

**SERGIO MOURA MEDEIROS ARARUNA DE MENDONÇA**

**USOS DE INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE  
OBJETOS E ESPAÇOS ATRAVÉS DE IMAGENS HIPERESPECTRAIS**

Trabalho de Conclusão de Curso  
apresentada à Escola Politécnica da  
Universidade de São Paulo como  
requisito parcial para Graduação no  
Curso de Engenharia Elétrica

São Paulo

2022

SERGIO MOURA MEDEIROS ARARUNA DE MENDONÇA

USOS DE INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE OBJETOS E  
ESPAÇOS ATRAVÉS DE IMAGENS HIPERESPECTRAIS

Trabalho de Conclusão de Curso apresentada à  
Escola Politécnica da Universidade de São  
Paulo como requisito parcial para Graduação  
no Curso de Engenharia Elétrica

Orientador: Prof. Dr. Felipe Pait

São Paulo

2022

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catalogação-na-publicação

MENDONÇA, SERGIO

USOS DE INTELIGÊNCIA ARTIFICIAL PARA CLASSIFICAÇÃO DE  
OBJETOS E ESPAÇOS ATRAVÉS DE IMAGENS HIPERRESPECTRAIS / S.  
MENDONÇA -- São Paulo, 2022.

36 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São  
Paulo. Departamento de Engenharia de Telecomunicações e Controle.

1.SENSORIAMENTO REMOTO 2.ESPECTOMETRIA I.Universidade de  
São Paulo. Escola Politécnica. Departamento de Engenharia de  
Telecomunicações e Controle II.t.

## **AGRADECIMENTOS**

Devo os agradecimentos do presente trabalho de conclusão e a conclusão em si do curso a um número enorme de pessoas, mas cito aqui com muito carinho algumas delas.

Gostaria de agradecer a todos os professores da banca da disciplina PTC3530, sempre cordiais e muito dispostos a ajudar.

Agradeço também ao professor da École Centrale Marseille, Salah Bourennane, e aos 4 integrantes do grupo que começou este estudo ainda durante meu duplo diploma na escola francesa: Fleur de Font-Réaulx, Hind Choukri, Laetitia Demerens e Quentin Tribal Bayol.

Agradeço especialmente aos pesquisadores da universidade de Las Palmas de Gran Canaria que desenvolveram estudos importantes sobre o sujeito deste projeto e cordialmente me cederam acesso à uma extensa base de dados criada por eles.

Agradeço, por fim, toda minha família e especialmente a senhorita Jaqueline Estelita que esteve comigo durante esses últimos 5 anos de curso e me ajudou muito durante todo o percurso.

## **RESUMO**

Sensoriamento hiperespectral caracteriza-se como uma tecnologia que captura e analisa todo o espectro eletromagnético refletido ou emitido por objetos, permitindo a criação de imagens multiespectrais de alta resolução, as quais contém informações detalhadas sobre a composição e propriedades dos objetos. No presente trabalho estuou-se as aplicações desta tecnologia em campos como a medicina, tratamento de resíduos e outras utilizações que envolvam classificação de imagens. Através de algoritmos de *machine learning* criou-se um classificador não supervisionado. O objetivo final é demonstrar que esse mesmo classificador pode ser empregado para resolver problemas de diversos campos e assim chamar atenção para o potencial dessa tecnologia.

Palavras-chaves: inteligência artificial; *machine learning*; classificação; hiperspectral.


## SUMÁRIO

1.	INTRODUÇÃO .....	6
2.	ALGORITMOS DE CLASSIFICAÇÃO .....	7
2.1.	CLASSIFICAÇÃO NÃO SUPERVISIONADA <i>K-MEANS CLUSTERING</i>	7
2.2.	CLASSIFICAÇÃO SUPERVISIONADA MAXIMUM LIKELIHOOD CLASSIFICATION .....	9
2.2.1.	TREINAMENTO DE DADOS .....	9
2.2.2.	<i>MAXIMUM LIKELIHOOD</i> EM CÓDIGO.....	10
3.	MODELO COMPUTACIONAL E SIMULAÇÕES.....	10
3.1.	MÓDULO SPECTRALPYTHON (SPY).....	10
3.2.	BASES DE DADOS .....	10
3.3.	CÓDIGO.....	11
3.4.	MODELO DE APLICAÇÃO INICIAL .....	11
3.5.	SIMULAÇÃO <i>K-means</i> .....	11
3.5.1.	RESULTADOS DA SIMULAÇÃO.....	12
4.	SIMULAÇÃO <i>MAXIMUM LIKELIHOOD</i> .....	16
5.	TRIAGEM DE RECICLÁVEIS EM CTR .....	19
6.	ATIVIDADES REALIZADAS SEMESTRE 1 .....	20
7.	PROPOSTAS DE INTERVENÇÃO.....	21
8.	DETECÇÃO DE CÂNCER DE PELE .....	22
8.	ACOMPANHAMENTO DE MÉTODOS DE RESTAURAÇÃO ECOLÓGICA .....	30
	REFERÊNCIAS BIBLIOGRÁFICAS.....	34

## 1. INTRODUÇÃO

Imagens hiperespectrais, diferentemente das comuns, guardam todo o espectro eletromagnético. Portanto, o uso delas permite a extração da composição químicas de objetos.

Tais imagens são, na verdade, a superposição de centenas de outras imagens matrizes, onde cada matriz contém uma banda do espectro eletromagnético. A junção de todas as bandas gera um hipercubo que é finalmente chamado de imagem hiperespectral. Cada pixel desta imagem é, na realidade, uma curva no espectro eletromagnético que revela a composição do que se encontra neste pixel.



1

Na imagem acima podemos notar a esquerda o hipercubo e a direita um gráfico onde o eixo x representa um comprimento de onda e o eixo y uma reflectância. Esse gráfico é na verdade a curva espectral do pixel destacado, cada ponto do gráfico é na verdade a reflectância de um mesmo pixel em diferentes bandas do espectro. Dessa maneira, ao contrário de uma imagem comum onde cada ponto contém uma informação que nada mais é do que uma cor,

<sup>1</sup> Geotecnologia Aplicada em Agricultura e Floresta. **MERCADO GLOBAL DE SENSORIAMENTO REMOTO HIPERESPECTRAL REGISTRA CRESCIMENTO.** Disponível em <<https://pesquisa.unemat.br/gaaf/noticia/130/mercado-global-de-sensoriamento-remoto-hiperespectral-registra-crescimento>>. Acesso em Acesso em: 14 de abril de 2022.

neste tipo de imagem cada ponto contém a informação sobre todo o espectro da luz que se reflete dele, e, portanto, sua composição.

## 1. OBJETIVO DO PROJETO

A geração e a análise rápida destes cubos pode ser amplamente utilizada em diversos campos. Imagens como estas, registradas a partir de satélites, permitem, por exemplo, a análise da composição de solos e revelam informações sobre a saúde de grandes plantações; podem também ser utilizadas em bacias hidrográficas e na exploração de recursos naturais. O objetivo deste projeto é se utilizar inteligência artificial para a classificação de diferentes áreas dentro dessas imagens e realizar uma prova de conceito do código criado aplicando-o para a resolução de diversos problemas. Assim, pretende-se ao fim deste projeto demonstrar o potencial da tecnologia de sensoriamento hiperespectral e chamar atenção para o uso dessa tecnologia em áreas que não somente o mapeamento geográfico ou o estudo da composição química de estrelas, áreas onde a tecnologia é mais proeminente hoje. O primeiro exemplo do uso do referido algoritmo será no processo de triagem de lixo dentro de uma CTR, central de tratamento de resíduos. Futuramente, outras oportunidades de desenvolvimento serão exploradas a fim de tornar a tecnologia acessível e mais utilizada.

