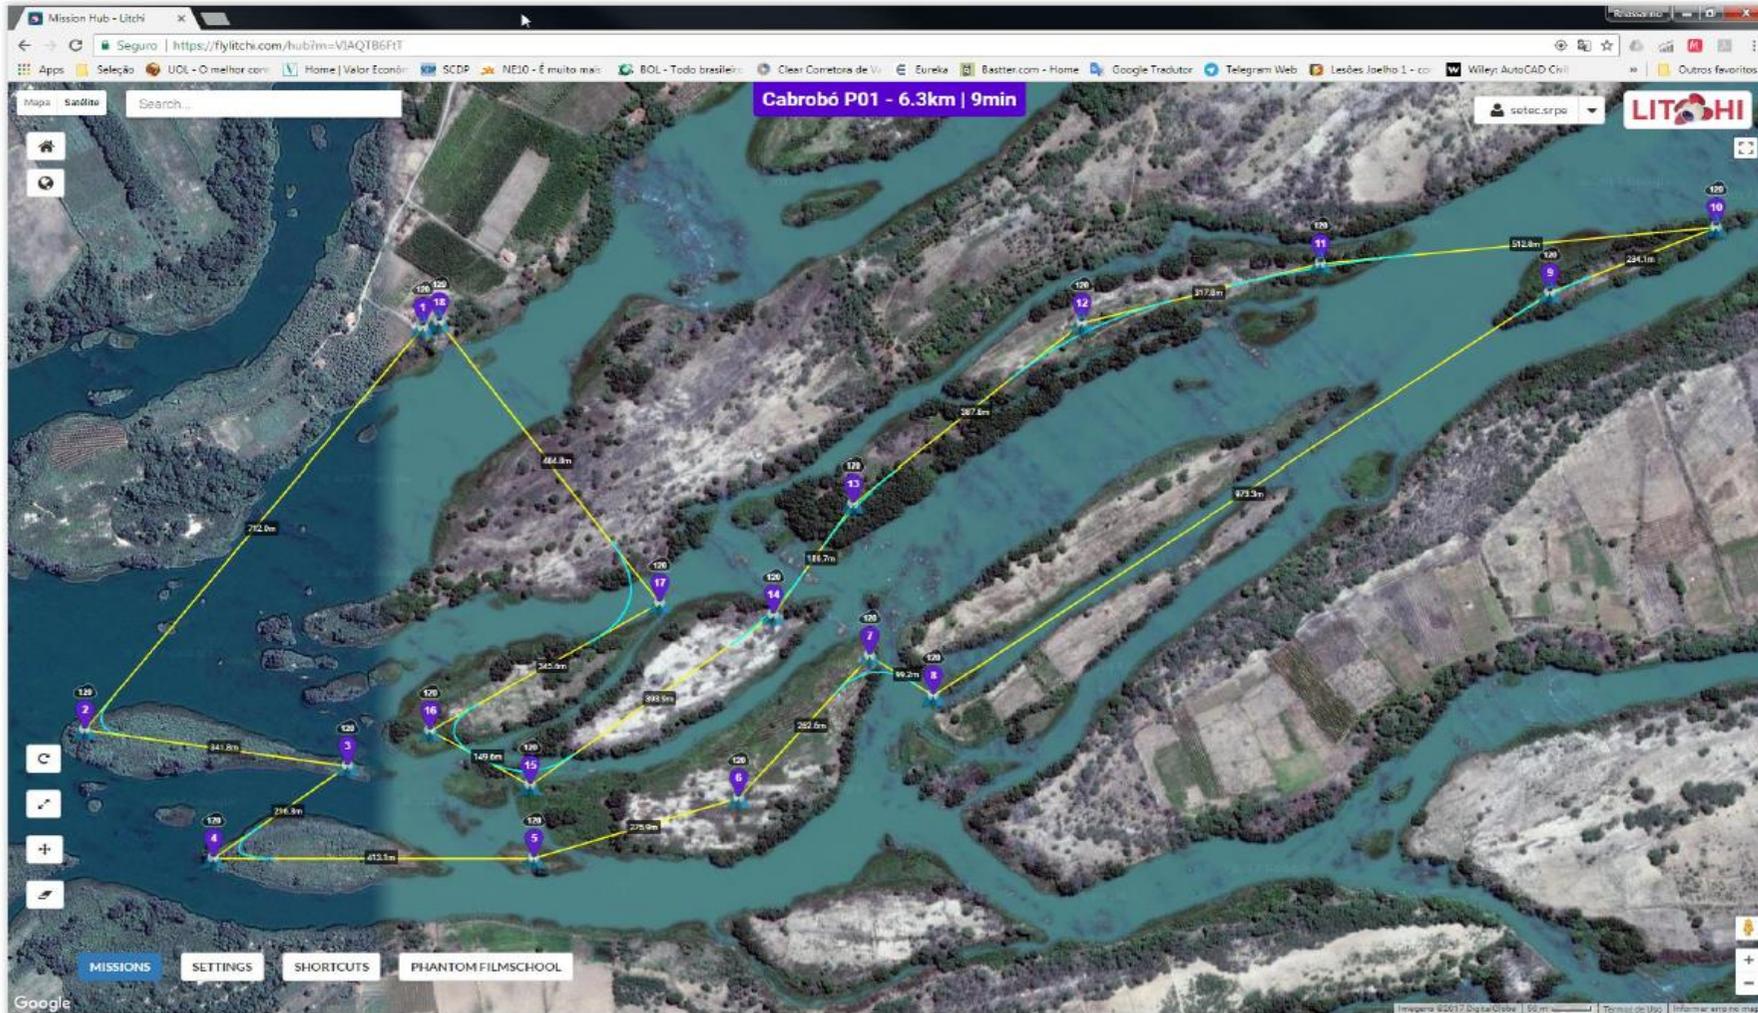
19) Remanso B03



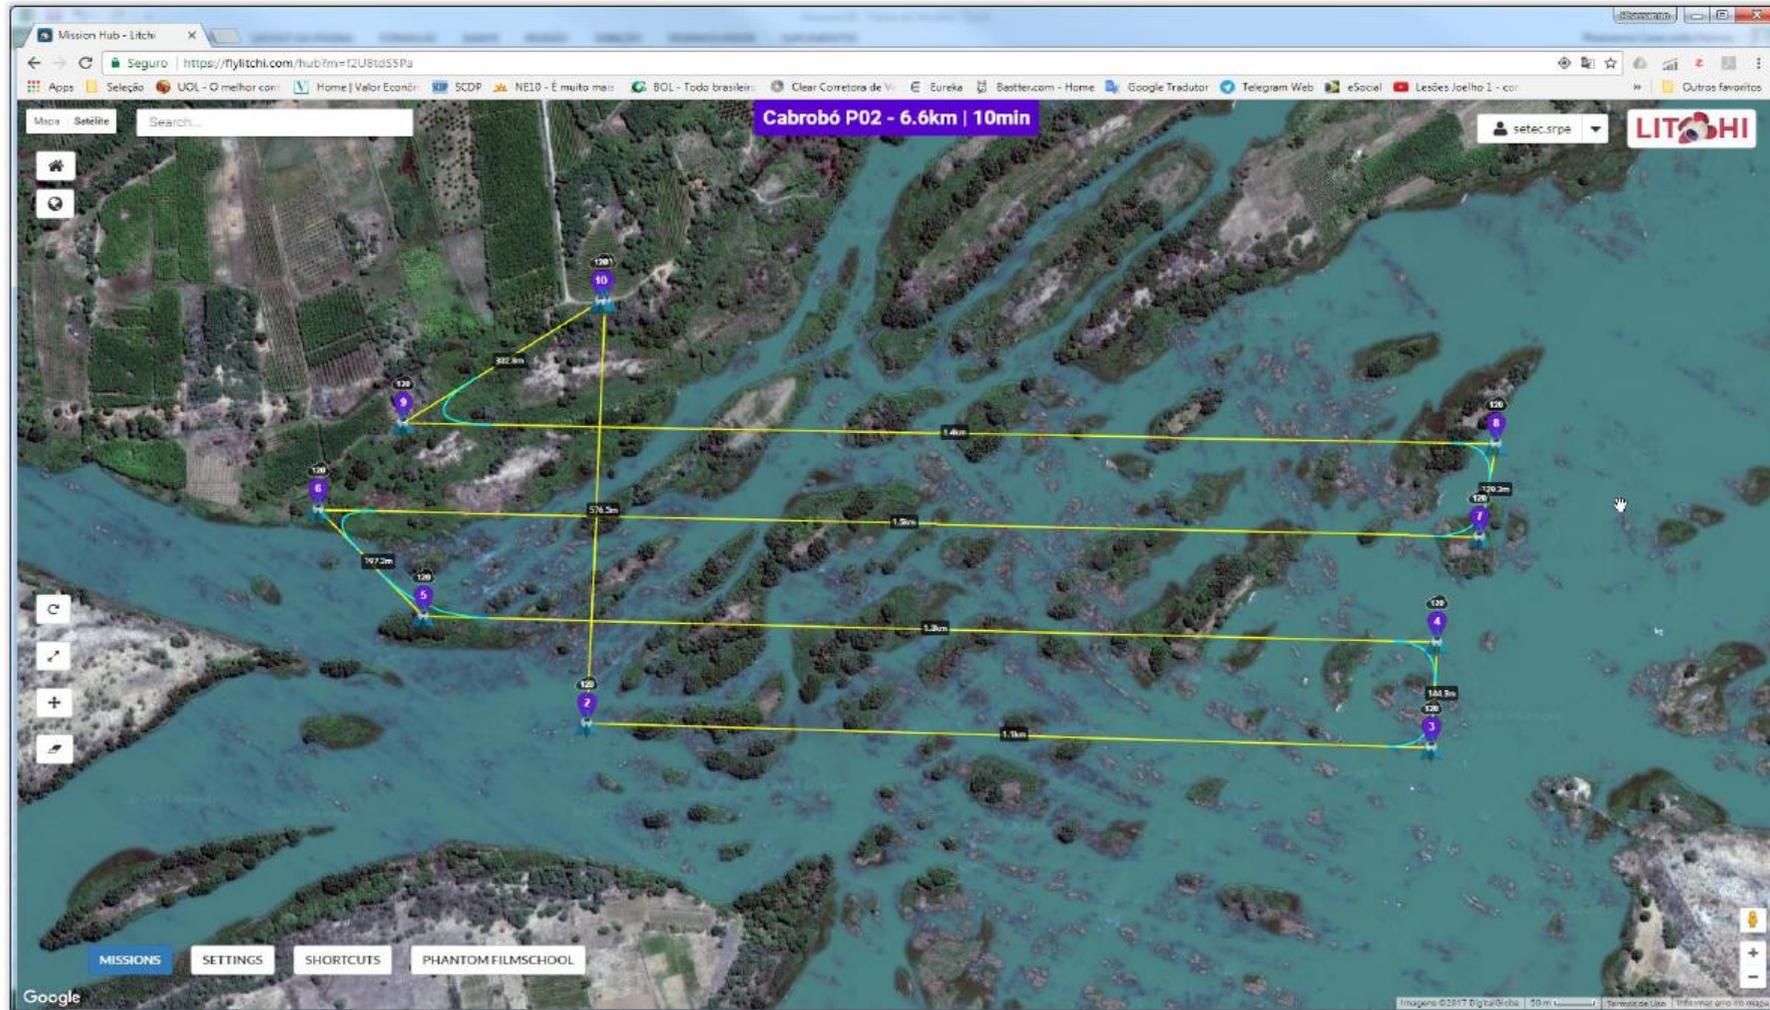
21) Pedra Branca 01-02



