

23 - Segmentasi Citra (Bagian 2)

IF4073 Interpretasi dan Pengolahan Citra


Oleh: Rinaldi Munir




Program Studi Teknik Informatika
Sekolah Teknik Elektro dan Informatika
Institut Teknologi Bandung
2023

3. Split and Merge


- Menggunakan algoritma *divide and conquer*
- Citra dibagi (split) menjadi sejumlah region yang *disjoint*
- Gabung (*merge*) region-region bertetangga yang homogen




(a) Whole Image



(b) First Split




(c) Second Split



(d) Merge

R_1	R_2	
R_3	R_{41}	R_{42}
	R_{43}	R_{44}


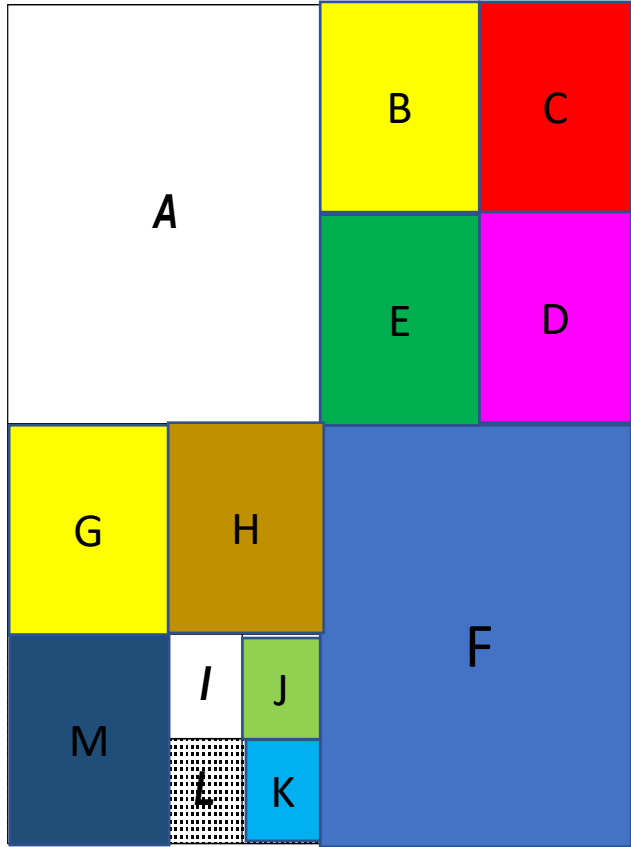


Algoritma *Split & Merge*

Given an image f and a predicate Q , the basic algorithm is:

1. $R_1 = f$
2. Subdivision in quadrants of each region R_i for which $Q(R_i) = \text{FALSE}$.
3. If $Q(R_i) = \text{TRUE}$ for every regions, merge those adjacent regions R_i and R_j such that $Q(R_i \cup R_j) = \text{TRUE}$; otherwise, repeat step 2.
4. Repeat the step 3 until no merging is possible.

Sumber: Image segmentation
Stefano Ferrari
Universit`a degli Studi di Milano
stefano.ferrari@unimi.it





Sumber: Image Segmentation, by Dr. Rajeev Srivastava

Segmentation steps: Original image (a), feature description image (b), image after the splitting process (c), image after the merging process (d), elimination of small regions (e), and the resulting segmentation classes obtained after the region growing procedure (f).



