

情報デザイン専攻

画像情報処理論及び演習II

- フィルタ処理・エッジ強調 -

差分法・変分法と平滑化・エッジ

第6回講義

水曜日 1限

教室6218

吉澤 信
shin@riken.jp, 非常勤講師

大妻女子大学 社会情報学部

独立行政法人
理化学研究所

Shin Yoshizawa: shin@riken.jp

今日の授業内容

www.riken.jp/brict/Yoshizawa/Lectures/index.html
www.riken.jp/brict/Yoshizawa/Lectures/Lec17.pdf

1. 勾配とエッジの基礎: 差分法.
2. Laplacianと拡散方程式の基礎: 変分法.
3. 演習: エッジ強度抽出と拡散方程式.




今日の演習は第2回のレポートで出すので、
みなさん頑張ってくださいねーp(^^)q

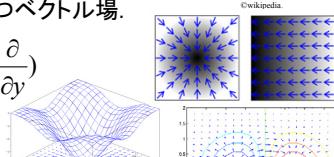
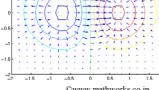
Shin Yoshizawa: shin@riken.jp

復習: 勾配(Gradient)

- ✓ 勾配(Gradient): スカラー場の各点で変化が最大の方向と変化率を大きさに持つベクトル場.
- ✓ 勾配作用素: $\nabla = \left(\frac{\partial}{\partial x}, \frac{\partial}{\partial y} \right)$
- ✓ 勾配ベクトルの表記:

$$\nabla I = \nabla I(x, y) = \left(\frac{\partial I}{\partial x}, \frac{\partial I}{\partial y} \right) = (I_x, I_y)$$

$$= \left(\frac{\partial I(x, y)}{\partial x}, \frac{\partial I(x, y)}{\partial y} \right) = (I_x, I_y)$$

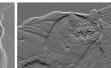

1階微分は接線、傾き.

Shin Yoshizawa: shin@riken.jp

重要: 画像のエッジ

- ✓ 画像の勾配: 画像を高さ関数と考えたときの勾配ベクトル場、画像のエッジ部分で大きい勾配ベクトルをもつ画像.
- ✓ 勾配ベクトルの方向: 画像エッジと垂直な方向.





$I(x, y)$ x 方向微分 I_x y 方向微分 I_y

∇I I_x I_y

勾配ベクトルの大きさ=エッジ強度:
 $\|\nabla I\| = \sqrt{I_x^2 + I_y^2}$

$\theta = \arctan(I_y / I_x)$





入力 $I(x, y)$ エッジ強度画像 $\|\nabla I(x, y)\|$

Shin Yoshizawa: shin@riken.jp

復習: Laplacian, Laplace-Poisson方程式

- ✓ ラプラス作用素(Laplacian): 滑らかさを記述.

$$\Delta = \nabla^2 = \nabla \cdot \nabla = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2} \quad \Delta I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}$$

- ✓ Laplace方程式: 自然科学の多くの分野で重要. $\Delta I = 0$
- ✓ Poisson方程式: Laplace方程式の右辺が関数. $\Delta I = g$




Target画像
Source画像

$h = h(x, y)$

Poisson方程式を解く!



Shin Yoshizawa: shin@riken.jp

微分(導関数)の近似: 差分法

- ✓ 微分の定義: $\frac{\partial f(x)}{\partial x} = \lim_{\varepsilon \rightarrow 0} \frac{f(x + \varepsilon) - f(x)}{\varepsilon}$
- ✓ テーラー展開:

$$f(b) = f(a) + f'(a)(b-a) + \frac{1}{2!} f''(a)(b-a)^2 + \dots + \frac{1}{(n-1)!} f^{(n-1)}(a)(b-a)^{n-1} + \frac{1}{n!} f^n(c)(b-a)^n = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (b-a)^n, \quad a < c < b.$$

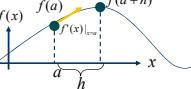
$$f(x+h) \approx f(x) + f'(x)h + \frac{1}{2!} f''(x)h^2 + \dots + \frac{1}{(n-1)!} f^{(n-1)}(x)h^{n-1}$$

$$f(x+h) \approx f(x) + f'(x)h + O(h^2) \Rightarrow f'(x) \approx \frac{f(x+h) - f(x)}{h} + O(h^2)$$

