

Компьютерное зрение '2014

Who? Александр Вахитов

When? November 1, 2014

План лекции

Точки

SIFT

Сопоставление

Линии

Содержание

- 1 Детекция точек
- 2 Дескрипторы точек
- 3 Сопоставление
- 4 Отслеживание
- 5 Границы
- 6 Линии

Основной материал: R. Szeliski, *Computer Vision: Algorithms and Applications*, гл. 4

Все материалы без отдельных ссылок, взяты из указанной книги

Какие бывают особенности



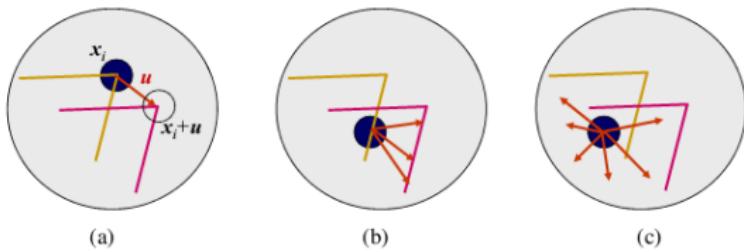
Какие бывают особенности

- Точки
- Регионы
- Линии

Работа с особенностями

- Детекция
- Описание
- Сопоставление / отслеживание

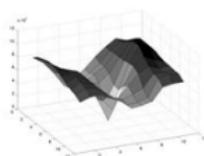
Какие бывают точки



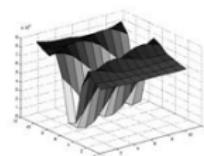
Какие бывают точки



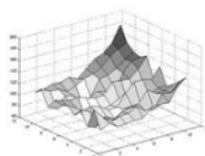
(a)



(b)



(c)



(d)

Уравнение оптического потока

$$(I(x(t), y(t), t))'_t = 0$$

$$I'_x \delta x + I'_y \delta y + I'_t = 0$$

$$I(x(t), y(t), t+1) = I(x(t), y(t), t) - I'_x \delta x - I'_y \delta y$$

Необходимо найти δ_x, δ_y .

Для любого ли изображения эта задача разрешима?

Задача: поиск сдвига на изображении

I, J - изображения, при этом сдвиг переводит I в J

$$C_{LK}(\delta_x, \delta_y) = \int_x \int_y (I(x, y) - J(x - \delta_x, y - \delta_y))^2 \rightarrow \min$$

$$\nabla C_{LK}(\delta_x, \delta_y) = 0 =$$

$$= -2 \int_{x,y} (I(x, y) - J(x - \delta_x, y - \delta_y)) \nabla J(x - \delta_x, y - \delta_y).$$

Решение и его свойства

Будем считать, что $\nabla J(x + \delta_x, y + \delta_y) \approx J(x, y)$

Разложение по Тейлору до первой степени:

$$J(x - \delta_x, y - \delta_y) = J(x, y) - (\delta_x, \delta_y)^T \nabla J(x, y)$$

$$0 = -2 \int_{x,y} (I(x, y) - J(x - \delta_x, y - \delta_y)) \nabla J(x - \delta_x, y - \delta_y) =$$

$$= -2 \int_{x,y} \left(I(x, y) - J(x, y) + (\delta_x, \delta_y)^T \nabla J(x, y) \right) \nabla J(x, y)$$

Если $I(x, y) = I(x, y, t + 1)$, а $J(x, y) = I(x, y, t)$,
 $\nabla J(x, y) \neq 0$, то получаем

$$I(x(t), y(t), t + 1) - I(x(t), y(t), t) + \delta_x I'_x + \delta_y I'_y = 0$$

Т.о., в данных предположениях решаем задачу
поиска опт. потока.

Обусловленность системы

$$Ax = b$$

$$A(x + \Delta x) = b + \Delta b$$

Требование: $\text{cond}(A) > \lambda_{\min}$, т.е. $\min\{\lambda_1, \lambda_2\} > \lambda_{\min}$

