



Лаборатория компьютерной графики и
мультимедиа
ВМК МГУ имени М.В. Ломоносова

Курс «Компьютерное зрение»

Лекция №4
«Задача классификации изображений.
Введение в нейросети»

Антон Конушин и Тимур Мамедов

2025 год

План лекции



1. Задача классификации изображений и датасеты
2. Линейная классификация и перспептрон
3. Свёрточные нейронные сети
4. Ключевой этап: модель AlexNet



1. Задача классификации изображений и датасеты

Бинарная классификация



- Есть ли на этом изображении пешеход?
- Бинарный ответ $y \in [0,1]$, 1 – да, 0 – нет
- Альтернативные формулировки
 - Оценка вероятности положительного ответа $p_{yes} \in [0,1]$
 - Оценки вероятности обоих ответов $p_{yes} \in [0,1]$, $p_{no} \in [0,1]$,
 $p_{yes} + p_{no} = 1$

Многоклассовая классификация



- Какой объект показан на этом изображении?
- Список s классов задан изначально
- Эталонный ответ - метка класса $y \in [1, S]$
- Альтернативный вариант, список оценённых (estimated) вероятностей:
 - $p_i \in [0,1], i = [1, S] \quad , \sum p_i = 1$

Распознавание свойств (атрибутов) объектов



Мужчина

Азиат

Бородат

Улыбается

- Атрибуты – «типичные» характеристики объекта
- Для человека - пол, возраст, раса, борода, усы, улыбка, очки и т.д.
- Можем свести к задачам классификации
 - Определение пола – бинарная классификация
 - Определение расы – многоклассовая классификация
 - Определение возраста – либо классификация (возрастные группы), либо регрессия (определение числового параметра)

Показатели качества («метрики»)



1) % правильно классифицированных изображений

Dataset	CNN	Original	BP[23]	CBP[11]	KP	Others
CUB [43]	VGG-16 [38]	73.1*	84.1	84.3	86.2	82.0 84.1
	ResNet-50 [15]	78.4	N/A	81.6	84.7	[18] [16]
Stanford Car [19]	VGG-16	79.8*	91.3	91.2	92.4	92.6 82.7
	ResNet-50	84.7	N/A	88.6	91.1	[18] [14]
Aircraft [27]	VGG-16	74.1*	84.1	84.1	86.9	80.7
	ResNet-50	79.2	N/A	81.6	85.7	[14]
Food-101 [4]	VGG-16	81.2	82.4	82.4	84.2	50.76
	ResNet-50	82.1	N/A	83.2	85.5	[4]

Table 2. Performance comparisons among all baselines, where KP is the proposed kernel pooling method with learned coefficients. Following the standard experimental setup, we use the input size of 448×448 for CUB, Stanford Car and Aircraft datasets except the original VGG-16 (marked by an asterisk *), which requires a fixed input size of 224×224 . For Food-101, we use the input size of 224×224 for all the baselines.

2) Rank X

- Если классификация многоклассовая, мы ранжируем все выходы по качеству
- Если истинный ответ попадает в первые X выходов, тогда результат считается верным (часто X=5)

Домены данных




- Каждый алгоритм компьютерного зрения разрабатывается для работы с определённой выборкой изображений из некоторого распределения (statistical population) изображений (ещё называется *доменом*)
- Распределение всех «валидных» (для алгоритма) изображений:
 - $img \sim P(I), I \subseteq R^{H \times W \times C}$
- Алгоритмы работают, используя свойства и закономерности в рассматриваемой выборке данных
- Примеры доменов – рентгены лёгких, данные видеонаблюдения, лица людей, и т.д.

CIFAR-10 и CIFAR-100



Выборки из TinyPictures



- **CIFAR-10**
 - 10 классов
 - 60000 изображений
 - 5000 обучающих и 1000 тестовых на класс
- **CIFAR-100**
 - 100 классов
 - 60000 изображений
 - 500 обучающих и 100 тестовых на класс

<http://www.cs.toronto.edu/~kriz/cifar.html>



Цель: собрать коллекцию с 1000 изображений на каждый из 117000 категорий

~14 000 000 изображений (~1 000 000 с аннотацией ограничивающими
прямоугольниками)

