

Digital Image Processing

المحاضرة التاسعة


Image Enhancement

Spatial Domain Methods

العمليات على مستوى القناع أو جيران البكسل
باستخدام المرشحات المكانية

د. عيسى الغنام د. إياد حاتم
2023 الفصل الصيفي

□ الحدود الفاصلة بين منطقتين تتميزان بخواص مختلفة في الصورة



□ مرشح القيمة المتوسطة "هو تابع التكامل في حالته المتقطعة" يؤدي إلى تنعيم الصورة وبالأتي فقدان بعض التفاصيل

□ لإظهار وتوضيح التفاصيل يتم اللجوء إلى المرشحات التفاضلية

□ يستخدم هذا النوع من المرشحات كخطوة أولى قبل عملية التعرف على الحواف

✓ مرشح ناغامود Nagamod filter

✓ المرشح الثنائي

✓ ترشيح الصورة الموجه

✓ الانتشار متباين الخواص

مرشحات التنعيم مع الحفاظ على الحواف مرشح ناغامود

□ يطبق وفق الخطوات:

✓ يعرف قناع المرشح $H(m,n)$ لجيران

البكسل المركزي بحيث لا يقلّ حجم هذا

المرشح عن 5×5



✓ تحسب القيمة المتوسطة والتباين من

أجل كلّ بكسل

✓ تكون القيمة الجديدة للبكسل

المركزي هي القيمة المتوسطة للبكسل


الذي يكون التباين عنده أقل




الصورة بعد تطبيق مرشح ناغامود



صورة تحتوي على تشويش غاوص




الصورة بعد تطبيق مرشح ناغامود




صورة تحتوي على تشويش الملح والفلفل

```
a=imread('nsp saturn.jpg');
figure, imshow(a)
[r c]=size(a);
af=zeros(size(a));
for i=3:r-3
for j=3:c-3
b=a(i-2:i+2,j-2:j+2);
b1=colfilt(b,[3 3],'sliding',@mean);
b2=colfilt(b,[3 3],'sliding',@var);
d=b1(find(b2==min(min(b2)))));
af(i,j)=d;
end
end
```




الصورة بعد تطبيق مرشح ناغامود



الصورة بعد تطبيق مرشح ناغامود



صورة تحتوي على تشويش غاوص



صورة تحتوي على تشويش الملح والفلفل


B = colfilt(A, [m n], block type, fun)

processes the image A by rearranging each m-by-n block of A into a column of a temporary matrix, and then applying the function fun to this matrix.


الكشف عن الحواف

- أثبتت الدراسات أن نظام الرؤية عند الإنسان (HVS(Human Visual System) يحتوي في مراحله البدائية على خلايا حسّاسة للحواف تتحفز عند وجود تغيّر في الشدّة الضوئية "الحواف" ويتمّ استغلال هذه الخاصية في التعرف على الكائنات وتحديد بعدها واتجاهها
- ظهرت مجموعة من الخوارزميات التي تحاول محاكاة القدرة على كشف الحواف الموجودة في نظام الرؤية عند الإنسان
- الكشف عن الحواف من عمليات معالجة الصورة صعبة الإنجاز في الصور التي تحتوي على مشاهد حقيقية
- من الشائع جداً أن تسبق عملية كشف الحواف مجموعة من العمليات التمهيدية التي تقوم بتحضير الصورة

الكشف عن الحواف بالاعتماد على التدرج



(a)



(c)

$$f'(x) = \frac{df}{dx}(x)$$

• لتابع احادي البعد

$$\frac{df}{du}(u) \approx \frac{f(u+1) - f(u-1)}{(u+1) - (u-1)} = \frac{f(u+1) - f(u-1)}{2}$$

• لتابع ثنائي البعد يحسب التدرج وطويلة التدرج



$$\nabla I(u, v) = \begin{bmatrix} \frac{\partial I}{\partial u}(u, v) \\ \frac{\partial I}{\partial v}(u, v) \end{bmatrix}$$

$$|\nabla I|(u, v) = \sqrt{\left(\frac{\partial I}{\partial u}(u, v)\right)^2 + \left(\frac{\partial I}{\partial v}(u, v)\right)^2}$$

First Order Derivative



Intensity profile

$p(x)$





1st derivative

$\frac{dp}{dx}$



$\left| \frac{dp}{dx} \right|$



يعدّ حساب التدرج المحلي لتابع الصورة هو الأساس في معظم مرشحات كشف الحواف.

