

# Нейронные сети

Лабораторные работы

Единый сборник описаний лабораторных работ

## Содержание

01-lab-01. Равномерная аппроксимация на компакте .....	4
02-lab-01. Формальный нейрон и функции активации .....	6
03-lab-01. Итерационные вычисления на графе .....	9
04-lab-01. Функции эмпирического риска .....	12
05-lab-01. Ручное обучение простой нейросети .....	15
06-lab-01. Автоматическое дифференцирование через Value .....	18
07-lab-01. Траектории практических градиентных методов .....	21
08-lab-01. Настройка обучения .....	22
09-lab-01. Стандартные блоки нейросетей .....	23
10-lab-01. Регуляризация и переобучение .....	24
11-lab-01. Обучение без учителя .....	25
12-lab-01. Сверточные сети для изображений .....	26
13-lab-01. Рекуррентные сети .....	27
14-lab-01. Трансформеры и самовнимание .....	28
15-lab-01. Q-обучение .....	29
16-lab-01. Прямой процесс диффузии .....	30
17-lab-01. Байесовское предсказание .....	31

## **Вводная часть**

Данный файл не является самостоятельной частью практической составляющей курса «Нейронные сети». Актуальная навигация по материалам курса ведется через сайт дисциплины: <https://gitverse.ru/gurgutan/nn-site>. Текст сборника «Нейронные сети. Лабораторные работы» не является самостоятельным учебным материалом. Он предназначен только для того, чтобы в одном файле собрать описания работ для удобной навигации по ним и создания комплекта документов по учебной дисциплине.

## 01-lab-01. Равномерная аппроксимация на компакте

### Цель

Научиться воспроизводить вычислительный пример аппроксимации непрерывной функции на компакте и наблюдать, как максимальная ошибка меняется при увеличении степени аппроксимирующего семейства.

### Материал лекции

Лабораторная относится к лекции 1 «Основные теоремы нейронной информатики» и опирается на понятия:

1. компакт;
2. непрерывная функция;
3. равномерная аппроксимация;
4. максимальная ошибка на сетке;
5. переход от теоремы существования к вычислительному наблюдению.

В лабораторной не требуется строить нейронную сеть или обучать модель.

### Состав шаблона

Файлы лабораторной находятся в текущем каталоге:

1. **lab.py** - основной блокнот в виде .py-файла с ячейками # %% ;
2. **results/** - каталог, который создается автоматически после запуска.

### Команда запуска блокнота

Откройте lab.py в редакторе, который поддерживает запуск ячеек # %% , и выполните ячейки сверху вниз.

Для проверки всего файла как обычного скрипта можно выполнить:

```
uv run python lab.py
```

### Структура ячеек блокнота

1. **Постановка опыта** - объясняет цель и показывает каталог результатов.
2. **Параметры опыта** - задает функцию, степени многочленов и размер сетки.
3. **Целевые функции** - показывает доступные непрерывные функции на  $[0, 1]$ .
4. **Подготовительное вычисление** - вычисляет значение многочлена Бернштейна в одной точке.
5. **Таблица ошибок на сетке** - выводит максимальные ошибки для выбранных степеней.
6. **Задание** - предлагает изменить параметры опыта.
7. **Проверка выбранного варианта** - пересчитывает таблицу для измененных параметров.

8. **Визуализация выбранного варианта** - строит график выбранной функции и лучшей аппроксимации.
9. **Финальный артефакт** - сохраняет файлы результата.

### Параметры, которые нужно изменить

В ячейке **Задание** разрешается изменить:

1. **SELECTED\_TARGET\_NAME** - имя функции из словаря шаблона;
2. **SELECTED\_DEGREES** - список степеней аппроксимирующего многочлена;
3. **SELECTED\_GRID\_SIZE** - число точек сетки для оценки максимальной ошибки.

### Шаги воспроизведения

1. Откройте `./Lab.py`.
2. Выполните подготовительные ячейки сверху вниз без изменений.
3. Посмотрите таблицу ошибок и график аппроксимации.
4. В ячейке **Задание** измените функцию, степени или размер сетки.
5. Выполните ячейки **Проверка выбранного варианта** и **Финальный артефакт**.
6. Сравните лучшую ошибку базового и измененного вариантов.

### Что нужно сдать

1. `approximation_errors.csv`
2. `approximation_summary.json`
3. `bernstein_approximation.png`

### Формат результата

Файл `approximation_errors.csv` должен содержать столбцы:

```
target,degree,grid_size,max_abs_error
```

Файл `approximation_summary.json` должен содержать поля:

```
{
  "target": "sin_pi",
  "best_degree": 0,
  "best_max_abs_error": 0.0,
  "grid_size": 0
}
```

### Критерии проверки

1. Оба файла результата существуют.
2. В CSV есть строка для каждой степени из **DEGREES**.
3. Значение **best\_degree** в JSON соответствует строке с минимальной ошибкой в CSV.
4. Значения ошибок неотрицательны.
5. PNG-файл с графиком существует и открывается как изображение.

