Perceptronul și rețele de perceptroni

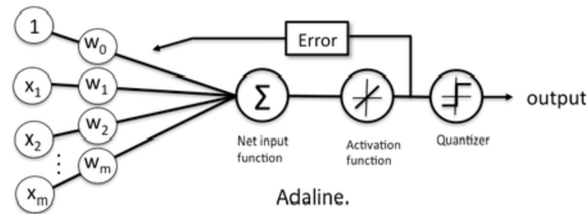

Structura unui perceptron cu *m* ponderi. Functia de predictie a perceptronului este $y_{hat} = sign(\sum_{i=0}^{i=m} x_i * w_i)$.

1. Perceptronul

Perceptronul este un clasificator liniar. Predictia clasificatorului pentru exemplul $X = \{x_1, x_2, ..., x_n\}$ este $y_{hat} = f(\sum_{i=1}^{i=n} x_i * w_i + b)$, unde $W = \{w_1, w_2, ..., w_n\}$ si $b = w_0$ sunt ponderile, respectiv bias-ul perceptronului, iar f este functia de transfer (numita si functie de activare). Putem inlocui suma din calcularea lui y_{hat} cu produsului dintre vectorul datelor de intrare X si matricea ponderilor$W$, rezultatand $y_{hat} = f(X \cdot W + b)$.

2. Algoritmul Widrow-Hoff.

Algoritmul Widrow-Hoff, numit si *metoda celor mai mici patrate* (*Least mean squares*), este un algoritm de optimizare a erorii perceptronului pe baza metodei coborarii pe gradient tinand cont doar de eroare de la exemplul curent.

Regula de actualizare foloseste derivata partiala a functiei de pierdere, in functie de ponderi si bias. In continuare vom calcula detaliat derivatele partiale ale functiei de pierdere. Functia de activare a perceptronului din algoritmul Widrow-Hoff este *identitatea* ($f(x) = x$).

$$loss = \frac{(y_{hat} - y)^2}{2},\ unde\ y_{hat} = X \cdot W + b,\ iar\ y\ este\ eticheta\ lui\ X$$

∂W	∂b
$\frac{\partial loss}{\partial W} = \frac{\partial \frac{(y_{hat} - y)^2}{2}}{\partial W}$ $\frac{\partial loss}{\partial W} = \frac{\partial \frac{(x \cdot W + b - y)^2}{2}}{\partial W}$	$\frac{\partial loss}{\partial b} = \frac{\partial \frac{(y_{hat} - y)^2}{2}}{\partial b}$ $\frac{\partial loss}{\partial b} = \frac{\partial \frac{(x \cdot W + b - y)^2}{2}}{\partial b}$

$\frac{\partial loss}{\partial W} = \frac{2 \cdot (x \cdot W + b - y) \cdot \frac{\partial (x \cdot W + b - y}{\partial W}}{2}$	$\frac{\partial loss}{\partial b} = \frac{2 \cdot (x \cdot W + b - y) \cdot \frac{\partial (x \cdot W + b - y)}{\partial b}}{2}$
$\frac{\partial loss}{\partial W} = (x \cdot W + b - y) \cdot x$	$\frac{\partial loss}{\partial b} = (x \cdot W + b - y) \cdot 1$
$\frac{\partial loss}{\partial W} = (y_{hat} - y) \cdot x$	$\frac{\partial loss}{\partial b} = (y_{hat} - y)$

Algoritmul Widrow-Hoff.

1. $X = \{x_0, x_1, ..., x_{T-1}\}, X \in R^{TxN}$ $-$ *datele de intrare*, $Y = \{y_0, y_1, ..., y_{T-1}\}$ $-$ *etichet*
2. $W = \{w_0, w_1, ..., w_{N-1}\} = 0 \,;\, b = 0$ $//$ *initializeaza ponderile cu un vector de* 0 –
3. *pentru* $e = 0 : E - 1$ *executa*: $//$ *pentru fiecare epoca*
   a. *amesteca datele de antrenare*
   b. *pentru* $t = 0 : T - 1$ *executa*: $//$ *pentru fiecare exemplu* x_t *din* X
      i. $y_{hat} = x_t \cdot W + b$ $//$ *calculeaza predictia*
      ii. $loss = \frac{(y_{hat} - y_t)^2}{2}$
      $//$ *calculeaza eroarea pentru exemplul* x_t
      iii. $W = W - \eta(y_{hat} - y_t)x_t$ $//$ *actualizeaza ponderile folosind* $\frac{\partial loss}{\partial W}$
      iv. $b = b - \eta(y_{hat} - y_t)$ $//$ *actualizeaza bias − ul folosind* $\frac{\partial loss}{\partial b}$

