conbea

LI CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA

NovasTecnologias de inteligência Artificial, drones e sensores de satélite na Agricultura

EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária)

Lúcio André de Castro Jorge

lucio.jorge@embrapa.br

2023

Embrapa Instrumentação

Automation, Precision Agriculture, Nanotecnology, ...

National Nanotecnology Lab for Agriculture

National Precision Agriculture

LANAPRE – Precision Farming Lab


Rainfall
Connected
Location Map
10
6
8.5
9
7.1
3
12
7
8
5
4
Prev 12
15
16
17
18
19
20
21
22
Next
Nitrogen in Soil
Humidity
pH
25000 lux
Light Level
pH
NPK

Tendência evolutiva

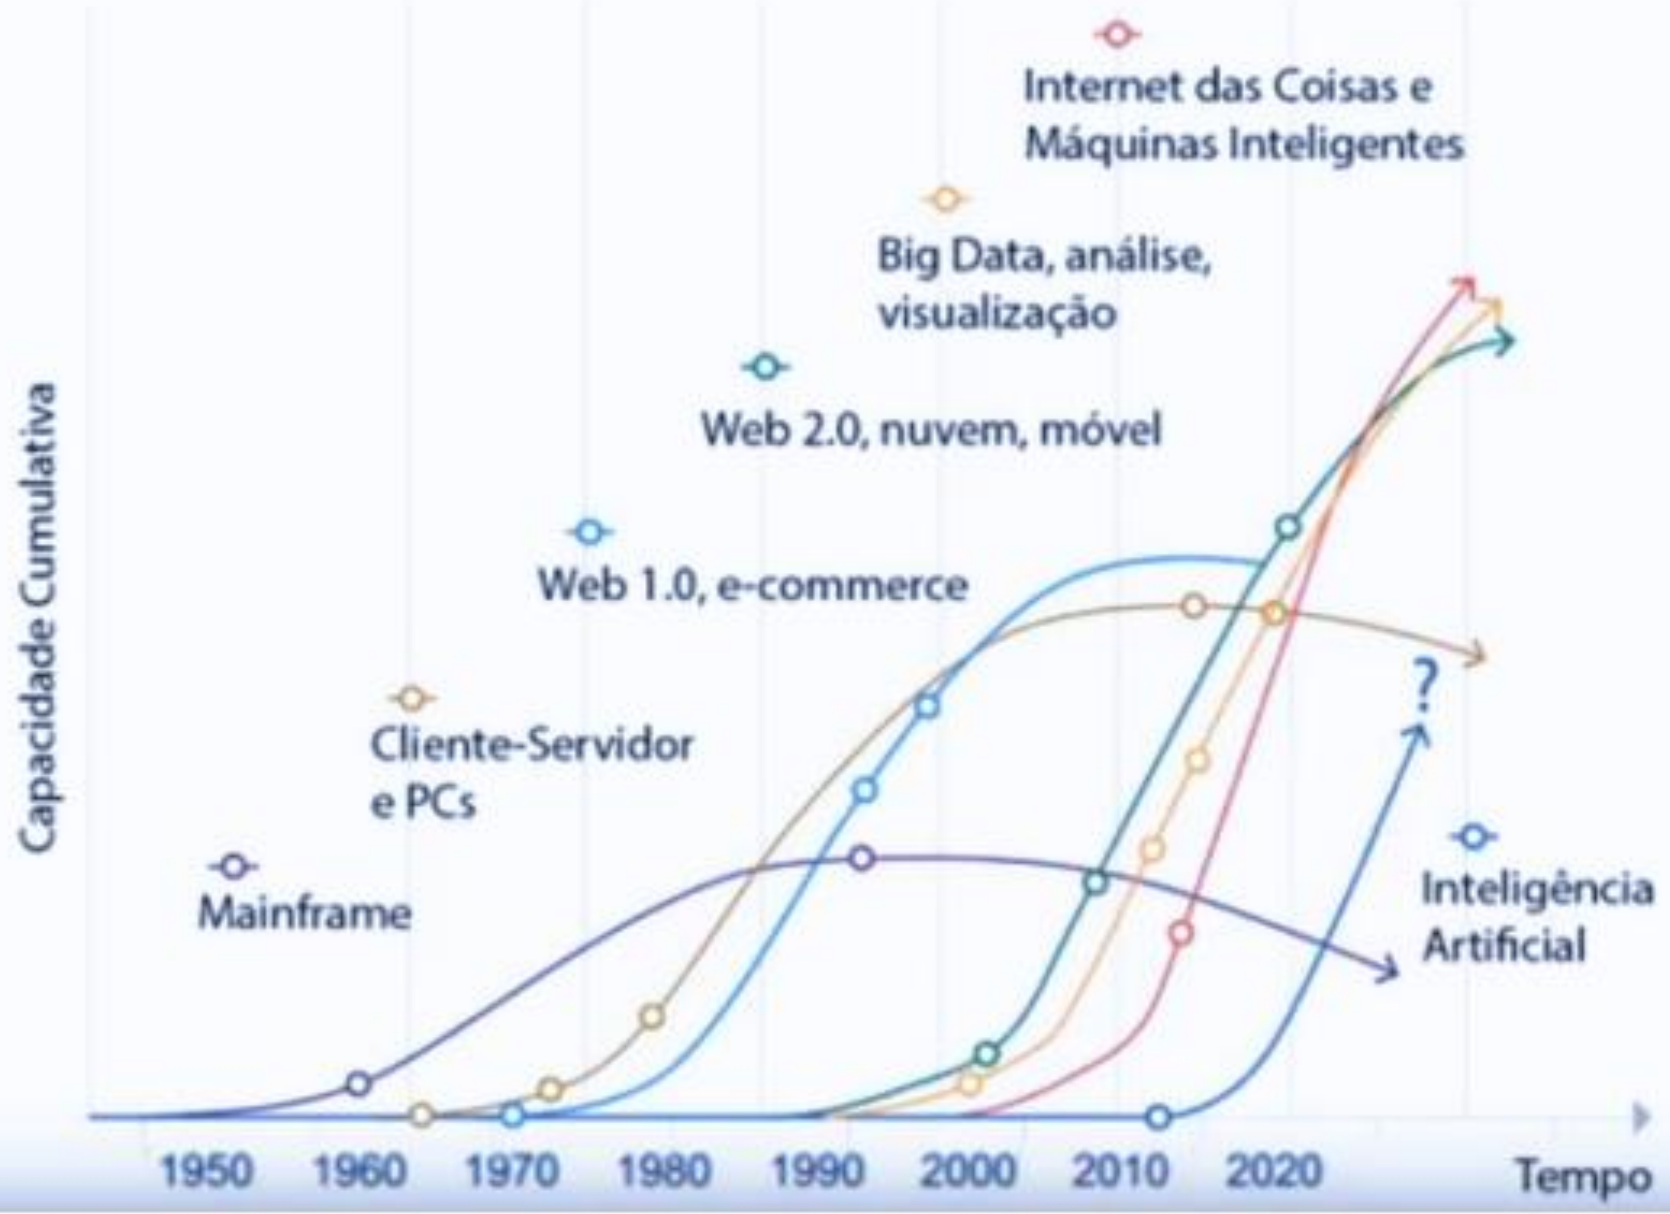

Figure 1. Hype Cycle for Emerging Technologies, 2015

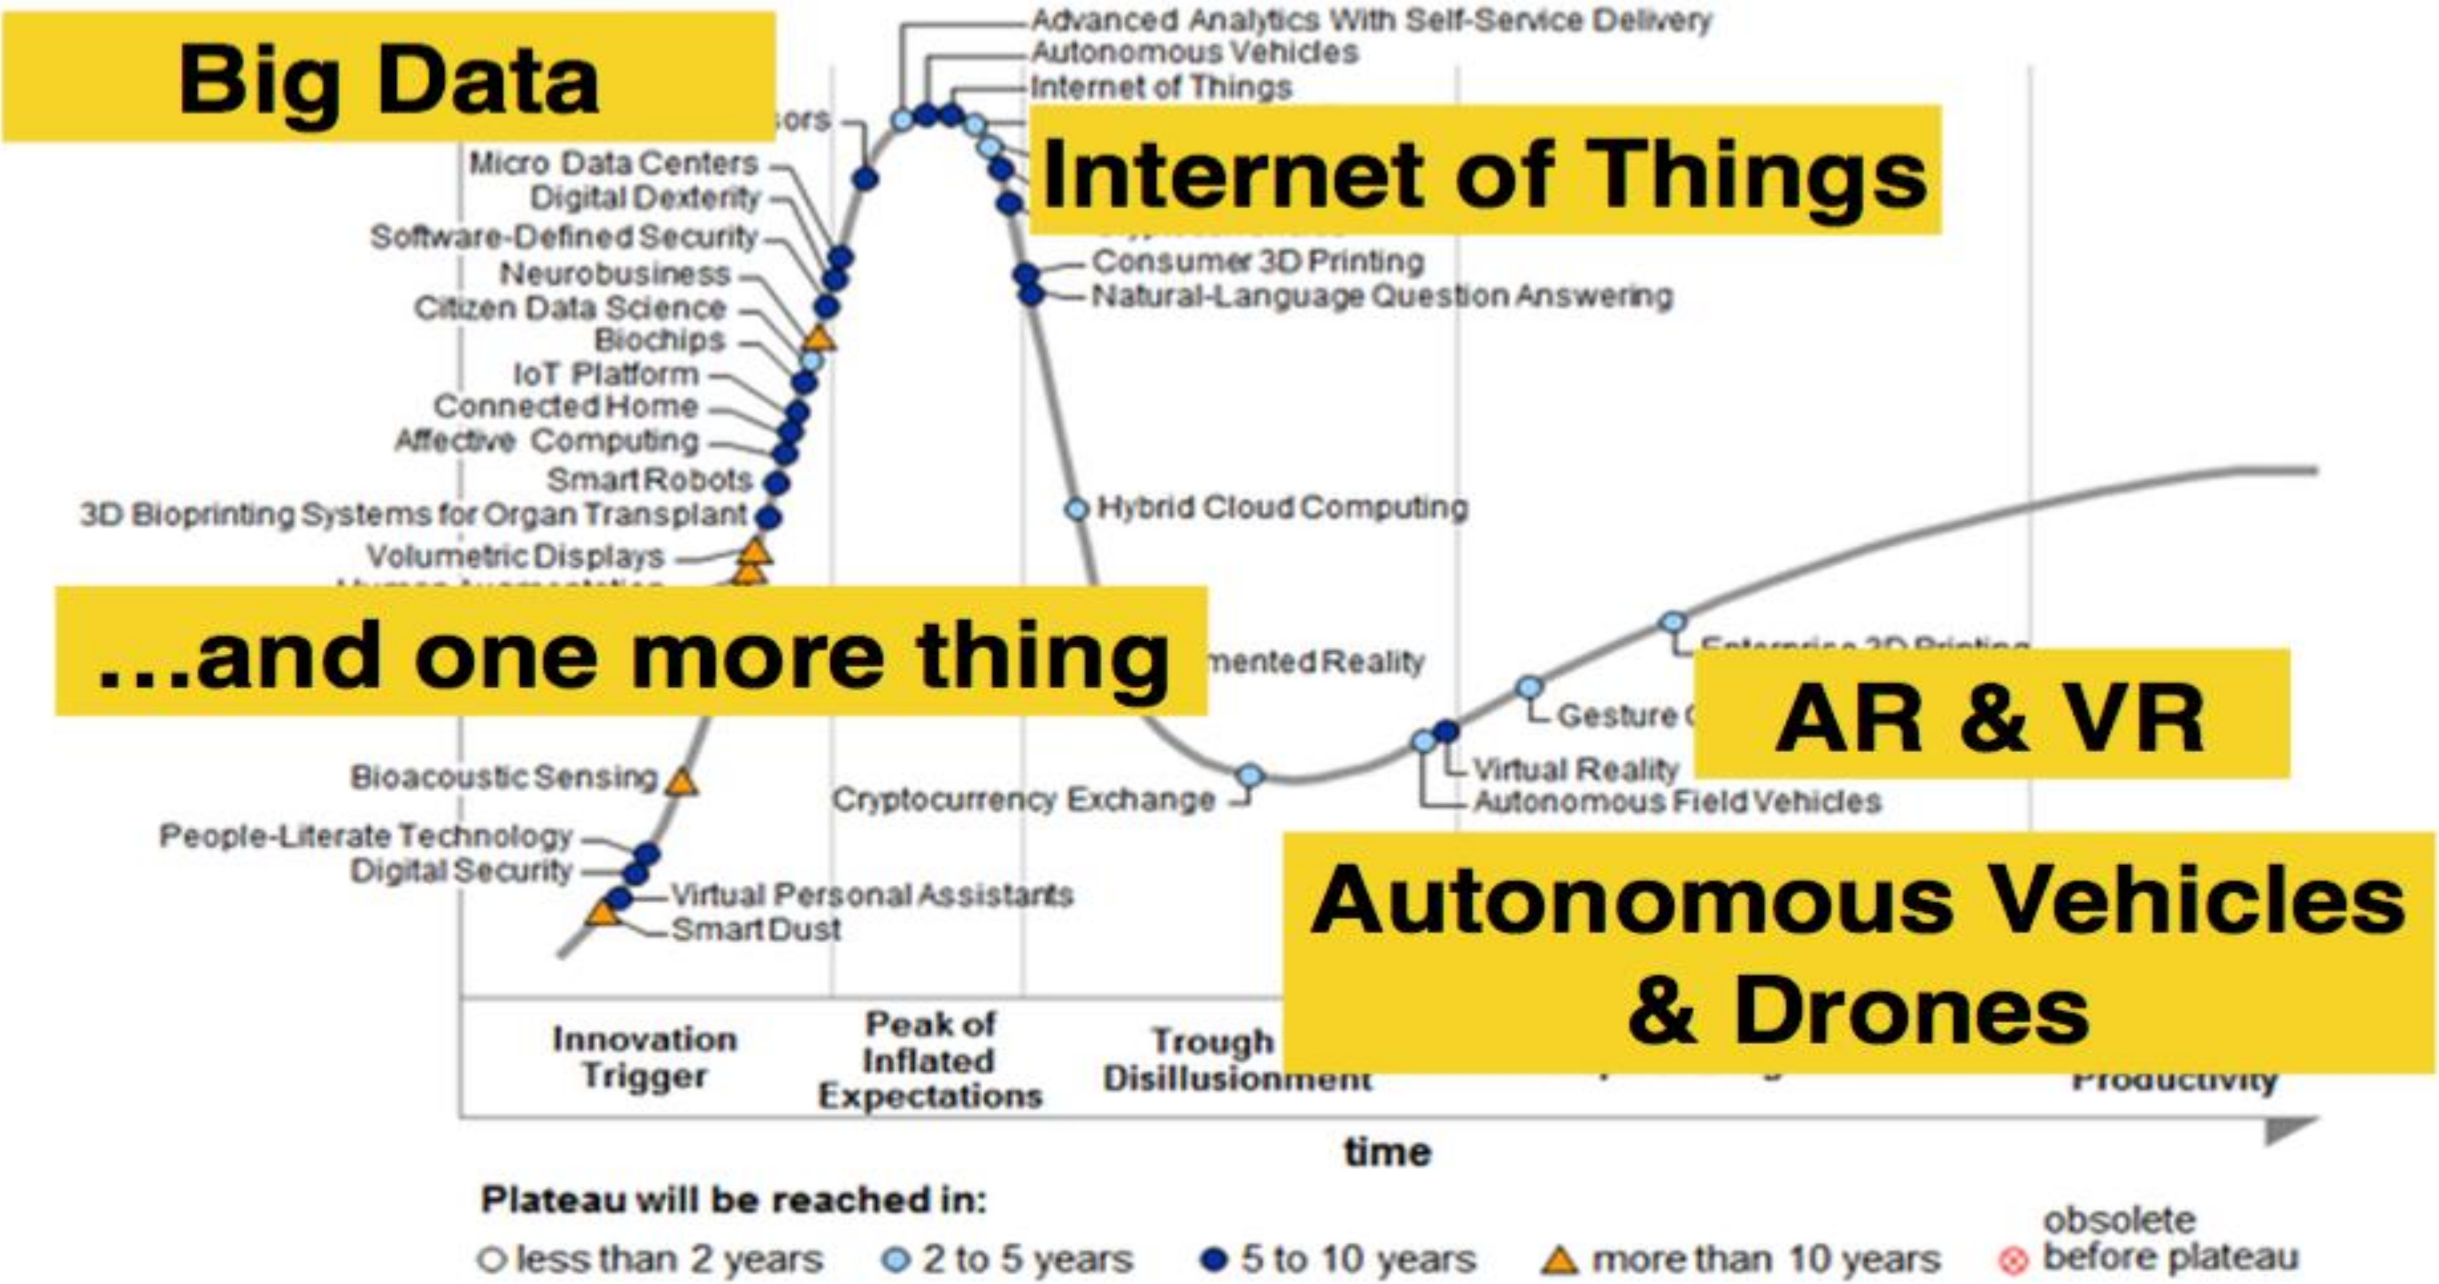

Agricultura está Evoluindo

Cada vez mais **biodiversidade** e **ambiente**.

Mono-cultura
(revolução verde)

Standardization

Produtividade e o que fazer
Com menos informações
(pesticidas, herbicidas, fertilizantes, irrigação)

Multiplas culturas

Diversification

Dinâmica Temporal e espacial

Etienne Lord, Ph.D.

Transformação de dados em conhecimento
Insigths para tomada de decisão
Agregação de valor ao produto final
Maior rentabilidade para o produtor