## 02-lab-01. Формальный нейрон и функции активации

### Цель

Научиться наблюдать графики стандартного формального нейрона  $y=f(\mathbf{w}\mathbf{x}+\mathbf{b})$  для разных функций активации и визуализировать соединение двух нейронов через бинарную матрицу как ориентированный граф.

### Материал лекции

Лабораторная относится к лекции 2 «Формальное описание искусственных нейронных сетей» и опирается на понятия:

1. стандартный формальный нейрон;
2. входной вектор;
3. вектор весов;
4. смещение;
5. функция активации;
6. матрица связи между выходами и входами.
7. граф соединений нейронов.

В лабораторной не требуется обучать веса или строить многослойную сеть.

### Состав шаблона

Файлы лабораторной находятся в текущем каталоге:

1. **lab.py** - основной блокнот в виде .py-файла с ячейками # %% ;
2. **results/** - каталог, который создается автоматически после запуска.

### Команда запуска блокнота

Откройте lab.py в редакторе, который поддерживает запуск ячеек # %% , и выполните ячейки сверху вниз.

Для проверки всего файла как обычного скрипта можно выполнить:

```
uv run python lab.py
```

### Структура ячеек блокнота

1. **Постановка опыта** - связывает формальный нейрон и бинарную матрицу связей.
2. **Параметры нейрона** - задает вес, смещение и интервал входов.
3. **Функции активации** - вводит ReLU, sigmoid, tanh и Gaussian.
4. **Таблица значений стандартного нейрона** - вычисляет  $\mathbf{z}=\mathbf{w}\mathbf{x}+\mathbf{b}$  и  $\mathbf{y}=\mathbf{f}(\mathbf{z})$  на сетке.
5. **График функций активации нейрона** - строит четыре кривые  $\mathbf{y}=\mathbf{f}(\mathbf{w}\mathbf{x}+\mathbf{b})$ .
6. **Бинарная матрица соединения двух нейронов** - задает два исходных и два следующих нейрона.

7. **Значения, переданные через матрицу** - вычисляет входы следующего слоя.
8. **Визуализация графа соединения** - строит ориентированный граф через `networkx`.
9. **Задание** - предлагает изменить вес, смещение или бинарную матрицу.
10. **Проверка выбранного варианта** - пересчитывает кривые и переданные значения.
11. **Визуализация выбранного варианта** - строит графики и graph-схему для выбранных параметров.
12. **Финальный артефакт** - сохраняет файлы результата.

### Параметры, которые нужно изменить

В ячейке **Задание** разрешается изменить:

1. `SELECTED_WEIGHT` - вес стандартного формального нейрона;
2. `SELECTED_BIAS` - смещение стандартного формального нейрона;
3. `SELECTED_CONNECTION_MATRIX` - бинарную матрицу связей;
4. `SELECTED_SOURCE_OUTPUTS` - вектор исходных выходов.

Функции активации ReLU, sigmoid, tanh и Gaussian уже заданы в шаблоне.

### Шаги воспроизведения

1. Откройте `.lab.py`.
2. Выполните подготовительные ячейки сверху вниз без изменений.
3. Посмотрите график четырех функций активации стандартного нейрона.
4. Посмотрите graph-визуализацию бинарной матрицы соединения двух нейронов.
5. В ячейке **Задание** измените вес, смещение или матрицу связей.
6. Выполните ячейки **Проверка выбранного варианта**, **Визуализация выбранного варианта** и **Финальный артефакт**.
7. Сравните, как изменились кривые активаций, дуги графа и численные входы следующего слоя.

### Что нужно сдать

1. `activation_curves.csv`
2. `connection_result.csv`
3. `lab_summary.json`
4. `selected_activation_curves.png`
5. `selected_binary_connection_graph.png`

### Формат результата

Файл `activation_curves.csv` должен содержать столбцы:

`activation,x,z,y`

Файл `connection_result.csv` должен содержать столбцы:

`target_neuron,value`

Файл **lab\_summary.json** должен содержать вес, смещение, список функций активации, размер матрицы связи и число дуг графа.