(a)



(b)



(c)



(d)



(e)

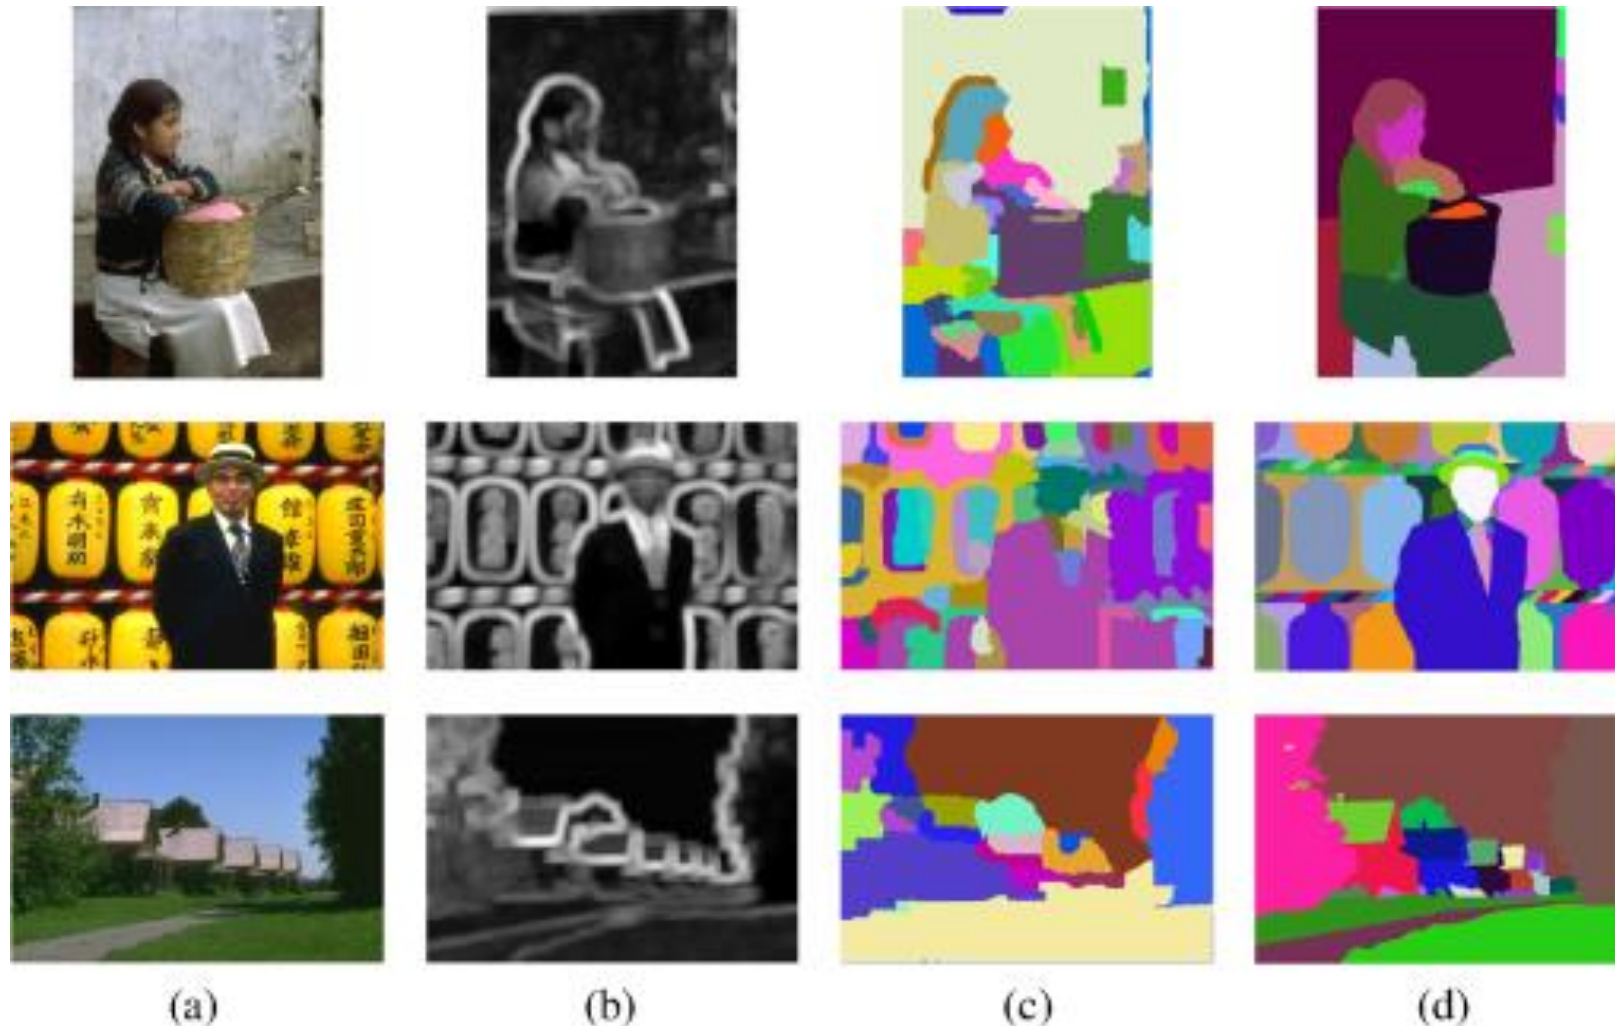


(f)

Sumber: *Integral split-and-merge methodology for real-time image segmentation*

By Fernando E. Correa-Tome, Raul E. Sanchez-Yanez

Example results: the input image (a), the SD image (b), the segmentation of the SD image using ISM (c), and a human-made reference segmentation (d).




Sumber: *Integral split-and-merge methodology for real-time image segmentation*
By Fernando E. Correa-Tome, Raul E. Sanchez-Yanez

4. Clustering

Prinsip *clustering* secara umum

- Misalkan terdapat N buah titik data (terokan, vektor fitur, dll), $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$
- Kelompokkan (*cluster*) titik-titik yang mirip dalam kelompok yang sama



Bagaimana kaitan *clustering* pada segmentasi citra?

- Nyatakan citra sebagai vektor fitur $\mathbf{x}_1, \dots, \mathbf{x}_n$
 - Sebagai contoh, setiap *pixel* dapat dinyatakan sebagai vektor:
 - Intensitas \rightarrow menghasilkan vektor dimensi satu
 - Warna \rightarrow menghasilkan vektor berdimensi tiga (R, G, B)
 - Warna + koordinat, \rightarrow menghasilkan vektor berdimensi lima
- Kelompokkan vektor-vektor fitur ke dalam k kluster

citra input

9 4 2	7 3 1	8 6 8
8 2 4	5 8 5	3 7 2
9 4 5	2 9 3	1 4 4

**Vektor fitur untuk clustering
berdasarkan warna**

[9 4 2]	[7 3 1]	[8 6 8]