3. Retele feedforward de perceptroni

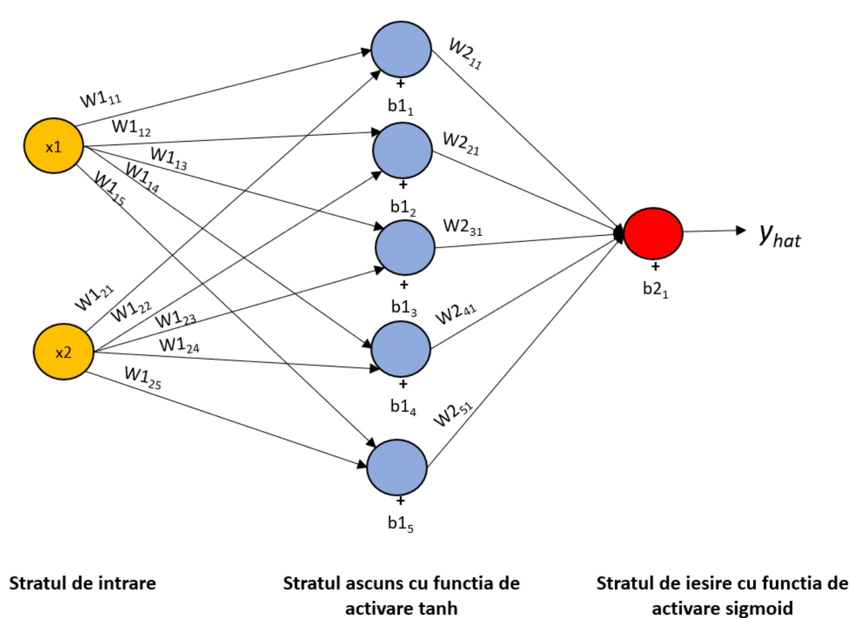

O retea neuronala cu 5 perceptronii pe stratul ascuns si un perceptron pe stratul de iesire.

Retelele neurale feedforward sunt retele de perceptroni grupati pe straturi, in care propagarea informatiei se realizeaza numai dinspre intrare spre iesire (de la stanga la dreapta). Retelele feedforward sunt multistrat, continand mai multe straturi de perceptroni. Perceptronii de pe primul strat sunt singurii care primesc date de intrare din exterior. Perceptronii de pe celelalte straturi (numite *straturi ascunse (hidden layers)*), primesc ca date de intrare rezultatul stratului anterior. Ultimul strat din retea se numeste *strat de iesire (output layer)*.

In cadrul laboratorului vom antrena o retea cu un strat ascuns cu ***num_hidden_neurons*** neuroni si functia de activare ***tanh*** si un neuron pe stratul de iesire cu functie de activare ***logistic*** (sigmoid) pentru rezolvarea problemei **XOR**. Predictia retelei pentru un exemplu X este

$y_{hat} = sigmoid(tanh(X \cdot W_1 + b_1) \cdot W_2 + b_2)$.