2次以降の項で打ち切ると... 誤差は h の2乗に比例: $O(h^2)$

- ✓ 1階微分の前進1次差分近似、後退1次差分近似:

$$\frac{\partial}{\partial x} f(x) \approx \frac{f(x+\varepsilon) - f(x)}{\varepsilon} \quad \frac{\partial}{\partial x} f(x) \approx \frac{f(x) - f(x-\varepsilon)}{\varepsilon} \quad \varepsilon = h = -\varepsilon$$



Shin Yoshizawa: shin@riken.jp

微分(導関数)の近似: 差分法2

- ✓ 高階微分の近似はより多くの評価点が必要: 例えば2階微分の前進1次差分近似:

1階の前進1次差分近似

$$f''(x) = \frac{d}{dx} f'(x) \approx \frac{d}{dx} \left(\frac{f(x+h) - f(x)}{h} + O(h^2) \right) \approx \frac{f(x+2h) - f(x+h)}{h^2} - \frac{f(x+h) - f(x)}{h^2} + O(h^2)$$

$$f''(x) \approx \frac{f(x+2h) - 2f(x+h) + f(x)}{h^2} + O(h^2)$$

誤差は h の2乗に比例: $O(h^2)$

2階微分はラプラスアン

- ✓ 1次精度の差分近似は n 階の微分を $n+1$ の評価点で近似する。
- ✓ 同様に n 次精度の差分近似は1階の微分を $n+1$ の評価点で近似する(次のスライド)。

Shin Yoshizawa: shin@riken.jp

微分(導関数)の近似: 差分法3

- ✓ 高次の近似もより多くの評価点が必要: 例えば1階微分の前進2次差分近似:

1階の前進1次差分近似

$$f(x+h) \approx f(x) + f'(x)h + \frac{1}{2!} f''(x)h^2 + O(h^3) \Rightarrow f'(x) \approx \frac{f(x+h) - f(x)}{h} - \frac{1}{2!} f''(x)h + O(h^3)$$

代入

2階の前進1次差分近似

$$f''(x) = \frac{d}{dx} f'(x) \approx \frac{d}{dx} \left(\frac{f(x+h) - f(x)}{h} + O(h^2) \right) \approx \frac{f(x+2h) - f(x+h)}{h^2} - \frac{f(x+h) - f(x)}{h^2} + O(h^2)$$

2階の前進1次差分近似

$$f'(x) \approx \frac{f(x+h) - f(x)}{h} - \frac{1}{2!} \left(\frac{f(x+2h) - 2f(x+h) + f(x)}{h} \right) + \frac{1}{2!} O(h^2)h + O(h^3)$$

注目! h の2乗の誤差が h の3乗の誤差になる!

$$f'(x) \approx \frac{-f(x+2h) + 4f(x+h) - 3f(x)}{2h} + O(h^3)$$

Shin Yoshizawa: shin@riken.jp

微分(導関数)の近似: 差分法4

- ✓ 2階の微分の前進1次差分: $f''(x) \approx \frac{f(x+2h) - 2f(x+h) + f(x)}{h^2} + O(h^3)$
- ✓ 中心差分を使うと、評価点の数は同じで、より高精度になる: 例えば2階微分の中心2次差分近似:

$$\begin{cases} f(x+a) \approx f(x) + f'(x)a + \frac{1}{2!} f''(x)a^2 + O(a^3) \\ f(x-b) \approx f(x) - f'(x)b + \frac{1}{2!} f''(x)b^2 + O(b^3) \end{cases} \Rightarrow \begin{cases} f(x+a)/a \approx f(x)/a + f'(x) + \frac{1}{2} f''(x)a + O(a^3)/a \\ f(x-b)/b \approx f(x)/b - f'(x) + \frac{1}{2} f''(x)b + O(b^3)/b \end{cases}$$

$$\Rightarrow \frac{bf(x+a) + af(x-b)}{ab} \approx \frac{(a+b)f(x) + (a+b)f''(x)}{2} \quad \leftarrow \text{微小距離が異なるときの中心差分近似}$$

$$\Rightarrow f''(x) \approx \frac{2bf(x+a) - 2(a+b)f(x) + 2af(x-b)}{ab(a+b)} + O(a^3, b^3)$$