~ 22 000 не пустых класса (~10 000 классов с более чем 1000 примерами)

printer housing animal weight drop headquarters egg white
offspring teacher computer album garage down flower television
register measure court key structure light date spread breakfast
gallery horse church press market lighter
king fireplace concert counter restaurant
hotel road paper cup side site door pack
sport screen tree file tower camp fish coffee
sky plant means fan hill arrow bathroom
bread wine fox house school stock film
weapon cover coast file tower railcar
cloud cover means fan hill arrow railcar
spring range leash van suite mirror seat
descent fruit dog bed top man car fly bird
bed shop kit net menu ball flash button
kitchen train memory sieve cell roll sign glass
engine camera box center step
chain boat tea overall sleeve bar watch
dinner stone student stand
apple girl flat ocean
flag bank home room office rule hall
cross chair mine castle
radio support level line street golf
beach library stage video food building
baseball player material machine security call clock
football hospital match equipment cell phone mountain crowd telephone
short circuit bridge scale equipment cell phone mountain crowd telephone
gas pedal microphone recording crowd


The screenshot shows the ImageNet homepage. At the top, there is a navigation bar with links for Home, About, Explore, and Download. Below the navigation bar, a search bar contains the text "14,197,122 images, 21841 synsets indexed". A green "SEARCH" button is to the right of the search bar. Below the search bar, there is a message "Not logged in. Login | Signup". The main content area features a heading "Start exploring here" and a section titled "1-20 of 735 most popular synsets in current ImageNet ([How do we measure popularity?](#))". This section includes three rows of images and their corresponding synset definitions. The first row is for "Synset: people" and includes images of groups of people. The second row is for "Synset: homo, man, human being, human" and includes images of individuals. The third row is for "Synset: child, kid" and includes images of children. Each row has a heading and a "WordNet Structure" link.

Source: <http://image-net.org>

Проблемы с разметкой в ImageNet




mite	container ship	motor scooter	leopard
mite	container ship	motor scooter	leopard
black widow	lifeboat	go-kart	jaguar
cockroach	amphibian	moped	cheetah
tick	fireboat	bumper car	snow leopard
starfish	drilling platform	golfcart	Egyptian cat
grille	mushroom	cherry	Madagascar cat
convertible	agaric	dalmatian	squirrel monkey
grille	mushroom	grape	spider monkey
pickup	jelly fungus	elderberry	titi
beach wagon	gill fungus	ffordshire bullterrier	indri
fire engine	dead-man's-fingers	currant	howler monkey



Пример microwave oven

- Цель – сделать самую большую открытую коллекцию изображений из реальной жизни с разнообразной разметкой
- 9 млн. изображений с лицензией CC BY 2.0
- 59,919,574 меток для 19,957 категорий
- Для тех же изображений есть много других видов разметок, например, локализованные текстовые описания


Fine-graded classification



- Конкретные экземпляры (виды)
в рамках одной категории

Figure 7. Images we used for visual recognition. From left to right, each column contains examples from CUB Bird [43], Stanford Car [19], Aircraft [27] and Food-101 [4].

Как готовить коллекции?



- Mechanical Turk - Automaton Chess Player – робот, игравший в шахматы
 - Автоматон двигает фигуры, говорит «Чек» и обыгрывает всех!
- С 1770 по 1854 развлекал публику, только в 1820 году раскрыли обман

Galaxy Zoo



GALAXY ZOO

<http://www.galaxyzoo.org/>

- Классификация изображений галактик
- Первый масштабный проект такого рода
- Более 150000 волонтёров за первый год бесплатно сделали более 60 млн. меток



Какие объекты присутствуют на картинке?

1 2 3 4 5 6 7 8 9 10


- 1 Светофоры
- 2 Люди
- 3 Машины
- 4 Велосипеды
- 5 Мотоциклы
- 6 Рельсовый
- 7 Ничего

Сделано: 0/10

Для переключения между изображениями используйте кнопки в верхней части экрана или клавиши "←" и "→" на клавиатуре.

Выбор варианта ответа можно сделать с помощью клавиатуры. Клавиши от 1 до 9, соответствующие подсказкам.


Для масштабирования пользуйтесь колёсиком мыши или клавишами "+" и "-".






