



# Ciencia y Tecnología

Secretaría de Ciencia, Humanidades, Tecnología e Innovación



CIMAT  
UNIDAD MÉRIDA

# PROCESAMIENTO DE IMÁGENES (ANÁLISIS DE OBJETOS EN IMÁGENES BINARIAS)

Dr. Francisco J. Hernández López

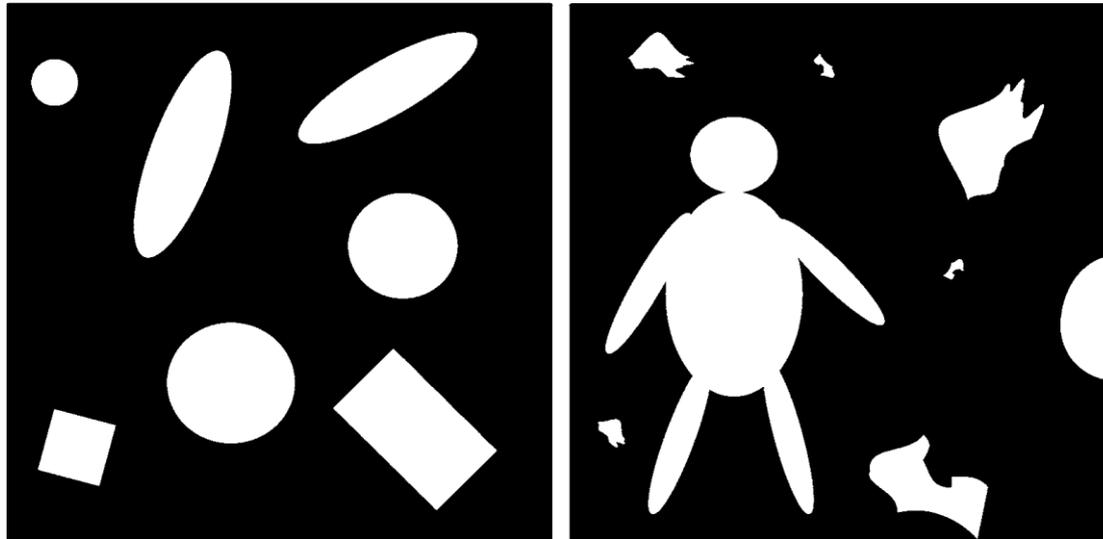
SECIHTI – CIMAT-Mérida

fcoj23@cimat.mx, [www.cimat.mx/~fcoj23](http://www.cimat.mx/~fcoj23)



# ANÁLISIS DE OBJETOS EN IMÁGENES BINARIAS

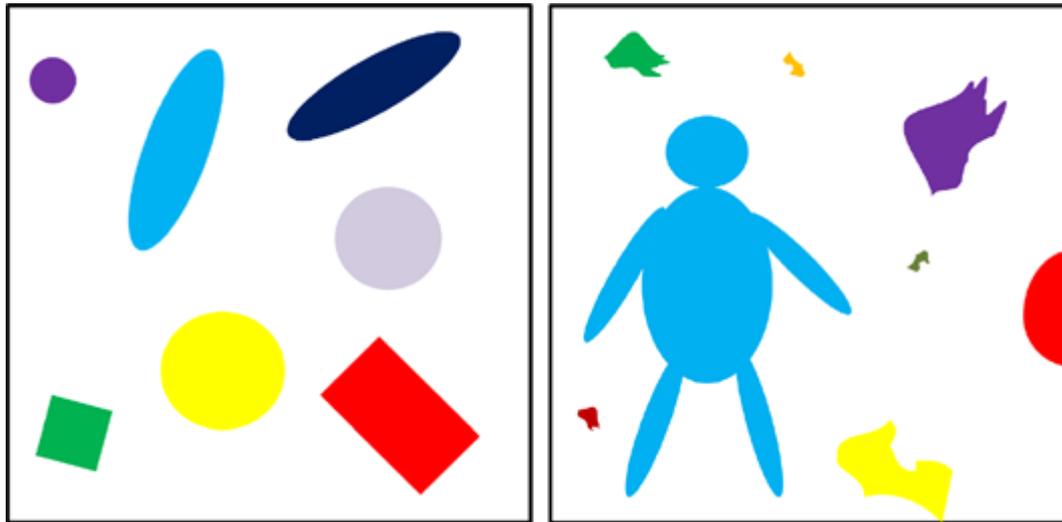
- *BLOB* (*Binary Large Object*) hace referencia a un grupo de píxeles conectados de tamaño no despreciable en una imagen binaria
- **Objetivo:** Extraer y clasificar los *BLOBs*



Moeslund, T. B. (2012). Introduction to video and image processing: Building real systems and applications. Springer Science & Business Media.

