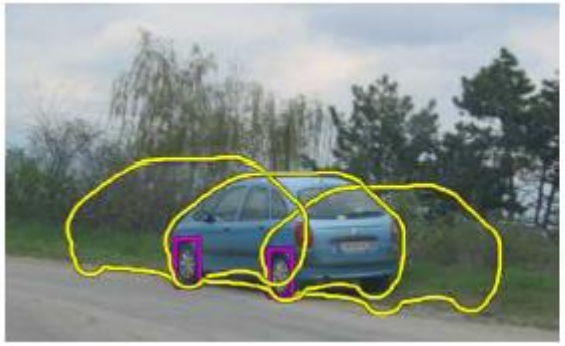

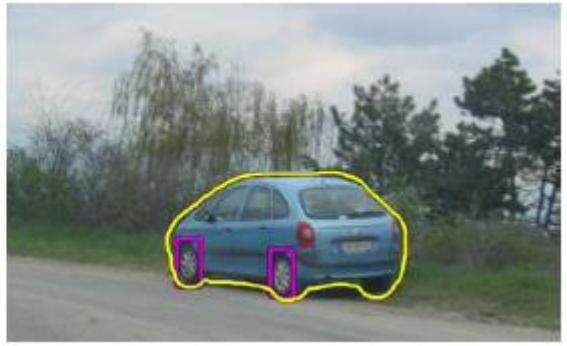

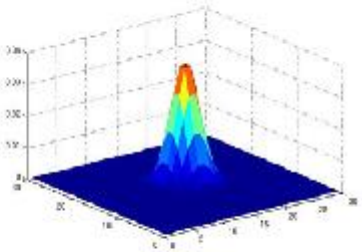

Computer Vision
Lecture 9
Grouping & Fitting
(Hough Transform & Deformable Contours)

Dr. Ali Mahmoud Mayya

Computer Science Dept.

AL Manara University, Syria

2024

Fitting الملاءمة

- Want to associate a model with observed features
- ربط النموذج مع السمات المستخلصة (الحواف ، الخطوط ، الزوايا، المناطق المدورة الخ).

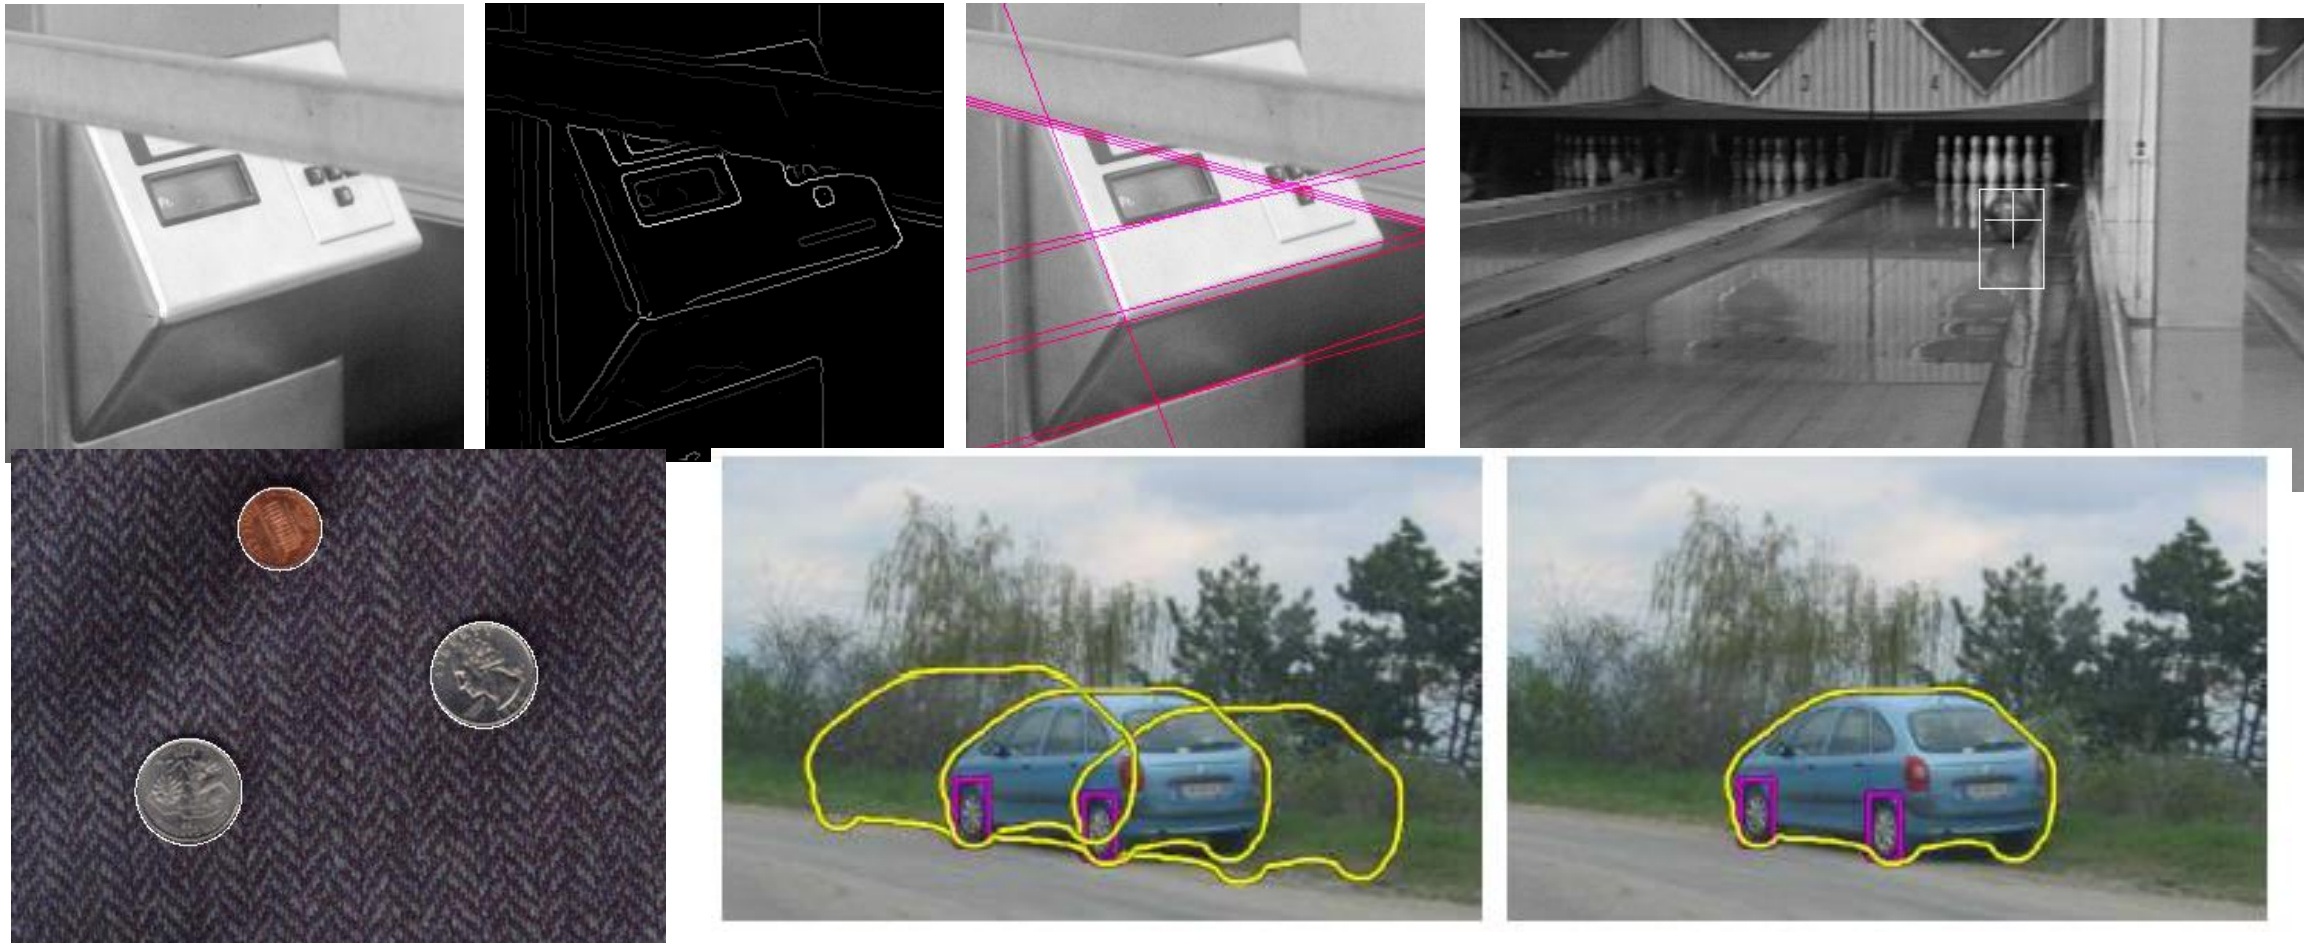

النموذج يمكن أن يكون خط line، دائرة Circle، أو شكل عشوائي Arbitrary shape.