#### **Критерии проверки**

1. Все файлы результата существуют.
2. В CSV **activation\_curves.csv** есть строки для ReLU, sigmoid, tanh и Gaussian.
3. Значения **x**, **z** и **y** являются числами.
4. Число строк в **connection\_result.csv** равно числу следующих нейронов.
5. PNG-файл **selected\_activation\_curves.png** показывает четыре функции активации.
6. PNG-файл **selected\_binary\_connection\_graph.png** показывает граф соединения двух нейронов через бинарную матрицу.

## 03-lab-01. Итерационные вычисления на графе

### Цель

Научиться строить граф вычислений по матрице смежности, приписывать дугам веса, приписывать вершинам функции нейронов и выполнять несколько итераций вычислений на графе.

### Материал лекции

Лабораторная относится к лекции 3 «Вычисления на графе» и опирается на понятия:

1. ориентированный граф;
2. матрица смежности;
3. веса дуг;
4. один шаг вычислений  $x = y A$ ;
5. рациональная сигмоида;
6. итерационная схема  $y^{(n)} = f(y^{(n-1)} A)$ .

### Состав шаблона

Файлы лабораторной находятся в текущем каталоге:

1. **lab.py** - основной блокнот в виде .py-файла с ячейками # %% ;
2. **results/** - каталог, который создается автоматически после запуска.

### Команда запуска блокнота

Откройте lab.py в редакторе, который поддерживает запуск ячеек # %% , и выполните ячейки сверху вниз.

Для проверки всего файла как обычного скрипта можно выполнить:

```
uv run python lab.py
```

### Структура ячеек блокнота

1. **Постановка опыта** - объясняет вычисления на графе.
2. **Матрица смежности вершин** - задает ориентированные дуги.
3. **Веса дуг** - приписывает дугам численные веса.
4. **Функции нейронов в вершинах** - задает функцию каждой вершины.
5. **Проверка согласованности матриц** - проверяет, что веса заданы только для существующих дуг.
6. **Визуализация графа с весами и функциями** - строит graph-схему через `networkx`.
7. **Один шаг вычислений на графе** - вычисляет входные суммы и новые значения.
8. **Несколько итераций вычислений** - строит траекторию значений вершин.
9. **График траекторий вершин** - показывает динамику по шагам.
10. **Задание** - предлагает изменить веса, функции вершин или начальные значения.

11. **Проверка выбранного варианта** - пересчитывает выбранную конфигурацию.
12. **Визуализация выбранного варианта** - строит выбранный граф и траектории.
13. **Финальный артефакт** - сохраняет файлы результата.

#### **Параметры, которые нужно изменить**

В ячейке **Задание** разрешается изменить:

1. **SELECTED\_WEIGHT\_MATRIX** - веса существующих дуг;
2. **SELECTED\_VERTEX\_FUNCTIONS** - функции нейронов в вершинах;
3. **SELECTED\_INITIAL\_VALUES** - начальные значения вершин;
4. **SELECTED\_STEP\_COUNT** - число итераций.

Размерность начального вектора должна совпадать с числом вершин. Ненулевые веса можно задавать только там, где в матрице смежности есть дуга.

#### **Шаги воспроизведения**

1. Откройте **.lab.py**.
2. Выполните подготовительные ячейки сверху вниз без изменений.
3. Посмотрите матрицу смежности, матрицу весов и функции в вершинах.
4. Посмотрите graph-визуализацию с подписями весов дуг и функций вершин.
5. Сравните один шаг вычислений с таблицей нескольких итераций.
6. В ячейке **Задание** измените веса, функции вершин или начальные значения.
7. Выполните ячейки **Проверка выбранного варианта**, **Визуализация выбранного варианта** и **Финальный артефакт**.

#### **Что нужно сдать**

1. **graph\_iterations.csv**
2. **graph\_summary.json**
3. **selected\_weighted\_computation\_graph.png**
4. **selected\_graph\_iteration\_trajectories.png**

#### **Формат результата**

Файл **graph\_iterations.csv** должен содержать столбцы:

`step, y1, y2, y3, y4`

Число столбцов **y1, y2, ...** зависит от числа вершин графа.

Файл **graph\_summary.json** должен содержать число вершин, число шагов и последний вектор значений.

#### **Критерии проверки**

1. В CSV есть строка для шага **0** и для каждого выполненного шага.
2. Число координат в каждой строке совпадает с числом вершин.

3. В JSON поле **step\_count** совпадает с параметром **STEP\_COUNT**.
4. Последний вектор в JSON совпадает с последней строкой CSV.
5. PNG-файл графа показывает функции вершин и веса дуг.
6. PNG-файл траекторий показывает значения всех вершин по итерациям.

## 04-lab-01. Функции эмпирического риска

### Цель

Научиться вычислять основные функции эмпирического риска без работы с нейронными сетями: MAE и MSE для регрессии, кросс-энтропию для бинарной и многоклассовой классификации, KL-дивергенцию для двух нормальных распределений.