2階微分はラプラスアン

誤差は h の3乗に比例: $O(h^3)$ $\uparrow a=b=h$

Shin Yoshizawa: shin@riken.jp

GradientとLaplacianの離散化(差分近似)

$$\nabla I = \left(\frac{\partial I}{\partial x}, \frac{\partial I}{\partial y} \right) \quad \Delta I = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}$$

- ✓ 1次精度前進: 数学的には $h < 1$ だが、画像などでは $h=1$ を良く使う。

$$\nabla I \approx (I(x+1, y) - I(x, y), I(x, y+1) - I(x, y))$$

$$\Delta I \approx I(x+2, y) - 2I(x+1, y) + 2I(x, y) + I(x, y+2) - 2I(x, y+1)$$

- ✓ 2次精度中心: 画像ではこれが基本。

$$\nabla I \approx \left(\frac{I(x+1, y) - I(x-1, y)}{2}, \frac{I(x, y+1) - I(x, y-1)}{2} \right)$$

$$\Delta I \approx I(x+1, y) + I(x-1, y) + I(x, y+1) + I(x, y-1) - 4I(x, y)$$

$$\Delta f(\mathbf{x}) \approx \sum_{i=1}^n \frac{f(x_i + h_i) - 2f(x_i) + f(x_i - h_i)}{h_i^2} + O(h^3) \quad \Delta f = \frac{\partial^2}{\partial x_1^2} f + \frac{\partial^2}{\partial x_2^2} f + \dots + f \frac{\partial^2}{\partial x_n^2} f$$

$$\mathbf{x} = \{x_1, x_2, \dots, x_n\}$$

Shin Yoshizawa: shin@riken.jp

GradientとLaplacianの離散化(差分近似)2

- ✓ 下記1階微分の中心差分近似の分母になぜ2が出てくるのかは、2階微分の中心差分と同様に計算するとわかる。

$$\nabla I \approx \left(\frac{I(x+1, y) - I(x-1, y)}{2}, \frac{I(x, y+1) - I(x, y-1)}{2} \right)$$

$$\begin{cases} f(x+a) \approx f(x) + f'(x)a + \frac{1}{2!} f''(x)a^2 + O(a^3) \\ f(x-b) \approx f(x) - f'(x)b + \frac{1}{2!} f''(x)b^2 + O(b^3) \end{cases} \Rightarrow \begin{cases} f(x+a)/a^2 \approx f(x)/a^2 + f'(x)/a + \frac{1}{2} f''(x) + O(a^3)/a^2 \\ f(x-b)/b^2 \approx f(x)/b^2 - f'(x)/b + \frac{1}{2} f''(x) + O(b^3)/b^2 \end{cases}$$

$$\Rightarrow \frac{b^2 f(x+a) - a^2 f(x-b)}{a^2 b^2} \approx \frac{(b^2 - a^2) f(x)}{a^2 b^2} + \frac{(a+b) f'(x)}{ab}$$

$$\Rightarrow f'(x) \approx \frac{b^2 (f(x+a) - f(x)) + a^2 (f(x) - f(x-b))}{ab(a+b)} + O(a^3, b^3)$$

$$\Rightarrow f'(x) \approx \frac{f(x+h) - f(x-h)}{2h} \quad \uparrow a = b = h$$

Shin Yoshizawa: shin@riken.jp

画像では3x3の作用素(オペレータ)

0 0 0	0 0 0	0 0 0	0 1 0	0 0 0	0 $\frac{1}{2}$ 0
0 -1 1	-1 1 0	$-\frac{1}{2}$ 0 $\frac{1}{2}$	0 -1 0	0 1 0	0 0 0
0 0 0	0 0 0	0 0 0	0 0 0	0 -1 0	0 $-\frac{1}{2}$ 0