Детектор Харриса

$$M_C = \lambda_1 \lambda_2 - \kappa(\lambda_1 + \lambda_2)^2$$

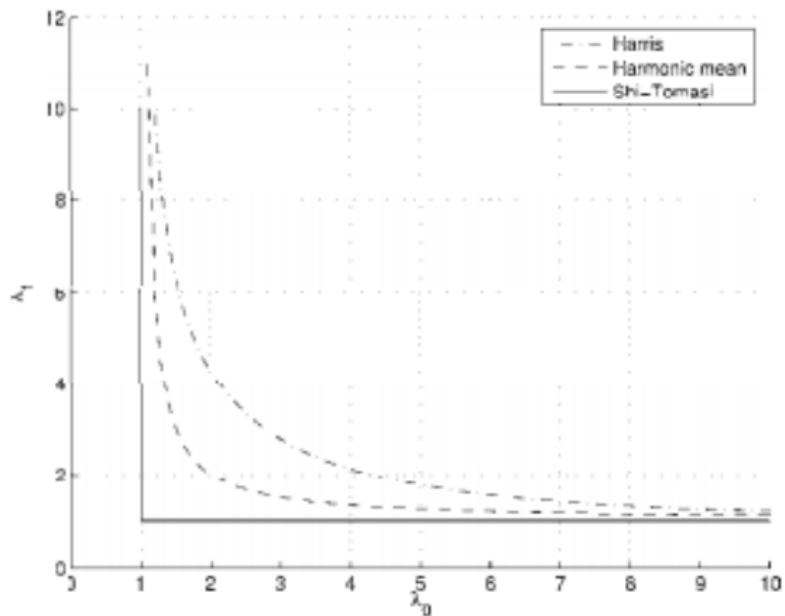
Уголок: $M_c < \epsilon$

Другие функции:

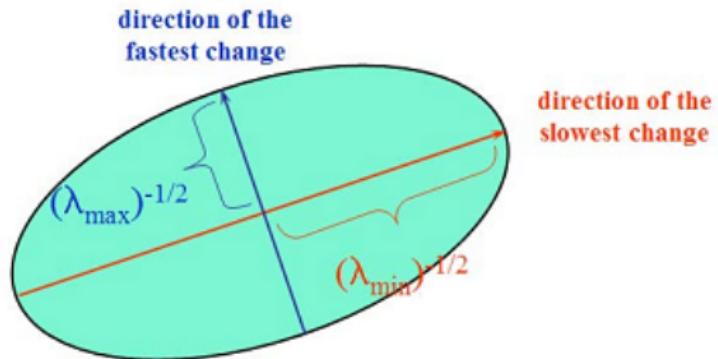
$$\lambda_1 - \alpha \lambda_2$$

$$\frac{\det A}{\text{Tr} A} = \frac{\lambda_1 \lambda_2}{\lambda_1 + \lambda_2}$$

Детекторы уголков



Структура автокорреляции



DoG: Difference of Gaussians

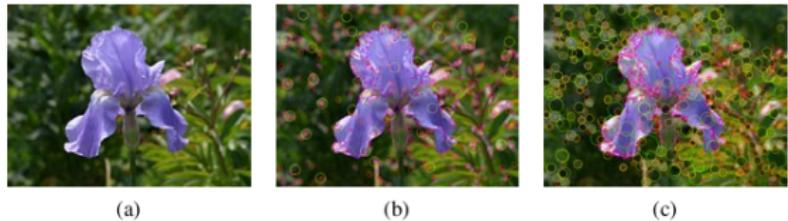
$$DoG(I, \sigma, k) = G(k * \sigma) * I - G(\sigma) * I$$

$G(\sigma)$ - гауссовское ядро

k - коэффициент

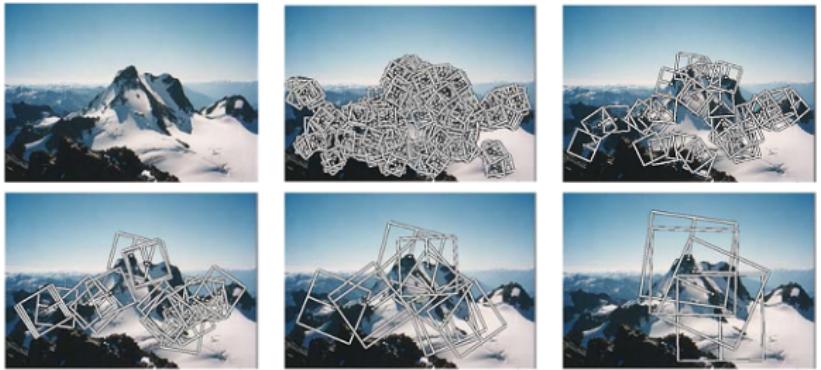
Детектор: экстремум DoG

Сравнение DoG и Harris



Вывод: взаимно дополняют друг друга
Размер круга: масштаб
Выбор масштаба?