[Fig from Marszalek & Schmid, 2007]

Line fitting ملاءمة الخطوط (تحويل هاف)

- Why fit lines? ما هي الخطوط
  Many objects characterized by presence of straight lines
  هناك العديد من الأجسام يمكن تمييزها من خلال الخطوط

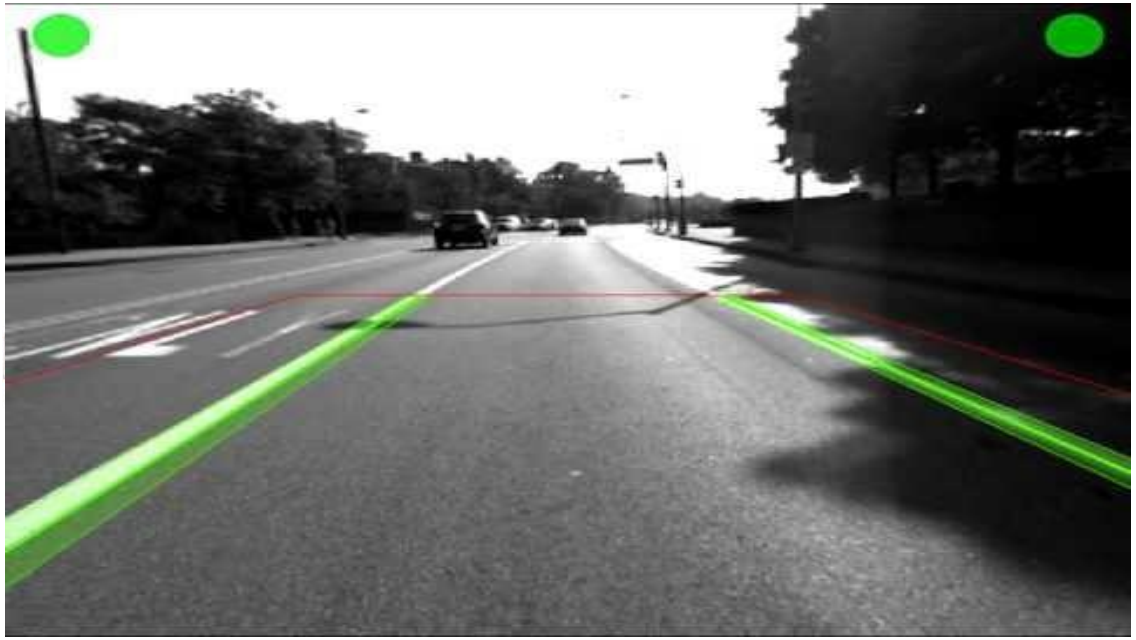

- Wait, why aren't we done just by running edge detection?

Hough transform for circles تحويل هاف للدوائر(ملاءمة الدوائر)

- Circle: center (a,b) and radius r

$$(x_i - a)^2 + (y_i - b)^2 = r^2$$

- For a fixed radius r, unknown gradient direction

- من أجل نصف قطر محدد r، واتجاه غير معروف للتدرج --> تحويل هاف ثنائي البعد ومصفوفة المراكم تتضمن حساب بارامترين هما: a,b أي تصبح مصفوفة المراكم هي A(a,b)

كل نقطة تقع على محيط دائرة في فضاء الصور تقابل دائرة في فضاء البارمترات وتتقاطع هذه الدوائر في نقطة واحدة تكافئ مركز الدائرة في فضاء الصورة

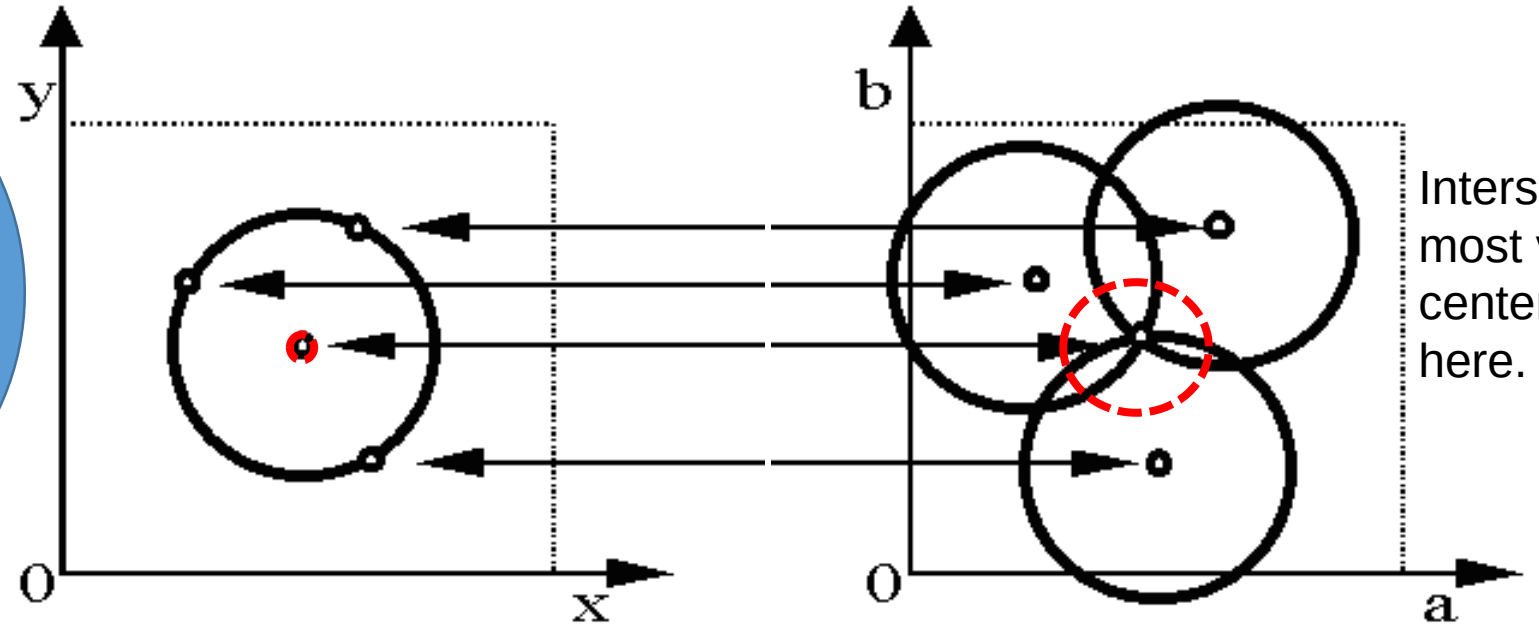

Intersection: most votes for center occur here.

Image space

Hough space

Hough transform for circles تحويل هاف للدوائر

- Circle: center (a,b) and radius r

$$(x_i - a)^2 + (y_i - b)^2 = r^2$$

- For an unknown radius r, unknown gradient direction
- من أجل نصف قطر غير معروف، واتجاه مشتق أو تدرج غير معروف تتحول المسألة إلى فضاء ثلاثي الأبعاد r,a,b وتصبح مصفوفة المراكم هي A(r,a,b). (لاحظ نحصل في فضاء البارمترات على مخاريط Cones.

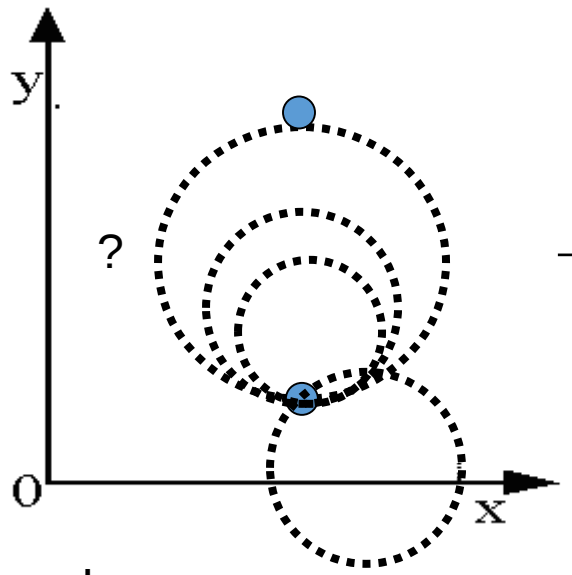

Image space

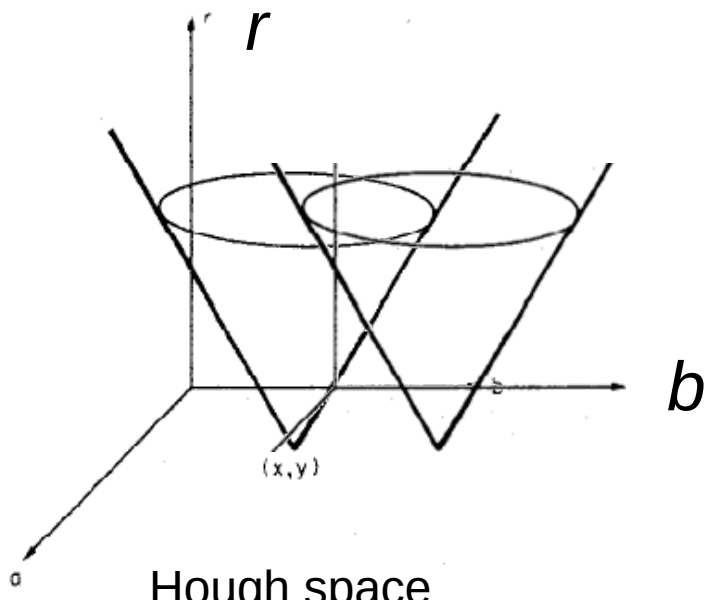

Hough space

Hough transform for circles تحويل هاف للدوائر

- For an unknown radius r, **known** gradient direction
- من أجل نصف قطر غير معلوم، واتجاه تدرج معلوم تبقى المسألة ثلاثية الأبعاد لكن مركز الدائرة في فضاء البارامترات سيصبح ضمن نطاق خط line وليس مخروط cone