## 2. ALGORITMOS DE CLASSIFICAÇÃO

Problemas de classificação em *machine learning* se baseiam em métodos algorítmicos para a minimização de diferenças ou resíduos quando comparando dados. O objetivo deste projeto é encontrar uma maneira eficiente de classificar um conjunto de dados 3D sem supervisão, isto é, sem comparação com uma base de dados pré-existente. O algoritmo deve ser capaz de diferenciar os dados entre si utilizando apenas o conjunto que se quer classificar como base para tomada de decisão. O algoritmo escolhido inicialmente para tal proposta é conhecido como *k-means clustering*.

### 2.1. CLASSIFICAÇÃO NÃO SUPERVISIONADA K-MEANS CLUSTERING

Considerando um conjunto de dados, o algoritmo dividirá este conjunto em  $k$  clusters através de um método iterativo de complexidade *NP-hard*. A quantidade de interações realizadas será determinada pela diferença entre a quantidade de *pixels* realocados entre a iteração “P” e “P-1”. Neste caso, a complexidade do algoritmo é  $O(n^dk+1)$ .

De modo exemplificativo, o algoritmo funciona em duas etapas, quais sejam, (i) etapa de atribuição; e (ii) etapa de atualização de centroides. Veja-se:

### I. Etapa de atribuição

$K$  centroides são escolhidos aleatoriamente entre a amostra. A partir disso, cada dado será atribuído ao centroide menos distante dele utilizando a definição euclidiana de distância:

$$S_i^{(t)} = \left\{ x_p : \|x_p - m_i^{(t)}\|^2 \leq \|x_p - m_j^{(t)}\|^2 \forall j, 1 \leq j \leq k \right\},$$

### II. Etapa de atualização

É calculado o centro de cada cluster e assim repete-se segunda parte da primeira etapa utilizando os novos  $K$  clusters

$$m_i^{(t+1)} = \frac{1}{|S_i^{(t)}|} \sum_{x_j \in S_i^{(t)}} x_j$$

Uma das principais características deste algoritmo, também sendo vista como uma de suas desvantagens a partir de outra perspectiva, é o fato de “K” ser um *input*, fazendo com que a quantidade de classes nas quais se quer classificar o conjunto de estudo deva ser previamente fornecida, o que compromete a autossuficiência do código. No entanto, para aplicações nas quais se conhece o conjunto estudado e sabe-se em quantas classes se pode dividi-lo, o algoritmo é extremamente preciso e eficiente. Além disso, o *k-means* pode facilmente tratar conjuntos tridimensionais ou de diversas dimensões, já que considera a minização da norma euclidiana como parâmetro de classificação.

## **2.2. CLASSIFICAÇÃO SUPERVISIONADA MAXIMUM LIKELIHOOD CLASSIFICATION**

O método *Maximum likelihood classification* se baseia em tentar predizer a classe y de um valor observado x que maximize a função de probabilidade do valor observado x. Uma vez estabelecidas funções de probabilidade  $Y_i(x)$ , que são as classes nas quais treinamos nosso algoritmo. Observado um valor de x assume-se que a classe que possui a máxima probabilidade  $Y_i(x)$  é a classe correta para aquele valor observado. Portanto, a fim de classificar a imagem é preciso primeiramente treinar os dados, e o treinamento desses dados é exatamente a criação destas funções de probabilidade. Uma vez o algoritmo treinado, ou seja, as funções de probabilidade criadas, basta calcular o máximo  $Y_i(x)$  e assumir  $Y_i$  como a classe do valor observado x.

### **2.2.1. TREINAMENTO DE DADOS**

O treinamento de dados consiste em fornecer ao algoritmo uma folha resposta, a qual consiste em uma cópia de uma banda da imagem original onde cada pixel recebe o número de sua classe. Essa folha resposta é utilizada então pelo algoritmo de treinamento para gerar as funções de probabilidades de cada classe. Com a folha resposta e a imagem original que gerou esta folha pode-se construir a distribuição de cada um dos centros ou seja, a quantidade de pixels em cada comprimento de onda que compõe uma classe. Esta distribuição será utilizada para construir a distribuição gaussiana que guiará o algoritmo de *maximum likelihood*. Do ponto de vista do algoritmo basta que se possua uma imagem parecida com as imagens as quais se quer classificar. Isto é, necessita-se de ao menos uma imagem classificada. Possuindo uma imagem classificada pode-se classificar imagens com o mesmo número de bandas e que possuam os mesmos elementos daquilo que se deseja classificar.

$$f(x) = \frac{1}{\sqrt{(2\pi)^d \det \Sigma}} \cdot e^{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)}$$

where:

$x$  = a column vector with data from one observation

$d$  = dimension of  $x$  ( $x$  is a  $d \times 1$  vector)

$\mu$  = mean of  $x$  (also  $d \times 1$ )

$\Sigma$  = covariance matrix of  $x$  ( $d \times d$ )

### 2.2.2. MAXIMUM LIKELIHOOD EM CÓDIGO

O código consiste em uma função de treinamento, uma classe classificadora que toma uma imagem e uma folha resposta como parâmetros e retorna as classes, isto é, as funções de probabilidade. Um objeto da classe classificadora pode então ser instanciado e a função “classify” utilizada para classificar qualquer imagem.

A inclusão de um algoritmo de classificação supervisionada tornará o código mais robusto para algumas das aplicações possíveis e também de velocidade otimizada. Pode-se, inclusive, utilizar a imagem classificada de um método de classificação não supervisionado como *input* para classificações supervisionadas posteriores.

## 3. MODELO COMPUTACIONAL E SIMULAÇÕES

O código que se encarregará do problema foi desenvolvido em python com a ajuda da biblioteca SpectralPython (Spy).

### 3.1. MÓDULO SPECTRALPYTHON (SPY)

A Biblioteca é um módulo python desenvolvido no M.I.T para o processamento de imagens hiperespectrais, sendo utilizado para ler, manipular, visualizar e classificar imagens.

### 3.2. BASES DE DADOS

Imagens hiperespectrais são geradas por câmeras especiais capazes de criar imagens através das espectroscopias HS, PFD, SCMOS, ENIR, CMOS, NIR, SWIR, MWIR, LWIR. Estes equipamentos podem custar de R\$ 30.000,00 (trinta) a R\$ 100.000,00 (cem) mil reais e são amplamente utilizados no estudo da astronomia. Apesar de muito utilizadas no campo da pesquisa, bases de dados com esse tipo de imagem são de difícil acesso, geralmente disponibilizadas por universidades. Bases gerenciadas pelo M.I.T e Harvard serão utilizadas como base para a criação e validação do modelo sugerido neste projeto.

### **3.3. CÓDIGO**

O módulo python SPY possui uma função para a classificação utilizando o algoritmo *kmeans* na qual uma imagem e um número de clusters são parâmetros de entrada. Além disso, as bibliotecas *numpy*, *matplotlib* e *scipy* são utilizadas para tratamento dos dados e visualização dos resultados.

### **3.4. MODELO DE APLICAÇÃO INICIAL**

A primeira proposta de aplicação do projeto, e sob a qual o projeto inicialmente desenvolvido na escola francesa Centrale Marseille foi baseado, é a triagem de lixo em uma usina de reciclagem. Além da classificação da imagem entre classes de lixo, também foi modelado braço mecânico que receberia a localização do centro de massa de cada objeto na imagem, para que a retirada do objeto fosse possível. Nesse caso, o código consistirá no carregamento de uma imagem, classificação desta em *k clusters* e fornecimento do centro de massa de cada objeto da imagem a partir dos clusters classificados.

### **3.5. SIMULAÇÃO *K-means***


Considerando a evidente dificuldade do encontro e da geração das imagens hiperespectrais, não foi possível, ainda, testar o modelo com imagens de lixo em uma usina de reciclagem. Em contrapartida, foram utilizadas imagens de um banco de dados criado por Harvard para propósitos de pesquisa. Dentre estas, serão usados como exemplos de execução do código imagens realizadas pelo satélite AVIRIS no noroeste de Indiana sobre áreas de

floresta e plantações, bem como imagem de um sofá com poucos elementos diferentes presentes. A partir dos testes, ficaram claras as principais desvantagens do algoritmo e os seus pontos fortes.