前進1次 後退1次 中心2次 前進1次 後退1次 中心2次

- ✓ 微分フィルタはエッジを検出できるが、ノイズに対しても敏感。エッジ強度画像を白をエッジとするか、黒をエッジとするかは、表現の違い。
- ✓ ノイズを抑えながらエッジ抽出:
- ✓ 微分と平滑化の組み合わせ。
- ✓ 横と縦の組み合わせ。

Shin Yoshizawa: shin@riken.jp

微分と平滑化オペレータの合成

✓ プリューウィットオペレータ:

- x方向微分: 横に微分 + 縦に平滑化.
- y方向微分: 縦に微分 + 横に平滑化.

*
* 置込み

$(f * g) * h = f * (g * h)$

入力画像 \rightarrow 横方向微分 \rightarrow 縦方向平滑化 \rightarrow 出力画像

$f * (g * h) \equiv \begin{matrix} 0 & 0 & 0 \\ -1 & 0 & 1 \\ 0 & 0 & 0 \end{matrix} \Rightarrow \begin{matrix} 0 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 1 & 0 \end{matrix} \Rightarrow \begin{matrix} 1 & 1 & 1 \\ -1 & 0 & 1 \\ 0 & 0 & 0 \end{matrix} \Rightarrow \begin{matrix} 0 & 0 & 0 \\ 0 & 1 & 1 \\ -1 & -1 & -1 \end{matrix}$

ECC-ARTS協会

Shin Yoshizawa: shin@riken.jp

重要: ソーベルオペレータ

✓ 最もよく使われている一階の偏微分オペレータ:

- 平滑化を中央に重み付.

[a] 入力画像 [b] 偏微分フィルタ [c] ソーベルフィルタ
ECC-ARTS協会

[d] 偏微分フィルタ(拡大) [e] ソーベルフィルタ(拡大)

$\begin{matrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{matrix} \Rightarrow \begin{matrix} 0 & 1 & 0 \\ 0 & 2 & 0 \\ 0 & 1 & 0 \end{matrix} \Rightarrow \begin{matrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{matrix}$

[a] 偏微分フィルタ(拡大) [e] ソーベルフィルタ(拡大)

Shin Yoshizawa: shin@riken.jp

勾配の細線化による線検出

✓ 勾配強度画像を細線化してもエッジ検出が可能.

$$\|\nabla I\| = \sqrt{I_x^2 + I_y^2}$$

Shin Yoshizawa: shin@riken.jp

2階微分オペレータ(Laplacian)

✓ 2次の中心差分でLaplaceオペレータの4連結での近似:

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

$$\Delta I \approx I(x+1,y) + I(x-1,y) + I(x,y+1) + I(x,y-1) - 4I(x,y)$$

中心2次

[a] 2つの1次差分の差
[b] 2次差分フィルタ
[a] 横方向の2次差分と縦方向の2次差分の和
[b] ラプラシアンフィルタ

Shin Yoshizawa: shin@riken.jp

2階微分オペレータ(Laplacian)2

✓ 8連結では?

$$\Delta f(x) \approx \sum_{i=1}^n \frac{f(x_i + h_i) - 2f(x_i) + f(x_i - h_i)}{h_i^2} + O(h^3)$$

$$\Delta I \approx I(x+1,y) + I(x-1,y) + I(x,y+1) + I(x,y-1) - 6I(x,y) + 0.5(I(x+1,y+1) + I(x-1,y+1) + I(x+1,y-1) + I(x-1,y-1))$$

0.5	1	0.5
1	-6	1
0.5	1	0.5

中心2次8連結

上下左右の $h=1$ 、斜めの $h=\sqrt{2}$

$$h = \sqrt{2} \Rightarrow \frac{1}{h^2} = 0.5$$

Shin Yoshizawa: shin@riken.jp

重要: 平滑化とエッジ

✓ 平滑化(滑らかにする事)の意味は?

✓ 前回の講義でやったノイズと何の関係があるの?

✓ 前々回の周波数分解との関係は?

