

# デジタルメディア処理2

担当: 井尻 敬

## デジタルメディア処理2、2018（前期）

- 4/19 序論 : イントロダクション, テクスチャ合成
- 4/26 特徴検出1 : テンプレートマッチング、コーナー・エッジ検出
- 5/10 特徴検出2 : DoG特徴量、SIFT特徴量、ハフ変換
- 5/17 領域分割 : 領域分割とは、閾値法、領域拡張法、動的輪郭モデル
- 5/24 領域分割 : グラフカット, モーフォロジー処理, Marching cubes
- 5/31 パターン認識基礎1: パターン認識概論, サポートベクタマシン
- 6/07 パターン認識基礎2: ニューラルネットワーク、深層学習
- 6/14 パターン認識基礎3: オートエンコーダ
- 6/21 筆記試験 (50点満点)(n点以下の場合レポート出すかも)
- 6/28 プログラミング演習 1 (基礎的な課題40点, 発展的な課題 20点)
- 7/05 プログラミング演習 2
- 7/12 プログラミング演習 3
- 7/19 プログラミング演習 4
- 7/26 プログラミング演習 5

## 特徴検出 と パターン認識

### 第2,3回 - パターン・図形・特徴の検出とマッチング

画像の中から, 特定のパターン, コーナー, 直線, 円, などの特徴点を検出するアルゴリズムを紹介する

### 第6-8回-- パターン認識

既存のデータセットからクラス分類を学習し, 未知画像がどのクラス属すかを推測する手法を紹介する

深層学習にも少しだけ触れる

## Contents 画像内の特定パターンを発見する手法


- テンプレートマッチング
- 特徴点検出
  - コーナー検出 (Harris corner detector/FAST)
  - エッジ検出 (Canny edge detector)
  - その他有名な特徴点 (SIFT/BRIEF/ORB)
- 特徴点の対応付け
- Hough変換

## 準備: ノルム(norm)

$d$ 次元空間のベクトル  $\mathbf{x} = (x_1, x_2, \dots, x_n)$  の  $p$ -ノルムは以下の通り定義される

$$\|\mathbf{x}\|_p = (|x_1|^p + |x_2|^p + \dots + |x_n|^p)^{\frac{1}{p}}$$

例  $d=2$  のとき



$p=2$  なら...

$$\|\mathbf{x} - \mathbf{y}\|_2 = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2}$$

これはよく知っているユークリッド空間の距離

$p=1$  なら...

$$\|\mathbf{x} - \mathbf{y}\|_1 = |x_1 - y_1| + |x_2 - y_2|$$

点  $x$  から点  $y$  へ、軸に沿った方向のみで移動した際の距離  
市街地における移動距離になぞらえて**市街地距離**や**マンハッタンノルム**と呼ばれる

左の画像から右の画像を探せ



※地味な例ですみません。。。

左の画像から右の画像を探せ



※地味な例ですみません。。。

## テンプレート マッチング

templateMatching.py



入力画像





比較



テンプレート  
画像

- 入力画像をラスタスキャンし、入力画像とテンプレートの類似度を比較
- 類似度が閾値より高い部分を入力する
- ※ **テンプレート**: 検索対象を表す標準画像
- ※ **ラスタスキャン**: 画像を左から右に、上から下に、一画素ずつ走査すること

## 類似度（相違度）の定義



Grayscale化  
されている

- 相違度: **Sum of Square Distance**

$$R_{SSD} = \sum_{i,j} (I(i, j) - T(i, j))^2$$

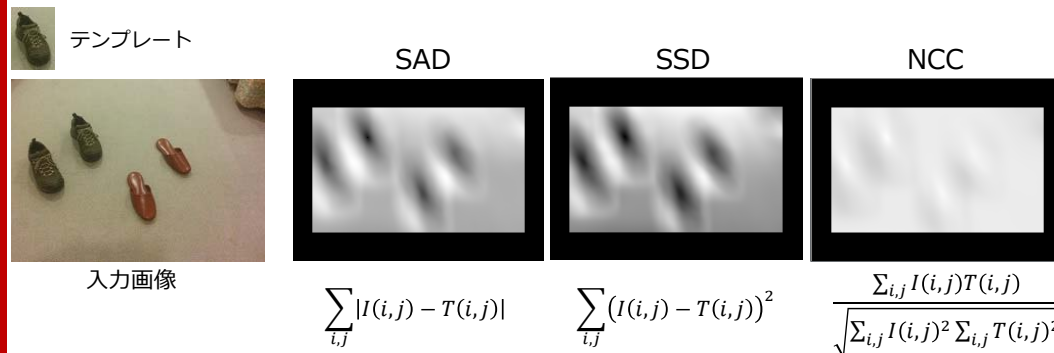
- 相違度: **Sum of Absolute Distance**

$$R_{SAD} = \sum_{i,j} |I(i, j) - T(i, j)|$$

- 類似度: **Normalized Cross Correlation**(正規化相互相関)