### **3.5.1. RESULTADOS DA SIMULAÇÃO**


O primeiro teste aqui descrito foi realizado com uma imagem registrada pelo satélite ARIVIS no noroeste de Indiana, Estados Unidos. A cena consiste em um terreno que possui uma plantação de diversas hortaliças e legumes; esta imagem está presente em diversas pesquisas de algoritmos de classificação sensorial e nos permite, portanto, comparar resultados e se aproveitar de classificações pré-existentes para avaliar a acurácia do programa.

#### **I. SalinasA**



2

A imagem acima foi classificada inicialmente em 16 *clusters*. Sabe-se que existem dentro da imagem plantações de pelo menos 16 tipos diferentes de vegetal, de acordo com a fonte consultada. Com a simetria do terreno e das plantações espera-se encontrar fronteiras bem definidas entre os *clusters*. Os resultados são os seguintes:



3

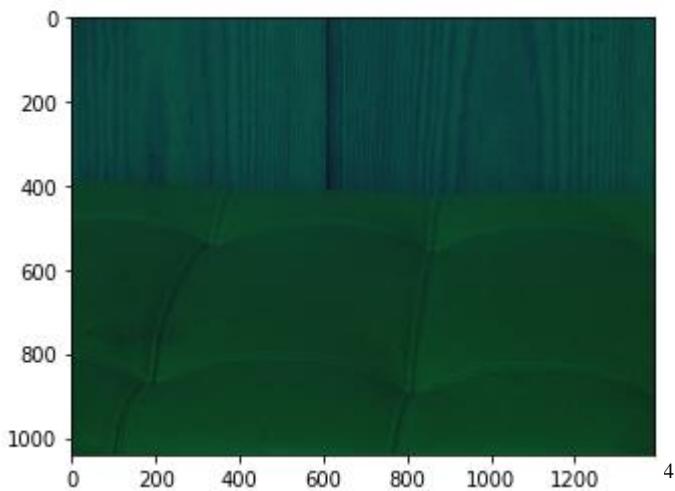
Como esperado, as fronteiras entre as plantações são bastante definidas e a execução do código levou cerca de 35 (trinca e cinco) segundos, contando com 30 (trinta) interações. As curvas espectrais dos centroides dos *clusters* revelam alguns padrões bastante similares entre si, que indicam a possibilidade de existência de ainda mais grupos de elementos dentro da imagem. De todo modo, o resultado inicial é bastante satisfatório, com uma série grande de pixels classificados e um tempo de execução razoavelmente baixo.

## II. Ambiente interno – Sofá

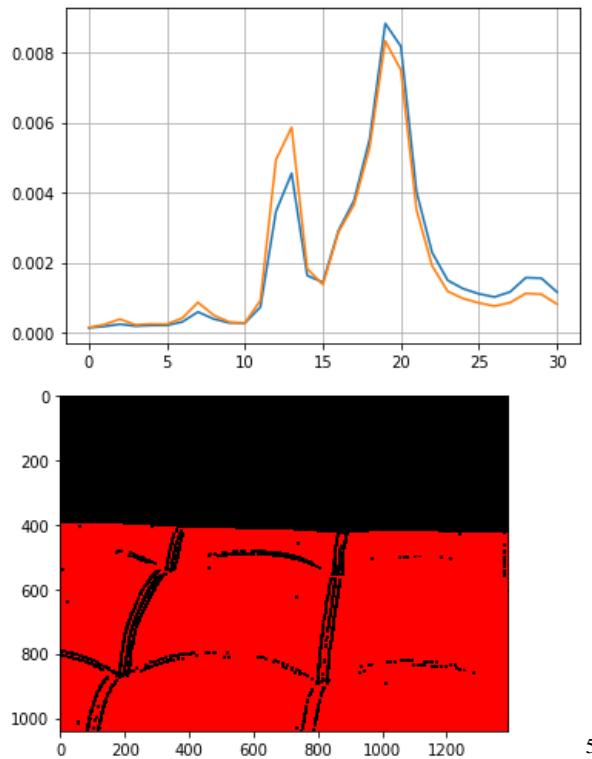
A segunda simulação foi realizada em uma imagem de um ambiente interno com apenas um sofá e uma parede de madeira na imagem.

---

<sup>3</sup> **Hyperspectral image classification.** Github. Disponível em <<https://github.com/breathingcyborg/hyperspectral-image-classification>>



A imagem é interessante, pois avaliará não somente a velocidade de execução ou capacidade de lidar com grande quantidade de dados e classes, mas também a acurácia da classificação. Tem-se apenas dois elementos na imagem e espera-se que estes sejam perfeitamente classificados. Os resultados são os seguintes:



Como esperado, o sofá e a madeira foram perfeitamente diferenciados. Algo interessante nesta simulação foi a classificação da costura do sofá no mesmo grupo da madeira da parede.

---


<sup>4</sup> Imagem RGB do sofá estudado

<sup>5</sup> Espectro do centroide da classificação e mapa da classificação gerada pelo algoritmo

Isso revela que a composição do tecido da costura está mais próxima da madeira do que do couro do sofá. Nota-se também que as curvas espectrais dos dois centróides são bastante parecidas; isso se sustenta a partir da percepção de que tanto a madeira, quanto o sofá, foram pintados de verde, fazendo com que toda a parte visível do espectro destes pixels possua uma curva muito próxima. Esse fato revela, na verdade, uma característica do método de classificação e dos dados utilizados: imagens hiperespectrais contém tanto o espectro visível, quanto o não visível. Nesse caso, imagens com cores parecidas terão a parte visível de suas curvas espectrais próximas e isso enviesará o algoritmo para que classifique esses objetos em um mesmo grupo.

#### **4. SIMULAÇÃO $\tilde{\text{MAXIMUM LIKELIHOOD}}$**

Para a simulação relatada neste relatório utilizou-se mais uma vez a base de dados dos *Indian Pines*. Será utilizado aqui os dois algoritmos, em um primeiro momento o algoritmo *k-means* gerará um gabarito (*truth ground*) que será usado como folha de cálculo para o treinamento da classificação supervisionada. Após a classificação feita o algoritmo de *maximum likelihood* é utilizado sobre outra imagem ainda nos *Indian Pines*, a qual é classificada segundo as classes geradas pelo *k-means*.




6

A folha de cálculo gerada no *k-means* foi criada a partir de 30 iterações do algoritmo com 10 classes de classificação. O algoritmo *k-means* possui grande complexidade e, portanto, tempo de execução reduzido. Portanto propõe-se a utilização deste apenas uma vez para gerar o critério de avaliação e a partir de então usa-se o algoritmo supervisionado Maximum Likelihood o qual possui complexidade variável, porém possivelmente de  $O(N)$ . O tempo de execução de uma classificação com o algoritmo supervisionado foi reduzido de 15 segundos para algo em torno de 1 a 3 segundos. Como esperado houve redução de 10x no tempo de execução sendo possível agora propor a utilização do código para soluções imediatas de análise que necessitam de respostas na ordem de poucos segundos.

---

<sup>6</sup> Imagem original dos Indian Pines, mapa de classificação e espectro dos centroides

## Resultados:



O resultado como indicado acima foi a classificação das 5 faixas presentes na imagem em apenas 4 das 10 classes. Com diferentes conjuntos de dados os resultados parecem promissores, no entanto necessita-se ainda de mais testes e confirmações de que as classificações estão de acordo com o contido na imagem. A obtenção de uma folha de cálculo externa diretamente da fonte das imagens utilizadas forneceria as confirmações necessárias. No entanto, até o momento da pesquisa tal dado não foi encontrado e fica, portanto, como tarefa prevista nas atividades do segundo semestre.