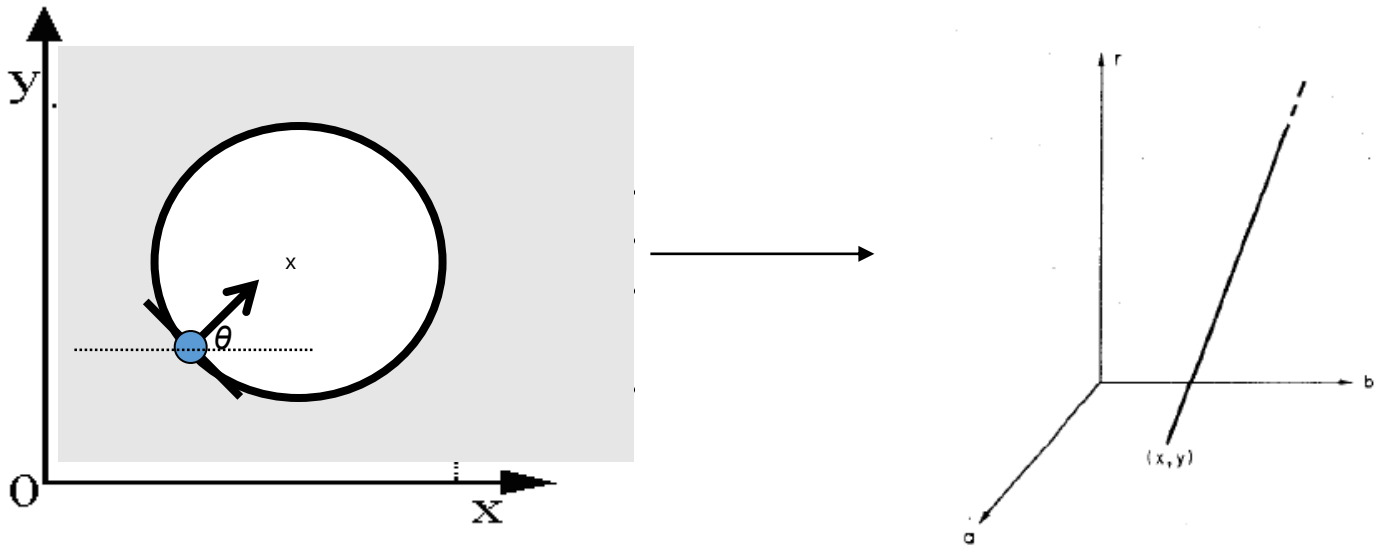

Image space Hough space

Hough transform for circles تحويل هاف للدوائر

```
For every edge pixel (x,y) :
  For each possible radius value r:
    For each possible gradient direction ϑ:
      // or use estimated gradient at (x,y)
            a = x + r cos(ϑ) // column
            b = y - r sin(ϑ)  // row
            H[a,b,r] += 1
  end
end
```

- Check out online demo : http://www.markschulze.net/java/hough/

Hough transform for circles تحويل هاف للدوائر

Original

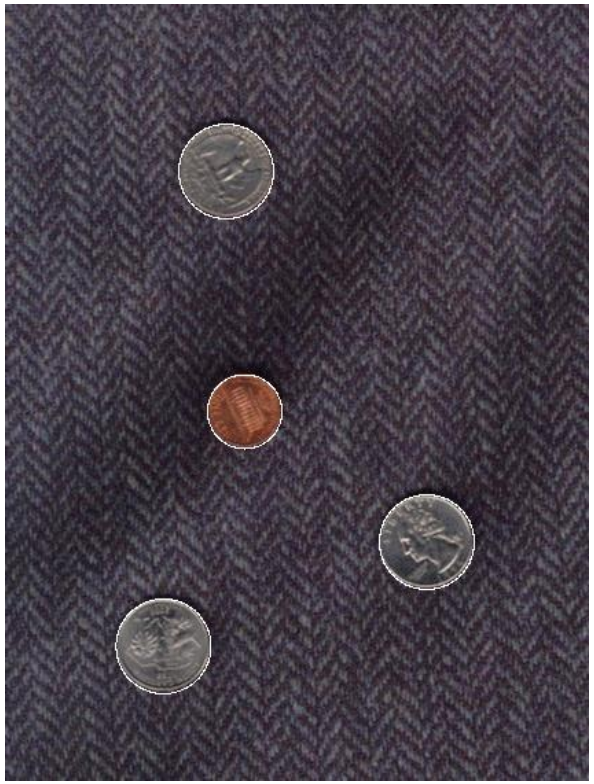

Edges

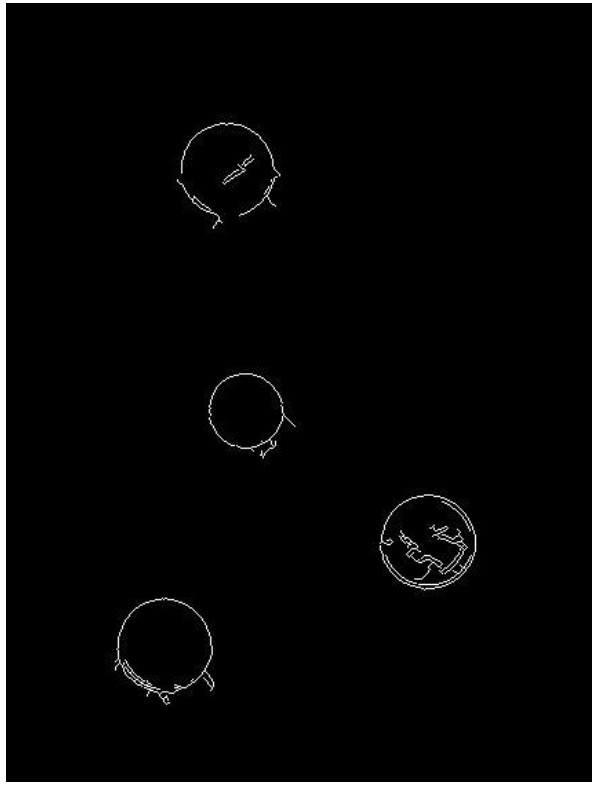

Votes

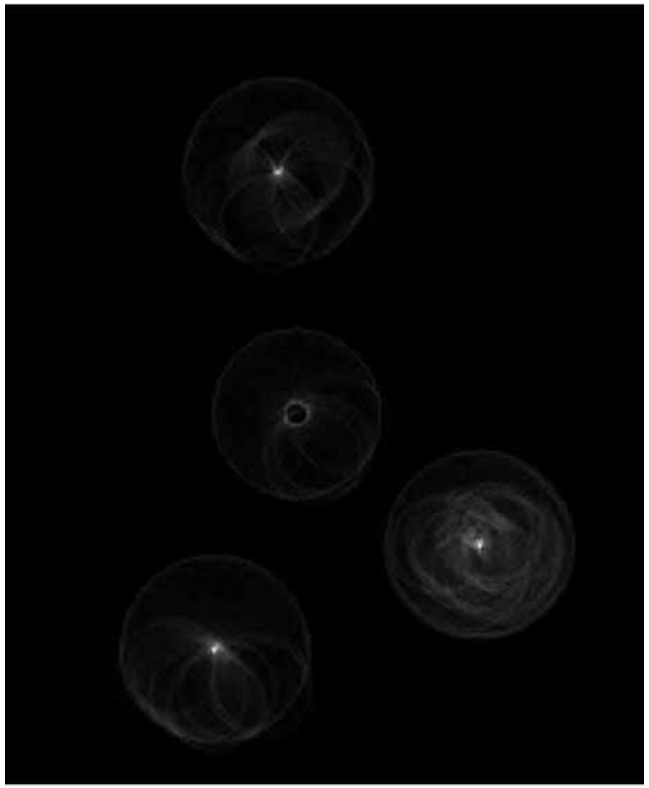

Coin finding sample images from: Vivek Kwatra

Hough transform for circles تحويل هاف للدوائر

Example: iris detection

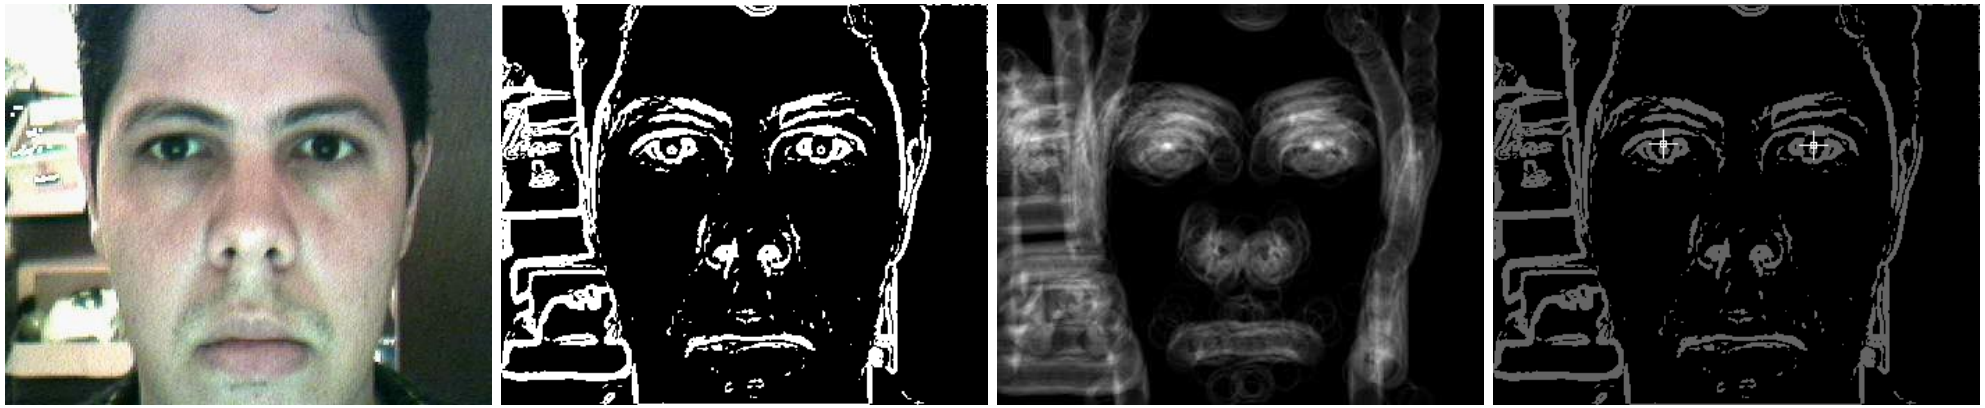

Gradient+threshold

Hough space
(fixed radius)