### Материал лекции

Лабораторная относится к лекции 4 «Обучение как задача многомерной оптимизации» и опирается на понятия:

1. обучающая выборка;
2. функция потерь на одном примере;
3. эмпирический риск;
4. средняя абсолютная ошибка;
5. среднеквадратичная ошибка;
6. бинарная кросс-энтропия;
7. многоклассовая кросс-энтропия;
8. дивергенция Кульбака-Лейблера.

В лабораторной не рассматриваются нейронные сети, параметры сети или шаги оптимизации.

### Состав шаблона

Файлы лабораторной находятся в текущем каталоге:

1. **lab.py** - основной блокнот в виде .py-файла с ячейками # %% ;
2. **results/** - каталог, который создается автоматически после запуска.

### Команда запуска блокнота

Откройте lab.py в редакторе, который поддерживает запуск ячеек # %% , и выполните ячейки сверху вниз.

Для проверки всего файла как обычного скрипта можно выполнить:

```
uv run python lab.py
```

### Структура ячеек блокнота

1. **Постановка опыта** - задает четыре группы функций риска.
2. **Обучающая выборка для регрессии** - строит выборку для функции  $a x + b + c \sin(d x)$ .
3. **MAE и MSE** - вычисляет среднюю абсолютную и среднеквадратичную ошибки.
4. **График регрессии и ошибок** - показывает обучающую выборку, прогноз, поточечные ошибки, MAE и MSE.
5. **SE для бинарной классификации** - вычисляет бинарную кросс-энтропию.

6. **SE для многоклассовой классификации** - вычисляет многоклассовую кросс-энтропию.
7. **KL-дивергенция двух распределений Гаусса** - вычисляет  $D_{KL}(P || Q)$ .
8. **График распределений Гаусса** - показывает плотности, поточечный вклад в KL и значение  $D_{KL}(P || Q)$ .
9. **Задание** - предлагает изменить прогнозные коэффициенты, вероятности или параметры распределений.
10. **Проверка выбранного варианта** - пересчитывает все функции риска.
11. **Визуализация выбранного варианта** - строит выбранные графики регрессии, MAE/MSE, распределений и KL.
12. **Финальный артефакт** - сохраняет файлы результата.

### Параметры, которые нужно изменить

В ячейке **Задание** разрешается изменить:

1. **SELECTED\_PREDICTED\_COEFFICIENTS** - коэффициенты прогнозной функции;
2. **SELECTED\_BINARY\_CASES** - вероятности для бинарной классификации;
3. **SELECTED\_MULTICLASS\_CASES** - вероятности для многоклассовой классификации;
4. **SELECTED\_GAUSSIAN\_P** и **SELECTED\_GAUSSIAN\_Q** - параметры двух нормальных распределений.

Вероятности для кросс-энтропии должны быть строго положительными; в многоклассовом случае вероятности каждого объекта должны суммироваться в **1**.

### Шаги воспроизведения

1. Откройте `./lab.py`.
2. Выполните подготовительные ячейки сверху вниз без изменений.
3. Сравните MAE и MSE для обучающей выборки.
4. Сравните SE для бинарной и многоклассовой классификации.
5. Посмотрите, как смещение и дисперсия нормальных распределений связаны с KL-дивергенцией.
6. В ячейке **Задание** измените коэффициенты, вероятности или параметры распределений.
7. Выполните ячейки **Проверка выбранного варианта**, **Визуализация выбранного варианта** и **Финальный артефакт**.

### Что нужно сдать

1. `empirical_risks.csv`
2. `regression_sample.csv`
3. `risk_summary.json`
4. `selected_regression_mae_mse.png`
5. `selected_gaussian_kl.png`

### Формат результата

Файл **empirical\_risks.csv** должен содержать столбцы:

`case_id`, `loss_type`, `value`

Файл **regression\_sample.csv** должен содержать столбцы:

`x`, `y_true`, `y_pred`

Файл **risk\_summary.json** должен содержать значения MAE, MSE, бинарной CE, многоклассовой CE и KL-дивергенции.

### Критерии проверки

1. В CSV **empirical\_risks.csv** есть строки для MAE, MSE, бинарной CE, многоклассовой CE и KL.
2. Все значения функций риска неотрицательны.
3. В **regression\_sample.csv** есть значения истинной функции и прогноза.
4. В **risk\_summary.json** есть параметры двух нормальных распределений.
5. PNG-файл регрессии показывает обучающую выборку, прогноз, поточечные ошибки, MAE и MSE.
6. PNG-файл распределений показывает две нормальные плотности, поточечный вклад в KL и значение  $D_{KL}(P || Q)$ .