---


<sup>7</sup> Imagem original das salinas e mapa de classificação

## **5. TRIAGEM DE RECICLÁVEIS EM CTR**

Em 2020, na École Centrale de Marseille, foi realizado um trabalho de conclusão semestral com o objetivo de criar um algoritmo de classificação de imagens hiperespectrais para a classificação de objetos em uma esteira rolante dentro de uma central de triagem de resíduos. O projeto aconteceu ao longo de todo um semestre e dele partiu o início do que se tornaria hoje o presente trabalho.

Uma CTR é o lugar para onde são encaminhados os resíduos gerados pelos municípios, as grandes cidades costumam possuir uma ou mais centrais como essa. Tais locais são de extrema importância para o tratamento adequado dos diversos tipos de resíduos gerados pela sociedade. Para que os resíduos sejam tratados de forma adequada uma triagem deve ser realizada a fim de encaminhas cada um ao seu tratamento específico. Os resíduos recicláveis possuem valor econômico e são de extrema importância sob o ponto de vista ambiental. Portanto, ser capaz de identificar e triar de maneira correta objetos como garrafas pet, garrafas de vidro e latinhas, entre outros, é de extrema importância dentro dessas centrais.

Ao longo do segundo semestre de 2020, um grupo de 5 alunos desenvolveu um código capaz de classificar imagens hiperespectrais. No entanto, não se possuía uma base de dados desse tipo de imagem para garrafas pet e resíduos recicláveis. A maioria das bases públicas existentes é composta por imagens de satélite e paisagens. Portanto, o projeto consistiu em testar o funcionamento do código criado com as imagens encontradas em bases públicas e simular como se daria o funcionamento da CTR em função do projeto desenvolvido.



8

Na imagem, o esquema projetado para o funcionamento da uma esteira rolante com uma câmera hiperespectral instalada acima. Através do código desenvolvido, garras ou pistões pneumáticos seriam acionados na posição dos objetos de interesse para separação e reciclagem. Como dito anteriormente, o código havia sido testado em imagens de satélite encontradas em bases de dados públicas e não em imagens de resíduos recicláveis especificamente. Ao longo da realização do presente trabalho realizado na Escola Politécnica da Universidade de São Paulo, o código foi refeito em grande parte e passou por novos testes que estão demonstrados ao longo deste relatório. Portanto, os testes e resultados obtidos no projeto anterior que deu início ao presente estudo não serão aqui discutidos.

## 6. ATIVIDADES REALIZADAS SEMESTRE 1

A primeira etapa do projeto consiste principalmente de vasta pesquisa quanto aos pontos principais que serão desenvolvidos durante o estudo, buscando um melhor entendimento do assunto, bem como e aprofundamento da biblioteca Python, que é utilizada no tratamento dos dados.

Função relevante da primeira etapa é o levantamento dos dados de teste que serão utilizados pelos algoritmos, tendo em vista que imagens hiperespectrais não são material

---

<sup>8</sup> Esquema do funcionamento da esteira rolando da CTR projetada pelo grupo de alunos da École Centrale Marseille

facilmente acessível e há poucos bancos de dados com tamanho suficiente para a realização de testes estatisticamente extenso.

Após o levantamento citado, experiências com o algoritmo de classificação começaram a ser realizadas sobre a base de dados anteriormente criada.

Os resultados das experiências levantaram alguns pontos sobre os limites do algoritmo escolhido e os escopos no qual ele poderá ser utilizado. O algoritmo é ideal para conjuntos de dados nos quais se sabe o número de classes total e o tempo de execução está abaixo de 1 minuto, a depender da quantidade de classes desejada. Para grupos nos quais não se conhece previamente a quantidade de classes possível, o algoritmo perde, em escala menor, sua utilidade, uma vez que a acurácia dele não poderá ser medida com precisão, a não ser por uma análise externa.

Em um segundo momento o algoritmo supervisionado começou a ser implementado o qual está descrito no tópico 5 do presente relatório. Os resultados dos testes com este método têm sido promissores e aliar os dois métodos para a criação do código final parece ser o melhor caminho a ser seguido. A união dos dois métodos permite que se crie uma base de classificação sem nenhum conhecimento prévio sobre a imagem e com a utilização desta como base de treino pode aumentar o tempo de execução total do código e classificar com a mesma eficiência, porém com mais velocidade. Além disso a classificação pode também ser realizada manualmente para a criação de uma folha gabarito que então será utilizada como base para futuras classificações.

Desta maneira, as atividades realizadas culminaram em um código versátil que poderá ser utilizado em diferentes ambientes e que se adequa a diferentes necessidades. Como a intenção do projeto é sugerir usos diversos e mais cotidianos para a tecnologia que hoje é encontrada principalmente no meio da pesquisa, um código modular e versátil que não precise de nada além das imagens que se quer classificar é o ideal e é isto que a primeira etapa do projeto criou.

A partir disso espera-se no segundo semestre, estudar a possibilidade do uso deste mesmo código para automatizar processos de classificação em indústrias, em projetos escolares, na criação de bases de dados etc.

## 7. PROPOSTAS DE INTERVENÇÃO

O principal objetivo deste projeto, como salientado anteriormente, é o estudo das possíveis aplicações da tecnologia do sensoriamento hiperespectral aliada ao *machine learning*

e a classificação de imagens. Uma vez que o algoritmo para tal foi desenvolvido e apresentou resultados satisfatórios, parte-se para a sugestão de aplicações para a tecnologia e a validação do emprego desta. A tecnologia da análise de imagens hiperespectrais possui um imenso potencial nos mais diversos campos. Hoje é possível encontrar estudos da aplicação do sensoriamento hiperespectral para fins militares, em áreas da construção, de estudos geológicos e até da medicina.

Apesar do grande potencial dessa tecnologia, seu uso e principalmente seu uso conjunto com técnicas de *machine learning* é relativamente recente. Muitos dos estudos citados ao longo deste trabalho datam de 2 a 3 anos antes do momento em que se desenvolve o presente estudo. Tal fato, aliado a dificuldade em se gerar imagens hiperespectrais traz dificuldade relevante para a realização e validação das propostas aqui apresentadas.

Isto posto, deve-se ressaltar que a validação dos métodos aqui propostos necessita do uso de bases de dados com imagens hiperespectrais geradas especificamente para tal validação. Tais bases ainda não foram encontradas ou ainda não se tem acesso a elas até o presente momento. Espera-se conseguir acesso a tais bases de dados para que se possa seguir com a validação do projeto.

Uma vez definidas as restrições encontradas até o presente momento, segue-se as propostas de intervenção para o estudo e o código desenvolvido. Nesse sentido, propõe-se o estudo da utilização da classificação de imagens hiperespectrais para a análise de casos de câncer de pele e para o acompanhamento de métodos de reflorestamento.

## 8. DETECÇÃO DE CÂNCER DE PELE

O Câncer de pele é um dos tipos de câncer mais comuns na sociedade, sendo responsável por 33% dos casos desta doença no Brasil. O INCA (Instituto Nacional do Câncer) registra a cada ano mais de 185 mil novos casos<sup>9</sup>. Existem dois tipos de câncer de pele, o melanoma e o não melanoma, sendo o primeiro o de mortalidade baixa e mais comum, e o segundo menos comum, porém mais letal.

A eficácia no tratamento da referida doença está diretamente vinculada à sua detecção e tratamento prévio. Hoje muitos sistemas de análise de imagens RGB convencionais criados através de dermoscópios são utilizados para sua identificação. No entanto, tais sistemas ainda

---

<sup>9</sup> Sociedade Brasileira de Dermatologia. CANCER DE PELE. Disponível em <<https://www.sbd.org.br/doencas/cancer-da-pele/>> Acesso em 25/09/2022.

dependem muito da opinião e análise técnica médica na avaliação de coloração, formas e outras características dos hematomas e, portanto, são pouco automatizados e demandam mais trabalho.

Tecnologias emergentes como o sensoriamento hiperespectral permitem enxergar características além da capacidade do olho humano e tratá-las de maneira automatizada para facilitar a identificação de potenciais casos de câncer de pele. Com isso, sugere-se aqui o uso do algoritmo desenvolvido para a classificação de imagens hiperespectrais de lesões de câncer de pele para que seja possível a detecção automática e rápida de potenciais lesões.