Max detections

- Hemerson Pistori and Eduardo Rocha Costa http://rsbweb.nih.gov/ij/plugins/hough-circles.html

Hough transform: pros and cons المحاسن والمساوئ

Pros

- All points are processed independently, so can cope with occlusion, gaps
- تعالج كل النقاط بشكل مستقل، لذا يمكن التغلب على مشكلة التغطية
- Some robustness to noise: noise points unlikely to contribute *consistently* to any single bin
- يبدي بعض المقاومة للضجيج
- Can detect multiple instances of a model in a single pass
- يمكن كشف عدة خطوط في مرور واحد للخوارزمية

Cons

- Complexity of search time increases exponentially with the number of model parameters
- التعقيد الزمني يزداد أسياً مع زيادة عدد بارامترات النموذج
- Non-target shapes can produce spurious peaks in parameter space
- تنتج بعض الأشكال غير المهمة قمماً لامعة في فضاء البارامترات
- Quantization: can be tricky to pick a good grid size
- التكميم: يمكن أن يكون هذا التحويل صعباً (مخادعاً) في تحديد حجم الشبكة المناسب (كبير جداً، صغير جداً).

Fitting arbitrary shape with “active” deformable contours
ملاءمة الأشكال العشوائية باستخدام الحدود الفعالة

Deformable contours الحدود الفعالة أو القابلة للتشوه

active contours, snakes

Given: initial contour (model) near desired object لدينا
نموذج أو حد ابتدائي بالقرب من الجسم المرغوب الحصول عليه

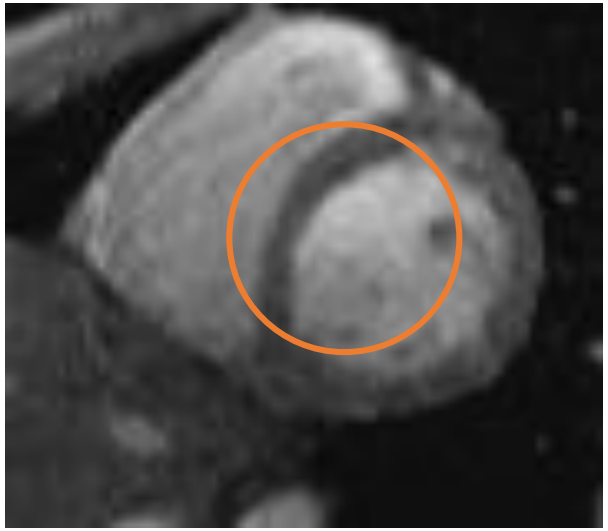

Fitting arbitrary shape with “active” deformable contours
ملاءمة الأشكال العشوائية باستخدام الحدود الفعالة

الحدود الفعالة أو القابلة للتشوه
Deformable contours, active contours, snakes

لدينا نموذج أو حد ابتدائي بالقرب من الجسم المرغوب الحصول عليه

الهدف: تطوير الحد بحيث يناسب أو يلائم حدود الجسم المطلوب تماماً.

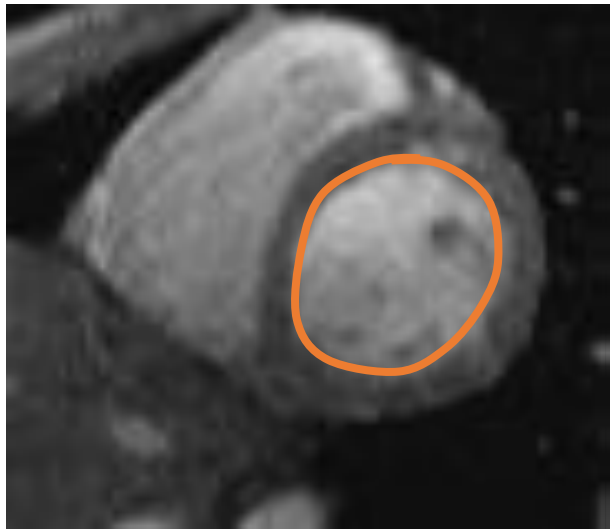

الفكرة الأساسية: يتم تعديل الحزام المرن حول المنطقة بشكل تكراري ليكون:

- قرب مناطق الصورة ذات التدرجات العالية (الحواف)
- ويحقق متطلبات شكل المنطقة المطلوبة أو أساسيات الحد

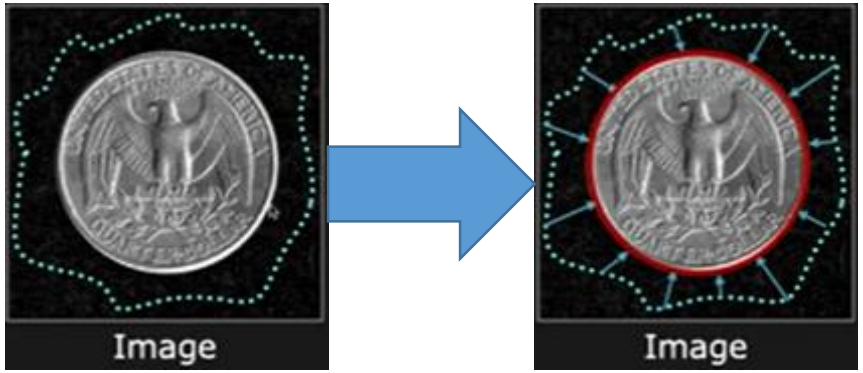

Fitting arbitrary shape with “active” deformable contours
ملاءمة الأشكال العشوائية باستخدام الحدود الفعالة

يتشابه تحويل هاف وملاءمة الحدود Border Fitting بأنهما يستخدمان من أجل ملاءمة الأشكال

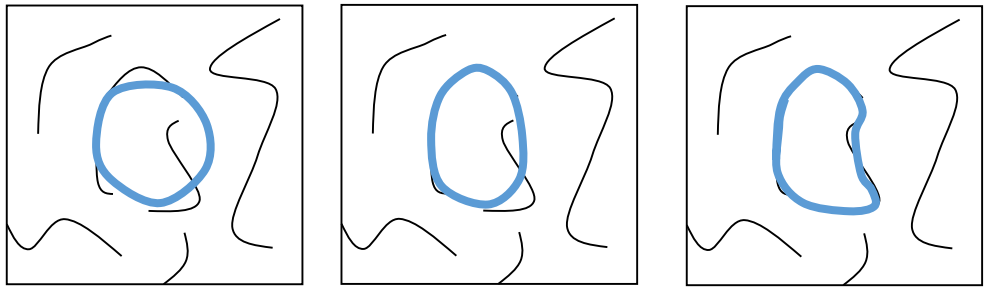

الحدود القابلة للتشوه:

تعتمد على اختيار نقطة البداية وعلى نوع الشكل حيث تتعدل الحدود مع كل تكرار للخوارزمية وفي كل تكرار نحصل على حد مختلف.

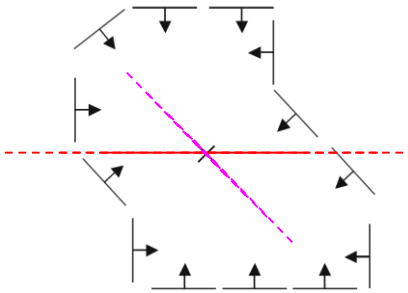

تحويل هاف:

شكل نموذج ثابت (خطوط أفقية – مائلة)

