



# IDENTIFICANDO ÁREAS DE ARBORIZAÇÃO URBANA: MÚLTIPLAS ABORDAGENS DE SEGMENTAÇÃO (FASE II)

Colégio São Francisco de Sales – Diocesano  
Orientando: Gonçalo Ponte Leite  
Orientador: Victor Eduardo Alves da Silva Carvalho

## INTRODUÇÃO

A ARBORIZAÇÃO URBANA TRAZ BENEFÍCIOS ECONÔMICOS E SOCIAIS COMO A MELHORIA DO MICROCLIMA E DA SAÚDE FÍSICA E MENTAL.

SOB ESSA PERSPECTIVA, FOI ESTABELECIDO O ARTIGO 172 DA LEI COMPLEMENTAR Nº 5.481 DE TERESINA-PI.

**LEI COMPLEMENTAR Nº 5.481** • EXIGE QUE OS CONDOMÍNIOS CUBRAM PELO MENOS 12% DE SEU TERRENO COM ÁREAS VERDES

NO ENTANTO, FALTAM DADOS PÚBLICOS E SUA FISCALIZAÇÃO É INEFICIENTE E INSUFICIENTE.

PARA CONTORNAR ISSO, EM 2023 DESENVOLVEU-SE UM PROGRAMA QUE ANALISA IMAGENS DE SATÉLITE DO GOOGLE MAPS E QUANTIFICA AS ÁREAS VERDES, APRESENTANDO UMA ACURÁCIA DE 84,62%, QUE, APESAR DE PROMISSORA, AINDA FAZ DESEJAR MELHORIAS.

### NECESSIDADE

IDENTIFICAR A METODOLOGIA MAIS OPTIMIZADA PARA A SEGMENTAÇÃO OU SELEÇÃO DAS ÁREAS ARBORIZADAS DE IMAGENS DE SATÉLITE

### OBJETIVOS

IMPLEMENTAR DIFERENTES TÉCNICAS DE SEGMENTAÇÃO E QUANTIFICAR SUA ACURÁCIA PARA ELEGER O "MELHOR" MÉTODO

## METODOLOGIA

O ALGORITMO DESENVOLVIDO É COMPOSTO: PELO DELIMITADOR DA ÁREA À ANALISAR, PELO SEGMENTADOR E PELO QUANTIFICADOR DE ÁREA.

APENAS O SEGMENTADOR FOI ALTERADO NESSA 2ª FASE DA PESQUISA

PARA DEFINIR A ACURÁCIA DA SEGMENTAÇÃO DAS ÁREAS VERDES FORAM ANALISADOS 14 TERRENOS URBANOS, USANDO-SE DIFERENTES ESPAÇOS DE COR PERCEPTUAIS PARA OBSERVAR SUA INFLUÊNCIA

OS RESULTADOS FORAM COMPARADOS COM VALORES EXTRAÍDOS MANUALMENTE, POR MEIO DA FERRAMENTA MEDIR DISTÂNCIA, PARA ASSIM DEFINIR A PRECISÃO DO ALGORITMO E DA SEGMENTAÇÃO ISOLADAMENTE.

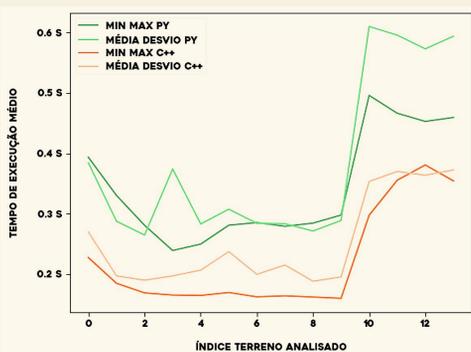


FIGURA 1 - GRÁFICO DO TEMPO DE EXECUÇÃO MÉDIO PARA CADA PLATAFORMA E TÉCNICA SEGMENTAR A IMAGEM DE CADA TERRENO

INICIALMENTE, O SISTEMA FOI PROGRAMADO EM PYTHON, NO ENTANTO, COM O USO DE TÉCNICAS DE OPTIMIZAÇÃO, QUE SÃO ESSENCIALMENTE ITERATIVAS, A ANÁLISE TORNOU-SE MUITO DEMORADA

POR ISSO, DECIDIU-SE POR IMPLEMENTAR O CÓDIGO TAMBÉM EM C++, MEDIANTE SUA MAIOR VELOCIDADE.