2. Линейная классификация и перспептрон

Структура мозга человека





Нейросеть

Типичная структура нейрона



Отдельный нейрон


Линейная модель МакКаллока-Питтса



$$a(x, w) = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

- w_i - весовые коэффициенты синаптических связей
- b – bias (иногда w_0 - порог активации)
- $f()$ – функция активации

Нейрон как линейный классификатор




$$a(x, w) = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

x_i положительные: $x_i \cdot w + b \geq 0$
 x_i отрицательные: $x_i \cdot w + b < 0$


- Нейрон с функцией активации sign задаёт бинарный линейный классификатор (гиперплоскость в x)
- «Обучение» нейрона = настройка весов w_j и b
- Настраивать веса линейного классификатора можем по обучающей выборке с использованием градиентного спуска, минимизируя выбранную функцию потерь

Напоминание про градиентный спуск




- Есть функция стоимости от параметров w , нужной найти параметры, при которых она достигает минимума
- Считаем градиент функции с точке начального приближения и сдвигаем w в сторону уменьшения стоимости
- Повторяем до сходимости
- Попадаем в локальный минимум (который может быть глобальным, или нет)


Многоклассовая линейная классификация



Линейный персепtron



Многоклассовая линейная классификация



Функция потерь для многоклассовой классификации



- Categorical cross-entropy loss
- Измеряет близость истинного и оцененного распределения меток

$$L(\hat{y}, y) = - \sum_k^K y^{(k)} \log \hat{y}^{(k)}$$

- Будем интерпретировать выходы (score) как ненормализованный логарифм вероятности и подадим на вход softmax преобразованию



$$x = x_1, \dots, x_k$$
$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}}$$

- После этого получаем метки – оценку вероятности принадлежности классу



Многоклассовая линейная классификация



matrix multiply + bias offset



Представимость функций нейросетями



- Обычный перспептрон и нейрон реализуют линейную классификацию
- А суперпозицией (сетью) нейронов?

Логические элементы







Функции И, ИЛИ, НЕ от бинарных переменных x^1 и x^2 :

$$x^1 \wedge x^2 = \left[x^1 + x^2 - \frac{3}{2} > 0 \right];$$

$$x^1 \vee x^2 = \left[x^1 + x^2 - \frac{1}{2} > 0 \right];$$

$$\neg x^1 = \left[-x^1 + \frac{1}{2} > 0 \right];$$



Исключающее ИЛИ (XOR)



Функция $x^1 \oplus x^2 = [x^1 \neq x^2]$ не реализуема одним нейроном.



Два способа реализации:

- Добавлением нелинейного признака:

$$x^1 \oplus x^2 = [x^1 + x^2 - 2x^1x^2 - \frac{1}{2} > 0];$$

- Сетью (двухслойной суперпозицией) функций И, ИЛИ, НЕ:

$$x^1 \oplus x^2 = [(x^1 \vee x^2) - (x^1 \wedge x^2) - \frac{1}{2} > 0].$$





Утверждение

Любая булева функция представима в виде ДНФ, следовательно, и в виде двухслойной сети.

Решение тринадцатой проблемы Гильберта:

Теорема (Колмогоров, 1957)

Любая непрерывная функция n аргументов на единичном кубе $[0, 1]^n$ представима в виде суперпозиции непрерывных функций одного аргумента и операции сложения:

$$f(x^1, x^2, \dots, x^n) = \sum_{k=1}^{2n+1} h_k \left(\sum_{i=1}^n \varphi_{ik}(x^i) \right),$$



где h_k , φ_{ik} — непрерывные функции, и φ_{ik} не зависят от f .

Представимость функций



- Итого, теоретически доказано, что с помощью линейных операций и одной нелинейной функции активации можно вычислить любую непрерывную функцию с любой желаемой точностью
- Однако из доказательств не следует, как должна быть устроена сеть, сколько в ней должно быть нейронов, какие у них должны быть веса

Задание нейросети




$$x = w_1 f(z_1) + w_2 f(z_2) + w_3 f(z_3)$$

x is called the total input to the neuron, and $f(x)$ is its output

- **Архитектура нейросети** – взвешенный ориентированный граф, в котором вершины – нейроны, ребра – связи
 - Архитектуру обычно задаёт разработчик на основании опыта и «лучших примеров»
 - Архитектуру только недавно начали «учить» (Neural Architecture Search)
- **Веса нейросети** – совокупность весов всех рёбер (веса каждого нейрона)
 - Настройка весов – «обучение» нейросети, для этого предложено несколько подходов

Многослойный персепtron




- Промежуточные слои – «скрытые»
- Если каждый нейрон слоя связан с каждым нейроном предыдущего слоя, то такой слой – **полносвязанный (fully connected)**
- Нейроны скрытых слоёв обычно имеют функцию активации (нелинейную)

Многослойная feed-forward нейросеть




Пусть для общности $Y = \mathbb{R}^M$, для простоты слоёв только два.