$$R_{NCC} = \frac{\sum_{i,j} I(i, j)T(i, j)}{\sqrt{\sum_{i,j} I(i, j)^2 \sum_{i,j} T(i, j)^2}}$$

## テンプレートマッチングの結果



SAD/SSDは相違度なので、近いところほど値が小さくなる  
NCCは類似度なので近いところほど値が大きくなる  
例えば、閾値以下の局所最小部を検出対象とすればよい

## テンプレートマッチングの結果




SAD



SSD



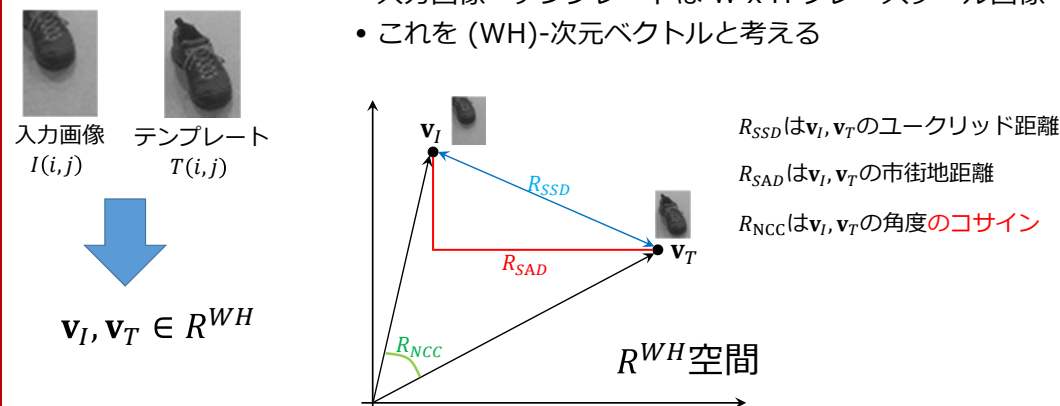
NCC



SAD/SSDは相違度なので、近いところほど値が小さくなる  
NCCは類似度なので近いところほど値が大きくなる  
例えば、閾値以下の局所最小部を検出対象とすればよい

## 類似度・相違度の定性的理解

- 入力画像・テンプレートは  $W \times H$  グレースケール画像
- これを  $(WH)$ -次元ベクトルと考える



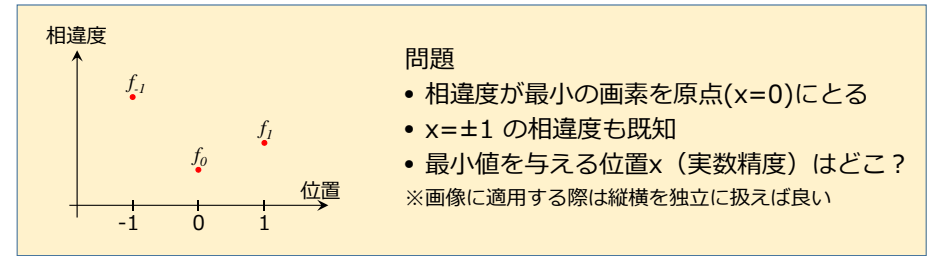
## サブピクセル精度のテンプレートマッチング

- テンプレートマッチングは目的画像にテンプレート画像を重ね差分を評価するため発見できる位置は**ピクセル単位（離散値）**
- サブピクセル（連続値）**精度で位置検出を行いたい