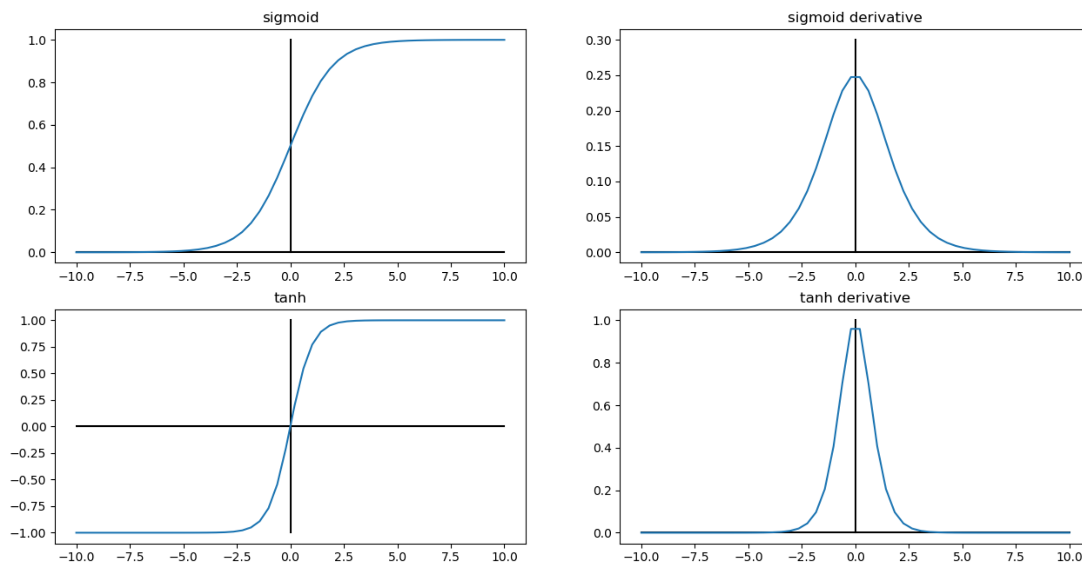

Stânga -sus: graficul functiei sigmoid; *Dreapta-jos*: graficul functiei sigmoid derivat. *Stânga Jos*:graficul funcției tanh; *Dreapta-jos*: graficul functiei tanh derivat.

Functia de pierdere pe care o vom folosi pentru antrenarea retelei este: $logistic_loss(y_{hat}, y) = -(y * log(y_{hat}) + (1 - y) * log(1 - y_{hat}))$, unde y_{hat} este predicția rețelei pentru exemplul X, iar y este eticheta binara (0 sau 1) a lui X