平滑化・Low Path → ノイズの除去・エッジの削除

$\text{Smoothed Image} + \text{Edge Map} = \text{Resulting Edge Map}$

Shin Yoshizawa: shin@riken.jp

変分法

- ✓ **変分法**(Variational Calculus): 極小、極大を汎関数で停留条件を満たす様に求め、対応する偏微分方程式を導出.
- ✓ **汎関数**(functional): 関数の関数.

例(エッジ強度の積分): $E(I(x, y)) = \frac{1}{2} \iint_{\Omega} \|\nabla I\|^2 dx dy$

✓ **停留条件**: 第一変分がゼロ(関数での1階微分がゼロ).

$E(u(x, y)) = \iint_{\Omega} F(x, y, u, u_x, u_y) dx dy \Rightarrow \min \Leftarrow \delta E = 0$

✓ **復習: 極小、極大**:

Shin Yoshizawa: shin@riken.jp

変分法2

$E(u(x, y)) = \iint_{\Omega} F(x, y, u, u_x, u_y) dx dy \Rightarrow \min \Leftarrow \delta E = 0$

摂動(微小変化)した比較関数で置 $U(x, y, \alpha) = u(x, y) + \alpha \eta(x, y)$ き換え、その偏微分をゼロとする.

積分の領域: Ω の境界曲線 $\partial\Omega$ では $\eta(x, y) = 0$ とする.

$E(U(x, y)) = \iint_{\Omega} F(x, y, U, U_x, U_y) dx dy = \iint_{\Omega} F(x, y, u + \alpha \eta, u_x + \alpha \eta_x, u_y + \alpha \eta_y) dx dy$

$$\delta E = \left. \frac{\partial}{\partial \alpha} E(u + \alpha \eta) \right|_{\alpha=0} = \left. \iint_{\Omega} \frac{\partial}{\partial \alpha} F(x, y, U, U_x, U_y) dx dy \right|_{\alpha=0}$$

↑第一変分

$$= \left. \iint_{\Omega} \left(\frac{\partial F}{\partial U} \frac{\partial U}{\partial \alpha} + \frac{\partial F}{\partial U_x} \frac{\partial U_x}{\partial \alpha} + \frac{\partial F}{\partial U_y} \frac{\partial U_y}{\partial \alpha} \right) \right|_{\alpha=0} dx dy \quad \leftarrow \text{全微分}$$

$$= \iint_{\Omega} \left(\frac{\partial F}{\partial u} \eta + \frac{\partial F}{\partial u_x} \eta_x + \frac{\partial F}{\partial u_y} \eta_y \right) dx dy$$

Shin Yoshizawa: shin@riken.jp

変分法3

- ✓ **準備:**

グリーンの定理 \rightarrow

$$\iint_{\Omega} \left(\frac{\partial F}{\partial u_x} \eta_x + \frac{\partial F}{\partial u_y} \eta_y \right) dx dy$$

$$= \iint_{\Omega} \left(\frac{\partial}{\partial x} \left(\eta \frac{\partial F}{\partial u_x} \right) + \frac{\partial}{\partial y} \left(\eta \frac{\partial F}{\partial u_y} \right) \right) dx dy - \iint_{\Omega} \eta \left(\frac{\partial}{\partial x} \frac{\partial F}{\partial u_x} + \frac{\partial}{\partial y} \frac{\partial F}{\partial u_y} \right) dx dy$$

$$\iint_{\Omega} \eta \left(\frac{\partial}{\partial x} \frac{\partial F}{\partial u_x} + \frac{\partial}{\partial y} \frac{\partial F}{\partial u_y} \right) dx dy = \int_{\partial\Omega} \eta \left(\frac{\partial F}{\partial u_x} dy + \frac{\partial F}{\partial u_y} dx \right) \quad \leftarrow \text{グリーンの定理: 面積分を線積分に変換.}$$

積分の定義域: Ω の境界曲線 $\partial\Omega$ では $\eta(x, y) = 0$ なので.

$$\iint_{\Omega} \left(\frac{\partial F}{\partial u_x} \eta_x + \frac{\partial F}{\partial u_y} \eta_y \right) dx dy = - \iint_{\Omega} \eta \left(\frac{\partial}{\partial x} \frac{\partial F}{\partial u_x} + \frac{\partial}{\partial y} \frac{\partial F}{\partial u_y} \right) dx dy$$