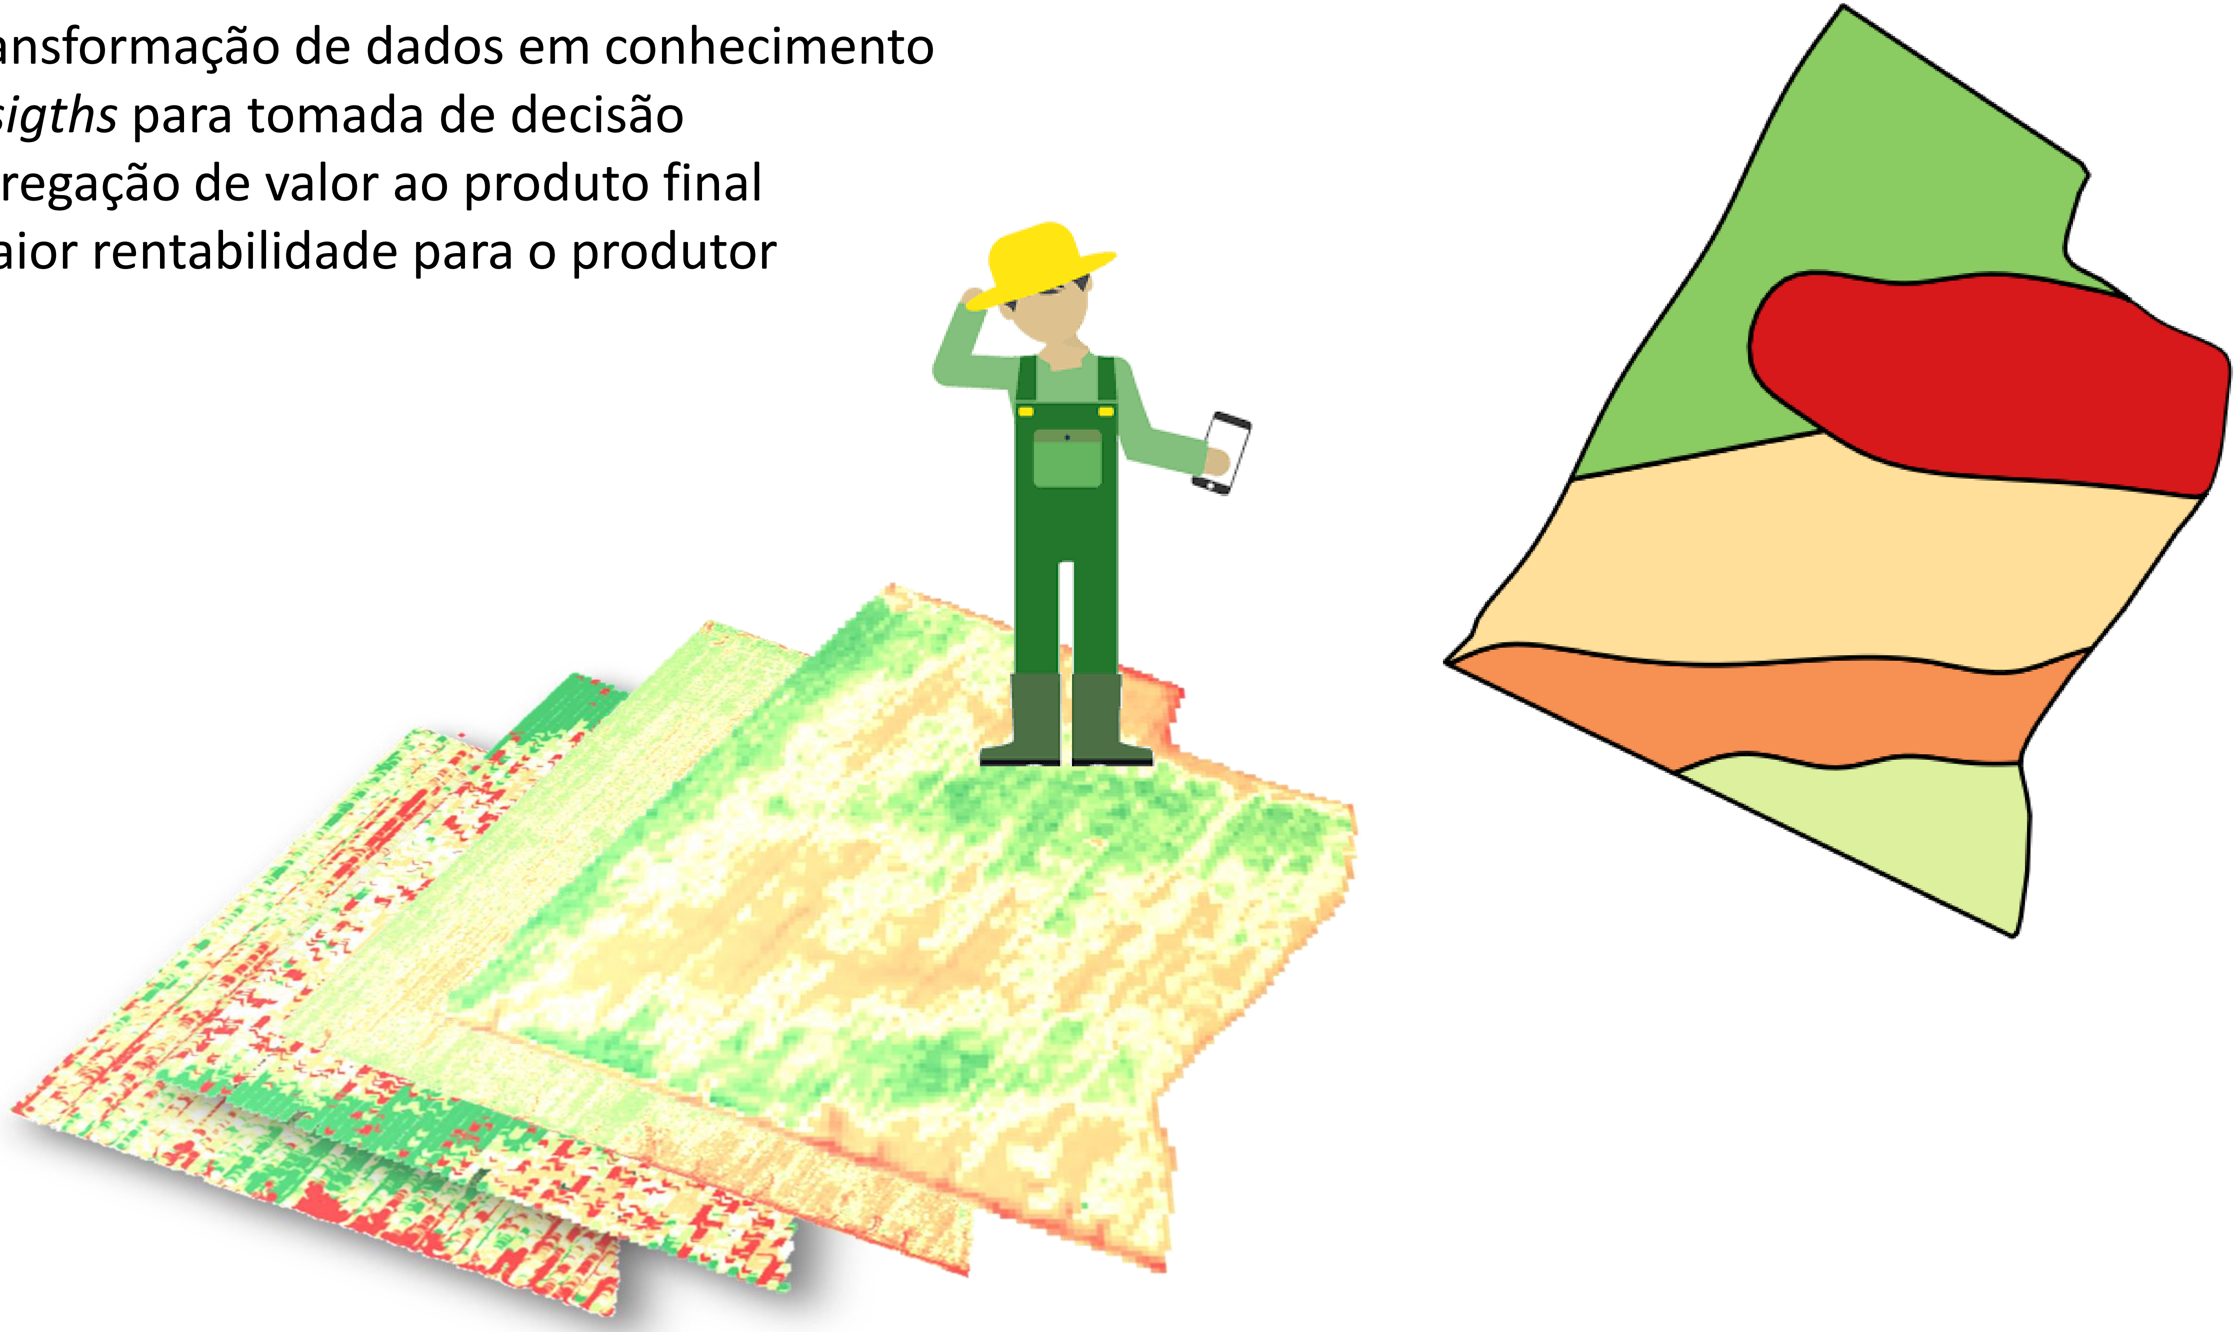

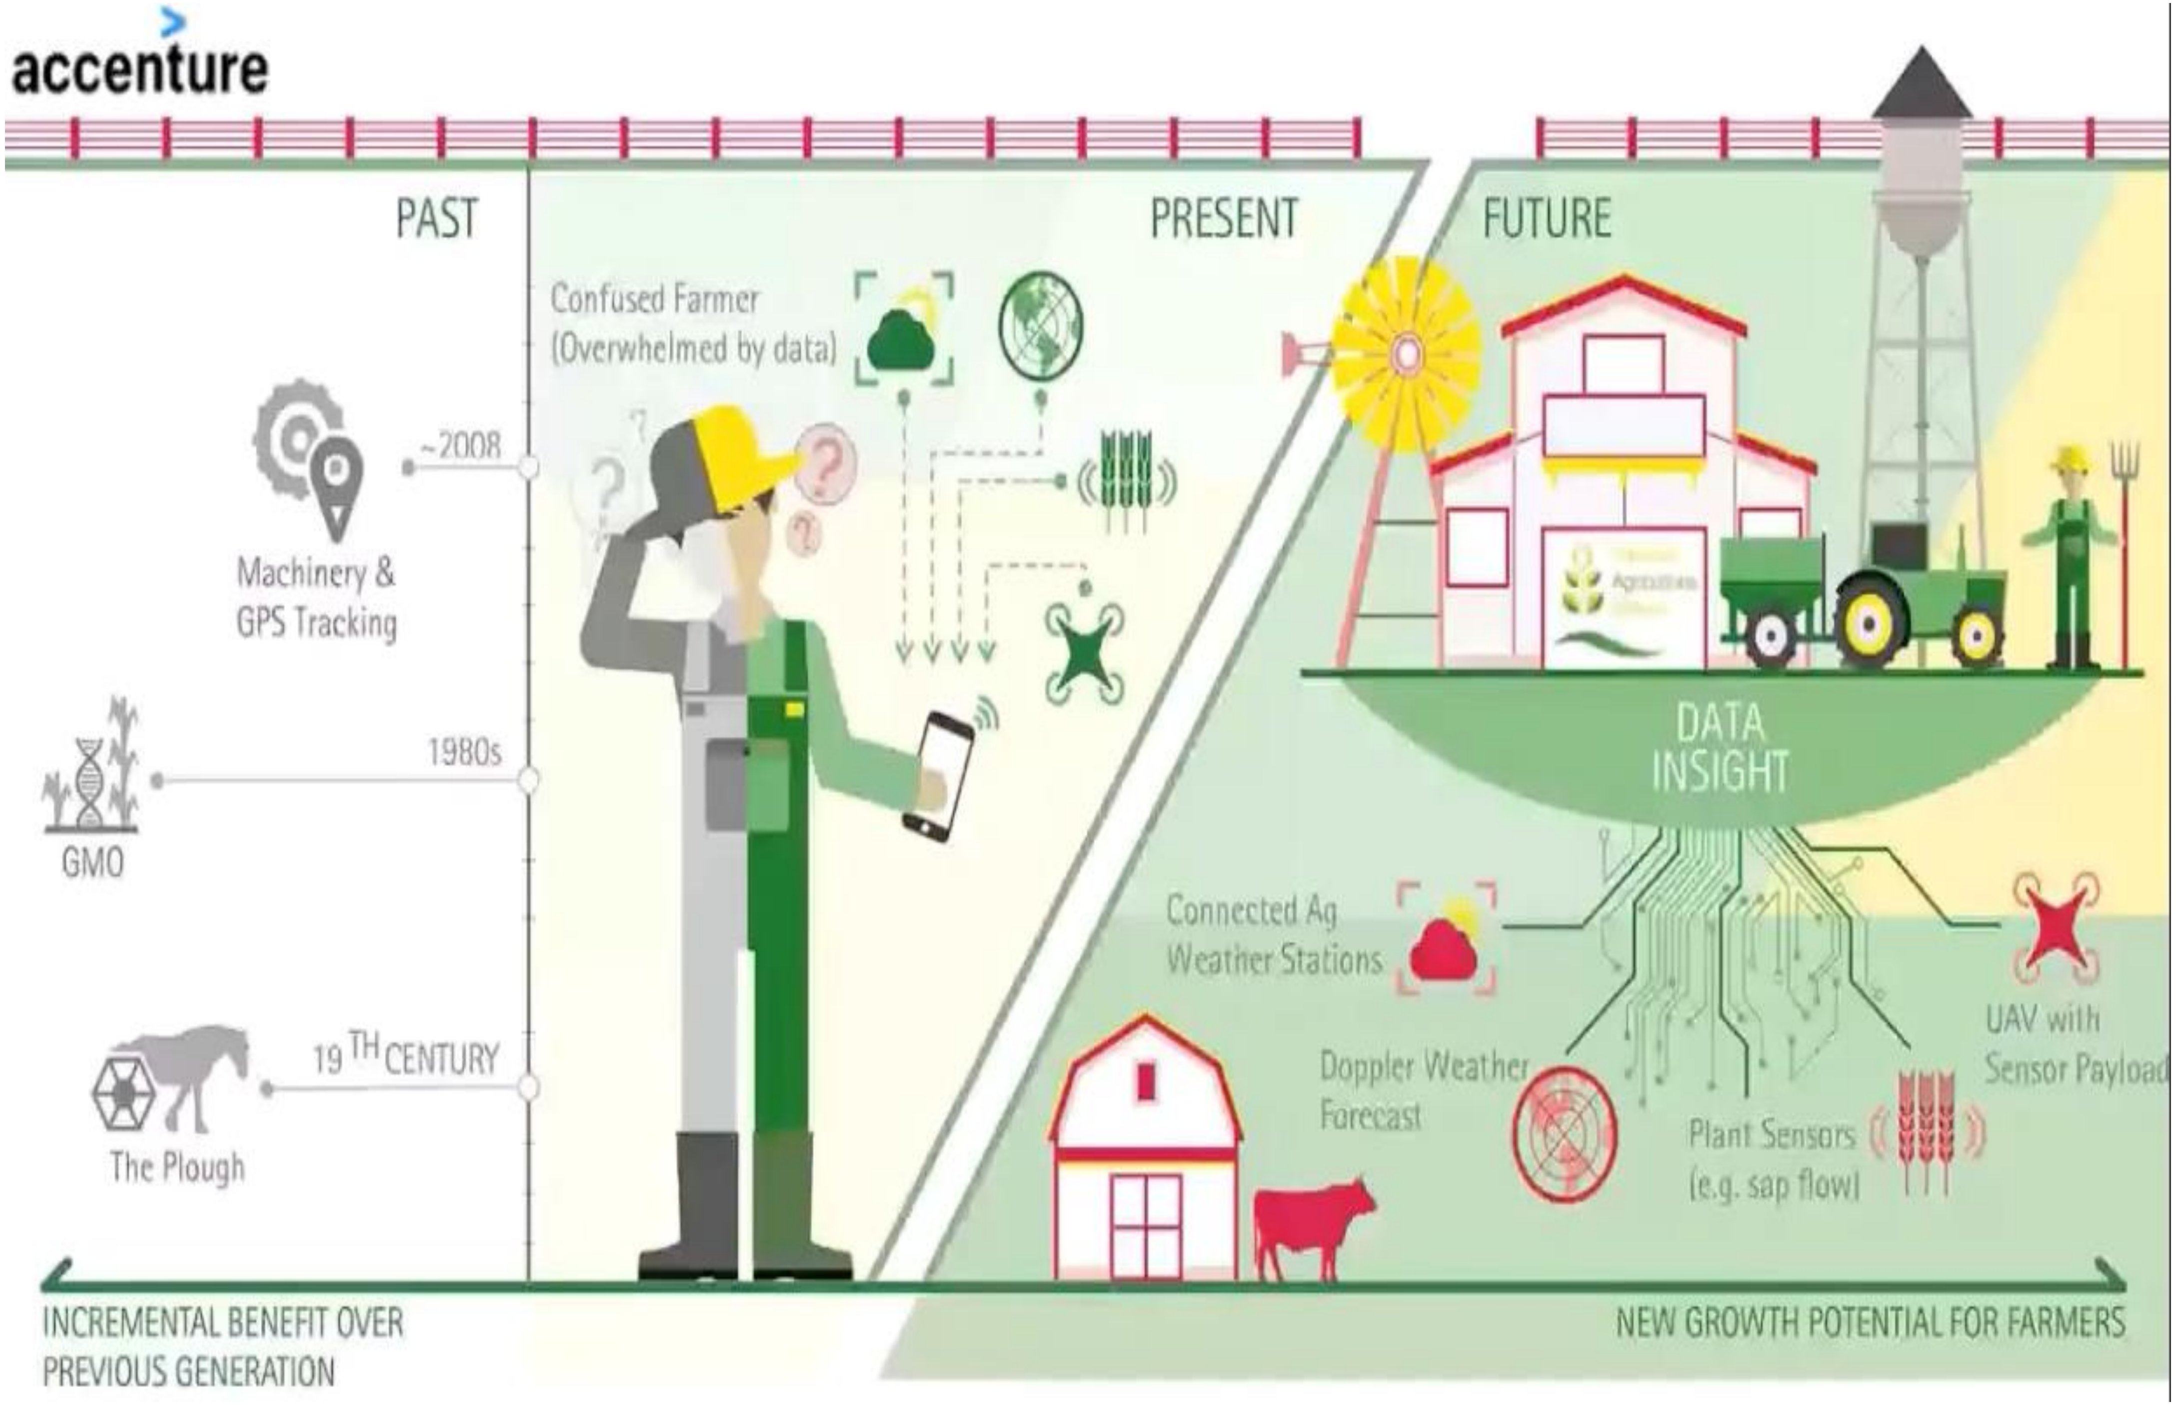
accenture
PAST
PRESENT
FUTURE
Confused Farmer
(Overwhelmed by data)
Machinery &
GPS Tracking
~2008
GMO
1980s
The Plough
19 TH CENTURY
DATA
INSIGHT
Connected Ag
Weather Stations
Doppler Weather
Forecast
Plant Sensors
(e.g. sap flow)
UAV with
Sensor Payload
INCREMENTAL BENEFIT OVER
PREVIOUS GENERATION
NEW GROWTH POTENTIAL FOR FARMERS


“Uma imagem vale
mais que mil palavras”

“Tecnologias em destaque:
Drones/ Nanosatélites
Inteligência Artificial
Robótica
IOT
Analytics”

Fazendas Agricultura Digital

Drone é mais uma ferramenta!
Tem também os nanosatélites e robôs terrestres

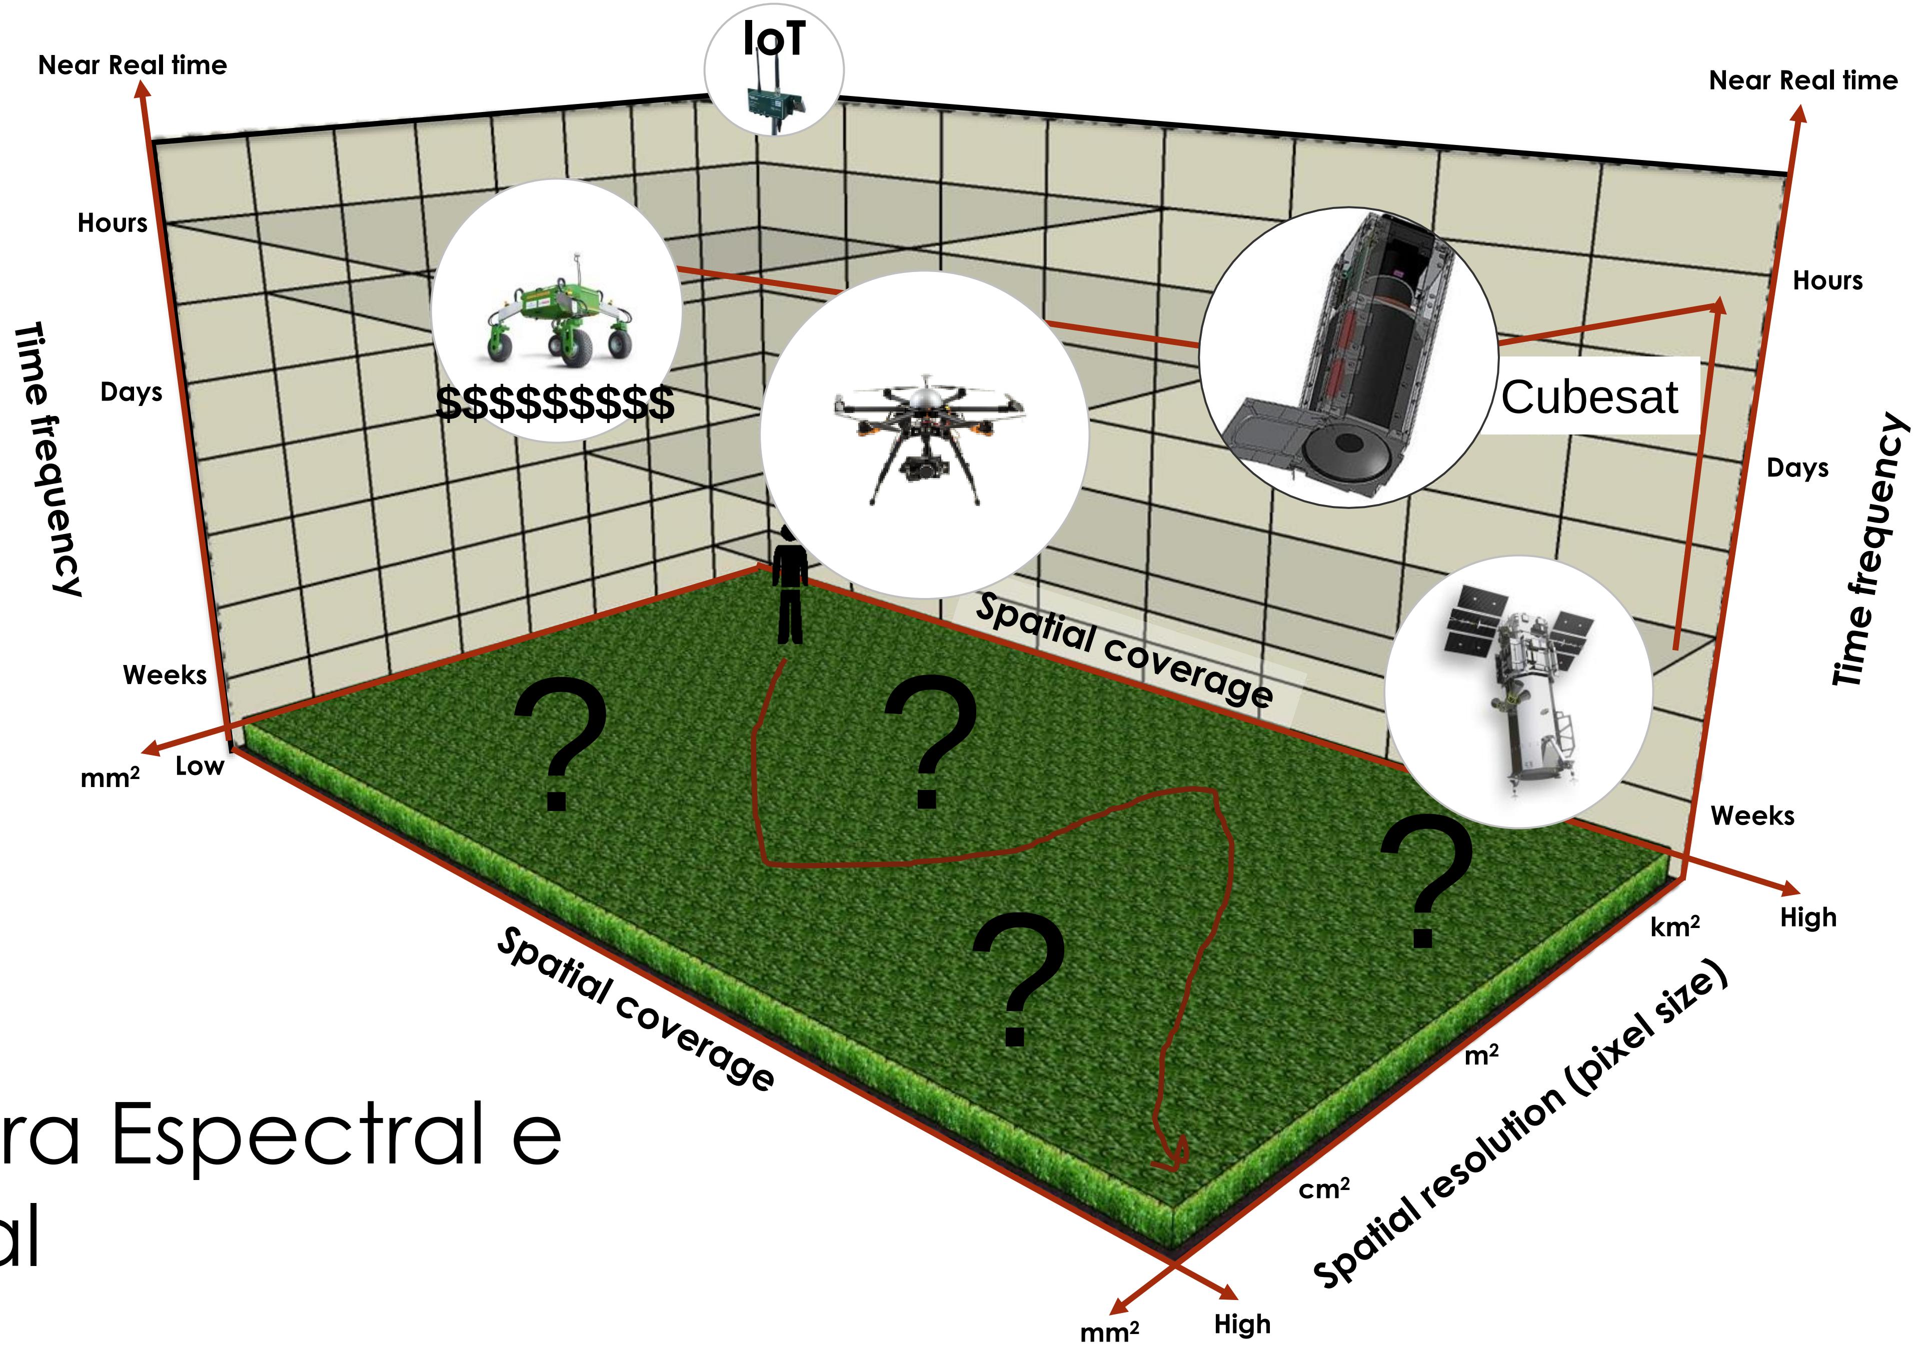

Cobertura Espectral e Temporal

Mercado de Drones no mundo

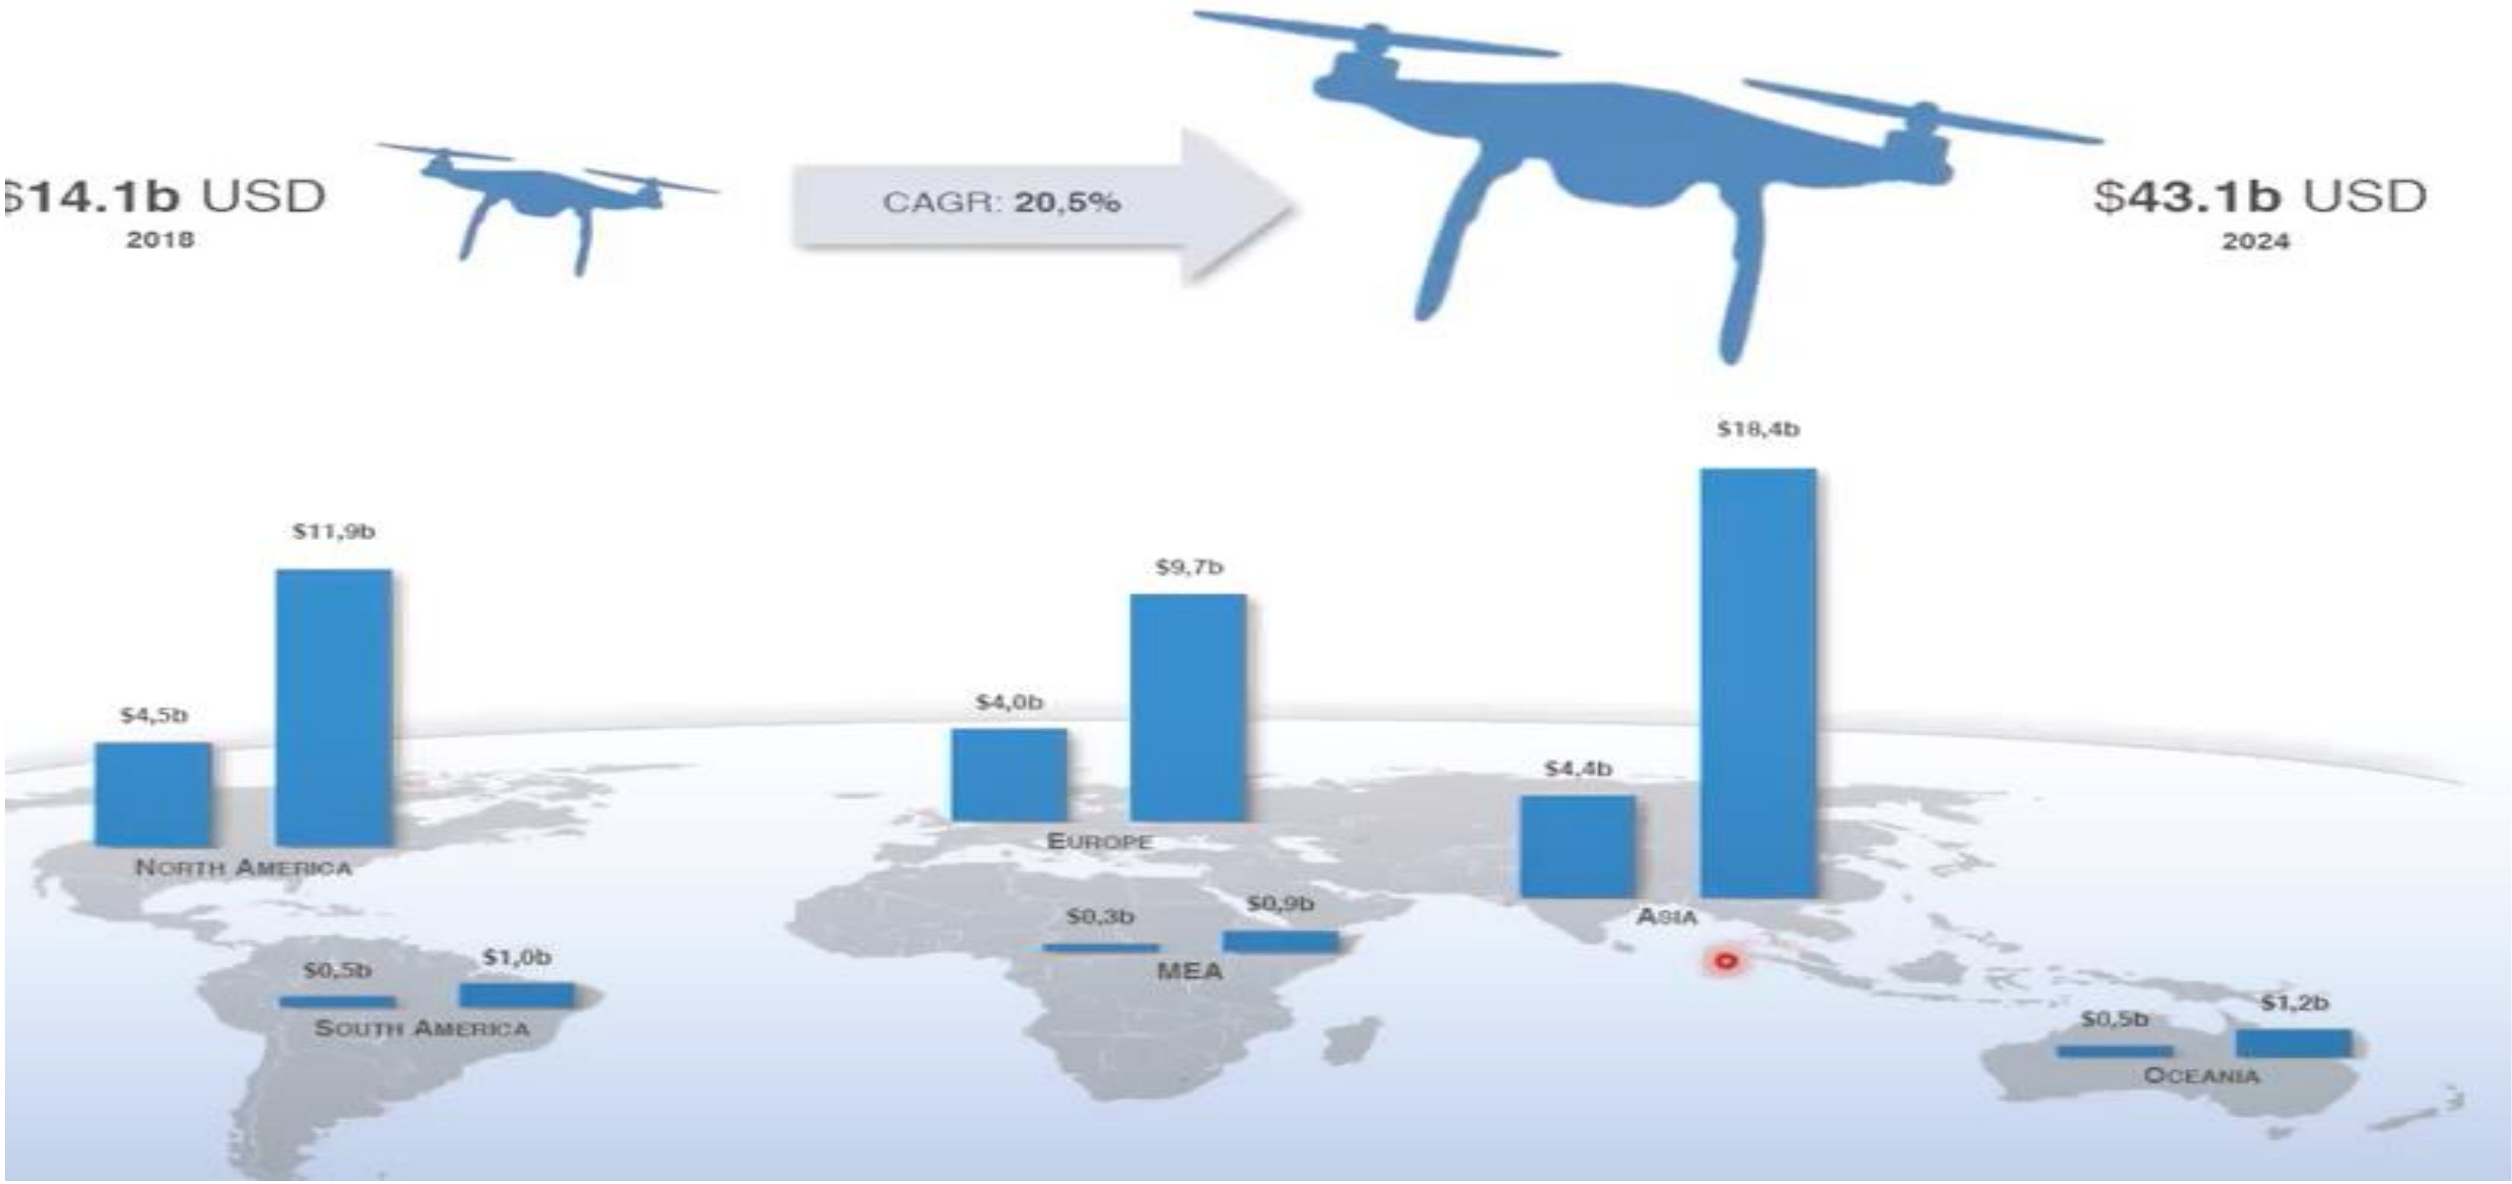

Drones no Brasil

Número de drones no Brasil → 78.304

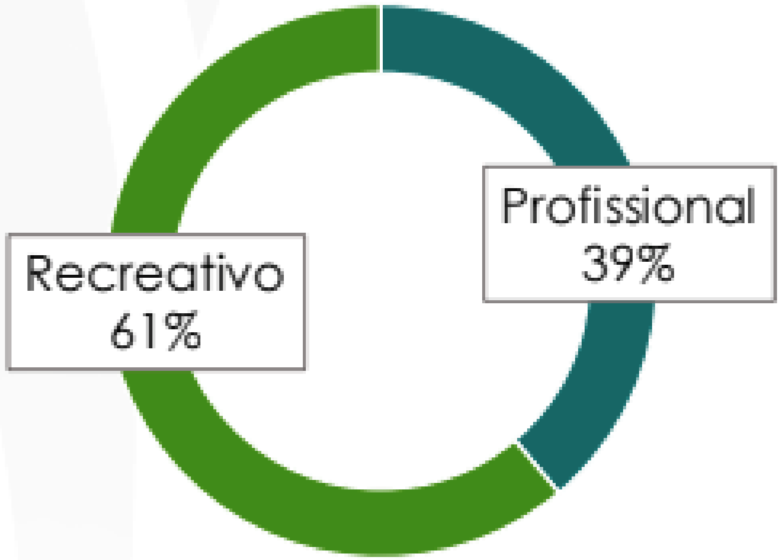

ANAC: setembro/2020

Receitas estimadas com drones no Brasil em 2020

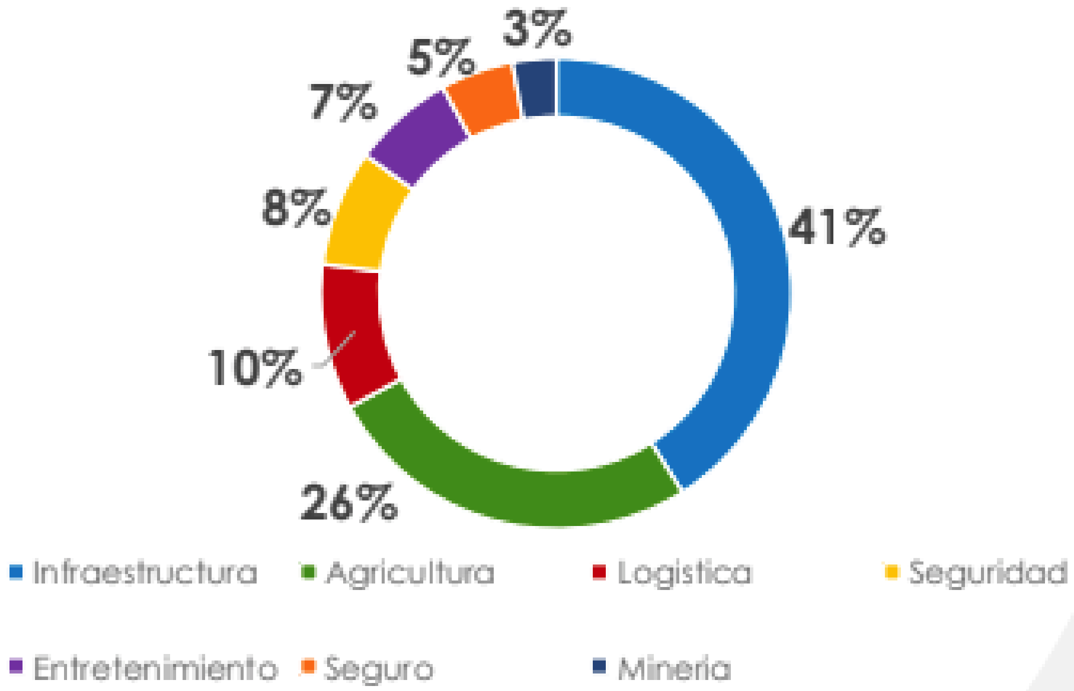

Forbes: R$ 500 milhões no Brasil em 2019.
PwC: estima que o mercado crescerá 33% em 2020.