## 05-lab-01. Ручное обучение простой нейросети

### Цель

Реализовать минимальную нейросеть из линейного слоя и слоя активации, явно вычислить MSE, градиент MSE, одну итерацию обучения и цикл обучения с постоянным **learning rate**.

### Материал лекции

Лабораторная относится к лекции 5 «Общая схема градиентного обучения» и опирается на понятия:

1. прямой проход;
2. линейный слой;
3. слой активации;
4. функция ошибки MSE;
5. градиент функции ошибки;
6. направление антиградиента;
7. коррекция весов;
8. цикл обучения с постоянным шагом.

### Состав шаблона

Файлы лабораторной находятся в текущем каталоге:

1. **lab.py** - основной блокнот в виде **.py**-файла с ячейками **# %%** ;
2. **results/** - каталог, который создается автоматически после запуска.

### Команда запуска блокнота

Откройте **lab.py** в редакторе, который поддерживает запуск ячеек **# %%**, и выполните ячейки сверху вниз.

Для проверки всего файла как обычного скрипта можно выполнить:

```
uv run python lab.py
```

### Структура ячеек блокнота

1. **Постановка опыта** - задает идею сети **LinearLayer -> TanhActivation**.
2. **Обучающая выборка** - строит одномерную регрессионную выборку.
3. **Линейный слой** - реализует  $z = \mathbf{xW}^T + \mathbf{b}$  и градиенты параметров.
4. **Слой активации** - реализует **tanh(z)** и производную активации.
5. **Простая нейросеть** - объединяет линейный слой и слой активации.
6. **MSE и градиент MSE** - вычисляет ошибку и градиент по прогнозам.
7. **Одна итерация обучения** - выполняет **forward -> MSE -> градиент -> коррекция весов**.
8. **Задание** - предлагает изменить начальные параметры, **learning rate** или число итераций.
9. **Цикл обучения** - выполняет несколько итераций с постоянным **learning rate**.

10. **Визуализация обучения** - показывает MSE по итерациям и итоговый прогноз сети.
11. **Финальный артефакт** - сохраняет файлы результата.

### Параметры, которые нужно изменить

В ячейке **Задание** разрешается изменить:

1. **SELECTED\_INITIAL\_WEIGHTS** - начальную матрицу весов линейного слоя;
2. **SELECTED\_INITIAL\_BIASES** - начальные смещения;
3. **SELECTED\_LEARNING\_RATE** - постоянный шаг обучения;
4. **SELECTED\_ITERATION\_COUNT** - число итераций цикла обучения.

Слишком большой **learning rate** может увеличить MSE или привести к колебаниям траектории.

### Шаги воспроизведения

1. Откройте **.Lab.py**.
2. Выполните подготовительные ячейки сверху вниз без изменений.
3. Сравните MSE до и после одной итерации обучения.
4. В ячейке **Задание** измените **SELECTED\_LEARNING\_RATE** или начальные параметры.
5. Выполните ячейки **Цикл обучения**, **Визуализация обучения** и **Финальный артефакт**.
6. Сравните итоговое MSE и форму прогноза сети.

### Что нужно сдать

1. **training\_history.csv**
2. **training\_sample.csv**
3. **final\_model.json**
4. **training\_mse\_and\_fit.png**

### Формат результата

Файл **training\_history.csv** должен содержать столбцы:

`iteration,mse,weight,bias`

Файл **training\_sample.csv** должен содержать столбцы:

`x,target`

Файл **final\_model.json** должен содержать архитектуру сети, начальные параметры, итоговые параметры, **learning rate**, число итераций, начальное и итоговое MSE.

### Критерии проверки

1. В **training\_history.csv** есть строка **iteration = 0** и строка последней итерации.
2. Значения MSE неотрицательны.
3. В **final\_model.json** указаны слои **LinearLayer** и **TanhActivation**.

4. Итоговые веса и смещения отличаются от начальных при ненулевом **learning rate**.
5. PNG-файл показывает траекторию MSE и итоговый прогноз сети.

## 06-lab-01. Автоматическое дифференцирование через Value

### Цель

Реализовать простой механизм автоматического дифференцирования через класс **Value**, расширить его новой операцией и функцией, построить двухслойную сеть через **Value** и получить градиенты MSE для параметров каждого слоя.

### Материал лекции

Лабораторная относится к лекции 6 «Автоматическое дифференцирование» и опирается на понятия:

1. вычислительный граф;
2. локальная производная операции;
3. цепное правило;
4. обратный топологический обход графа;
5. автоматическое дифференцирование в обратном режиме;
6. прямой проход нейросети;
7. MSE как узел вычислительного графа;
8. градиенты параметров слоя.

