



Научно учебная группа  
«Цифровые методы в неврологии»

Пермь,  
2023

# Реализация модели глубинного обучения для модели семантической сегментации

Лукин Семён Олегович

студент 3 курса ОП Программная инженерия



# Работа модели

convolution



$H \times W$




$H/4 \times W/4$



$H/8 \times W/8$



$H/16 \times W/16$



$H/32 \times W/32$







$H \times W$

↑  
conv, pool,  
nonlinearity



↑  
upsampling

↑  
pixelwise  
output + loss





# Как хранятся картинки?




```
In [2]: image_path = r"S:\neurology\0be1_1.png"  
np.array(Image.open(image_path))
```

```
Out[2]: array([[0, 0, 0],  
               [0, 0, 0],  
               [0, 0, 0],  
               ...,  
               [0, 0, 0],  
               [0, 0, 0],  
               [0, 0, 0]],  
            [[0, 0, 0],  
             [0, 0, 0],  
             [0, 0, 0],  
             ...,  
             [0, 0, 0],  
             [0, 0, 0],  
             [0, 0, 0]])
```

```
In [3]: mask_path = r"S:\neurology\0be1_1_mask.png"  
np.array(Image.open(mask_path))
```

```
Out[3]: array([[0, 0, 0, ..., 0, 0, 0],  
               [0, 0, 0, ..., 0, 0, 0],  
               [0, 0, 0, ..., 0, 0, 0],  
               ...,  
               [0, 0, 0, ..., 0, 0, 0],  
               [0, 0, 0, ..., 0, 0, 0],  
               [0, 0, 0, ..., 0, 0, 0]], dtype=uint8)
```







# Как собрать все данные в одном месте?

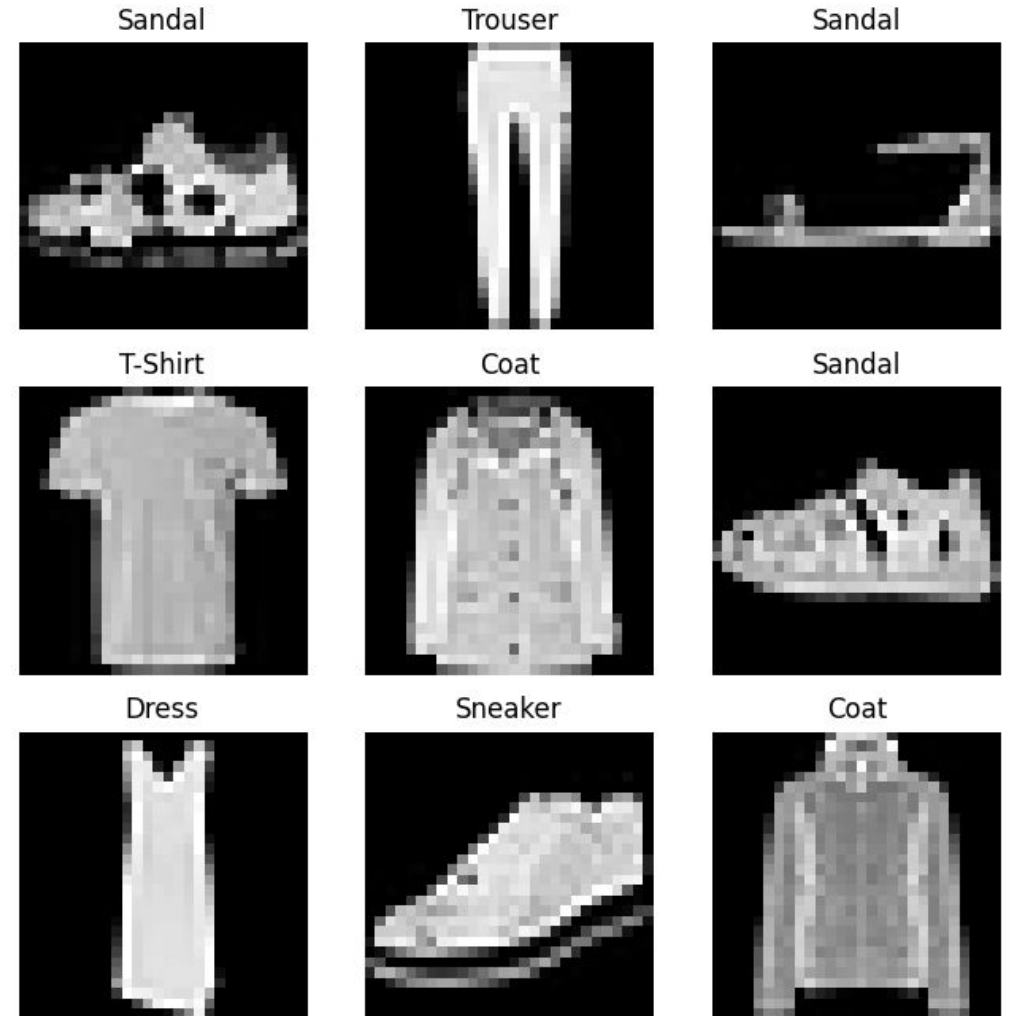
Создать датасет!

```
import torch
from torch.utils.data import Dataset
from torchvision import datasets
from torchvision.transforms import ToTensor
import matplotlib.pyplot as plt

training_data = datasets.FashionMNIST(
    root="data",
    train=True,
    download=True,
    transform=ToTensor()
)

test_data = datasets.FashionMNIST(
    root="data",
    train=False,
    download=True,
    transform=ToTensor()
)
```