[8 2 4]	[5 8 5]	[3 7 2]
[9 4 5]	[2 9 3]	[1 4 4]

RGB (or YUV) space clustering

citra input

9 4 2	7 3 1	8 6 8
8 2 4	5 8 5	3 7 2
9 4 5	2 9 3	1 4 4

Vektor fitur untuk clustering
berdasarkan warna dan
koordinat pixel

[9 4 2 0 0] [7 3 1 0 1] [8 6 8 0 2]
[8 2 4 1 0] [5 8 5 1 1] [3 7 2 1 2]
[9 4 5 2 0] [2 9 3 2 1] [1 4 4 2 2]


RGBXY (or YUVXY) space clustering

K-Means Clustering


- *K-means clustering* merupakan algoritma *clustering* yang paling populer
- Asumsikan jumlah cluster adalah k
- Mengoptimalkan (secara hampiran) fungsi objektif berikut untuk variabel D_i dan μ_i

$$E_k = SSE = \sum_{i=1}^k \sum_{x \in D_i} \|x - \mu_i\|^2$$

sum of squared errors dari cluster dengan pusat μ_i




$$SSE = \text{red star} + \text{green star} + \text{blue star}$$



$$SSE = \text{[red star]} + \text{[green star]} + \text{[blue star]}$$

Good (tight) clustering
smaller value of SSE




$$SEE = \text{[red star]} + \text{[green star]} + \text{[blue star]}$$

Bad (loose) clustering
larger value of SSE


Algoritma K-means Clustering

- Initialization step
 1. pick k cluster centers randomly




Algoritma K-means Clustering

- Initialization step
 1. pick k cluster centers randomly




Algoritma K-means Clustering

- Initialization step
 1. pick k cluster centers randomly
 2. assign each sample to closest center



