Семантическая сегментация

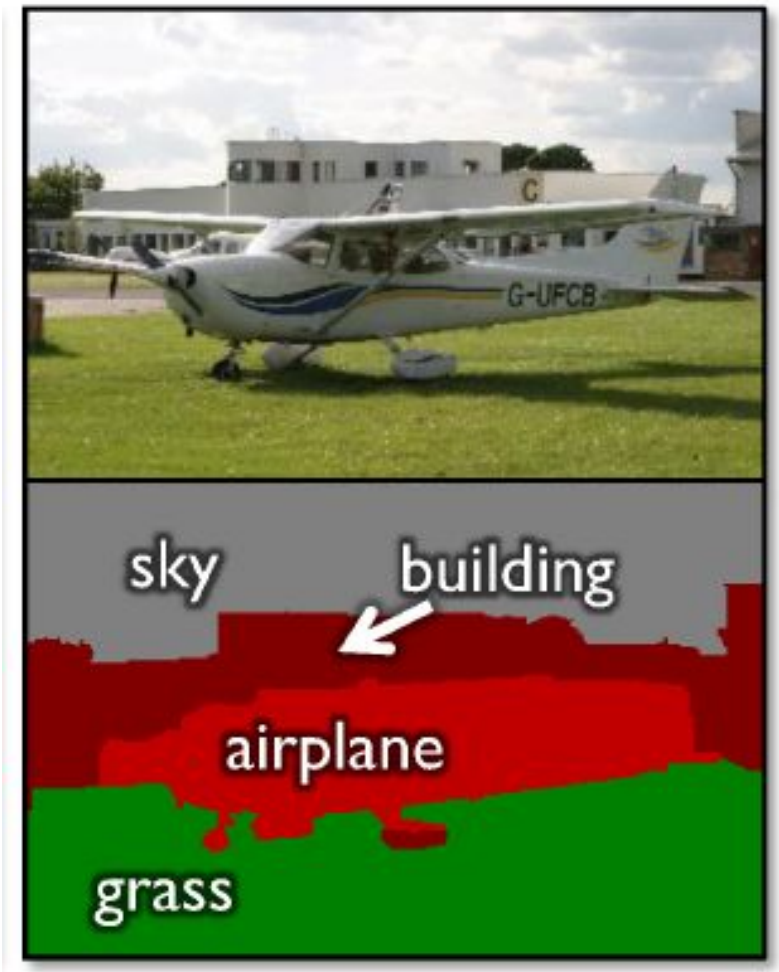

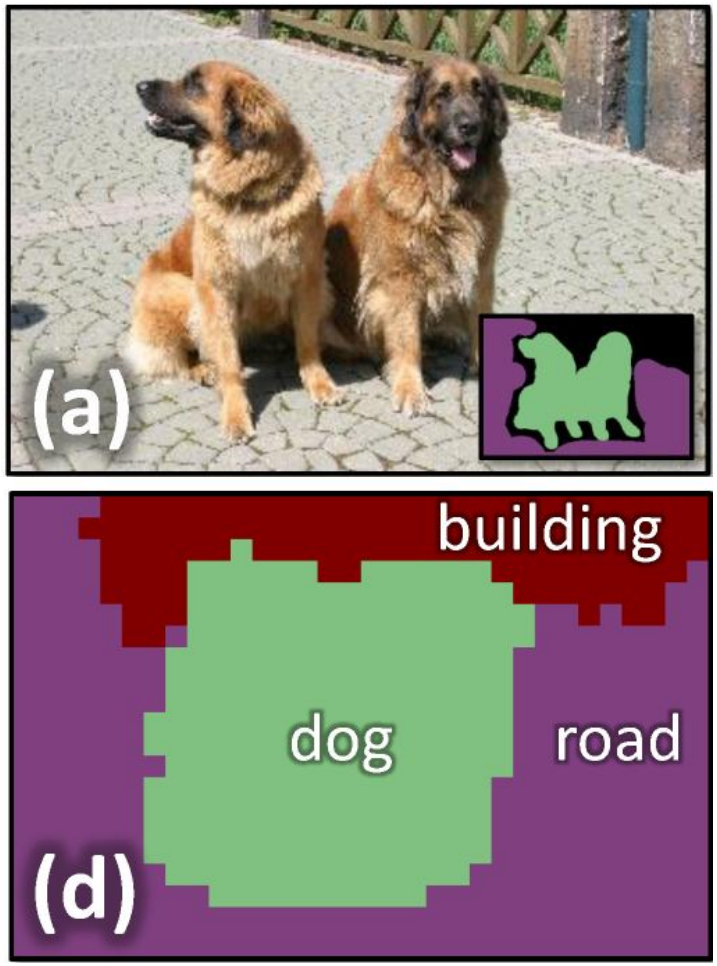

Many slides adapted from Alexei Efros and Daniel Munoz

Наивная классификация

- Нужно классифицировать каждый пиксель
  - 1 МП на картинку!
- Что можно сказать про 1 пиксел?
  - Классификация окрестности пиксела

Наивная классификация

Классифицируем каждый пиксель по окрестности

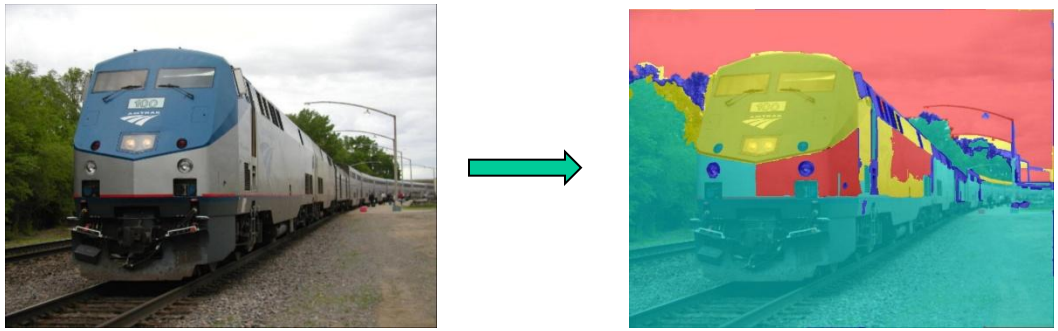

Сегментируем картинку, затем классифицируем сегменты

Пространственная поддержка

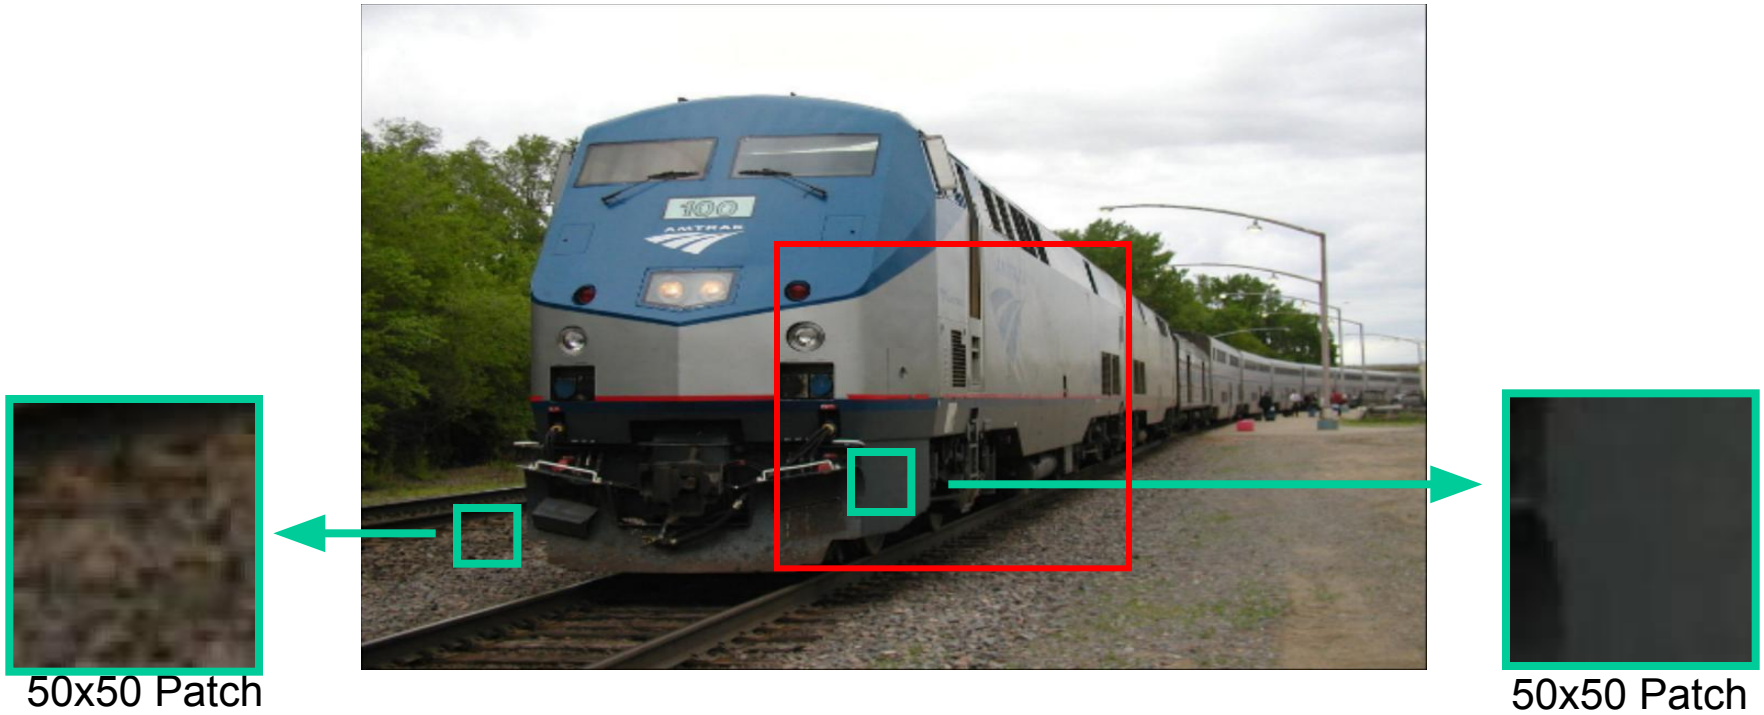

- По небольшой окрестности зачастую невозможно правильно определить метку
- Пространственная поддержка
- Необходимо каким-то образом задавать метки для всех пикселов в совокупности