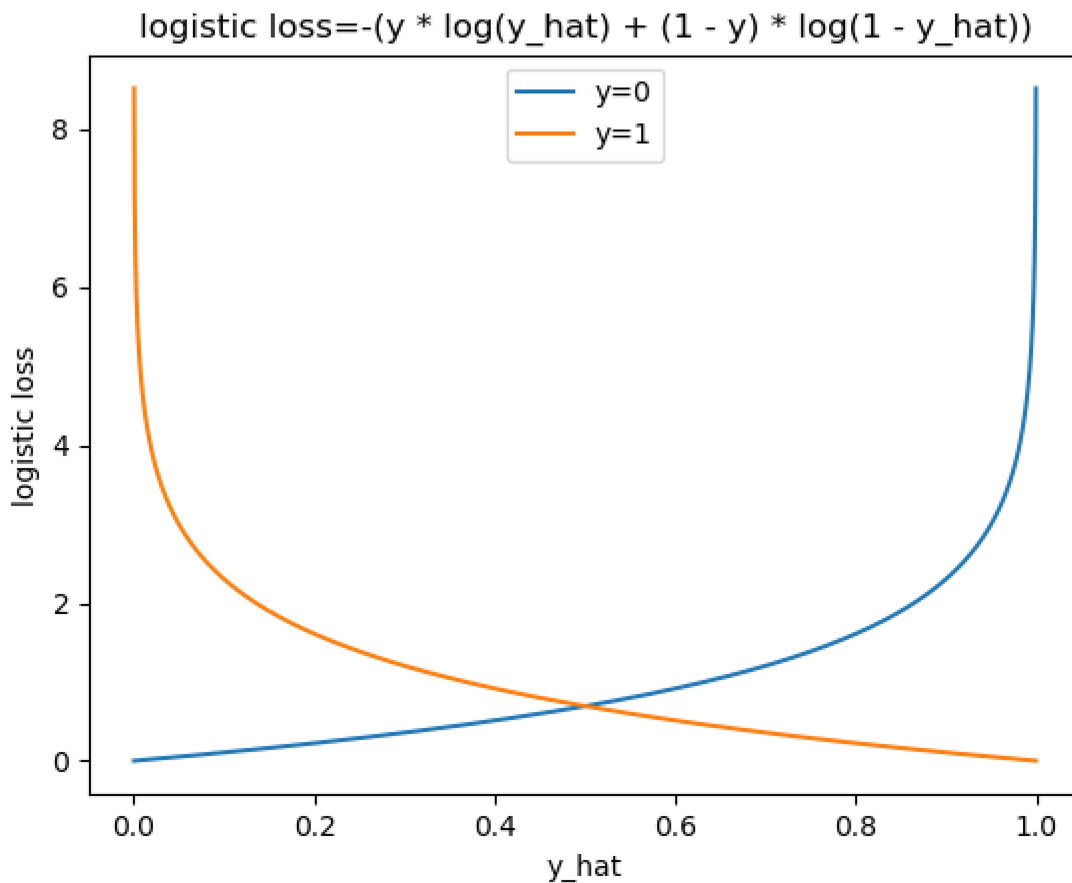

Linia portocalie: valoarea functiei *logistic loss*, cand y=1, iar *y_hat* variaza intre (0,1). Observam ca cu cat ne apropiem de 1 (pe axa Ox) valoarea functiei scade. Se observa ca daca y=1, valoarea functiei este data doar de produsul din partea stanga (partea dreapta inmultindu-se cu 0).
Linia albastra: valoarea functiei *logistic loss*, cand y=0, iar *y_hat* variaza intre (0,1). Observam ca cu cat ne indepartam de 0 (pe axa Ox) valoarea functiei creste. Se observa ca daca y=0, valoarea functiei este data doar de produsul din partea dreapta (partea stanga inmultindu-se cu 0).

4. Antrenarea retelelor de perceptroni cu algoritmul coborarii pe gradient

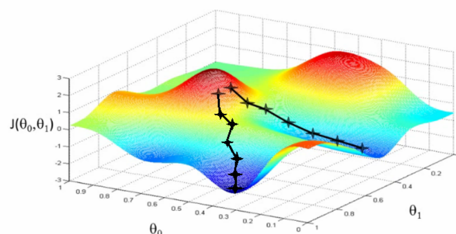

Observam ca in functie de initializarea ponderilor putem ajunge in minime locale diferite.

Algoritmul coborarii pe gradient se bazeaza pe derivata de ordinul 1, pentru a gasi minimul functiei de pierdere. Pentru a gasi un minim local al functiei de pierdere, vom actualiza ponderile retelei proportional cu negativul gradientului functiei la pasul curent.

In continuare vom detalia implementarea (pseudo-cod) algoritmului de coborare pe gradient pentru reteaua descrisa anterior.

Pasii algoritmului sunt:

1) Initializare ponderilor - ponderile si bias-ul retelei se initializeaza aleator cu valori mici aproape de 0 sau cu valoare 0.

```
W_1 = random((2, num_hidden_neurons), miu, sigma)
# generam aleator matricea ponderilor stratului ascuns (2 -
dimensiunea datelor de intrare, num_hidden_neurons - numarul
neuronilor de pe stratul ascuns), cu media miu  si deviatia
standard sigma.
b_1 = zeros(num_hidden_neurons) # initializam bias-ul cu 0
W_2 = random((num_hidden_neurons, 1), miu, sigma)
# generam aleator matricea ponderilor stratului de iesire
(num_hidden_neurons - numarul neuronilor de pe stratul ascuns, 1
- un neuron pe stratul de iesire), cu media miu  si deviatia
standard sigma.
b_2 = zeros(1) # initializam bias-ul cu 0
```

2) Pasul **forward -** Vom defini o metoda forward care calculeaza predictia retelei folosind ponderile actuale si datele de intrare date ca parametri, apoi vom calcula pentru fiecare strat valoarea lui ***z*** (***z*** = inmultirea datelor de intrare cu ponderile si adunarea bias-ului) si valoarea lui ***a*** (***a*** = aplicarea functiei de activare lui ***z***, ($a = f(z)$)).

```
forward(X, W_1, b_1, W_2, b_2)
# X - datele de intrare,  W_1, b_1, W_2 si b_2 sunt ponderile
retelei
z_1 =  X * W_1 + b_1
a_1 = tanh(z_1)
z_2 = a_1 * W_2 + b_2
a_2 = sigmoid(z_2)
return z_1, a_1, z_2, a_2 # vom returna toate elementele
calculate
```

3) Calculam valoarea functiei de eroare (logistic loss) si acuratetea.

```
z_1, a_1, z_2, a_2 = forward(X, W_1, b_1, W_2, b_2)
loss = (-y .* log(a_2) - (1 - y) .* log(1 - a_2)).mean()
accuracy = (round(a_2) == y).mean()
```

functia	***derivata***	***Derivata functiei compuse***
$sigmoid(x) \ = \ \frac{}{1}$	$sigmoid(x) \ * \ (1 - sigmoi$	$sigmoid(u(x)) \ * \ (1 - sigmoid(u(x))) \ *$
$tanh(x) \ = \ \frac{e^{2x}-}{e^{2x}+}$	$1 \ - \ tanh(x)^2$	$(1 \ - \ tanh(u(x))^2) \ * \ u(x)'$
x	1	$-$
$c \ * \ x$	c	$-$
$ln\ x$	$\frac{1}{x}$	$\frac{u(x)'}{u(x)}$
x^n	$n \ * \ x^{n-1}$	$n \ * \ u(x)^{n-1} \ * \ u(x)'$

Derivatele functiilor folosite in laborator.