Algoritma K-means Clustering


- Initialization step
 1. pick k cluster centers randomly
 2. assign each sample to closest center



Algoritma K-means Clustering

- Initialization step

1. pick k cluster centers randomly
2. assign each sample to closest center




- Iteration steps

1. compute means in each cluster $\mu_i = \frac{1}{|D_i|} \sum_{x \in D_i} x$

Algoritma K-means Clustering

- Initialization step

1. pick k cluster centers randomly
2. assign each sample to closest center




- Iteration steps

1. compute means in each cluster $\mu_i = \frac{1}{|D_i|} \sum_{x \in D_i} x$
2. re-assign each sample to the closest mean

Algoritma K-means Clustering

- Initialization step

1. pick k cluster centers randomly
2. assign each sample to closest center




- Iteration steps

1. compute means in each cluster $\mu_i = \frac{1}{|D_i|} \sum_{x \in D_i} x$
2. re-assign each sample to the closest mean

- Iterate until clusters stop changing

Algoritma K-means Clustering

- Initialization step
 1. pick k cluster centers randomly
 2. assign each sample to closest center



- Iteration steps
 1. compute means in each cluster $\mu_i = \frac{1}{|D_i|} \sum_{x \in D_i} x$
 2. re-assign each sample to the closest mean
- Iterate until clusters stop changing

- This procedure decreases the value of the objective function

$$E_k(D, \mu) = \sum_{i=1}^k \sum_{x \in D_i} \|x - \mu_i\|^2$$

↖ ↗



optimization variables

$$D = (D_1, \dots, D_k)$$

$$\mu = (\mu_1, \dots, \mu_k)$$


block-coordinate descent: step 1 optimizes μ , step 2 optimizes D

Contoh hasil *K-means clustering*





K-means menghasilkan
Pengelompokan yang kompak


Pada kasus ini, K-means ($K=2$) secara otomatis menemukan nilai ambang yang bagus antara 2 cluster



$k = 3$

(random colors are used to better show segments/clusters)





An image(I)



**Three cluster
image (J) on gray
values of I**

1. Select an image:

2. Select a processor:

3. Click




640*480

(607,118): RGB(20,22,1)

Options:

Init Method

Process done !



(228,26): RGB(255,170,0)

1. Select an image:

2. Select a processor:

3. Click




640*480

(636,95): RGB(102,130,151)


Options:

Init Method



Process done !

(590,209): RGB(0,46,255)



Sumber: <https://www.mathworks.com/discovery/image-segmentation.html>

Contoh hasil *K-means clustering* (berdasarkan warna)



0 100 200 300 400



0 100 200 300 400



0 100 200 300 400 500



0 100 200 300 400 500

Contoh hasil *K-means clustering* (berdasarkan warna + koordinat)

color quantization



RGB features

superpixels



RGBXY features


Voronoi cells




XY features only

Sifat-sifat K-means


- Works best when clusters are spherical (blob like)



- Fails for elongated clusters
 - SSE is not an appropriate objective function in this case