70,000  
28x28 grayscale  
e images of  
fashion  
products from  
10 categories,  
2017






# Как собрать все данные в одном месте?

## Создать датасет!

```
class SegmentationDataset(Dataset):
    def __init__(self,
                 slices_dir,
                 masks_dir,
                 transforms):

        self.slices_dir = sorted(glob.glob(os.path.join(slices_dir, "*.png")))
        self.masks_dir = sorted(glob.glob(os.path.join(masks_dir, "*.png")))
        self.transforms = transforms

        assert len(self.slices_dir) == len(self.masks_dir)
```



```
def __getitem__(self, idx):
    image = np.array(Image.open(self.slices_dir[idx]))
    mask = np.array(Image.open(self.masks_dir[idx]))

    mask[mask == 255.0] = 1.0

    if self.transforms is not None:
        augmentations = self.transforms(image=image, mask=mask)
        image = augmentations["image"]
        mask = augmentations["mask"]

    mask = torch.unsqueeze(mask, 0)
    mask = mask.type(torch.float32)
    return image, mask

def __len__(self):
    return len(self.slices_dir)
```



# Как сообщить модели о способе работы с датасетом?

## создать DataLoader!

```
from torch.utils.data import DataLoader
```

```
train_dataloader = DataLoader(training_data, batch_size=64, shuffle=True)
```

```
test_dataloader = DataLoader(test_data, batch_size=64, shuffle=True)
```

```
def create_dataloaders(train_dataset, val_dataset, test_dataset,
                       batch_size=8, pin_memory=True, num_workers=4):

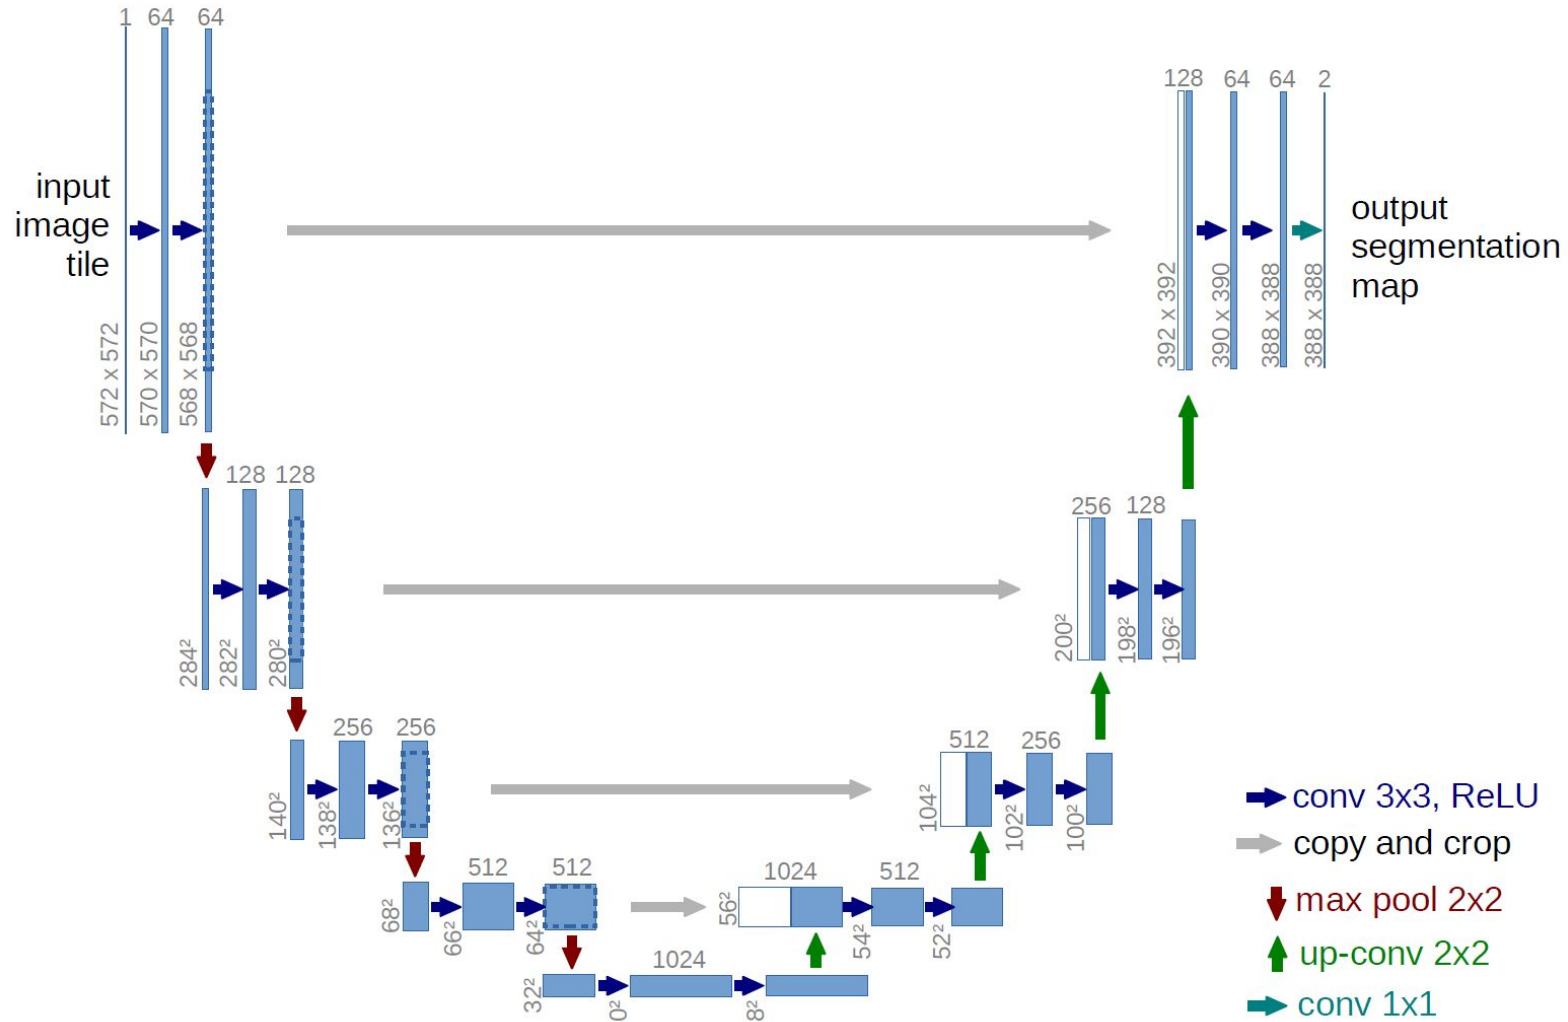
    train_loader = torch.utils.data.DataLoader(
        dataset=train_dataset, batch_size=batch_size,
        shuffle=True, pin_memory=pin_memory, num_workers=num_workers)

    val_loader = torch.utils.data.DataLoader(
        dataset=val_dataset, batch_size=batch_size,
        shuffle=True, pin_memory=pin_memory, num_workers=num_workers
    )

    test_loader = torch.utils.data.DataLoader(
        dataset=test_dataset, batch_size=batch_size,
        shuffle=False, pin_memory=pin_memory, num_workers=num_workers
    )

    return train_loader, val_loader, test_loader
```