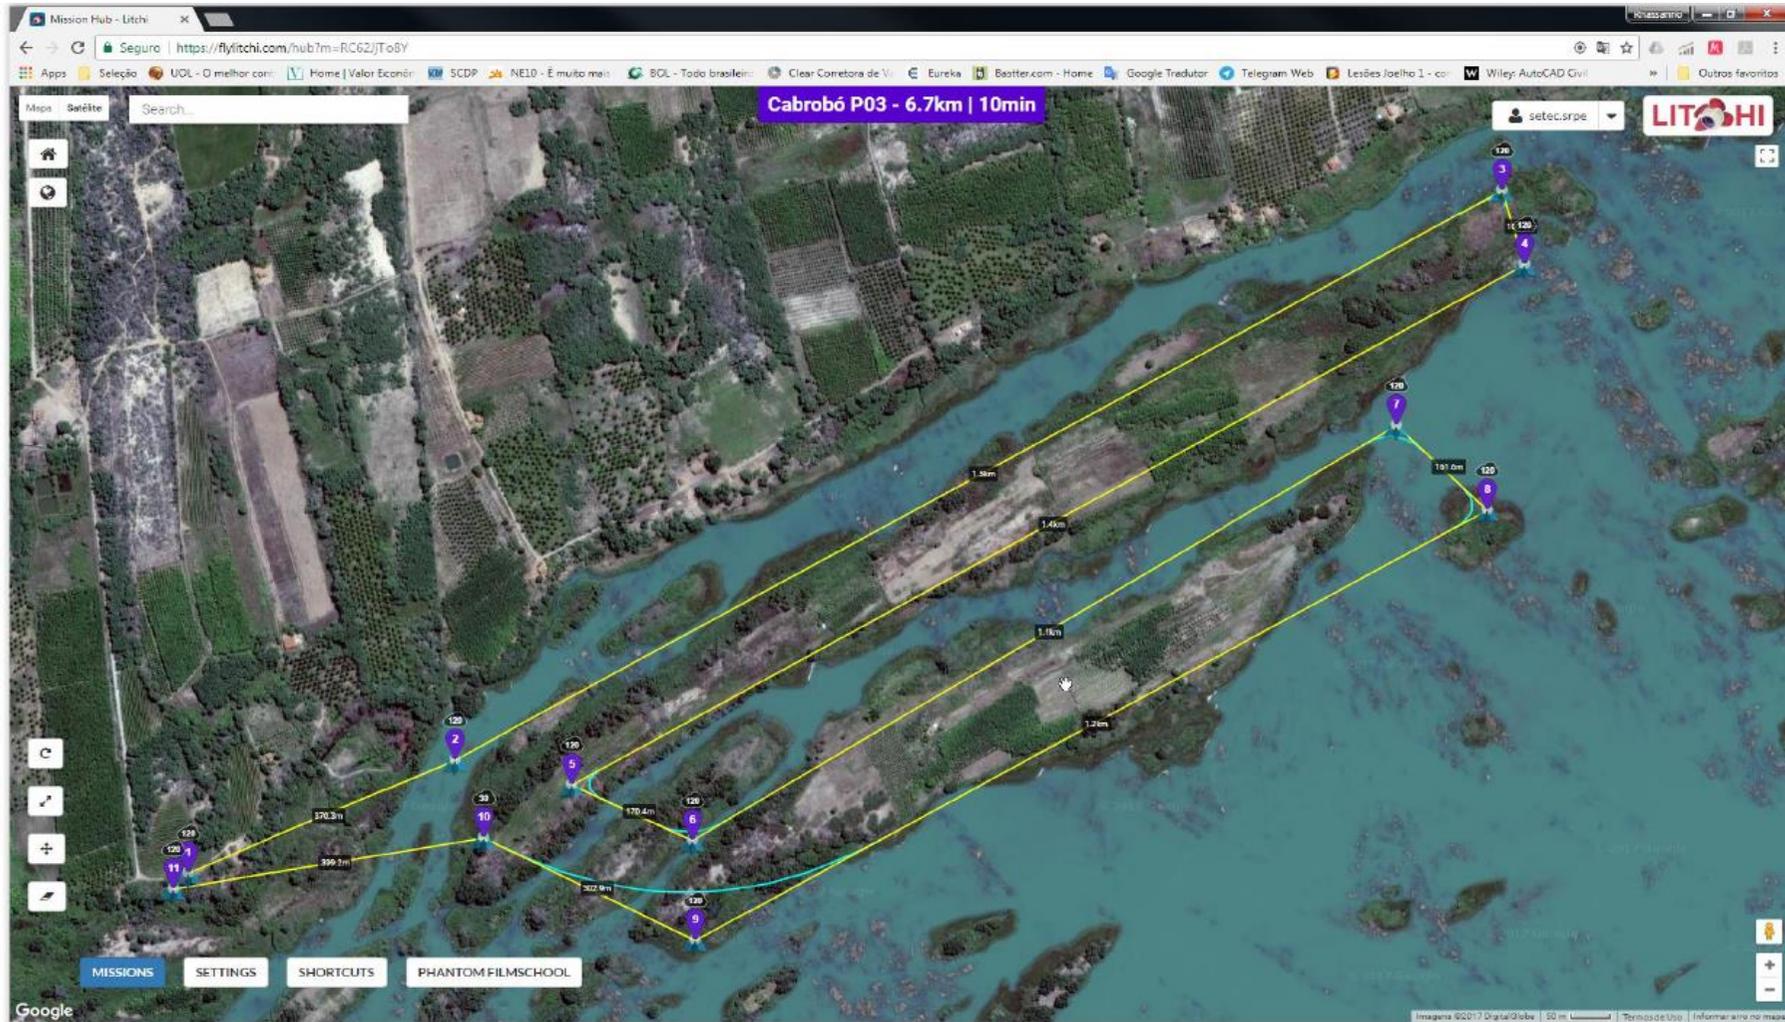
22) Cabrobó P01



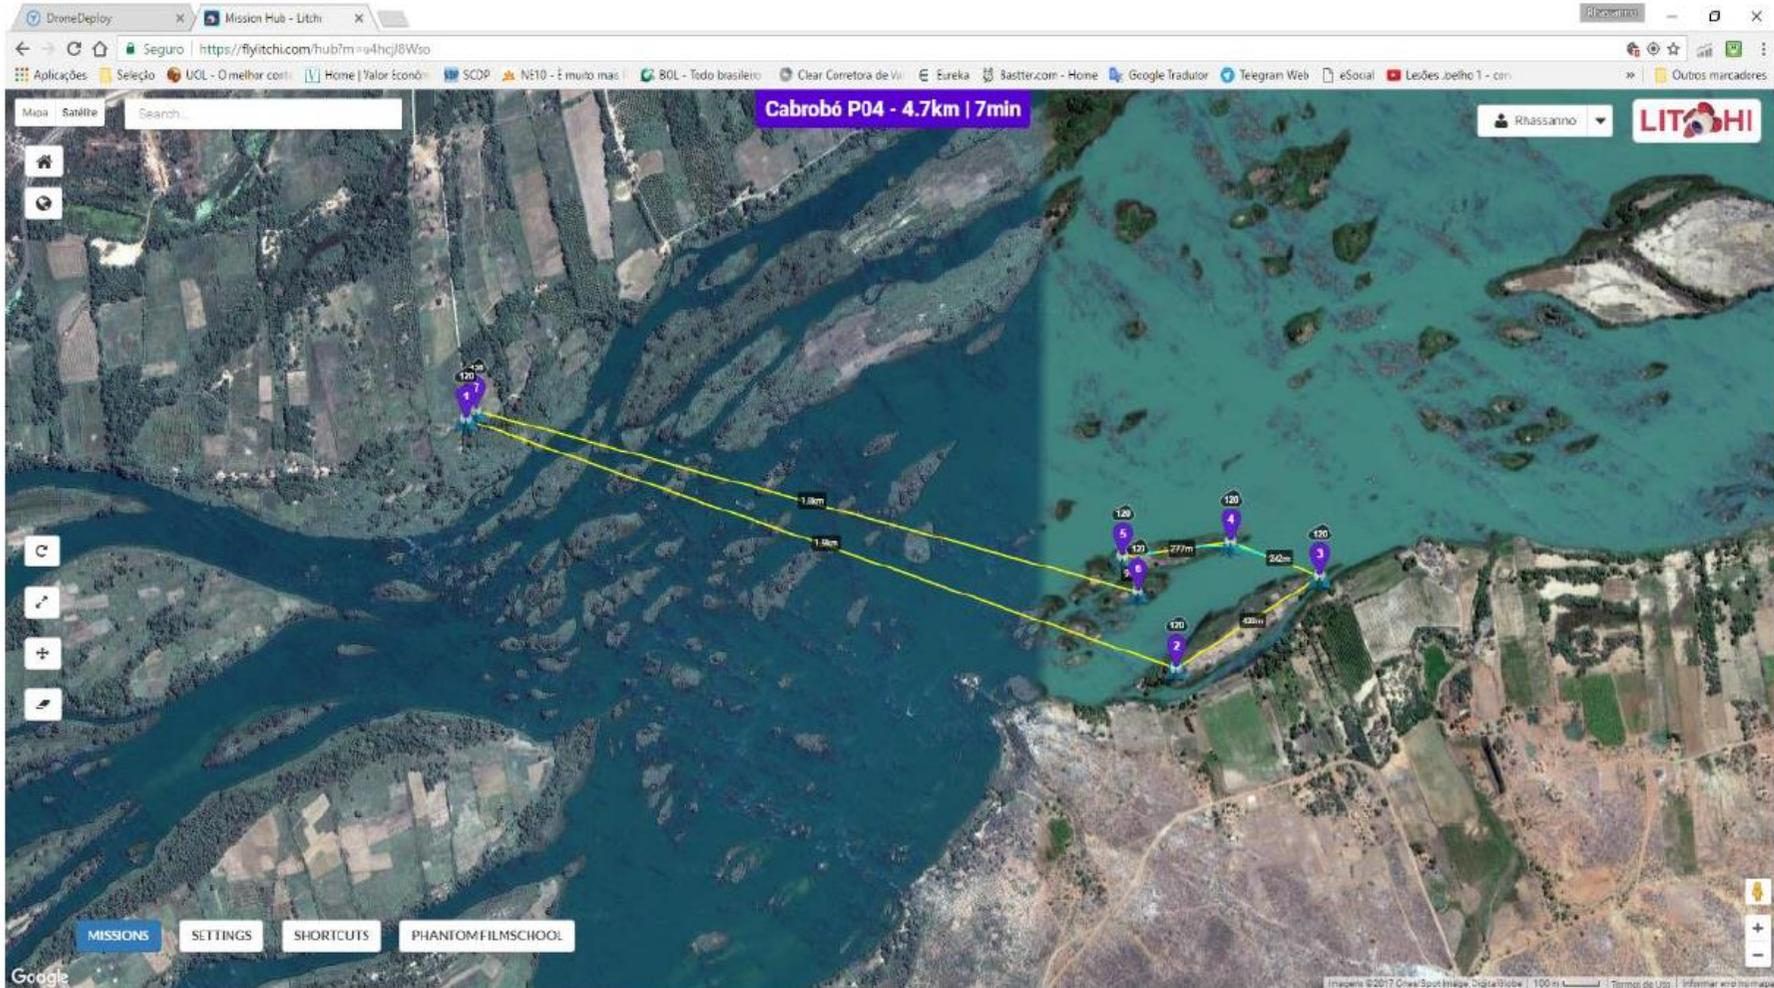
23) Cabrobó P02



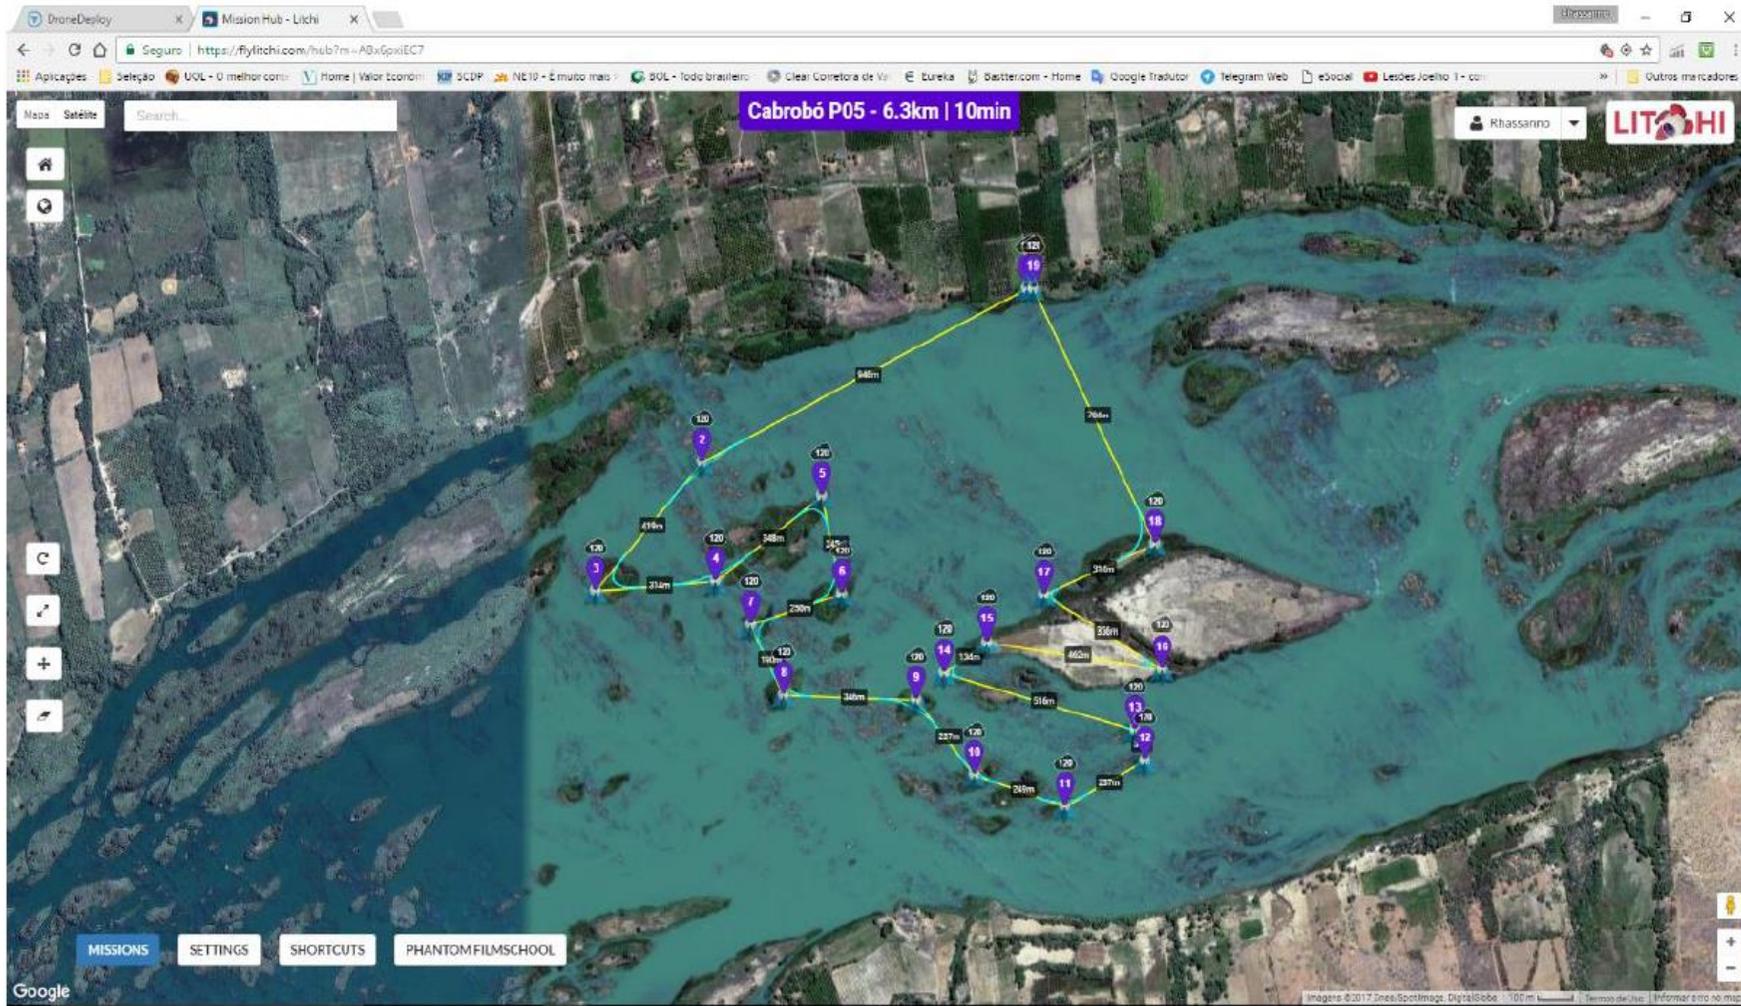