Fabricantes
Drones, robôs,
Satélites

Inteligência
Artificial

Consultorias
em AP

Empresas
Máquinas
agrícolas

Cooperativas

Empresas
prestadoras
de
Serviço
Agricultura
Digital

Fazendas

Empresas do IA
exterior

CAPA | AGRICULTURA DIGITAL

agriculture

MDPI

Article

Precision and Digital Agriculture: Adoption of Technologies and Perception of Brazilian Farmers

Édson Luis Bolfe [1,2,*], Lúcio André de Castro Jorge [3], Ieda Del'Arco Sanches [4], Ariovaldo Luchiari Júnior [1], Cinthia Cabral da Costa [3], Daniel de Castro Victoria [1], Ricardo Yassushi Inamasu [3], Célia Regina Grego [1], Victor Rodrigues Ferreira [5] and Andrea Restrepo Ramirez [5]

Received: 19 November 2020; Accepted: 17 December 2020; Published: 21 December 2020

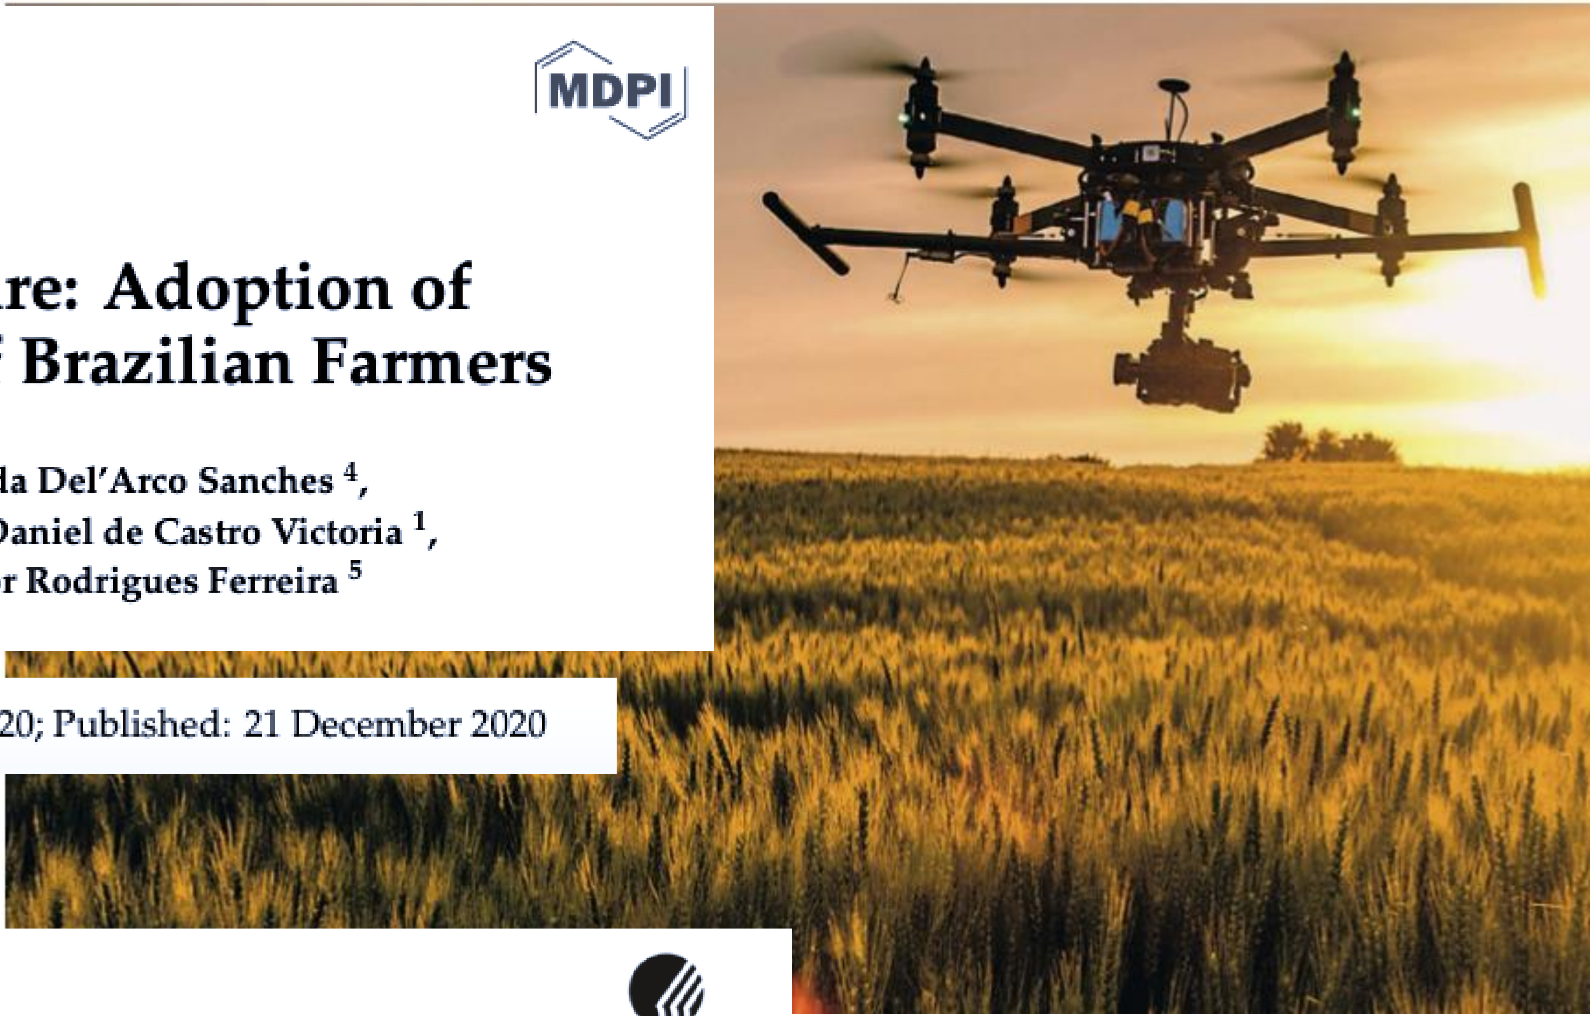

REVISTA GLOBO RURAL

globorural.globo.com

A PALAVRA DO CAMPO

GLOBORURAL

ISSN 0102-6178

AGOSTO 2020 | Nº 418 | R$ 16,00

CARGA TRIBUTÁRIA FEDERAL APROXIMADA 4,65%

EDITORA GLOBO

Soluções oferecidas

44%

Softwares de gerenciamento de fazendas, drones e sensores (IoT – Internet of the things): sistemas para otimização da produção agropecuária e utilização de hardware (drones e sensores) para gestão.

22%

Plataformas de comercialização: plataformas, aplicativos e sistemas de vendas de produtos ou insumos agropecuários

15%

Gestão de Dados Agrícolas e Analytics: tecnologias de suporte à decisão para agricultura de precisão como organização e controle das atividades, dos gastos e produtividade em cada área.

Fonte: Associação Brasileira de Startups (Abstartups). Ebook Agetch

Soluções oferecidas

9%

Plataformas de rastreabilidade e segurança alimentar:
plataformas, aplicativos e sistemas para controle de qualidade do alimento ou do processo de produção.

7%

Ferramentas de comunicação e interação:
Sistemas que facilitam troca de mensagens e informações entre produtores rurais, profissionais da área e prestadores de serviços.

3%

Biomateriais, Bioenergia e Biotecnologia:
utilização de tecnologias para desenvolvimento de soluções de irrigação, água, energia e alimentos.

Fonte: Associação Brasileira de Startups (Abstartups). Ebook Agetch

Monitoramento do Campo com imagens

Literature review
(2008-2020)

Desafios !!!

Desafios!!!

Best use for crop biophysical parameter assessment: Biomass, Crop Vigor, N management, Chl content or Deriving a LAI

Desafios !!!

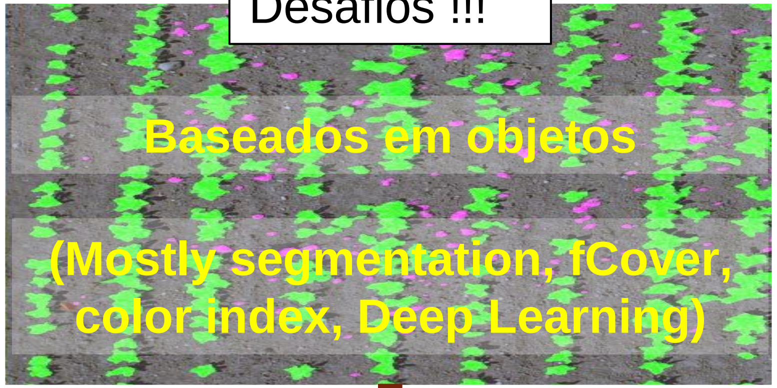

Best use for weed monitoring, crop traits, growth monitoring; fresh biomass and Yield

Philippe Vigneau

Escolha requer Tempo, Esforço e Conhecimento

Plataforma certa?

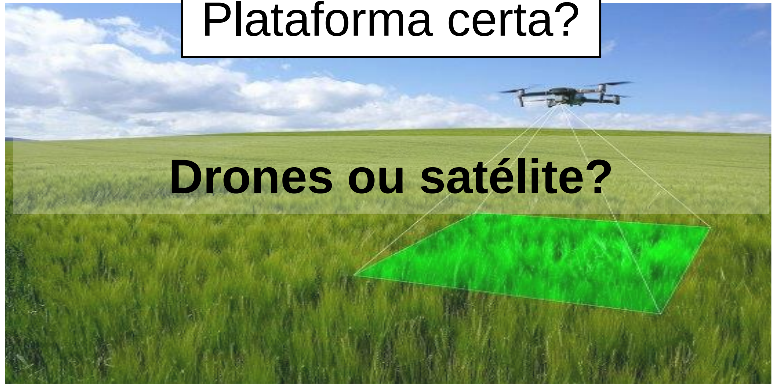

Drones ou satélite?

sensor certo

Desafios!!!

resolução alta (pure pixels vs misturas)

(bandas co-registradas)

Métodos óticos

Desafios!!!

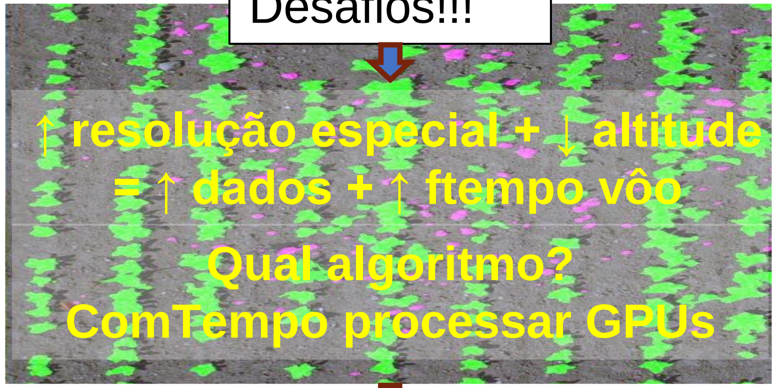

↑ resolução especial + ↓ altitude = ↑ dados + ↑ ftempo vôo

Qual algoritmo?

ComTempo processar GPUs

Métodos por objetos

Philippe Vigneau

Desafios com Sensores

- Imagens **melhor forma de obter as informações ?**
  - **Identificar com precisão doenças, pragas etc**
  - **Contar e characterizar (produtividade, volume, qualidade)**
  - **Multiplas culturas**
  - **Mudanças Climáticas (series temporais)**
  - **Treinamento fácil para novas culturas/cultivares**
  - **Uma classe, uma vez → multiplas-classes, multi-temporal**
  - **Annotações manuais para grande volume informações**

Etienne Lord, Ph.D.

Considerar Sistemas Complexos

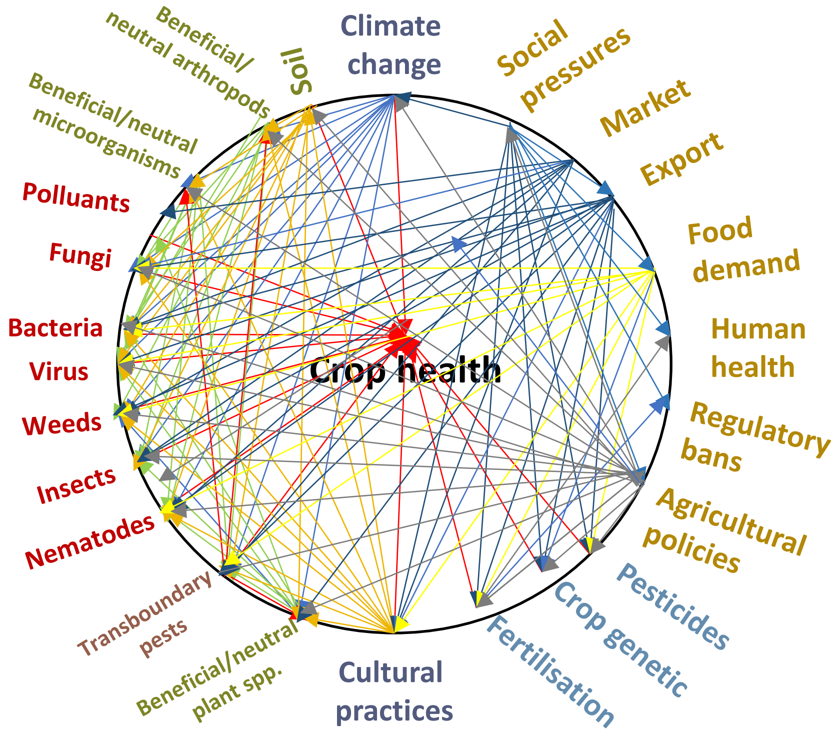

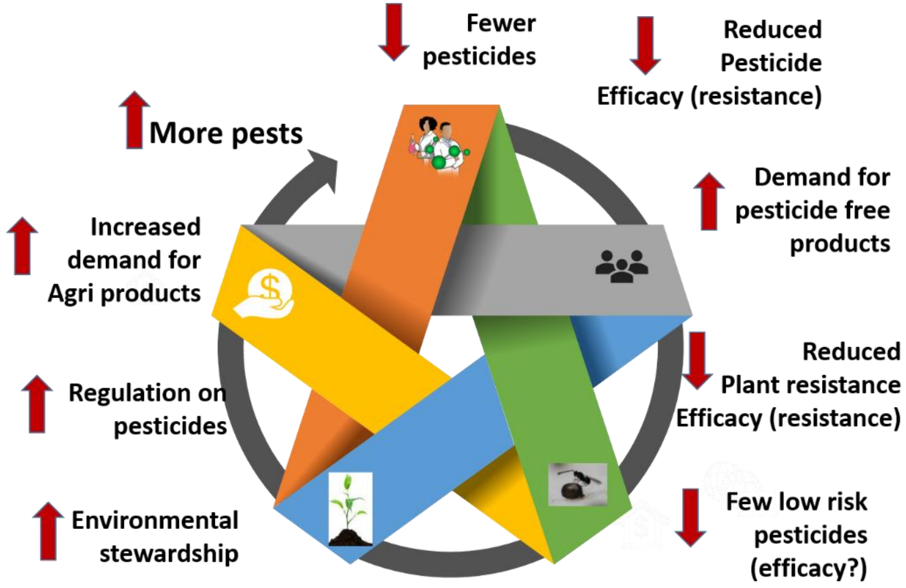

Abordagem baseada no Conhecimento (sem bola de cristal)
Muitos dados necessitam de levar em conta as interações

Desafios no treinamento de imagens

Definição dos padrões

- Imagem não é suficiente, necessita de meta-informações: tipo, volume, peso do fruto
- mais que RGB, ou seja, U.V. MicaSense, Mapir, Hyperspectral
- Necessita de info 3D, 4D da mesma maçã?
- Como informar estes padrões (base dados)?
- pixels ou regiões?
- frutas escondidas?
- GPS para cada fruta ou planta?

Etienne Lord, Ph.D.

Séries temporais de imagens

- Desafio em usar video, drones ou satélites :
  - **Perdas de images devido o clima, ocorrências**
  - **Velocidade de máquinas para contar individuos (frutas, plantas)**

50 m, 4 km/h

Questões abertas/ Melhor resolução?

- Redes neurais com series temporais
- Super-resolução para estimar perdas de dados
- Redes neurais com IoT
- Detectar somente anomalias?

Faixas espectrais

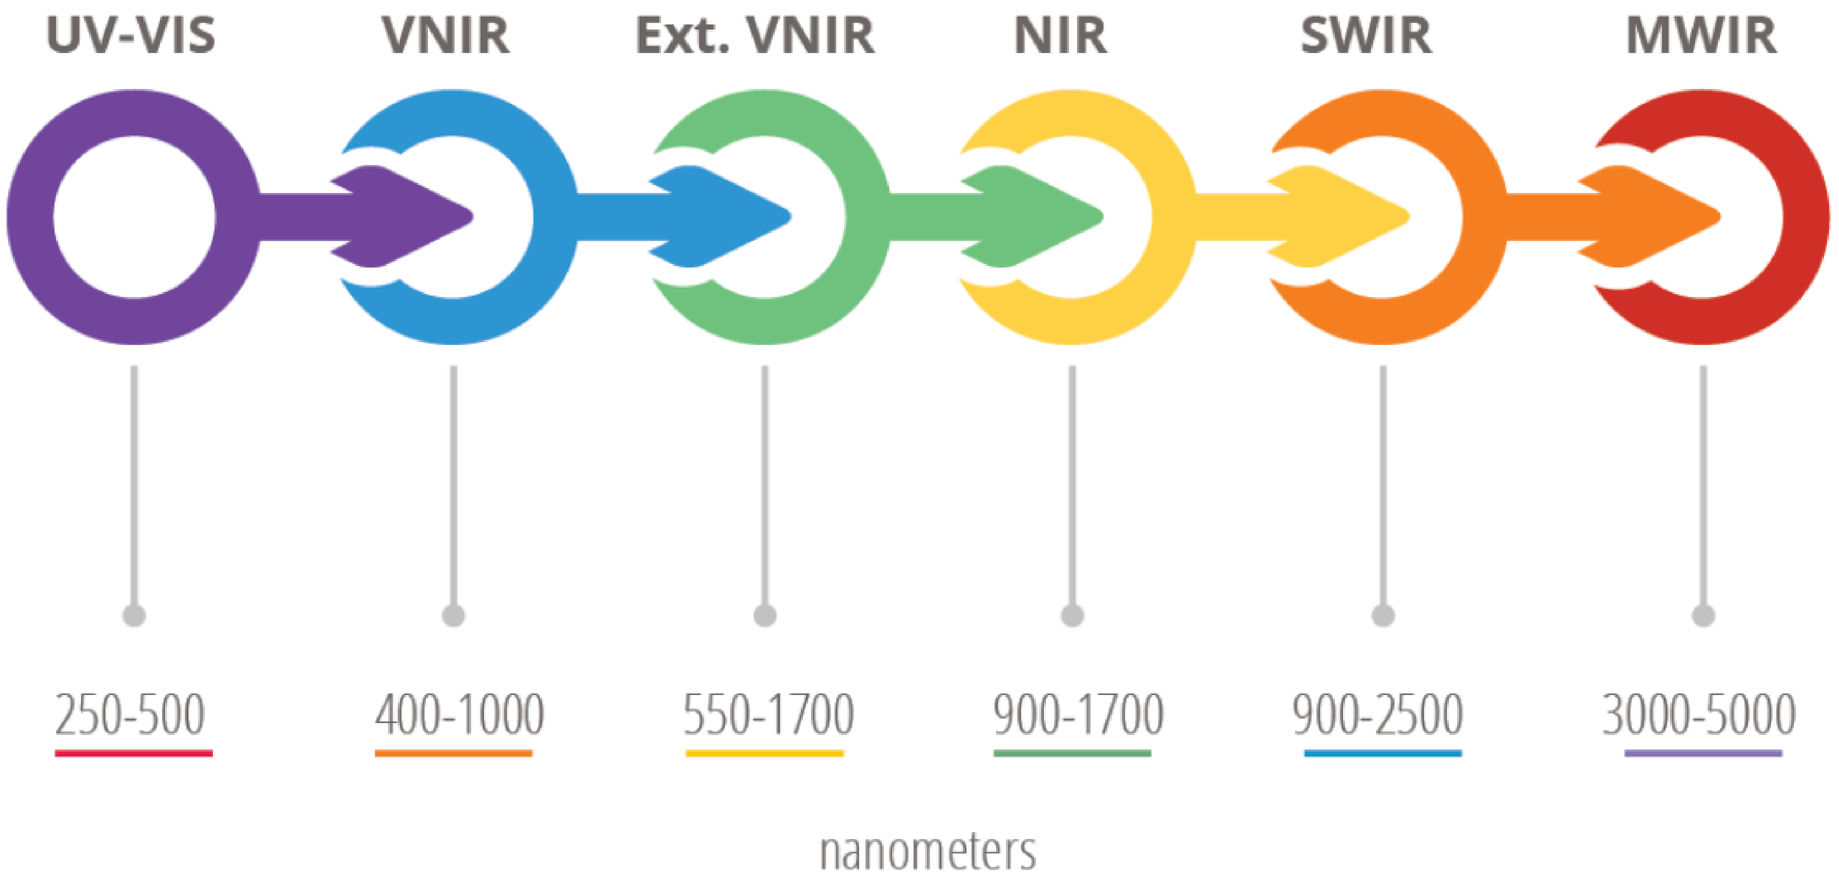

Figura 4 – Comportamento espectral da folha da videira analisada em laboratório

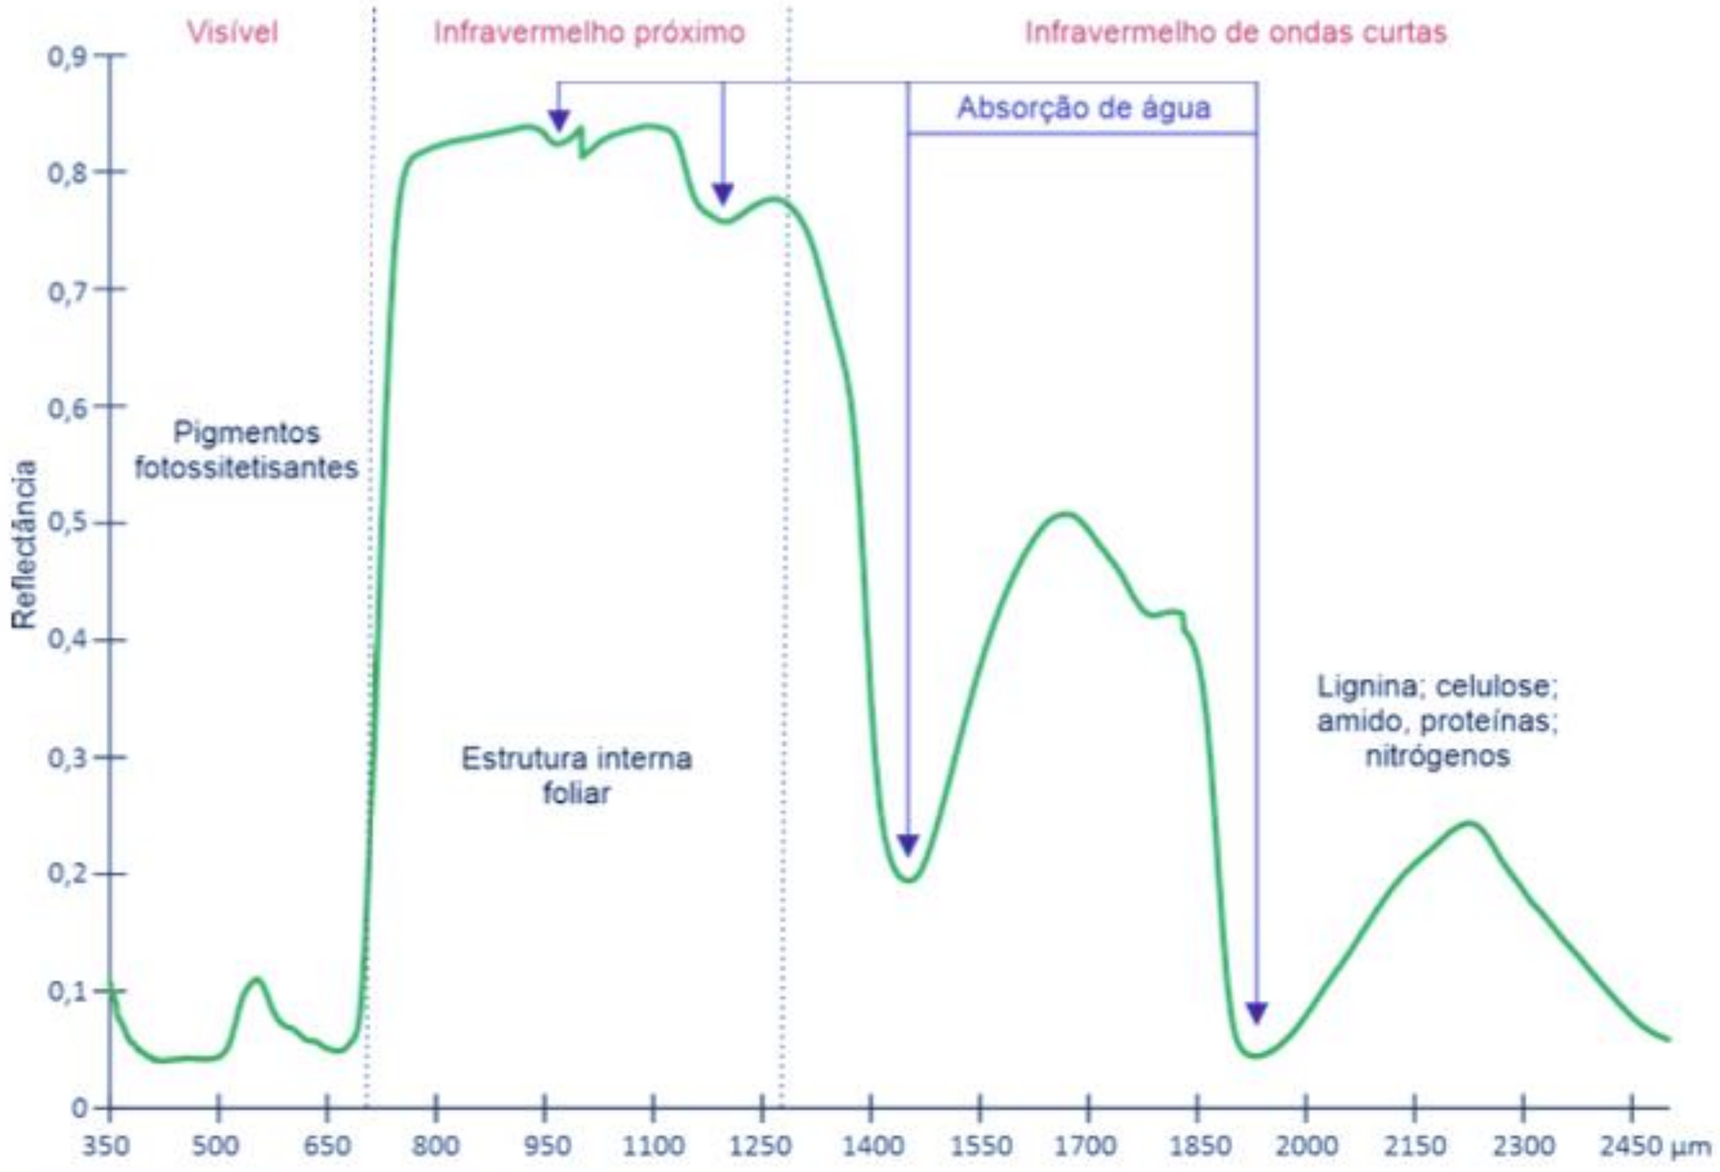

Autor: Anderson de Jesus Pereira, 2022

UAV Imaging Sensors (< 2 kg)

Escalas de observação

❖ **Trabalhos Desenvolvidos:**

1. Monitoramento Terrestre - Espectroscopia (Nível Foliar/Planta);
2. Monitoramento Aéreo - Drone (Nível Planta/Dossel);
3. Monitoramento Orbital – Satélite/Computação em Nuvem (Nível Talhão/Fazenda);

MONITORAMENTO TERRESTRE - ESPECTROSCOPIA

- A **espectroscopia** refere-se ao estudo e à análise da interação entre a radiação eletromagnética e os alvos na superfície da Terra. Essa interação resulta em padrões específicos de reflexão, absorção e emissão de radiação em diferentes comprimentos de onda, formando o que chamamos de "**assinatura espectral**" de um objeto.