## 7.1. OBTENÇÃO DE DADOS

Como mencionado anteriormente, a obtenção de dados de imagens hiperespectrais não é simples: ela depende primeiramente da disposição de uma câmera especial, bem como do tipo de objeto que será sujeito do estudo. No caso do câncer de pele, seria necessária uma amostragem entre pacientes com câncer, o que torna ainda mais complexa a aquisição dos dados necessários. Felizmente, a Universidade de *Las Palmas de Gran Canaria* vem desenvolvendo diversos estudos no campo do sensoriamento hiperespectral, sendo uma das grandes referências no meio. Em um destes estudos<sup>10</sup>, foi elaborada uma base de dados contendo 76 imagens de 61 pacientes com lesões que foram classificadas entre benignas e malignas, sendo este conjunto de imagens a base utilizada para validação do funcionamento do código proposto neste trabalho.

## 7.2. BASE DA UNIVERSIDADE DE LAS PALMAS DE GRAN CANARIA

Ao longo do estudo<sup>11</sup> foram adquiridas 76 imagens empregando 125 bandas espectrais entre 450 e 950nm. Estas imagens foram previamente classificadas com o auxílio de dermatologistas, criando uma espécie de gabarito para que fosse possível proceder com a realização de teste dos algoritmos de classificação empregados pelos pesquisadores espanhóis e verificação do funcionamento do método proposto.

A campanha de aquisição dos dados foi realizada de março de 2018 a junho de 2019. Diversas lesões foram capturadas de diferentes partes do corpo de 116 indivíduos em dois hospitais. O Hospital Universitario de Gran Canaria e Complejo Hospitalario Universitario

---

<sup>10</sup> Leon R, Martinez-Vega B, Fabelo H, Ortega S, Melian V, Castaño I, Carretero G, Almeida P, Garcia A, Quevedo E, Hernandez JA, Clavo B, M Callico G. **Non-Invasive Skin Cancer Diagnosis Using Hyperspectral Imaging for In-Situ Clinical Support.** J Clin Med. 2020 Jun 1. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7356572/>> Acesso em 01/11/2022.

<sup>11</sup> Ibid.

Insular – Materno Infantil. Após análise preliminar 55 indivíduos/imagens foram removidos da base, pois as lesões se encontravam em áreas de difícil captura, o que prejudicava a qualidade destas. A base final contém 76 imagens de 61 pacientes.

### **7.3. EMPREGO DO ALGORITMO *K-MEANS***

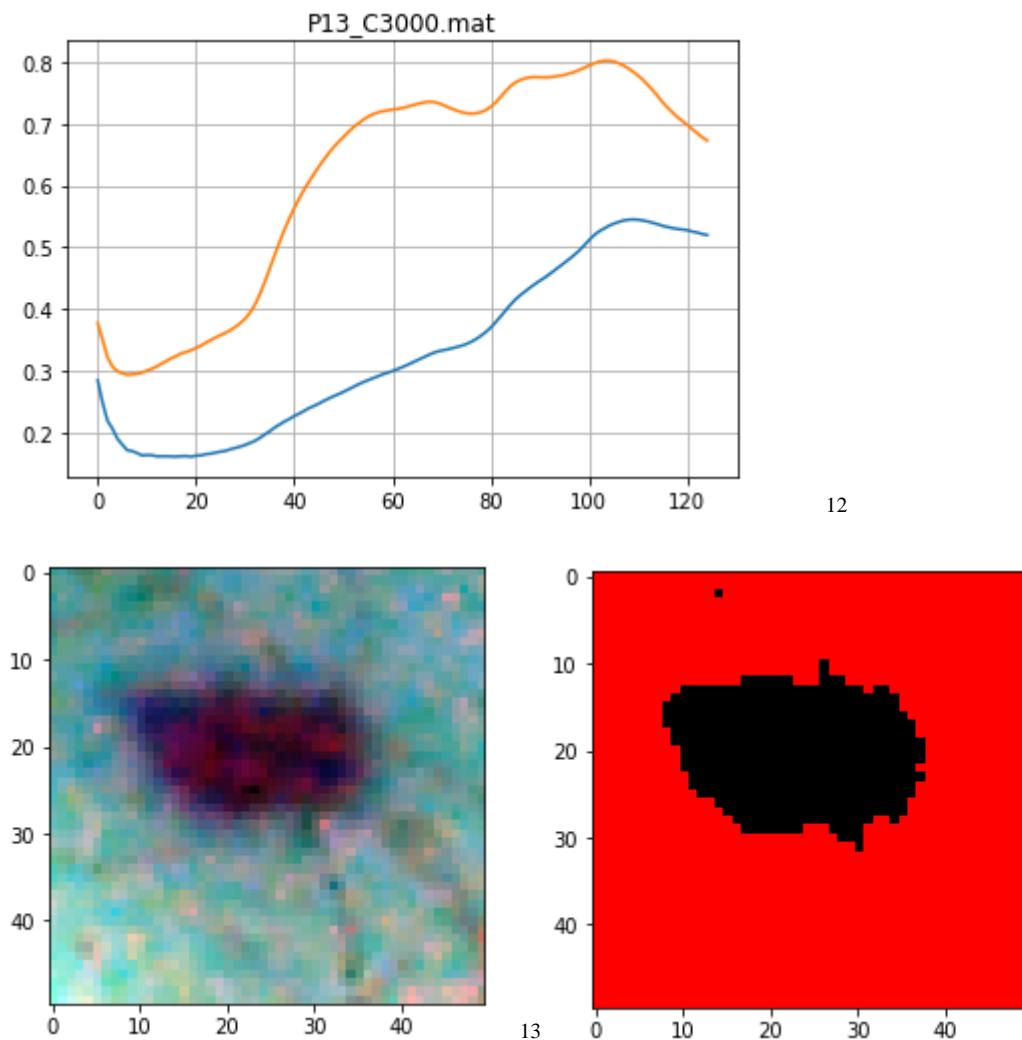
Das 76 imagens obtidas diversos testes foram realizados pelo grupo de pesquisadores espanhóis a fim de determinar quais imagens possuíam qualidade boa o suficiente para gerar testes com relevância estatística. Destas imagens, foi decidido que 10 delas possuíam clareza o suficiente para eliminar ao máximo falsos positivos e falsos negativos. Dentre elas, apenas um paciente possuía mais de uma lesão sendo algumas delas benignas e outras malignas. Este paciente, denotado aqui como paciente 13, será alvo do presente estudo para que se realize uma prova de conceito do código desenvolvido ao longo deste projeto. A escolha de análise de uma paciente específico se deu pelo fato de o algoritmo *k-means* ser um classificador “não supervisionado” e os pacientes possuírem tipos de pele muito diferentes. Analisando os padrões dos centróides das imagens obtidas foi possível perceber que a curva espectral dos centróides da pele de cada um dos pacientes era diferente entre si. Portanto, a tentativa de classificar entre tumores benignos e malignos lesões de diferentes pacientes nos levaria a desconsiderar as diferenças entre os tipos de pele de cada paciente e possivelmente geraria resultados errôneos utilizando o algoritmo *k-means*. Assim, foi decidido empregar o algoritmo para classificar diferentes lesões de um mesmo paciente o que idealmente nos resultaria em espectros iguais para a pele e diferentes para lesões benignas de malignas.

É importante ressaltar que apesar dos resultados promissores, para que haja relevância estatística no teste seria necessário o emprego de mais imagens, mais pacientes e diversos tipos de métodos de classificação diferentes. No escopo deste projeto, trazer é preciso evidenciar e dar atenção para a temática da utilização do sensoriamento hiperespectral e dos métodos de classificação que empregam *machine learning*, e não necessariamente desenvolver e provar os métodos em questão. As demonstrações aqui realizadas têm o objetivo de serem provas de conceito e apontarem o potencial do código modular e prático aqui desenvolvido assim como da tecnologia como um todo.