Построение решения

- Задача / Данные
- Элемент
  - Пиксель
  - Сегмент
- Классификация пикселов / регионов
  - Признаки для классификации
  - Метод классификации (бустинг, лес, SVM)
- Расширение пространственной поддержки
  - Множественные сегментации
  - Случайные поля

Уличные изображения

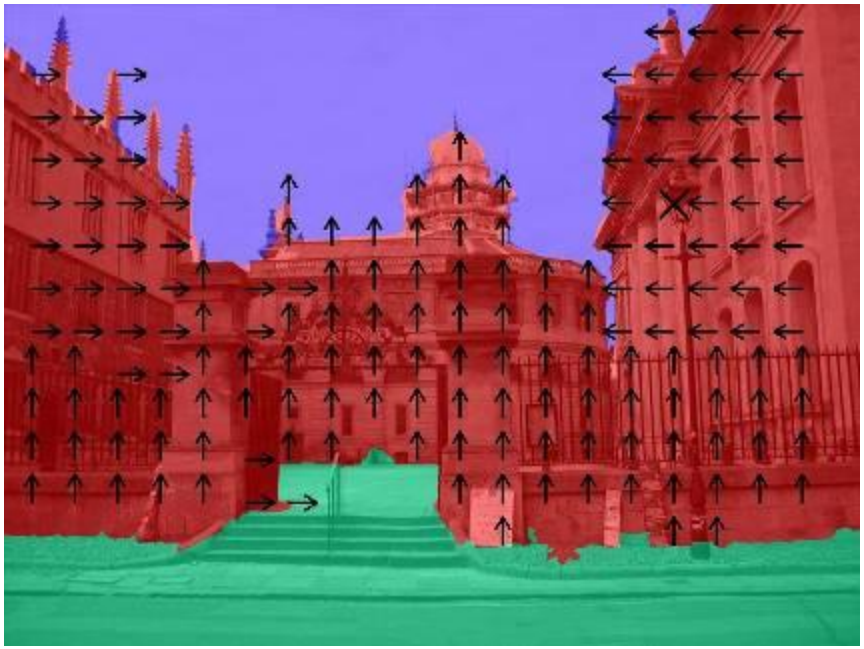

Цель: 7 геометрических классов

- **Земля**
- **Вертикальные стены**
  - Плоскости: смотрящие влево (□), **Прямо** ( ), Направо (□)
  - Другоеr: **Твердые** (**X**), **Дырявые** (**O**)
- **Небо**

Hoiem et al 2005

Размеченные данные

- 300 изображений из гугла

Признаки

Цвет

Текстура

Положение

Перспектива

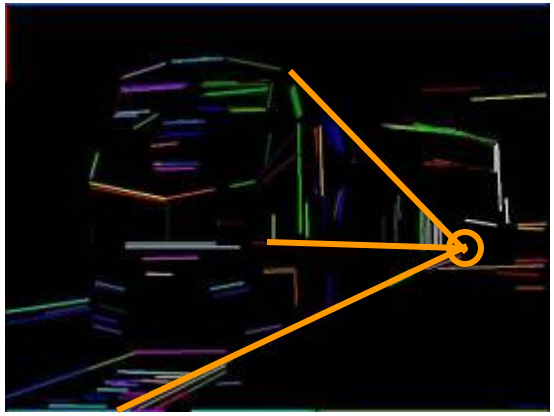

Сегментация изображений

- Использование нескольких вариантов сегментации (с разными параметрами)
- Решение, какие сегменты хорошие, откладывается на потом

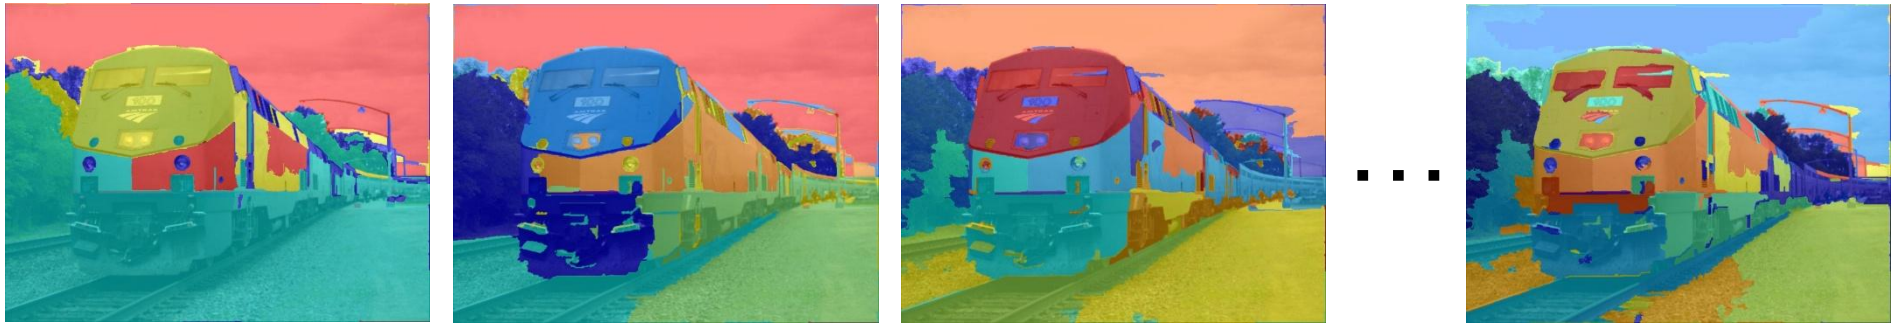

Классификация областей

- Что мы хотим узнать:
  - Хороший ли это сегмент?

    P(*good segment* | *data*)
  - Если сегмент хороший, то какая у него метка?

    P(*label* | *good segment*, *data*)