يمكن لتكرار واحد لخوارزمية هاف أن يكشف عدة خطوط

Why to feet the deformable shapes
لماذا نطبق عملية ملاءمة للأشكال القابلة للتشوه

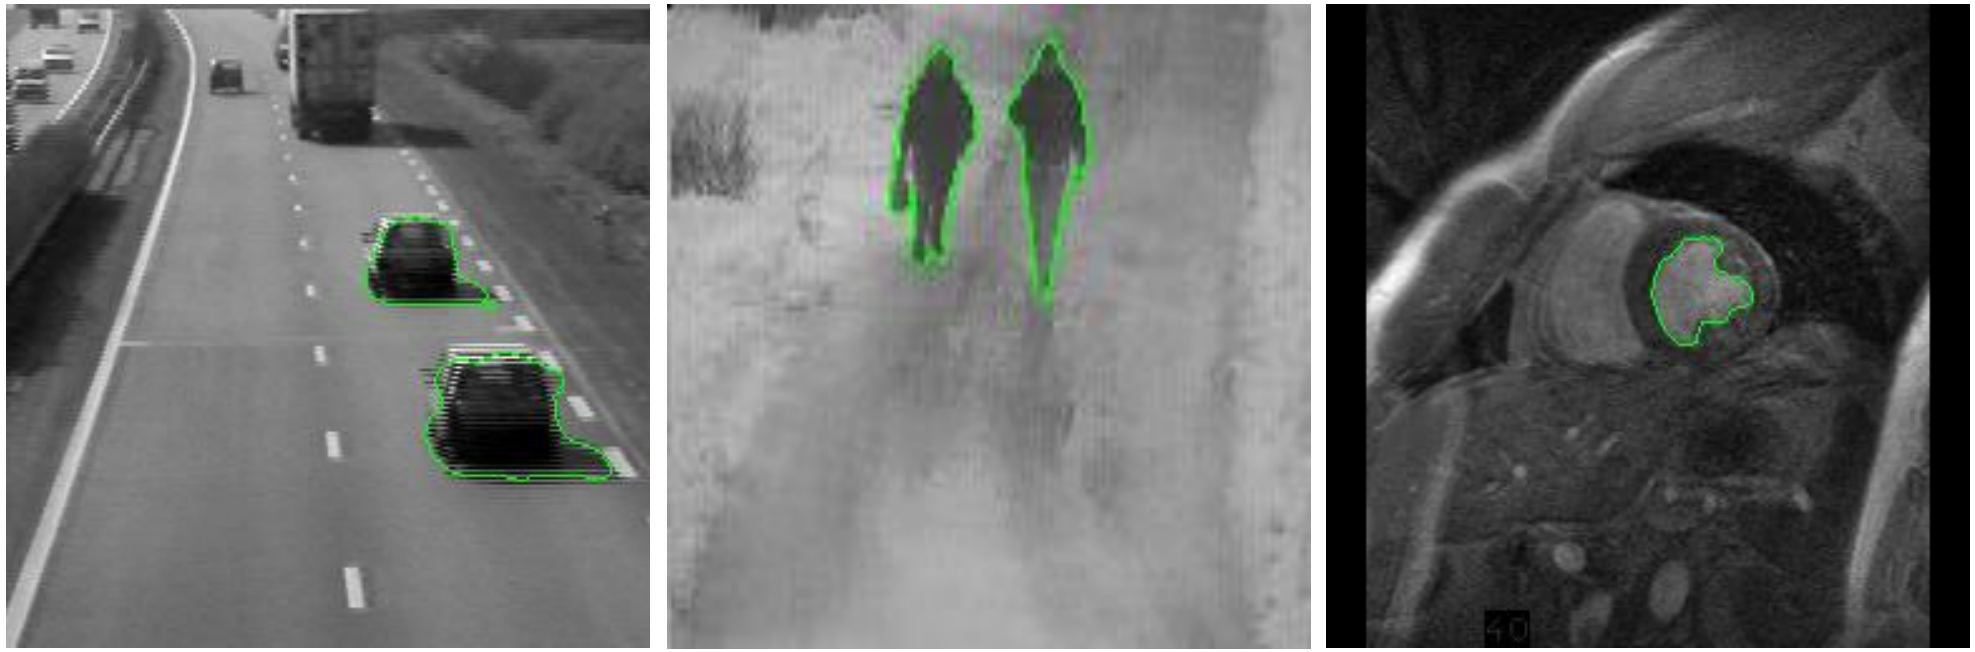

- Non-rigid, deformable objects can change their shape over time.
- يمكن للأشياء الصلبة والقابلة للتشوه تغيير شكلها مع تغير الوقت.

Figure credit: Julien Jomier

Fitting arbitrary shape with “active” deformable contours
ملاءمة الأشكال العشوائية باستخدام الحدود الفعالة

الأشياء التي يجب أخذها في الحسبان:

Representation of the contours تمثيل الحدود

Defining the energy functions تمثيل تابع الطاقة

- External
- Internal

Minimizing the energy function تقليل تابع الطاقة

Extensions:

- Tracking التعقب
- Interactive segmentation التجزيء التفاعلي

Representation التمثيل

- سنعتبر أن لدينا التمثيل التالي للحد وهو مؤلف من سلسلة ثنائية البعد من النقاط (الرؤوس الخضراء)

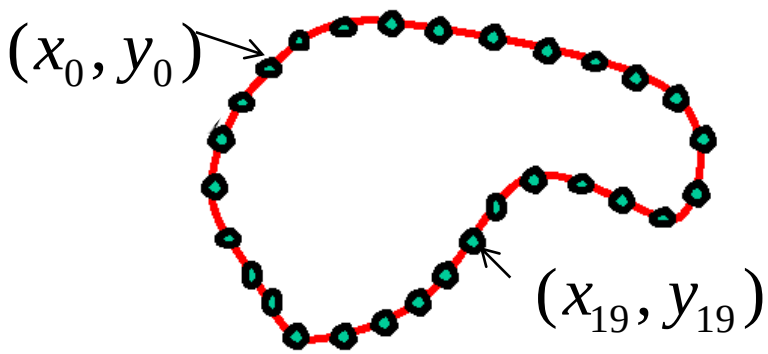

$$v_i = (x_i, y_i),$$

$$\text{for } i = 0, 1, \ldots, n-1$$

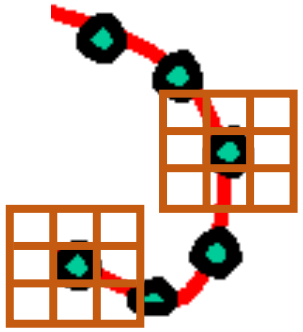

- في كل تكرار، سيكون لدينا خيار لأن نحرك كل نقطة إلى أقرب موقع لها (حالة جديدة).

Representation التمثيل

كيف نعدل الحد الحالي لتشكيل حد جديد في كل تكرار؟

- أولاً نحدد تابع كلفة Energy Function لكل نقطة في الحد، وهو يحدد مدى جودة الحد في تكرار ما.
- ثانياً نبحث عن الحالة التي تحقق أقل قيمة لتابع الكلفة Minimize Cost Function بحيث يكون الحد عندها هو الحد النهائي.
- تستمر تكرارات الخوارزمية حتى يصبح عدد النقاط التي تحركت في الحد أقل من عتبة معينة T.

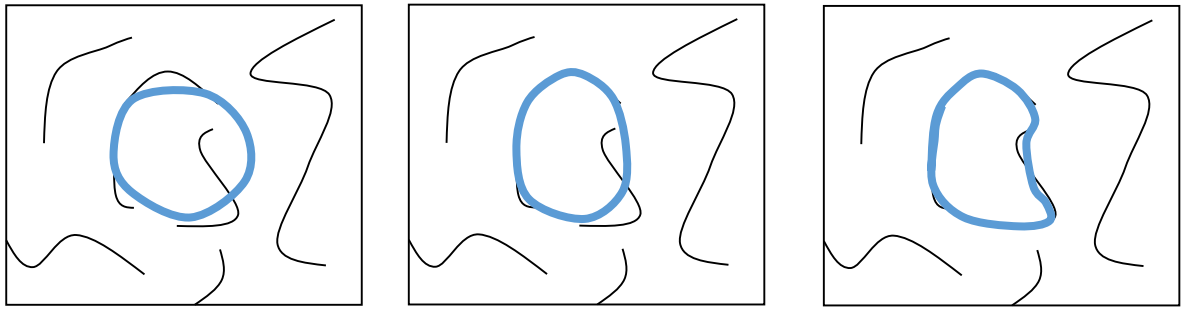

Energy Function تابع الكلفة

يعرف تابع الكلفة لخوارزميات ملاءمة الأشكال snake وفق العلاقة الآتية:

$$E_{total} = E_{internal} + E_{external}$$

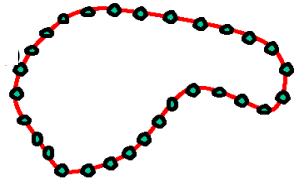

$$\boldsymbol{E_{total} = E_{contour} + E_{image}}$$

الطاقة **الداخلية** **Internal** energy: معلومات الشكل المسبقة مثل النعومة Smoothness، المرونة Elasticity، والشكل المحدد المعروف مسبقاً. أو نسميها $E_{contour}$

الطاقة **الخارجية** **External** energy: أو طاقة الصورة وهي تساعد الحد لكي يتلاءم تماماً مع حواف الأشكال في الصورة. أو نسميها E_{image}

الملاءمة الجيدة بين الحد الحالي والشكل الفعلي النهائي للحد في الصورة مرتبطة مع قيمة منخفضة لتابع الكلفة.

External energy

Energy Function تابع الكلفة

- تقيس مدى مطابقة المنحني مع مكونات الصورة
- "تهتم الطاقة الخارجية لتابع الكلفة بجذب المنحني نحو سمات الصورة المختلفة مثل الحواف والخطوط وتدرج النسيج.