- Sensitive to outliers



maximum likelihood (ML) fitting
of parameters μ_i (means) of Gaussian distributions



$$E_k = \sum_{i=1}^k \sum_{x \in D_i} \|x - \mu_i\|^2$$



equivalent (easy to check)


$$E_k \sim - \sum_{i=1}^k \sum_{x \in D_i} \log P(x | \mu_i) + \text{const}$$

Gaussian distribution $P(x | \mu_i) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{\|x - \mu_i\|^2}{2\sigma^2}\right)$



$$E_k = \sum_{i=1}^k \sum_{x \in D_i} \|x - \mu_i\|^2$$



just plug-in
expression
 $\mu_i = \frac{1}{|D_i|} \sum_{y \in D_i} y$



equivalent (easy to check)

$$E_k = \sum_{i=1}^k \sum_{x, y \in D_i} \frac{\|x - y\|^2}{2 \cdot |D_i|}$$

sample variance: $\text{var}(D_i) = \frac{1}{|D_i|} \sum_{x \in D_i} \|x - \mu_i\|^2 = \frac{1}{2|D_i|^2} \sum_{x, y \in D_i} \|x - y\|^2$



both formulas can be written as

$$E_k = \sum_{i=1}^k |D_i| \cdot \text{var}(D_i)$$

sample variance: $\text{var}(D_i) = \frac{1}{|D_i|} \sum_{x \in D_i} \|x - \mu_i\|^2 = \frac{1}{2|D_i|^2} \sum_{x, y \in D_i} \|x - y\|^2$

Rangkuman K-means

- Advantages
 - Principled (objective function) approach to clustering
 - Simple to implement (the approximate iterative optimization)
 - Fast
- Disadvantages
 - Only a local minimum is found (sensitive to initialization)
 - May fail for non-blob like clusters ← K-means fits Gaussian models
 - Sensitive to outliers ← Quadratic errors are such
 - Sensitive to choice of k ← Can add sparsity term and make k an additional variable

$$E = \sum_{i=1}^k \sum_{x \in D_i} \|x - \mu_i\|^2 + \gamma \cdot |k|$$

*Akaike Information Criterion (AIC) or
Bayesian Information Criterion (BIC)*

<https://www.youtube.com/watch?app=desktop&v=pw6sTn55fZY>

Program Matlab untuk image segmentation dengan K-means

- Fungsi **imsegkmeans** hanya tersedia untuk Matlab R2022a

```
I = imread('camera.bmp');  
imshow(I)  
title('Original Image');  
[L, Centers] = imsegkmeans(I, 3); % Segmentasi citra menjadi tiga  
label dengan K-means clustering  
B = labeloverlay(I, L);  
imshow(B)  
title('Labeled Image')
```