24) Cabrobó P03



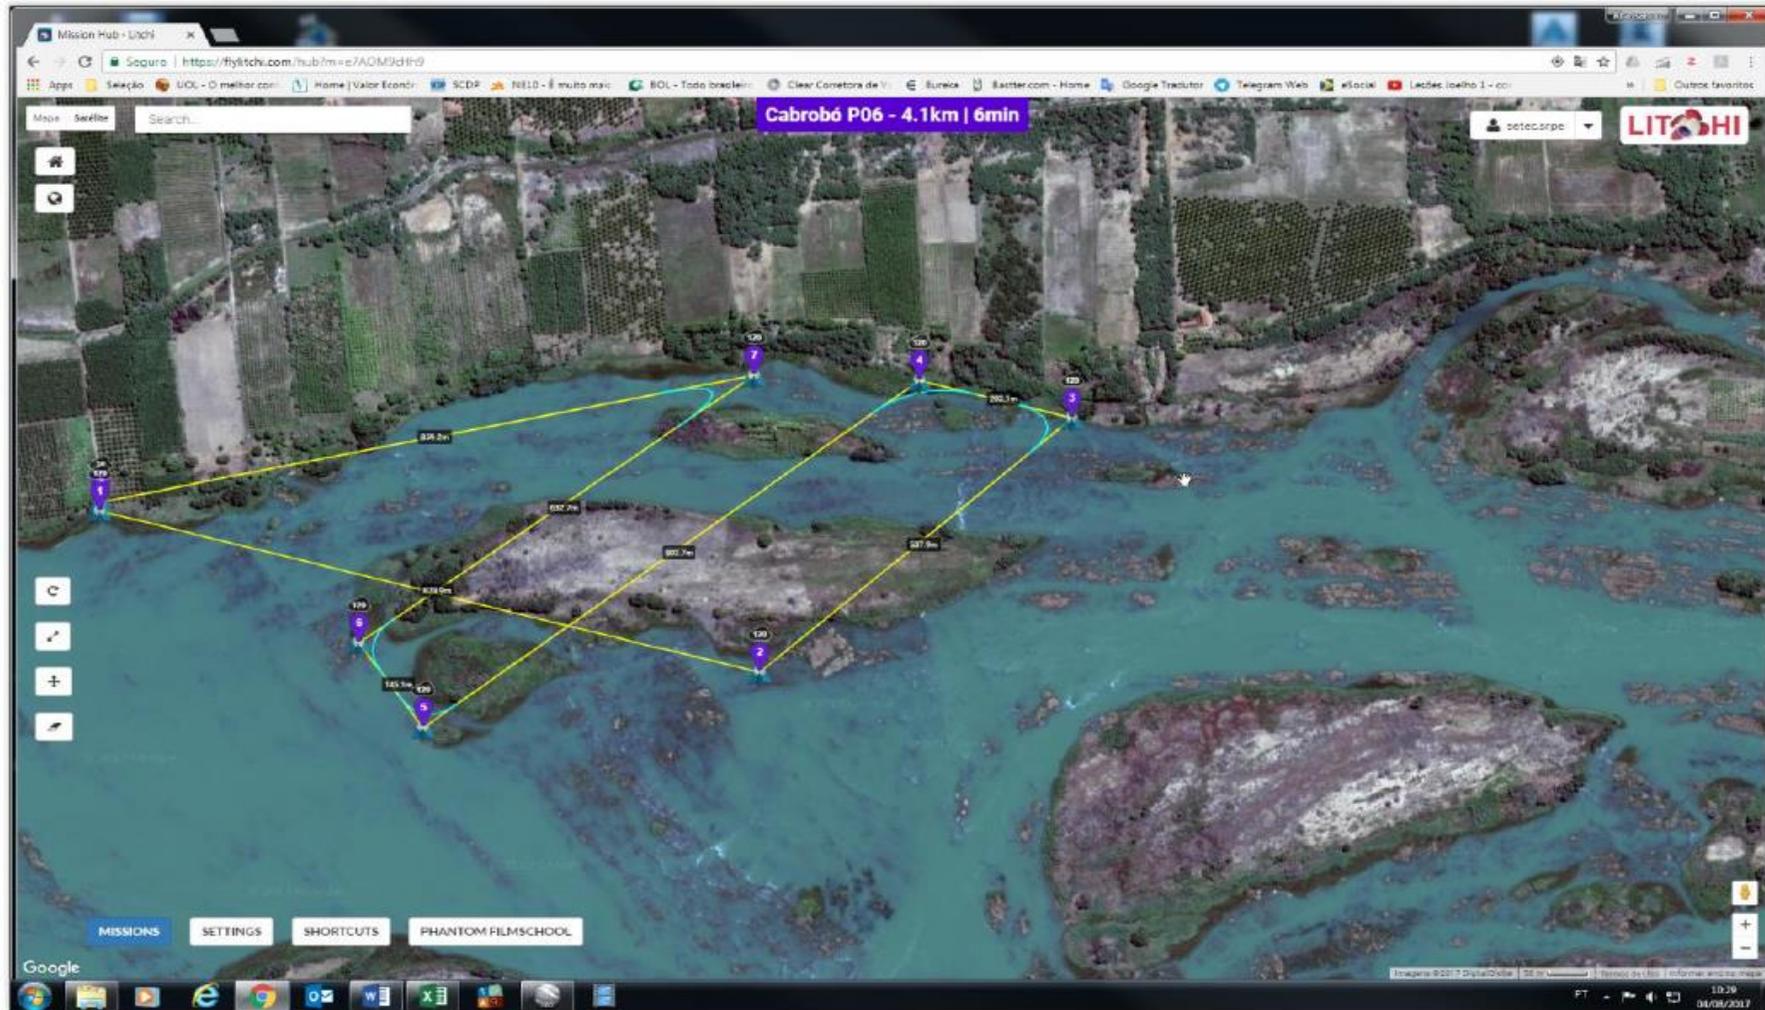
25) Cabrobó P04



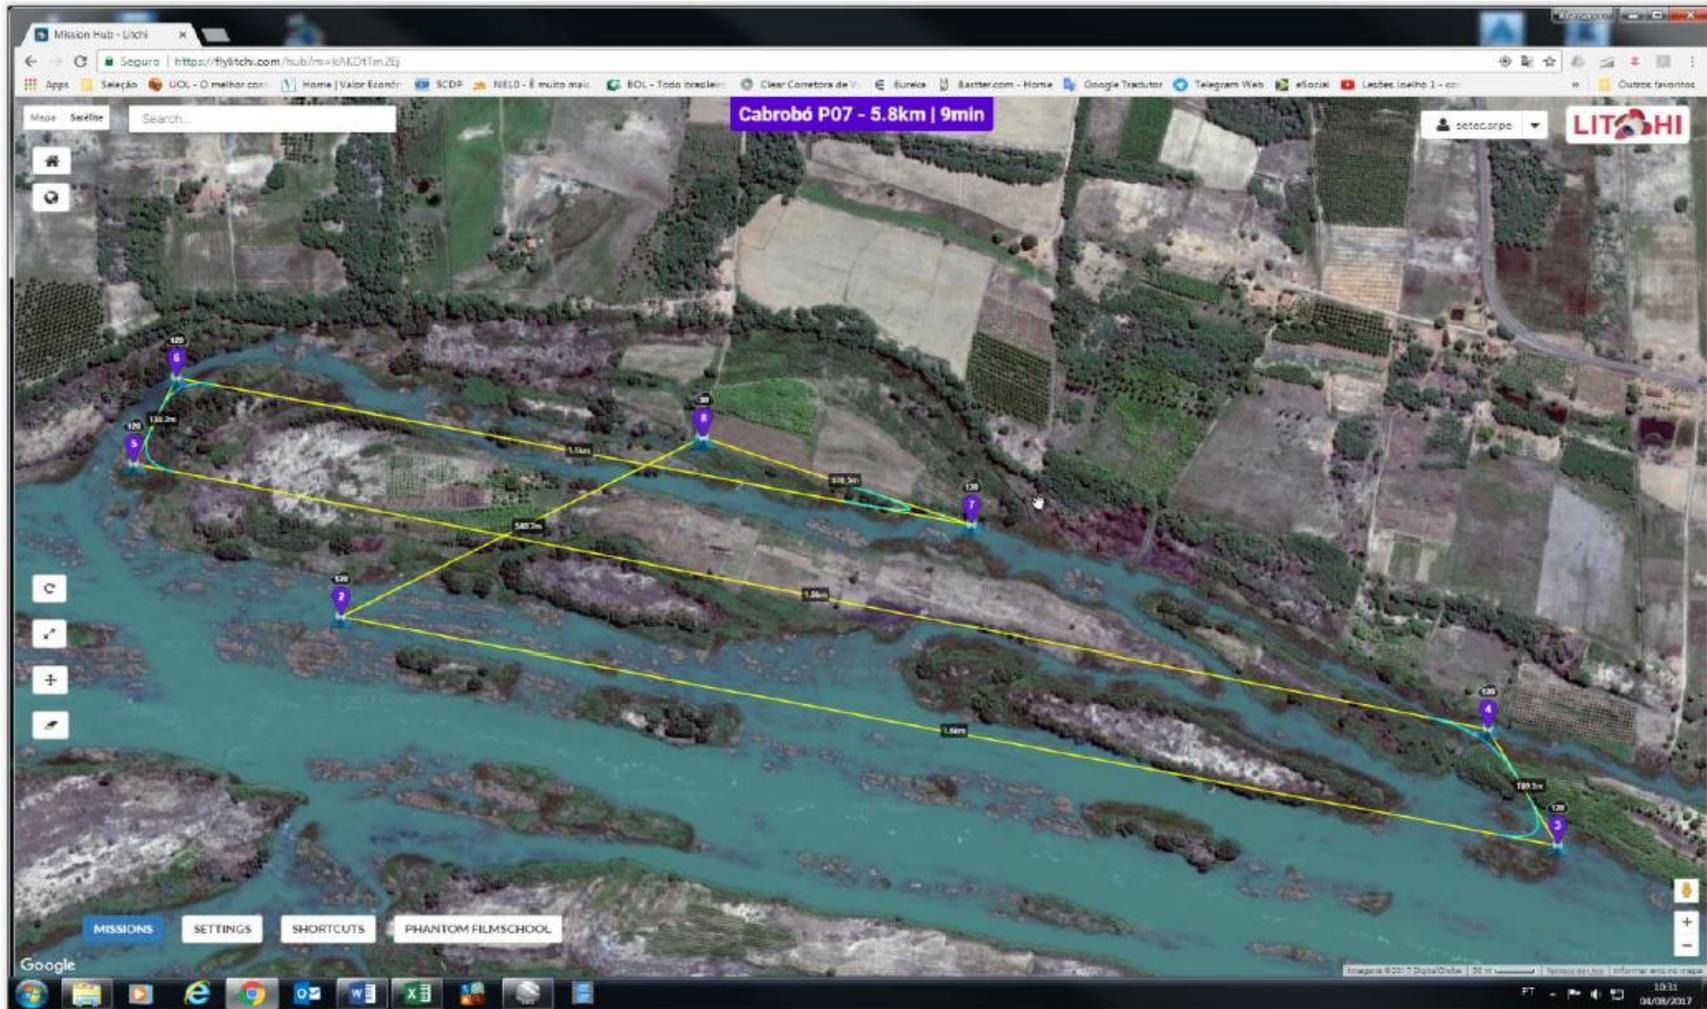
26) Cabrobó P05