### Исходный ориентир

Класс **Value** строится в учебном стиле скалярного автоматического дифференцирования: операция создает новый **Value**, сохраняет родителей и локальные производные, а **backward()** распространяет градиенты от итогового скаляра к листьям графа.

### Состав шаблона

Файлы лабораторной находятся в текущем каталоге:

1. **lab.py** - основной блокнот в виде **.py**-файла с ячейками **# %%** ;
2. **results/** - каталог, который создается автоматически после запуска.

### Команда запуска блокнота

Откройте **lab.py** в редакторе, который поддерживает запуск ячеек **# %%**, и выполните ячейки сверху вниз.

Для проверки всего файла как обычного скрипта можно выполнить:

```
uv run python lab.py
```

### Структура ячеек блокнота

1. **Постановка опыта** - задает роль **Value** и обратного прохода.
2. **Базовый класс Value** - реализует скалярный autodiff-движок.
3. **Проверка цепного правила** - вычисляет градиенты простого выражения.

4. **Модификация Value** - добавляет `square()` и `sigmoid()` с локальными производными.
5. **Скалярная обучающая точка** - задает один вход  $x$  и целевое значение  $y$ .
6. **Скалярная двухслойная сеть** - строит выражение  $w_2 * \text{sigmoid}(w_1 * x + b_1) + b_2$ .
7. **MSE как узел графа** - вычисляет MSE через объекты `Value`.
8. **Обратный проход и градиенты слоев** - получает градиенты параметров скрытого и выходного слоев.
9. **Узлы вычислительного графа** - показывает компактную таблицу узлов графа.
10. **Граф Value через networkx** - строит граф зависимостей от MSE к параметрам, входу  $x$  и целевому значению  $y$ .
11. **Задание** - предлагает изменить скалярные параметры, learning rate или входное значение.
12. **Демонстрация шага по антиградиенту** - показывает потенциальную коррекцию параметров.
13. **Визуализация градиентов** - строит график градиентов и антиградиентов по слоям.
14. **Финальный артефакт** - сохраняет файлы результата.

### Параметры, которые нужно изменить

В блокноте разрешается изменить:

1. начальные скалярные параметры в `ScalarTwoLayerNetwork`;
2. `X_VALUE` и `TARGET_VALUE`;
3. `SELECTED_LEARNING_RATE` для демонстрации шага;
4. `SELECTED_EXTRA_X` для дополнительного прямого прохода с видимым прогнозом.

После изменений нужно заново выполнить ячейки от создания сети до финального артефакта.

### Шаги воспроизведения

1. Откройте `./lab.py`.
2. Выполните ячейки с `Value` и проверьте градиенты простого выражения.
3. Выполните ячейку **Модификация Value** и убедитесь, что добавленные `square()` и `sigmoid()` дают градиенты.
4. Выполните прямой проход скалярной двухслойной сети до MSE.
5. Выполните `loss.backward()` и сравните градиенты первого и второго слоев.
6. Измените параметры в ячейке **Задание** и пересчитайте результат.

### Что нужно сдать

1. `layer_gradients.csv`
2. `autodiff_graph_nodes.csv`

3. **forward\_mse\_summary.json**
4. **layer\_gradients.png**
5. **value\_graph\_from\_mse.png**

#### Формат результата

Файл **layer\_gradients.csv** должен содержать столбцы:

`layer,parameter,value,gradient,antigradient`

Файл **autodiff\_graph\_nodes.csv** должен содержать столбцы:

`label,op,value,gradient,children`

Файл **forward\_mse\_summary.json** должен содержать источник **microbert.py**, список добавленных членов **Value**, скалярное выражение сети, значение MSE, число параметров и имя PNG-файла с графом **Value**.

#### Критерии проверки

1. В **forward\_mse\_summary.json** указаны **square** и **sigmoid**.
2. В **layer\_gradients.csv** есть параметры слоев **layer1** и **layer2**.
3. В **layer\_gradients.csv** есть ненулевые градиенты для параметров обоих слоев.
4. В **autodiff\_graph\_nodes.csv** присутствуют операции **sigmoid** и **square**.
5. PNG-файл показывает градиенты и антиградиенты параметров по слоям.
6. PNG-файл **value\_graph\_from\_mse.png** показывает граф **Value** от MSE к параметрам, входу **x** и целевому значению **y**.

## 07-lab-01. Траектории практических градиентных методов

### Цель

Сравнить несколько практических методов градиентного обучения на одной квадратичной функции и увидеть, как момент, AdaGrad, RMSprop и Adam меняют траекторию параметра.