- Обучаем модель по размеченным данным
  - Бустинг на решающих деревьях

Классификация

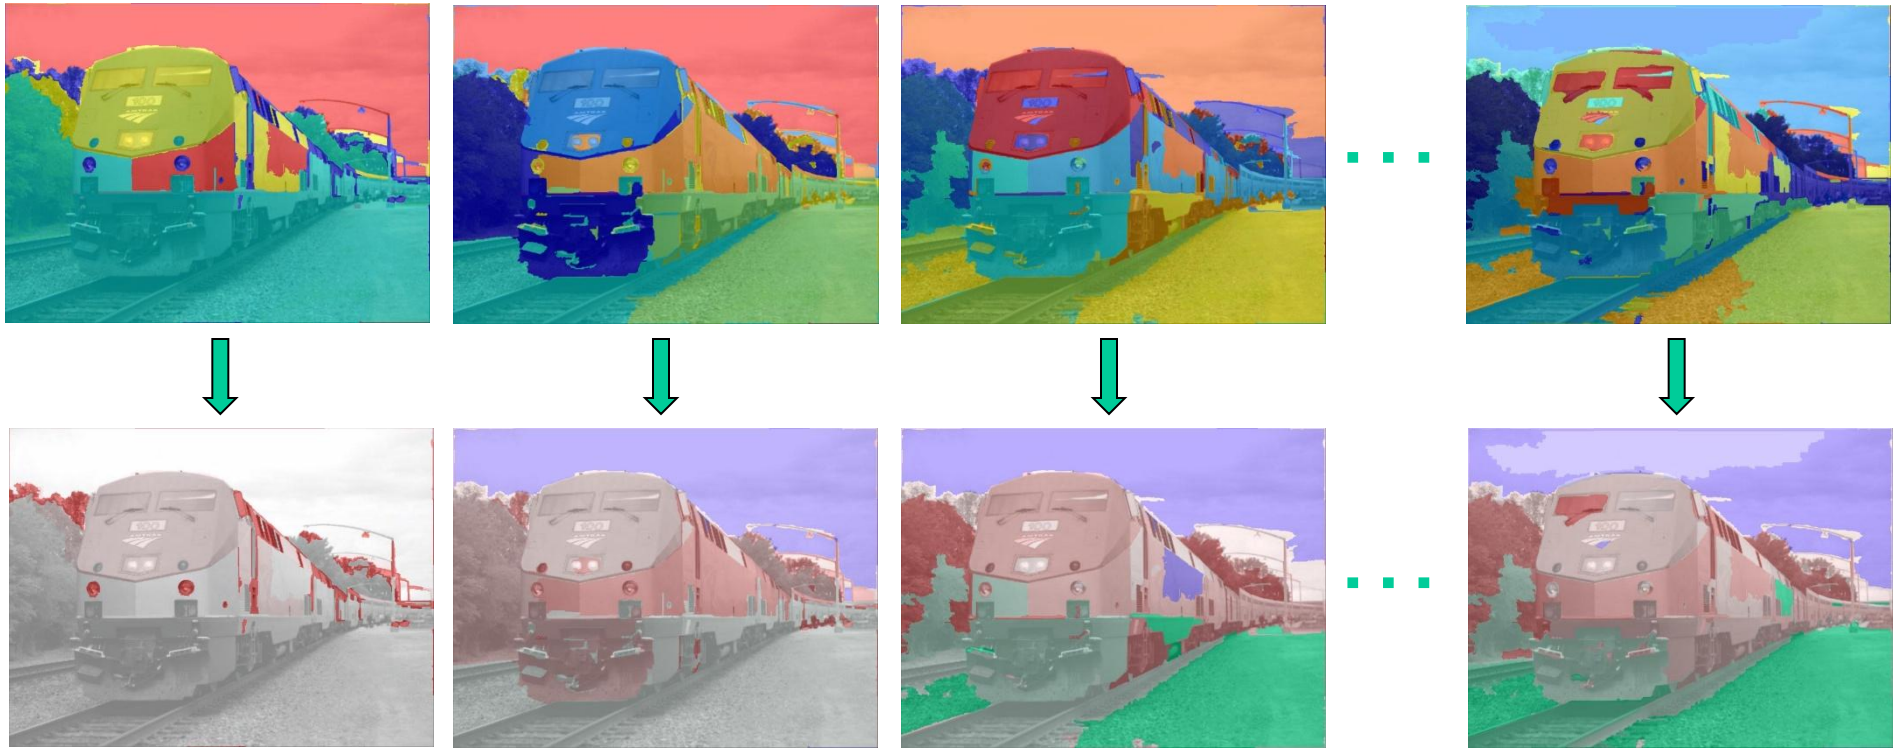

Для каждого сегмента вычисляется:

- P(*good segment* | *data*) P(*label* | *good segment*, *data*)