4) Pasul **backward** - vom defini o metoda backward care calculeaza derivata functiei de eroare pe directiile ponderilor, respectiv a fiecarui bias. Vom incepe calculul cu derivata functiei de pierdere pe directia ***z_2*** folosind regula de inlantuire (chain-rule) a derivatelor.

$$\frac{\partial loss}{\partial z_2} = \frac{\partial loss}{\partial a_2} * \frac{\partial a_2}{\partial z_2} \ | \ aplicam\ regula\ de\ inlantuire$$

$$Stim\ ca\ \ a_2 = \ sigmoid(z_2)\ ,\ folosind\ derivata\ functiei\ sigmoid\ \ rezulta:$$

$$\frac{\partial a_2}{\partial z_2} = \frac{sigmoid(z_2)}{\partial z_2} = sigmoid(z_2) \ * \ (1 \ - \ sigmoid(z_2)) \ = \ a_2 \ * \ (1 \ - a_2)$$

$$\frac{\partial loss}{\partial a_2} = \frac{\partial(-y * log(a_2) \ - \ (1 - y) * log(1 - a_2))}{\partial a_2}$$

$$\frac{\partial loss}{\partial a_2} = (\frac{-y}{a_2} + \frac{1 - y}{1 - a_2})$$

$$\frac{\partial loss}{\partial a_2} = \frac{-y + a_2 * y \ + a_2 - a_2 * y}{a_2 * (1 - a_2)}$$

$$\frac{\partial loss}{\partial z_2} = \frac{\partial loss}{\partial a_2} * \frac{\partial a_2}{\partial z_2}$$

$$\frac{\partial loss}{\partial z_2} = \frac{-y + a_2{}^*y + a_2 - a_2{}^*y}{a_2{}^*(1-a_2)} * a_2 * (1 - a_2)$$