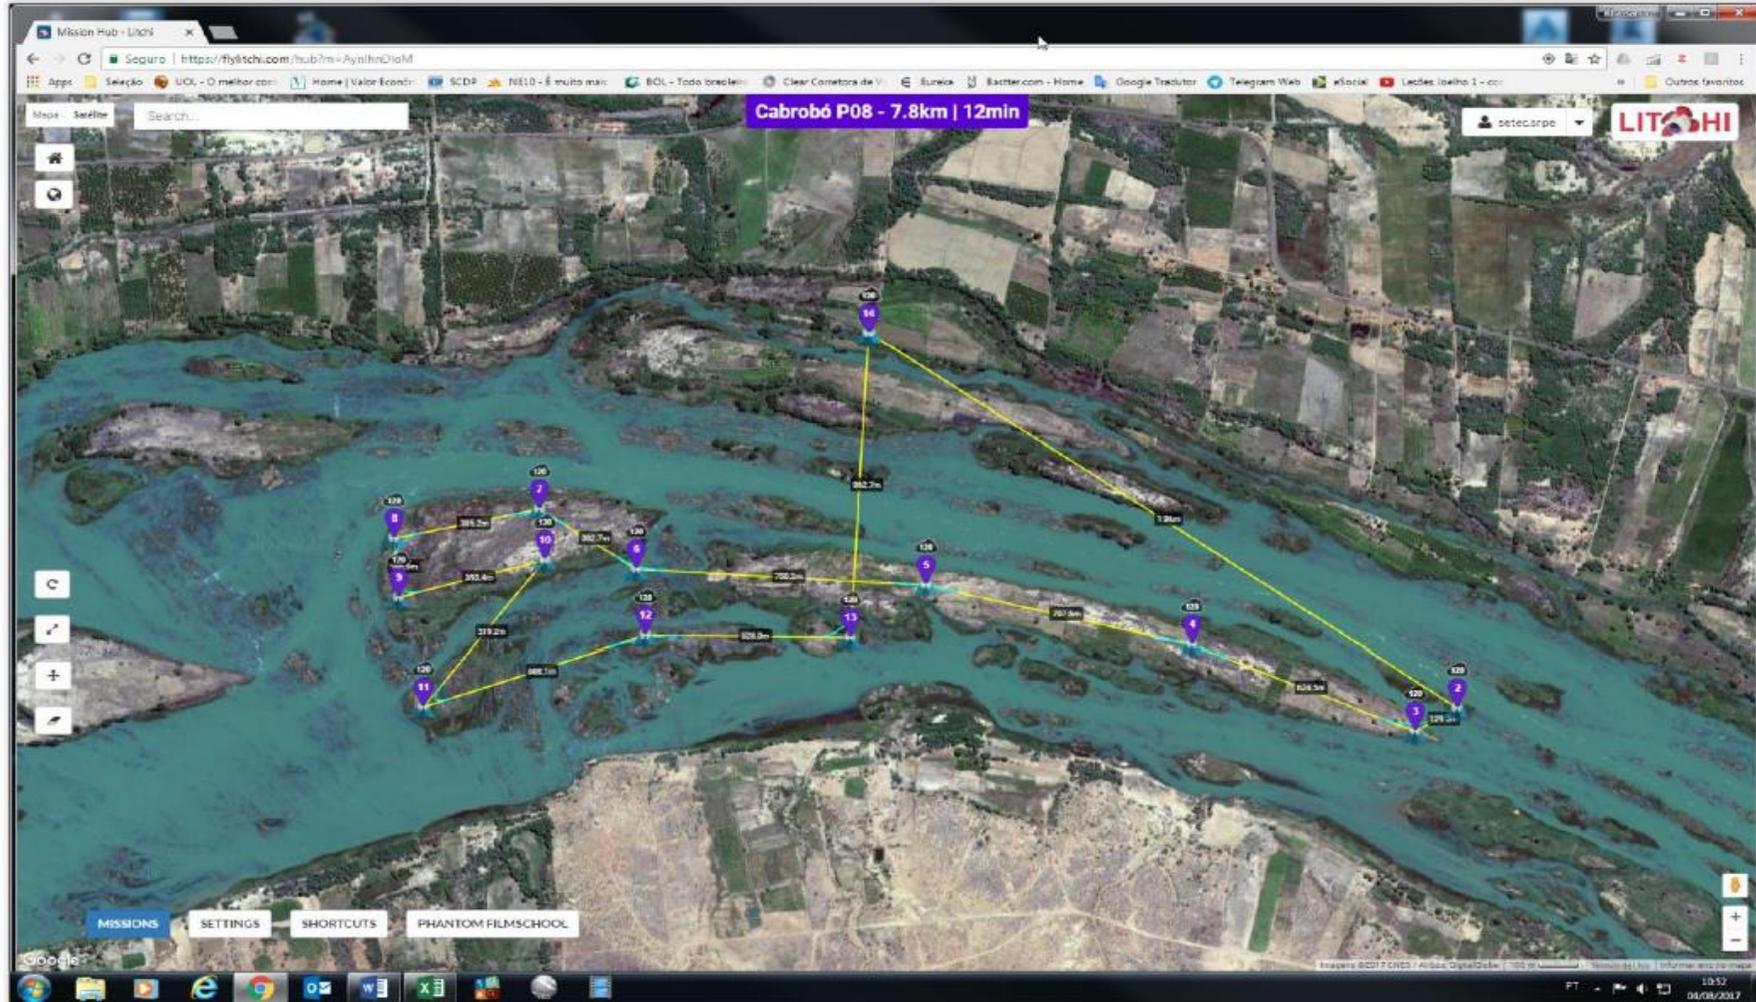
27) Cabrobó P06



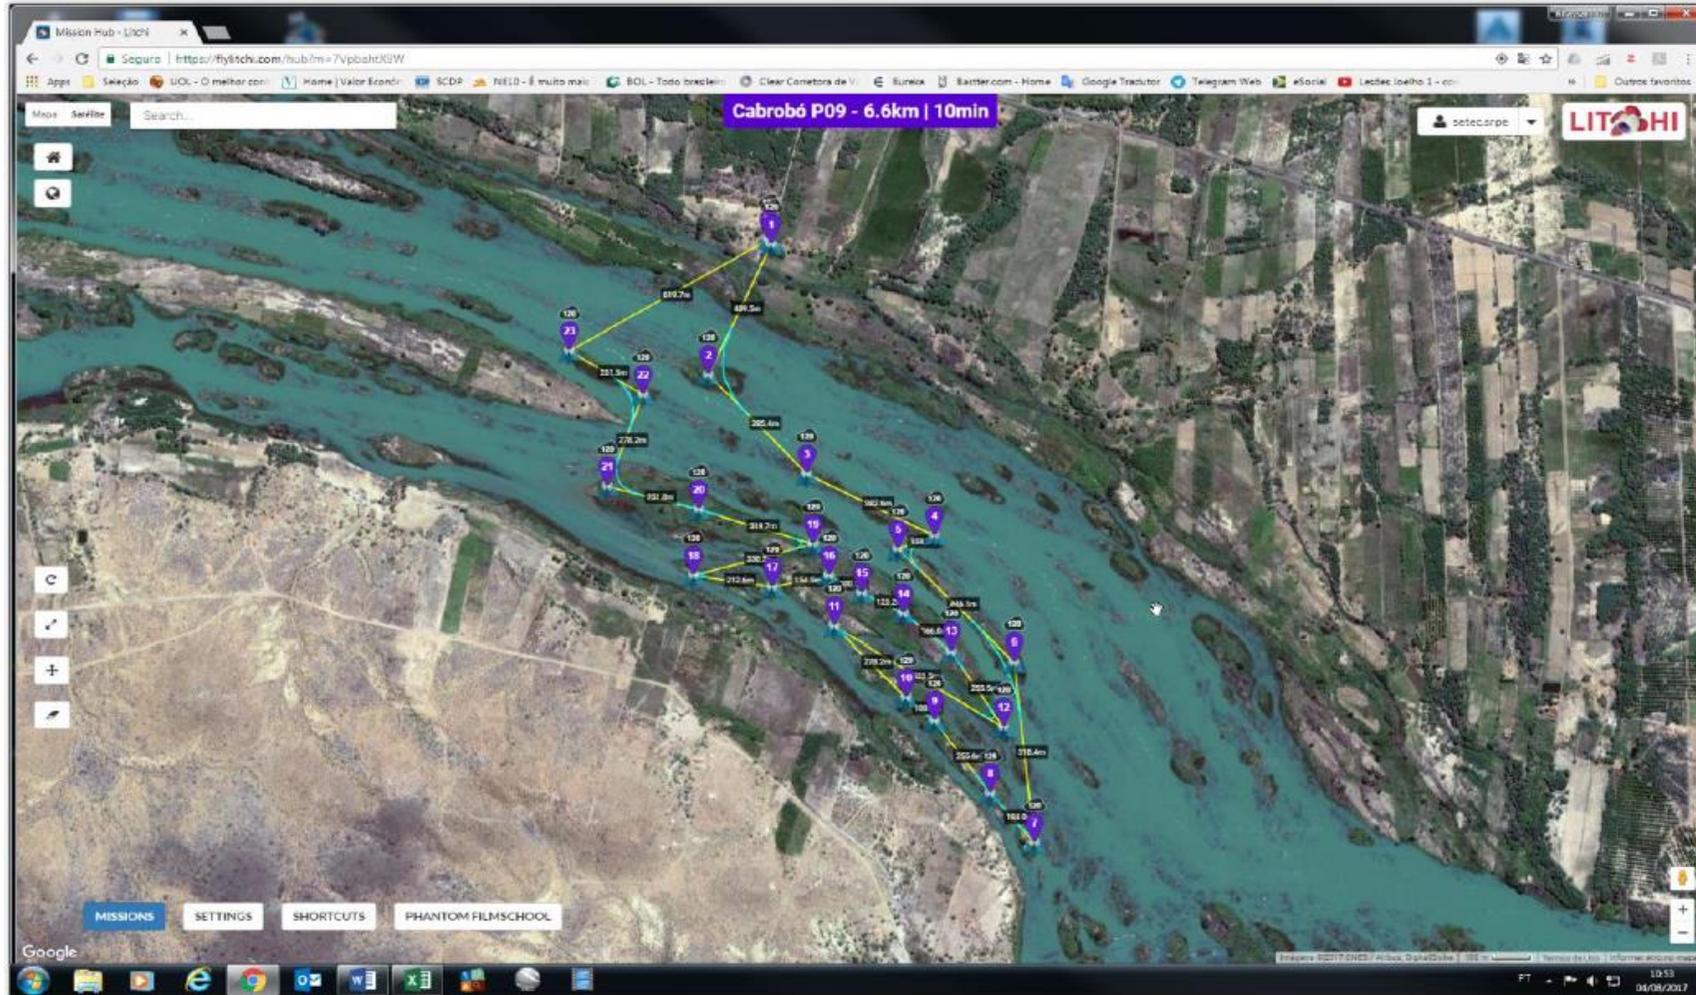
28) Cabrobó P07



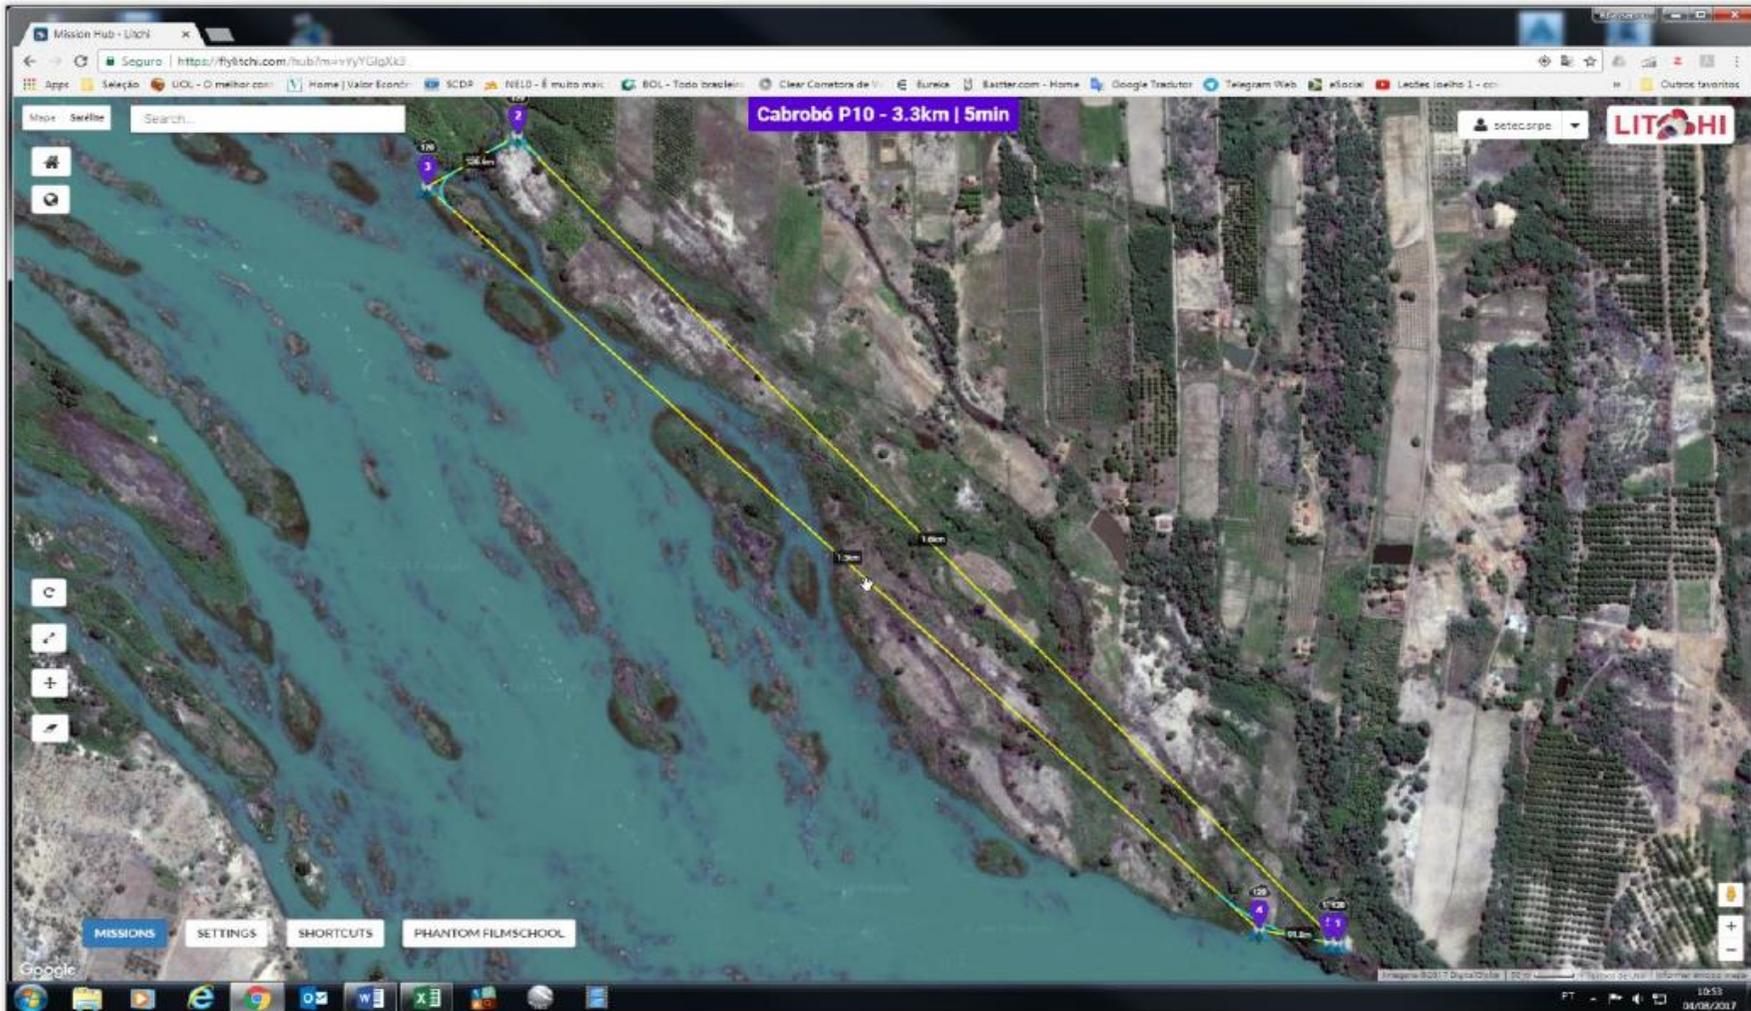