Разметка изображений

Размеченные сегментации

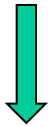

Размеченные пиксели

Вероятностная разметка

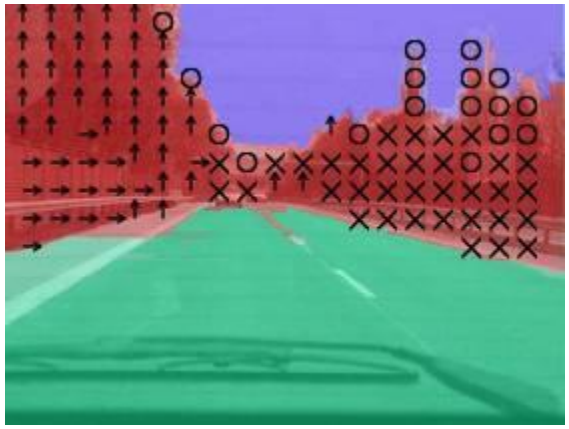

Support Vertical Sky

V-Left V-Center V-Right V-Porous V-Solid

Результат

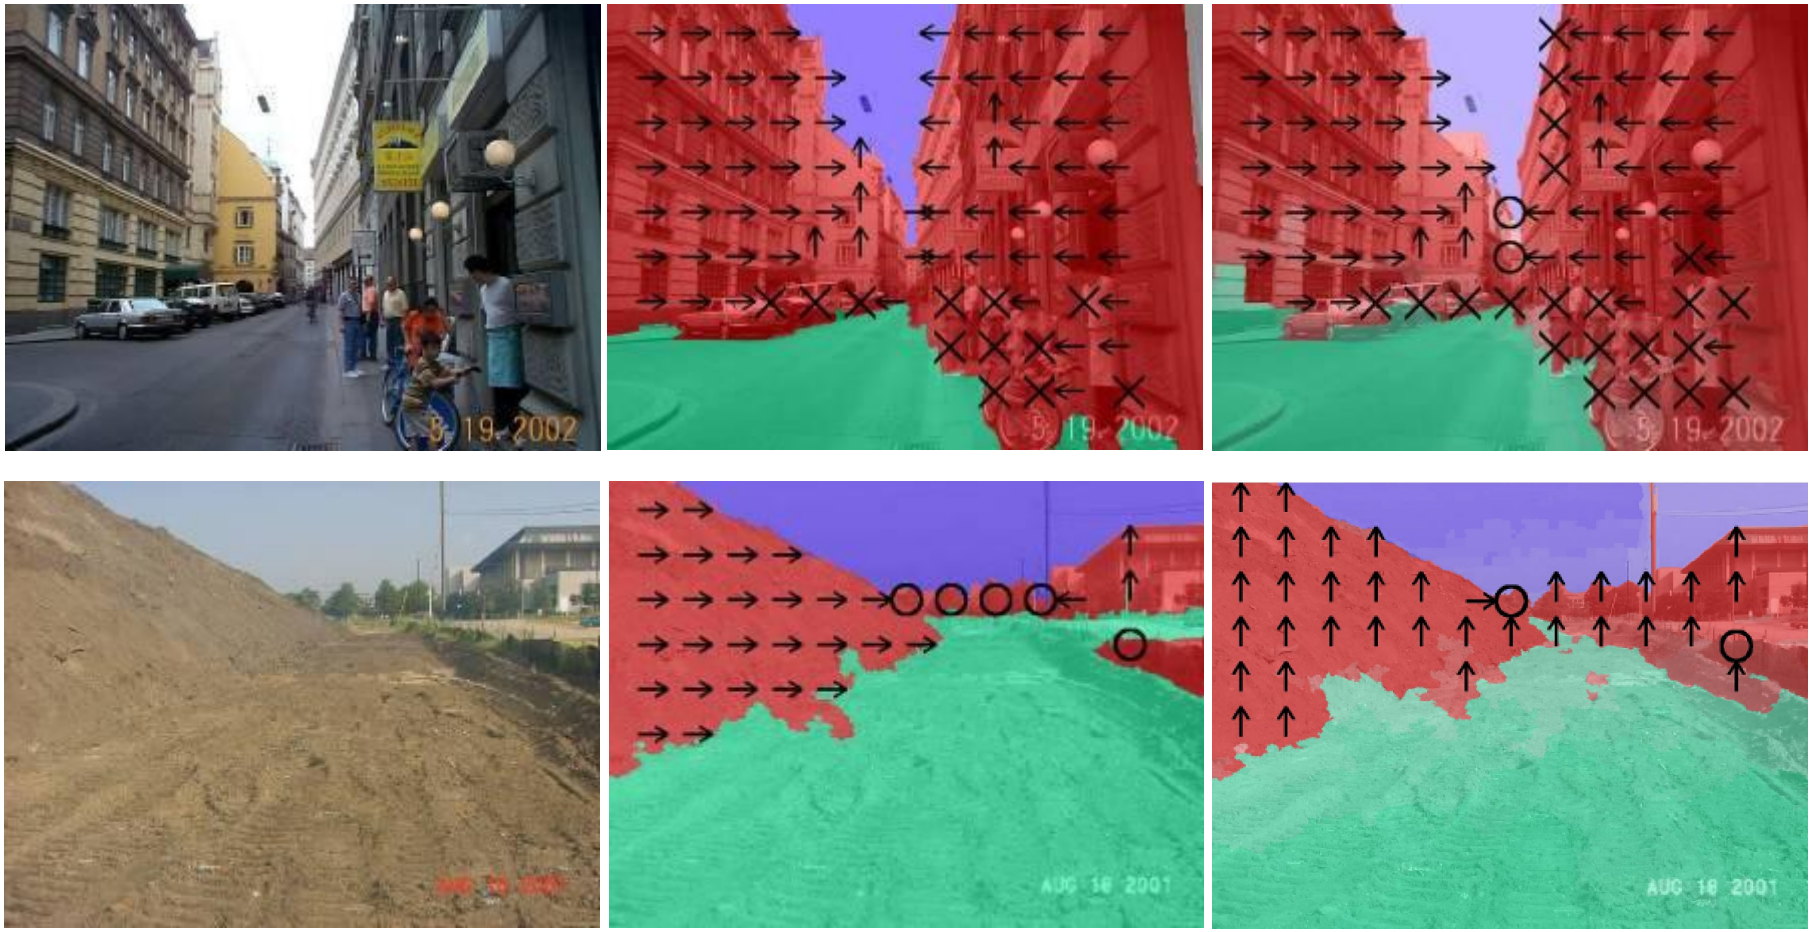

Вход | Ручная разметка | Результат алгоритма

Изображения из помещений

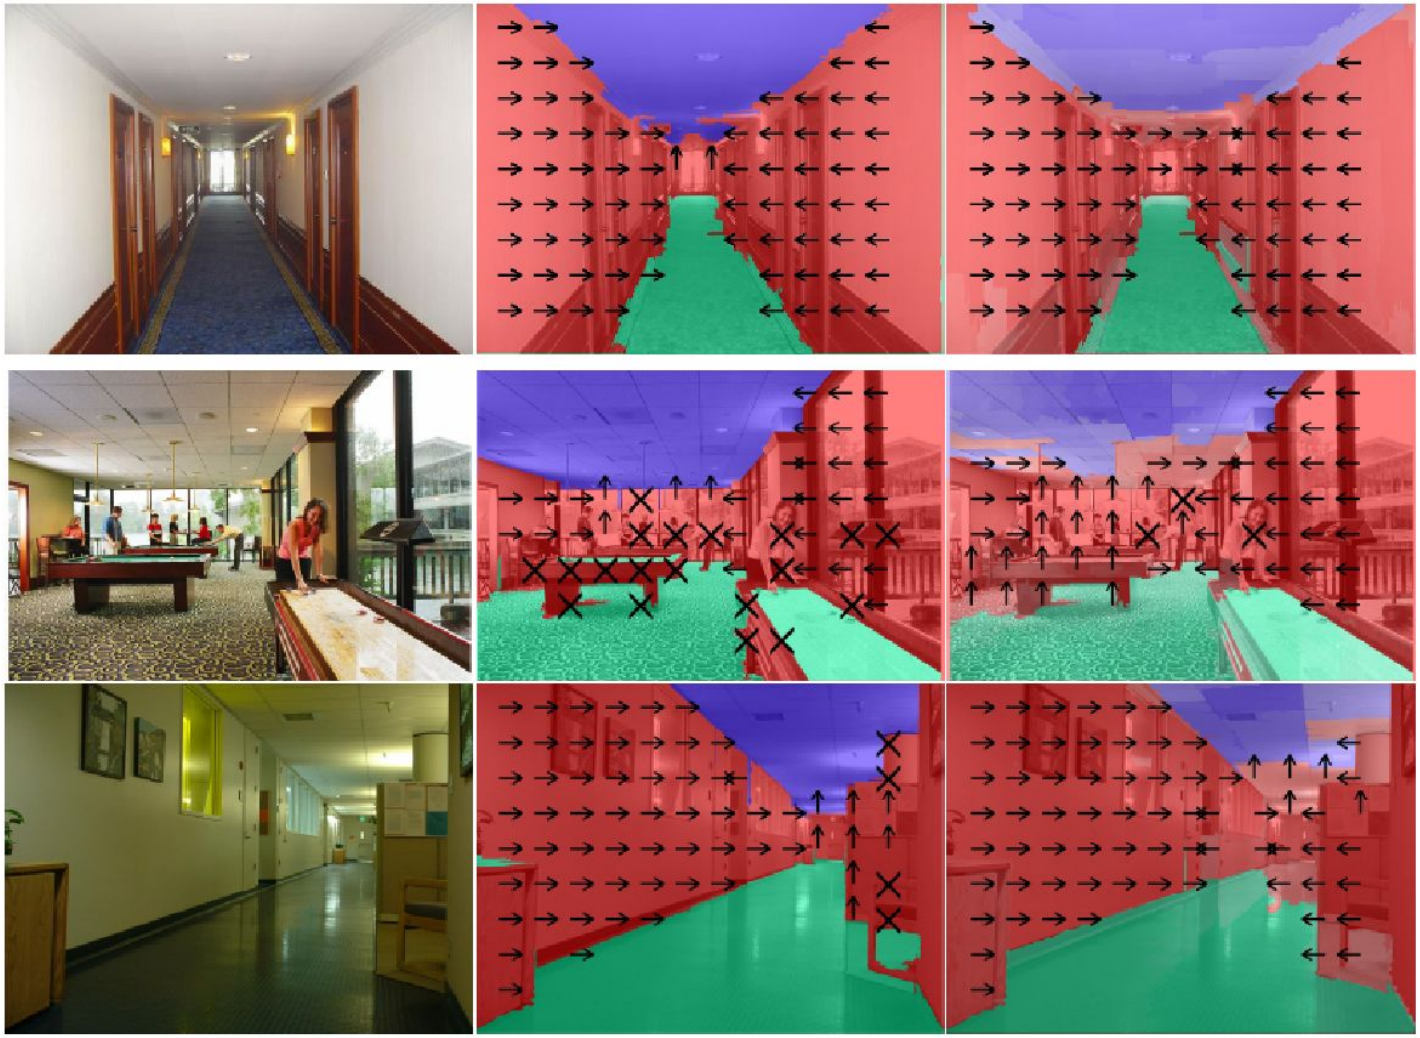

Вход Ручная разметка Результат

Рисунки

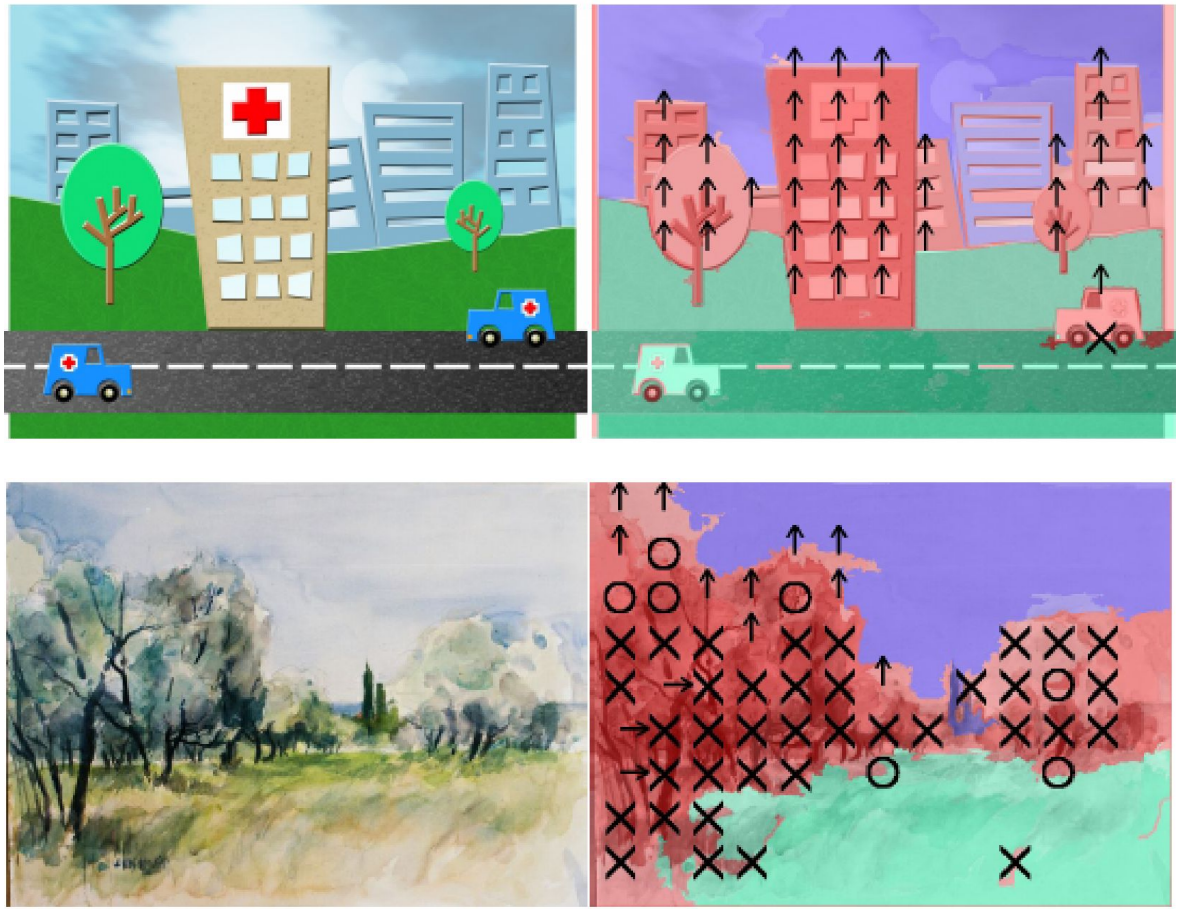

Вход Результат

Приложение: Automatic Photo Pop-up (SIGGRAPH’05)

Изображение

Метки

Нижняя линия

Раскладка

Новый вид

Automatic Photo Pop-up

TextonBoost

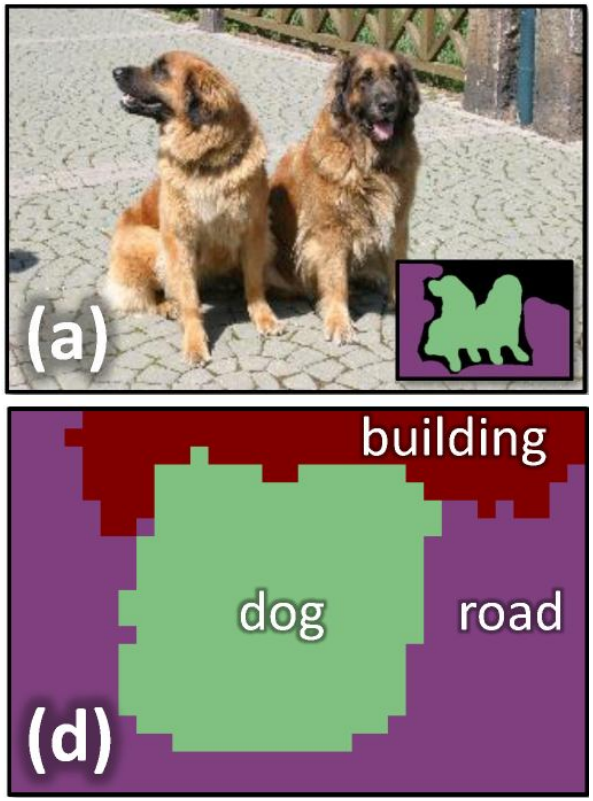

- J. Shotton, J. Winn, C. Rother, A. Criminisi, *TextonBoost: Joint Appearance, Shape and Context Modeling for Multi-Class Object Recognition and Segmentation*, ECCV 2006

Data and Classes

- Goal: assign every pixel to a label

Object classes	Building	Grass	Tree	Cow	Sheep	Sky	Aeroplane	Water	Face	Car
Bike	Flower	Sign	Bird	Book	Chair	Road	Cat	Dog	Body	Boat

- MSRC-21

sting)

Марковские Случайные Поля

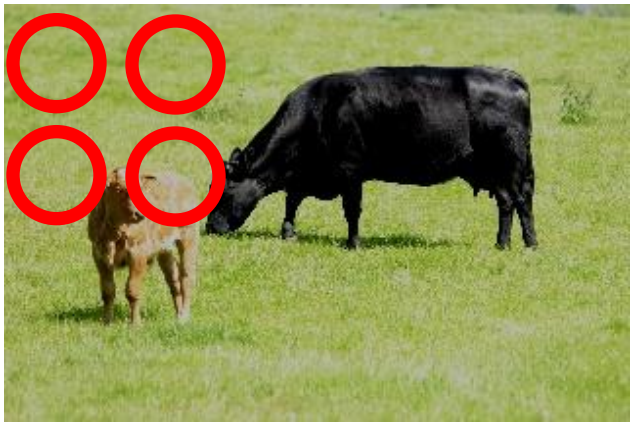

- Независимая классификация
  - Применяем обычный метод классификации (SVM, бустинг и т.д.)