#### **7.3.1. IMAGENS CLASSIFICADAS E PRIMEIROS RESULTADOS**

O paciente 13 possui 2 lesões benignas e uma maligna segundo os dermatologistas que auxiliaram no projeto espanhol. Esperava-se, portanto, resultados de espectro semelhante para duas das lesões apresentadas e um diferente para a terceira.

Em um primeiro momento, cada imagem foi classificada em dois *clusters* a fim de apenas delimitar pele e lesão e verificar qual seria o aspecto esperado dos dois centroides de cada imagem. Assim pode-se visualmente tentar inferir qual das 3 imagens é a lesão maligna.



14

Como ilustrado acima, a lesão foi bem diferenciada do restante da pele do paciente sendo a curva laranja o espectro que mais se aproxima da pele do paciente e a curva azul o

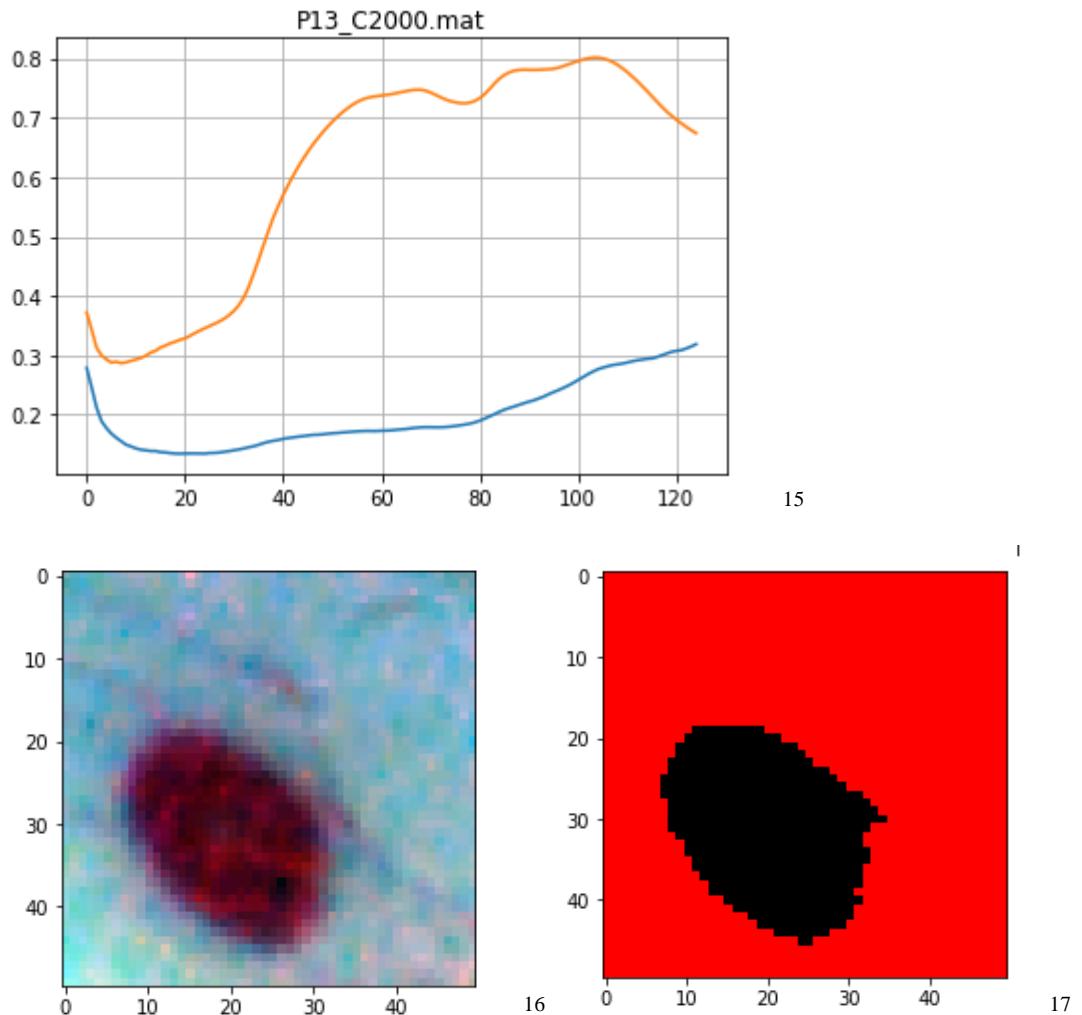
---

<sup>12</sup> Centroides da classificação de uma das lesões em dois clusters pelo algoritmo *k-means* (lesão 1).

<sup>13</sup> RGB da lesão classificada.

<sup>14</sup> Resultado da classificação do algoritmo *k-means*.


espectro que mais se aproxima da lesão. O mesmo processo foi realizado para as outras 3 lesões resultando nas imagens a seguir.



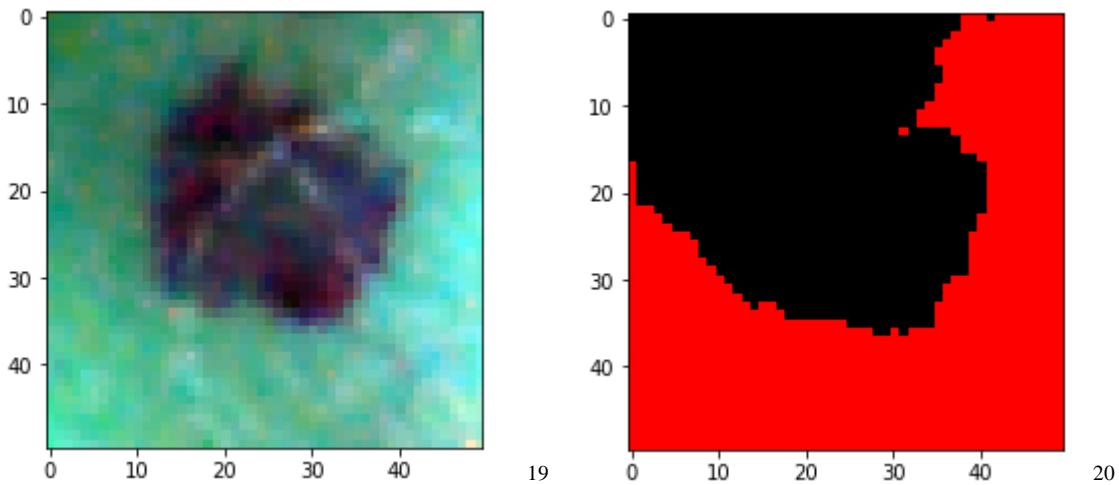
<sup>15</sup> Centroides da classificação de uma das lesões em dois clusters pelo algoritmo *k-means* (lesão 2).

<sup>16</sup> RGB da lesão classificada.

<sup>17</sup> Resultado da classificação do algoritmo *k-means*.



18



19

20


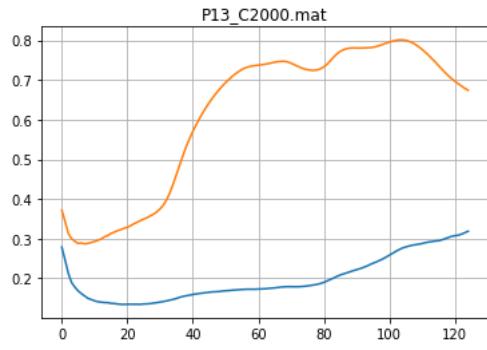

Uma vez geradas as classificações individuais de cada uma das lesões com o algoritmo de classificação não supervisionada *k-means*, é possível realizar uma comparação visual entre os 3 espectros na tentativa de inferir se há diferença notável neste primeiro momento.

---

<sup>18</sup> Centroídes da classificação de uma das lesões em dois clusters pelo algoritmo *k-means* (lesão 3).

<sup>19</sup> RGB da lesão classificada.

<sup>20</sup> Resultado da classificação do algoritmo *k-means*.