29) Cabrobó P08



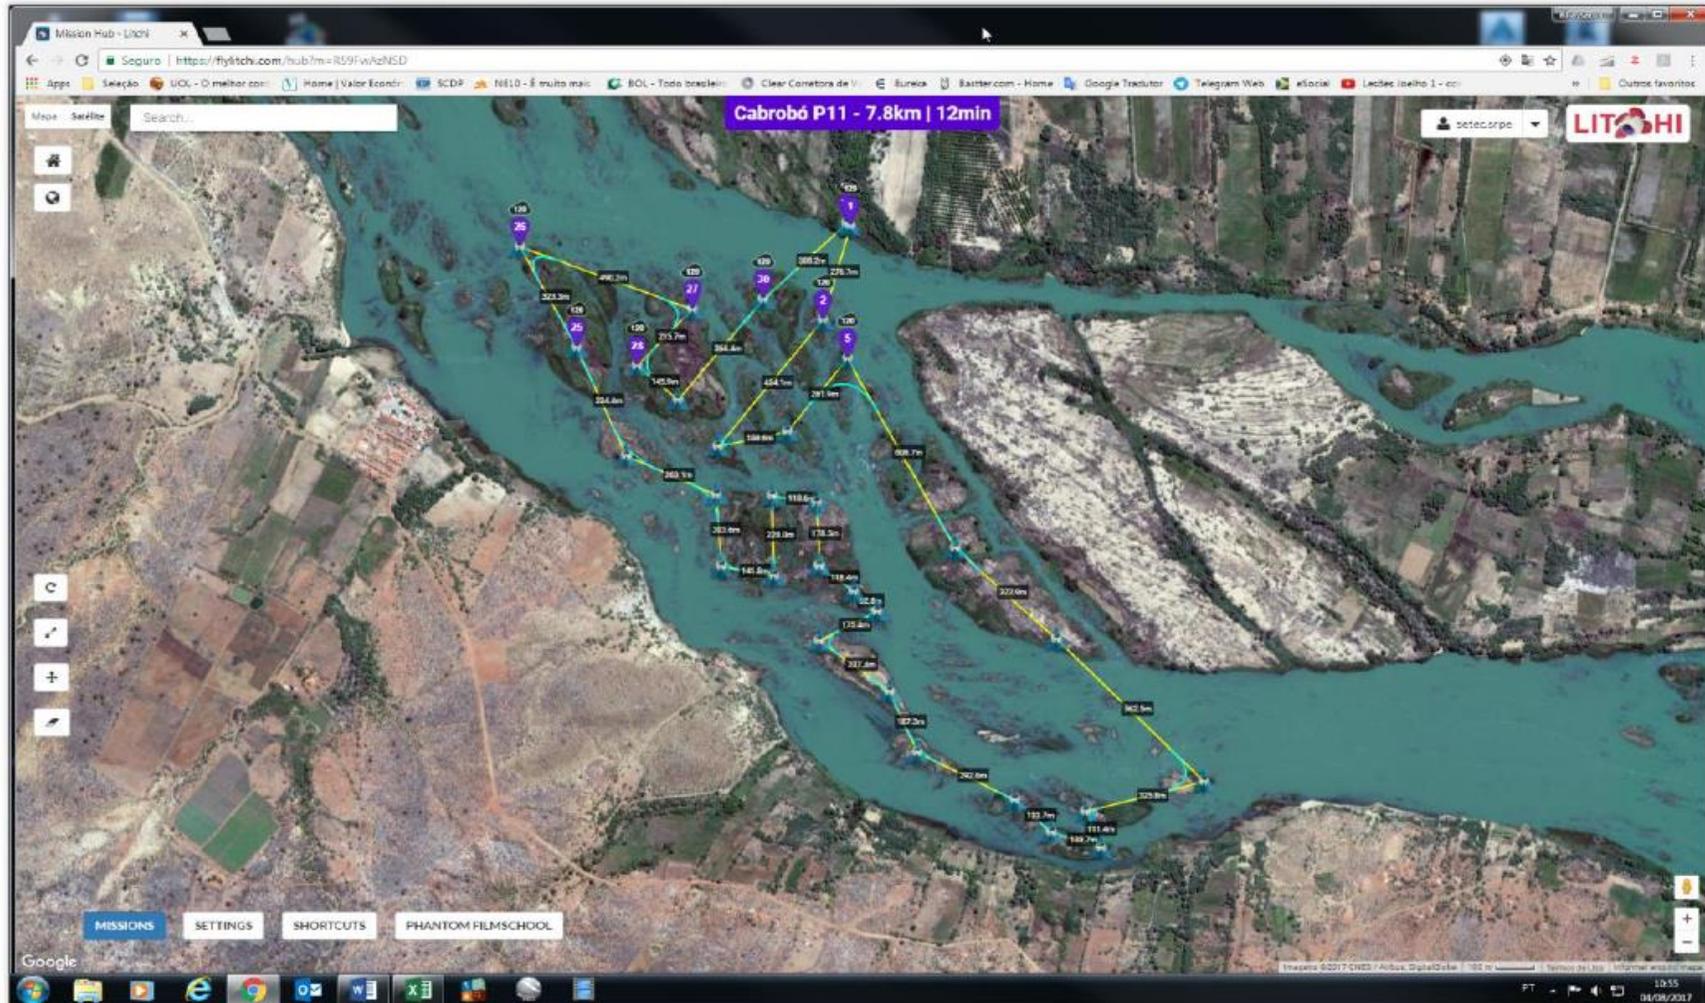
30) Cabrobó P09



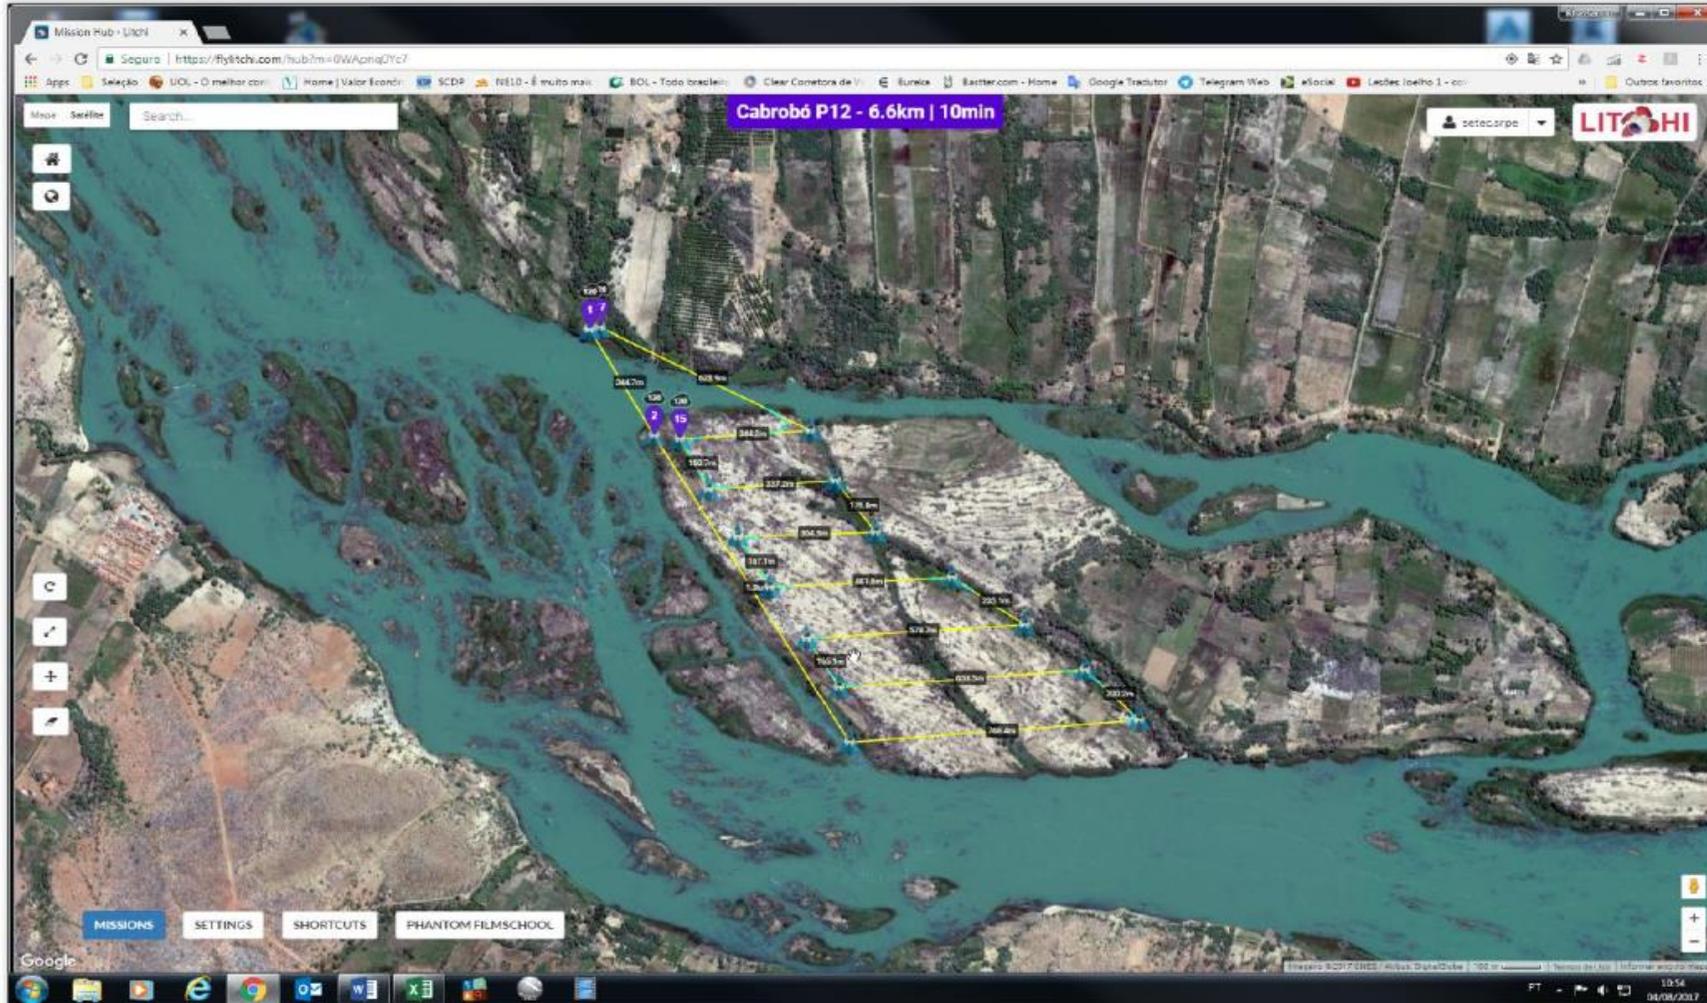