### Материал лекции

Лабораторная относится к лекции 7 «Практические методы градиентного обучения» и опирается на понятия: градиентный шаг, метод тяжелого шарика, AdaGrad, RMSprop, Adam и методы второго порядка как ориентир для сравнения.

### Состав шаблона

1. **lab.py** - запускаемый блокнот с ячейками # %%;
2. **results/** - каталог результатов после запуска.

### Что нужно сделать

1. Запустите базовый вариант.
2. Измените **SELECTED\_START**, **SELECTED\_STEPS** или **SELECTED\_LR**.
3. Сравните финальные значения функции потерь у разных методов.
4. Проверьте, как меняется график траекторий.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. **optimizer\_trajectories.csv**
2. **optimizer\_summary.json**
3. **optimizer\_trajectories.png**

### Критерии проверки

1. CSV содержит столбцы **method**, **step**, **w**, **loss**, **gradient**.
2. JSON содержит лучший метод по финальному значению функции.
3. PNG показывает траектории функции потерь по шагам.

## 08-lab-01. Настройка обучения

### Цель

Исследовать влияние расписания шага обучения, инициализации и размера мини-батча на простую задачу линейной регрессии.

### Материал лекции

Лабораторная относится к лекции 8 «Настройка обучения и практический выбор оптимизатора» и опирается на выбор шага, планы изменения шага, разогрев, Xavier/He-инициализацию, мини-батчи и критерии останова.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените `SELECTED_BATCH_SIZE`, `SELECTED_SCHEDULE` или `SELECTED_INIT_SCALE`.
3. Сравните кривые обучения и финальную ошибку.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `training_setup_history.csv`
2. `training_setup_summary.json`
3. `training_setup_loss.png`

### Критерии проверки

1. CSV содержит историю `epoch`, `schedule`, `learning_rate`, `loss`.
2. JSON фиксирует выбранные параметры опыта.
3. PNG показывает кривую функции потерь.

## 09-lab-01. Стандартные блоки нейросетей

### Цель

Собрать малую сеть из стандартных блоков, проследить размерности тензоров и сравнить статистики активаций.

### Материал лекции

Лабораторная относится к лекции 9 «Стандартные вычислительные блоки нейросетей» и использует линейные слои, свертки, pooling, функции активации и нормализацию.

### Что нужно сделать

1. Запустите базовый вариант.
2. Измените `SELECTED_ACTIVATION` или число каналов.
3. Сравните размерности и статистики активаций.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `block_shapes.csv`
2. `block_summary.json`
3. `activation_statistics.png`

### Критерии проверки

1. CSV содержит имя блока, форму выхода и число параметров.
2. JSON содержит выбранную активацию и общее число параметров.
3. PNG показывает распределение активаций по блокам.

## 10-lab-01. Регуляризация и переобучение

### Цель

Сравнить обучение полиномиальной регрессии без регуляризации, с L2-штрафом и с dropout-шумом в признаках.

### Материал лекции

Лабораторная относится к лекции 10 «Методы регуляризации» и использует L2-регуляризацию, случайное выключение признаков и сравнение обучающей и проверочной ошибки.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените `SELECTED_WEIGHT_DECAY` или `SELECTED_DROPOUT`.
3. Сравните разрыв между обучающей и проверочной ошибкой.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `regularization_metrics.csv`
2. `regularization_summary.json`
3. `regularization_curves.png`

### Критерии проверки

1. CSV содержит train/test MSE для нескольких режимов.
2. JSON содержит лучший режим по test MSE.
3. PNG показывает сравнение ошибок.

## 11-lab-01. Обучение без учителя

### Цель

Построить простую модель скрытых переменных для двумерных данных, сравнить реконструкцию и качество кластеризации в латентном пространстве.

### Материал лекции

Лабораторная относится к лекции 11 «Обучение без учителя» и использует скрытые переменные, сжатие данных, генеративную реконструкцию и метрики качества.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените `SELECTED_LATENT_DIM` или число эпох.
3. Сравните реконструкционную ошибку и разделимость скрытых кодов.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `unsupervised_latent_codes.csv`
2. `unsupervised_summary.json`
3. `latent_space.png`

### Критерии проверки

1. CSV содержит координаты объектов и скрытый код.
2. JSON содержит реконструкционную ошибку.
3. PNG показывает скрытое пространство.

## 12-lab-01. Сверточные сети для изображений

### Цель

Построить малую сверточную обработку изображения, сравнить карты признаков и увидеть влияние padding и stride.