$$\frac{\partial loss}{\partial z_2} = a_2 - y$$

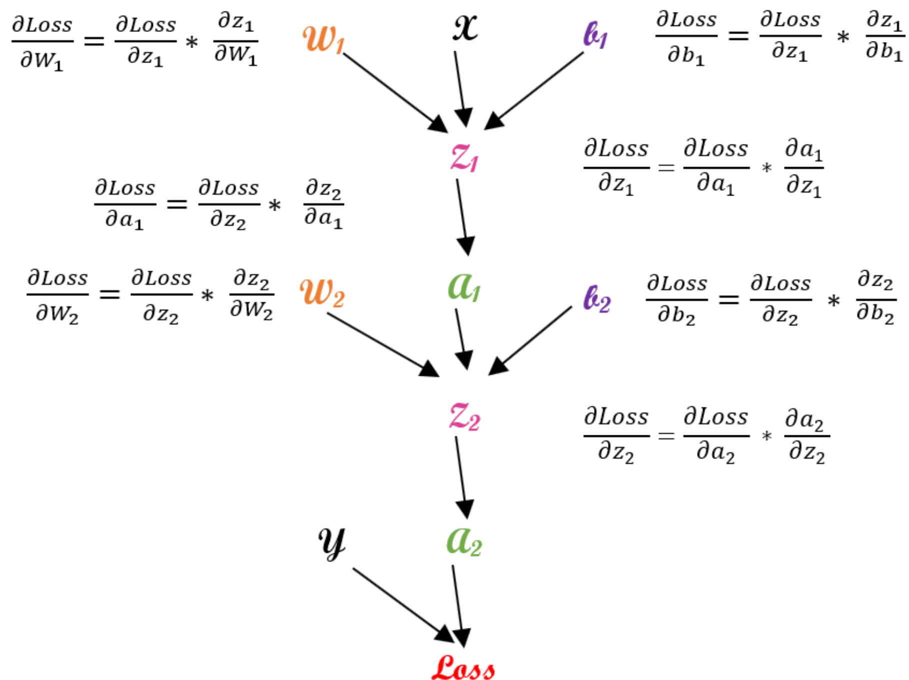

Calcularea derivatele partiale pe directiile ponderilor si a fiecarui bias folosind regula de inlantuire.

```
backward(a_1, a_2, z_1, W_2, X, Y, num_samples)
dz_2 = a_2 - y # derivata functiei de pierdere (logistic loss) in functie de z
dw_2 = (a_1.T * d_z2) / num_samples
# der(L/w_2) = der(L/z_2) * der(dz_2/w_2) = dz_2 * der((a_1 * W_2 + b_2)/ W_2)
db_2 = sum(dz_2) / num_samples
# der(L/b_2) = der(L/z_2) * der(z_2/b_2) = dz_2 * der((a_1 * W_2 + b_2)/ b_2)
# primul strat
da_1 = dz_2 * W_2.T
# der(L/a_1) = der(L/z_2) * der(z_2/a_1) = dz_2 * der((a_1 * W_2 + b_2)/ a_1)
dz_1 = da_1 .* tanh_derivative(z_1)
# der(L/z_1) = der(L/a_1) * der(a_1/z1) = da_1 .* der((tanh(z_1))/ z_1)
```

```
dw_1 = X.T * dz_1 / num_samples
# der(L/w_1) = der(L/z_1) * der(z_1/w_1) = dz_1 * der((X * W_1 +
b_1)/ W_1)
db_1 = sum(dz_1) / num_samples
# der(L/b_1) = der(L/z_1) * der(z_1/b_1) = dz_1 * der((X * W_1 +
b_1)/ b_1)
return dw_1, db_1, dw_2, db_2
```

5) Actualizarea ponderilor - ponderile se actualizeaza proportional cu negativul mediei derivatelor din batch (mini-batch).

```
W_1 -= lr * dw_1 # lr - rata de invatare (learning rate)
b_1 -= lr * db_1
W_2 -= lr * dw_2
b_2 -= lr * db_2
```

6) Pentru a antrena o retea neuronala cu ajutorul algoritmului coborarii pe gradient trebuie sa:
    a) Stabilim numarul de epoci
    b) Stabilim rata de invatare
    c) Sa initiliazam ponderile (pasul 1)
    d) Sa amestecam datele la fiecare epoca
    e) Sa luam un subset din multimea (sau toata multimea) de antrenare si sa executam pasii 2, 3, 4, 5 pana la convergenta.

Exercitii

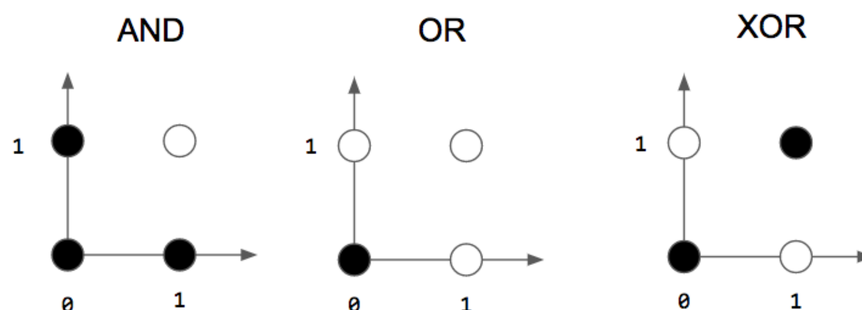

1. Se da urmatoare multime de antrenare X =[[0, 0], [0, 1], [1, 0], [1, 1]], y = [-1, 1, 1, 1]. Sa se gaseasca o dreapta care separa perfect multimea de antrenare.
2. Antrenati un Perceptron cu algoritmul Widrow-Hoff pe multimea de antrenare de la exercitiul anterior timp de 70 epoci cu rata de invatare 0.1. Care este acuratetea pe multimea de antrenare? Apelati functia *plot_decision_boundary* la fiecare pas al algoritmului pentru a afisa dreapta de decizie.

```
import matplotlib.pyplot as plt

def compute_y(x, W, bias):
    # dreapta de decizie
    # [x, y] * [W[0], W[1]] + b = 0
    return (-x * W[0] - bias) / (W[1] + 1e-10)

def plot_decision_boundary(X, y , W, b, current_x, current_y):
    x1 = -0.5
    y1 = compute_y(x1, W, b)
    x2 = 0.5
    y2 = compute_y(x2, W, b)
    # sterge continutul ferestrei
    plt.clf()
    # ploteaza multimea de antrenare
    color = 'r'
    if(current_y == -1):
        color = 'b'
    plt.ylim((-1, 2))
    plt.xlim((-1, 2))
    plt.plot(X[y == -1, 0], X[y == -1, 1], 'b+')
    plt.plot(X[y == 1, 0], X[y == 1, 1], 'r+')
    # ploteaza exemplul curent
    plt.plot(current_x[0], current_x[1], color+'s')
    # afisarea dreptei de decizie
    plt.plot([x1, x2] ,[y1, y2], 'black')
    plt.show(block=False)
    plt.pause(0.3)
```