• 局所的に関数をフィッティングし、最小値を求める


→ 等角直線フィッティング

→ パラボラフィッティング



### 等角直線フィッティング


下図の通り傾きが-1倍の2本の直線の交点を利用



$f_{-1} > f_1$  のときは、 $f_{-1}$  と  $f_0$  を通る直線と、 $f_0$  と  $f_1$  を通る直線を考える

### パラボラフィッティング

二次関数で相違度を補間し相違度の最小位置を求める



## テンプレートマッチングの高速化




W×H



w×h

対象画像全領域にテンプレートを重ね合わせて差分を計算する計算複雑度は…



**残差逐次検定**：目標画像をラスタスキャンしテンプレートとの差分計算をする際、現在の最小値よりも差分が大きくなったら計算を打ち切る

**粗密探索法**：ガウシアンピラミッドを生成。低解像度画像にてマッチングする画素を発見。ひとレベル高解像度画像に移動し、発見した画素に関する数画素のみに対してマッチングを計算する

## 復習: Steepest descent - 最急降下法

### 最小化問題

関数  $f(x)$  を最小化する  $x$  を求めよ

$$\arg \min_x f(x)$$

※ 関数  $f(x)$  の形が分かっている  $\nabla f(x) = 0$  が解けるならそれでよいが、そうでない場合に使える手法の一つが最急降下法

### 最急降下法

- $x^0$  を初期解とする（何らかの方法で発見する）
- 変化が十分少なくなるまで以下を繰り返す

$$x^{t+1} = x^t - h \nabla f(x)$$

## Chamfer Matching

1. 入力画像  $I$  のエッジ画像  $I_E(x, y)$  を生成し, エッジ画素からの距離画像  $I_{DT}$  を計算

2. テンプレート画像  $T$  をエッジ画像  $T_E$  に変換

$$T_E(u, v) = \begin{cases} 0 & (u, v) \text{ がエッジ画素} \\ 1 & \text{それ以外} \end{cases}$$

3. 相違度を以下の通り定義する

$$S(x, y) = \sum_{v=0}^H \sum_{u=0}^H T_E(u, v) I_{DT}(x + u, y + v)$$

※ エッジ画素上で距離画像をサンプリング

※ テンプレート全体を見ないので高速

教科書図 11.7

## Chamfer Matching

3. 相違度を以下の通り定義する

$$S(x, y) = \sum_{v=0}^H \sum_{u=0}^W T_E(u, v) I_{DT}(x + u, y + v)$$

4. 初期位置  $(x^0, y^0)$  から最急降下法により相違度が最小となる位置を探索する

$$\begin{pmatrix} x^{t+1} \\ y^{t+1} \end{pmatrix} = \begin{pmatrix} x^t \\ y^t \end{pmatrix} - \nabla S(x, y)$$

※ 勾配の式は以下の通り

$$\nabla S(x, y) = \begin{pmatrix} \sum_v \sum_u T_E(u, v) \frac{\partial}{\partial x} I_{DT}(x + u, y + v) \\ \sum_v \sum_u T_E(u, v) \frac{\partial}{\partial y} I_{DT}(x + u, y + v) \end{pmatrix}$$

教科書図 11.7

## まとめ：テンプレートマッチング



入力画像



テンプレート

入力画像から物体を検出するための手法  
 検出対象の画像 (テンプレート) を用意し, 入力画像をラスタスキャンし相違度を評価  
 相違度が閾値以下の領域を出力する  
 相違(類似)度: SAD, SSD, NCCなど


サブピクセル精度で検出するための関数フィッティング

高速化のための残差逐次検定・粗密(coarse to fine)探索・chamfer matching

HarrisCorner.py  
CannyEdge.py

## コーナー、輪郭線の検出

物体認識・物体追跡・位置あわせなど, より高度な画像処理に利用するため  
 画像から『コーナー』や『輪郭線』といった特徴的な点・曲線を検出する




コーナー検出  
(Harris Corner Detector)



輪郭検出  
(Canny Edge detector)

## Harrisのコーナー検出アルゴリズム

[C. Harris & M. Stephens (1988). "A Combined Corner and Edge Detector". Proc. of the 4th ALVEY Vision Conference. pp. 147-151.]



• 入力：グレースケール画像

• 出力：コーナー画素群

• 手法の概要

Harris行列（又はStructure tensor matrixと呼ばれる）を定義し、この固有値固有ベクトルを用いて、局所領域の輝度変化方向と変化量を検出する  
局所領域の輝度変化が、直交する2方向について大きくなる部分をコーナーと定義

## Structure tensor matrix (1/3)

画像上の点 $(x, y)$ の輝度値を $I(x, y)$ と表す

点 $(x, y)$ における**Structure tensor matrix**は以下の通り定義される

$$\mathbf{A}(x, y) = \sum_{u, v} G(u, v) \begin{pmatrix} I_x I_x & I_x I_y \\ I_x I_y & I_y I_y \end{pmatrix}$$