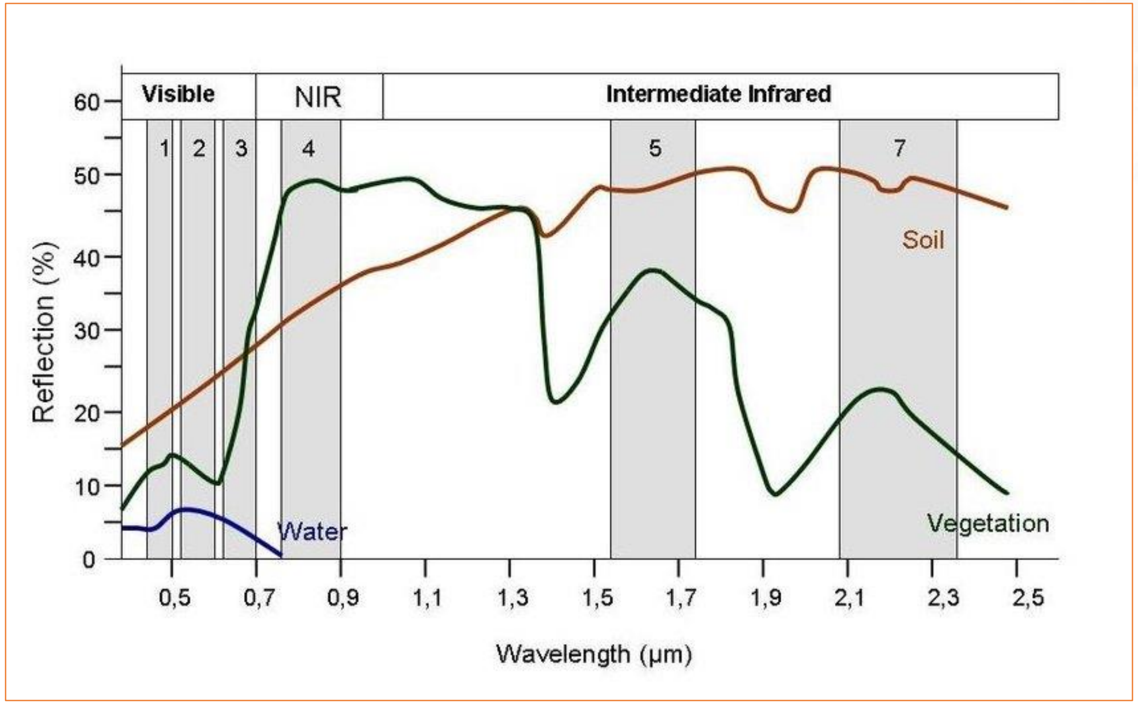

MONITORAMENTO TERRESTRE - ESPECTROSCOPIA

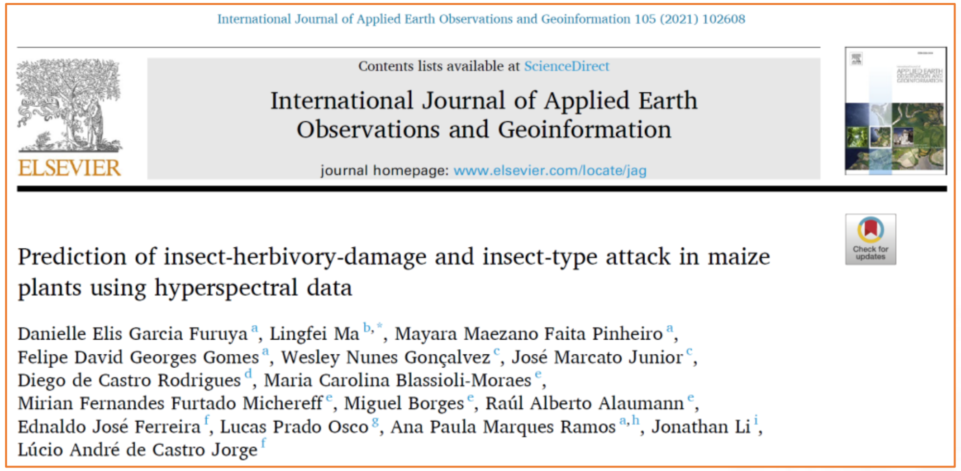

International Journal of Applied Earth Observations and Geoinformation 105 (2021) 102608

Contents lists available at ScienceDirect

International Journal of Applied Earth Observations and Geoinformation

journal homepage: www.elsevier.com/locate/jag

ELSEVIER

Prediction of insect-herbivory-damage and insect-type attack in maize plants using hyperspectral data

Danielle Elis Garcia Furuya [a], Lingfei Ma [b,*], Mayara Maezano Faita Pinheiro [a], Felipe David Georges Gomes [a], Wesley Nunes Gonçalvez [c], José Marcato Junior [c], Diego de Castro Rodrigues [d], Maria Carolina Blassioli-Moraes [e], Mirian Fernandes Furtado Michereff [e], Miguel Borges [e], Raúl Alberto Alaumann [e], Ednaldo José Ferreira [f], Lucas Prado Osco [g], Ana Paula Marques Ramos [a,h], Jonathan Li [i], Lúcio André de Castro Jorge [f]

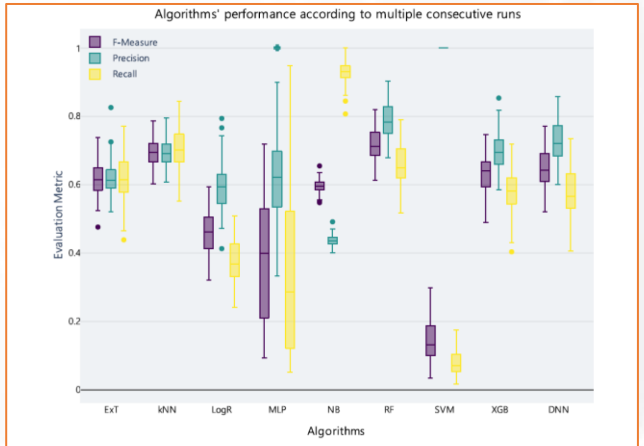

Fig. 2. Models' performance comparison considering undamaged and insect-damaged maize plants with 8 consecutive days of insect-damage.

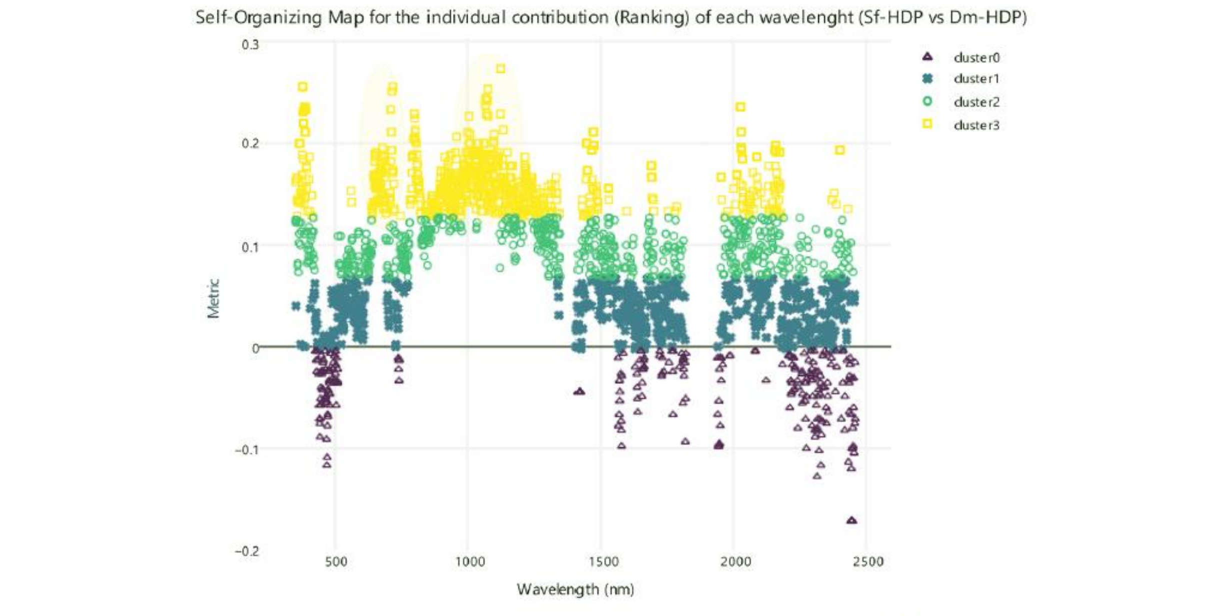

Fig. 5. Ranking metric and SOM clustering method indicating the importance of wavelengths for the three maize plant experiments.

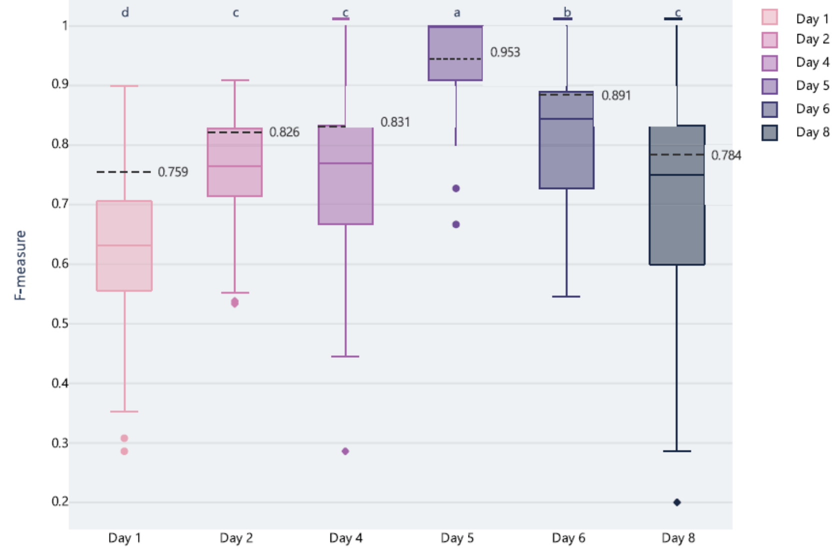

Fig. 3. Random Forest (RF) performance metric comparison between days of analysis considering undamaged and insect-damaged maize plants. Letters positioned above the metric value indicate the differences between each day's prediction. The value highlighted inside the box-plot regions corresponds with the F-measure returned at the testing phase.

MONITORAMENTO TERRESTRE - ESPECTROSCOPIA

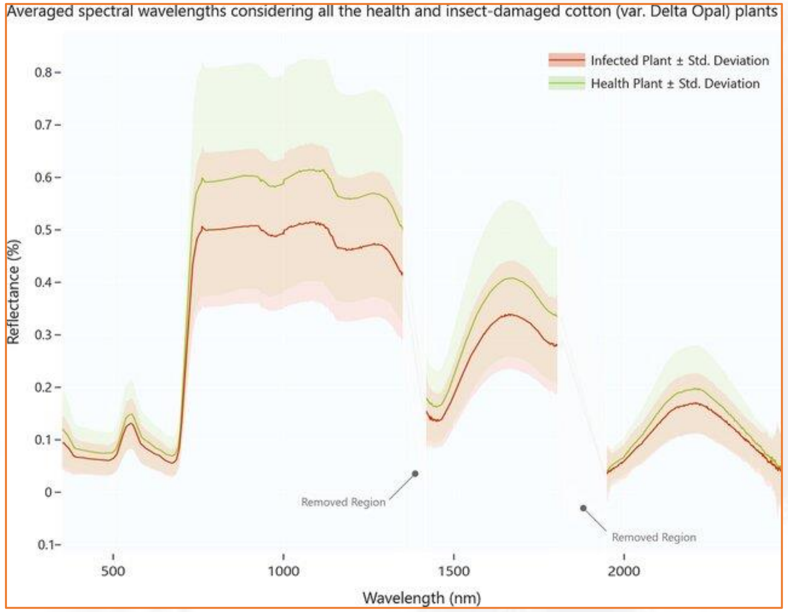

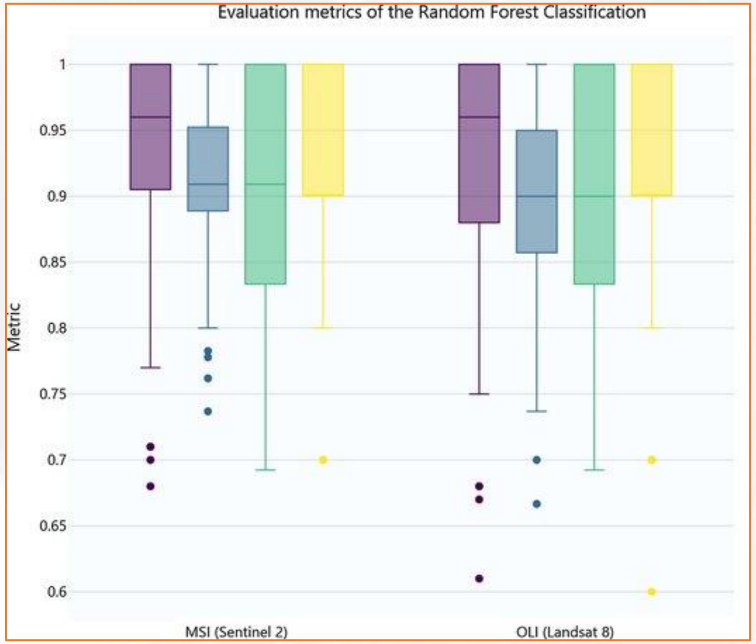

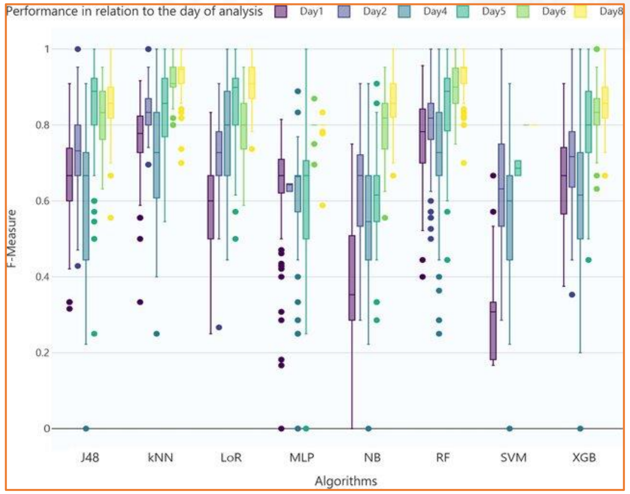

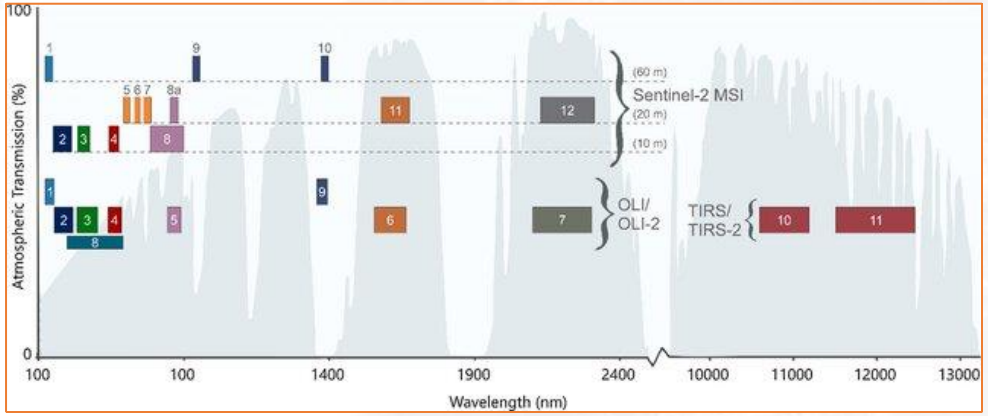

MONITORAMENTO TERRESTRE - ESPECTROSCOPIA

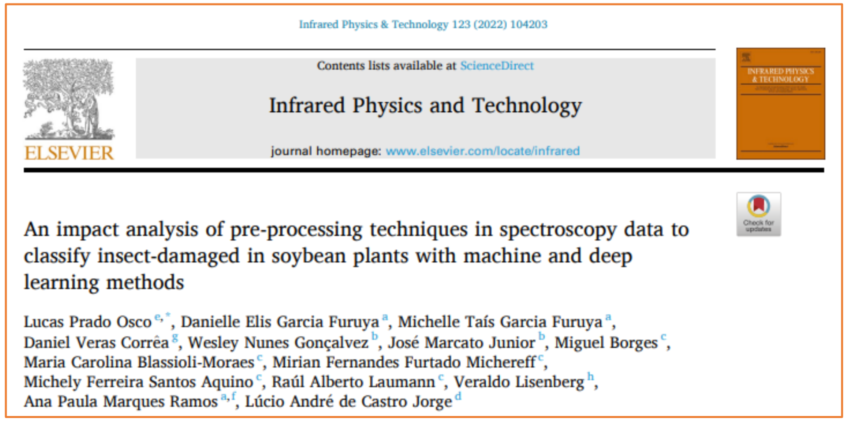
Infrared Physics & Technology 123 (2022) 104203

Contents lists available at ScienceDirect

Infrared Physics and Technology

journal homepage: www.elsevier.com/locate/infrared

An impact analysis of pre-processing techniques in spectroscopy data to classify insect-damaged in soybean plants with machine and deep learning methods

Lucas Prado Osco[e,*], Danielle Elis Garcia Furuya[a], Michelle Taís Garcia Furuya[a], Daniel Veras Corrêa[g], Wesley Nunes Gonçalvez[b], José Marcato Junior[b], Miguel Borges[c], Maria Carolina Blassioli-Moraes[c], Mirian Fernandes Furtado Michereff[c], Michely Ferreira Santos Aquino[c], Raúl Alberto Laumann[c], Veraldo Lisenberg[h], Ana Paula Marques Ramos[a,f], Lúcio André de Castro Jorge[d]

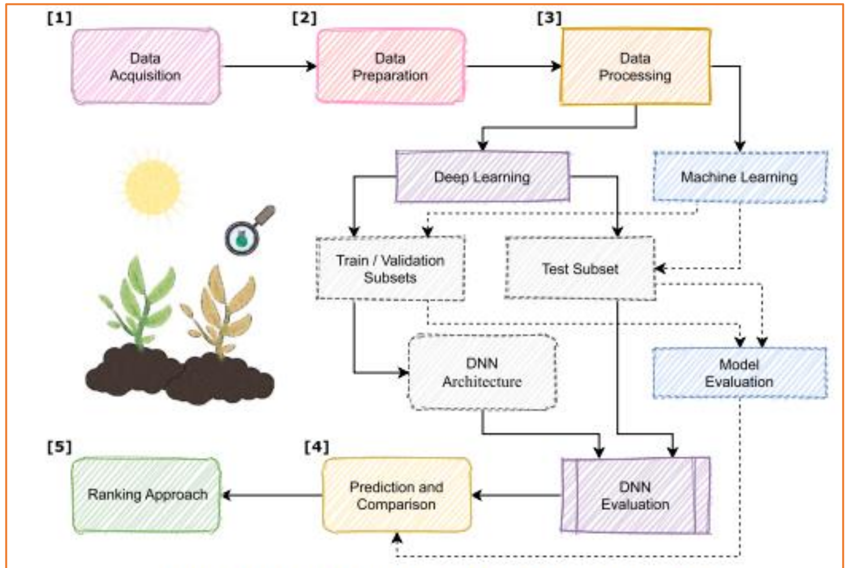

Fig. 1. Simplified scheme with the processing-steps implemented in this study.

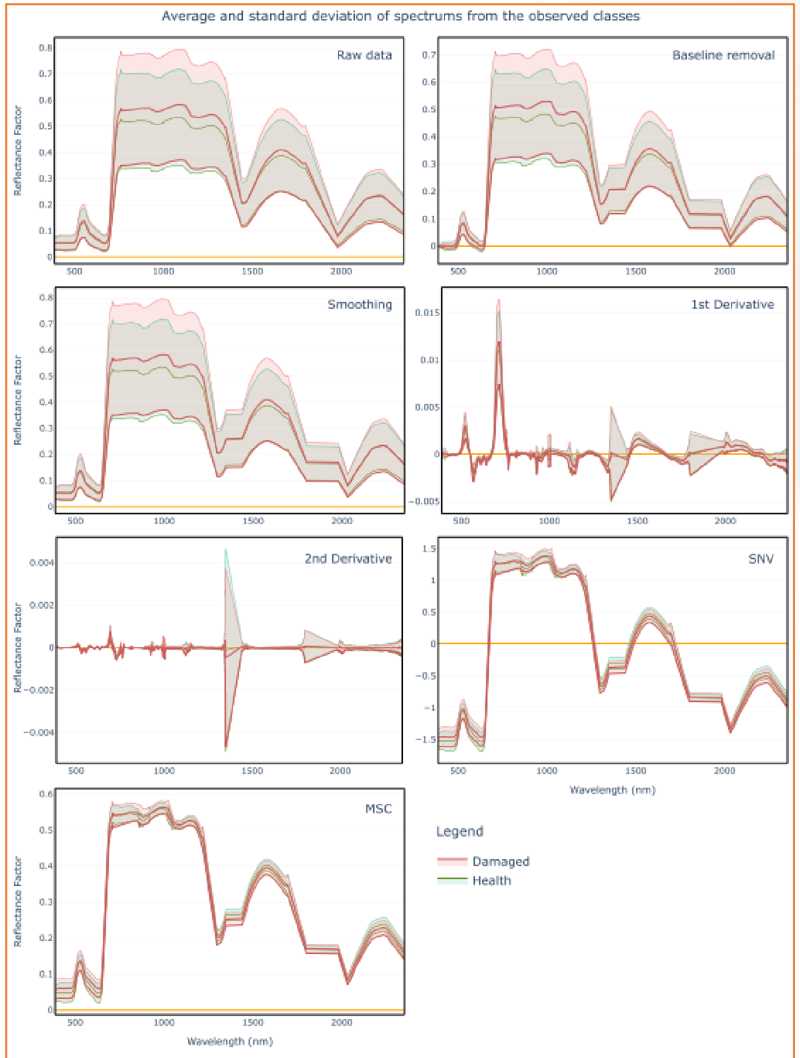

Fig. 4. Spectral averaged data of the implemented pre-processing techniques obtained from the experiment in soy plants.

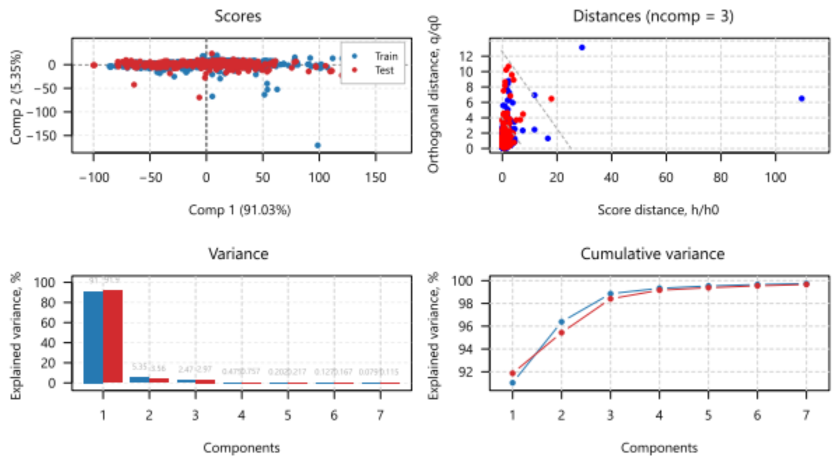

Fig. 5. PCA information obtained from the raw data spectrum.

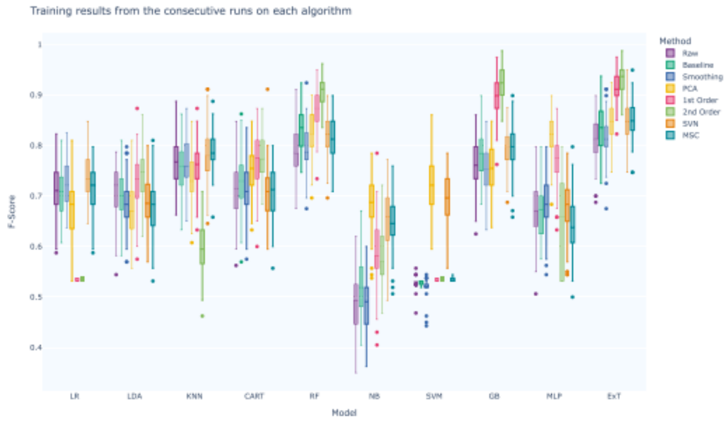

Fig. 6. Training results from the consecutive runs on each algorithm.

MONITORAMENTO TERRESTRE - ESPECTROSCOPIA

Open Access Article

A Machine Learning Framework to Predict Nutrient Content in Valencia-Orange Leaf Hyperspectral Measurements

by Lucas Prado Osco [1,*], Ana Paula Marques Ramos [2], Mayara Maezano Faita Pinheiro [2], Érika Akemi Saito Moriya [3], Nilton Nobuhiro Imai [3], Nayara Estrabis [1], Felipe Ianczyk [1], Fábio Fernando de Araújo [4], Veraldo Liesenberg [5], Lúcio André de Castro Jorge [6], Jonathan Li [7], Lingfei Ma [7], Wesley Nunes Gonçalves [1], José Marcato Junior [1] and José Eduardo Creste [4]