Разные масштабы важны



Проблема: неравномерное распределение точек

Детектируемые точки распределены неравномерно, что вызывает проблемы в геометрической реконструкции и др. приложениях

Non-maximal suppression



(a) Strongest 250



(b) Strongest 500

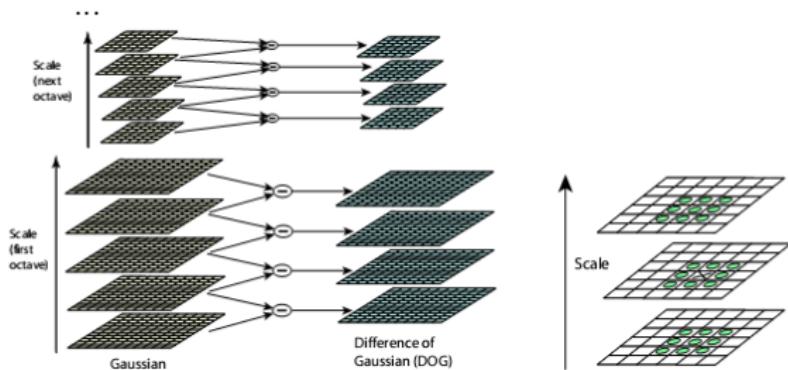


(c) ANMS 250, $r = 24$



(d) ANMS 500, $r = 16$

Scale Invariant Feature Transform SIFT

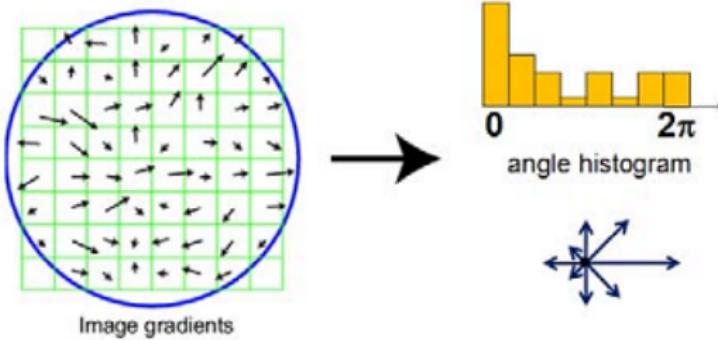


Идея: максимумы в 3D (изображение + масштаб)

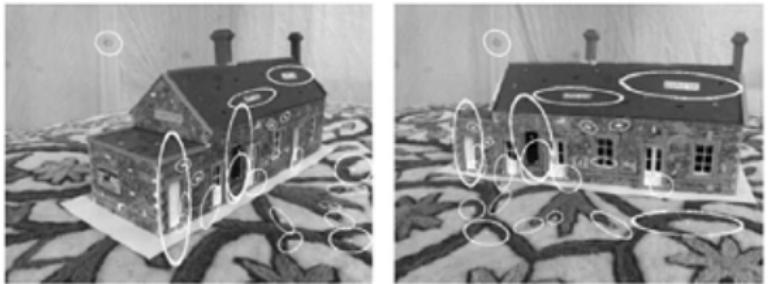
SIFT: оценка ориентации

Зачем?

Ответ: особенности изменяются и в масштабе, и в
ориентации!