# Построение архитектуры модели с помощью PyTorch






# Построение архитектуры модели с помощью

```

1 model = nn.Sequential() # создаем пустую модель, в которую будем добавлять слои
2 model.add_module('l1', nn.Linear(3, 3)) # добавили слой с 3-мя нейронами на вход и 3-мя на выход
3 model.add_module('r1', nn.ReLU()) # добавили функцию активации
4 model.add_module('l2', nn.Linear(3, 3)) # добавили слой с 3-мя нейронами на вход и 3-ю на выход
5 model.add_module('r2', nn.ReLU()) # добавили функцию активации
6 model.add_module('l3', nn.Linear(3, 3)) # добавили слой с 3-мя нейронами на вход и 3-ю на выход
7 model.add_module('r3', nn.ReLU()) # добавили функцию активации
8 model.add_module('l2', nn.Linear(3, 2)) # добавили слой с 3-мя нейронами на вход и 2-ю на выход

1 y_pred = model(batch_x) # получили предсказания модели
    
```




# Построение архитектуры модели с помощью PyTorch

```
class DoubleConv(pl.LightningModule):
    def __init__(self, in_channels, out_channels):
        super(DoubleConv, self).__init__()
        self.conv = nn.Sequential(

            nn.Conv2d(in_channels, out_channels, kernel_size=3, stride=1, padding=1, bias=False), # bias=False for BatchNorm
            nn.BatchNorm2d(out_channels),
            nn.ReLU(inplace=True),

            nn.Conv2d(out_channels, out_channels, 3, 1, 1, bias=False),
            nn.BatchNorm2d(out_channels),
            nn.ReLU(inplace=True),
        )

    def forward(self, x):
        return self.conv(x)
```



→ conv 3x3, ReLU



# Построение архитектуры модели с помощью


```
class UNET(nn.Module):
    def __init__(
        self, in_channels=3, out_channels=1, features=[64, 128, 256, 512],
    ):
        super(UNET, self).__init__()


        self.ups = nn.ModuleList()
        self.downs = nn.ModuleList()
        self.pool = nn.MaxPool2d(kernel_size=2, stride=2)

        # Down part of UNET - only left side
        for feature in features:
            self.downs.append(DoubleConv(in_channels, feature))
            in_channels = feature

        # Up part of UNET - only right side
        for feature in reversed(features):
            # up
            self.ups.append(
                nn.ConvTranspose2d(
                    # with skip-conn
                    feature*2, feature, kernel_size=2, stride=2,
                )
            )
            # two times right
            self.ups.append(DoubleConv(feature*2, feature))

        self.bottleneck = DoubleConv(features[-1], features[-1]*2)
        self.final_conv = nn.Conv2d(features[0], out_channels, kernel_size=1)
```

 model.py

 model.ipynb

```
def forward(self, x):
    skip_connections = []

    for down in self.downs:
        x = down(x)
        skip_connections.append(x)
        x = self.pool(x)

    x = self.bottleneck(x)

    # reverse skip_connections
    skip_connections = skip_connections[::-1]

    # пропускаем DoubleConv
    for idx in range(0, len(self.ups), 2):
        x = self.ups[idx](x)
        skip_connection = skip_connections[idx//2]

        # resize if x does not match skip_conn
        if x.shape != skip_connection.shape:
            x = TF.resize(x, size=skip_connection.shape[2:], antialias=True)

        concat_skip = torch.cat((skip_connection, x), dim=1)
        x = self.ups[idx+1](concat_skip)

    return self.final_conv(x)
```