External energy Energy Function تابع الكلفة

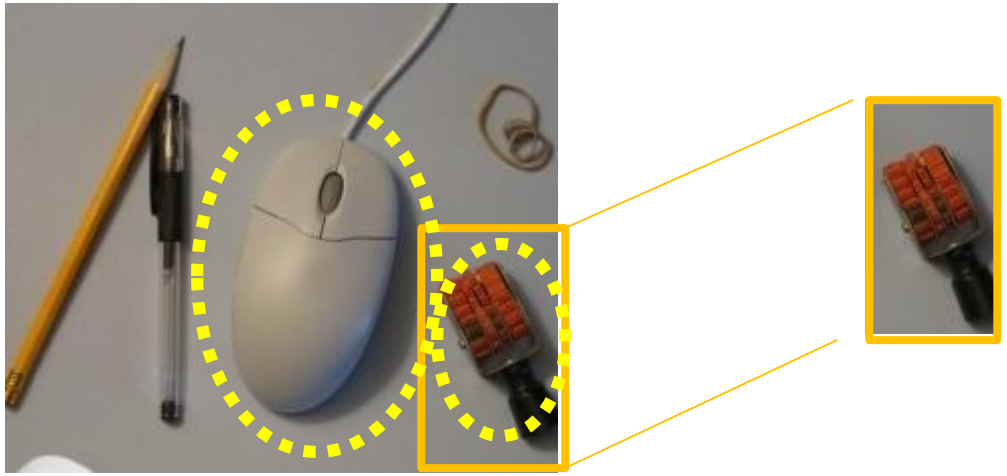

كيف تؤثر الحواف على تغير مكان النقاط من تكرار لتكرار آخر؟

يمكن اعتبار الطاقة **الخارجية** (طاقة الصورة) على أنها طاقة جذب نحو المناطق عالية التباين في الصورة **(الحواف)**

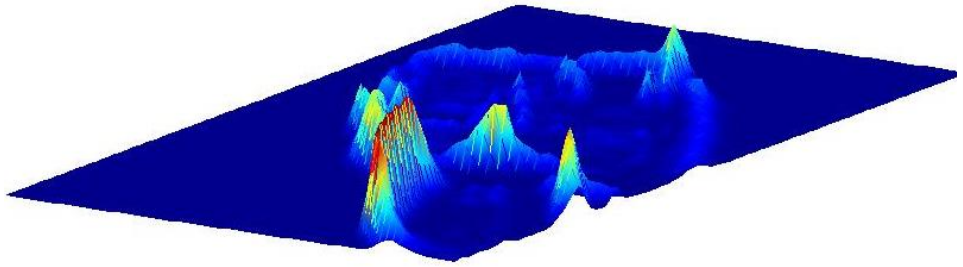

Magnitude of gradient طويلة التدرج

$$G_x(I)^2 + G_y(I)^2$$

Slide credit: Kristen Grauman

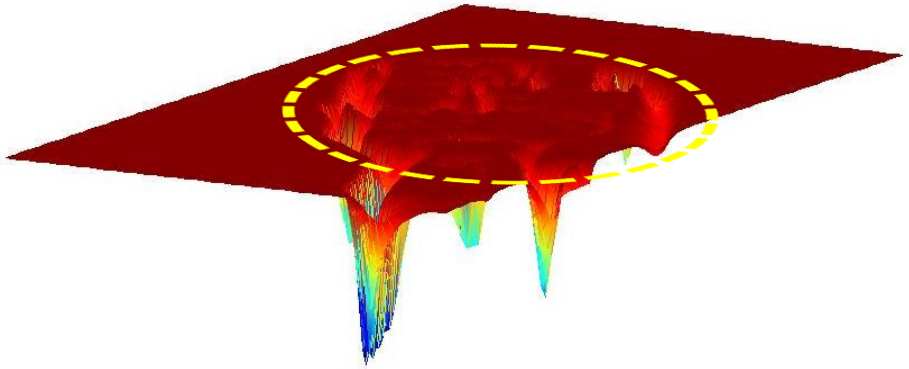

- (Magnitude of gradient)

$$-\left(G_x(I)^2 + G_y(I)^2\right)$$

External energy Energy Function تابع الكلفة

- Gradient images صور التدرج

$G_x(x,y)$ $G_y(x,y)$

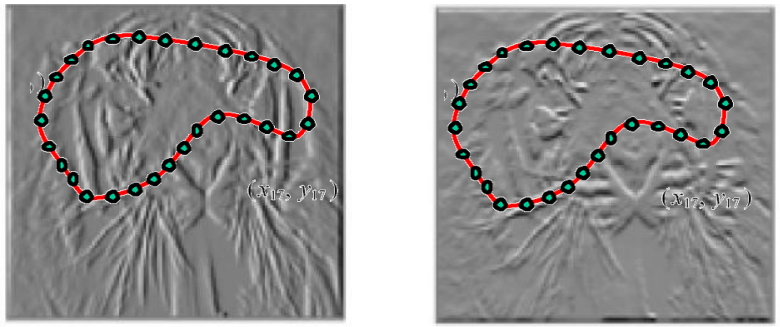

- External energy at a point on the curve is الطاقة الخارجية في نقطة على المنحني تعطى بالعلاقة

$$E_{external}(v) = -(|G_x(v)|^2 + |G_y(v)|^2)$$

سالب طويلة التدرج في نقطة على المنحني

- External energy for the whole curve الطاقة الخارجية لكامل المنحني تعطى بالعلاقة

$$E_{external} = -\sum_{i=0}^{n-1} |G_x(x_i, y_i)|^2 + |G_y(x_i, y_i)|^2$$

سالب مجموع قيم طويلة التدرج في كل إحداثيات نقاط المنحني

Internal energy

Energy Function تابع الكلفة

بدايةً، نريد أشكال ناعمة، حدود ذات انحناءات أقل، حدود مشابهة لأشكال معروفة (دائرة، قطع، الخ...) كل ذلك من أجل تحقيق التوازن بين ما يتم ملاحظته بالفعل (أي في صورة التدرج).

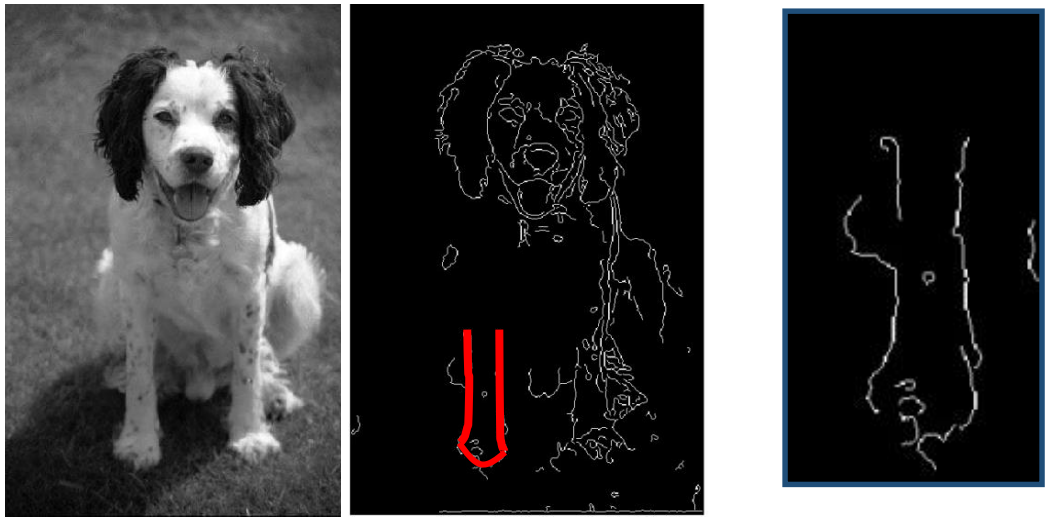

Slide credit: Kristen Grauman

Internal energy

Energy Function تابع الكلفة

في نقطة v(s) على المنحني نعرف الطاقة الداخلية بأنها مجموع طاقتي المرونة Elasticity والانحناء (التقوس) Curvature وتعطى بالعلاقة:

$$E_{internal}(v(s)) = \boxed{\alpha \left| \frac{dv}{ds} \right|^2} + \boxed{\beta \left| \frac{d^2 v}{d^2 s} \right|^2}$$

Tension, Elasticity
توتر، مرونة

Stiffness, Curvature
صلابة، انحناء

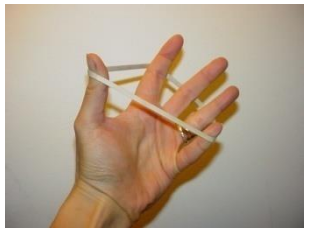

Slide credit: Kristen Grauman

Internal energy Energy Function تابع الكلفة

- For our discrete representation من أجل التمثيل المتقطع

$$v_i = (x_i, y_i) \qquad i = 0 \ldots n-1$$

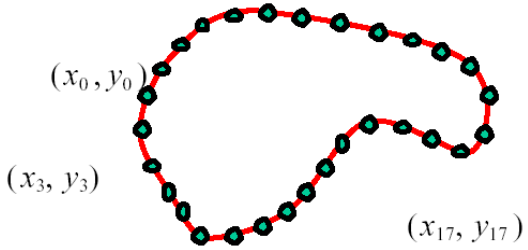

$$\frac{dv}{ds} \approx v_{i+1} - v_i \qquad \frac{d^2v}{ds^2} \approx (v_{i+1} - v_i) - (v_i - v_{i-1}) = v_{i+1} - 2v_i + v_{i-1}$$

- Internal energy for the whole curve:

$$E_{internal} = \sum_{i=0}^{n-1} \alpha \left\| v_{i+1} - v_i \right\|^2 + \beta \left\| v_{i+1} - 2v_i + v_{i-1} \right\|^2$$

Compare Curvature Example

Energy Function تابع الكلفة

$$E_{curvature}(v_i) = \left\| v_{i+1} - 2v_i + v_{i-1} \right\|^2 \qquad = (x_{i+1} - 2x_i + x_{i-1})^2 + (y_{i+1} - 2y_i + y_{i-1})^2$$