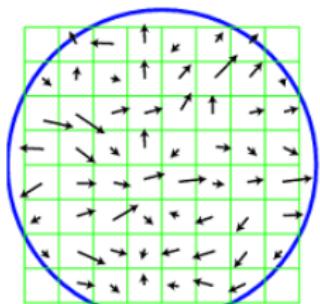


Аффинные детекторы

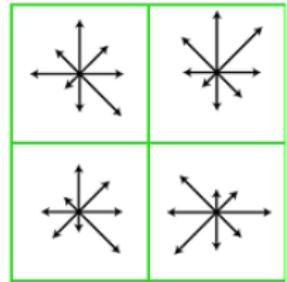


Идея: локальные координаты по "осям"
автокорреляции

Дескрипторы: SIFT

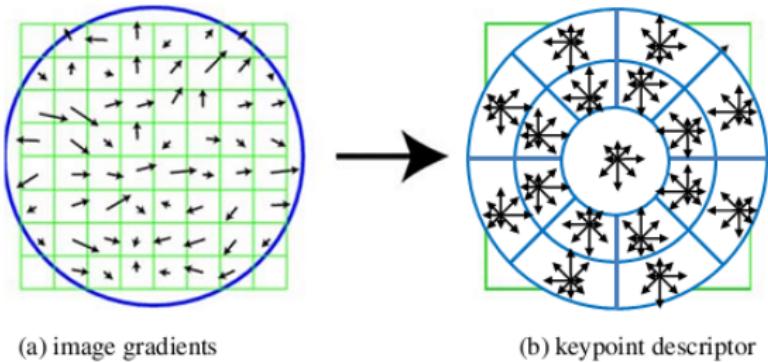


(a) image gradients

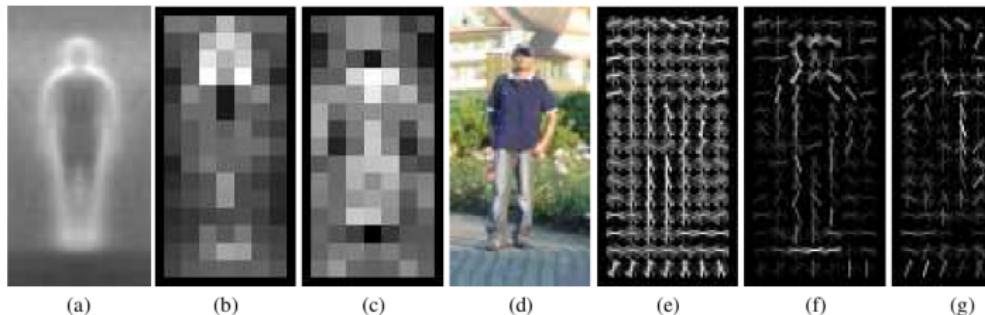


(b) keypoint descriptor

Дескрипторы: GLOH

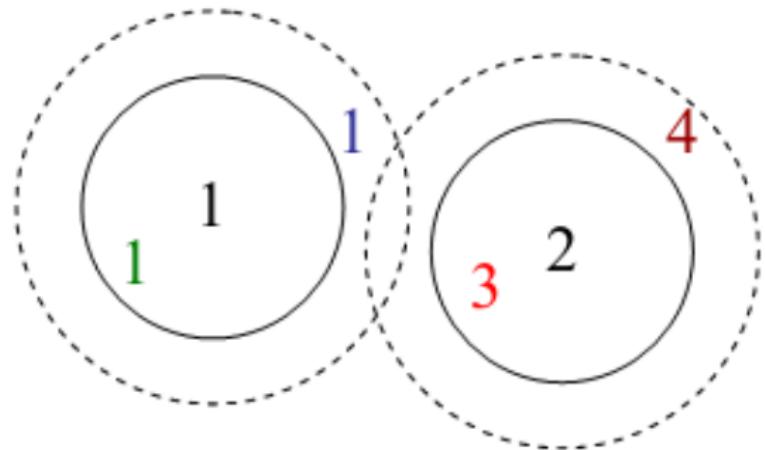


Дескрипторы: HOG



(Dalal, Triggs 2005)

Основные понятия

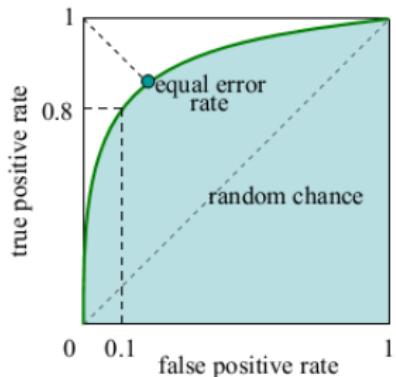


Зеленый: true positive (TP)

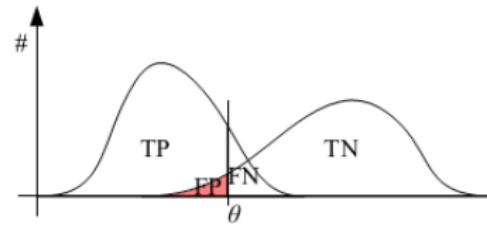
Синий: false negative (FN)

...

Receiver Operating Characteristic (ROC)



(a)



(b)

Сопоставление: первое - второе расстояния

d_1, d_2, d_3, \dots - расстояния до точек от тестовой точки,
упорядоченные по возрастанию

$$NNDR = \frac{d_1}{d_2}$$

Nearest Neighbour Distance Ratio

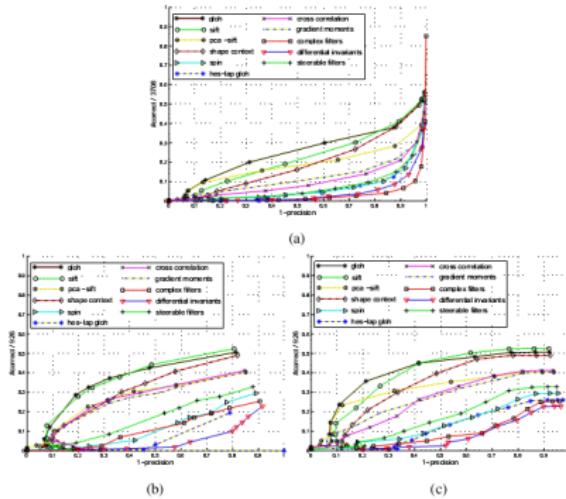
Сопоставление: первое - второе расстояния