ただし、 $I_y = I_y(x + u, y + v)$ ,  $I_x = I_x(x + u, y + v)$  と省略したもの

$I_x$ と $I_y$ は画像の微分（sobel filter）


また、 $G(u, v)$ は重み関数（ガウシアンを用いる）

※教科書の式11.6 ~ 11.9に対応する

## Structure tensor matrix (2/3)

実際の計算手順

$$\mathbf{A}(x, y) = \sum_{u, v} G(u, v) \begin{pmatrix} I_x I_x & I_x I_y \\ I_x I_y & I_y I_y \end{pmatrix}$$



Structure Tensorの性質

- 固有値を $\lambda_1, \lambda_2$  とする ( $\lambda_1 > \lambda_2$ )
- 固有ベクトルを  $\mathbf{v}_1, \mathbf{v}_2$  とする
- 対称行列 → 固有値は実数
- 対称行列 → 固有ベクトルは直交
- 半正定置 →  $\lambda_1 \geq 0, \lambda_2 \geq 0$ 
  - 半正定置行列の和なので。

- $\mathbf{v}_1$ は輝度値変化の最も大きな方向
- $\lambda_1$ は $\mathbf{v}_1$ 方向の輝度値変化の大きさ
- $\lambda_2$ は $\mathbf{v}_2$ 方向の輝度値変化の大きさ

## Harrisのコーナー検出アルゴリズム

グレースケール画像からコーナーを検出


1. 各画素 $(x, y)$ におけるStructure Tensor  $\mathbf{A}$  と固有値 $\lambda_1, \lambda_2$  を計算
2. 各画素 $(x, y)$ において $R = \lambda_1 \lambda_2 - k(\lambda_1 + \lambda_2)^2$ を計算
3.  $R$ が極大かつ閾値以上の点をコーナーとして出力する

※ただし、 $k$ はユーザが指定するパラメタ (0.04~0.06)

※ $R = \lambda_1 \lambda_2 - k(\lambda_1 + \lambda_2)^2$ は、コーナーらしさを現す関数：  
 $\lambda_1$ と $\lambda_2$ が大きくかつ近いときに大きな値を返す

評価式Rの3Dプロット →

[http://www.wolframalpha.com/input/?i=z%3Dx\\*y+-+0.02\\*\(x%2By\)%5E2](http://www.wolframalpha.com/input/?i=z%3Dx*y+-+0.02*(x%2By)%5E2)



## Harrisのコーナー検出アルゴリズム

グレースケール画像からコーナーを検出

1. 各画素 $(x,y)$ におけるStructure Tensor  $A$  と固有値 $\lambda_1, \lambda_2$  を計算
2. 各画素 $(x,y)$ において $R = \lambda_1 \lambda_2 - k(\lambda_1 + \lambda_2)^2$ を計算
3.  $R$ が極大かつ閾値以上の点をコーナーとして出力する



グレースケール画像からコーナーを検出 **new**

1. 各画素 $(x,y)$ におけるStructure Tensor  $A$  を計算
2. 各画素 $(x,y)$ において $R = \det A - k(\text{tr } A)^2$ を計算
3.  $R$ が極大かつ閾値以上の点をコーナーとして出力する

**固有値の計算時間が無駄**

$$\det A = \lambda_1 \times \lambda_2$$

$$\text{tr } A = \lambda_1 + \lambda_2$$

**という関係を利用すると  
計算を効率化できる**

※練習) 上記の関係を証明せよ

## Harrisのコーナー検出アルゴリズム (実装例)

## Cannyの輪郭線検出アルゴリズム(1/2)

※井尻はキャニーと呼んでますが、教科書はケニーですね。。。

### 1. ガウシアンフィルタをかける : $I \rightarrow G * I$

例)  $5 \times 5$ ,  $\sigma = 1.4$  のガウシアンなどが利用される


### 2. 勾配強度・勾配方向計算

Sobel filterにより縦横方向の微分を計算 :  $I \rightarrow I_x, I_y$

$$\text{勾配強度} : g(x,y) = \sqrt{I_x(x,y)^2 + I_y(x,y)^2}$$

$$\text{勾配方向} : d(x,y) = \tan^{-1} \frac{I_y(x,y)}{I_x(x,y)}$$

( $0^\circ/45^\circ/90^\circ/135^\circ$ の4通りに量子化)