21

Com os 3 espectros em paralelo, verifica-se que o padrão do espectro da pele (curva em laranja) das 3 lesões é bastante parecido. Vale ressaltar que a imagem 3 possui uma curva laranja levemente diferente das outras em seu início (bandas 0 a 40), com 2 ondulações mais bem definidas e menos inclinadas. No que diz respeito ao centróide da lesão (curvas em azul), verifica-se 3 curvas bastante diferentes entre si. As duas primeiras mostram reflectâncias bem diferentes nas mesmas bandas, no entanto possuem um formato parecido, pois são mais lineares. A terceira curva possui reflectâncias mais próximas da primeira, no entanto apresenta curvas mais acentuadas. Em suma, a análise a olho nu não diz muita coisa, a não ser o fato de todas as lesões serem diferentes entre si.

A partir disso, resta classificar as 3 lesões utilizando os mesmos centroides, os quais deveriam ser determinados automaticamente pelo algoritmo em função da quantidade de centroides escolhida. Primeiramente as 3 imagens foram concatenadas, isto é, os 3 cubos hiperespectrais que são arrays de 50x50x125 foram transformados em um array de 150x50x125. Assim é possível afirmar que no momento uma só imagem que será classificada pelo algoritmo segundo os mesmos centroides. Após alguns testes, observou-se que o uso de 6 centroides na classificação resultava na melhor diferenciação entre as 3 lesões.

---

<sup>21</sup> Espectros dos 2 centróides na classificação das 3 imagens separadamente.



Os resultados obtidos nesta etapa são altamente promissores. Segundo a classificação que se identifica na imagem 22, verifica-se um perfil parecido para as duas primeiras lesões, enquanto a terceira lesão se diferencia das duas outras em alguns aspectos. Primeiramente a cor preta se encontra bem menos presente e pouco uniforme. Além disso, classes ao redor da lesão também são menos uniformes inclusive com uma classificação diferente de todo o entorno das duas primeiras lesões. Analisando visualmente a classificação, poderíamos concluir que as lesões 1 e 2 são parecidas entre si, enquanto a terceira destoa. Segundo o gabarito da base gerado pelos dermatologistas que auxiliaram o estudo espanhol, de fato as duas primeiras lesões são tumores benignos e a terceira um tumor maligno, concluindo aqui um resultado promissor.

<sup>22</sup> 6 centroides da classificação das 3 lesões em conjunto.

<sup>23</sup> Imagem RGB das 3 lesões justapostas.

<sup>24</sup> Resultado da classificação das 3 lesões justapostas.

Ainda, foi coletado indícios de que o código desenvolvido poderia ser adaptado para estudos em áreas como a da saúde, resolvendo problemas de classificação de imagens multiespectrais desde que corretamente adaptado; no presente momento, as evidências coletadas com os testes apresentados são suficientes para apontar o potencial da tecnologia do sensoriamento hiperespectral aliada ao *machine learning* e do código aqui desenvolvido, que pode ser instrumento de estudo para futuros projetos no campo.

## 8. ACOMPANHAMENTO DE MÉTODOS DE RESTAURAÇÃO ECOLÓGICA

Um dos maiores problemas da sociedade moderna é a questão ambiental no que diz respeito à degradação e exploração de recursos naturais. Segundo a ONU, os recursos naturais têm chegado ao seu limite de exploração cada vez mais cedo em uma base anual. Com base no conceito de esgotamento da terra, todos os anos é verificado o dia em que se acabam os recursos naturais que o planeta consegue recuperar ainda naquele ano: o dia da sobrecarga da terra. Em 2022 ele ocorreu em 28 de julho, um dia mais cedo que no ano de 2021<sup>25</sup>.

Visto isso, a recuperação ecológica é um assunto cada vez mais estudado e importante, sendo inclusive assunto de uma disciplina na graduação de engenharia ambiental na Escola Politécnica da Universidade de São Paulo. Nesta disciplina são estudados diversos métodos de reflorestamento nos quais está presente uma importante etapa de manutenção e monitoramento de projeto. Esta etapa consiste no acompanhamento da evolução da mata na qual foi realizada o plantio para restauração ecológica.

Os métodos de restauração ecológica são regulamentados pela resolução SMA SP no 32 de 03/04/2014. Neste processo, parâmetros como quantidade de espécimes e área coberta pelos mesmos são constantemente analisados para que se atinjam os valores de distribuição de espécies originalmente existentes no local. Esse acompanhamento é realizado de maneira manual através da amostragem e contagem de indivíduos por pesquisadores. Os valores de referência definidos na resolução supracitada encontram-se na tabela a seguir.

---

<sup>25</sup> OVERSHOOT DAY. DIA DA SOBRECARGA DA TERRA. WWF BRASIL. Disponível em <<https://www.wwf.org.br/overshootday/#:~:text=28%20DE%20JULHO%20DE%202022,sustentar%20nosso%20padr%C3%A3o%20de%20consumo>>. Acesso em 25/09/2022.

Florestas Ombrófilas e Estacionais / Restinga Florestal / Mata Ciliar em região de Cerrado										
Indicador	Cobertura com vegetação nativa (%)			Densidade de indivíduos nativos regenerantes (ind./ha)			Nº de espécies nativas regenerantes (nº spp.)			
Nível de adequação	Critico	Mínimo	Adequado	Critico	Mínimo	Adequado	Critico	Mínimo	Adequado	
Valores intermediários de referência	3 anos	0 a 15	15 a 80	> 80	–	0 a 200	> 200	–	0 a 3	> 3
	5 anos	0 a 30	30 a 80	> 80	0 a 200	200 a 1000	> 1000	0 a 3	3 a 10	> 10
	10 anos	0 a 50	50 a 80	> 80	0 a 1000	1000 a 2000	> 2000	0 a 10	10 a 20	> 20
	15 anos	0 a 70	70 a 80	> 80	0 a 2000	2000 a 2500	> 2500	0 a 20	20 a 25	> 25
Valores utilizados para atestar recomposição	20 anos	0 a 80	–	> 80	0 a 3000	–	> 3000	0 a 30	–	> 30

26

Portanto, o acompanhamento dos diversos métodos de reflorestação faz-se através da medida de 3 indicadores: Cobertura vegetal nativa, Densidade de indivíduos nativos e Número de espécies nativas regenerantes. Estes indicadores, são hoje obtidos através de amostragem manual realizada por profissionais da área. No entanto, a natureza dos indicadores é propicia para análise via sensoriamento. Já foi demonstrado no item 3.5 do presente trabalho, imagem 2, que o código desenvolvido funciona bem para a classificação de diferentes tipos de vegetação nas imagens de plantações geradas pelo satélite ARIVIS. Espera-se, portanto, que a utilização da tecnologia do sensoriamento hiperespectral e o código desenvolvido neste projeto sejam adequados para a geração e acompanhamento dos indicadores descritos acima.

Com o uso de imagens hiperspectrais geradas por satélite espera-se que tal processo de manutenção e acompanhamento torne-se mais automático e simples permitindo respostas mais rápidas e eficientes dos responsáveis do projeto no que tange a adaptação de parâmetros e objetivos dele.

Como visto na tabela 26, usualmente, o acompanhamento da recuperação florestal é realizado em intervalos de 5 ou 10 anos. Portanto, a validação das propostas do projeto de recuperação ecológica leva ao menos 5 anos e depende não só do crescimento das espécies, mas também da mobilização de mão de obra qualificada para amostragem e análise do material.

O uso de imagens hiperespectrais e algoritmos de classificação apresenta, portanto, o potencial de reduzir o tempo e a mão de obra necessária para o acompanhamento de projetos de restauração ecológica e consequentemente agilidade e eficácia na intervenção nestas áreas quando necessário.