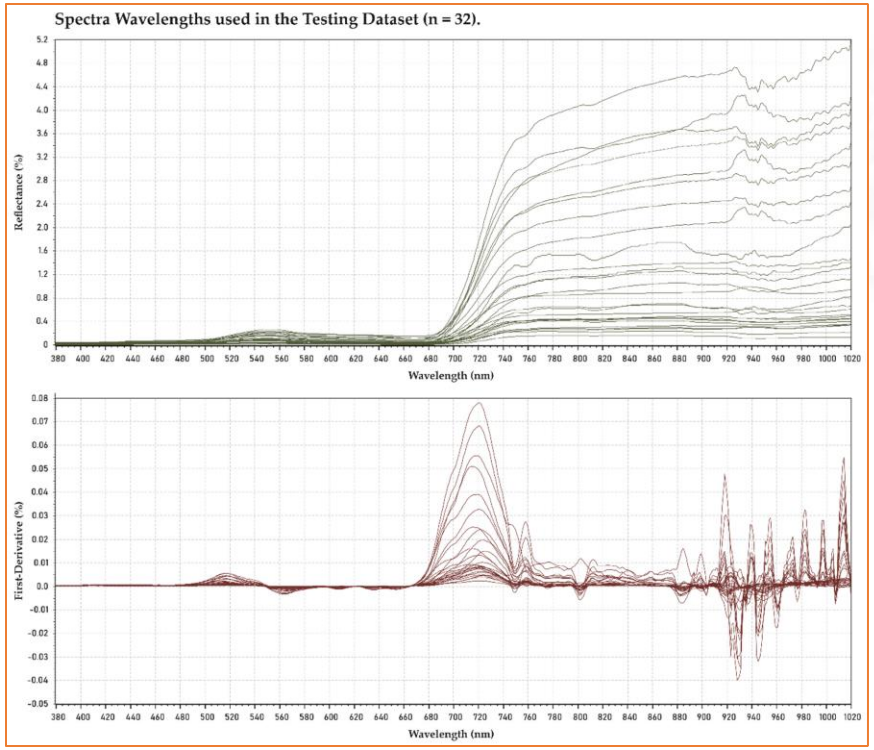

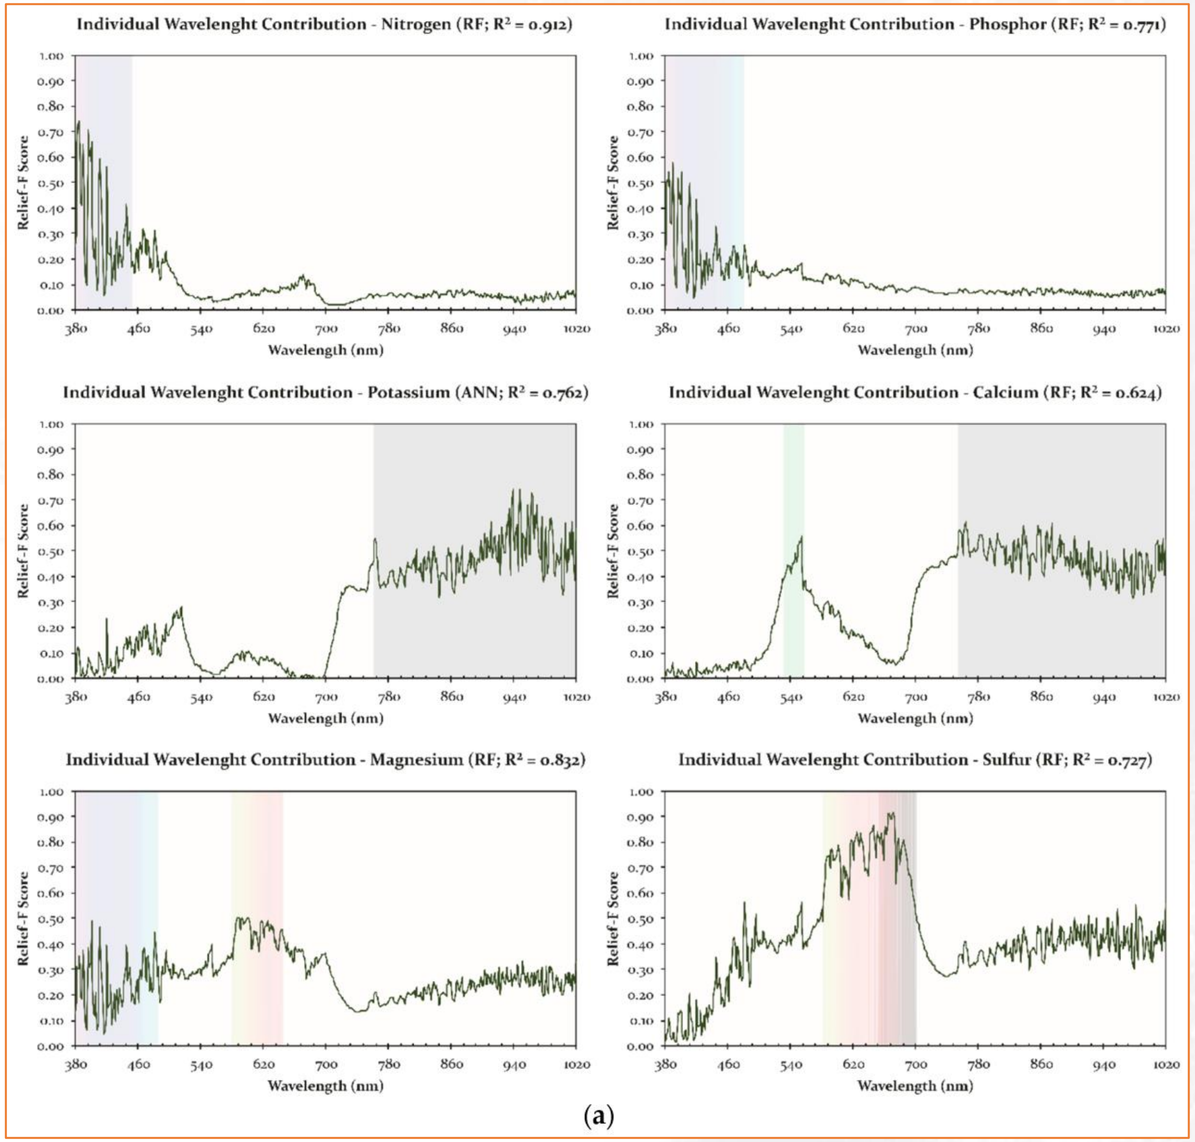

MONITORAMENTO TERRESTRE - ESPECTROSCOPIA

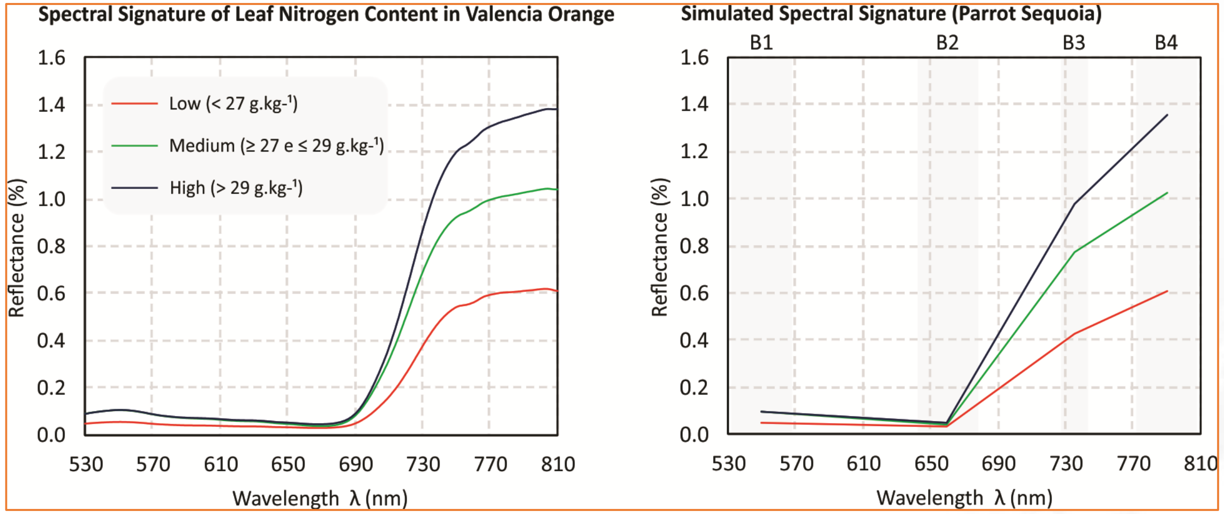

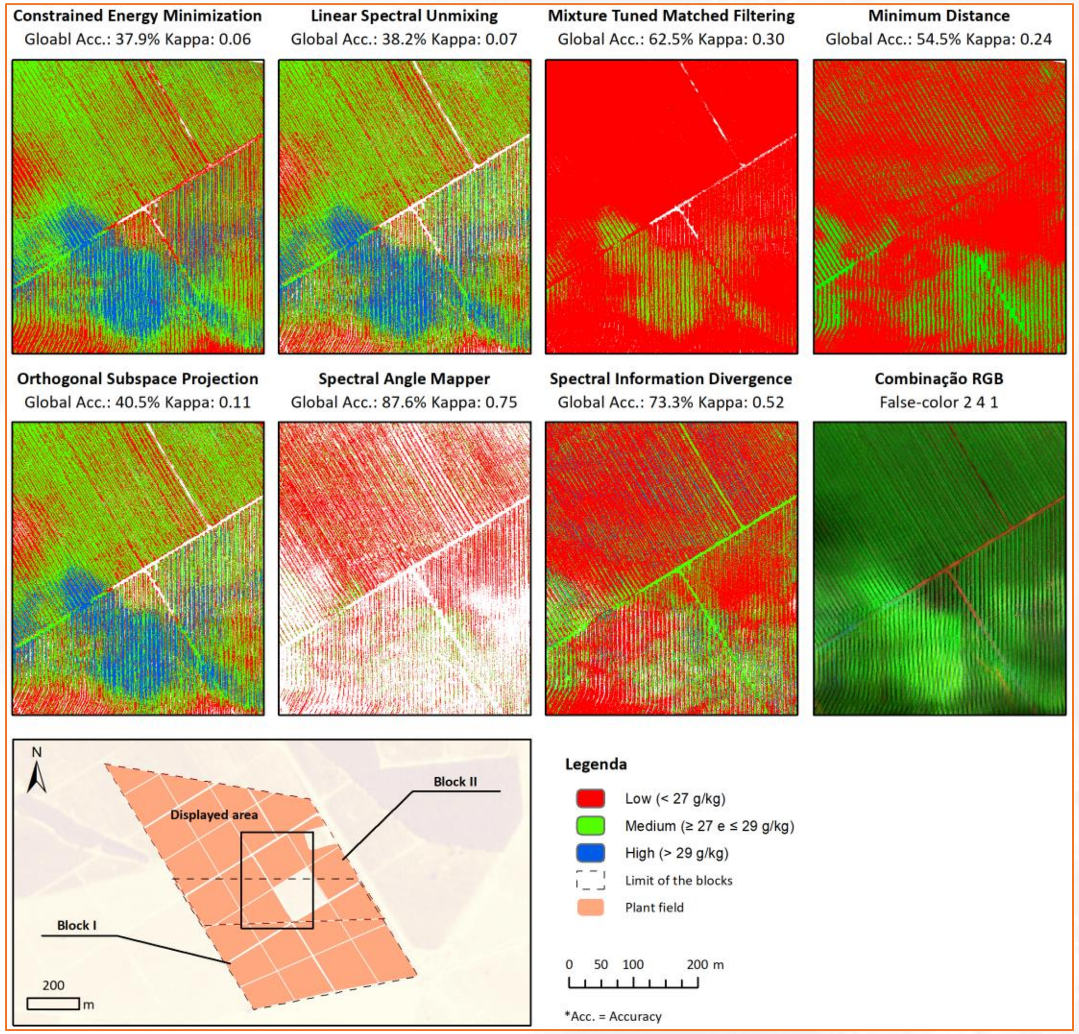

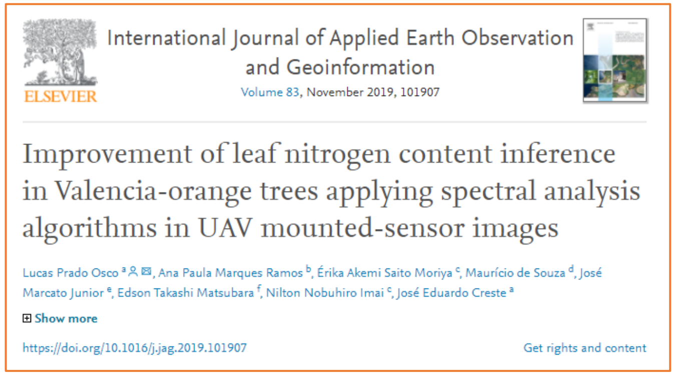

International Journal of Applied Earth Observation and Geoinformation
Volume 83, November 2019, 101907

Improvement of leaf nitrogen content inference in Valencia-orange trees applying spectral analysis algorithms in UAV mounted-sensor images

Lucas Prado Osco [a], Ana Paula Marques Ramos [b], Érika Akemi Saito Moriya [c], Maurício de Souza [d], José Marcato Junior [e], Edson Takashi Matsubara [f], Nilton Nobuhiro Imai [c], José Eduardo Creste [a]

Show more

https://doi.org/10.1016/j.jag.2019.101907

Get rights and content

MONITORAMENTO AÉREO - DRONES

- **Fotogrametria aérea** (ou aerofotogrametria) é uma subdivisão da fotogrametria, na qual as fotografias do terreno são tomadas por uma câmara de precisão montada em uma aeronave.

Como usar?

Field Data Collection

Data Visualization & Analysis

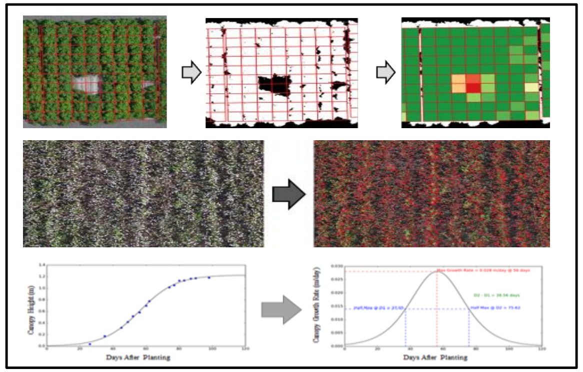

Platforms & Sensors

Data Interpretation & Applications

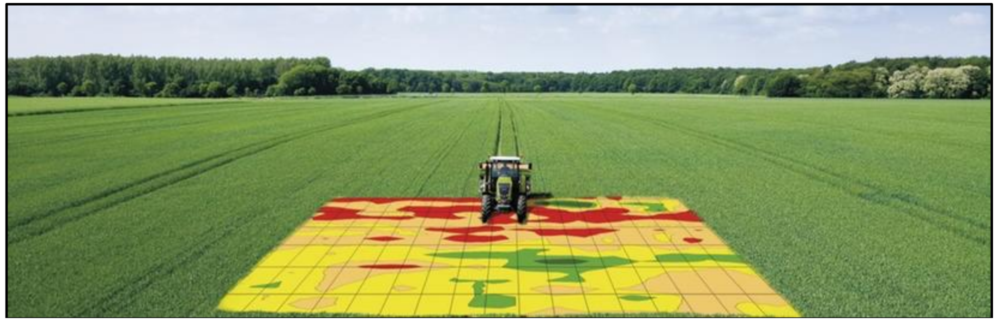

Interdisciplinary Group

- Engineers
- Computer Scientists
- Agronomists
- Biologists
- Breeders
- Pathologists
- Soil Scientists

Inteligência Artificial

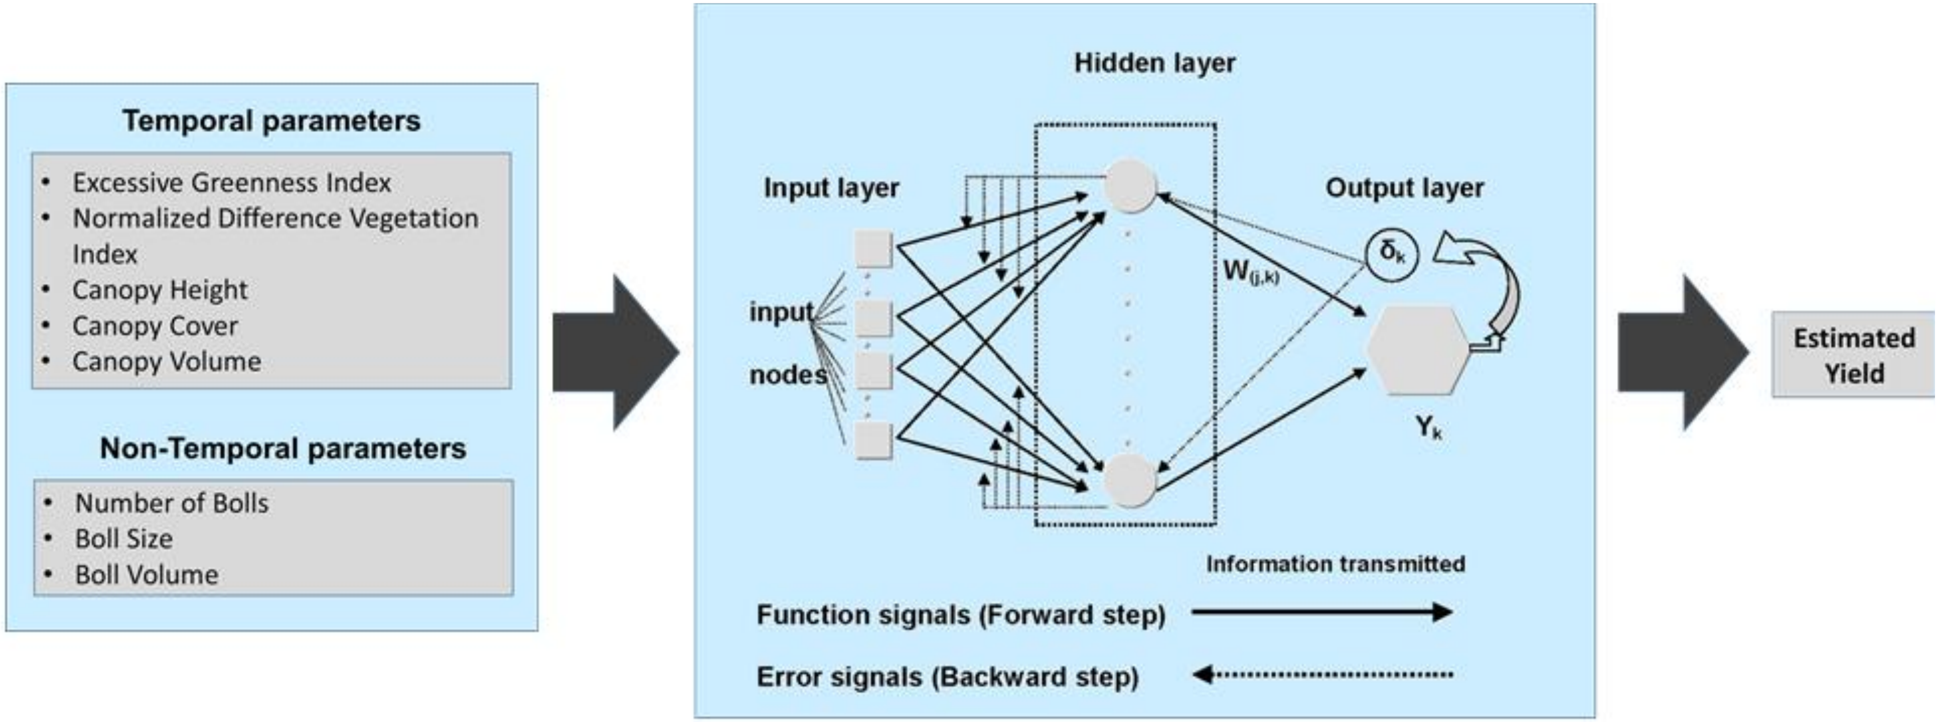

Convolutional Neural Network

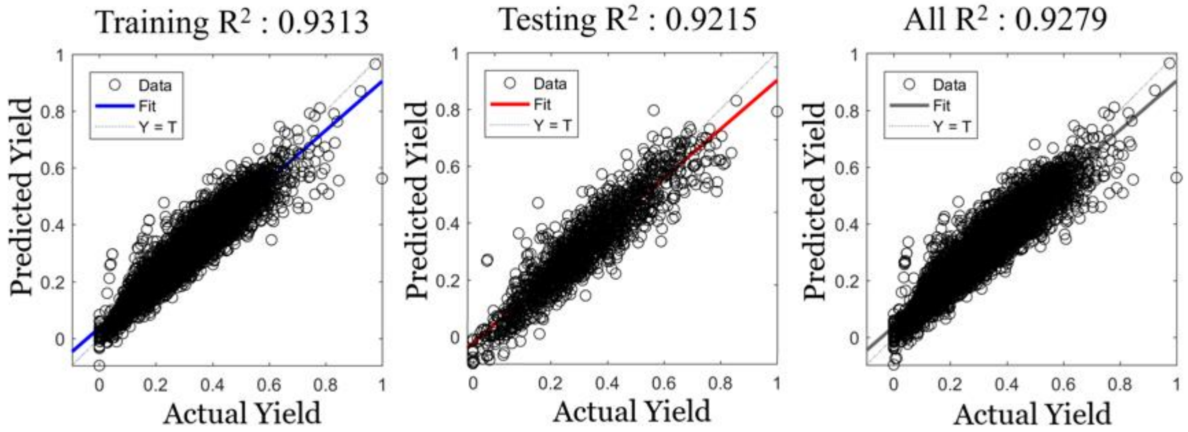

MONITORAMENTO AÉREO - DRONES

A Review on Deep Learning in UAV Remote Sensing

Preprint, compiled August 22, 2023

Lucas Prado Osco [1*], José Marcato Junior [2], Ana Paula Marques Ramos [3], Lúcio André de Castro Jorge [4], Sarah Narges Fatholahi [5], Jonathan de Andrade Silva [6], Edson Takashi Matsubara [6], Hemerson Pistori [7], Wesley Nunes Gonçalves [6], and Jonathan Li [5]

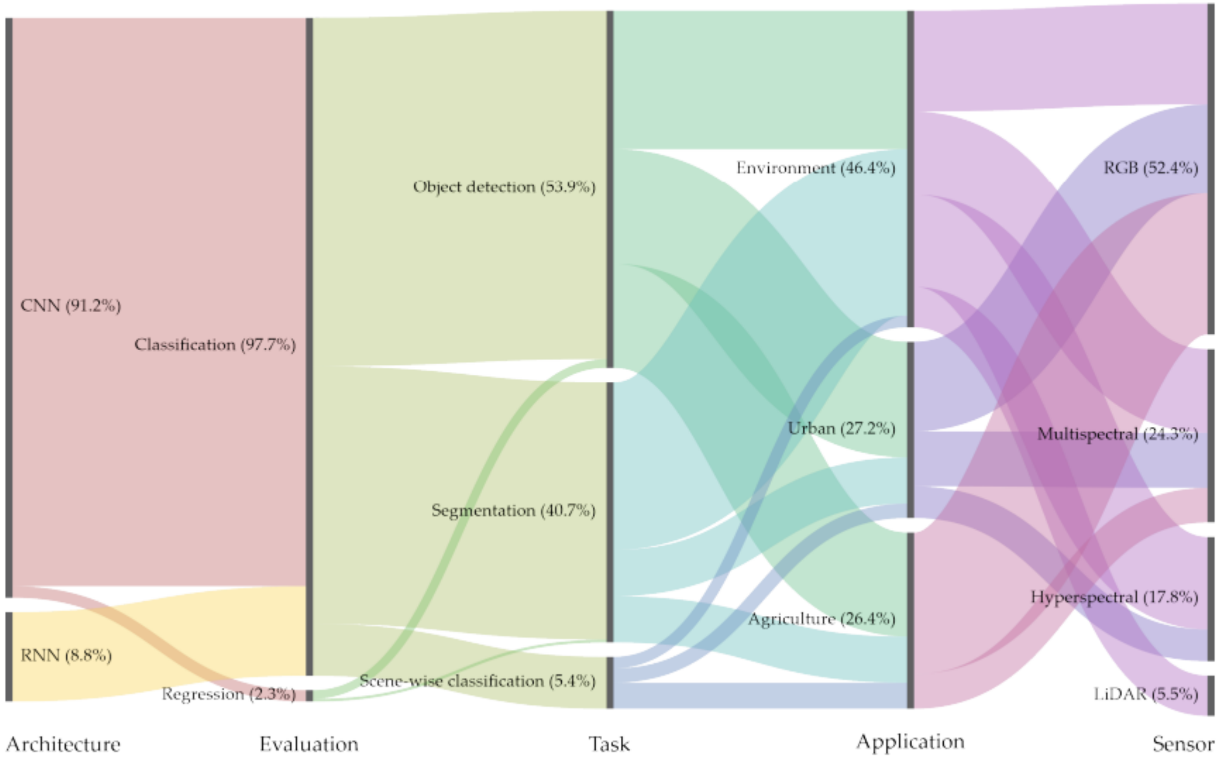

Figure 9: Diagram describing proceedings and articles according to the defined categories using WOS and Google Scholar datasets.

MONITORAMENTO AÉREO - DRONES

sensors

MDPI

Letter

Deep Learning Applied to Phenotyping of Biomass in Forages with UAV-Based RGB Imagery

Wellington Castro [1], José Marcato Junior [2,*], Caio Polidoro [1], Lucas Prado Osco [3], Wesley Gonçalves [2], Lucas Rodrigues [1], Mateus Santos [4], Liana Jank [4], Sanzio Barrios [4], Cacilda Valle [4], Rosangela Simeão [4], Camilo Carromeu [4], Eloise Silveira [2], Lúcio André de Castro Jorge [5] and Edson Matsubara [1]

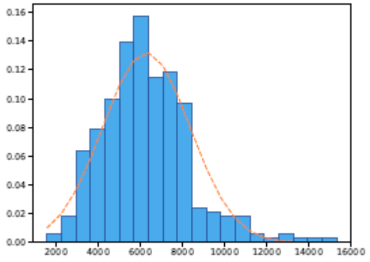

Figure 3. Class attribute y distribution-biomass in kg·ha^{-1}.

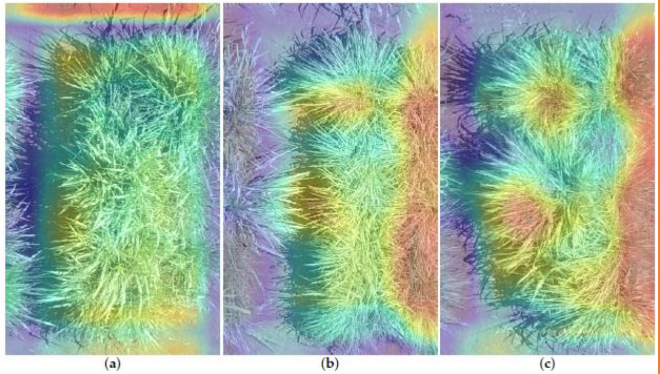

Figure 9. Heatmaps of the top 3 best predictions made by Experiment #9 (Pre-trained AlexNet Model with hv data augmentation): (a) First best prediction; (b) Second best prediction; (c) Third best prediction.

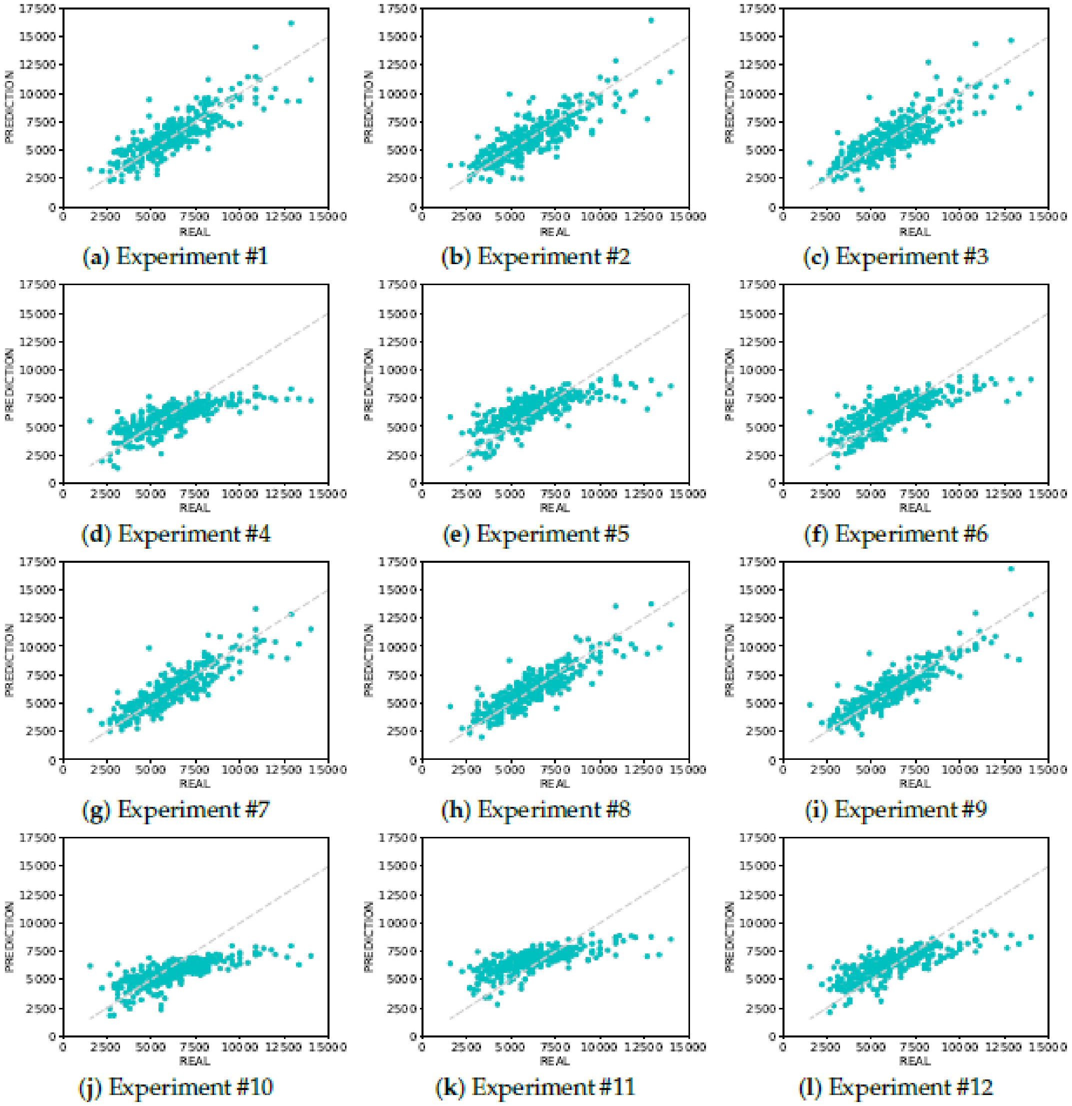

MONITORAMENTO AÉREO - DRONES

sensors MDPI

Article

Convolutional Neural Networks to Estimate Dry Matter Yield in a Guineagrass Breeding Program Using UAV Remote Sensing

Gabriel Silva de Oliveira [1], José Marcato Junior [2,*], Caio Polidoro [1], Lucas Prado Osco [2,3], Henrique Siqueira [2], Lucas Rodrigues [1], Liana Jank [4], Sanzio Barrios [4], Cacilda Valle [4], Rosângela Simeão [4], Camilo Carromeu [4], Eloise Silveira [2], Lúcio André de Castro Jorge [5], Wesley Gonçalves [1,2], Mateus Santos [4] and Edson Matsubara [1]

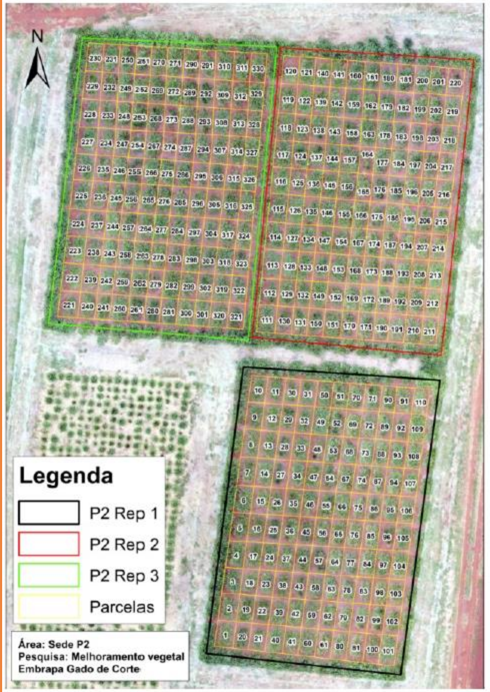

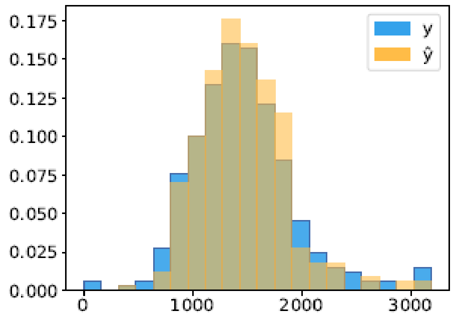

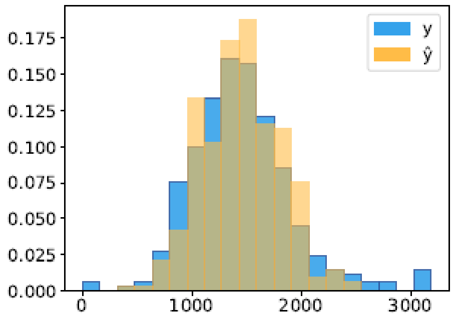

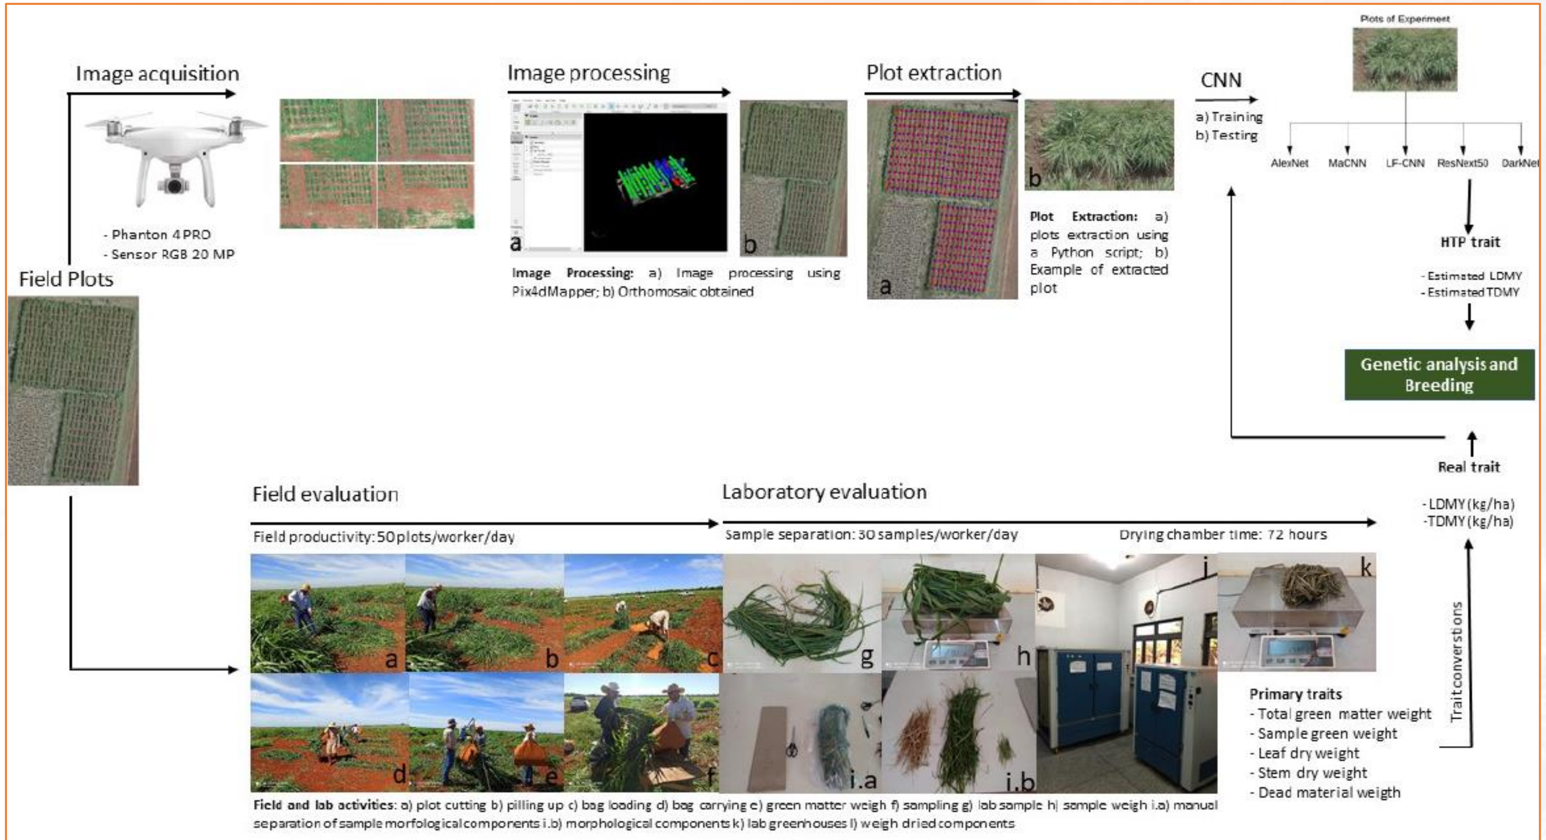

Figure 1. Workflow of phenotyping DMY traits by conventional (**bellow**) and high-throughput (**above**) processes in the guineagrass breeding program at Embrapa Beef Cattle.