- مرشح روبرتس Roberts Filter
- مرشح برويت Prewitt Filters
- مرشح سوبل Sobel Filters
- مرشح روبنسون
- مرشح الاتجاه

□ يعمل هذا المرشح على القيام بعملية تنعيم قبل حساب التدرج

$$H_x^p = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} * [-1 \ 0 \ 1] \quad H_y^p = [1 \ 1 \ 1] * \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix}$$

□ يستخدم مرشح برويت القناع:

$$H_x^p = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad H_y^p = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$$

□ قيمة التدرج:

$$\nabla I(u, v) \approx \frac{1}{6} \begin{bmatrix} (I * H_x^p)(u, v) \\ (I * H_y^p)(u, v) \end{bmatrix}$$

مرشحات الكشف عن الحواف

مرشح سوبل Sobel Filter

Sobel operators – combine smoothing with derivative

□ يعمل أيضا هذا المرشح على القيام بعملية تنعيم قبل حساب التدرج

□ تكاد أقنعتة تطابق مرشح برويت إلا أن سوبل يعطي وزناً أكبر للخط أو العمود المركزي في قسم التنعيم

$$H_x^S = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

dx filter

to compute $\frac{\partial P}{\partial x}$

$$H_y^S = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

dy filter

to compute $\frac{\partial P}{\partial y}$

□ قيمة التدرج

$$\nabla I(u, v) \approx \frac{1}{8} \begin{bmatrix} (I * H_x^S)(u, v) \\ (I * H_y^S)(u, v) \end{bmatrix}$$

مرشحات الكشف عن الحواف

مرشح سوبل Sobel Filters

$f(x, y)$

0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	1	1	1	1	0	0
0	0	1	1	1	1	0	0
0	0	1	1	1	1	0	0
0	0	1	1	1	1	0	0
0	0	1	1	1	1	0	0

$g(x, y) = w(x, y) \otimes f(x, y)$

$$H_x^s = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

dx filter

$g(x, y) = w(x, y) \otimes f(x, y)$

0	0	0					
0	0	0	0	0	0	0	0
0	1	1	0	0	-1	-1	0
0	3	3	0	0	-3	-3	0
0	4	4	0	0	-4	-4	0
0	4	4	0	0	-4	-4	0
0	4	4	0	0	-4	-4	0
0	4	4	:				

□ بفرض نتائج تطبيق المرشحات (سواء سوبل أو بروت) بعد تنسيقها:

$$D_x = H_x * I$$


$$D_y = H_y * I$$

□ تعطى طويلة التدرج (قوة الحافة المحلية) بالعلاقة:


$$E(u, v) = \sqrt{(D_x(u, v))^2 + (D_y(u, v))^2}$$

□ تعطى زاوية التدرج (منحى الحافة المحلية) بالعلاقة:


$$\Phi(u, v) = \tan^{-1}\left(\frac{D_y(u, v)}{D_x(u, v)}\right) = \text{Arctan}\left(D_y(u, v), D_x(u, v)\right)$$



تطبيق مرشح سوبل الشاقولي




تطبيق مرشح سوبل الأفقي



الصورة الأصلية



منحى الحواف «زاوية التدرج»




قوة الحواف «طويلة التدرج»

-1	0	1
-2	0	2
-1	0	1


to compute $\frac{\partial P}{\partial x}$

-1	-2	-1
0	0	0
1	2	1


to compute $\frac{\partial P}{\partial y}$



P



$\frac{\partial P}{\partial x}$




$\frac{\partial P}{\partial y}$

مرشح سوبل Sobel Filter


First Order Partial Derivative

Image Gradient


P




$\frac{\partial P}{\partial y}$



$\frac{\partial P}{\partial x}$





$|\nabla P|$



Gradient magnitude

$$|\nabla P| = \sqrt{\left(\frac{\partial P}{\partial x}\right)^2 + \left(\frac{\partial P}{\partial y}\right)^2}$$



a b

FIGURE 3.45

Optical image of contact lens (note defects on the boundary at 4 and 5 o'clock).

(b) Sobel gradient.
(Original image courtesy of Mr. Pete Sites, Perceptics Corporation.)