3. Antrenati un Perceptron cu algoritmul Widrow-Hoff pe multimea de antrenare X =[[0, 0], [0, 1], [1, 0], [1, 1]], y = [-1, 1, 1, -1]. Care este acuratetea pe multimea de antrenare? Apelati functia *plot_decision_boundary* la fiecare pas al algoritmului pentru a afisa dreapta de decizie.
4. Antrenati o retea neuronala pentru rezolvarea problemei XOR cu arhitectura retelei descrise in **3**, si algoritmul coborarii pe gradient descris in **4**, folosind 70 epoci, rata de invatare 0.5, media si deviatia standard pentru initializarea ponderilor 0, respectiv 1, si 5 neuroni pe stratul ascuns. Afisati valoarea erorii si a acuratetii la fiecare epoca. Apelati functia *plot_decision* la fiecare pas al algoritmului pentru a afisa functia de decizie.

```
def compute_y(x, W, bias):
    # dreapta de decizie
    # [x, y] * [W[0], W[1]] + b = 0
    return (-x*W[0] - bias) / (W[1] + 1e-10)

def plot_decision(X_, W_1, W_2, b_1, b_2):
```

```
    # sterge continutul ferestrei
    plt.clf()
    # ploteaza multimea de antrenare
    plt.ylim((-0.5, 1.5))
    plt.xlim((-0.5, 1.5))
    xx = np.random.normal(0, 1, (100000))
    yy = np.random.normal(0, 1, (100000))
    X = np.array([xx, yy]).transpose()
    X = np.concatenate((X, X_))
    _, _, _, output = forward(X, W_1, b_1, W_2, b_2)
    y = np.squeeze(np.round(output))
    plt.plot(X[y == 0, 0], X[y == 0, 1], 'b+')
    plt.plot(X[y == 1, 0], X[y == 1, 1], 'r+')
    plt.show(block=False)
    plt.pause(0.1)
```

Retele de perceptroni - Pytorch & Scikit Learn

Definirea unei retele de perceptroni in Scikit-learn

```
from sklearn.neural_network import MLPClassifier # importul clasei


mlp_classifier_model = MLPClassifier(hidden_layer_sizes=(100, ),
activation='relu', solver='adam', alpha=0.0001, batch_size='auto',
learning_rate='constant', learning_rate_init=0.001, power_t=0.5,
max_iter=200, shuffle=True, random_state=None, tol=0.0001,
momentum=0.9, early_stopping=False, validation_fraction=0.1,
n_iter_no_change=10)
```

Parametrii:

- hidden_layer_sizes (tuple, lungime= n_layers - 2, default=(100,)): al i-lea element reprezinta numarul de neurori din al i-lea strat ascuns.
- activation({'identity', 'logistic', 'tanh', 'relu'}, default='relu')
- solver ({'lbfgs', 'sgd', 'adam'}, default='adam'): regula de invatare (update)
- 'sgd' - stochastic gradient descent (doar pe acesta il vom folosi).
- batch_size: (int, default='auto')
- auto - marimea batch-ului pentru antrenare este min(200, n_samples).
- learning_rate_init (double, default=0.001): rata de invatare
- max_iter (int, default=200): numarul maxim de epoci pentru antrenare.
- shuffle (bool, default=True): amesteca datele la fiecare epoca
- tol (float, default=1e-4) :
- Daca eroarea sau scorul nu se imbunatatesc timp n_iter_no_chage epoci consecutive (si learning_rate != 'adaptive') cu cel putin tol, antrenarea se opreste.
- n_iter_no_change : (int, optional, default 10, sklearn-versiune-0.20)
- Numarul maxim de epoci fara imbunatatiri (eroare sau scor).
- alpha (float, default=0.0001): parametru pentru regularizare L2.
- learning_rate ({'constant', 'invscaling', 'adaptive'}, default='constant'):
- 'constant' : rata de invatare este constanta si este data de parametrul learning_rate_init.
- 'invscaling': rata de invatare va fi scazuta la fiecare pas t, dupa formula: new_learning_rate = learning_rate_init / pow(t, power_t)
- 'adaptive': pastreaza rata de invatare constanta cat timp eroarea scade. Daca eroarea nu scade cu cel putin tol (fata de epoca anterior) sau daca scorul pe multimea de validare (doar daca ealy_stopping=True) nu creste cu cel putin tol (fata de epoca anteriora), rata de invatare curenta se imparte la 5.
- power_t (double, default=0.5): parametrul pentru learning_rate='invscaling'.
- momentum (float, default=0.9): - valoarea pentru momentum cand se foloseste gradient descent cu momentum. Trebuie sa fie intre 0 si 1.