d_1, d_2, d_3, \dots - расстояния до точек от тестовой точки,
упорядоченные по возрастанию

$$NNDR = \frac{d_1}{d_2}$$

Nearest Neighbour Distance Ratio

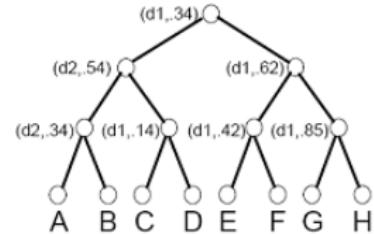
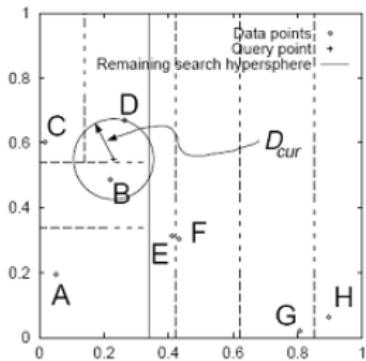
Достоинство NNDR



Линии - различные детекторы

- (a) - фиксированный барьер
- (b) - nearest neighbour
- (c) - NNDR

Эффективное сопоставление: kd-tree



Отслеживание

Видео

Непрерывное движение, локальные методы

Мультиразрешение

Кросс-корреляция блоков

Сопоставление на базе обучения



Детекция краев

Максимумы мощности края в направлении градиента
- производная градиента. Лапласиан:

$$S_\sigma(x) = \nabla J_\sigma(x) = \nabla^2 G_\sigma(x) * I(x)$$

Осталось найти точки перемены знака.

Субпиксельно:

$$x_z = \frac{x_i S(x_j) - x_j S(x_i)}{S(x_j) - S(x_i)}$$

Алгоритм Canny (1986)

Детекция края с двумя барьерами:

θ_0 для безусловной детекции пикселя края

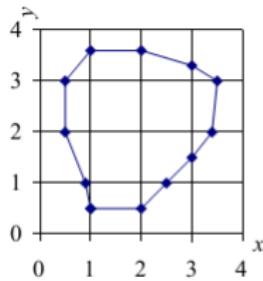
$\theta_1 < 0$ для детекции пикселя края при наличии соседних пикселей, принадлежащих краю

Объединение участков края

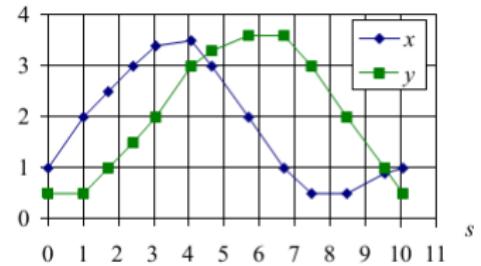
Цепной код: N, NW, W, SW, S, SE, E, NE
(следующий пиксель по отношению к предыдущему)
Натуральная параметризация $x(s)$:

$$s_0 = \int_0^{s_0} |\nabla x(s)|$$

Натуральная параметризация



(a)



(b)

$$z(s) = x(s) + iy(s)$$

Поворот равносителен домножению $z_2 = cz$, $c \in \mathbb{C}$

Преобразование Хафа (Hough)

Задача: объединить участки в линии

Идея:

- 1) минимальная параметризация прямой (θ, d)
- 2) голосование за каждое возможное значение (θ, d)

Детекция прямых на базе RANSAC

RANSAC = Random Sample Consensus

- 1) случайная гипотеза (θ, d - прямая)
- 2) голосование (сколько пикселей поддерживают гипотезу)

Детекция vanishing point

$$v_{ij} = m_i \times m_j$$

m_i, m_j - уравнения прямых: $m_i = (\sin(\theta), \cos(\theta), d)$
координаты vp: $x = v_{ij}^{(1)} / v_{ij}^{(3)}$, $y = v_{ij}^{(2)} / v_{ij}^{(3)}$
Голосование с весом $\|v_{ij}\| l_i l_j$, где l_i, l_j - длины
участков m_i, m_j