# COMPONENTES CONECTADOS

- También conocido como etiquetado o coloreado
- A cada grupo de píxeles en la imagen binaria se le asigna una etiqueta o color



Moeslund, T. B. (2012). Introduction to video and image processing: Building real systems and applications. Springer Science & Business Media.

## 1: SequentialLabeling( $I$ )

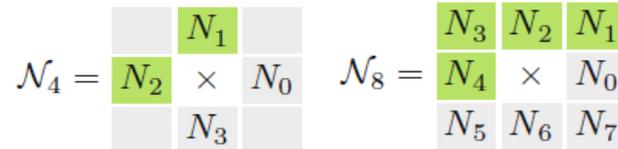
Input:  $I$ , an integer-valued image with initial values  $0 = \textit{background}$ ,  $1 = \textit{foreground}$ . Returns nothing but modifies the image  $I$ .

Step 1 – Assign initial labels: 
$$I(u, v) = \begin{cases} 0 & \textit{background} \\ 1 & \textit{foreground} \\ 2, 3, \dots & \textit{region label} \end{cases}$$

```

2:  ( $M, N$ )  $\leftarrow$  Size( $I$ )
3:   $label \leftarrow 2$  ▷ value of the next label to be assigned
4:   $C \leftarrow ()$  ▷ empty list of label collisions
5:  for  $v \leftarrow 0, \dots, N - 1$  do
6:    for  $u \leftarrow 0, \dots, M - 1$  do
7:      if  $I(u, v) = 1$  then ▷  $I(u, v)$  is a foreground pixel
8:         $\mathcal{N} \leftarrow \text{GetNeighbors}(I, u, v)$ 
9:        if  $N_i = 0$  for all  $N_i \in \mathcal{N}$  then
10:          $I(u, v) \leftarrow label$ .
11:          $label \leftarrow label + 1$ .
12:        else if exactly one  $N_j \in \mathcal{N}$  has a value  $> 1$  then
13:         set  $I(u, v) \leftarrow N_j$ 
14:        else if more than one  $N_k \in \mathcal{N}$  have values  $> 1$  then
15:          $I(u, v) \leftarrow N_k$  ▷ select one  $N_k > 1$  as the new label
16:         for all  $N_l \in \mathcal{N}$ , with  $l \neq k$  and  $N_l > 1$  do
17:            $C \leftarrow C \cup (N_k, N_l)$  ▷ register collision ( $N_k, N_l$ )

```



*Remark:* The image  $I$  now contains labels  $0, 2, \dots, label-1$ .

Create a partitioning of the label set (sequence of 1-element sets):

```

18:  $R \leftarrow (\{2\}, \{3\}, \{4\}, \dots, \{label-1\})$ 
19: for all collisions  $(A, B)$  in  $C$  do
    Find the sets  $R(a), R(b)$  holding labels  $A, B$ :
20:    $a \leftarrow$  index of the set  $R(a)$  that contains label  $A$ 
21:    $b \leftarrow$  index of the set  $R(b)$  that contains label  $B$ 
22:   if  $a \neq b$  then       $\triangleright A$  and  $B$  are contained in different sets
23:      $R(a) \leftarrow R(a) \cup R(b)$    $\triangleright$  merge elements of  $R(b)$  into  $R(a)$ 
24:      $R(b) \leftarrow \{\}$ 