### Материал лекции

Лабораторная относится к лекции 12 «Сверточные сети для обработки изображений» и использует двумерную свертку, дополнение границ, шаг, pooling и карту признаков.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените **SELECTED\_KERNEL** или **SELECTED\_STRIDE**.
3. Сравните форму выхода и карту признаков.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. **convolution\_features.csv**
2. **convolution\_summary.json**
3. **feature\_map.png**

### Критерии проверки

1. CSV содержит координаты и значения карты признаков.
2. JSON содержит форму выхода и параметры свертки.
3. PNG показывает карту признаков.

## 13-lab-01. Рекуррентные сети

### Цель

Развернуть простую рекуррентную сеть во времени и увидеть, как коэффициент рекуррентной связи влияет на скрытые состояния и градиентный множитель.

### Материал лекции

Лабораторная относится к лекции 13 «Рекуррентные сети» и использует скрытое состояние, развертку во времени, BPTT и затухание или рост градиента.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените `SELECTED_RECURRENT_WEIGHT`.
3. Сравните последовательность скрытых состояний и градиентный множитель.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `rnn_unroll.csv`
2. `rnn_summary.json`
3. `hidden_states.png`

### Критерии проверки

1. CSV содержит `time`, `input`, `hidden`, `gradient_multiplier`.
2. JSON содержит финальное состояние и общий множитель градиента.
3. PNG показывает скрытое состояние по времени.

## 14-lab-01. Трансформеры и самовнимание

### Цель

Вычислить матрицу самовнимания для короткой последовательности, применить причинную маску и визуализировать веса внимания.

### Материал лекции

Лабораторная относится к лекции 14 «Трансформеры» и использует запросы, ключи, значения, softmax-внимание, многоголовое внимание как обобщение и причинную маску.

### Что нужно сделать

1. Запустите базовый вариант.
2. Измените `SELECTED_TEMPERATURE` или включение маски.
3. Сравните веса внимания и выходные представления.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `attention_weights.csv`
2. `attention_summary.json`
3. `attention_heatmap.png`

### Критерии проверки

1. CSV содержит веса внимания для каждой пары токенов.
2. JSON содержит параметр маски и форму выхода.
3. PNG показывает тепловую карту внимания.

## 15-lab-01. Q-обучение

### Цель

Выполнить несколько итераций Q-обучения в малой среде и визуализировать изменение функции ценности действий.

### Материал лекции

Лабораторная относится к лекции 15 «Обучение с подкреплением» и использует марковский процесс принятия решений, награду, дисконтирование, уравнение Беллмана и Q-обучение.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените `SELECTED_GAMMA`, `SELECTED_ALPHA` или число эпизодов.
3. Сравните финальную таблицу Q-значений.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `q_learning_trace.csv`
2. `q_learning_summary.json`
3. `q_values.png`

### Критерии проверки

1. CSV содержит трассу обновлений Q-таблицы.
2. JSON содержит лучшую стратегию для состояний.
3. PNG показывает Q-значения.

## 16-lab-01. Прямой процесс диффузии

### Цель

Промоделировать прямой процесс зашумления, вычислить долю сигнала и шума и визуализировать траекторию  $z_t$ .

### Материал лекции

Лабораторная относится к лекции 16 «Диффузионные модели» и использует прямой процесс зашумления,  $\alpha_t$ ,  $\bar{\alpha}_t$ , предсказание шума и MSE по шуму.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените **SELECTED\_STEPS** или диапазон **beta**.
3. Сравните траекторию сигнала и шума.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. **diffusion\_forward.csv**
2. **diffusion\_summary.json**
3. **diffusion\_trajectory.png**

### Критерии проверки

1. CSV содержит **t**, **beta**, **alpha\_bar**, **signal**, **noise**.
2. JSON содержит финальное **alpha\_bar**.
3. PNG показывает изменение сигнала и шума.

## 17-lab-01. Байесовское предсказание

### Цель

Сравнить несколько выборок параметров линейной модели и разложить неопределенность предсказания на среднее и дисперсию.

### Материал лекции

Лабораторная относится к лекции 17 «Байесовы нейронные сети» и использует априорное распределение, MAP-связь с регуляризацией, апостериорное предсказательное распределение и эпистемическую неопределенность.

### Что нужно сделать

1. Запустите базовый опыт.
2. Измените `SELECTED_PRIOR_STD` или сетку входов.
3. Сравните среднее предсказание и доверительную полосу.

### Команда запуска

```
uv run python lab.py
```

### Что нужно сдать

1. `bayesian_predictions.csv`
2. `bayesian_summary.json`
3. `predictive_uncertainty.png`

### Критерии проверки

1. CSV содержит среднее и дисперсию предсказаний.
2. JSON содержит `prior` и среднюю эпистемическую дисперсию.
3. PNG показывает среднее и полосу неопределенности.