## Cannyの輪郭線検出アルゴリズム(2/2)

赤字は訂正


### 3. non-maximum suppression

細い輪郭線抽出のため、勾配強度が極大となる画素のみを残す

勾配強度画像の各画素 $x$ に対して…

勾配方向に隣接する2画素 $p,q$ と $x$ の勾配強度を比較

画素 $x$ の勾配強度が $p,q$ と比べて最大でないなら $x$ の勾配強度を0に



### 4. 閾値処理

二つの閾値 $T_{max}$ と $T_{min}$ を用意

勾配強度画像の画素 $x$ の勾配強度が…

- $T_{max}$ より大きい  $\rightarrow$  Strong edge: 画素 $x$ は輪郭線である
- $T_{min}$ より小さい  $\rightarrow$  not edge: 画素 $x$ は輪郭線でない
- それ以外  $\rightarrow$  weak edge: もしstrong edgeに隣接していれば輪郭線とする

参考: OpenCV [http://docs.opencv.org/2.4/doc/tutorials/imgproc/imgtrans/canny\\_detector/canny\\_detector.html](http://docs.opencv.org/2.4/doc/tutorials/imgproc/imgtrans/canny_detector/canny_detector.html)

原著論文: Canny, J., A Computational Approach To Edge Detection, IEEE PAMI, 1986.

※紹介したものは実装の一例です.

## Cannyの輪郭線検出アルゴリズム（実装例）

## まとめ：コーナー・輪郭検出

### コーナー検出：画像中の『角』形状を検出

- **Harris Corner detection**

→ Structure Tensorの固有値により角らしさを定義

• 様々な手法が知られる(FAST/SUSAN/ハッセ行列)

### 輪郭検出：画像中の物体と物体の境界を検出

- **Canny Edge Detection**


• 微分フィルタによる勾配画像取得

• 勾配方向を考慮した細線化

• 二つの閾値処理

• 様々な手法が知られる(Sobel/Hough変換…)

### 補足資料



## Structure Tensor Matrix（導出）

[A Combined Corner and Edge Detector in 1988]

窓領域SとSを微量量 $(u, v)$ だけ移動した領域Tを考える。

この2領域の重み付き二乗誤差は以下の通り。

$$D(u, v) = \sum_{(x, y) \in S} G(x, y) (I(x + u, y + v) - I(x, y))^2 \quad \dots (1)$$

これはSを $(u, v)$ だけずらした際の画像の変化量を示す

※ 重み関数 $G(x, y)$ には、ガウシアンがよく用いられる。


テーラー展開し2次以降の項を無視すると、以下の変形が得られる

$$I(x + u, y + v) \approx I(x, y) + uI_x(x, y) + vI_y(x, y)$$

これを(1)に代入すると、以下の通りStructure Tensor Matrix  $\mathbf{A}$  が現れる

$$D(u, v) = (u, v) \mathbf{A} \begin{pmatrix} u \\ v \end{pmatrix}, \quad \mathbf{A} = \sum_{(x, y) \in S} G(x, y) \begin{pmatrix} I_x I_x & I_x I_y \\ I_x I_y & I_y I_y \end{pmatrix}$$

### 補足資料



## Structure Tensor Matrix（導出）

窓領域SとSを $(u, v)$ だけ移動した領域Tの二乗誤差は以下の通り

$$D(u, v) = (u, v) \mathbf{A} \begin{pmatrix} u \\ v \end{pmatrix}, \quad \mathbf{A} = \sum_{(x, y) \in S} G(x, y) \begin{pmatrix} I_x I_x & I_x I_y \\ I_x I_y & I_y I_y \end{pmatrix}$$

今知りたいのは、どの方向 $(u, v)$ に動かすと差分が最大になるか？つまり、画像の変化が大きいか？である。そのため以下の最大化問題を考える。

$$\operatorname{argmax}_{(u, v)} \frac{(u, v) \mathbf{A} \begin{pmatrix} u \\ v \end{pmatrix}}{\begin{pmatrix} u \\ v \end{pmatrix} \begin{pmatrix} u \\ v \end{pmatrix}}$$

この目的関数はレイリー商と呼ばれ、 $(u, v)$ が行列 $\mathbf{A}$ の固有ベクトルに一致するとき、最大値（最小値）をとり、最大値・最小値は固有値と一致することが知られている(証明省略)。

つまり、Structure Tensor matrixの固有値固有ベクトルを $\lambda_1, \lambda_2$  ( $\lambda_1 > \lambda_2$ )  $\mathbf{v}_1, \mathbf{v}_2$ とすると、 $(u, v)$ が $\mathbf{v}_1$ に一致するとき画像は最も大きく変化する。また $(u, v)$ が $\mathbf{v}_2$ に一致するとき画像の変化は最小になる。