```

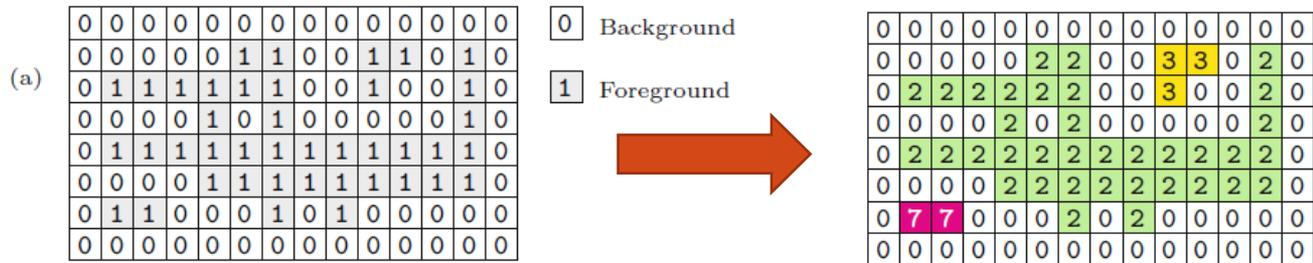
*Remark:* All *equivalent* labels (i.e., all labels of pixels in the same connected component) are now contained in the same subset of  $R$ .

```

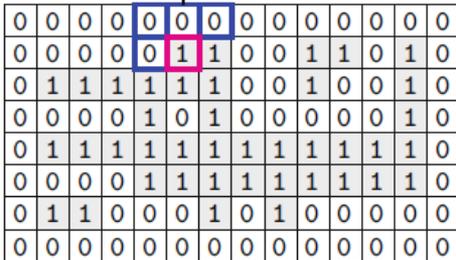
25: Step 3: Relabel the image:
26: for all  $(u, v) \in M \times N$  do
27:   if  $I(u, v) > 1$  then       $\triangleright$  this is a labeled foreground pixel
28:      $j \leftarrow$  index of the set  $R(j)$  that contains label  $I(u, v)$ 
     Choose a representative element  $k$  from the set  $R(j)$ :
29:      $k \leftarrow \min(R(j))$        $\triangleright$  e.g., pick the minimum value
30:      $I(u, v) \leftarrow k$            $\triangleright$  replace the image label
31: return

```

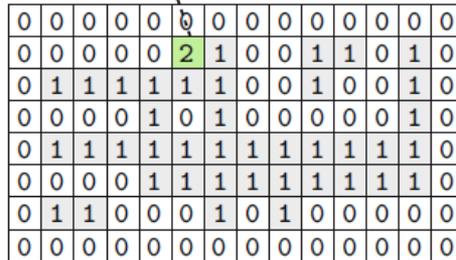
# EJEMPLO



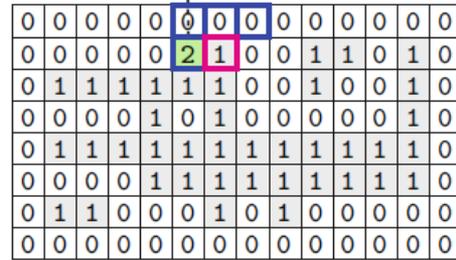
(b) Background neighbors only



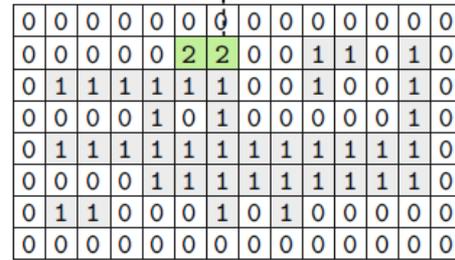
New label (2)



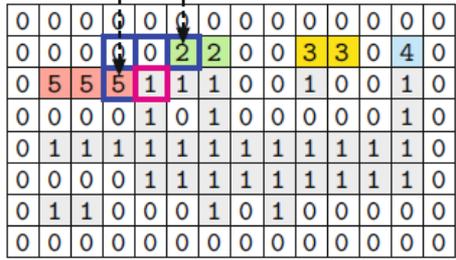
(c) Exactly one neighbor label



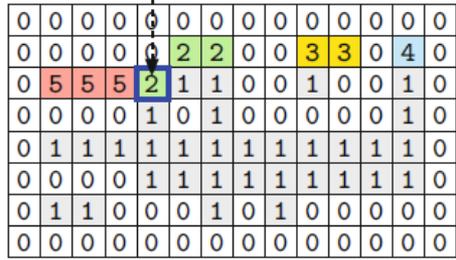
Neighbor label is propagated



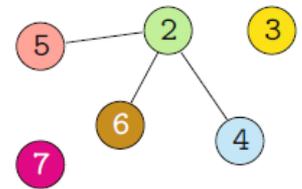
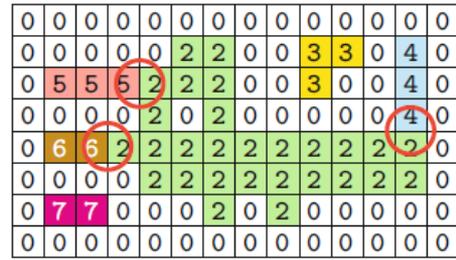
(d) Two different neighbor labels