31) Cabrobó P10



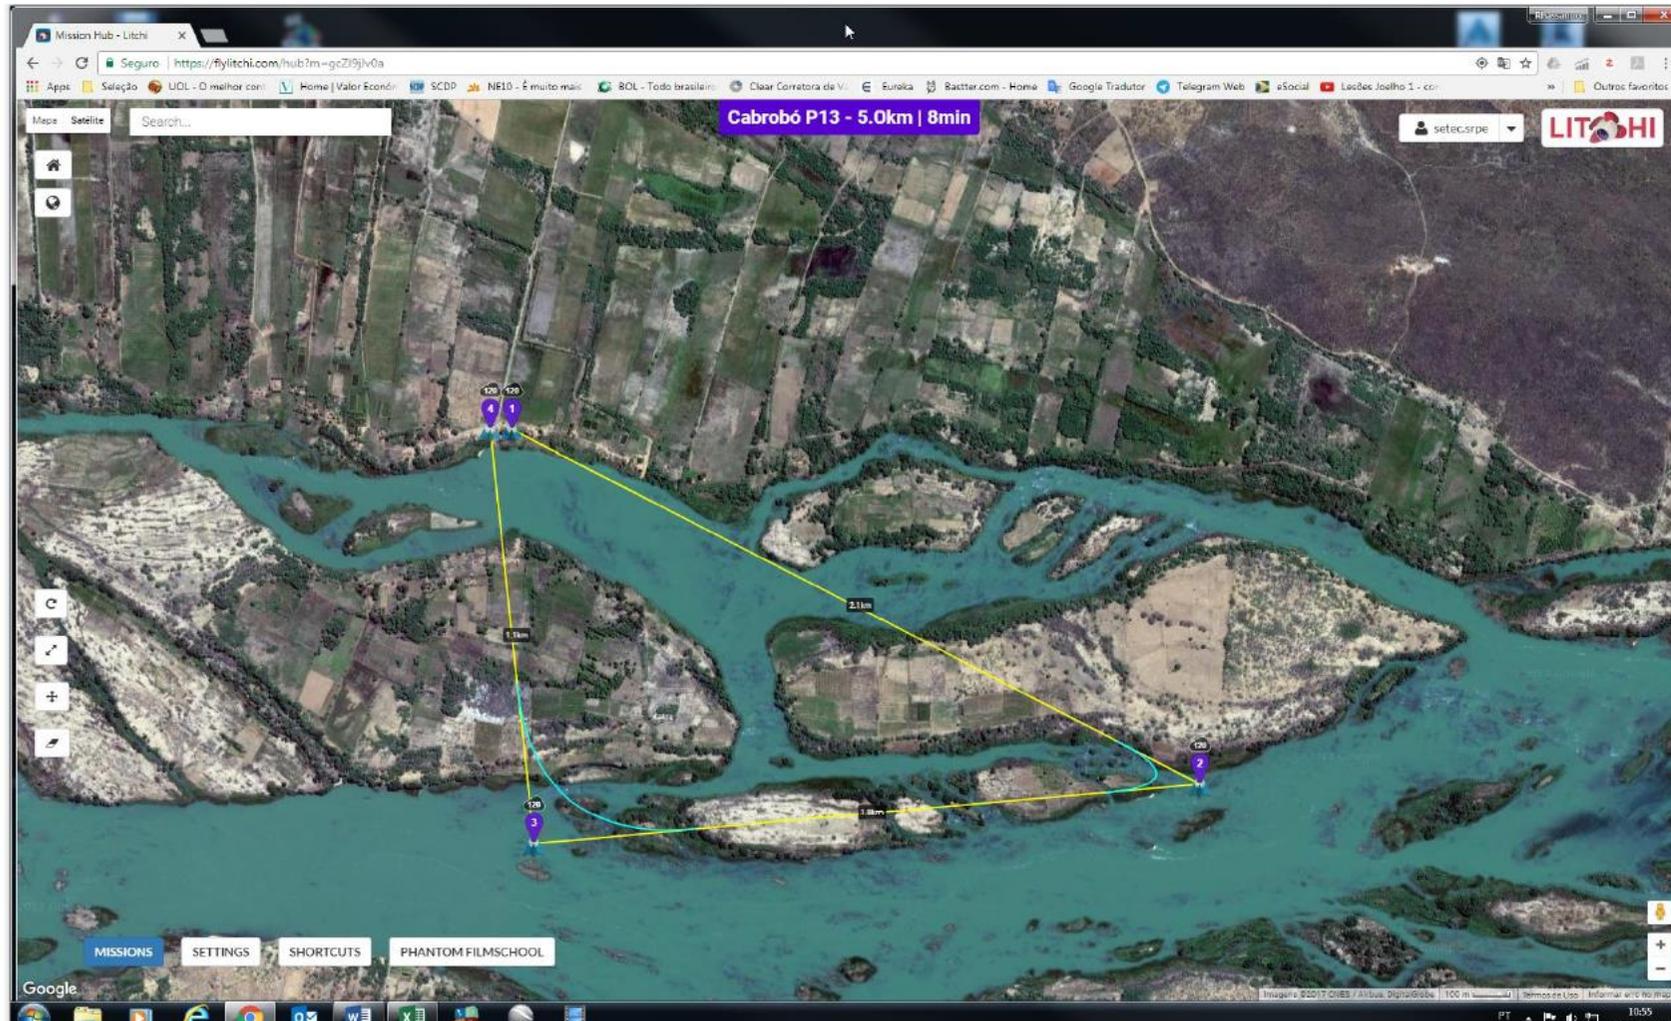
32) Cabrobó P11



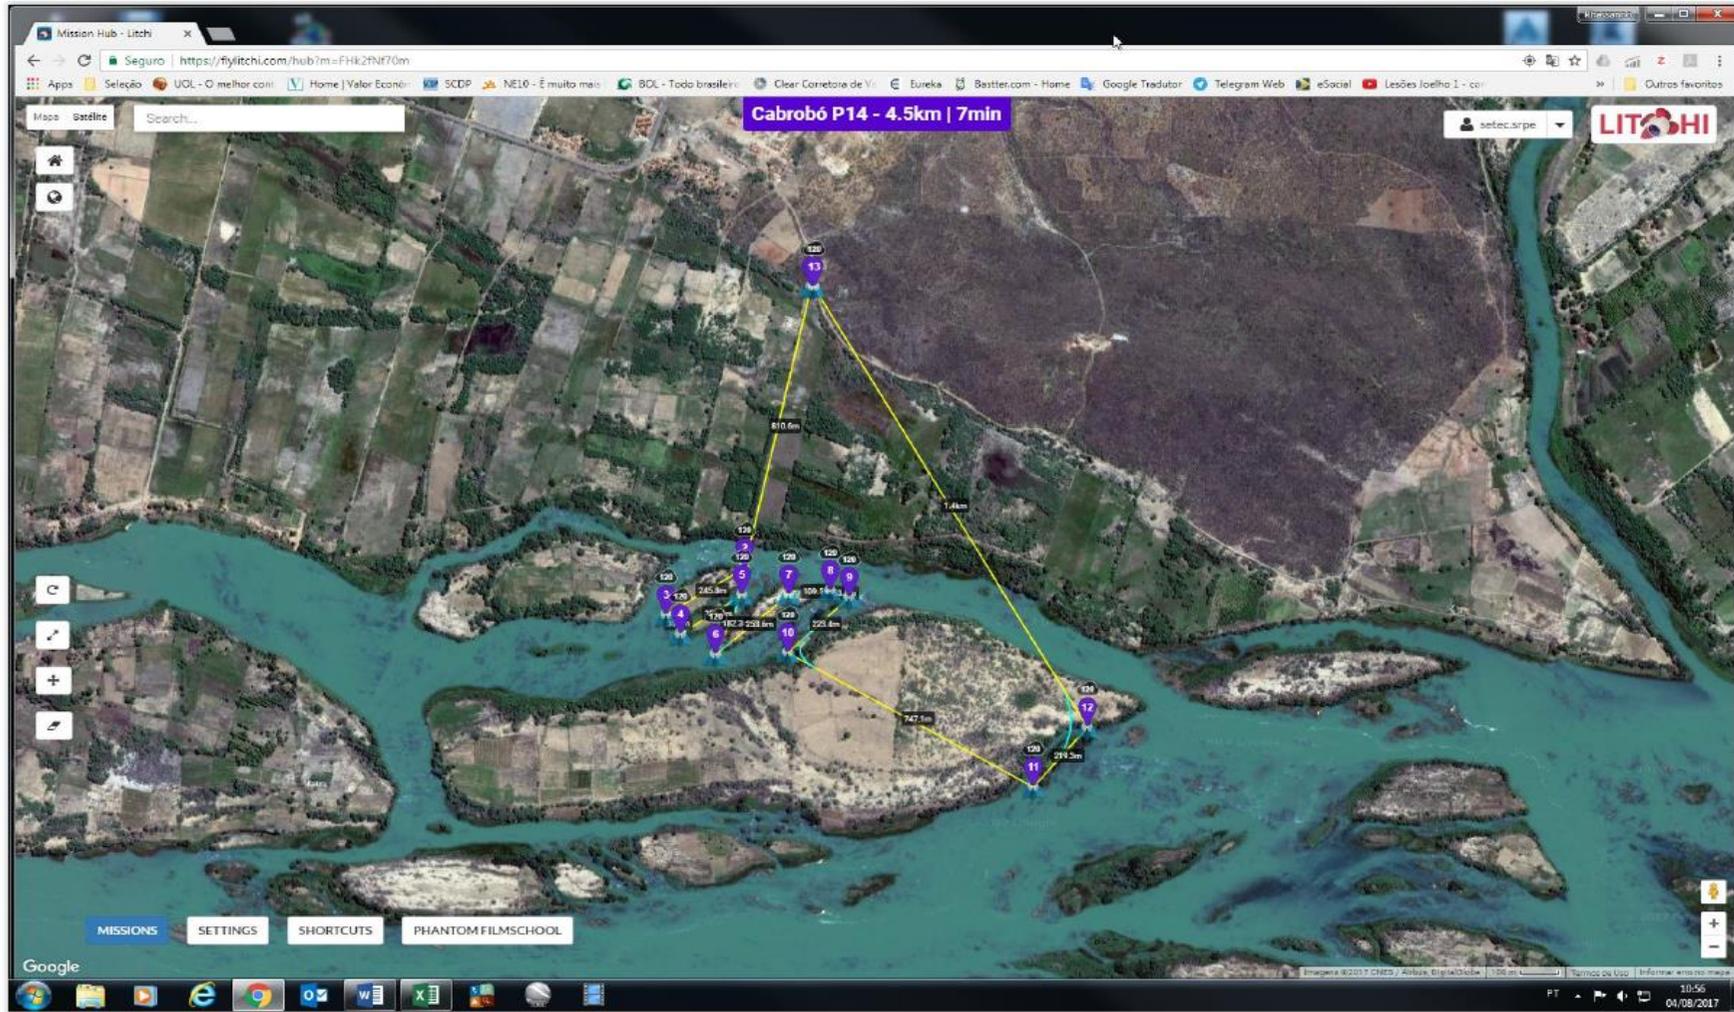
33) Cabrobó P12