# Выбираем функцию потерь

## PyTorch

### Loss Functions

`nn.L1Loss`

Creates a criterion that measures the mean absolute error (MAE) between each element in the input  $x$  and target  $y$ .

`nn.MSELoss`

Creates a criterion that measures the mean squared error (squared L2 norm) between each element in the input  $x$  and target  $y$ .

`nn.CrossEntropyLoss`

This criterion computes the cross entropy loss between input logits and target.

`nn.CTCLoss`

The Connectionist Temporal Classification loss

$$BCE = -\frac{1}{N} \sum_{i=0}^N y_i \cdot \log(\hat{y}_i) + (1 - y_i) \cdot \log(1 - \hat{y}_i)$$

## Segmentation Models

### Losses

- Constants
- JaccardLoss
- DiceLoss
- TverskyLoss
- FocalLoss
- LovaszLoss
- SoftBCEWithLogitsLoss
- SoftCrossEntropyLoss
- MCCLoss

$$Dice Loss = 1 - Dice coef$$





# Выбираем метод оптимизации – TORCH.OPTIM

## Algorithms

Adadelta

Implements Adadelta algorithm.

Adagrad

Implements Adagrad algorithm.

Adam

Implements Adam algorithm.

AdamW

Implements AdamW algorithm.

SparseAdam

Implements lazy version of Adam algorithm suitable for  
sparse tensors

```
[ ] 1 [elem for elem in dir(torch.optim) if not elem.startswith("_")]
```

```
['ASGD',  
'Adadelta',  
'Adagrad',  
'Adam',  
'AdamW',  
'Adamax',  
'LBFGS',  
'NAdam',  
'Optimizer',  
'RAdam',  
'RMSprop',  
'Rprop',  
'SGD',  
'SparseAdam',  
'lr_scheduler',  
'swa_utils']
```