One of the labels (2) is propagated

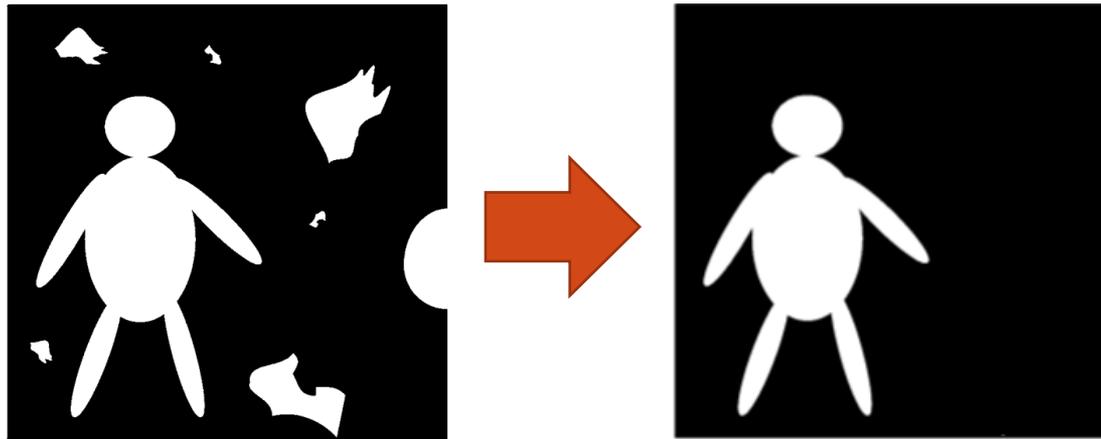


Colisión de etiquetas



# CARACTERÍSTICAS GEOMÉTRICAS DE LOS BLOBS

- **Área:** Número de píxeles del *BLOB* o componente conectado (CC), utilizada para remover *BLOBs* muy pequeños o muy grandes de la imagen



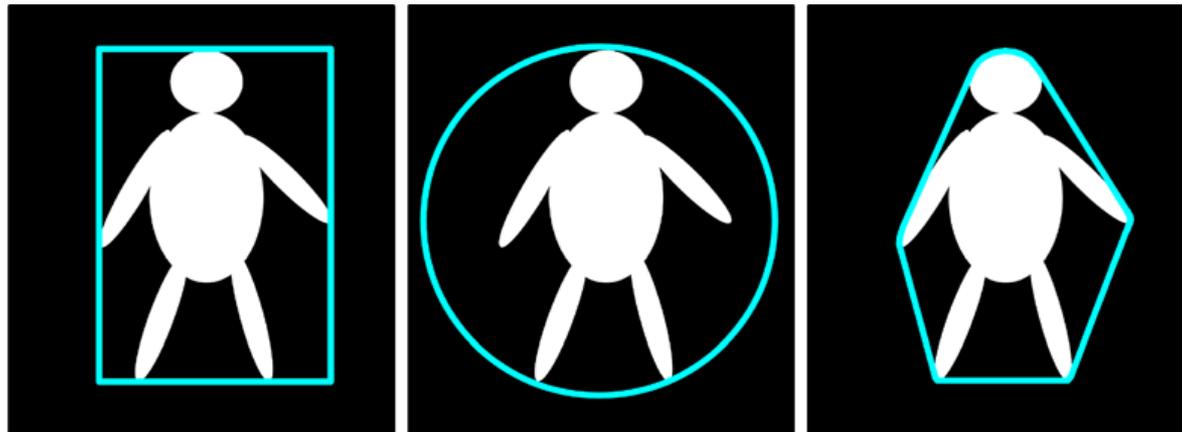
Con el área de cada *BLOB*, podríamos quitar aquellos *BLOBs* que son más pequeños que cierto umbral

Moeslund, T. B. (2012). Introduction to video and image processing: Building real systems and applications. Springer Science & Business Media.

- **Caja envolvente o *Bounding Box (BBox)***: Es el mínimo rectángulo que contiene al *BLOB*. Se calcula recorriendo los píxeles del *BLOB* y encontrando los 4 píxeles con el mínimo valor en  $x$ , máximo valor en  $x$ , mínimo valor en  $y$  y máximo valor en  $y$ . El ancho y alto se calculan como sigue:

$$\begin{aligned} \text{ancho} &= x_{max} - x_{min} \\ \text{alto} &= y_{max} - y_{min} \end{aligned}$$

- **Circulo envolvente**: Es el mínimo círculo que contiene al *BLOB*
- **Casco convexo o *Convex Hull***: Es el mínimo polígono convexo que contiene al *BLOB*



Moeslund, T. B. (2012). Introduction to video and image processing: Building real systems and applications. Springer Science & Business Media.