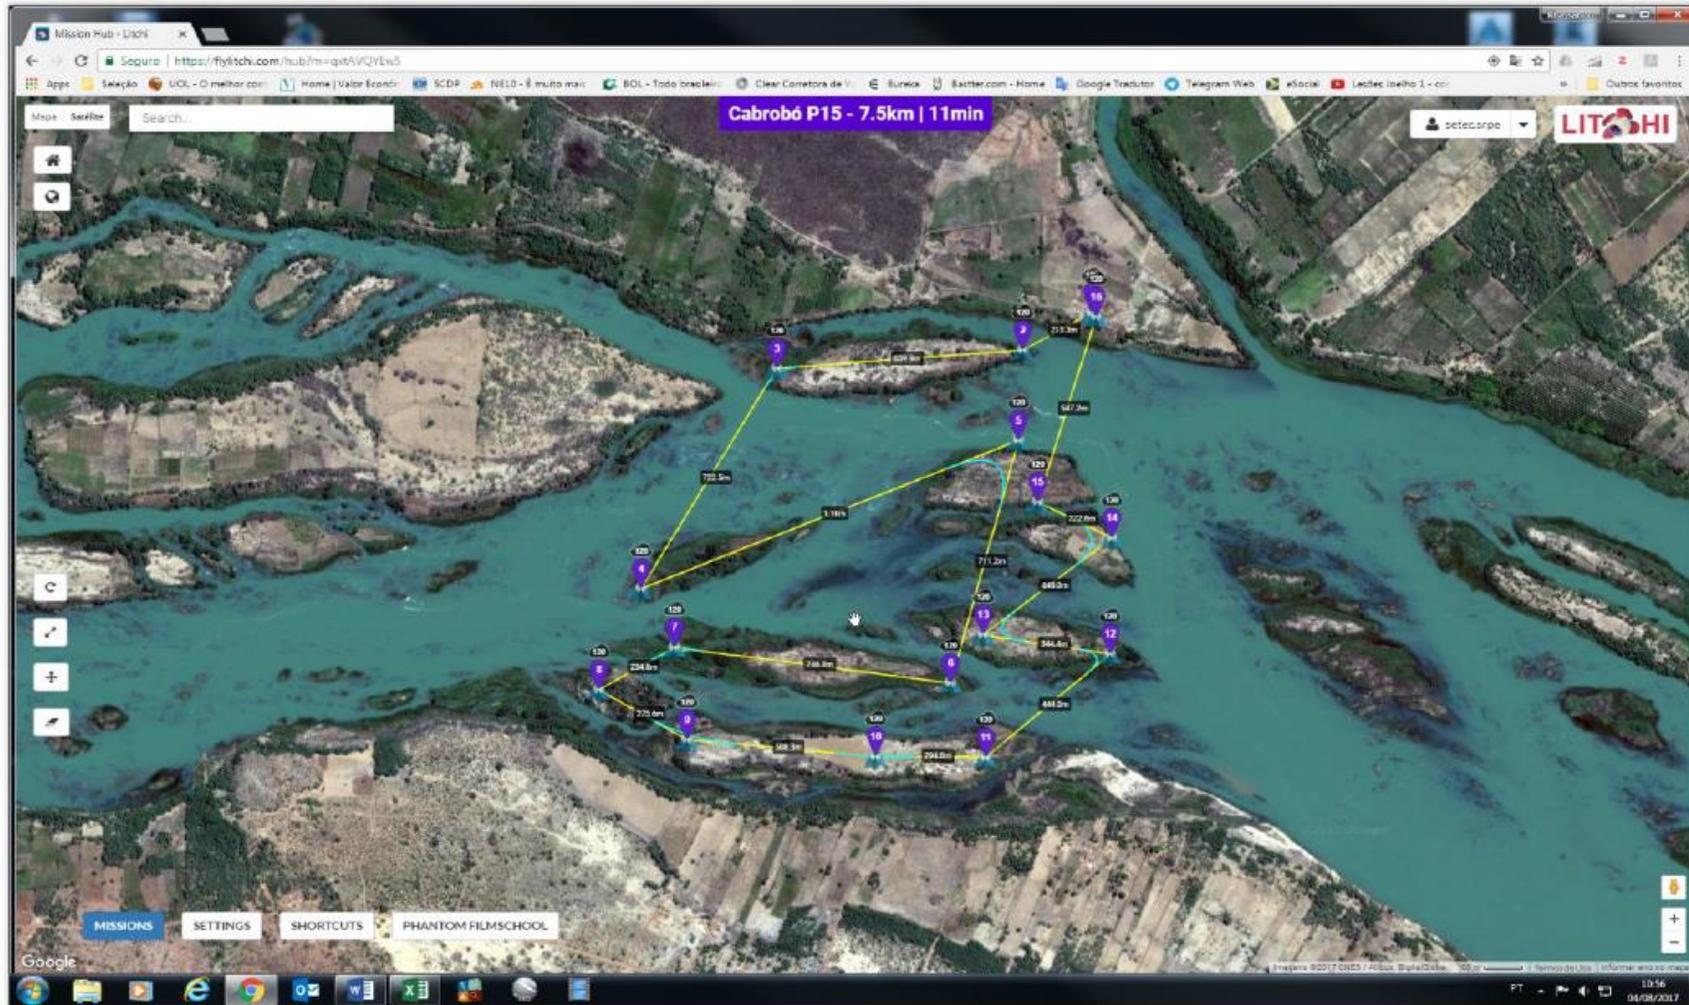
34) Cabrobó P13



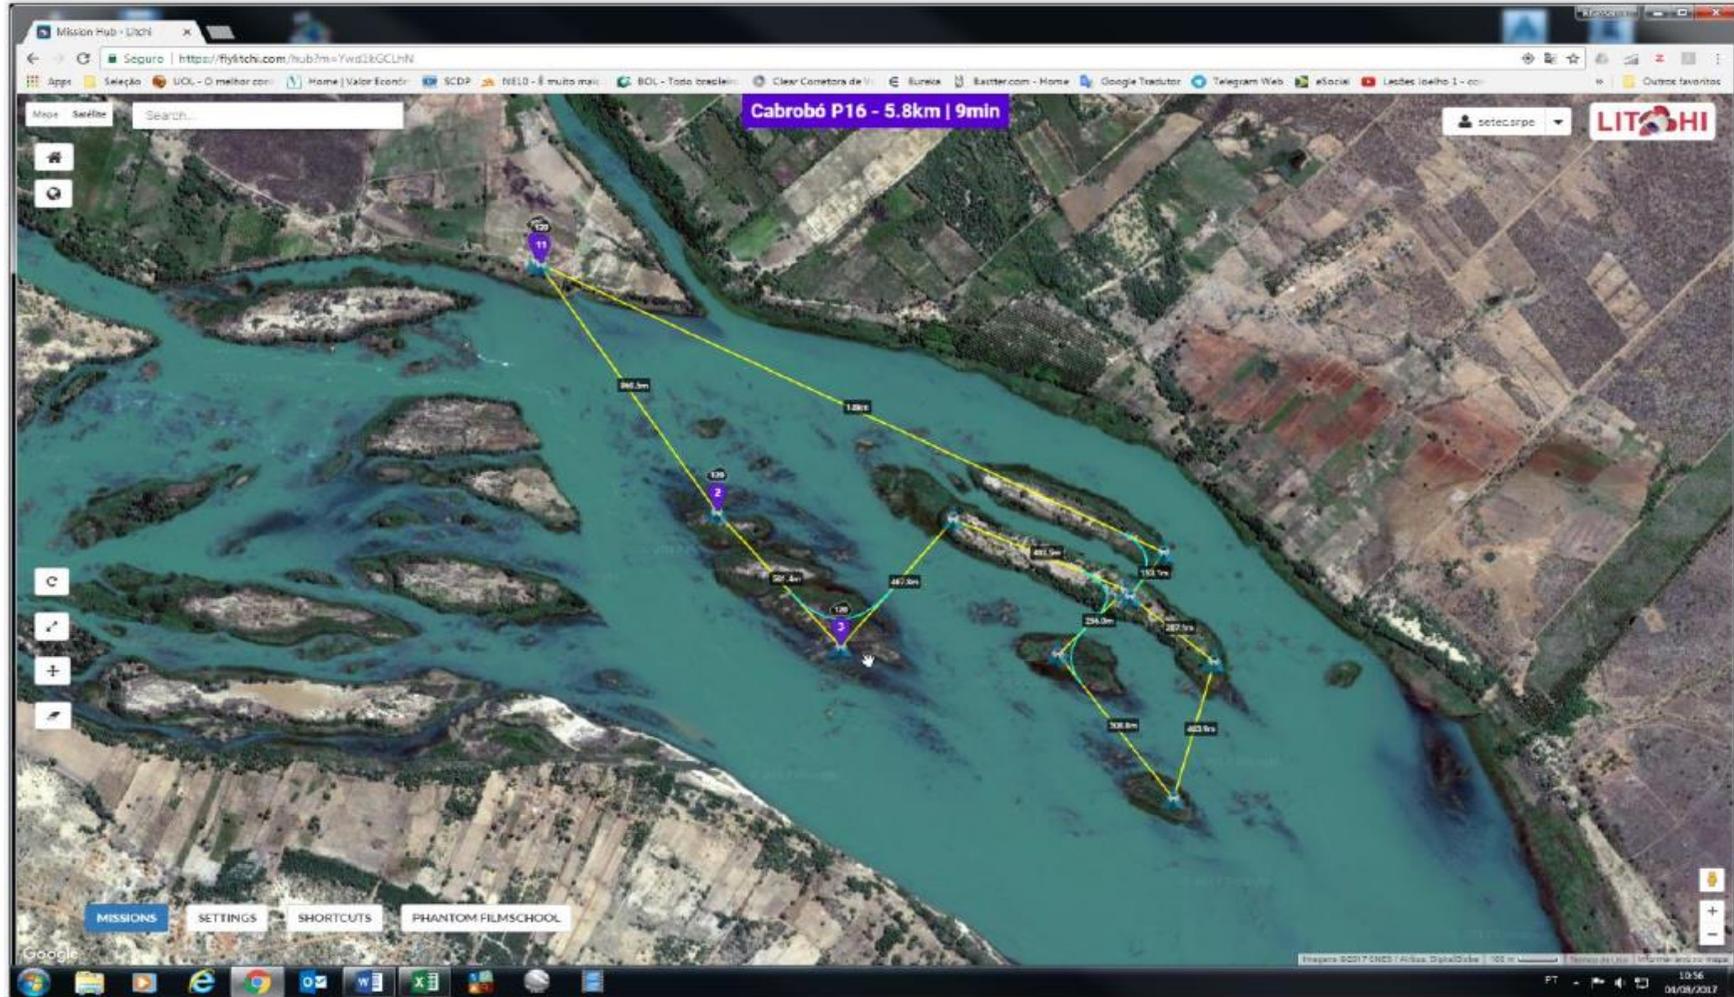
35) Cabrobó P14



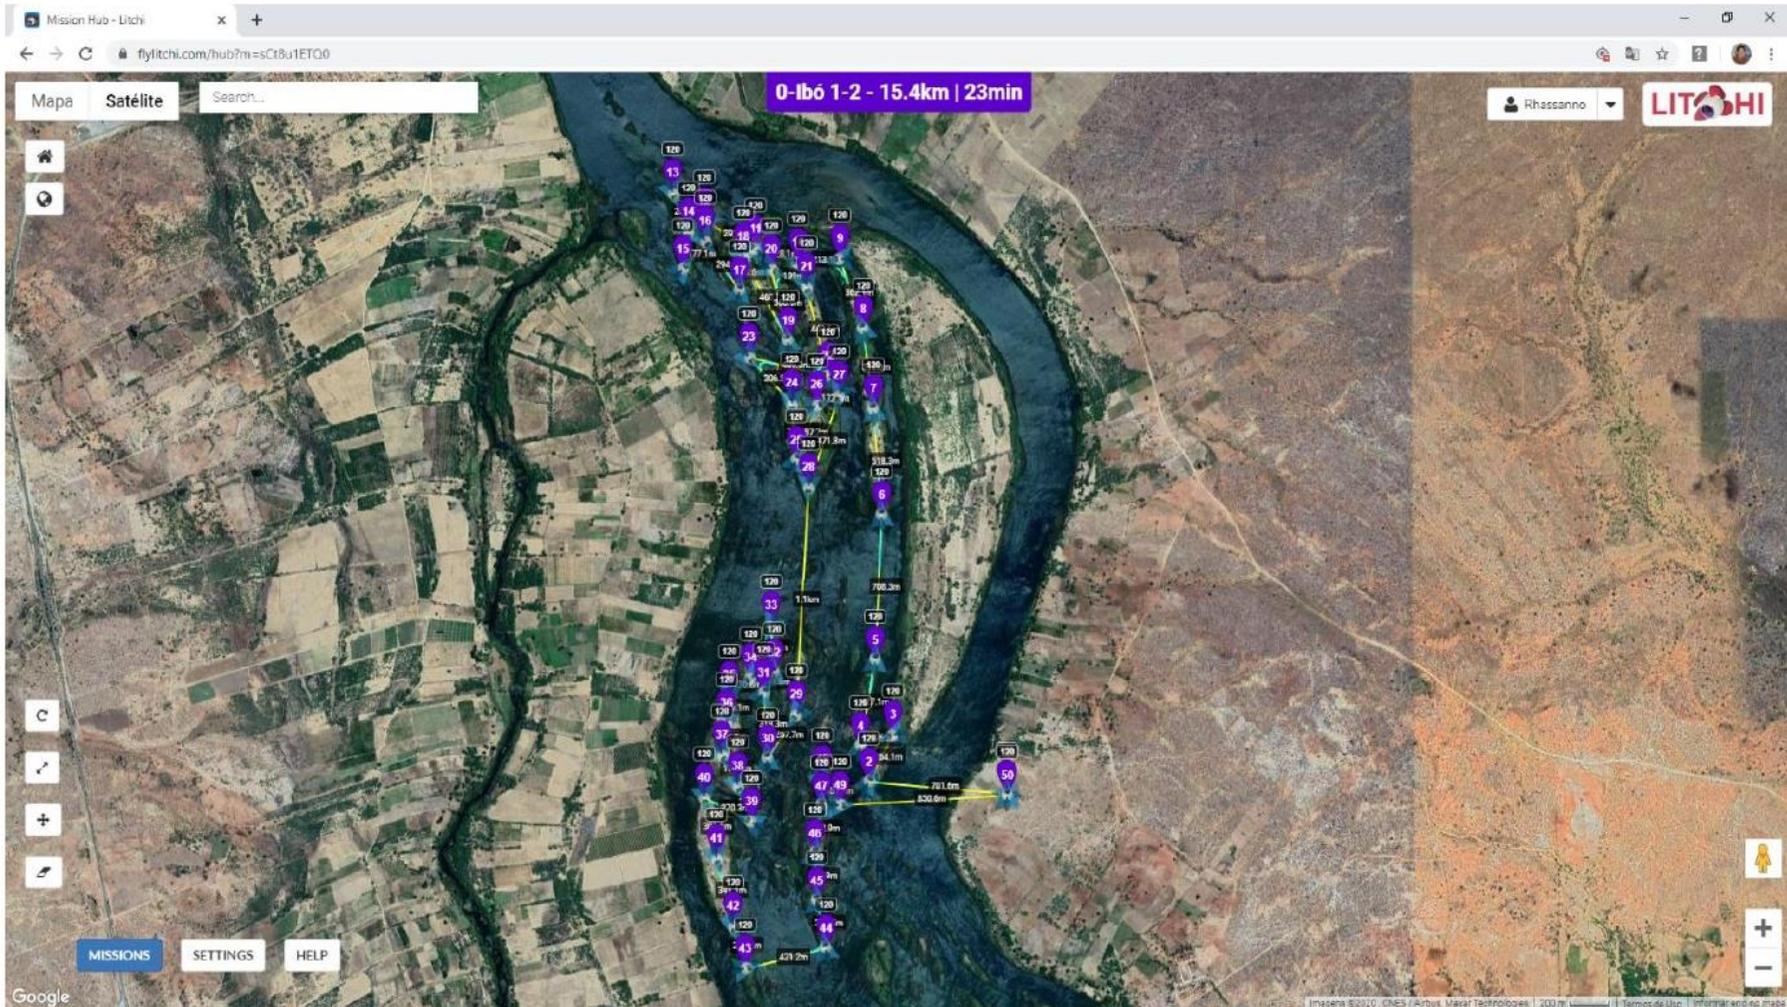