MONITORAMENTO AÉREO - DRONES

Springer Link

Published: 02 January 2021

Semantic segmentation of citrus-orchard using deep neural networks and multispectral UAV-based imagery

Lucas Prado Osco, Keiller Nogueira, Ana Paula Marques Ramos, Mayara Maezano Faita Pinheiro, Danielle Elis Garcia Furuya, Wesley Nunes Gonçalves, Lucio André de Castro Jorge, José Marcato Junior & Jefersson Alex dos Santos

Precision Agriculture **22**, 1171–1188 (2021) | Cite this article

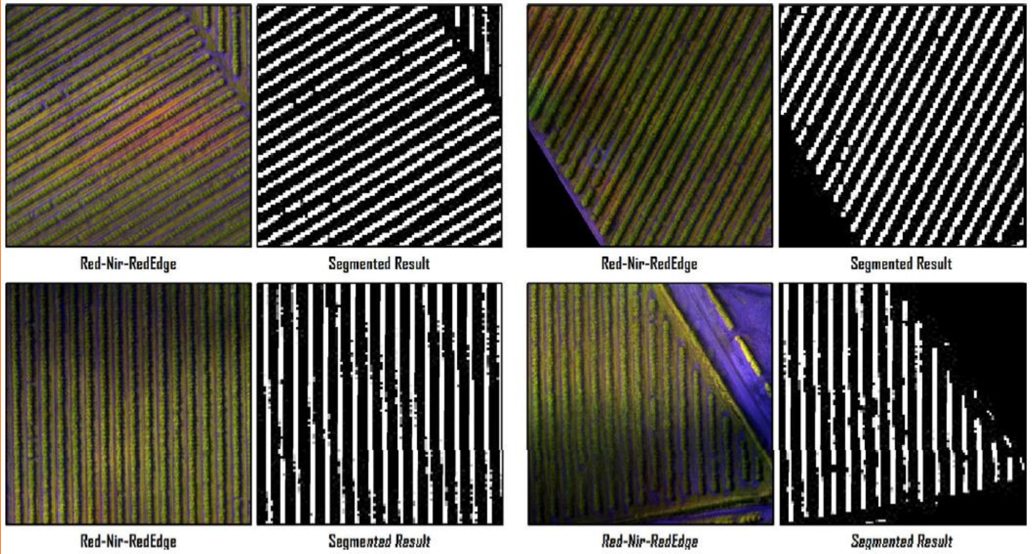

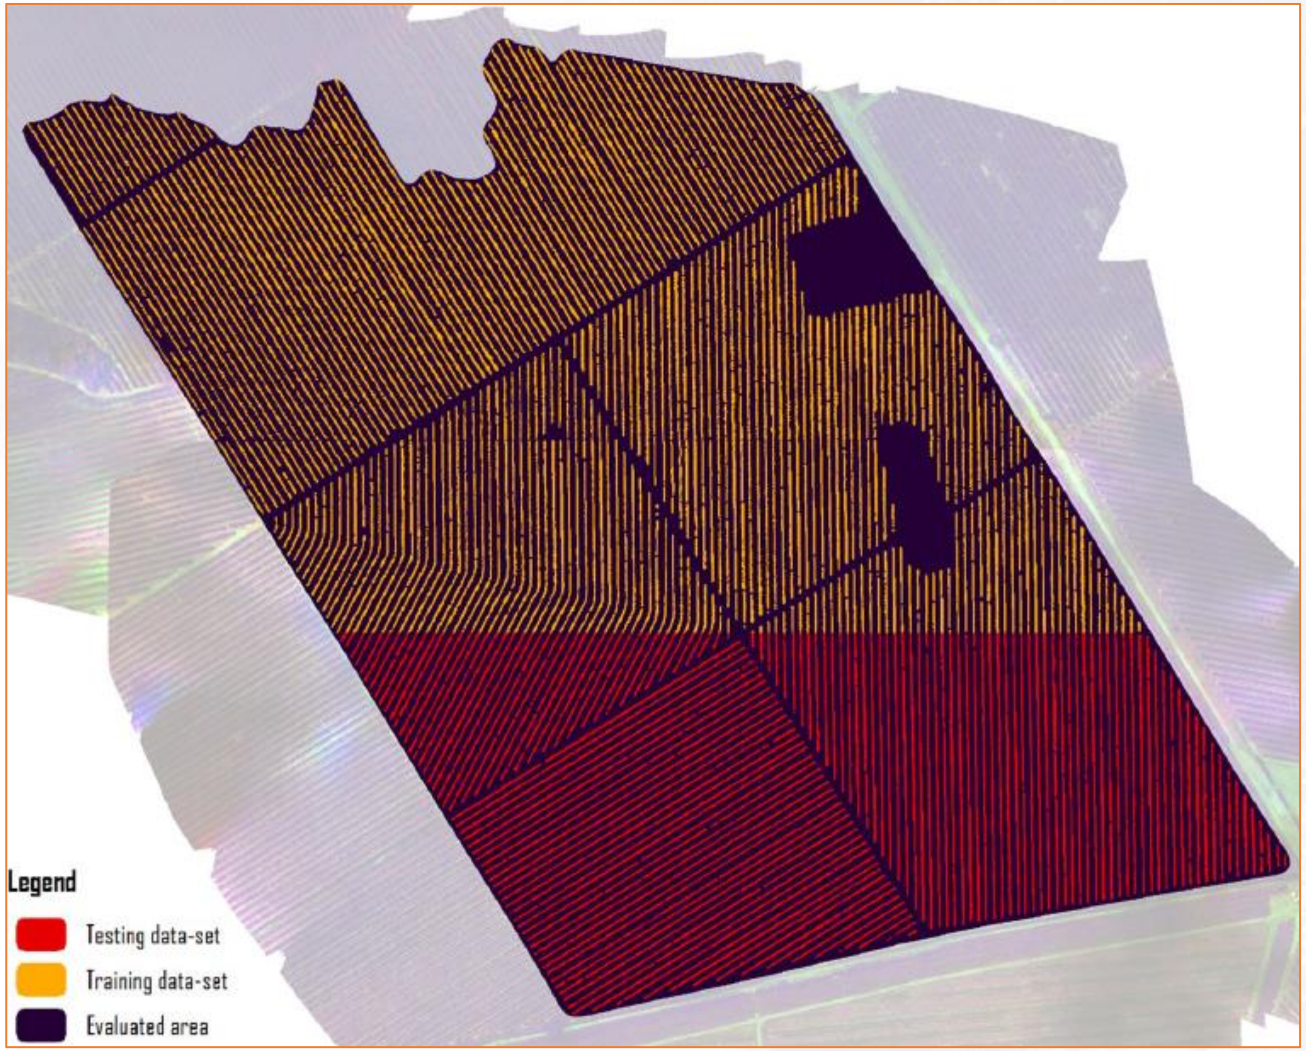

MONITORAMENTO AÉREO - DRONES

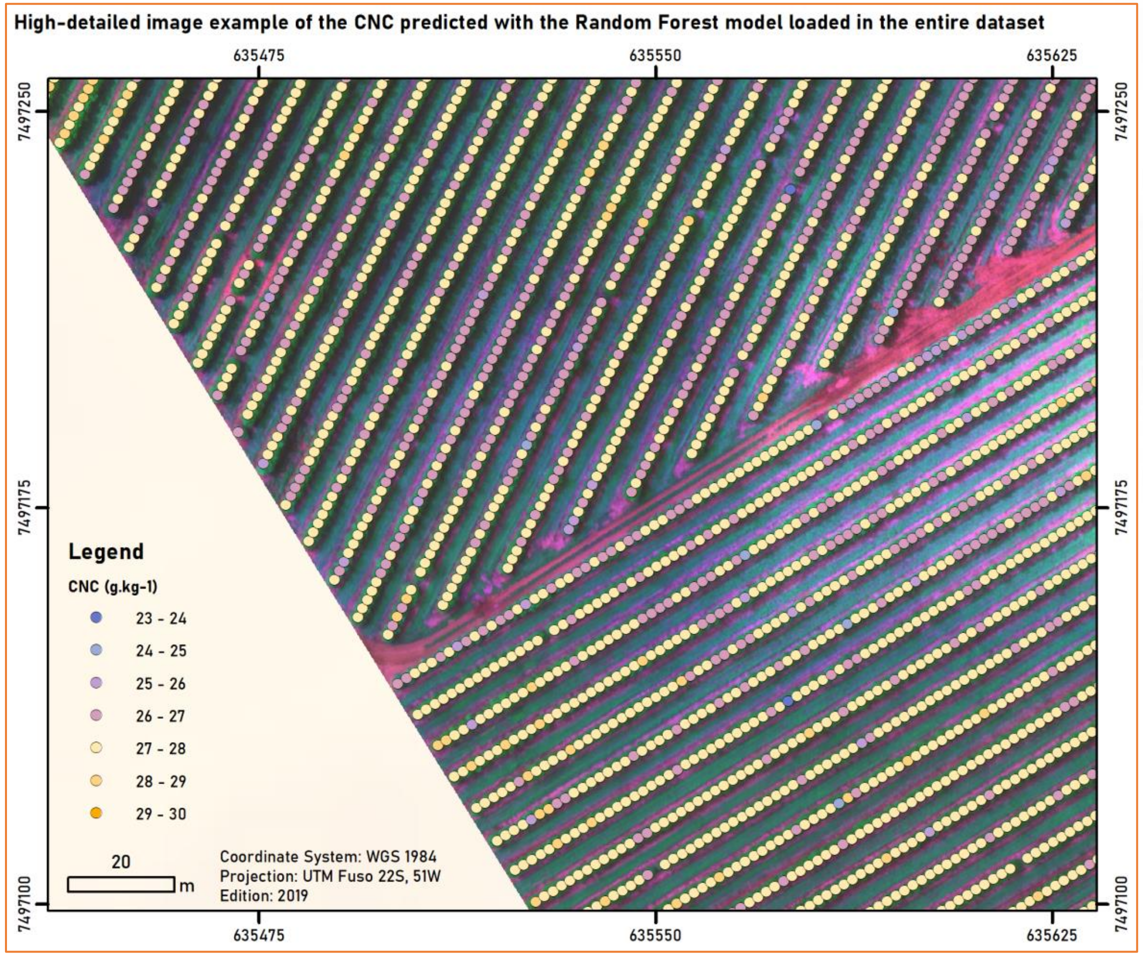

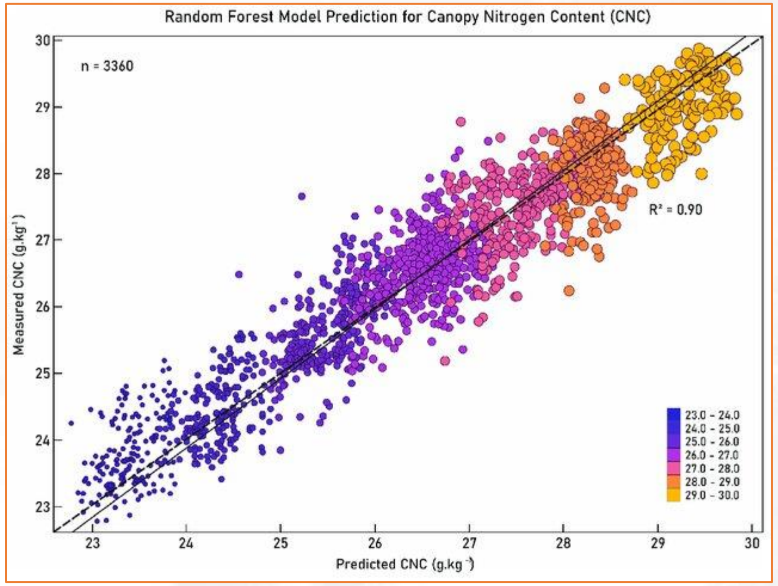

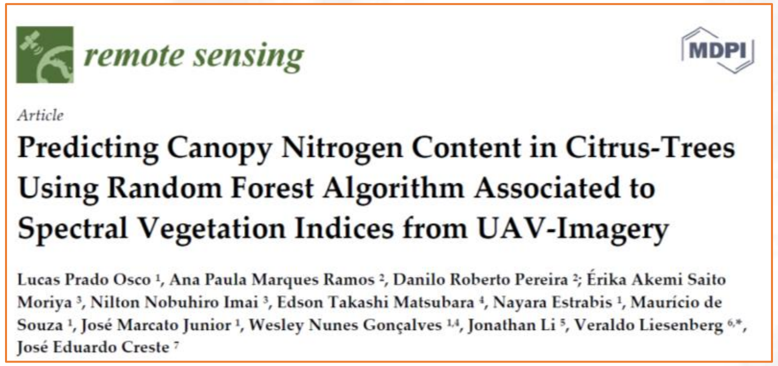
remote sensing

MDPI

Article

Predicting Canopy Nitrogen Content in Citrus-Trees Using Random Forest Algorithm Associated to Spectral Vegetation Indices from UAV-Imagery

Lucas Prado Osco [1], Ana Paula Marques Ramos [2], Danilo Roberto Pereira [2], Érika Akemi Saito Moriya [3], Nilton Nobuhiro Imai [3], Edson Takashi Matsubara [4], Nayara Estrabis [1], Maurício de Souza [1], José Marcato Junior [1], Wesley Nunes Gonçalves [1,4], Jonathan Li [5], Veraldo Liesenberg [6,*], José Eduardo Creste [7]

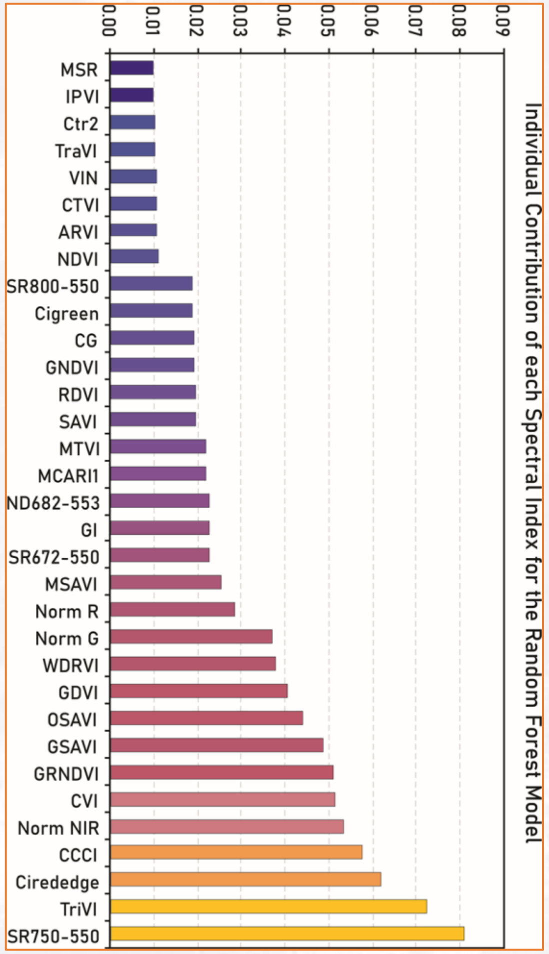

MONITORAMENTO AÉREO - DRONES

ISPRS Journal of Photogrammetry and Remote Sensing 174 (2021) 1–17

Contents lists available at ScienceDirect

ISPRS Journal of Photogrammetry and Remote Sensing

journal homepage: www.elsevier.com/locate/isprsjprs

A CNN approach to simultaneously count plants and detect plantation-rows from UAV imagery

Lucas Prado Osco[a], Mauro dos Santos de Arruda[b], Diogo Nunes Gonçalves[b], Alexandre Dias[c], Juliana Batistoti[c], Mauricio de Souza[d], Felipe David Georges Gomes[e], Ana Paula Marques Ramos[e,*], Lúcio André de Castro Jorge[f], Veraldo Liesenberg[g], Jonathan Li[h], Lingfei Ma[h], José Marcato Junior[d], Wesley Nunes Gonçalves[d]

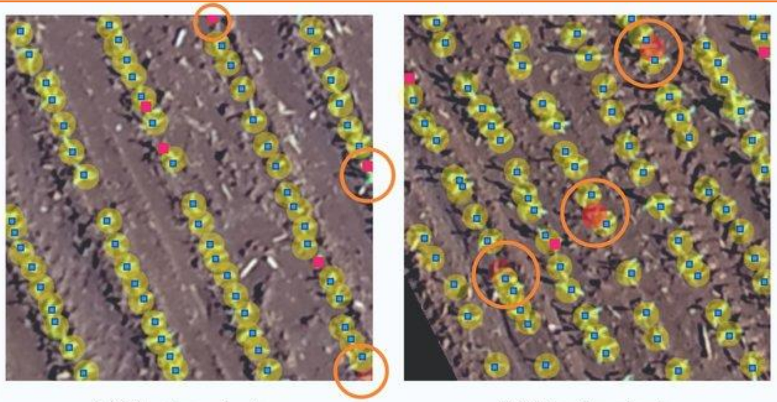

(a) Plants occlusion (b) Nearby plants

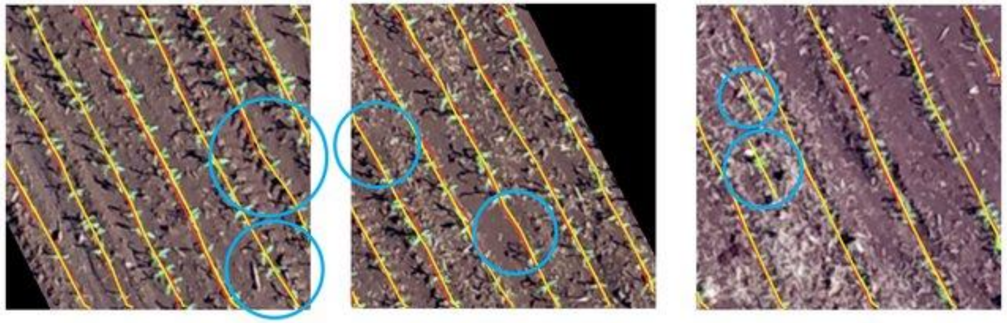

(a) Curve adaptation (b) Large spacing between plants (c) Single plants

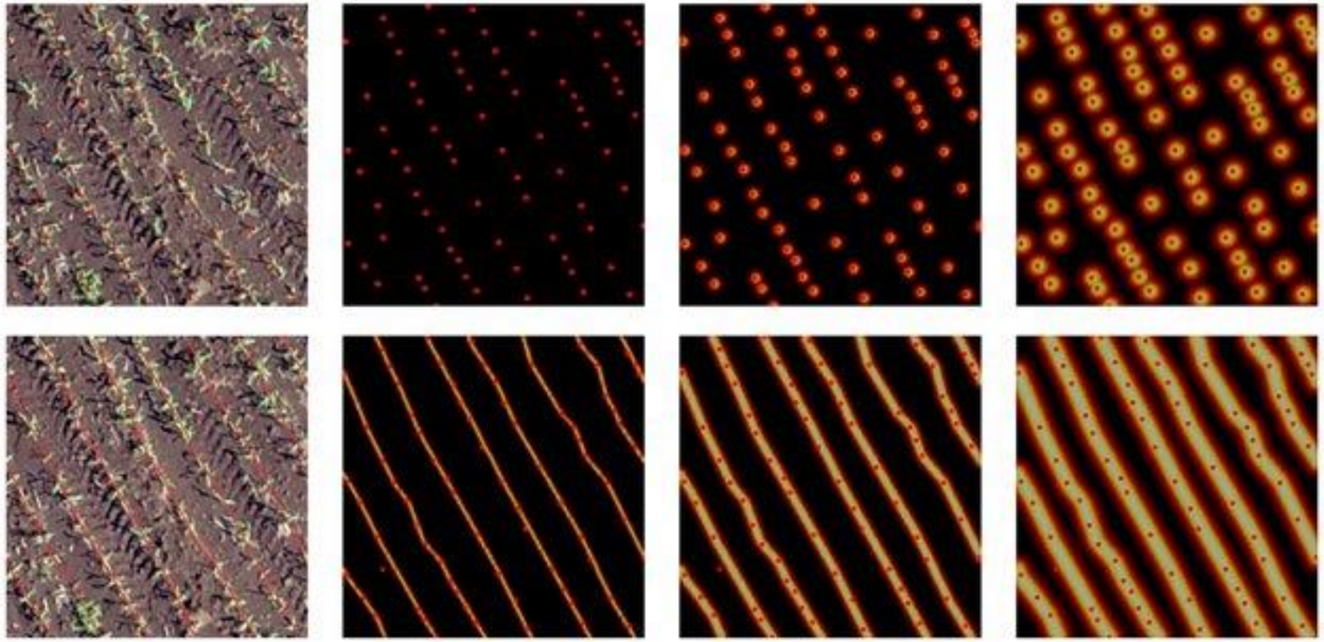

(a) RGB Image (b) $\sigma = 0.5$ (c) $\sigma = 1.5$ (d) $\sigma = 3.0$

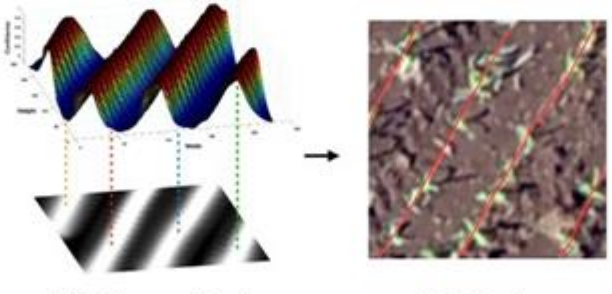

(a) Confidence map ($C_{T_{Lines}}$) (c) Predicted lines

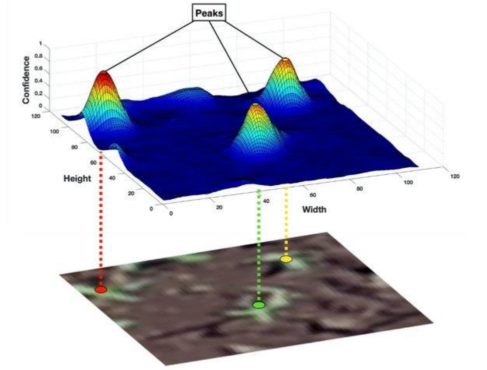

LIDAR + Hiperespectral milhares de informações em tempo real – projeto Embrapa Agricultura Precisão