- **Compacidad:** Se define como la razón del área del *BLOB* y el área del *BBox*

$$\text{Compacidad} = \frac{\text{área del BLOB}}{\text{ancho} \times \text{alto del BBox}}$$

- **Centro de masa o centro de gravedad o centroide:** Es el promedio en las posiciones  $x$  y  $y$ , definido como

$$x_c = \frac{1}{N} \sum_i^N x_i, \quad y_c = \frac{1}{N} \sum_i^N y_i$$

con  $(x_i, y_i)$  las coordenadas del pixel dentro del *BLOB* y  $N$  el número de pixeles del *BLOB*

- **Centro del *BBox*:**

$$x_{bb} = x_{min} + \frac{x_{max} - x_{min}}{2} = \frac{x_{min} + x_{max}}{2}$$

$$y_{bb} = y_{min} + \frac{y_{max} - y_{min}}{2} = \frac{y_{min} + y_{max}}{2}$$

Moeslund, T. B. (2012). Introduction to video and image processing: Building real systems and applications. Springer Science & Business Media.

- **Perímetro:** Es la longitud del contorno del *BLOB*, puede calcularse:
  - Recorriendo el contorno y sumando el número de píxeles encontrados
  - Detectando los bordes y sumando los píxeles que están en los bordes
- **Circularidad:** Define que tan circular es un *BLOB* usando su perímetro y área. El factor de circularidad de Heywood se define como

$$C_1 = \frac{\text{Perímetro del BLOB}}{2\sqrt{\pi \text{Área del BLOB}}}$$

$[1, \infty]$

1 → Círculo perfecto

$\infty$  → Línea

$$C_2 = \frac{1}{C_1} = \frac{2\sqrt{\pi \text{Área del BLOB}}}{\text{Perímetro del BLOB}}$$

$[0,1]$

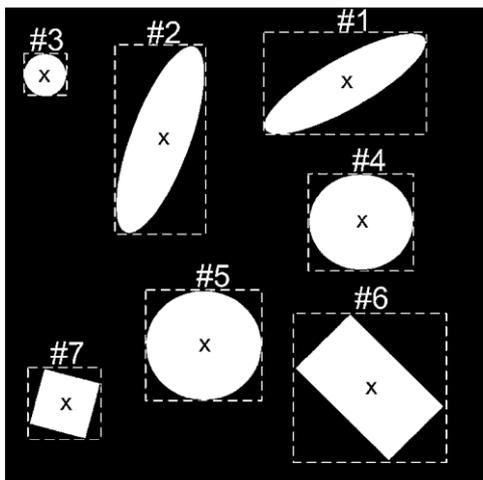
1 → Círculo perfecto

0 → Línea

Estas medidas se pueden salir del intervalo dado, debido a que la estimación del perímetro puede no ser exacta.

# CLASIFICACIÓN DEL *BLOB*

- Ya que se han extraído los *BLOBs* y que se tienen un conjunto de características de cada uno, ahora es posible clasificarlos para resolver algún problema en particular
- Ejemplo: Clasificar en círculo y no círculo los siguientes *BLOBs*



$C_2$

BLOB number	Circularity	Area (pixels)
1	0.31	6561
2	0.40	6544
3	0.98	890
4	0.97	6607
5	0.99	6730
6	0.52	6611
7	0.75	2073

Elegimos la característica de circularidad y proponemos un umbral  $T = 0.8$

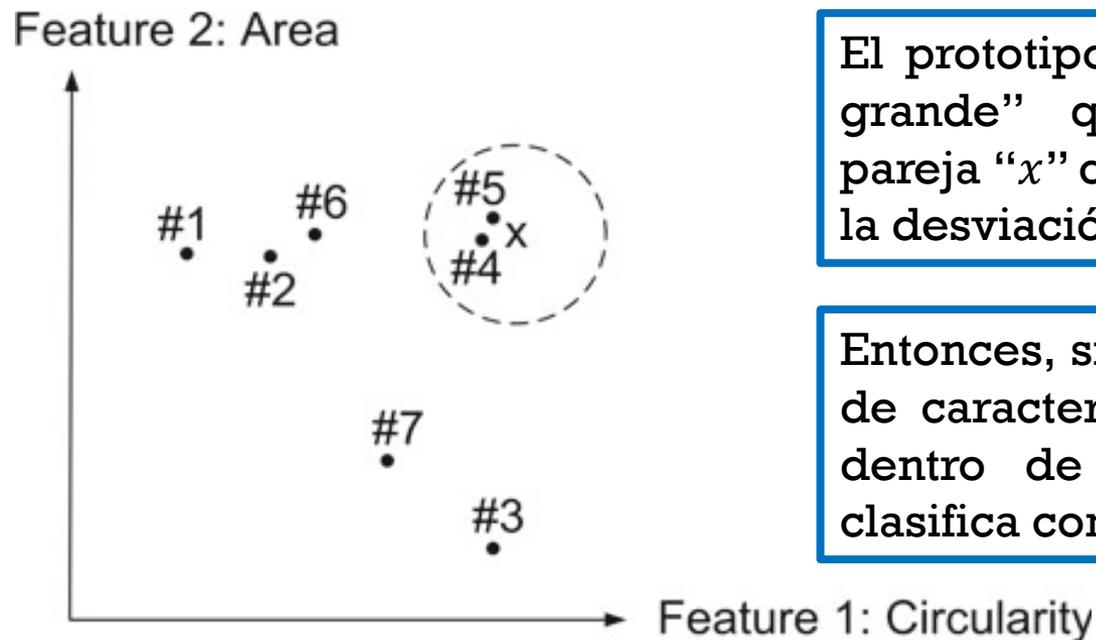
$$L(i) = \begin{cases} 1 & C_2(i) \geq T \\ 0 & C_2(i) < T \end{cases}$$