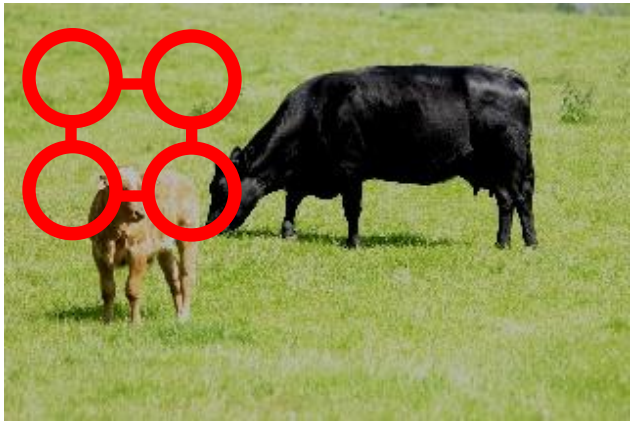

- Схема Марковских Случайных Полей (MRF) для совместной классификации
  - Каждый пиксел – вершина неориентированного графа
  - Связи между пикселами задаются ребрами графа

Условные случайные поля

- МСП для совместной оценки разметки случайных переменных (**c**), при условии всех данных (**x**)

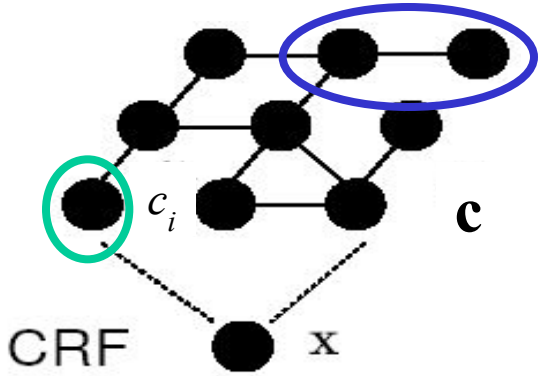

- Модель совместного распределения

$$P(\mathbf{c}|\mathbf{x}, \boldsymbol{\theta}) = \frac{1}{Z(\boldsymbol{\theta})} \prod_{i \in V} \Psi_i^{(1)}(c_i, \mathbf{x}; \boldsymbol{\theta}) \prod_{(i,j) \in E} \Psi_{i,j}^{(2)}(c_i, c_j, \mathbf{x}; \boldsymbol{\theta}) \quad (1)$$

  - $\Psi^{(1)}$ – модель локальной оценки качества метки
  - $\Psi^{(2)}$ - модель попарной оценки качества разметки

Images from Szummer DAR’05

Вывод (Inference)

- Вывод = поиск наилучшей совместной разметки
  - NP-полная задача в общем случае
- Argmax-разметка
  - Попарные потенциалы должны удовлетворять условию субмодулярности
    - Разрезы графов (GraphCuts)
  - Не-субмодулярные потенциалы
    - Quadratic Pseudo-Boolean Optimization (QPBO)
- Разметка с оценкой достоверности
  - Belief Propagation, TRW
  - Приближенное решение при наличии циклов
    - Сложность экспоненциально зависит от размера клики
    - Поэтому в основном рассматриваются модели с кликой не выше 2 (попарные)

Обзор метода

- Модель TextonBoost на основе CRF

$$\log P(\mathbf{c}|\mathbf{x},\boldsymbol{\theta}) = \sum_i \overbrace{\psi_i(c_i,\mathbf{x};\boldsymbol{\theta}_\psi)}^{\text{shape-texture}} + \overbrace{\pi(c_i,\mathbf{x}_i;\boldsymbol{\theta}_\pi)}^{\text{color}} + \overbrace{\lambda(c_i,i;\boldsymbol{\theta}_\lambda)}^{\text{location}}$$

$$+ \sum_{(i,j)\in\mathcal{E}} \overbrace{\phi(c_i,c_j,\mathbf{g}_{ij}(\mathbf{x});\boldsymbol{\theta}_\phi)}^{\text{edge}} - \log Z(\boldsymbol{\theta},\mathbf{x})$$

  - 4-х связанные окрестности
- Параметры обучаются независимо
- Вывод GraphCut

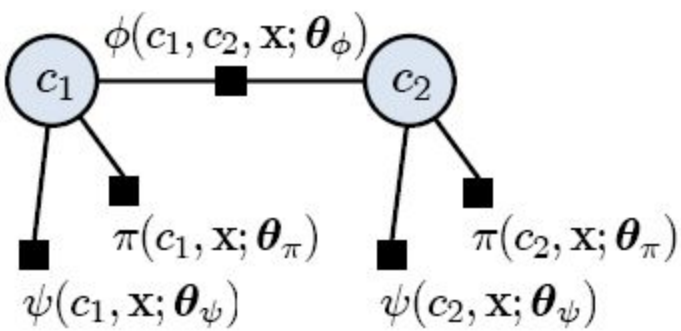

VS

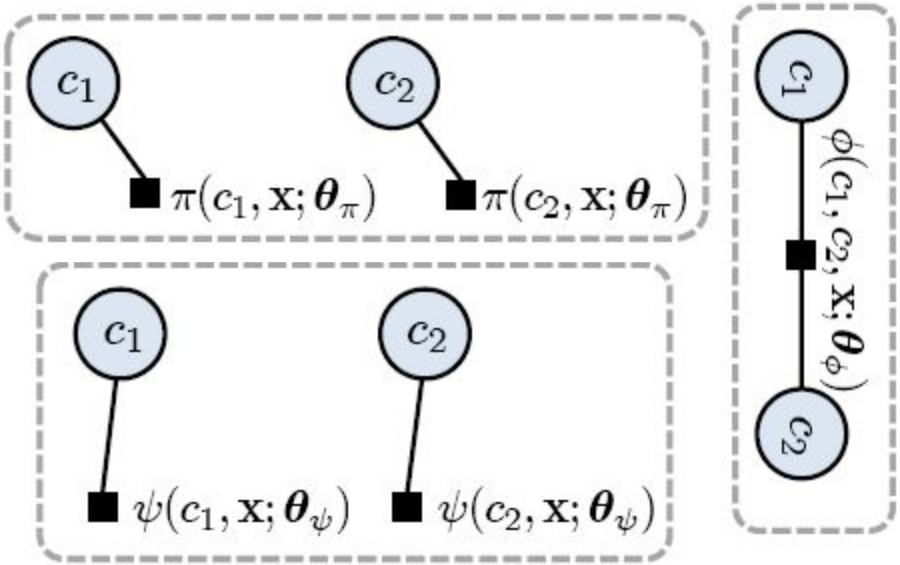

Форма и текстура (Shape & Texture)

- Первая и главная компонента модели

$$\log P(\mathbf{c}|\mathbf{x},\boldsymbol{\theta}) = \sum_i \overbrace{\psi_i(c_i, \mathbf{x}; \boldsymbol{\theta}_\psi)}^{\text{shape-texture}}.$$

- Текстоны

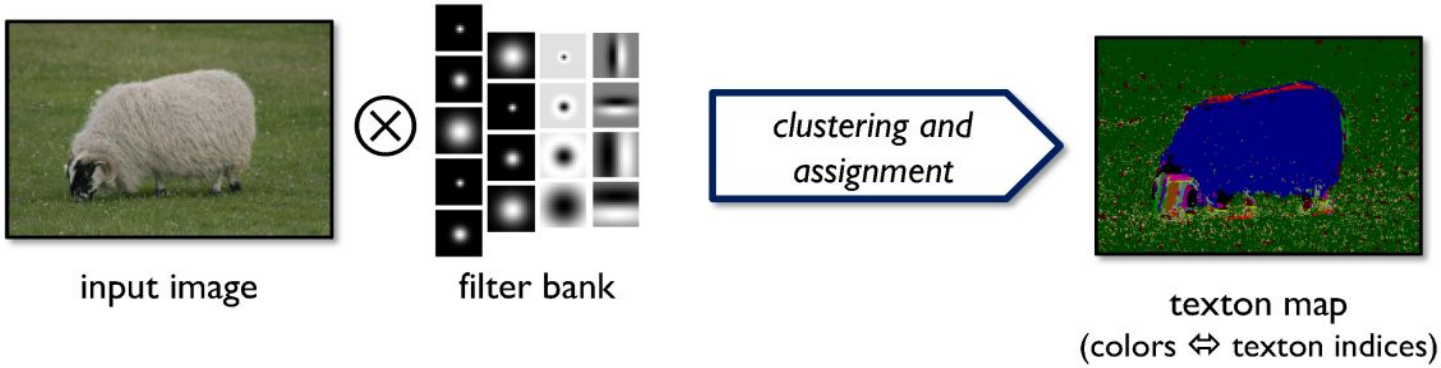

  - Фильтруем изображение банком фильтров (17 фильтров)
  - Каждый фильтр – вычисление определенной характеристики/статистики окрестности точки
  - Получаем 17 признаков для каждого пиксела (вектор-признаки)
  - Кластеризуем список всех вектор-признаков (400 кластеров)
  - Каждые кластер – «текстон»
  - Квантуем каждый пиксель к ближайшему текстону (карта текстонов)