36) Cabrobó P15



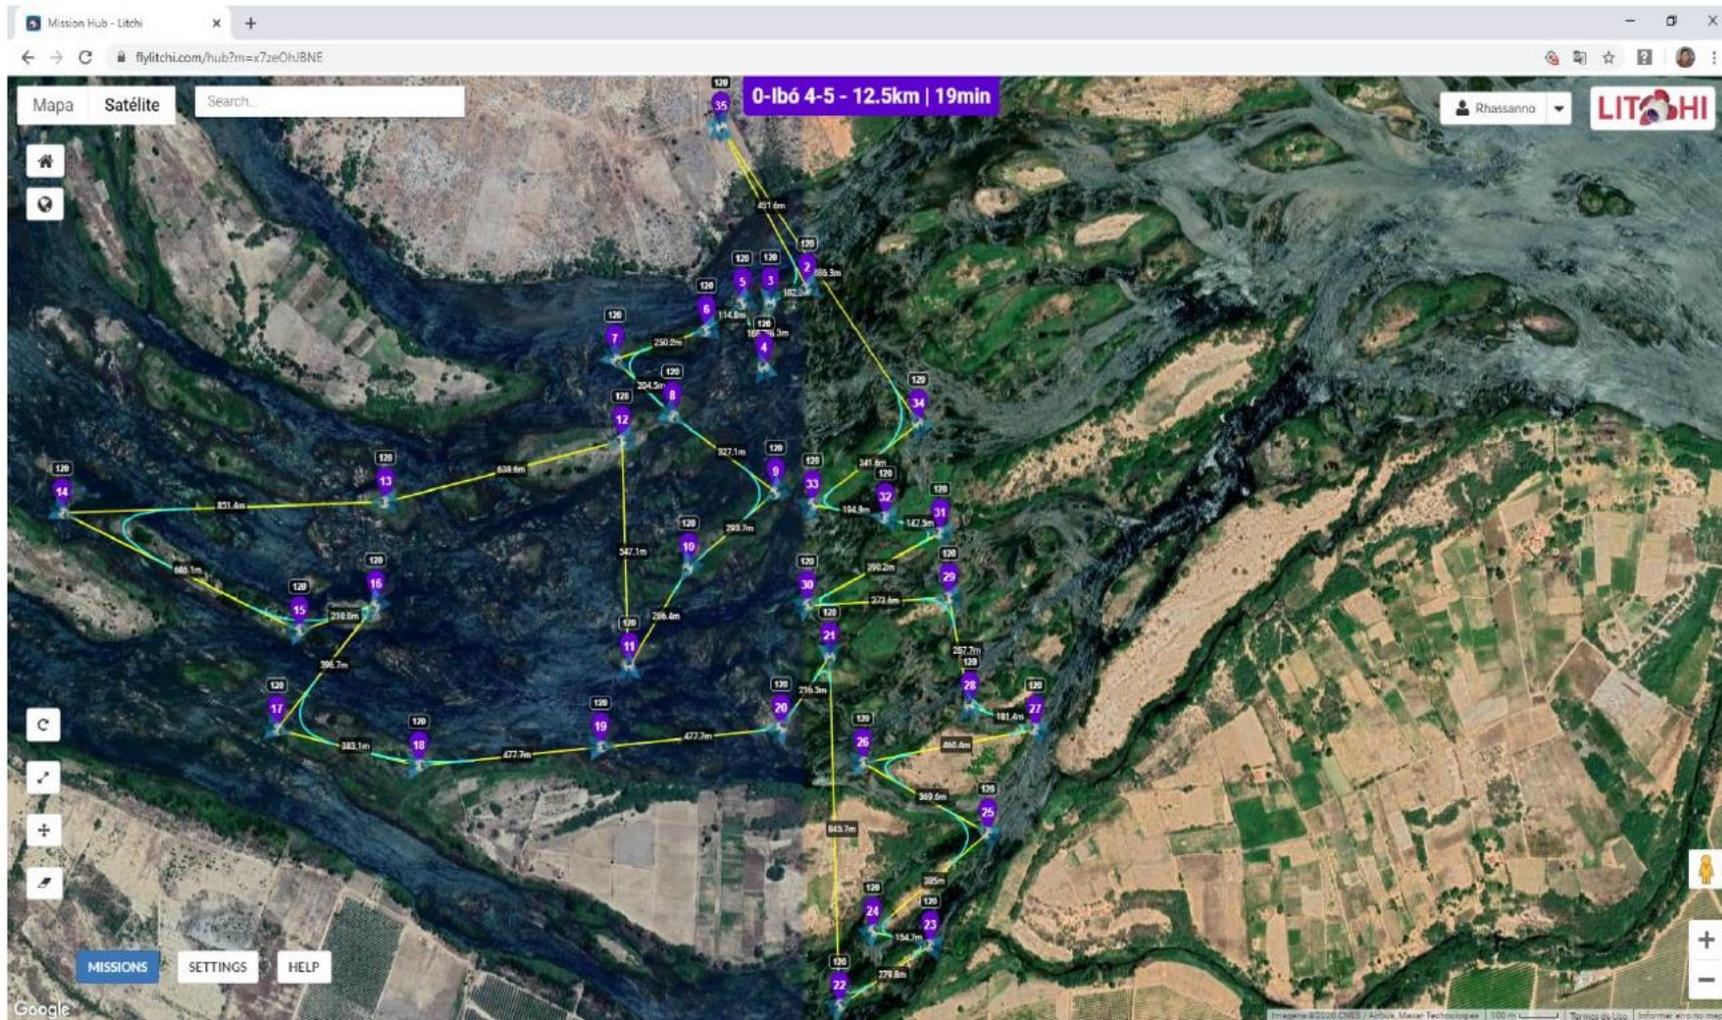
37) Cabrobó P16



38) lbó 01-02



40) lbó 04-05



41) Ibó 06-07