Con  $i = 1, \dots, N_B$  y  $N_B$  el número de *BLOBs*

Moeslund, T. B. (2012). Introduction to video and image processing: Building real systems and applications. Springer Science & Business Media.

# DETECTAR SOLO CÍRCULOS GRANDES

- Ahora, además de considerar la característica de circularidad, hay que tomar en cuenta la de área



El prototipo o modelo de un “círculo grande” queda definido por una pareja “ $x$ ” con un radio que representa la desviación permitida.

Entonces, si un BLOB tiene una pareja de características (circularidad, área) dentro de la región permitida, se clasifica como un círculo grande.

Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# NORMALIZACIÓN DE LAS CARACTERÍSTICAS

 $C_2$ 

BLOB number	Circularity	Area (pixels)
1	0.31	6561
2	0.40	6544
3	0.98	890
4	0.97	6607
5	0.99	6730
6	0.52	6611
7	0.75	2073

- Supongamos que el modelo es el vector

$$\vec{f}_m = \begin{bmatrix} 1 \\ 6700 \end{bmatrix}$$

- La distancia Euclidiana entre las características del BLOB 1 y el modelo sería

$$d(\vec{f}_1, \vec{f}_m) = \|\vec{f}_1 - \vec{f}_m\|_2 = \sqrt{(0.31 - 1)^2 + (6561 - 6700)^2}$$

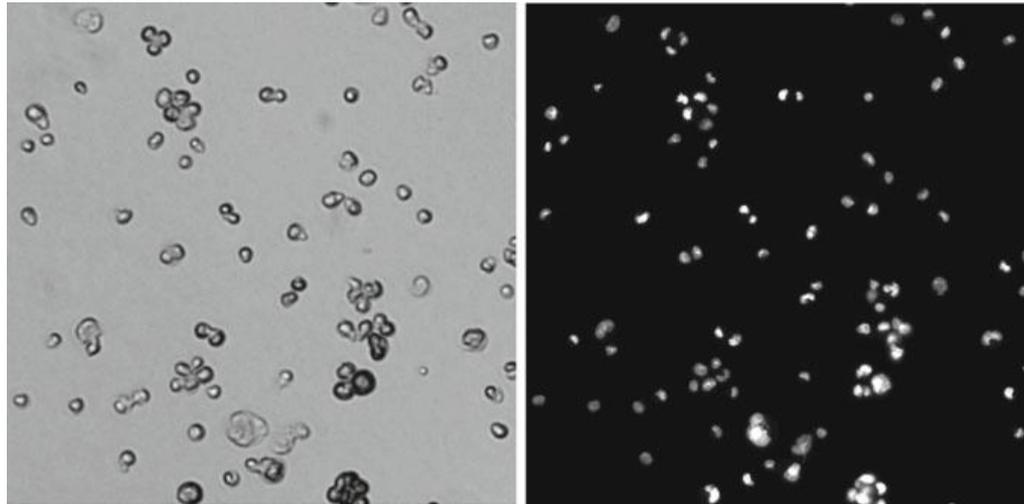
- Note que hay una gran diferencia entre las magnitudes de los valores de cada característica, la circularidad está entre [0.31,0.99] y las áreas están entre [890,6730]. Esto significa que la distancia está dominada por los valores del área. Una solución a este problema es normalizar los valores de las características, por ejemplo, en el rango [0,1]

$$\tilde{A} = \frac{A - A_{min}}{A_{max} - A_{min}}, \quad \tilde{C} = \frac{C - C_{min}}{C_{max} - C_{min}}$$

Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# APLICACIÓN: CLASIFICACIÓN DE CÉLULAS

- Estas imágenes fueron obtenidas de un instrumento llamado Citómetro. Las células son parte del tejido del riñón de un mono (COS-7)
- El objetivo es clasificar en dos clases: **Núcleo y Ruido**



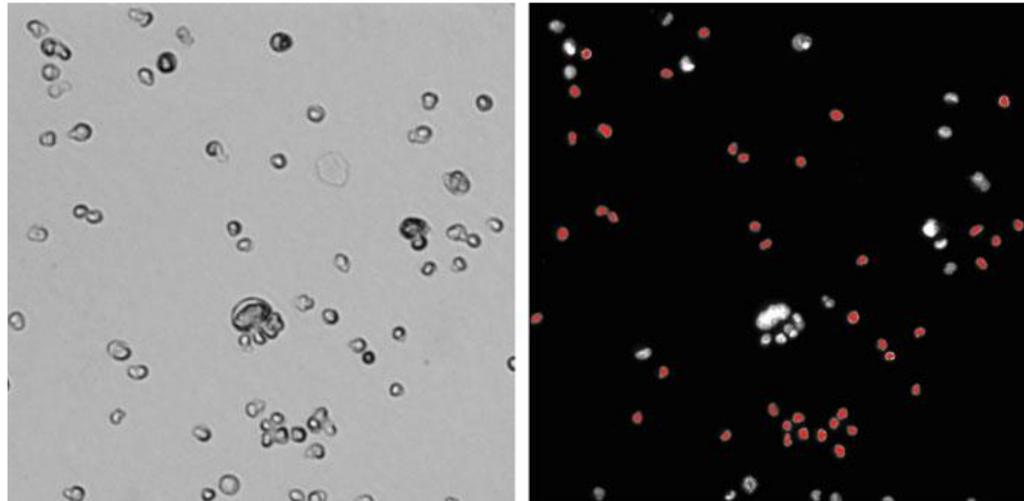
Microscopía ultravioleta

Microscopía de fluorescencia

Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# DATOS DE ENTRENAMIENTO

- Se obtienen a partir del etiquetado a mano (con color rojo) de todo lo que si es núcleo (*Ground Truth*)
- Antes de etiquetar, se aplica un umbral para obtener una imagen binaria y luego una operación morfológica de apertura y una de cerradura con un elemento de estructura circular de  $5 \times 5$  (Preprocesamiento)



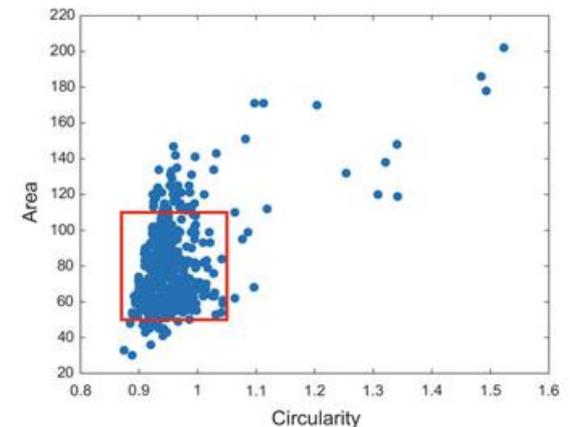
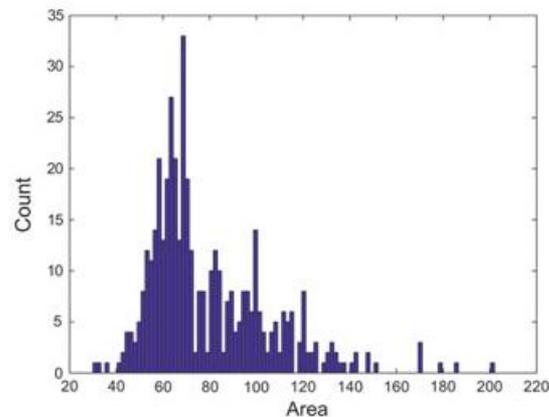
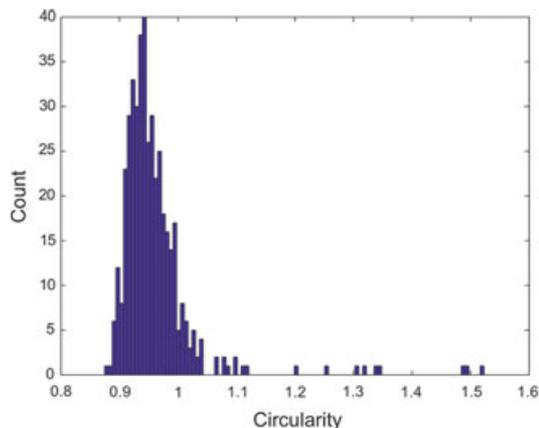
Microscopía ultravioleta