A gradient image emphasizes edges

لا يمكن لمرشحات الكشف عن الحواف البسيطة - التي تمت مناقشتها سابقاً - إظهار كل الحواف التي تعدّ مهمة للعين الناضرة وذلك لأسباب عدّة هي:

❑ تعتمد مرشحات كشف الحواف السابقة فقط على الاختلاف في الشدّة الضوئية " قوة الحافة " في حين يستطيع نظام الرؤية لدى الإنسان كشف الحواف التي يكون اختلاف الشدة الضوئية فيها صغيراً جداً أو حتى معدوم

❑ تعدّ مرشحات كشف الحواف هذه شديدة الحساسية للتشويش؛ إذ يؤدي وجود تشويش في الصورة إلى استجابة المرشح لهذا التشويش مع عدم وجود حافة أصلاً

❑ إن أغلب الحواف هي مستمرة في الحقيقة وليست متقطعة؛ إذ إنها عادة ما تكون إنسيابية وتتغيّر على نحو تدريجي تصاعداً أو تنازلاً ضمن مساحات محلية صغيرة. في حين أن أقنعة المرشحات السابقة غالباً ما تكون صغيرة الحجم 3×3 وهذا يجعل من الصعوبة بمكان / اكتشاف الحافة ضمن هذه الظروف. ولاكتشاف الحواف في هذه الحالة يتمّ اللجوء إلى مرشحات ذات حجم قناع أكبر. أو استخدام حجم القناع السابق نفسه بعد تصغير حجم الصورة، وتعدّ هذه هي الفكرة الأساس لما يسمى بالتقنيات متعددة الدقة (وتدعى أيضاً بالتقنيات الهرمية) والتي جرت العادة على استخدامها في العديد من تطبيقات معالجة الصورة.



- يقوم المشتق الثاني لتابع ما في العادة بقياس انحنائه المحلي
- عبور المشتق الثاني بالصفر يدلّ على أقصى تدرج محلي "الحافة"
- يميل هذا النوع من المرشحات غالباً إلى تضخيم التشويش في الصورة

$$\frac{\partial^2 f(x, y)}{\partial x^2} = \frac{\partial}{\partial x} \left(\frac{\partial f(x, y)}{\partial x} \right) = f(x+1, y) - 2f(x, y) + f(x-1, y)$$

As a filter

+1	-2	+1
----	----	----

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}$$

– As a filter

0	+1	0
+1	-4	+1
0	+1	0


=

0	0	0
+1	-2	+1
0	0	0


+

0	+1	0
0	-2	0
0	+1	0


– the Laplacian



كشف نقاط العبور بالصففر في المشتق الثاني.



الصورة الاصلية



□ من أجل تابع أحادي البعد يتم زيادة وضوح الحواف عن طريق طرح المشتق الثاني للتابع $f''(x)$ بعد تثقيله بوزن ما w من التابع الأصلي $f(x)$


$$f_n(x) = f(x) - w f''(x)$$

Laplacian Sharpening : How it works





Intensity profile

$p(x)$





1st derivative

$\frac{dp}{dx}$




2nd derivative

$\frac{d^2 p}{dx^2}$




Laplacian Sharpening : How it works

$p(x)$




$p(x) - 10 \frac{d^2 p}{dx^2}$




Laplacian sharpening results in larger intensity discontinuity near the edge.

Laplacian Sharpening : How it works



Before sharpening $p(x)$



After sharpening $p(x) - 10 \frac{d^2 p}{dx^2}$

Laplacian Masks



من أجل التوابع ثنائية البعد يتم زيادة وضوح الحواف عن طريق تطبيق المشتق الثاني في الاتجاهين الأفقي والشاقولي (جمعهما في مرشح لابلاس) ومن ثم طرح الناتج بعد تثقيله من الصورة الأصلية

أشكالاً أخرى شائعة لقناع مرشح لابلاس

$$\nabla^2 P = \frac{\partial^2 P}{\partial x^2} + \frac{\partial^2 P}{\partial y^2}$$

مرشح لابلاس ∇^2 لتابع ثنائي البعد $f(x,y)$

$$(\nabla^2 f)(x,y) = \frac{\partial^2 f}{\partial x^2}(x,y) + \frac{\partial^2 f}{\partial y^2}(x,y)$$

$$H^L = H_x^L + H_y^L = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

مرشح لابلاس لحساب المشتق الثاني للصورة


-1	-1	-1
-1	8	-1
-1	-1	-1

0	-1	0
-1	4	-1
0	-1	0


or

1	1	1
1	-8	1
1	1	1

0	1	0
1	-4	1
0	1	0



The center of the mask is positive




The center of the mask is negative

$H_8^L =$

Application: Enhance edge, line, point
Disadvantage: Enhance noise

$$H_{12}^L = \begin{bmatrix} 1 & 2 & 1 \\ 2 & -12 & 2 \\ 1 & 2 & 1 \end{bmatrix}$$