Shin Yoshizawa: shin@riken.jp

変分法4

$$\delta E = \iint_{\Omega} \left(\frac{\partial F}{\partial u} \eta + \frac{\partial F}{\partial u_x} \eta_x + \frac{\partial F}{\partial u_y} \eta_y \right) dx dy$$

$$= \iint_{\Omega} \eta \left(\frac{\partial F}{\partial u} - \frac{\partial}{\partial x} \left(\frac{\partial F}{\partial u_x} \right) - \frac{\partial}{\partial y} \left(\frac{\partial F}{\partial u_y} \right) \right) dx dy$$

↑ がゼロになるためには、下記偏微分方程式を満たす:

- ✓ **2変数で1階微分の汎関数に対する公式:**

$E(u(x, y)) = \iint_{\Omega} F(x, y, u, u_x, u_y) dx dy \Rightarrow \min$

Euler-Lagrange 方程式 $\frac{\partial F}{\partial u} - \frac{\partial}{\partial x} \left(\frac{\partial F}{\partial u_x} \right) - \frac{\partial}{\partial y} \left(\frac{\partial F}{\partial u_y} \right) = 0$

Shin Yoshizawa: shin@riken.jp

変分法5

$$\frac{\partial F}{\partial u} - \frac{\partial}{\partial x} \left(\frac{\partial F}{\partial u_x} \right) - \frac{\partial}{\partial y} \left(\frac{\partial F}{\partial u_y} \right) = 0$$

エッジ強度の積分エネルギーの場合は:

$$\frac{1}{2} \iint_{\Omega} \|\nabla I\|^2 dx dy \Rightarrow \min \quad F = \frac{1}{2} \|\nabla I\|^2 = \frac{1}{2} (I_x^2 + I_y^2)$$

$$\frac{\partial F}{\partial I} = 0, \quad \frac{\partial F}{\partial I_x} = I_x, \quad \frac{\partial F}{\partial I_y} = I_y$$

$$\frac{\partial F}{\partial I} - \frac{\partial}{\partial x} \left(\frac{\partial F}{\partial I_x} \right) - \frac{\partial}{\partial y} \left(\frac{\partial F}{\partial I_y} \right) = - \frac{\partial}{\partial x} I_x - \frac{\partial}{\partial y} I_y = - \frac{\partial^2 I}{\partial x^2} - \frac{\partial^2 I}{\partial y^2} = - \Delta I$$

つまり、Laplace方程式の解がエネルギーを最小化する:

$$\Delta I(x, y) = 0$$

Shin Yoshizawa: shin@riken.jp

変分法6

$$\frac{\partial F}{\partial u} - \frac{\partial}{\partial x} \left(\frac{\partial F}{\partial u_x} \right) - \frac{\partial}{\partial y} \left(\frac{\partial F}{\partial u_y} \right) = 0$$

例えば、Poisson方程式は:

$$\frac{1}{2} \iint_{\Omega} (\|\nabla I\|^2 + 2 If(x, y)) dx dy \Rightarrow \min \quad F = \frac{1}{2} (I_x^2 + I_y^2 + 2 If)$$

$$\frac{\partial F}{\partial I} = f, \quad \frac{\partial F}{\partial I_x} = I_x, \quad \frac{\partial F}{\partial I_y} = I_y$$

$$\frac{\partial F}{\partial I} - \frac{\partial}{\partial x} \left(\frac{\partial F}{\partial I_x} \right) - \frac{\partial}{\partial y} \left(\frac{\partial F}{\partial I_y} \right) = - \frac{\partial}{\partial x} I_x - \frac{\partial}{\partial y} I_y + f = - \frac{\partial^2 I}{\partial x^2} - \frac{\partial^2 I}{\partial y^2} + f = f - \Delta I$$