- Передача сигналов идёт в одном направлении (feed-forward)
- Сеть можно разделить на «слои нейронов», по числу предшествующих нейронов на пути сигнала



Обучение многослойных нейросетей



- Нейросеть вычисляет дифференцируемую функцию от своих входов
- Можем последовательно применять правило дифференцирования сложных функций для вычисления производных по каждому параметру нейросети
- Метод получил название «обратное распространение ошибки» и имеет длинную историю

• ↑ Галушкин А. И. Синтез многослойных систем распознавания образов. — М.: «Энергия», 1974.


• ↑ Werbos P. J., Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University, Cambridge, MA, 1974.

• ↑ 2 Rumelhart D.E., Hinton G.E., Williams R.J., Learning Internal Representations by Error Propagation. In: Parallel Distributed Processing, vol. 1, pp. 318—362. Cambridge, MA, MIT Press. 1986.

Rowley face detector (1998)



- Метод обратного распространения ошибки оказался очень эффективным
- Пример – детектор лица, лучший до Viola-Jones



B. Rowley, T. Kanade. Neural Network-Based Face Detection. PAMI, 1998.




Свёрточные нейронные сети

Нейросети для обработки картинок



- Персепtron работает с векторами
- Мы хотим обрабатывать изображение, т.е. на вход подавать 3D матрицу $X \in \mathbb{R}^{m \times n \times k}$
- Как должна быть устроена нейросеть, чтобы обрабатывать изображения?


- Мы также хотим учесть знания об обработке изображений в мозге человека и эвристическими методами распознавания
- Края, градиенты и т.д. хорошо помогают!



Простые и сложные клетки визуальной коры



Хубель и Визель (Hubel & Wiesel)



Визуальный стимул






Схема эксперимента




Простые клетки (S) - чувствительны к контрастным объектам определённого размера, ориентации и положения



Сложные клетки (C) -
инвариантны к сдвигам в
небольшой окрестности

Как S и C смоделировать?

Банки текстурных фильтров



- Выберем набор (банк) фильтров, каждый из которых чувствителен к краю определенной ориентации и размера
- Каждый пиксель изображения после обработки банком фильтров даёт вектор признаков
- Этот вектор признаков эффективно описывает локальную текстуру окрестности пикселя

Pietro Perona and Jitendra Malik «Detecting and Localizing edges composed of steps, peaks and roofs», ICCV 1990

Фильтры Габора как модель простых клеток



$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi\frac{x'}{\lambda} + \psi\right)$$

$$x' = x \cos(\theta) + y \sin(\theta)$$

$$y' = -x \sin(\theta) + y \cos(\theta)$$



θ - ориентация

λ - длина волны

σ - сигма гауссиана


γ - соотношение размеров (aspect ratio), «эллиптичность фильтра»

ψ - сдвиг фазы




- 2D фильтр Габора – ядро гауссиана, домноженное на синусоиду
- Предложены в 1947 Денисом Габором (нобелевским лауреатом), независимо переоткрыты в 1980 году
- Позволяет сделать банк фильтров, для выделения краёв разной ориентации, масштаба и положения в окрестности

MAX-pooling как модель сложных клеток




Инвариантность можно обеспечить за счёт применения оператора MAX на выходах набора «простых» клеток, чувствительных к краю одной ориентации, но в разных точках одной области

Свёрточный слой




$$x = w_1 f(z_1) + w_2 f(z_2) + w_3 f(z_3)$$





- Операцию линейной фильтрации (свёртки) для одного пикселя можно реализовать одним нейроном
- Свёртку изображения целиком можно реализовать как «слой» нейронов, веса которых одинаковы (shared weights)
- Обычно под «свёрточным слоем» понимают набор свёрток, применяемых к одному входу («башни фильтров»)

Свёрточный слой




- Мы рассматривали свёртку как операцию над одноканальным 2D изображением, теперь расширим на 3D матрицу
- Обычно под «свёрточным слоем» понимают набор свёрток, применяемых к одному входу («банк фильтров»)
- Результаты свёрток объединяют в один выход $X \in \mathbb{R}^{m \times n \times k}$, где k – число свёрток в слое

Pooling слой




- Можно сделать специальный слой, который реализует операцию max-pooling
- Мы просто применяем операцию тах по выбранным областям (по сетке)
- На вход получаем 3D матрицу, и выдаем 3D матрицу меньшего (обычно) разрешения
- При расчёте градиентов ошибки пробрасываем в тот нейрон предыдущего слоя, который дал тах
- Можем для pooling применять операции max, sum, average, etc.