تطبيق مرشح لابلاس مثال




المشتق الثاني الجزئي الأفقي



الصورة الأصلية




مرشح لابلاس $\nabla^2 I$



المشتق الثاني الجزئي الشاقولي

Laplacian Sharpening Example



Laplacian Sharpening

Mask for
 $\nabla^2 P$

1	1	1
1	-8	1
1	1	1

or

0	1	0
1	-4	1
0	1	0

Mask for
 $P - \nabla^2 P$




0	-1	0
-1	5	-1
0	-1	0

or

-1	-1	-1
-1	9	-1
-1	-1	-1

0	-1	0
-1	5	-1
0	-1	0


-1	-1	-1
-1	9	-1
-1	-1	-1




a b c
 d e

FIGURE 3.41 (a) Composite Laplacian mask. (b) A second composite mask. (c) Scanning electron microscope image. (d) and (e) Results of filtering with the masks in (a) and (b), respectively. Note how much sharper (e) is than (d). (Original image courtesy of Mr. Michael Shaffer, Department of Geological Sciences, University of Oregon, Eugene.)


زيادة وضوح حواف الصورة اعتماداً على مرشح لابلاس مثال



زيادة وضوح الحواف.



تطبيق مرشح لابلاس



الصورة الأصلية

□ تطبيق زيادة وضوح الحواف على الصورة ($w=1$)

□ طريقة كاني لازالت تعدّ أفضل خوارزمية لكشف الحواف من جميع النواحي فهي تقدم:

Canny is Optimal because:

- Less sensitive to noise
- It removes streaking by using two thresholds t_{high} t_{low}
- Offers good localization of edges and utilizes gradient of the edge to generate thin, one-pixel wide edges

✓ معدل خطأ منخفض

✓ التوضع الصحيح للحواف


✓ الاستجابة الوحيدة للحادّة

□ يعتمد كاشف الحواف كاني على سلسلة من العمليات الرياضية وعلى تنعيم الصورة باستخدام مرشح غاوص σ

□ يستخدم كاشف الحواف كاني عتبتين مختلفتين قيمة إحداهما $T2$ أكبر من الأخرى $T1$

The Canny Edge Detector

The process



The Canny edge detection algorithm is composed of 5 steps:

- 1.Noise reduction;
- 2.Gradient calculation;
- 3.Non-maximum suppression;
- 4.Double threshold;
- 5.Edge Tracking by Hysteresis.

☐ تنعيم الصورة باستخدام مرشح غاوص

☐ حساب قوة الحافة ومنحائها

☐ الإخماد اللاأعظمي

☐ تعذيب مزدوج

☐ التخلفية لتتبع الحواف

Noise Reduction

get rid of the noise. image convolution technique is applied with a Gaussian Kernel (3x3, 5x5, 7x7 etc...) to smooth it.

Basically, the smallest the kernel, the less visible is the blur.

Gradient Calculation


First order derivative of an image. It can be implemented by convolving I with Sobel kernels K_x and K_y , respectively:

$$K_x = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}, K_y = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix}$$

Sobel filters for both direction (horizontal and vertical)

$$|G| = \sqrt{I_x^2 + I_y^2},$$

$$\theta(x, y) = \arctan\left(\frac{I_y}{I_x}\right)$$



Gradient intensity and Edge direction

The edge direction angle is rounded to one of four angles representing vertical, horizontal, and the two diagonals (0°, 45°, 90°, and 135°).

Non-Maximum Suppression

Double threshold


The double threshold step aims at identifying 3 kinds of pixels: **strong, weak, and non-relevant**:

Strong pixels are pixels that have an intensity so high that we are sure they contribute to the final edge.


Weak pixels are pixels that have an intensity value that is not enough to be considered as strong ones, but yet not small enough to be considered as non-relevant for the edge detection.

Other pixels are considered as non-relevant for the edge.

Edge Tracking by Hysteresis



No strong pixels around




One strong pixel around

Based on the threshold results, the hysteresis consists of transforming weak pixels into strong ones, if and only if at least one of the pixels around the one being processed is a strong one.


Non-Maximum Suppression

perform non-maximum suppression to thin out the edges.


The principle is simple: the algorithm goes through all the points on the gradient intensity matrix and finds the pixels with the maximum value in the edge directions. المبدأ بسيط: تمر الخوارزمية عبر جميع النقاط الموجودة في مصفوفة كثافة التدرج وتجد وحدات البكسل ذات القيمة القصوى في اتجاهات الحافة.



If there are no pixels in the edge direction having more intense values, then the value of the current pixel is kept.




$T1=0.1, T2=0.2, \sigma = 1$



الصورة الاصلية




$T1=0.1, T2=0.2, \sigma = 5$



$T1=0.1, T2=0.2, \sigma = 0.5$



$T1=0.4, T2=0.6, \sigma = 1$



$T1=0.005, T2=0.1, \sigma = 1$

مرشح الحواف كاني مثال

نهاية المحاضرة