Моделирование формы

- Шаг 1: получили карту текстонов

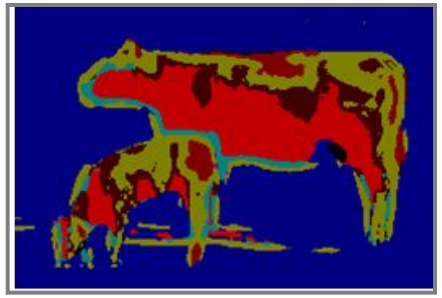

- Шаг 2: Фильтры формы (Shape Filters)
  - Для каждого текстона *t*
    - Вход
      - » Карта текстонов
      - » (Прямоугольная маска *r*, текстон *t*)
      - » Положение пикселя *i*
    - Выход
      - » Площадь в маске r, отвечающая *t*
  - Результат – гистограмма откликов по окрестностям

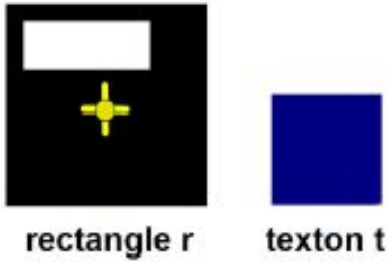

Фильтры формы

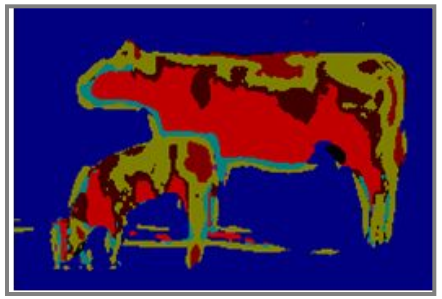

- Пара:

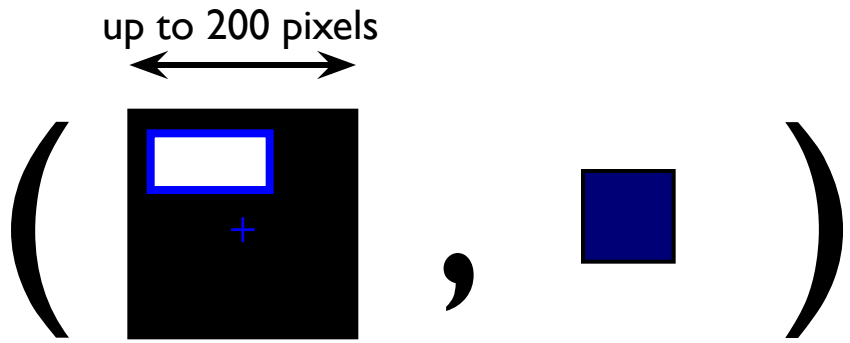

rectangle r texton t

- Отклики $v(i, r, t)$

- Большие области обеспечивают большую пространственную поддержку

- Рассчет через интегральные изображения

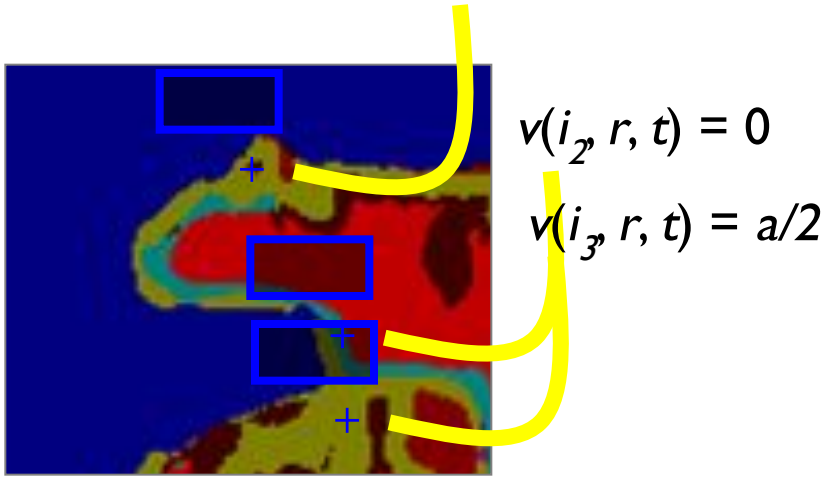

appearance context

Slides from Shotton's ECCV talk

Форма задается положением текстонов

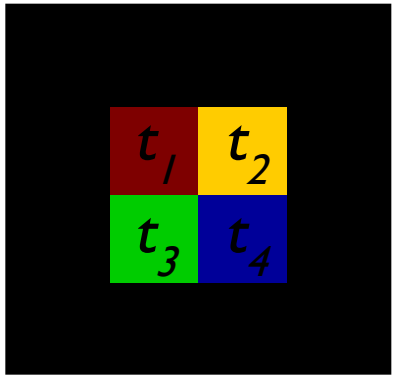

texton map

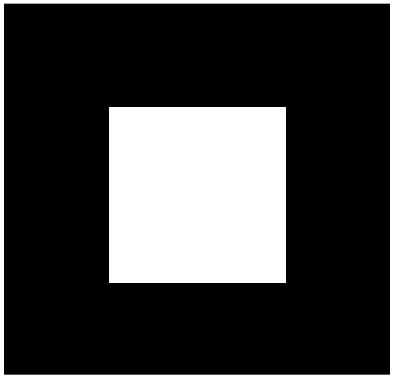

ground truth

$(r_1, t_1) =$

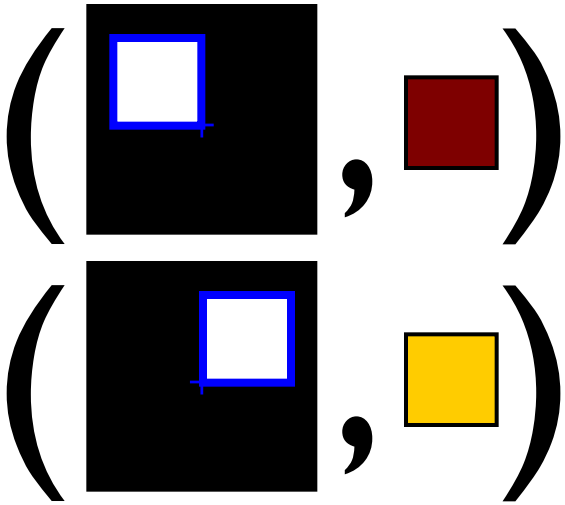

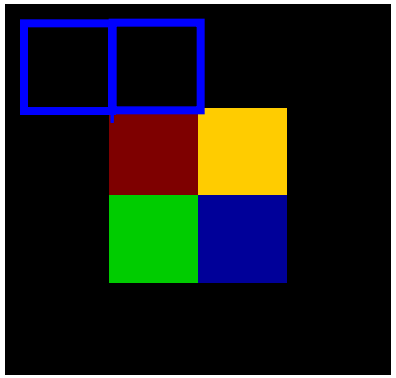

texton map

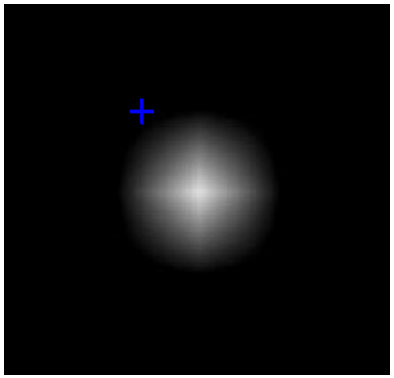

feature response image

$v(i, r_2, t_2)$

Slides from Shotton's ECCV talk

Форма задается положением текстонов

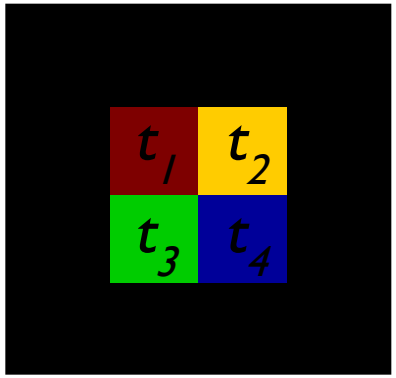

texton map

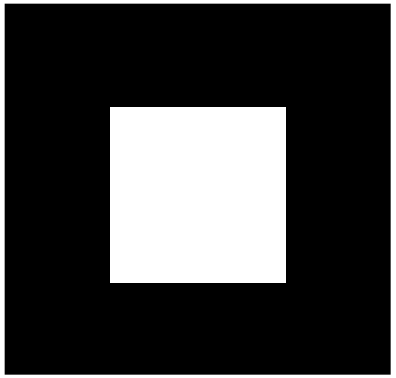

ground truth

$(r_1, t_1) =$

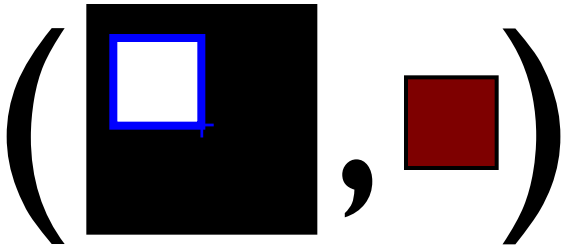

$(r_2, t_2) =$

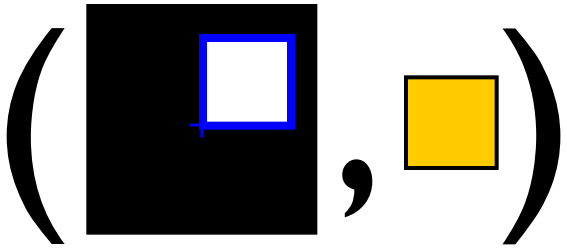

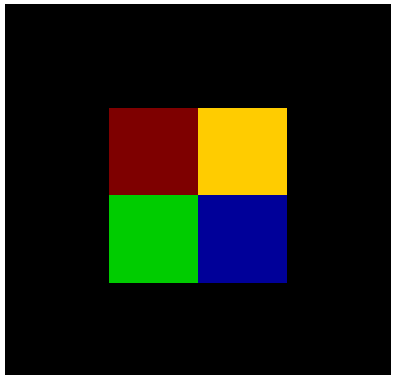

texton map

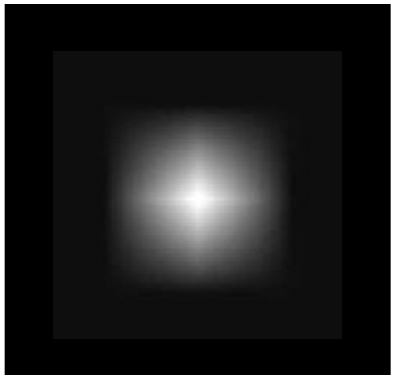

summed response images

$v(i, r_1, t_1) + v(i, r_2, t_2)$

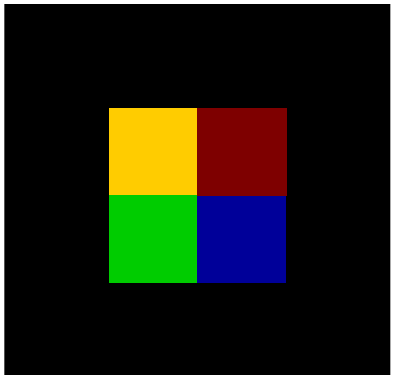

texton map

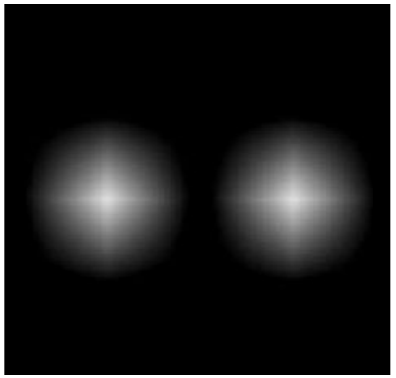

summed response images

$v(i, r_1, t_1) + v(i, r_2, t_2)$

Обучение

- Используется бустинг
- Обычный бустинг
  - Для каждого пикселя
    - Для каждой возможной маски
      - » Для каждого текстона
        - » Считаем признак

$$h(c_i) = \begin{cases} a\delta(v(i,r,t) > \theta) + b & \text{if } c_i \in N \\ k_{c_i} & \text{otherwise} \end{cases}$$

- Ускоренная версия
  - Для каждого пикселя в уменьшенном изображении
    - Для 10 случайных масок
      - » Для каждого текстона (K=400)
        - » Считаем признаки
- 42 часа на 276 изображениях

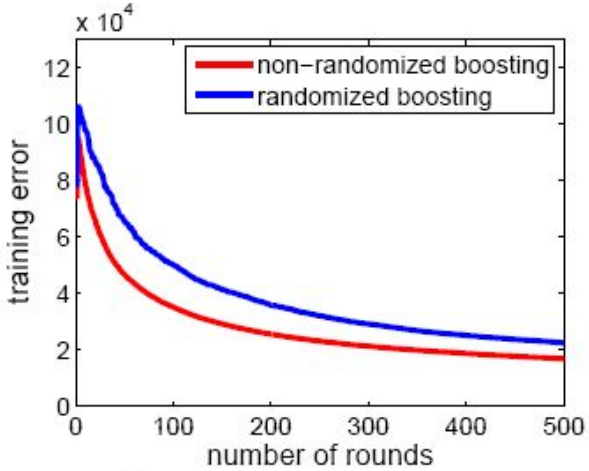

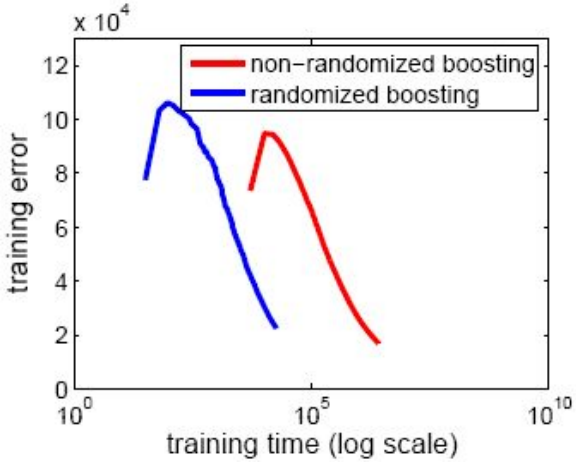

Первый результат

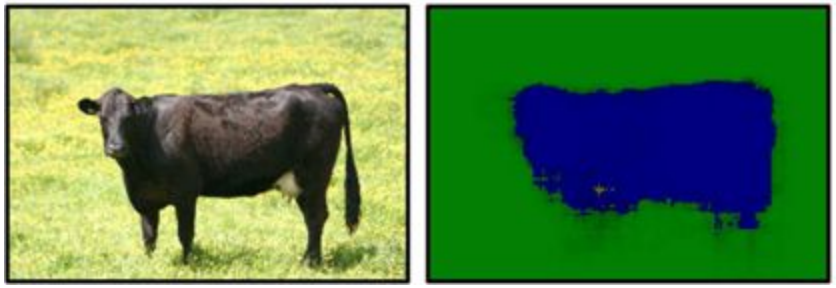

shape-texture

Только форма и текстура: 69.6%

Точность попиксельной сегментации

Slides from Shotton's ECCV talk

Уточняем разметку

- Добавляем границы

$$\log P(\mathbf{c}|\mathbf{x},\boldsymbol{\theta}) = \sum_i \overbrace{\psi_i(c_i,\mathbf{x};\boldsymbol{\theta}_\psi)}^{\text{shape-texture}} + \sum_{(i,j)\in\mathcal{E}} \overbrace{\phi(c_i,c_j,\mathbf{g}_{ij}(\mathbf{x});\boldsymbol{\theta}_\phi)}^{\text{edge}}$$

- **Потенциал границ**
  - Используем попарные потенциалы для определения и г

$$\phi(c_i,c_j,\mathbf{g}_{ij}(\mathbf{x});\boldsymbol{\theta}_\phi) = -\boldsymbol{\theta}_\phi^T \mathbf{g}_{ij}(\mathbf{x})\delta(c_i \neq c_j).$$

$$\mathbf{g}_{ij} = [\exp(-\beta\|x_i - x_j\|^2), 1]^T$$

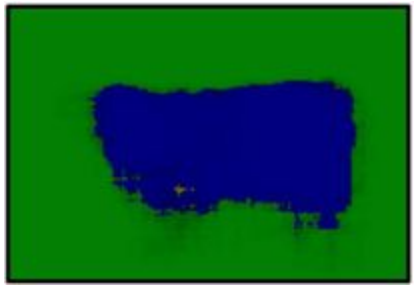

- Идея:
  - Если метки одинаковые, разница пикселей должна быть маленькой
  - Если метки разные, разница пикселей должна быть большой

- Модель Поттса, допускает разрезы графов

Точность

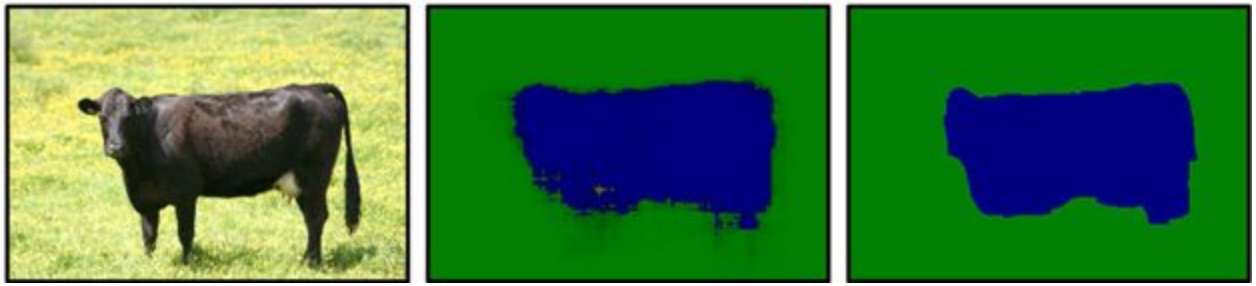

shape-texture + edge

Форма-текстура: 69.6%

+ границы: 70.3%

Точность

Попиксельной

сегментации

Slides from Shotton's ECCV talk

Положение объектов

- **Положение** $\lambda_i(c_i, i; \boldsymbol{\theta}_\lambda) = \log \boldsymbol{\theta}_\lambda(c_i, \hat{i})$
- Нормализуем координаты по всем изображениям
- Посчитываем частоту появления объектов в данной точке изображения

$$\boldsymbol{\theta}_\lambda(c_i, \hat{i}) = \left(\frac{N_{c,\hat{i}} + \alpha_\lambda}{N_{\hat{i}} + \alpha_\lambda} \right)^{w_\lambda}$$