つまり、Poisson方程式の解がエネルギーを最小化する:

$$\Delta I(x, y) = f(x, y)$$

Shin Yoshizawa: shin@riken.jp

重要: 变分法によるエネルギー最小化

- Laplace方程式はディリクレ・エネルギーを最小化する事で導かれ、その解は調和写像と呼ばれる。
- ディリクレ・エネルギー:** 勾配の大きさを積分→エッジの大きさの和=凹凸具合=ノイズの大きさ。

$$\frac{1}{2} \iint_{\Omega} \|\nabla I\|^2 dx dy \Rightarrow \min$$

定義域: Ω

定義域境界: $\partial\Omega$

✓ 变分法によりLaplace方程式がディリクレ・エネルギーの Euler-Lagrange方程式として導かれる↓

$$\Delta I(x, y) = 0 \quad (x, y \in \Omega)$$

$$I(x, y) = g(x, y) \quad (x, y \in \partial\Omega)$$

$g(x, y)$

凹凸具合が最小化=滑らかな(調和な)解=平均化。

Shin Yoshizawa: shin@riken.jp

重要: 拡散方程式

- ディリクレエネルギーの最小化過程は拡散方程式(熱伝導方程式)として記述出来る:
- 時間の変数を加えて関数(画像)を拡張しその時間方向への接線(時間変数での一階微分)が拡散のスピードになる。

$$\frac{\partial I(x, y, t)}{\partial t} = \Delta I(x, y, t)$$

✓ 拡散過程 $t \rightarrow \infty$ は、時間の極限で Laplace 方程式を満たす=解は調和関数となる ($\Delta I = 0$)。

例: クーラーを止めたら、温度は一定(又は周囲の部屋の温度の平均)になる。

Shin Yoshizawa: shin@riken.jp

LaplacianとDoG、LoG

- LoG: Laplacian of Gaussian. $LoG_\sigma = \Delta g_\sigma(x, y)$
- DoG: Difference of Gaussian.

$$g_\sigma(x, y) = \frac{1}{2\pi\sigma^2} \exp(-\frac{x^2 + y^2}{2\sigma^2})$$

$$\frac{\partial I(x, y, t)}{\partial t} = \Delta I(x, y, t) \quad L(x, y, \sigma) = g_\sigma(x, y) * I(x, y)$$

$$\sigma \Delta L(x, y, \sigma) = \frac{\partial L(x, y, \sigma)}{\partial \sigma} = \lim_{k \rightarrow 1} \frac{L(x, y, k\sigma) - L(x, y, \sigma)}{k\sigma - \sigma} \approx \frac{L(x, y, k\sigma) - L(x, y, \sigma)}{k\sigma - \sigma}$$

$$\sigma^2(1-k) LoG_\sigma * I(x, y) = \sigma^2(1-k) \Delta L(x, y, \sigma)$$

$$\approx (g_\sigma(x, y) - g_{k\sigma}(x, y)) * I(x, y) = DoG_\sigma * I(x, y)$$

$$DoG_\sigma(x, y) = g_\sigma(x, y) - g_{2\sigma}(x, y).$$

Shin Yoshizawa: shin@riken.jp

差分による拡散方程式の離散化

$$\frac{\partial I(x, y, t)}{\partial t} = \Delta I(x, y, t)$$

- 時間は、前進1次差分近似: epsilonは微小時間。

$$I^{n+1}(i, j) = I^n(i, j) + \epsilon \Delta I^n(i, j)$$

4連結

0	1	0
1	-4	1
0	1	0

- 空間は中心2次差分近似:

$$\Delta I \approx I(x+1, y) + I(x-1, y) + I(x, y+1) + I(x, y-1) - 4I(x, y)$$

$$\Delta I \approx I(x+1, y) + I(x-1, y) + I(x, y+1) + I(x, y-1) - 6I(x, y) + 0.5(I(x+1, y+1) + I(x-1, y+1) + I(x+1, y-1) + I(x-1, y-1))$$