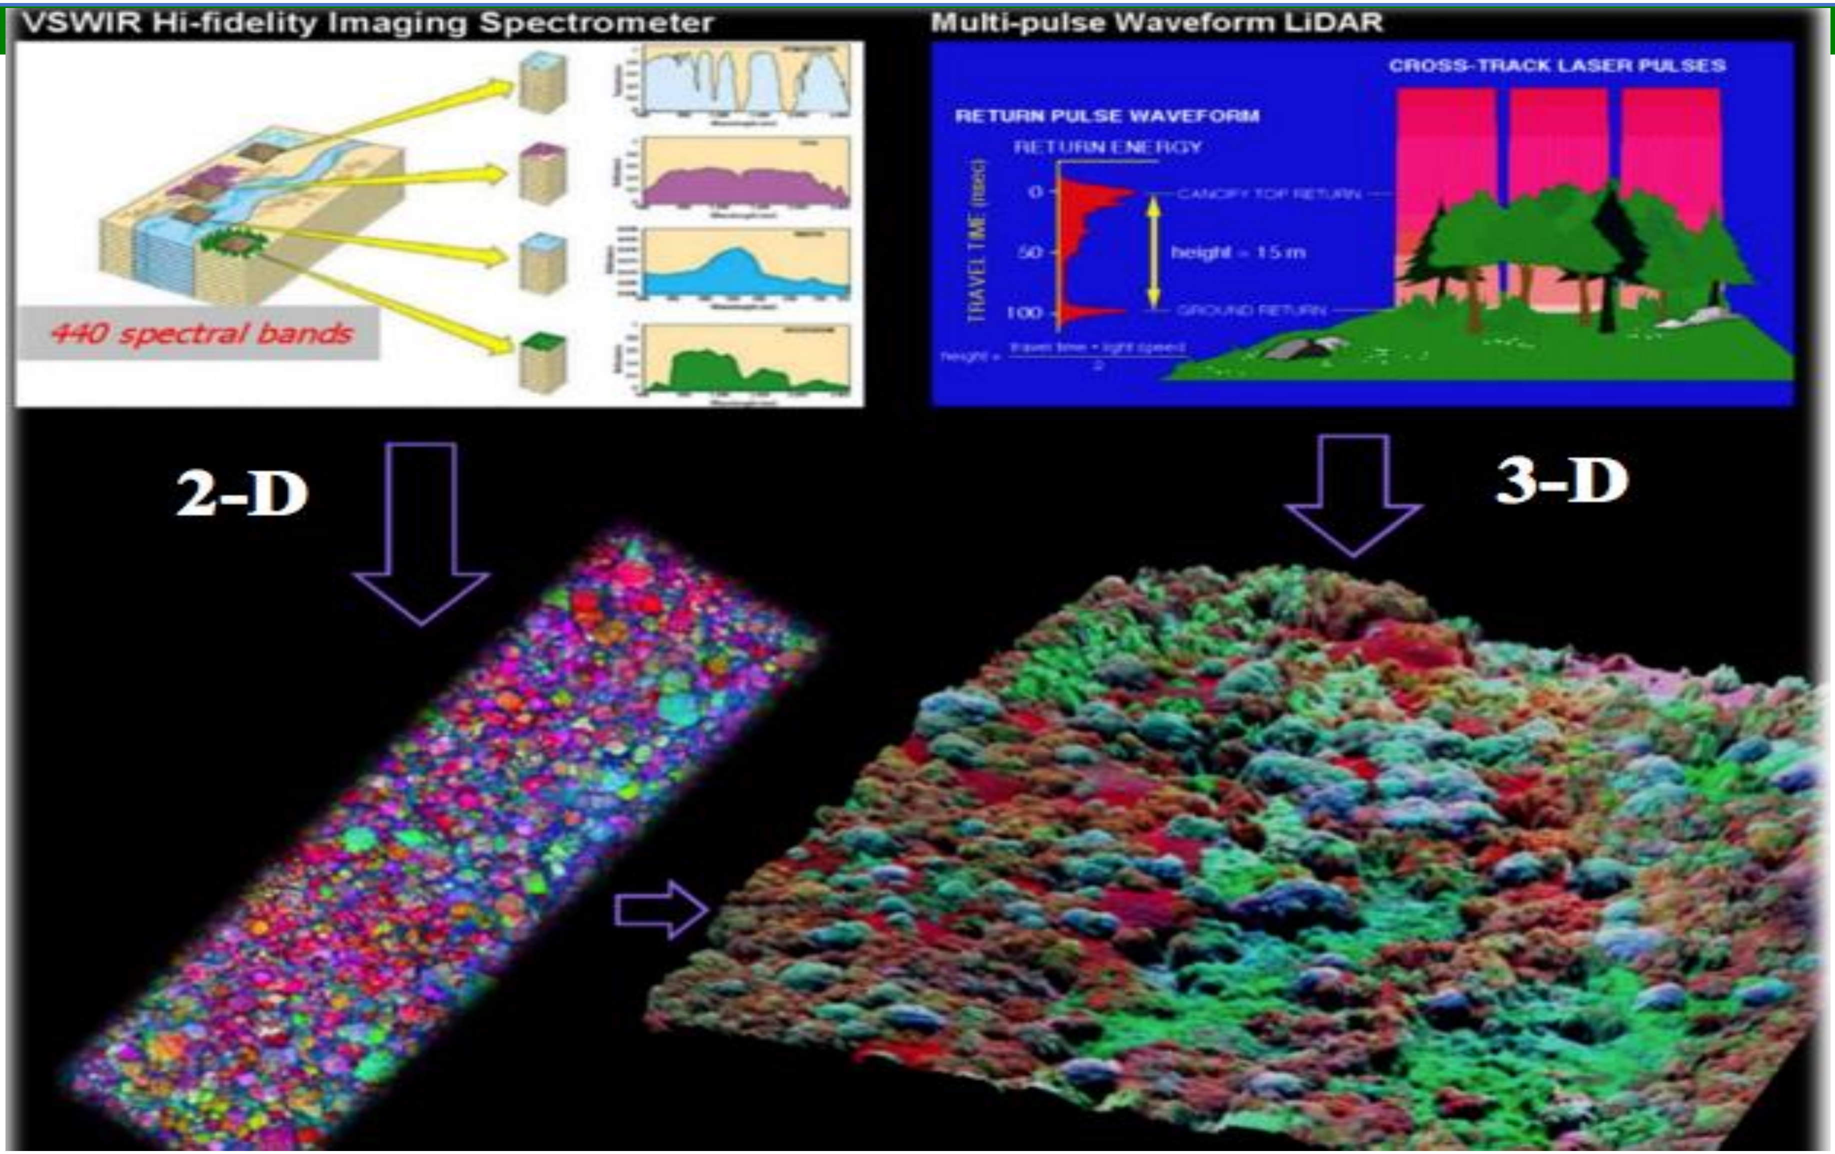


Embrapa Instrumentação
QUALCOMM Wireless Reach
ISES
Pág. 2
COAMO
AGROINDUSTRIAL COOPERATIVA
Análise do Vigor das Plantas
Análise do Índice Vegetativo MPRI
Total
Biomassa por Faixas
Índice Vegetativo
Menor
Médio
Maior
Área (ha)
16,2
2,2
3,7
5,5
3,1
1,6
Pág. 3
SONY
Embrapa
Instrumentação
QUALCOMM
Wireless Reach


Drone fácil de operar
Uma realidade, 2018

Tomada de Decisão

Rápida e após o vôo do drone

Integração da inteligência Artificial

“Deep Learning” para detectar Pragas e Doenças

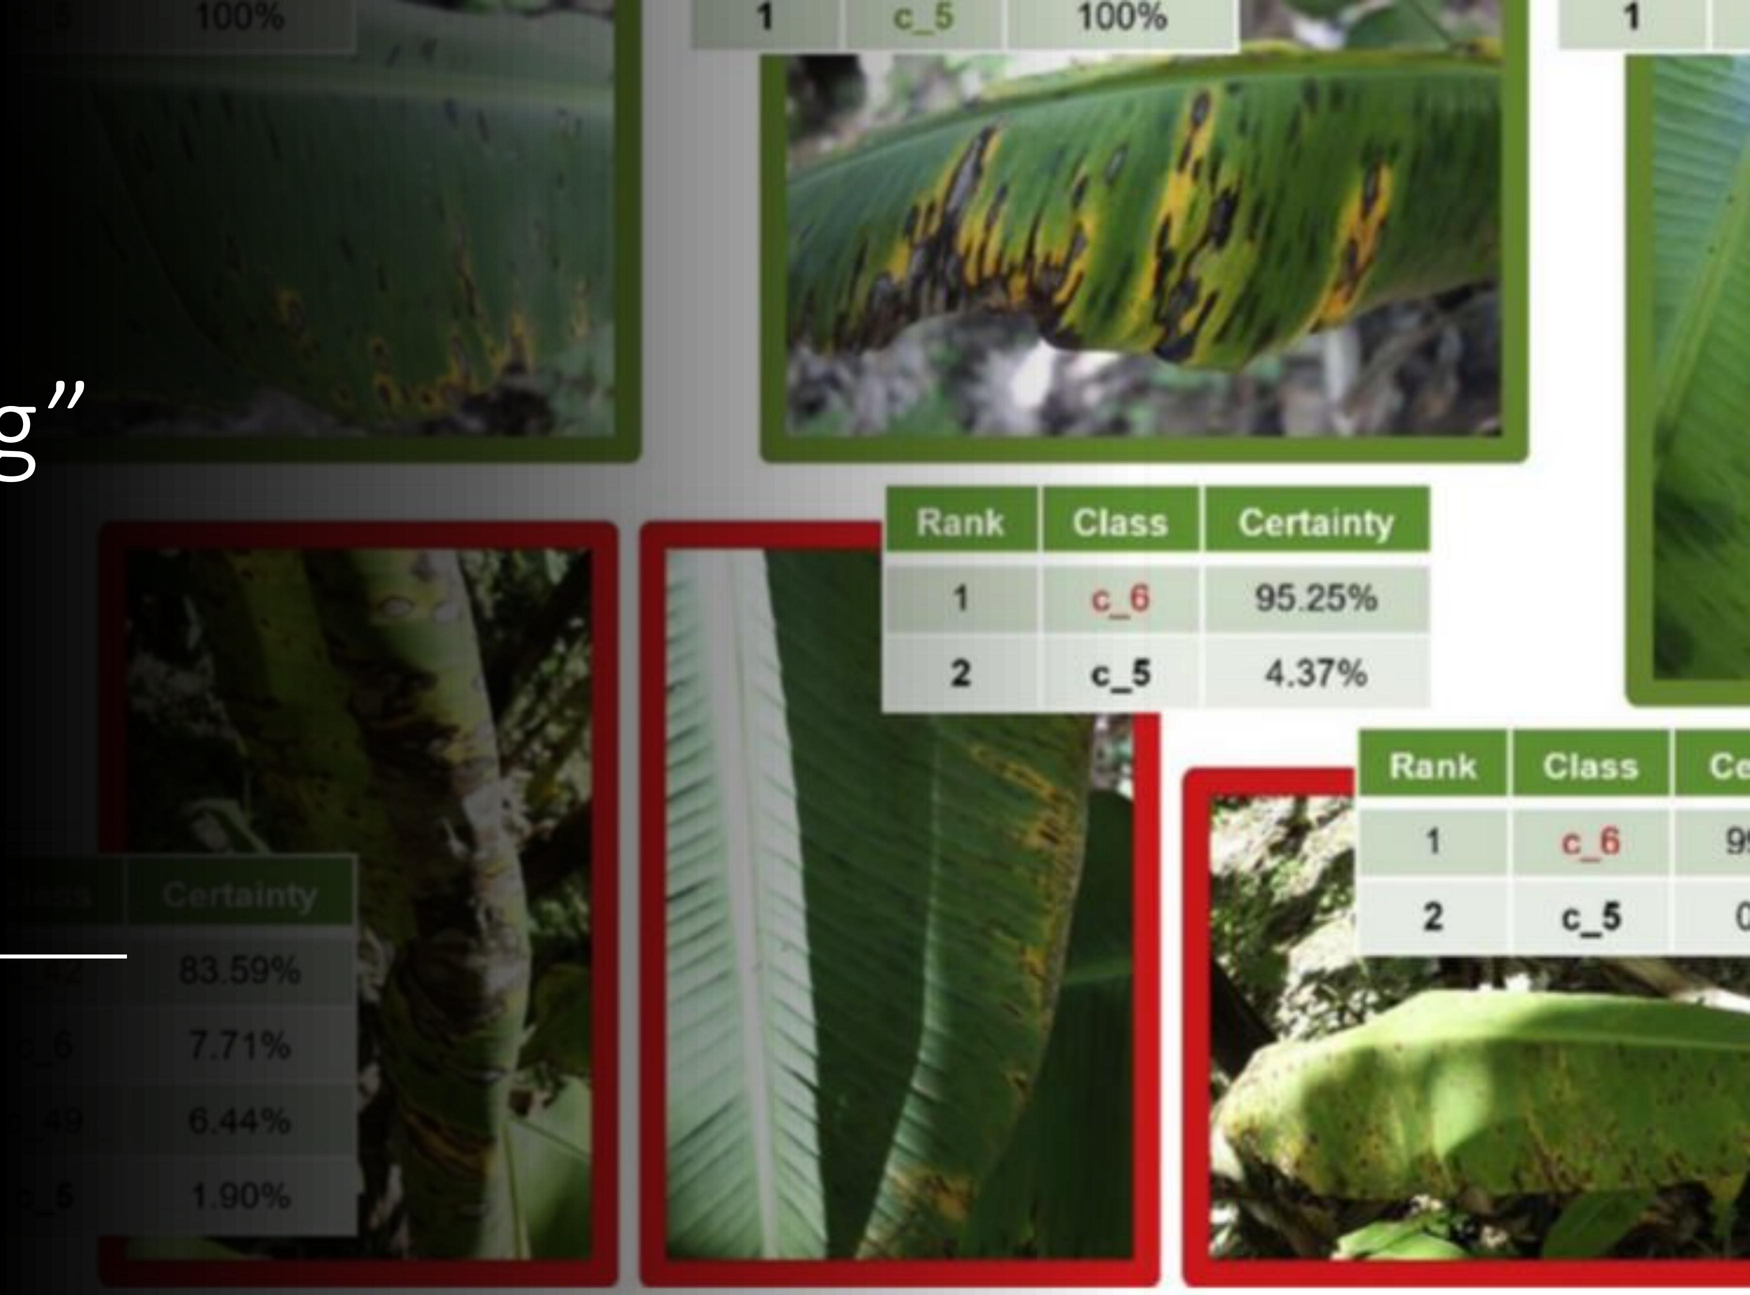

ative examples of correct (green and yellow rectangles) and incorrect (red rectangles) classifications of t
the references to colour in this figure legend, the reader is referred to the web version of this article.)

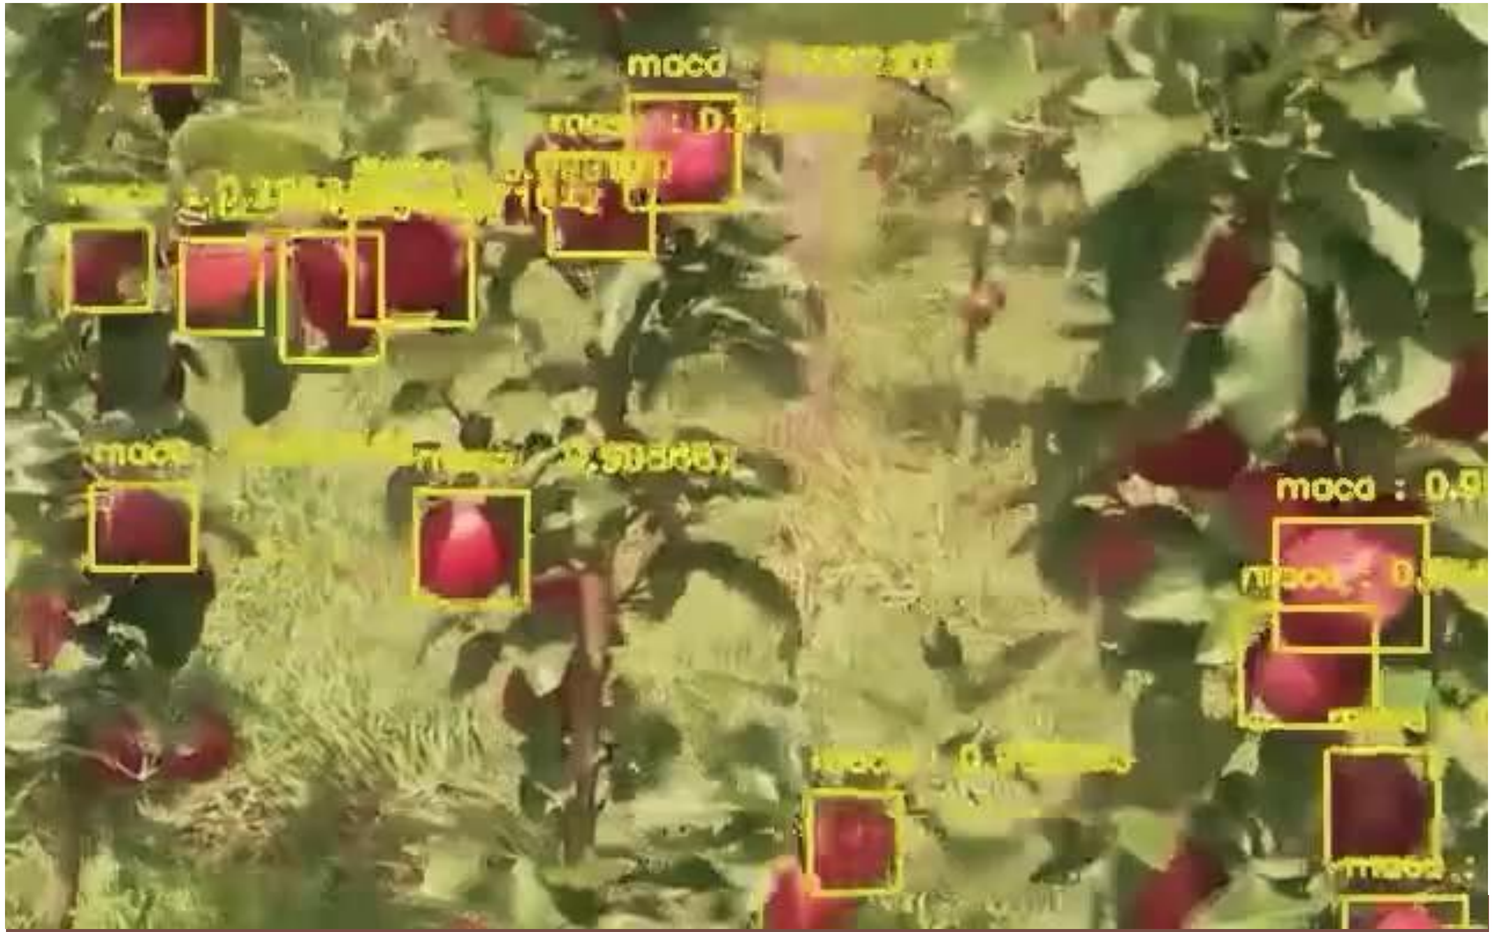

Controle de Produção

- Controle de produção
- Contagem de plantas
- Identificação frutas no ponto de colheita
- Apoio na colheita


400
450
500
550
600
350
375
400
425
450
475
500
525
550


0
200
400
600
800
1000
1200
0
200
400
600
800
1000
1200
1400

Drone contando plantas com CNN embarcados com GPUs dedicadas

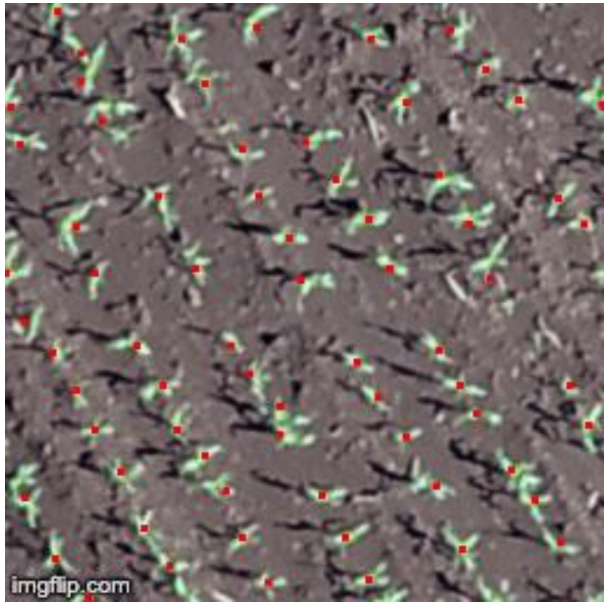

ROBÔS AGRÍCOLAS

Drones colhendo e escolhendo frutas no ponto ideal

Fotos Rafael Moreira Soares

Uso de drones pode auxiliar a atender à demanda de aplicações de defensivos agrícolas em diferentes locais e ambientes

Figura 1 - Croqui da área experimental para o teste de fungicida

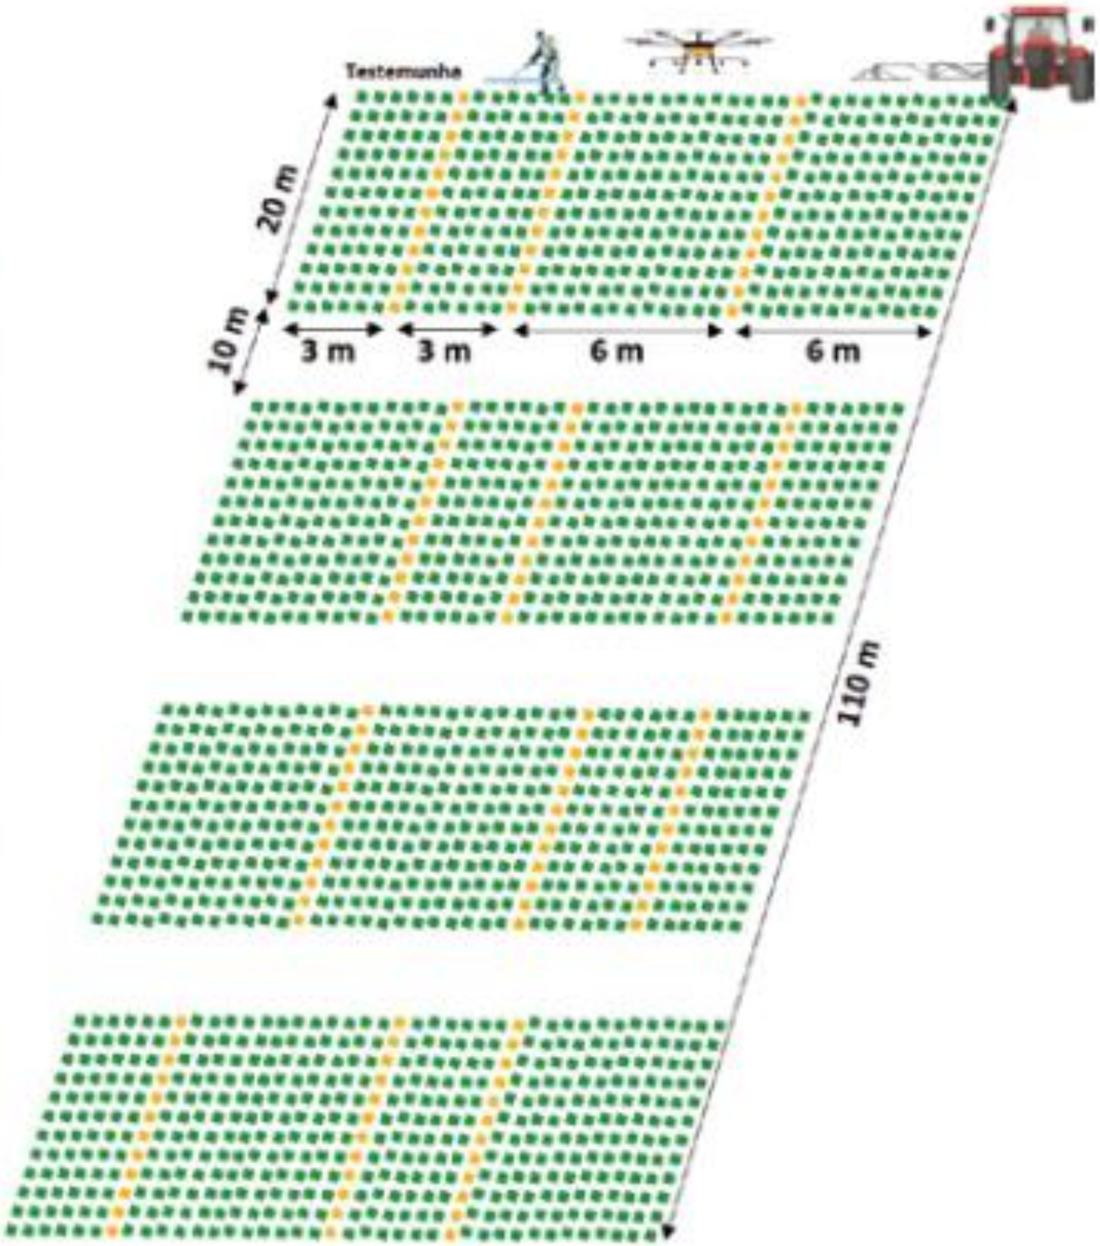

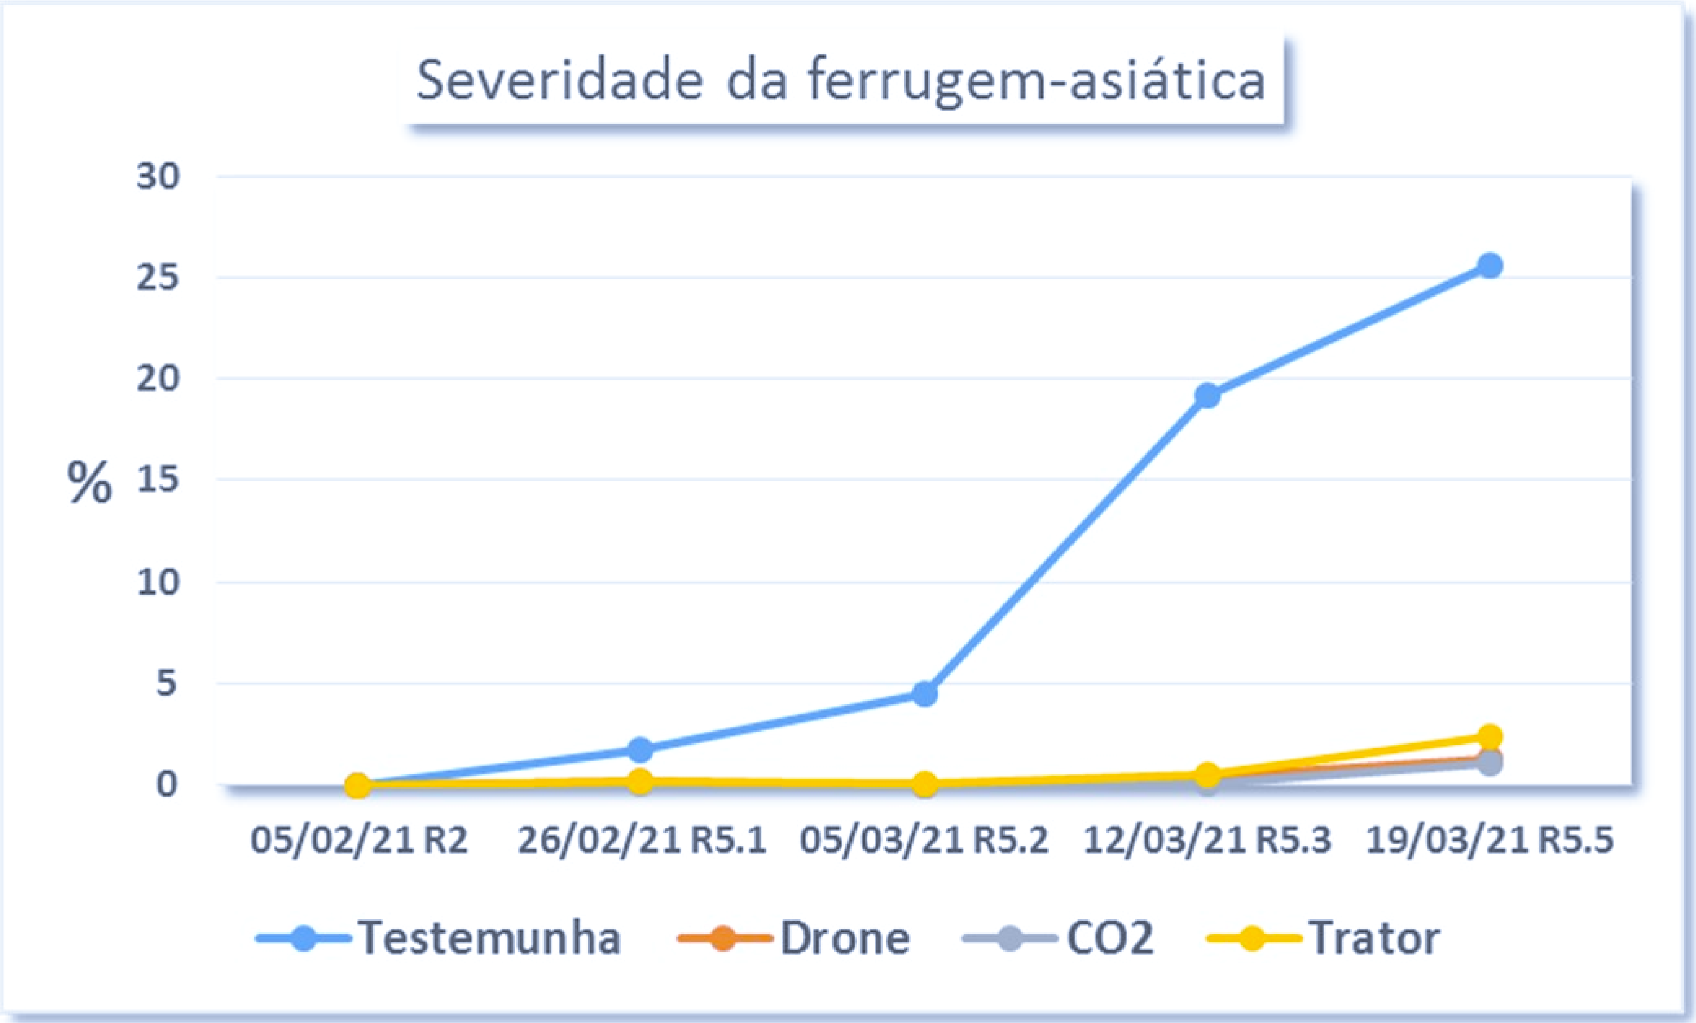

Rafael Moreira Soares,
Fernando Storniolo Adegas e
Samuel Roggia,
Embrapa Soja
Lúcio André de Castro Jorge,
Embrapa Instrumentação Agropecuária
Alberto Kalin Youssef Matulaitis,
Onesolve Tecnologia

A importância das instruções de uso do fabricante sobre a segurança e tecnologia de aplicação para os defensivos agrícolas (químico ou biológico).

Instruções de uso

→ Distância mínima
→ Altura de voo
→ Dose
→ Espectro de gotas

→ Temperatura < 30 ° C,
→ Umidade relativa >50%
→ Velocidade do vento entre 3 e 10 km/h

Aplicação aérea georreferenciada de produtos biológicos

1. ***Trichogramma galloi*:** cana de açúcar
2. ***Trichogramma pretiosum*:** soja, milho, feijão, abacate, frutas, hortaliças e outros cultivos;
3. ***Telenomus podisi*:** soja;
4. ***Telenomus remus*:** milho;
5. ***Cotesia flavipes*:** cana de açúcar

Primeiros resultados parceria Embrapa Instrumentação e BirdView

Aplicador de pós solidos / ovos de inseto

Aplicador de insetos adultos / formulações

Cartucho ‘refil’ para biodefensivos

birdview.com.br


birdview
birdview
DroneScan
birdview.com.br

MONITORAMENTO ORBITAL - SATÉLITE

- O **Google Earth Engine** (GEE) é uma plataforma que oferece múltiplas ferramentas de sensoriamento remoto e processamento de imagens de satélite em grande escala, o que pode ser útil para monitorar diversos problemas agrícolas.