OBSERVOU-SE NOS MÉTODOS DE LIMIARIZAÇÃO (QUE NÃO SÃO DE OPTIMIZAÇÃO) UM AUMENTO MÉDIO DE 54% DA VELOCIDADE

## DESENVOLVIMENTO

UMA AMOSTRA DE ÁRVORE É FORNECIDA PARA QUE O PROGRAMA RECONHEÇA O PADRÃO DAS ÁREAS ARBORIZADAS

### LIMIARIZAÇÃO

PROCESSO DE DIVIDIR UMA IMAGEM EM 2 REGIÕES: UMA QUE ESTÁ DENTRO DE UM INTERVALO DE VALORES E OUTRA QUE ESTÁ FORA. ASSIM PODE-SE SEGMENTAR UMA REGIÃO DE INTERESSE DO RESTANTE

### LIMIARIZAÇÃO MIN-MAX ⌚ 0,28s

O INTERVALO DE VALORES ESCOLHIDOS É DEFINIDO COMO OS VALORES MÍNIMOS E MÁXIMOS APRESENTADOS POR CADA COMPONENTE DA AMOSTRA

### LIMIARIZAÇÃO MÉDIA-DESVIO ⌚ 0,30s

O INTERVALO DE VALORES ESCOLHIDOS É DEFINIDO COM A MÉDIA DOS PIXELS DA AMOSTRA (MENOS) - SEU DESVIO PADRÃO E A MÉDIA DOS PIXELS DA AMOSTRA (MAIS) + DESVIO PADRÃO

### CLUSTERIZAÇÃO

AGRUPA PIXELS EM K GRUPOS, OBJETIVANDO A MAIOR SIMILARIDADE ENTRE PIXELS DE MESMO GRUPO

### SUPERPIXELIZAÇÃO

PROCESSO DE SIMPLIFICAR UMA IMAGEM, DIVIDINDO-A EM SUPERPIXELS: REGIÕES DE PIXELS SIMILARES, QUE SÃO HOMOGENEIZADOS COMO A MÉDIA DOS PIXELS DESSA REGIÃO, REDUZINDO O RUÍDO.

PARA REALIZAR A SEGMENTAÇÃO, É NECESSÁRIO USAR OUTRA TÉCNICA DE SEGMENTAÇÃO PARA PROCESSAR A IMAGEM SUPERPIXELADA

### SLIC + MIN-MAX ⌚ 51,2s

O SLIC É DAS MELHORES TÉCNICA DE SUPERPIXEL DO ESTADO DA ARTE, DESTACANDO-SE POR SUA VELOCIDADE; COMPLEXIDADE ALGORÍTMICA CONSTANTE; BOA ADERÊNCIA AOS CONTORNO DA IMAGEM, LEVANDO EM CONSIDERAÇÃO, ALÉM DA COR DOS PIXELS, SUA LOCALIZAÇÃO

### K-MEANS

O K-MEANS É UM ALGORITMO DE CLUSTERIZAÇÃO. ELE INICIALIZA UM PIXEL IDENTIDADE PARA CADA UM DOS GRUPOS QUE IRÁ FORMAR.

ENTÃO, OS PIXELS QUE ESTÃO SENDO AGRUPADOS BUSCAM O PIXEL IDENTIDADE MAIS SIMILAR, SE ASSOCIANDO AO GRUPO DESSE PIXEL.

ESSE PIXEL IDENTIDADE É ATUALIZADO COMO A MÉDIA DOS PIXELS DO RESPECTIVO GRUPO

ESSE PROCESSO É REPETIDO ATÉ QUE OS PIXELS IDENTIDADE SEJAM (DEPOIS DA ATUALIZAÇÃO) A MÉDIA DOS PIXELS DO SEU RESPECTIVO GRUPO

### K-MEANS + KNN ⌚ 2,43h

COM OS PIXELS DA IMAGEM AGRUPADOS, É POSSÍVEL UTILIZAR UMA KNN PARA DETERMINAR QUAIS SÃO OS AGRUPAMENTOS MAIS SIMILARES À CADA PIXEL DA AMOSTRA, DEFININDO-SE, ASSIM, OS GRUPOS DE PIXELS DAS REGIÕES ARBORIZADAS E, CONSECUTIVAMENTE, QUAIS SÃO OS PIXELS DE ÁRVORES.