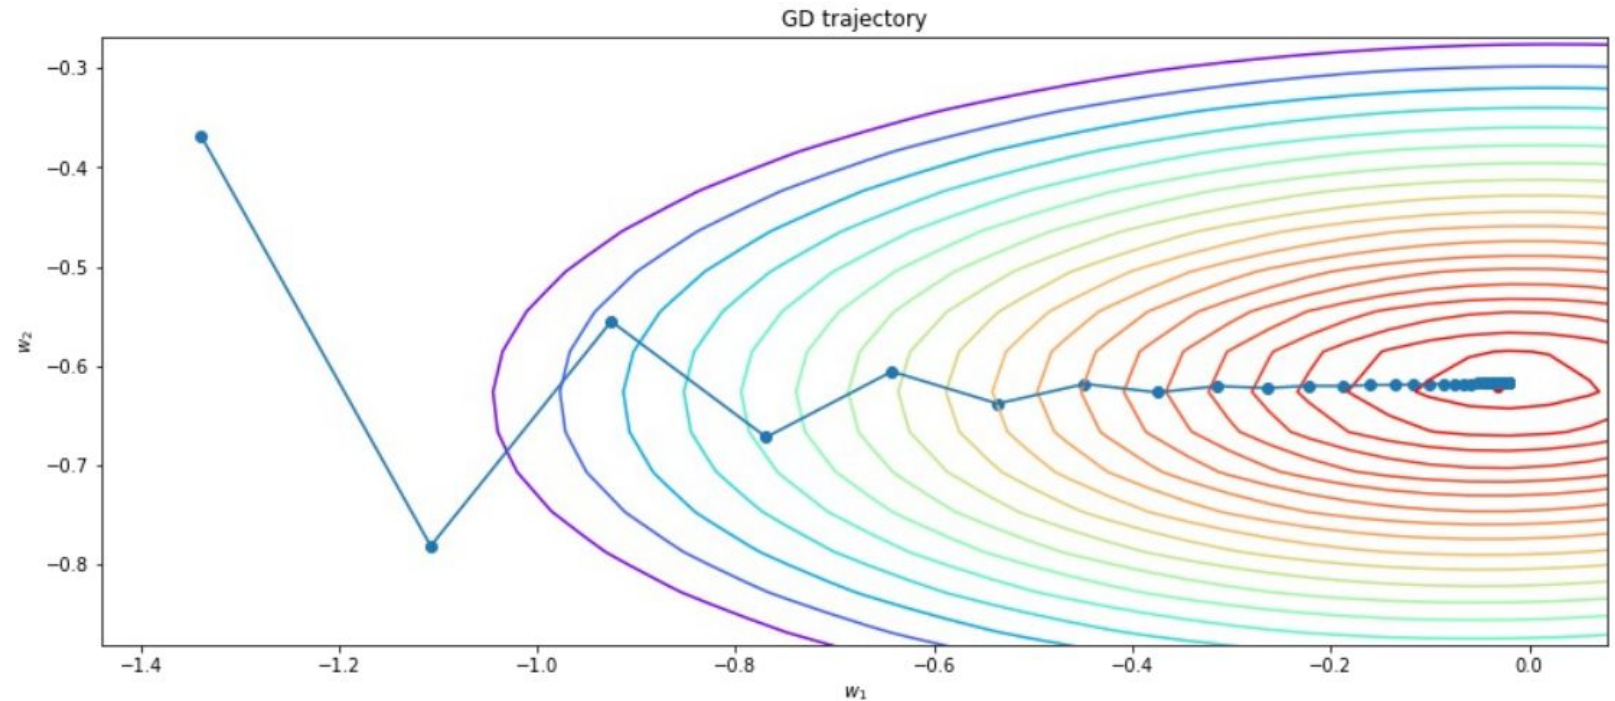
# Немного формул

## Gradient descent

$$w^t = w^{t-1} - \eta \nabla Q(w^{t-1})$$

+ Точное значение  
градиента

- Долго и трудозатратно




# Немного формул

## Stochastic Gradient Descent

$$w^t = w^{t-1} - \eta_t \nabla L(y_{i_t}, a(x_{i_t}))$$

+ Быстро

- Большой разброс



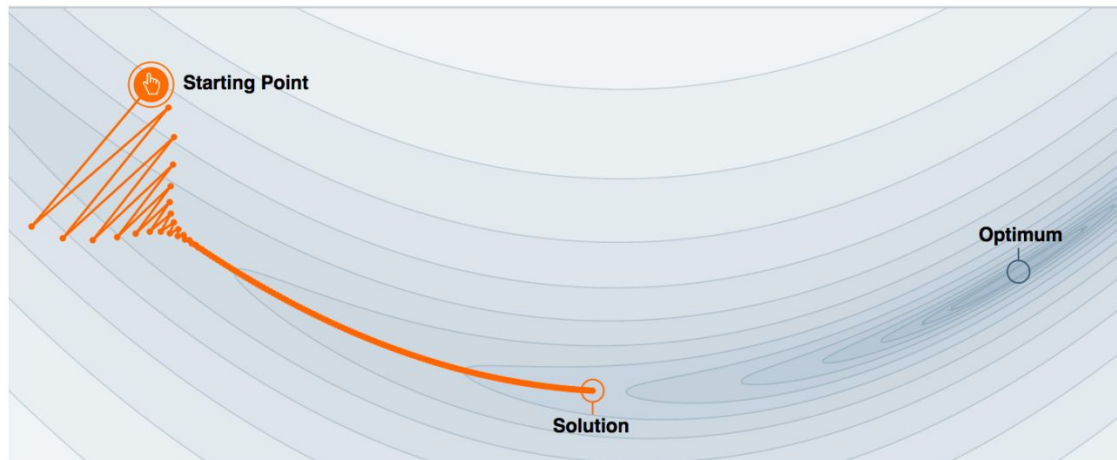
# Немного формул

Stochastic Gradient Descent with Momentum

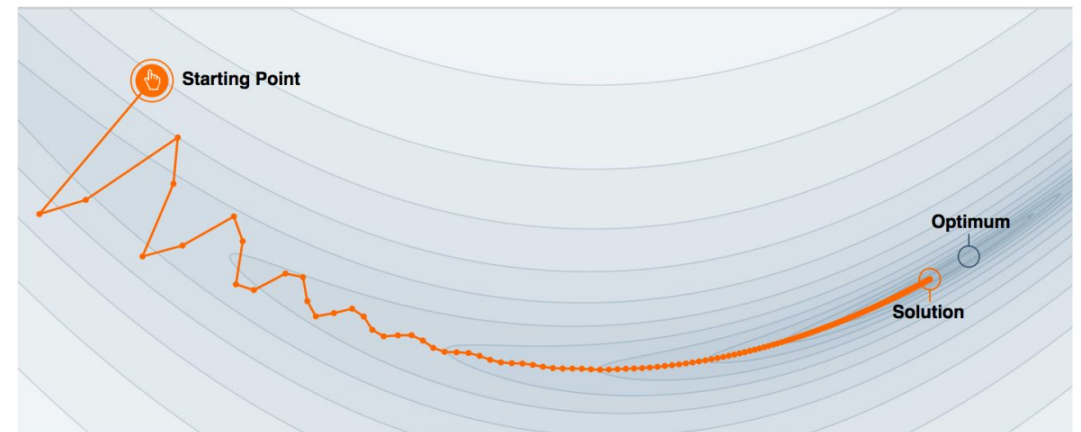
$$h_t = \alpha h_{t-1} + \eta_t \nabla Q(w^{t-1})$$

$$w^t = w^{t-1} - h_t$$

Без инерции



С инерцией





# Немного формул

## Адаптивные методы градиентного спуска

AdaGrad

$$G_j^t = G_j^{t-1} + (\nabla Q(w^{t-1}))_j^2$$
$$w_j^t = w_j^{t-1} - \frac{\eta_t}{\sqrt{G_j^t + \epsilon}} (\nabla Q(w^{t-1}))_j$$