Neocognitron (1980)




- Многослойная нейросеть с чередующимися S и C слоями
 - S-слои – линейные фильтры изображения («свёрточный слой»)
 - C-слои – MAX операторы, дающие инвариантность
- На верхнем уровне обеспечивается инвариантность по положению по всему изображению

Свёрточные сети




- Неокогнитрон + обратное распространение ошибки = свёрточная сеть (Convolutional Neural Network, CNN)
- Поскольку для сверточного слоя нужно задать параметры только всех свёрток, что число параметров заметно меньше общего числа весов слоя
- Очень эффективная архитектура для распознавания изображений

Подсчёт параметров




- Каковы размеры фильтров свёрток на разных слоях?
 - 5*5*1 на первом слое
 - 5*5*6 на втором свёрточном слое
 - «Глубина» тензора на выходе свёрточного слоя равна числу свёрток в свёрточном слое
 - Зе измерение свёртки равно «толщине» входного тензора
- Число весов и параметров второго слоя:
 - Параметров = 16 свёрток 5x5x6 = $150 \times 16 + 16 = 2416$
 - Весов = (примерно) Параметров $\times 10 \times 10 = 240000$

Фильтры первого уровня



- Визуализируем веса фильтров
- Поскольку сворачиваем RGB изображение, то визуализация весов в RGB
- Обратите внимание на вычисление градиентов цветов

Рецептивное поле (Receptive field)



- Receptive field нейрона – область изображения, от которой зависит выход этого нейрона
- Размер и положения поля определяется глубиной нейрона, размерами свёрток, размерами областей пулинга



4. Ключевой этап: модель AlexNet

Large-scale visual recognition 2012



- LSVR – конкурс на базе датасета ImageNet
- AlexNet вышла победителем конкурса 2012 года
- Ошибка упала в 2 раза по сравнению с соперниками





Car

Winner

SuperVision


Alex Krizhevsky, Ilya Sutskever, Geoffrey Hinton
University of Toronto

SuperVision




- 650,000 neurons
- 60,000,000 parameters
- 630,000,000 connections
- 1 машина, 2 GPU по 2Gb, 5GB Ram, 27Gb HDD, 1 неделя на обучение

Сравнение LeNet и AlexNet



1998 год

- 2 свёрточных слоя (6 и 6 фильтров)
- 2 полно связанных (120 и 84 нейрона)




2012 год

- 5 свёрточных слоёв (96, 256, 384, 384, 256 фильтров)
- 2 полно связанных (4096 и 4096 нейрона)


- Больше слоёв, фильтров, нейронов
- Какие ещё изменения произошли между LeNet и AlexNet?

Важные замечания по AlexNet vs LeNet




- Больше данных для обучения (ImageNet)
- Вычислительные мощности для обучения (GPU)
- Активация ReLU
- Аугментации изображений
- Регуляризация dropout

Переобучение



- Чем сложнее задача – тем более сложная нейросеть нужна
- Но параметров нейросети очень много, и нейросеть быстро «переобучалась»
- Происходило «запоминание» всей обучающей выборки без её «обобщения»

«Интернет-бум» + «Закон Мура»



ФУНКЦИИ АКТИВАЦИИ



- **Tanh**




- $\tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}$

- **Sigmoid:**

- $\text{sigm}(x) = \frac{1}{1+e^{-x}}$ - преобразует все значения в интервал $[0,1]$

- **Rectified linear**


- $\text{ReLU}(x) = \max(0, x)$




Проблемы обучения



- «Затухание» (saturation) градиентов, если попадаем на область низкого градиента функции активации
 - Sigmoid очень страдает от этого
 - ReLU не страдает
- «Мёртвые» (dead) нейроны, которые, так получилось, получают только отрицательные или нулевые входы
- Исчезающие или взрывные градиенты (vanishing or exploding gradients) в глубоких сетях



Важно - размножение данных





- «Data augmentation»
- Борьба с переобучением
- Из 256x256 случайно выбираем фрагменты 224x224 и их отражения
- Добавляем цветовые искажения

Варианты размножения данных



Небольшие сдвиги, отображения, повороты,
изменения масштаба

Dropout



- Отключаем половину нейронов в каждом слое
- Получаем случайную выборку из множества сетей
- Во время тестирования используем «среднюю» сеть с уполовиненными весами

Nitish Srivastava Improving Neural Networks with Dropout.
Master Thesis, 2013



- Рассмотрели постановку задачи классификации, примеры датасетов и как их собирать
- Основной способ решения задачи классификации изображений – свёрточные нейросети
- Концептуально нейросети остались такими же, как в 1990х, но было предложено множество относительно небольших изменений, которые в совокупности с ростом доступных данных позволили сети эффективно обучать