Original Image



Labeled Image



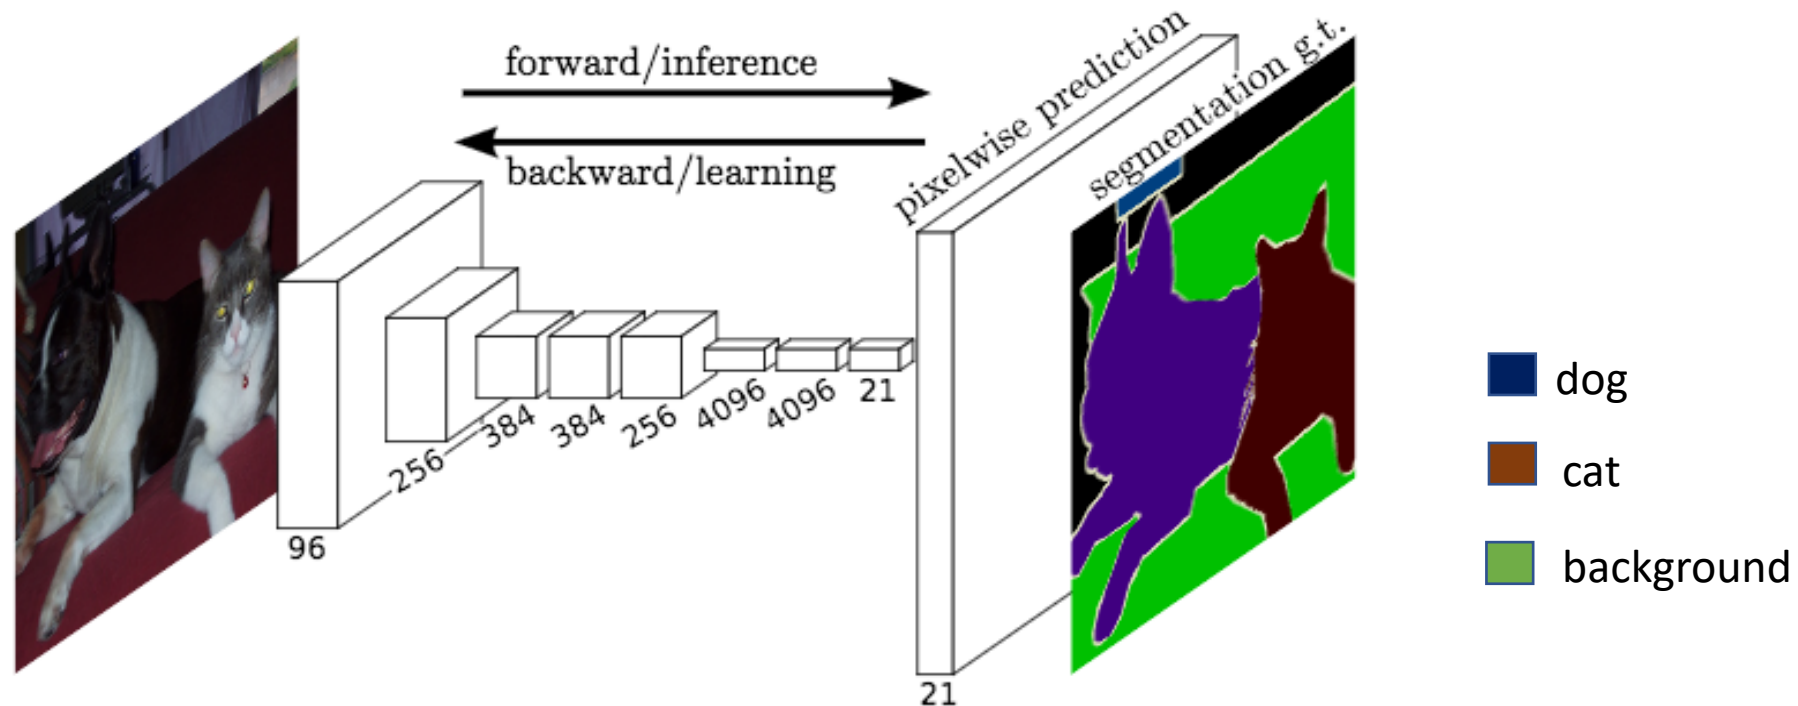
```
RGB = imread("kobi.png");  
RGB = imresize(RGB,0.5);  
imshow(RGB)  
L = imsegkmeans(RGB,2);  
B = labeloverlay(RGB,L);  
imshow(B)  
title("Labeled Image")
```



Segmentasi Citra dengan *Deep Learning*

- Disebut juga *semantic segmentation*
- Tiap *pixel* di dalam citra diasosiasikan dengan sebuah label kelas

semantic
segmentation




Segmentasi Semantik

- Segmentasi semantik adalah algoritma pembelajaran mendalam yang mengaitkan label atau kategori dengan setiap piksel dalam sebuah gambar.
- Ini digunakan untuk mengenali kumpulan piksel yang membentuk kategori berbeda. Misalnya, kendaraan otonom perlu mengidentifikasi kendaraan, pejalan kaki, rambu lalu lintas, trotoar, dan fitur jalan lainnya.
- Segmentasi semantik digunakan dalam banyak aplikasi seperti mengemudi otomatis, pencitraan medis, dan inspeksi industri.

Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>

- Contoh sederhana dari segmentasi semantik adalah memisahkan gambar menjadi dua kelas. Misalnya, pada Gambar 1, gambar yang memperlihatkan seseorang di pantai dipasangkan dengan versi yang menunjukkan piksel gambar yang disegmentasi menjadi dua kelas terpisah: orang dan latar belakang.



Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>

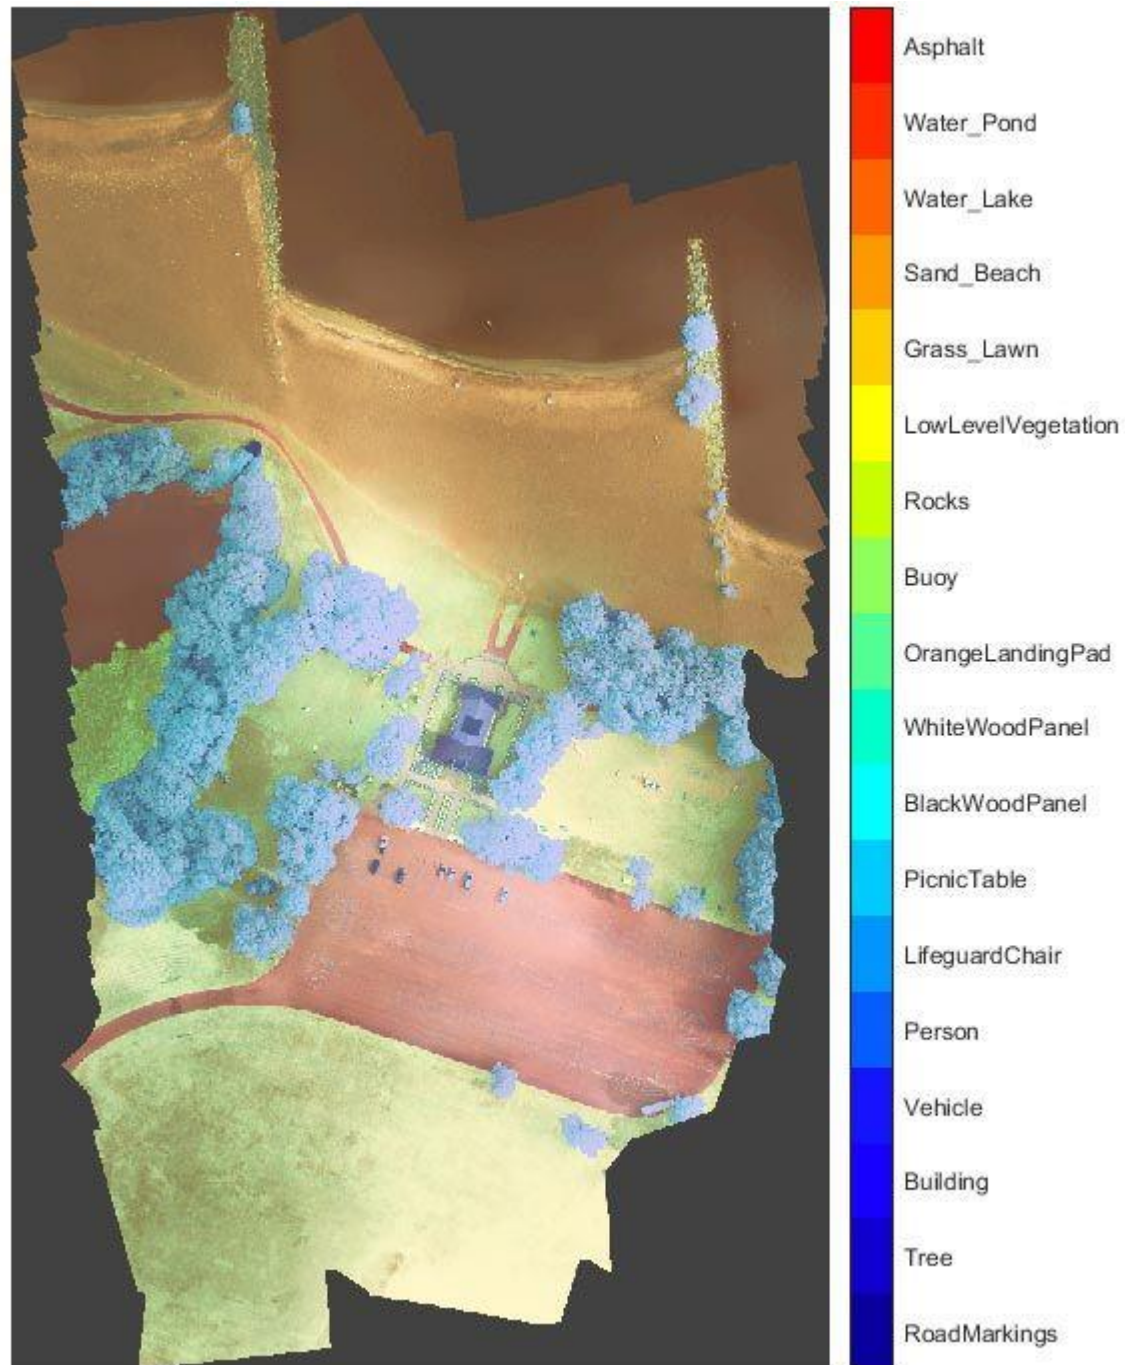


- person
- grass
- trees
- motorbike
- road

- Karena segmentasi semantik memberi label pada piksel dalam suatu gambar, maka segmentasi ini lebih tepat dibandingkan bentuk deteksi objek lainnya.
- Hal ini membuat segmentasi semantik berguna untuk aplikasi di berbagai industri yang memerlukan peta gambar yang tepat, seperti:
 - a) Mengemudi otonom—untuk mengidentifikasi jalur yang dapat dilalui mobil dengan memisahkan jalan dari rintangan seperti pejalan kaki, trotoar, tiang, dan mobil lain
 - b) Inspeksi industri—untuk mendeteksi cacat pada bahan, seperti inspeksi wafer
 - c) Citra satelit—untuk mengidentifikasi gunung, sungai, gurun, dan medan lainnya
 - d) Pencitraan medis—untuk menganalisis dan mendeteksi anomali kanker dalam sel
- Visi robotik—untuk mengidentifikasi dan menavigasi objek dan medan

Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>

Segmentasi semantik dari citra satelit multispektral.





Gambar Segmentasi semantik untuk aplikasi mengemudi otomatis.

Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>


Cara Kerja Segmentasi Semantik

Proses pelatihan jaringan segmentasi semantik untuk mengklasifikasikan gambar mengikuti langkah-langkah berikut:

1. Analisis kumpulan gambar berlabel piksel.
2. Buat jaringan segmentasi semantik.
3. Latih jaringan untuk mengklasifikasikan gambar ke dalam kategori piksel.
4. Menilai keakuratan jaringan.

Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>


- Segmentasi semantic menggunakan CNN



Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>

- Untuk mengklasifikasikan pada tingkat piksel, bukan keseluruhan gambar, kita dapat menambahkan implementasi CNN terbalik.
- Proses upsampling dilakukan dengan jumlah yang sama dengan proses downsampling untuk memastikan gambar akhir berukuran sama dengan gambar masukan.
- Terakhir, lapisan keluaran klasifikasi piksel digunakan, yang memetakan setiap piksel ke kelas tertentu. Ini membentuk arsitektur encoder-decoder, yang memungkinkan segmentasi semantik.

Sumber: <https://www.mathworks.com/solutions/image-video-processing/semantic-segmentation.html>



Gambar 6: CNN menjalankan fungsi terkait gambar di setiap lapisan dan kemudian melakukan downsampling gambar menggunakan lapisan penyatuan (hijau). Proses ini diulangi beberapa kali untuk paruh pertama jaringan. Output dari paruh pertama diagram ini diikuti oleh lapisan unpooling dalam jumlah yang sama (oranye).