## RMSProp

$$G_j^t = \alpha G_j^{t-1} + (1 - \alpha) (\nabla Q(w^{t-1}))_j^2$$
$$w_j^t = w_j^{t-1} - \frac{\eta_t}{\sqrt{G_j^t + \epsilon}} g_{tj}$$

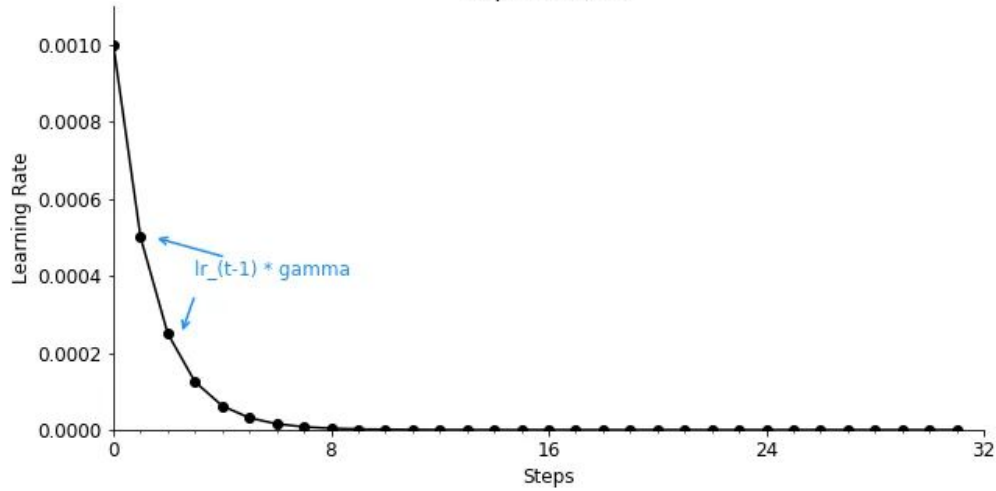
## Adam

$$m_j^t = \frac{\beta_1 m_j^{t-1} + (1 - \beta_1) (\nabla Q(w^{t-1}))_j}{1 - \beta_1^t}$$
$$v_j^t = \frac{\beta_2 v_j^{t-1} + (1 - \beta_2) (\nabla Q(w^{t-1}))_j^2}{1 - \beta_2^t}$$
$$w_j^t = w_j^{t-1} - \frac{\eta_t}{\sqrt{v_j^t + \epsilon}} m_j^t$$

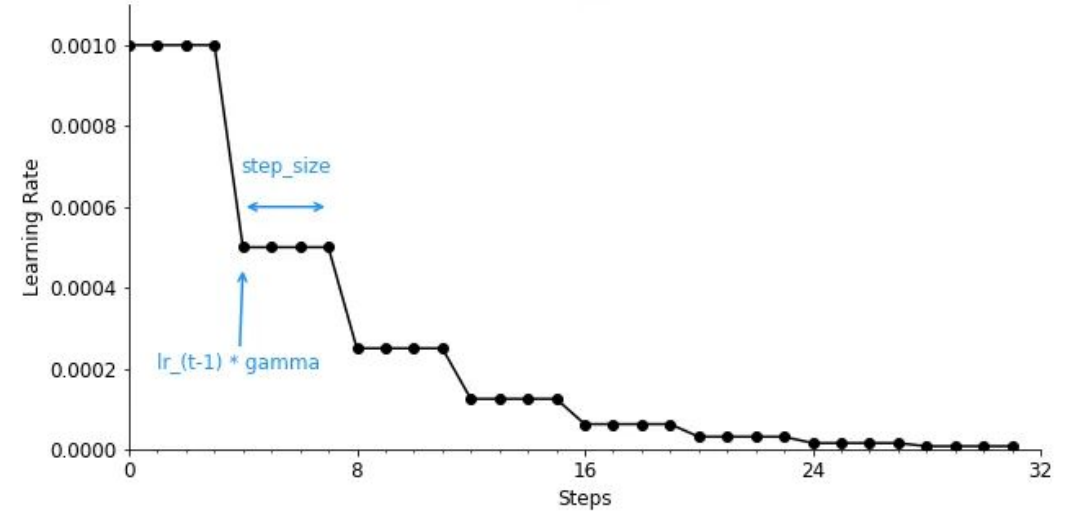


# Изменяем learning rate с помощью scheduler


ExponentialLR



StepLR



CyclicLR (triangular)







# Классический цикл обучения модели

```
[ ] 1 total_step = len(train_loader)
     2 for epoch in range(NUM_EPOCHS): # цикл по эпохам обучения
     3     for i, (images, labels) in enumerate(train_loader): # цикл по мини-батчам
     4         # Перенос обоих тензоров на GPU
     5         images = images.to(DEVICE)
     6         labels = labels.to(DEVICE)
     7
     8         # Проход вперед
     9         outputs = net(images)
    10         loss = criterion(outputs, labels)
    11
    12         # Проход назад
    13         optimizer.zero_grad()
    14         loss.backward()
    15
    16         # Обновление параметров нейросети
    17         optimizer.step()
    18
    19         if (i+1) % 200 == 0:
    20             print ('Epoch [{} / {}], Step [{} / {}], Loss: {:.4f}'
    21                   .format(epoch+1, NUM_EPOCHS, i+1, total_step, loss.item()))
```