---

<sup>26</sup> Valores de referência para monitoramento dos projetos de restauração ecológica. Disponível em: <<https://abesnacional.com.br/XP/XP-EasyArtigos/Site/Uploads/Evento36/TrabalhosCompletosPDF/VI-165.pdf>>

A prova de conceito que se tinha intenção de realizar para a proposta da aplicação da tecnologia aqui desenvolvida no acompanhamento dos métodos de recuperação florestal, necessita de imagens de satélite de áreas que passaram por processos de reflorestamento assim como as imagens estudadas no item 3.5 dos Indian Pines. No entanto, até o presente momento, imagens como esta não foram encontradas. Por se tratar de uma tecnologia pouco difundida, imagens desse tipo para usos específicos como o proposto aqui muitas vezes não existem ainda.

Com a ausência de bases de dados com as imagens necessárias para a validação da presente proposta, tornou-se inviável uma demonstração de conceito como a realizada no caso da detecção do câncer de pele. No entanto, o processo descrito se assemelha muito a classificação realizada das plantações presentes nas imagens utilizadas para a realização dos testes descritos no item 3.5. Assim, apesar de não se poder no momento realizar uma prova de conceito adequada, mostrou-se que o código funciona adequadamente para processos de classificação de cobertura vegetal de diferentes espécies de plantas no cultivo agrícola. Portanto, há indícios de que a intervenção proposta seria reproduzível em ambiente real.

## **CONCLUSÃO**

Atualmente, a engenharia é um dos carros chefes da inovação tecnológica. Essa inovação não se faz apenas com a criação de novas tecnologias, mas com o uso de tecnologias já existentes para a resolução de problemas ainda sem solução ou para o aperfeiçoamento das soluções existentes.

O presente estudo tinha por objetivo demonstrar que as imagens multiespectrais e o *machine learning*, duas tecnologias já consolidadas, podiam ser aliadas na resolução de problemas modernos e quotidianos. O sensoriamento hiperespectral é, ainda hoje, uma tecnologia pouco difundida. Estudos e bases de dados incidentes sobre referidas imagens são escassos e no Brasil quase não se encontram exemplos.

A inovação proposta pela presente pesquisa se deu, portanto, através de duas etapas. Vejamos.

A primeira delas consistiu na construção de um código modelo adaptável que pudesse ser empregado em qualquer tipo de classificação de imagens multiespectrais de maneira não supervisionada, não necessitando, portanto, da existência prévia de dados para treinamento do código.

A segunda etapa consistiu na prova de conceito da utilização do código em diferentes áreas como medicina e reflorestamento.

Portanto, com a construção de um código comprehensível e versátil e a demonstração da utilização do mesmo para o diagnóstico do câncer de pele no item 7 e a sugestão do item 8, espera-se chamar atenção para o grande potencial dessa tecnologia. A presente pesquisa e o código desenvolvido podem ser a ponte para a inovação e a difusão do sensoriamento.

## REFERÊNCIAS BIBLIOGRÁFICAS

B. Fischer, V. Roth, and J. M. Buhmann, **CLUSTERING WITH THE CONNECTIVITY KERNEL**, in Advances in Neural Information Processing Systems 16, S. Thrun, L. Saul, and B. Schölkopf, Eds. Cambridge, MA: MIT Press, 2004

CHI, Mingmin. BRUZZONE, Lorenzo. IEEE Xplore. **SEMISUPERVISED CLASSIFICATION OF HYPERSPECTRAL IMAGES BY SVMS OPTIMIZED IN THE PRIMAL.** Vol. 45, no. 6, pp. 1870-1880, 2007. Disponível em <<https://ieeexplore.ieee.org/abstract/document/4215036>>. Acesso em: 14 de abril de 2022.

Dorian Lazar, Maximum Likelihood Classification, fev. 2020. Disponível em: <<https://towardsdatascience.com/maximum-likelihood-classification-4b129971ea92>>

G. Camps-Valls and L. Bruzzone, **KERNEL-BASED METHODS FOR HYPERSPECTRAL IMAGES CLASSIFICATION**, IEEE Trans. Geosci. Remote Sens., vol. 43, no. 6, pp. 1351–1362, Jun. 2005

HARVARD DATABASE. **Real-World Hyperspectral Images Database**. Disponível em <<http://vision.seas.harvard.edu/hyperspec/d2x5g3/>>

**HYPERSPECTRAL REMOTE SENSING MARKET DYNAMICS**. Persistence Market Research, 2020. Disponível em: <<https://www.persistencemarketresearch.com/market-research/hyperspectral-remote-sensing-market.asp>>. Acesso em: 14 de abril de 2022.

H. Fabelo et al., "DERMATOLOGIC HYPERSPECTRAL IMAGING SYSTEM FOR SKIN CANCER DIAGNOSIS ASSISTANCE," 2019 XXXIV Conference on Design of Circuits and Integrated Systems (DCIS), Disponível em: <<https://ieeexplore.ieee.org/document/8959869>>

Jet Propulsion Laboratory. California Institute of Technology. **ARIVIS SENSOR.** Disponível em: <<https://aviris.jpl.nasa.gov/>> Acesso em: 30 de maio de 2022.

Johansen, TH, Møllersen, K, Ortega, S, et al. **RECENT ADVANCES IN HYPERSPECTRAL IMAGING FOR MELANOMA DETECTION.** *WIREs Comput Stat.* 2020; 12:e1465. Disponível em: <<https://doi.org/10.1002/wics.1465>>

Leon, R.; Martinez-Vega, B.; Fabelo, H.; Ortega, S.; Melian, V.; Castaño, I.; Carretero, G.; Almeida, P.; Garcia, A.; Quevedo, E.; Hernandez, J.A.; Clavo, B.; M. Callico, G. **NON-INVASIVE SKIN CANCER DIAGNOSIS USING HYPERSPECTRAL IMAGING FOR IN-SITU CLINICAL SUPPORT.** *J. Clin. Med.* 2020, 9, 1662. Disponível em: <<https://doi.org/10.3390/jcm9061662>>

Lloyd A. Courtenay, Diego González-Aguilera, Susana Lagüela, Susana del Pozo, Camilo Ruiz-Mendez, Inés Barbero-García, Concepción Román-Curto, Javier Cañuelo, Carlos Santos-Durán, María Esther Cardeñoso-Álvarez, Mónica Roncero-Riesco, David Hernandez-Lopez, Diego Guerrero-Sevilla, and Pablo Rodríguez-Gonzalvez, "**HYPERSPECTRAL IMAGING AND ROBUST STATISTICS IN NON-MELANOMA SKIN CANCER ANALYSIS,**" *Biomed.* Disponível em: <<https://opg.optica.org/boe/fulltext.cfm?uri=boe-12-8-5107&id=453472>>

MARIO HAUT, Juan. PAOLETTI, Mercedes. PLAZA, Javier. PLAZA, Antonio. **CLOUD IMPLEMENTATION OF THE K-MEANS ALGORITHM FOR HYPERSPECTRAL IMAGE ANALYSIS.** Springer Link, 2017. Acesso em: <<https://link.springer.com/article/10.1007/s11227-016-1896-3>>. Acesso em: 14 de abril de 2022.

M Graña, MA Veganzons, B Ayerdi. **HYPERSPECTRAL REMOTE SENSING SCENES.** Disponível em: <[https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes#Indian\\_Pines](https://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes#Indian_Pines)> Acesso em: 30 de maio de 2022.

O. L. Mangasarian, **A FINITE NEWTON METHOD FOR CLASSIFICATION**, *Optim. Methods Softw.*, vol. 17, no. 5, pp. 913–929, Jan. 2002.

Saiko, G, Lombardi, P, Au, Y, Queen, D, Armstrong, D, Harding, K. **HYPERSPECTRAL IMAGING IN WOUND CARE: A SYSTEMATIC REVIEW**. Int Wound J. 2020; 17: 1840–1856. Disponível em: <<https://doi.org/10.1111/iwj.13474>>

**WELCOME TO SPECTRAL PYTHON (SPY).** Spectral Python, 2019. Disponível em: <<https://www.spectralpython.net/>>. Acesso em: 14 de abril de 2022