Prevent overfit (tuned)

Think Naïve Bayes

- $N_{cow,}$ = 1, N = 3

Моделирование цвета

- **Цвет** $\overbrace{\pi(c_i, \mathbf{x}_i; \boldsymbol{\theta}_\pi)}^{\text{color}}$
- Обучаем модель цвета только по изображению
- **Идея**
  - Используем классификацию по другим признакам как исходные параметры
  - Обучаем модель смеси гауссиан (кластеризация цветов)
  - Каждый класс – свои веса смеси
  - Обучаем веса итеративным EM-алгоритмом

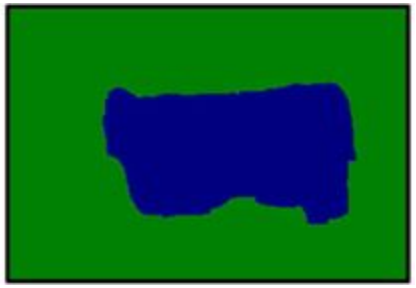

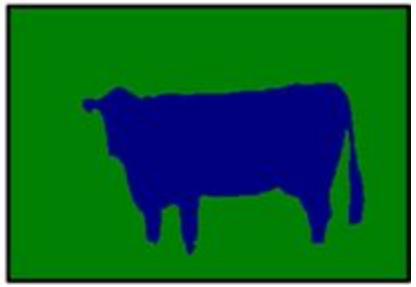

Общий результат

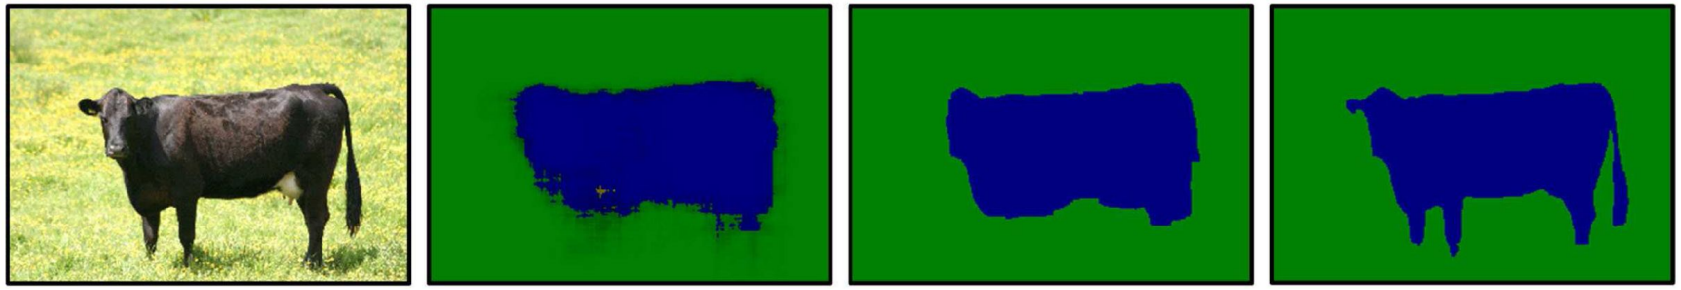

shape-texture + edge + colour & location

Форма и текстура: 69.6%

+ границ: 70.3%

+ цвет: 72.0%

+ положение: 72.2%

Точность ~~Попиксельной~~ сегментации

Slides from Shotton's ECCV talk

Результаты

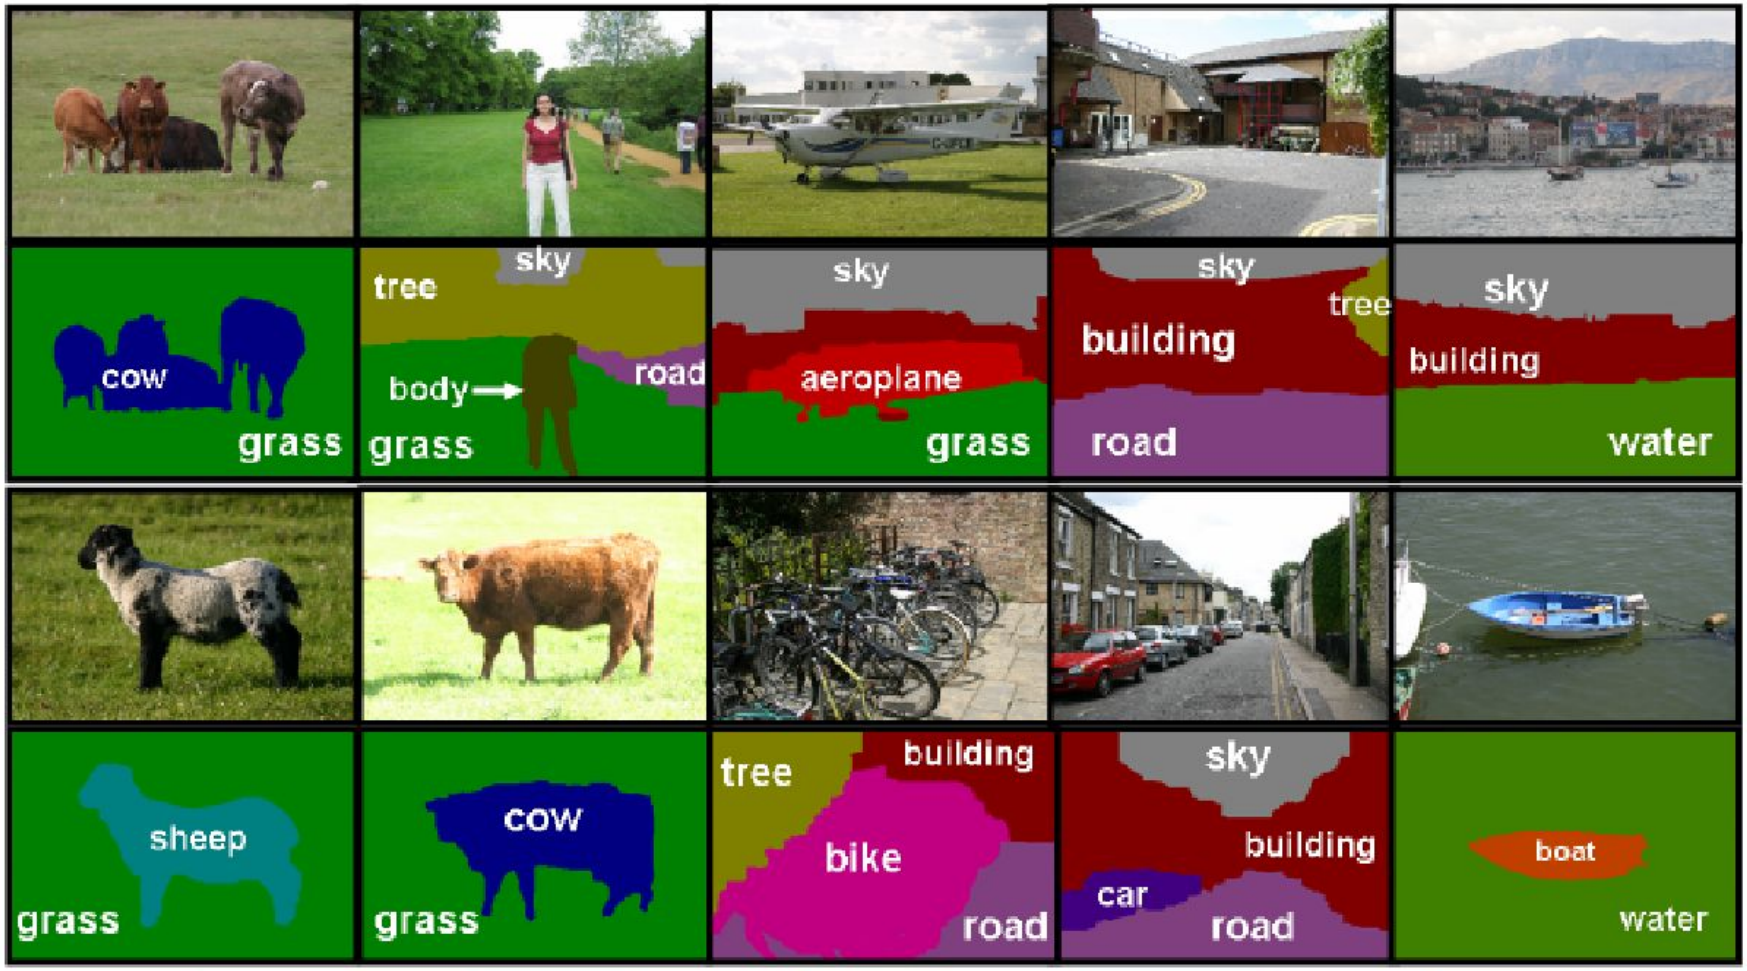

Object classes	Building	Grass	Tree	Cow	Sheep	Sky	Aeroplane	Water	Face	Car
Bike	Flower	Sign	Bird	Book	Chair	Road	Cat	Dog	Body	Boat

Ошибки

sky
cow
grass
sky
tree
water
building
sign
road
dog
road
build
road
bike

Завтра

Сказ о том, как Алеша Ефрос жульничал и грубил в компьютерном зрении за счет Гугла, Яндекса и их пользователей, и на этом прославился