Microscopía de fluorescencia

Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# SELECCIÓN DE CARACTERÍSTICAS Y RANGOS DE VALORES

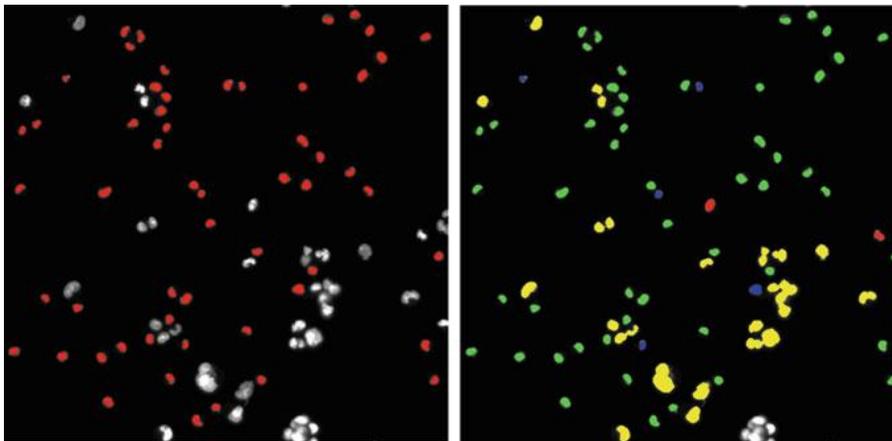
- Se toman como características la circularidad y el área
- Se observa la distribución de los datos de entrenamiento en los histogramas de las características y se toma un rango de valores aceptables para cada uno (ver cuadro rojo)
- Rangos: circularidad  $[0.87, 1.05]$ , área  $[50, 110]$ . Ya que son individuales, no hace falta normalizar los valores de las características



Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# CLASIFICAR CÉLULAS

- Se realiza el preprocesamiento indicado en la etapa de entrenamiento
- Se extraen todos los *BLOBs*, quitando los que están en la orilla de la imagen y se calculan sus características
- Se calculan las características de circularidad y área para cada *BLOB* y aquellos que tengan sus valores dentro del rango definido, se clasifican como núcleos, el resto como ruido



*Ground Truth*

Resultado de la clasificación

Verde: Verdaderos Positivos (TP)  
Rojo: Falsos Positivos (FP)  
Azul: Falsos Negativos (FN)  
Amarillo: Verdaderos Negativos (TN)

Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# EVALUACIÓN DE LA CLASIFICACIÓN

		Predicción	
		Núcleo	Ruido
Ground Truth	Núcleo	TP=51	FN=5
	Ruido	FP=2	TN=19

**Exactitud:** Con que frecuencia el clasificador acierta  $(TP + TN)/N$ , con  $N = TP + FN + FP + TN$  el número total de elementos a clasificar

**Tasa de clasificación errónea:** Con que frecuencia el clasificador falla  $(FP + FN)/N$

**Tasa de verdaderos positivos (Sensibilidad, Exhaustividad o Recall):** Con que frecuencia se predice un positivo cuando en realidad es positivo  $PDR = TP/(FN + TP)$

**Tasa de falsos positivos:** Con que frecuencia se predice un positivo cuando en realidad es negativo  $FP/(TN + FP)$

**Tasa de verdaderos negativos (Especificidad):** Con que frecuencia se predice un negativo cuando en realidad es negativo  $NDR = TN/(TN + FP)$

**Precisión:** Con que frecuencia el clasificador es correcto cuando se predice un positivo  $P = TP/(FP + TP)$

**Medida F1:**  $F_1 = 2 * PDR * P / (PDR + P)$

Paulsen, R. and T. Moeslund. (2020). Introduction to Medical Image Analysis. First Edition. Springer International Publishing. ISBN: 978-3-030-39363-2

# GRACIAS POR SU ATENCIÓN

Francisco J. Hernandez-Lopez

[fcoj23@ciamat.mx](mailto:fcoj23@ciamat.mx)

WebPage:

[www.cimat.mx/~fcoj23](http://www.cimat.mx/~fcoj23)