0.5	1	0.5
1	-6	1
0.5	1	0.5

8連結

Shin Yoshizawa: shin@riken.jp

差分の陽解法と陰解法

- 陽解法は…

$$I^{n+1}(i, j) = I^n(i, j) + \epsilon \Delta I^n(i, j)$$

- 陰解法は…

$$I^{n+1}(i, j) = I^n(i, j) + \epsilon \Delta I^{n+1}(i, j)$$

- 連立方程式となる:

$$(I - \epsilon \Delta) I^{n+1}(i, j) = I^n(i, j) \Rightarrow I^{n+1}(i, j) = (I - \epsilon \Delta)^{-1} I^n(i, j)$$

$$\Rightarrow A \mathbf{x} = \mathbf{b} \Rightarrow \mathbf{x} = A^{-1} \mathbf{b}$$

$$\Delta I \approx I(x+1, y) + I(x-1, y) + I(x, y+1) + I(x, y-1) - 4I(x, y)$$

なら

行列 A の対角成分は $1 + \epsilon$ 4、非対角成分は、0か-1の疎な行列になる。

Shin Yoshizawa: shin@riken.jp

差分の陽解法と陰解法2

- 画像の各画素にIDを $k = (i \times sx + j)$ と与えると…

(0,0) $\rightarrow j$ $(sx-1, 0)$
 i $(0, sy-1)$ $(sx-1, sy-1)$

$$\Delta I \approx I(x+1, y) + I(x-1, y) + I(x, y+1) + I(x, y-1) - 4I(x, y)$$

は、 $I(k-1) + I(k-sx)$
 $+ I(k+1) + I(k+sx) - 4I(k)$

$k - sx - 1$	$k - sx$	$k - sx + 1$	$k - sx + 2$
$k - 1$	k	$k + 1$	$k + 2$
$k + sx - 1$	$k + sx$	$k + sx + 1$	$k + sx + 2$
$k + 2sx - 1$	$k + 2sx$	$k + 2sx + 1$	$k + 2sx + 2$

となる、ここで、 $sx \times sy$ の行列を考える。

Shin Yoshizawa: shin@riken.jp

差分の陽解法と陰解法3

1行にはゼロでない要素が5つで対角成分が-4、それ以外は1: ラプラス行列とも呼ばれる。

$$\Delta I \approx I(k-1) + I(k-sx) + I(k+1) + I(k+sx) - 4I(k)$$

$$A = (I - \varepsilon \Delta)$$

行列 A の対角成分は $1 + \varepsilon 4$ 、非対角成分は、0か-1の疎な行列になる。

Shin Yoshizawa: shin@riken.jp

フィルタの繰り返し適用

✓ 陰解法では絶対安定だが、陽解法は微小時間epsilonが大きい値は解が不安定になる(クーラン条件)。演習では簡単の為陽解法を使う。

$$I^{n+1} = Filtering(I^n)$$

for(iteration){

$$tmp = Filtering(I);$$

$$I = tmp;$$

}

Shin Yoshizawa: shin@riken.jp

復習: エッジ強調フィルタ(空間領域)

✓ 周波数領域でのエッジ強調フィルタと同様に空間領域でも、元画像+k(元画像-平滑化画像)でエッジ強調画像を作成可能。

$$H_{h-emph}(u, v) = 1 + kH_{high}(u, v) = 1 + k(1 - H_{low}(u, v))$$

Shin Yoshizawa: shin@riken.jp

Laplacianオペレータによるエッジ強調

✓ Laplacianをたすと平滑化なので1から引いたオペレータは鮮鋭化(エッジ強調)。

この8連続は差分法的には精度がない近似。
[b] 鮮鋭化フィルタ

Shin Yoshizawa: shin@riken.jp

Laplacianオペレータによるエッジ強調2

[a] 入力画像(グレースケール)
[b] 鮮鋭化フィルタの結果
[a] 入力画像(カラー)
[b] 鮮鋭化フィルタの結果

✓ 多重解像度解析などの周波数フィルタと原理は同じ。

Shin Yoshizawa: shin@riken.jp

Laplacianオペレータによるエッジ強調3

✓ Multiresolutional Meshとして3D形状への応用もある。

(a) Wavelet coefficients
(b) ...
(c) M. Eck et al., SIGGRAPH'95.
© A. Koldovsky et al., SIGGRAPH'00.
© Guskov et al., SIGGRAPH'99.