# Обучение в PyTorch Lightning

```
[ ] 1 model = UNET()  
    2  
    3 trainer = pl.Trainer(  
    4     max_epochs=2,  
    5     accelerator="gpu",  
    6     devices=1,  
    7     auto_lr_find=True,  
    8 )  
    9  
   10 trainer.fit(model, train_loader, val_loader)
```



# Модель в PyTorch Lightning

`__init__ and setup()`

Define initialization here

`forward()`

To run data through your model only  
(separate from `training_step`)

`training_step()`

the complete training step

`validation_step()`

the complete validation step

`test_step()`

the complete test step

`predict_step()`

the complete prediction step

`configure_optimizers()`

define optimizers and LR schedulers

```
import lightning.pytorch as pl
import torch.nn as nn
import torch.nn.functional as F

class LitModel(pl.LightningModule):
    def __init__(self):
        super().__init__()
        self.l1 = nn.Linear(28 * 28, 10)

    def forward(self, x):
        return torch.relu(self.l1(x.view(x.size(0), -1)))


    def training_step(self, batch, batch_idx):
        x, y = batch
        y_hat = self(x)
        loss = F.cross_entropy(y_hat, y)
        return loss

    def configure_optimizers(self):
        return torch.optim.Adam(self.parameters(), lr=0.02)
```



## Вспомогательные функции

 utils.ipynb

 utils.py

- Сохранить и загрузить модель
- Создание датасета и даталоадера
- Подсчитать метрики с помощью готовой модели (mean Dice, accuracy)
- Вывести результат работы



# Поле экспериментов

## 0. Импорты

```
import torch
import torch.nn as nn
from tqdm import tqdm
import torch.nn as nn
import torch.optim as optim
import pytorch_lightning as pl

from model import UNET
from utils import (
    load_checkpoint,
    save_checkpoint,
    create_dataloaders,
    create_datasets,
    check_accuracy,
    get_mean_dice,
    show_three,
)

import albumentations as A
from albumentations.pytorch import ToTensorV2
```





# Поле экспериментов

## 1. Параметры и гиперпараметры

```
# Hyperparameters etc.  
DEVICE = "cuda" if torch.cuda.is_available() else "cpu"  
  
LEARNING_RATE = 1e-4  
BATCH_SIZE = 16  
NUM_EPOCHS = 20  
NUM_WORKERS = 2  
IMAGE_HEIGHT = 256 # 1280 originally  
IMAGE_WIDTH = 256 # 1918 originally  
  
PIN_MEMORY = True  
LOAD_MODEL = False  
#  
MASKS = "/kaggle/input/stroke-aid-dataset-splitted/masks"  
SLICES = "/kaggle/input/stroke-aid-dataset-splitted/slices"
```



# Поле экспериментов

## 2. Аугментации данных

```
train_transform = A.Compose(  
    [  
        A.Resize(height=IMAGE_HEIGHT, width=IMAGE_WIDTH),  
        # A.Rotate(limit=35, p=1.0),  
        # A.HorizontalFlip(p=0.5),  
        # A.VerticalFlip(p=0.1),  
        A.Normalize(  
            mean=[0.0, 0.0, 0.0],  
            std=[1.0, 1.0, 1.0],  
            max_pixel_value=255.0,  
        ),  
        ToTensorV2(),  
    ],  
)  
  
val_transforms = A.Compose(  
    [  
        A.Resize(height=IMAGE_HEIGHT, width=IMAGE_WIDTH),  
        A.Normalize(  
            mean=[0.0, 0.0, 0.0],  
            std=[1.0, 1.0, 1.0],  
            max_pixel_value=255.0,  
        ),  
        ToTensorV2(),  
    ],  
)
```



# Поле экспериментов

## 3. Определение функции потерь, оптимизатора и модели

```
loss_fn = nn.BCEWithLogitsLoss()
optimizer = optim.Adam
optimizer_params = [{"lr": LEARNING_RATE}]

model = UNET(in_channels=3,
             out_channels=1,
             loss_fn=loss_fn,
             optimizer=optimizer,
             optimizer_params=optimizer_params
             ).to(DEVICE)
```



# Поле экспериментов

## 4. Создаём лоадеры

```
train_dataset, val_dataset, test_dataset = create_datasets(MASKS, SLICES, train_transform)

train_loader, val_loader, test_loader = create_dataloaders(train_dataset, val_dataset, test_dataset, batch_size
```