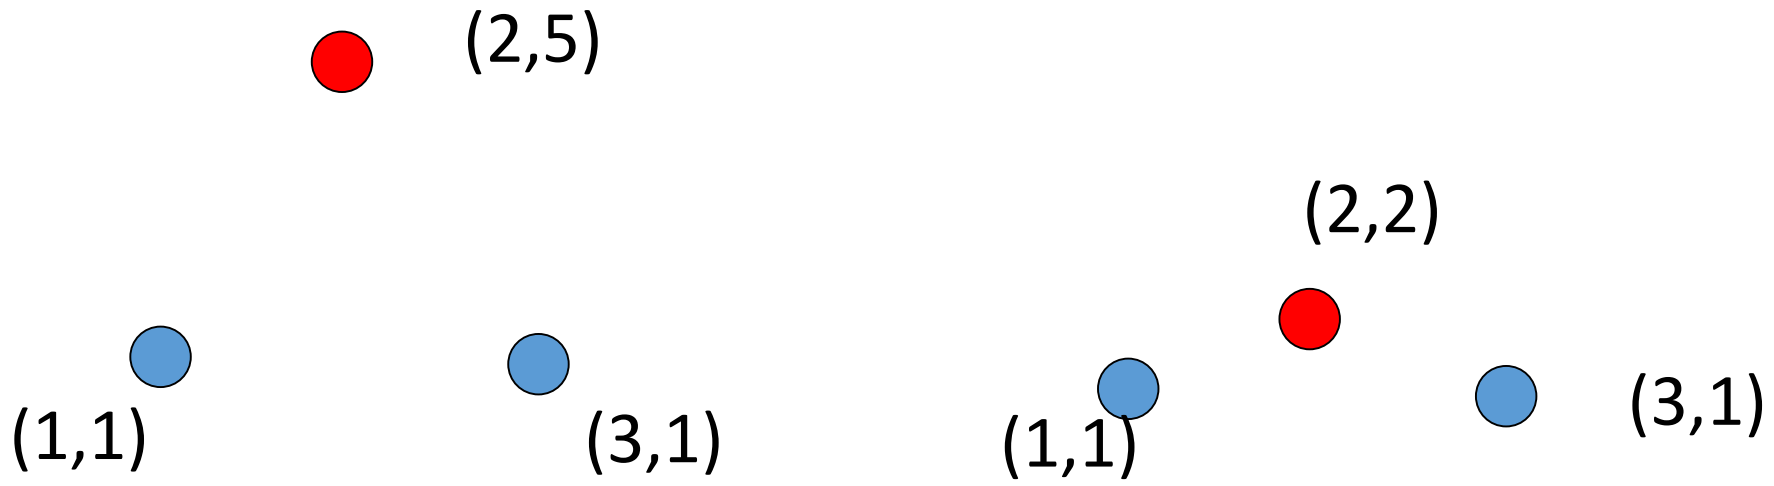

$$(3 - 2(2) + 1)^2 + (1 - 2(5) + 1)^2$$
$$= (-8)^2 = 64$$

$$(3 - 2(2) + 1)^2 + (1 - 2(2) + 1)^2$$
$$= (-2)^2 = 4$$

تزيد قيمة الطاقة الداخلية
(معامل الانحناء أو
الصلابة) مع زيادة
التشوه في شكل المنحني

Slide credit: Kristen Grauman

Total energy

Energy Function تابع الكلفة

Total energy: function of the weights تابع الأوزان

$$E_{total} = E_{internal} + E_{external}$$

$$E_{external} = -\sum_{i=0}^{n-1} |G_x(x_i, y_i)|^2 + |G_y(x_i, y_i)|^2$$

$$E_{internal} = \sum_{i=0}^{n-1} \alpha \left(\|v_{i+1} - v_i\|\right)^2 + \beta \|v_{i+1} - 2v_i + v_{i-1}\|^2$$

المعامل α بتحكم في غرامة التمدد أو المرونة والمعامل β يتحكم في غرامة التقوس (الانحناء)

Total energy

Energy Function تابع الكلفة

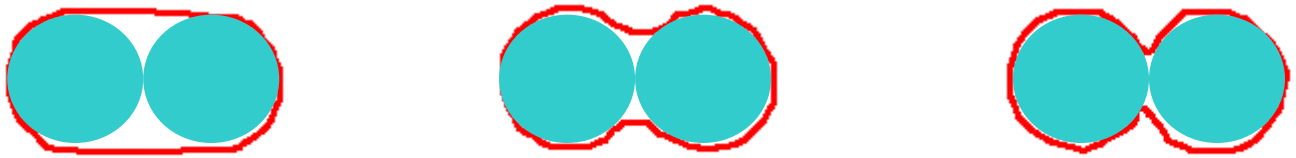

large α medium α small α

- تأثير تغيير قيمة α

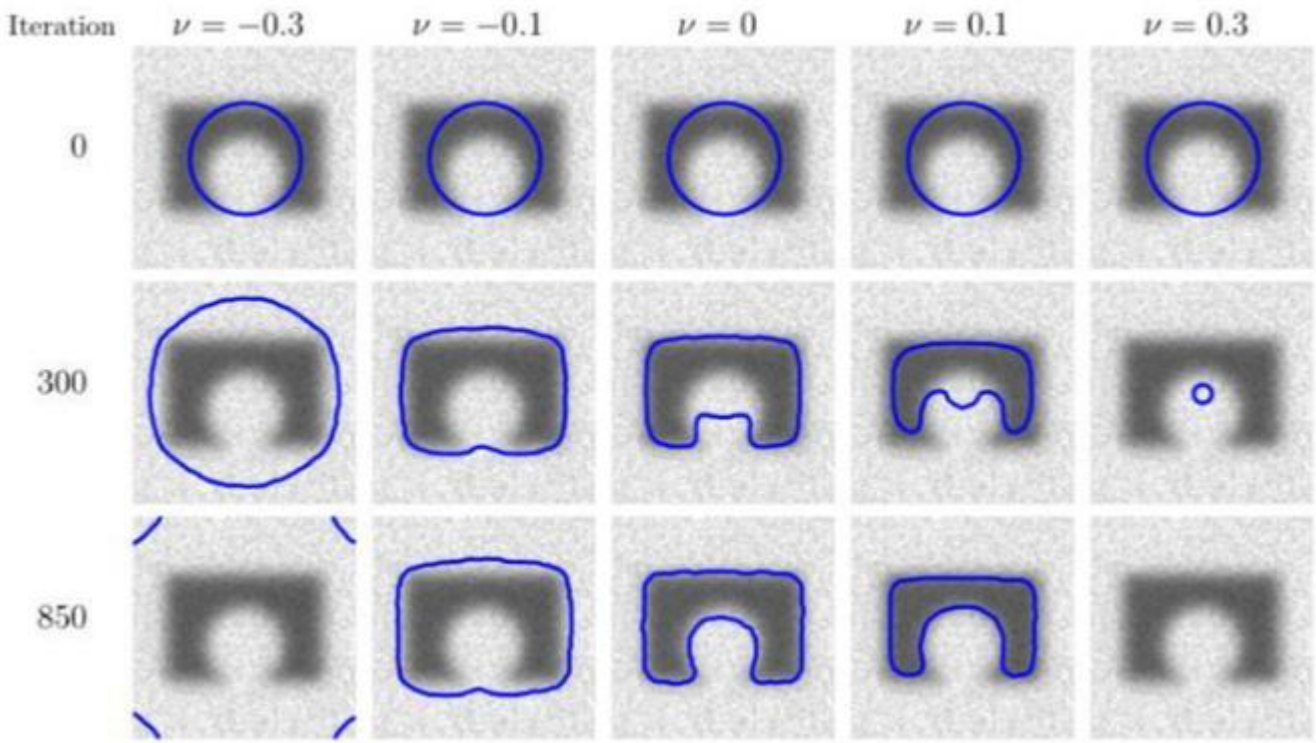

- تأثير تغيير قيمة β

Fig from Y. Boykov

Total energy

Energy Function تابع الكلفة

بدون استخدام الطاقة الخارجية

مع استخدام الطاقة الخارجية

Fig from Y. Boykov

الخلاصة

تابع الكلفة Energy Function

- يعرف المنحني المتحرك البسيط Elastic Snake بأنه مجموعة من النقاط n وطاقة داخلية (توتر، انحناء، الشكل المسبق) وطاقة خارجية (التدرجات أو الحواف).

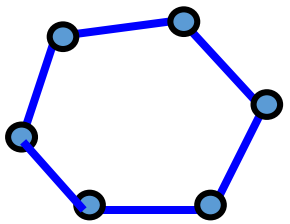

- يمكن استخدام هذه المنحنيات المتحركة في تجزيء الصور من خلال:
  - البدء بمنحني ابتدائي قريب من الكائن المطلوب الحصول عليه.
  - تعديل نقاط المنحني حتى نحصل على أقل قيمة لتابع الطاقة.

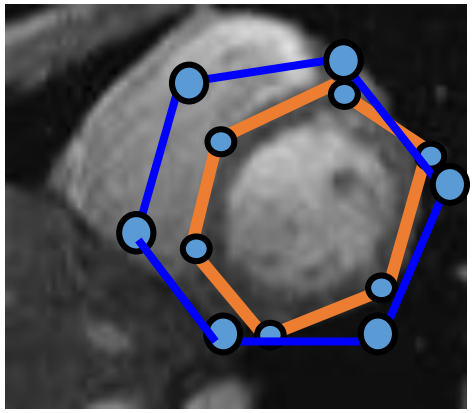

Tracking via deformable contours

Visual Dynamics Group, Dept. Engineering Science, University of Oxford.