### MÚLTIPLAS ABORDAGENS

DIFERENTES TÉCNICAS E ESPAÇOS DE COR TEM DIFERENTES PRÓS E CONTRAS. ASSIM, UTILIZAR MÚLTIPLAS METODOLOGIAS PODEM GERAR UM RESULTADO MELHOR QUE APENAS UMA.

### PRÓXIMOS PASSOS INCLUEM ELABORAR ESTRATÉGIAS PARA:

- DEFINIR O VALOR MAIS OPTIMIZADO DE GRUPOS PARA CLUSTERIZAÇÃO
- GENERALIZAR AMOSTRAS
- SEGMENTAR AS IMAGENS, EM TEXTURA, DIFICULTANDO A ADULTERAÇÃO DOS RESULTADOS COM EFEITOS PRÁTICOS OU DIGITAIS E AUMENTANDO ACURÁCIA
- IDENTIFICAR FORMAS PARA ACELERAR O TREINAMENTO DE REDES NEURAS

PARA ISSO, JUNTOU-SE AS SELEÇÕES DE VÁRIAS METODOLOGIAS COM UMA MÉDIA PONDERADA USANDO POR PESO A ACURÁCIA DE CADA ABORDAGEM.

ASSIM, TEM-SE UM MAPA DE CALOR INDICANDO A CHANCE DE CADA PIXEL SER UMA ÁRVORE, DE FATO, OU NÃO,

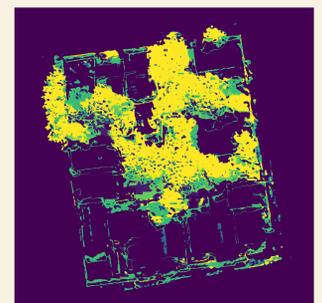


FIGURA 2 - MAPA DE CALOR DO TERRENO 13 APRESENTANDO A CHANCE DE CADA PIXEL DA REGIÃO DE ANÁLISE SER UMA ÁREA VERDE

## RESULTADOS & CONCLUSÕES

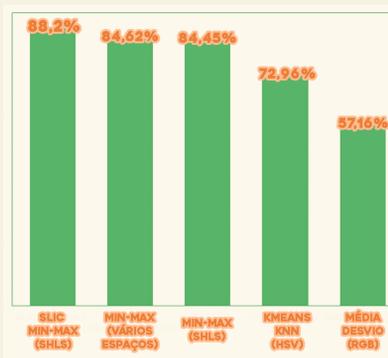


FIGURA 3 - COMPARAÇÃO DA ACURÁCIA APRESENTADA PELAS DIFERENTES METODOLOGIAS NO ESPAÇO DE COR COM OS MELHORES RESULTADOS

INTERESSANTEMENTE, A REDUÇÃO DO RUÍDO DA IMAGEM COM A SEGMENTAÇÃO SLIC MIN-MAX, QUE APRESENTOU UMA ACURÁCIA DE 88,2%, MELHOROU A ACURÁCIA DO SISTEMA EM 3,75% EM COMPARAÇÃO AO MIN-MAX PURO USADO NA 1ª FASE

HOVE, ASSIM, UMA MELHORIA MUITO POSITIVA, NO ENTANTO AINDA EXISTEM MUITAS METODOLOGIAS DE ANÁLISE DE TEXTURAS, MACHINE LEARNING, DEEP LEARNING, DENTRE OUTRAS PARA SEREM EXPLORADAS. INDICANDO UMA, AINDA, GRANDE POTENCIALIDADE DE APRIMORAMENTO

## REFERÊNCIAS

- [1] Gonzalez, Rafael C.; Woods, Richard E. Digital Image Processing. 4ª Edição, Pearson, 2018.
- [2] ACHANTA, R.; SHAJI, A.; SMITH, K.; et al. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods. Disponível em: <https://core.ac.uk/download/pdf/147983593.pdf>. Acesso em: 17 de out. 2022.
- [3] Mittal, Himanshu; Pandey, Avinash Chandra; et. al. A comprehensive survey of image segmentation: clustering methods, performance parameters, and benchmark datasets. Disponível em: <https://shorturl.at/gquM7>. Acesso em: 17 out. 2023.
- [4] Jain, Sneha; Laxmi, Vijaya. Color Image Segmentation Techniques: A Survey. Disponível em: <https://shorturl.at/nPTWZ>. Acesso em: 17 out. 2023.