Train size: 450

Valid size: 148

Test size: 149



# Поле экспериментов

## 5. Обучаем

```
seed_everything(123456)
torch.cuda.empty_cache()

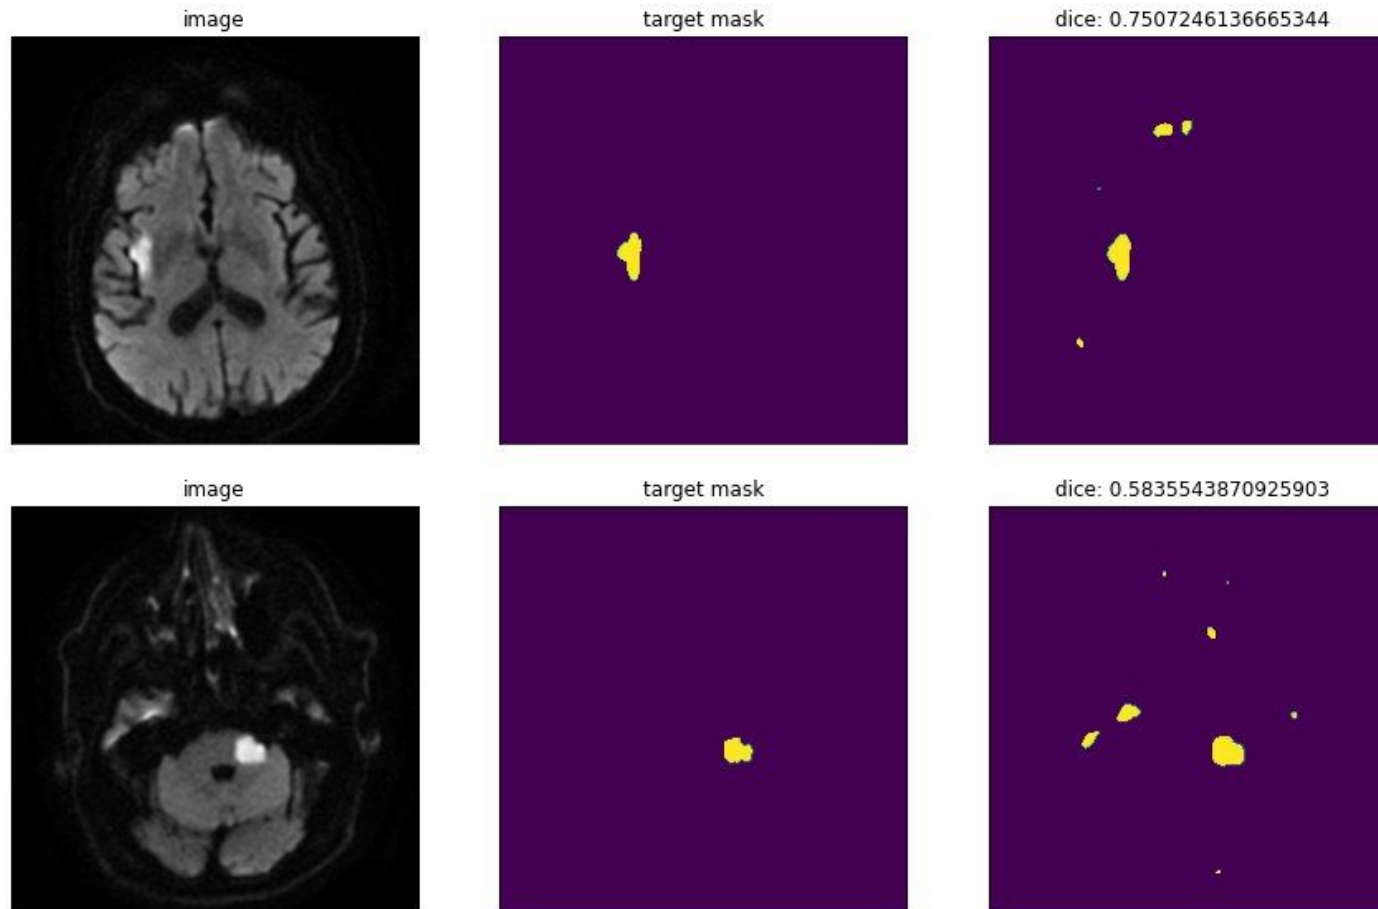
trainer = pl.Trainer(
    max_epochs=NUM_EPOCHS,
    accelerator=DEVICE,
    devices=1,
)

trainer.fit(model, train_loader, val_loader)
```





# Результат






## ИСТОЧНИКИ

- Лекции и семинары дисциплины «Основы глубинного обучения»  
<https://github.com/hse-ds/iad-deep-learning>
- Лекции и семинары дисциплины «Прикладные задачи анализа данных»  
<https://github.com/hse-ds/iad-applied-ds>







## Формулы

$$\epsilon_{\theta}(x_t, I, t) = D((E_t^I + E_t^x, t), t),$$

где:

$\theta$  – параметры обратного процесса,

$I_{n \times n}$  – входное изображение,


$E_t^I$  – условный эмбендинг (необработанное изображение),

$E_t^x$  – сегментационная разметка,

$D$  – декодер Unet,



# Прямой процесс диффузии




$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \mu_t = \sqrt{1 - \beta_t} x_{t-1}, \Sigma_t = \beta_t \mathbf{I})$$

где:

$\beta_t$  – константа,

$\mathbf{I}$  – диагональная матрица ковариаций, на диагоналях стоят  $\sigma$ , остальные – нули





Научно учебная группа  
«Цифровые методы в  
неврологии»

Применение генеративных  
моделей в задачах классификации  
и сегментации

36



# This X Does Not Exist

dd

A



Научно учебная группа  
«Цифровые методы в  
неврологии»

Применение генеративных  
моделей в задачах классификации  
и сегментации

38