Applications: Traffic monitoring
Human-computer interaction
Animation
Surveillance
Computer assisted diagnosis in medical imaging

Limitations

- May over-smooth the boundary أحياناً تكون نعومة المنحني الناتج أكبر من المطلوب

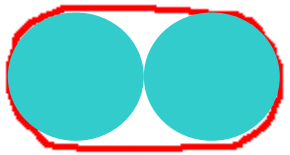

- Cannot follow topological changes of objects لا يمكن اتباع التغيرات الطوبولوجية للكائن

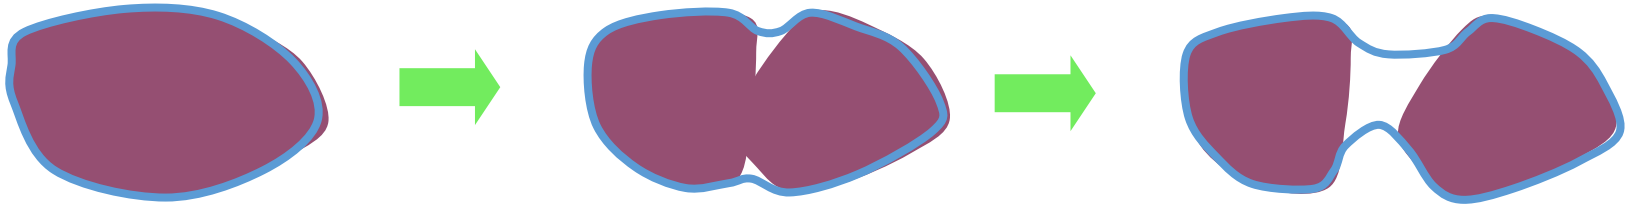

Deformable contours: pros and cons

Pros:

- Useful to track and fit non-rigid shapes نافعة لتعقب الأشكال غير الصلبة
- Contour remains connected تحافظ على اتصالية الحدود

Cons:

- Must have decent initialization near true boundary, may get stuck in local minimum
- يجب أن تكون عملية وضع الحد الابتدائي بالقرب من الحد الفعلي للشكل المراد تعقبه
- Parameters of energy function must be set well based on prior information
- بارامترات تابع الكلفة (الطاقة) يجب أن تعتمد بشكل جيد على المعلومات السابقة

Slide credit: Kristen Grauman

YOLO

Deep Learning Detection Models

يعتبر أحد أشهر نماذج DL لكشف الأجسام وهو اختصار لعبارة You Only Look Once والمقصود أنك تنظر مرة واحدة فقط للمشهد مما يعني سرعة أداء هذا النموذج الذي يعتمد على الطبقات الالتفافية Convolutional Layers.

تعتمد هذه النماذج على مرحلة معالجة واحدة فقط تسمى single-shot detectors

تم إصدار عدة نسخ من هذا النموذج وصدرت النسخة الأخيرة YOLOV8 في العام 2023 وهي الأفضل من حيث الأداء.

تتضمن بنية YOLO ثلاثة أجزاء:

Backbone وهي البنية الأساسية للشبكة (قسم استخلاص السمات)

Neck الجزء الداخلي الواصل بين جزئي Backbone وHead **وهو مسؤول عن إنجاز عملية prediction وحساب إحداثيات المربعات المحيطة بالأجسام في الصورة.**

Head الجزء الأمامي وهو يمثل **الخرج النهائي للنموذج (الصورة متضمنة المربعات المحيطة بالأجسام مع نسبة الثقة confidence)**

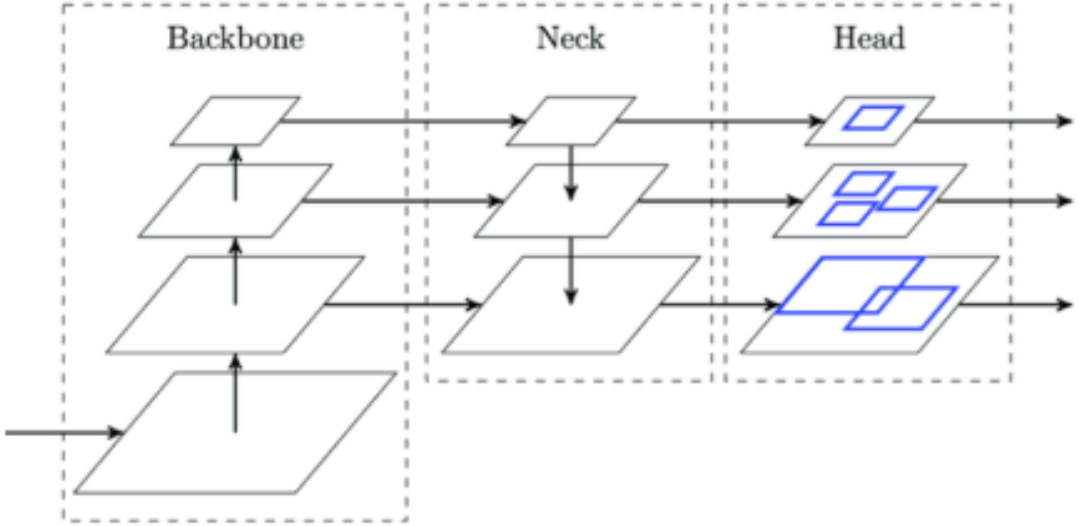

YOLO

Deep Learning Detection Models

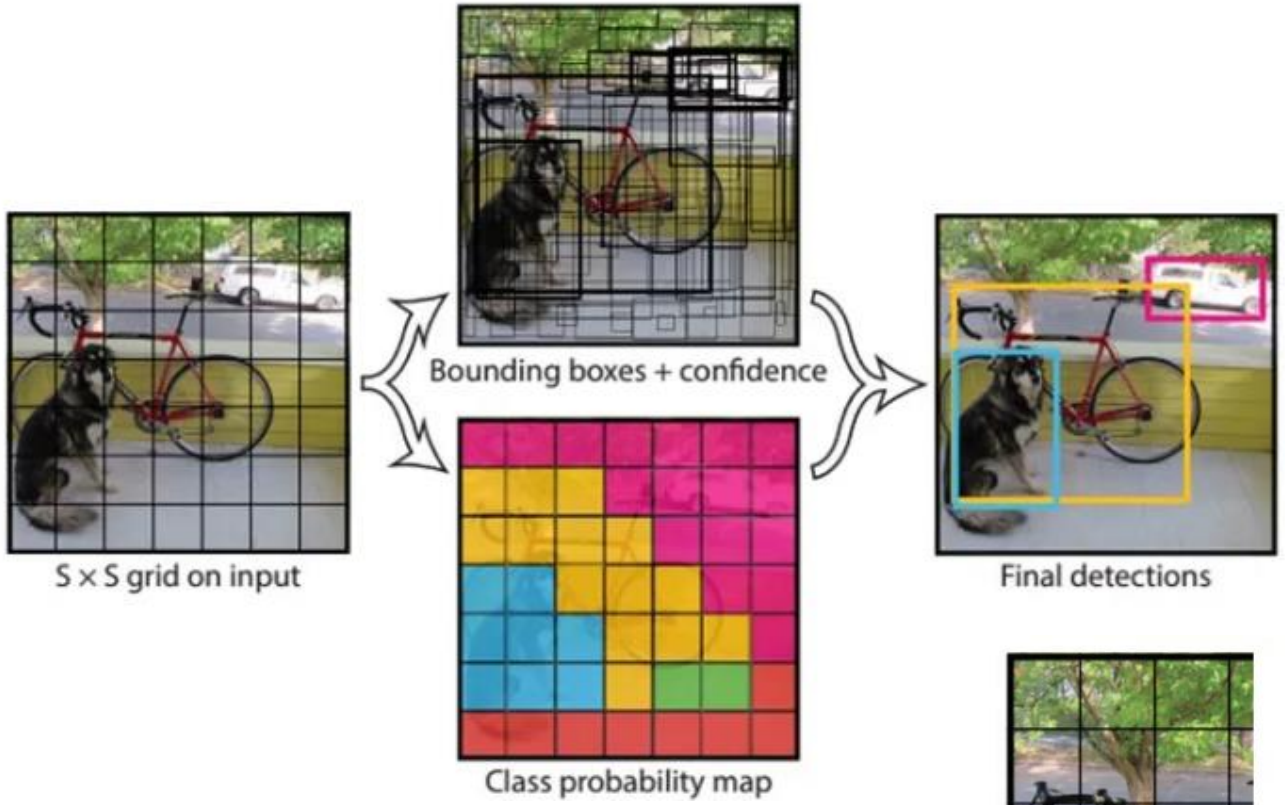

يتم تقسيم الصورة إلى خلايا Cells (صور فرعية) بحجم SxS
يتم دراسة كل خلية على حدة بحيث يتم اختيار الخلية التي تتضمن مركز أحد الأصناف في Ground truth مثلاً في الصورة المجاورة يتم البحث عن الخلية التي تتضمن مركز صورة المكون المطلوب (مثلا Dog)
وتكون مسؤولة عن البحث عن جميع المربعات التي يمكنها إحاطة صورة المكون (dog) وتسمى هذه المربعات Bounding Boxes حيث يتم حساب التقاطع في المساحة بينها وبين Actual Bounding Box الممثل لصورة المكون (dog) ويتم اختيار المربع Bounding Box ذو Confidence الأعلى.
تزيد Confidence إذا كانت نسبة Intersection of Union IoU أعلى بين المربع الحقيقي والمربع المدروس.
تكرر العملية على كل الأصناف.

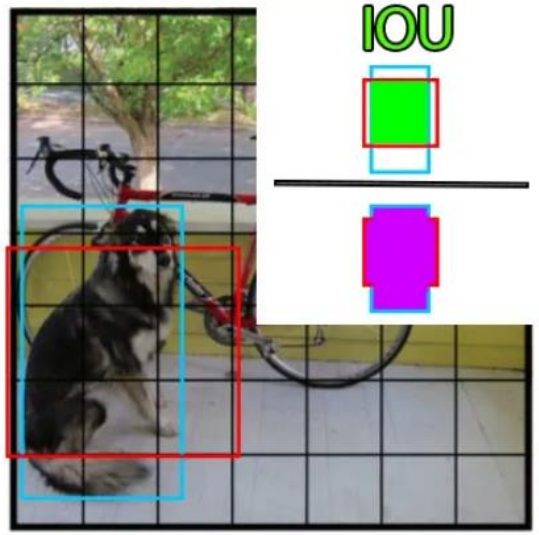

S × S grid on input