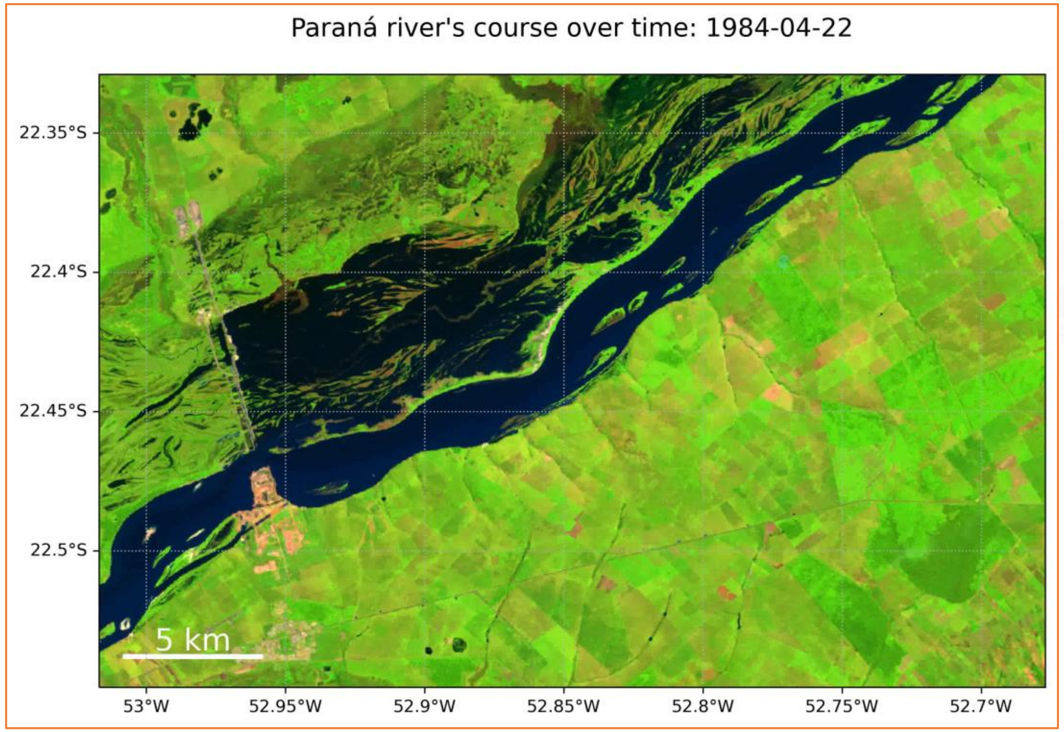

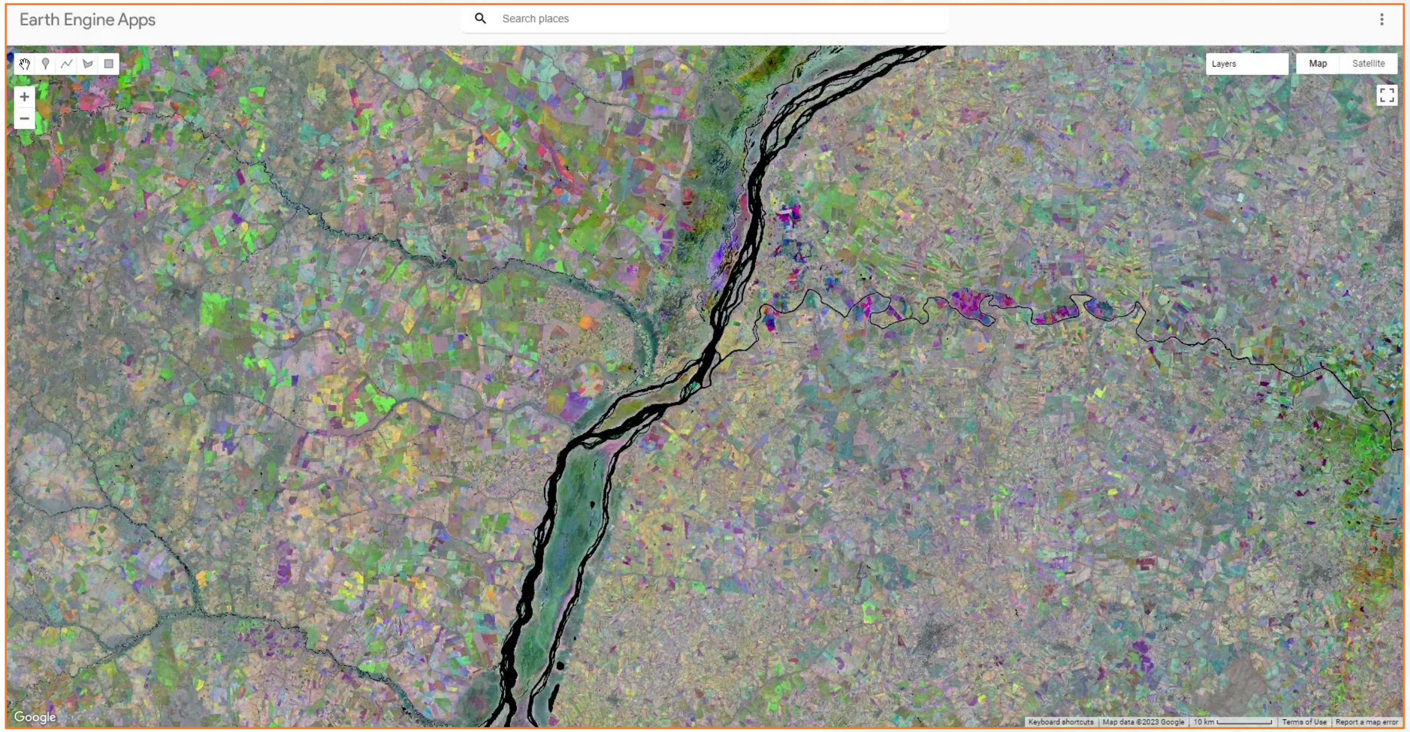

Exemplo no GEE: < https://code.earthengine.google.com/d1c10b4c9dee022b8498f77234158ab9 >

MONITORAMENTO ORBITAL - SATÉLITE

Google Earth Engine

AMSKepler

Smallsat

Mass Class Name	Satellite Mass (M) Kilograms (kg)	
Femto	$M \leq 0.1$	smallsat $\leq$ 600kg
Pico	$0.1 < M \leq 1$	
Nano	$1 < M \leq 10$	
Micro	$10 < M \leq 200$	
Mini	$200 < M \leq 600$	
Small	$600 < M \leq 1,200$	non-smallsat
Medium	$1,200 < M \leq 2,500$	
Intermediate	$2,500 < M \leq 4,200$	
Large	$4,200 < M \leq 5,400$	
Heavy	$5,400 < M \leq 7,000$	
Extra Heavy	$7,000 < M$	

Federal Aviation Administration's Office of Commercial Space Transportation (FAA AST)

2011 to 2022

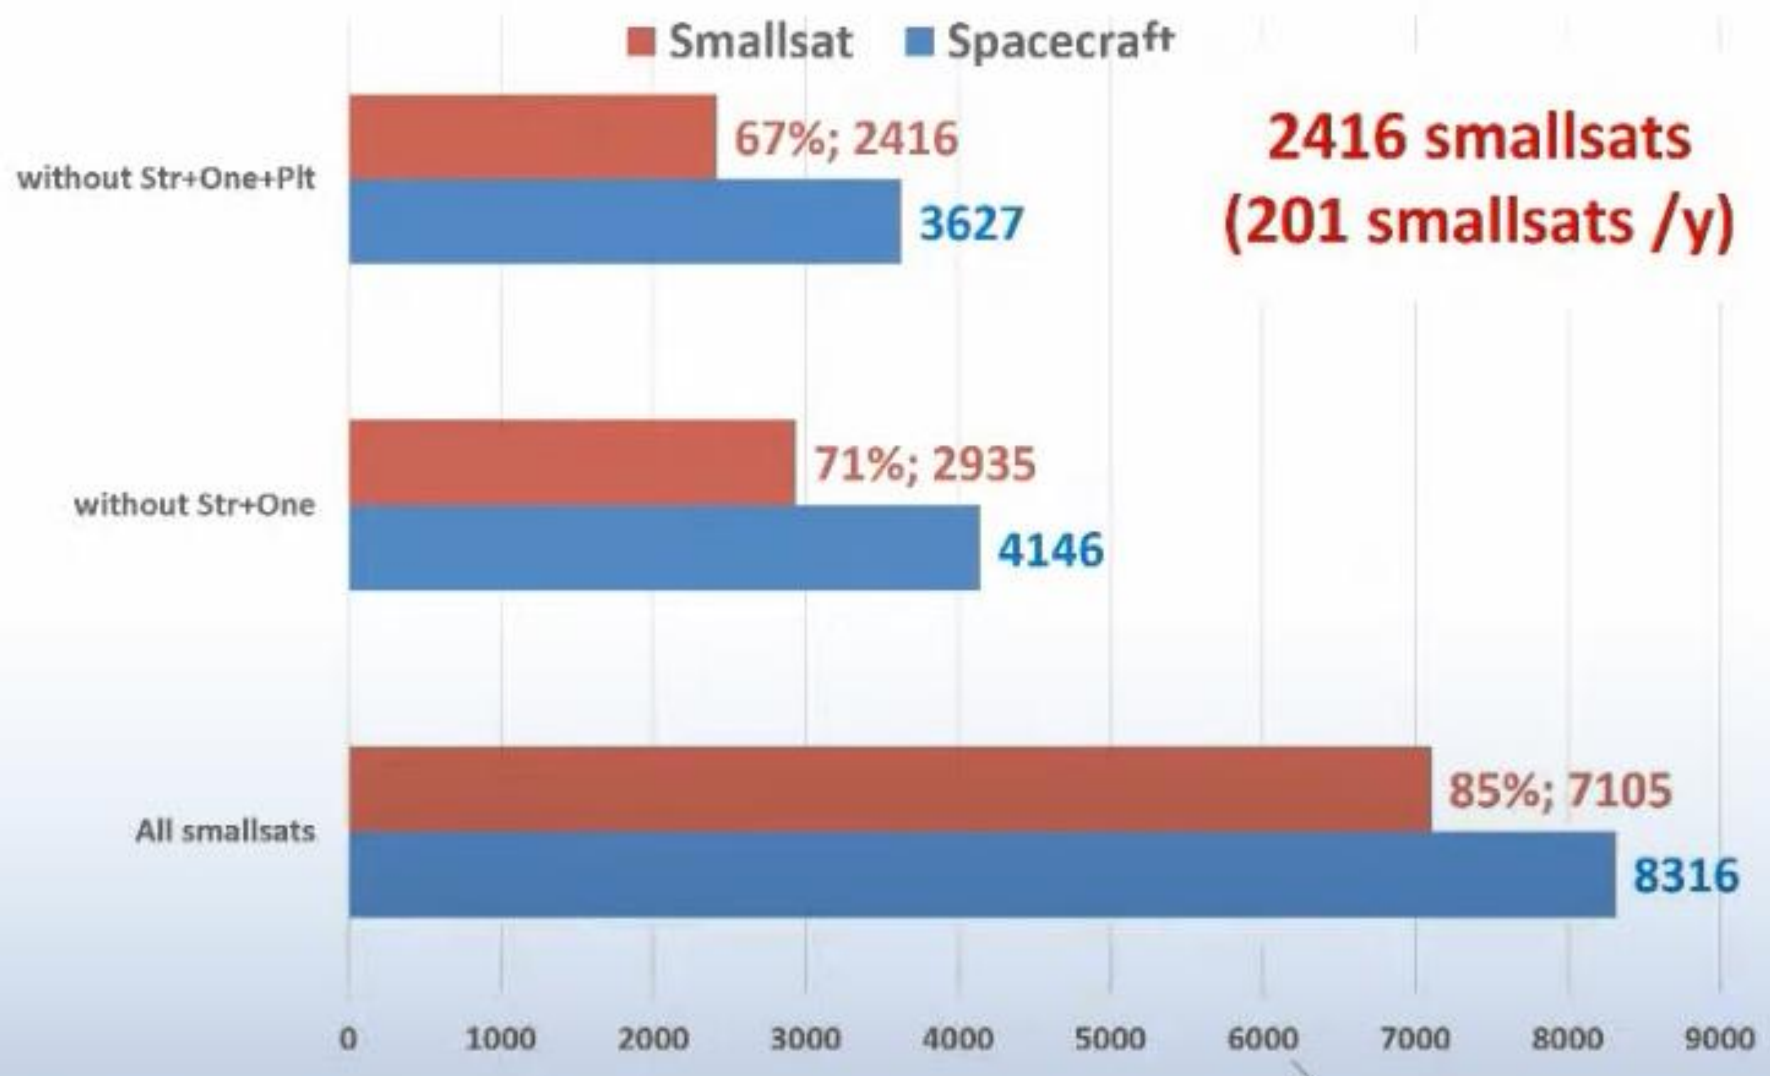

Smallsat
Spacecraft
without Str+One+Plt
67%; 2416
3627
2416 smallsats
(201 smallsats /y)
without Str+One
71%; 2935
4146
All smallsats
85%; 7105
8316
0
1000
2000
3000
4000
5000
6000
7000
8000
9000

AMSKepler

New space companies

BLACKSKY

HYPERSAT

Capella Space

OPEN COSMOS

ICEYE

KUVA SPACE

planet.

UMBRA

pixxel

SATELLOGIC

All smallsats (7105)

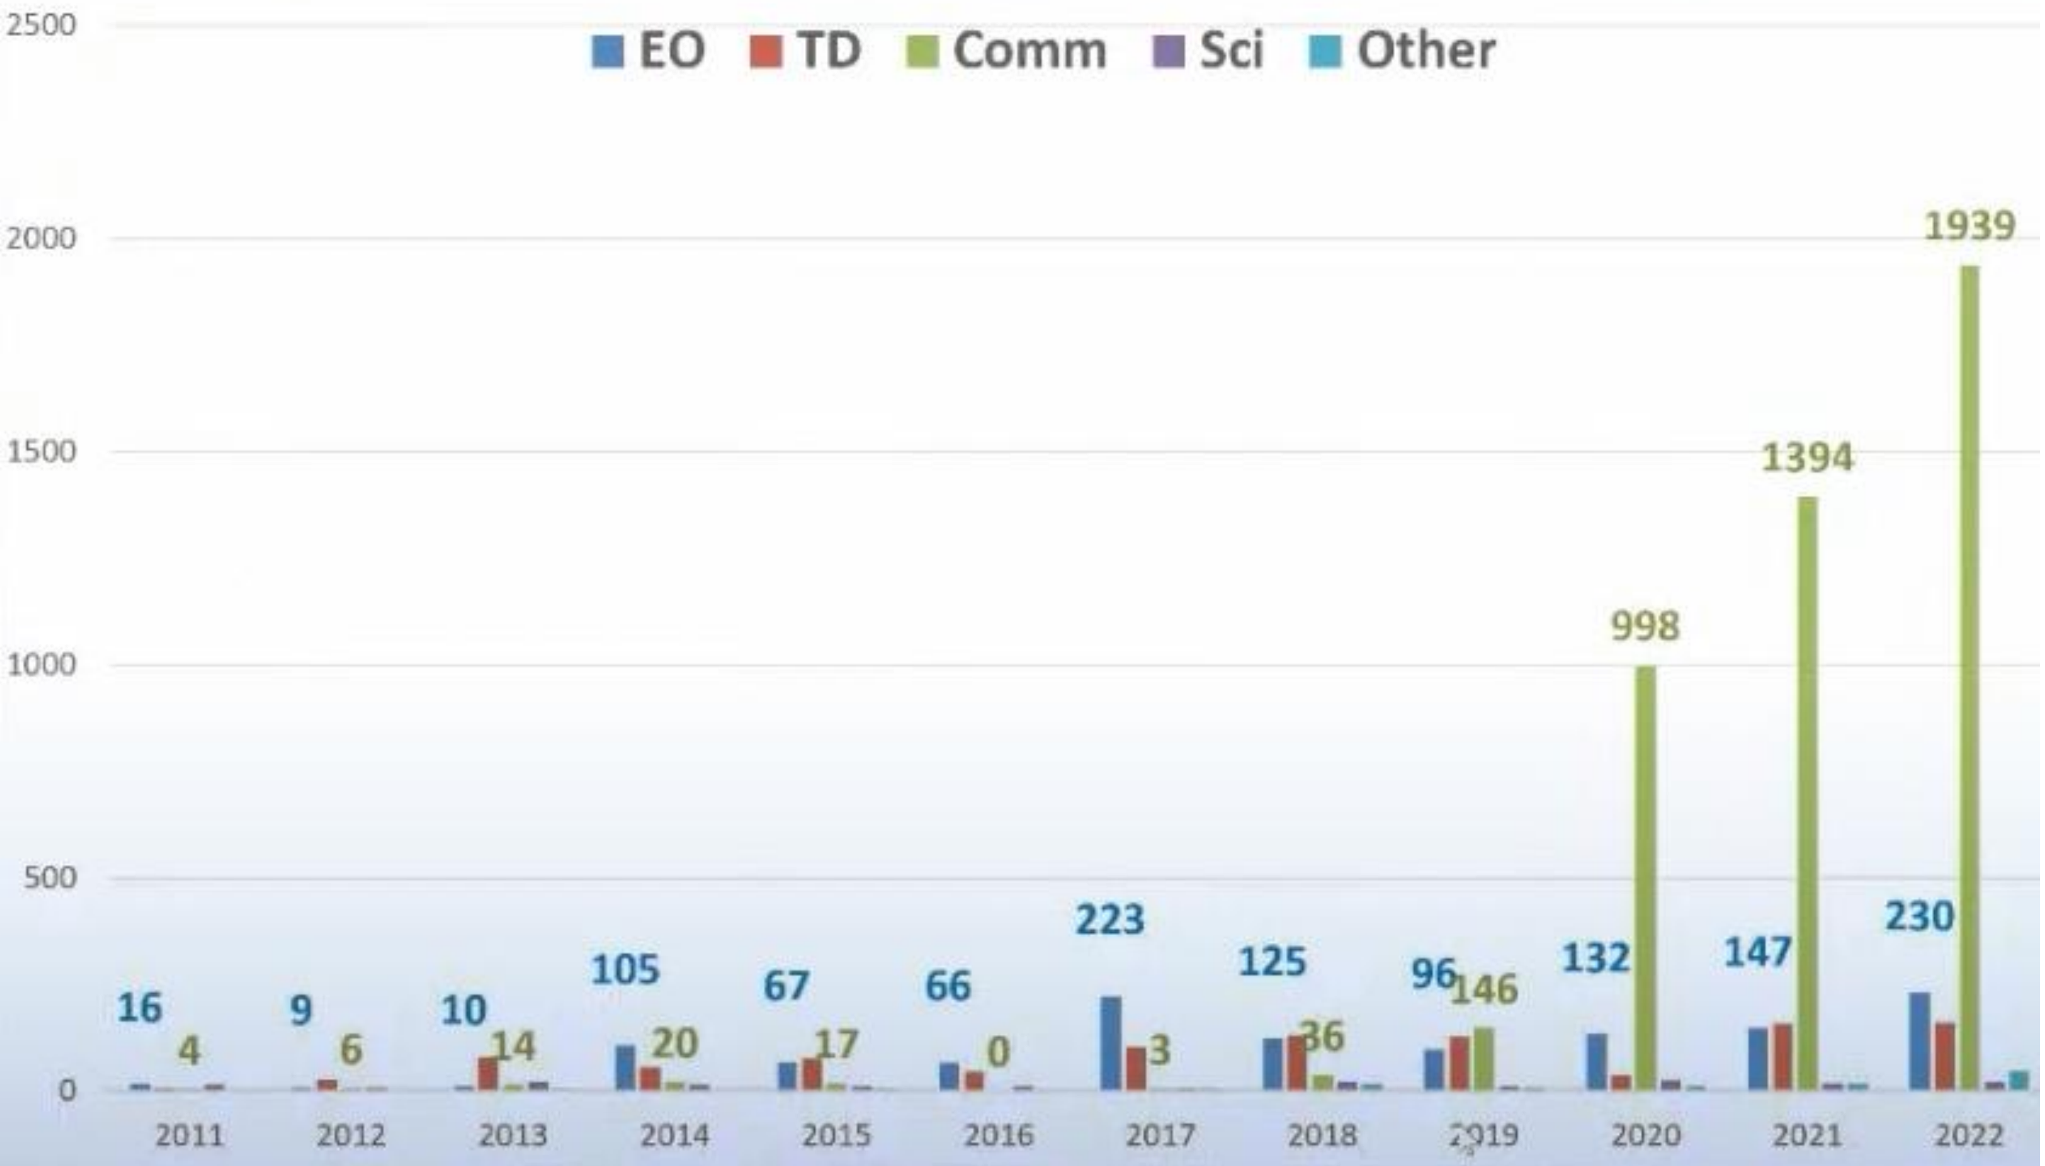

Without Starlink & OneWeb (2935)

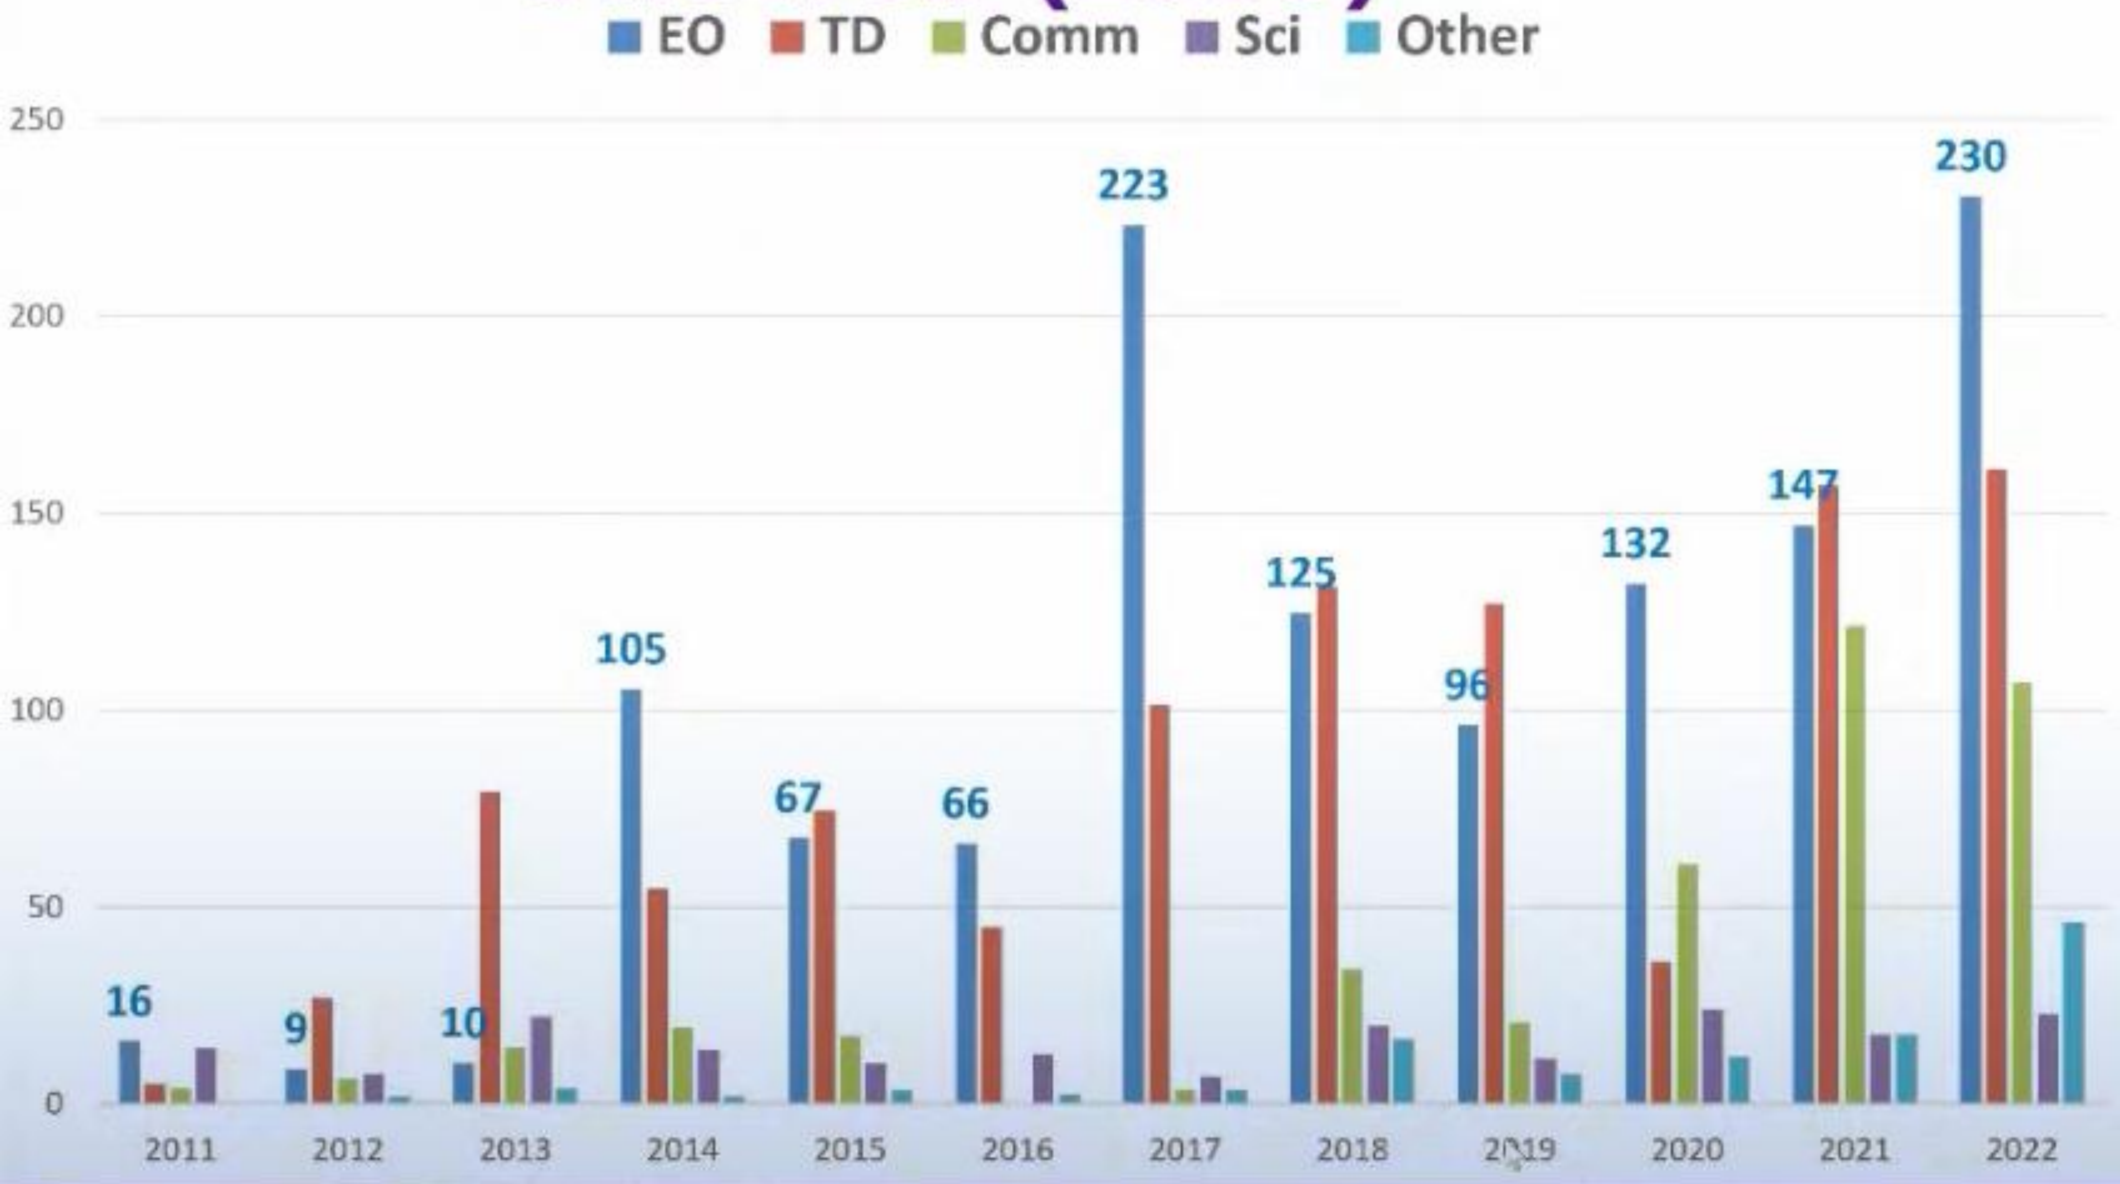

Top 10 Satellite Technology Trends in 2024

1. Small Satellites

"Equipped with smarter and compact subsystems, small satellites are replacing the need for large satellites and related infrastructure. Small satellites are increasingly positioned in LEO constellations for **earth observation (EO)** and remote sensing to generate superior insights."

Top 10 Satellite Technology Trends in 2024

5. Artificial Intelligence

“The large volumes of data collected by satellites pose challenges in data handling, analysis, and timely resource management. Machine learning (ML) and AI enable the analysis of satellite data obtained from earth observation (EO).”

SDSat: Software Defined Satellite

Hyperspectral Imaging Attracts a Host of Space Startups

"Hyperspectral imaging is still in the stages of demonstration and validation."

Aravind Ravichandran, a satellite data strategist for TerraWatch Space

Planet Tanager constellation

High Precision Hyperspectral Data

400nm (visible) to 2500nm (short wave):

+400 spectral bands – 5nm

Planet Pelican constellation – 30cm

"Planet's next-generation satellite constellation for delivering high-resolution, rapid revisit information anywhere on the globe."

”Estamos numa revolução de novas tecnologias. Como você está se preparando para o futuro?”

OBRIGADO

EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária)

Lúcio André de Castro Jorge

2023