- early_stopping (bool, default=False):
- Daca este setat cu True atunci antrenarea se va termina daca eroarea pe multimea de validare nu se imbunatateste timp n_iter_no_chage epoci consecutive cu cel putin tol.
- validation_fraction (float, optional, default=0.1):
- Procentul din multimea de antrenare care sa fie folosit pentru validare (doar cand early_stopping=True). Trebuie sa fie intre 0 si 1.

Mai departe in restul laboratorului ne vom focusa pe implementara retelelor neuronale folosind libraria Pytorch

Install Pytorch

Accesati linkul: https://pytorch.org, iar la sectiunea "Install Pytorch" selectati detaliile conform specificatiilor masinii voastre. Mai precis, daca masina dispune de o placa video atunci lasati selectia nemodificata, in caz contrar selectati CPU in campul "Compute Platform".

Exemplu configuratie masina cu GPU:

PyTorch Build	**Stable (1.13.1)**	Preview (Nightly)		
Your OS	Linux	Mac	**Windows**	
Package	**Conda**	Pip	LibTorch	Source
Language	**Python**	C++ / Java		
Compute Platform	**CUDA 11.6**	CUDA 11.7	~~ROCm 5.2~~	CPU
Run this Command:	conda install pytorch torchvision torchaudio pytorch-cuda=11.6 -c pytorch -c nvidia			

Exemplu configuratie masina doar cu CPU:

PyTorch Build	**Stable (1.13.1)**	Preview (Nightly)		
Your OS	Linux	Mac	**Windows**	
Package	**Conda**	Pip	LibTorch	Source
Language	**Python**	C++ / Java		
Compute Platform	CUDA 11.6	CUDA 11.7	~~ROCm 5.2~~	**CPU**
Run this Command:	conda install pytorch torchvision torchaudio cpuonly -c pytorch			

Pentru a verifica daca instalarea a fost cu succes, puteti rula urmatorul bloc de cod:

```
import torch
x = torch.rand(5, 3)
print(x)
```

Pentru a verifica daca GPU-ul este accesibil de catre Pytorch, puteti rula codul urmator. Daca totul este in regula, ultima linie ar trebui sa returneze True.

```
import torch
torch.cuda.is_available()
```

Definirea retelei neuronale

Pentru a crea un model in Pytorch este necesar sa extindem clasa **nn.Module**, iar in constructor vom defini straturile retelei care vor fi folosite in implementarea functiei **forward**. Mai jos aveti un exemplu pentru un Multilayer Perceptron cu un singur strat ascuns.

- stratul **Flatten** transforma datele de intrare in vectori 1-dimensionali.
- stratul **Linear** aplica o transformare liniara: xWT+b. Pentru acest strat trebuie sa specificam dimensiunile matricei W, care corespund cu dimensiunea tensorilor de intrare si iesire.

```
import torch.nn as nn
import torch.nn.functional as F

class NeuralNetwork(nn.Module):
    def __init__(self):
        super().__init__()
        self.flatten = nn.Flatten()
        self.first_layer = nn.Linear(28*28, 512)
        self.second_layer = nn.Linear(512, 512)
        self.output_layer = nn.Linear(512, 10)


    def forward(self, x):
        x = self.flatten(x)
        x = F.relu(self.first_layer(x))
        x = F.relu(self.second_layer(x))
        x = self.output_layer(x)
        return x
```

Trecerea unui exemplu prin reteaua precedenta se poate executa in felul urmator:

```
model = NeuralNetwork()
model(torch.rand(5, 1, 28, 28)).shape
```

Antrenarea retelei

Pentru antrenarea retelei avem nevoie de date de antrenare, un algoritm de optimizare si o functie de pierdere pe care sa o minimizam pe setul de antrenare.

Vom folosi MNIST pentru a ilustra o procedura de antrenare in Pytorch, ca algoritm de optimizare vom folosi stochastic gradient descent (SGD), iar functia de optimizare va fi cross entropy.

Crearea seturilor de date si a dataloader-lor care ne vor ajuta sa iteram prin batch-uri in timpul unei epoci:

```
from torchvision import datasets
from torchvision.transforms import ToTensor
from torch.utils.data import DataLoader

train_data = datasets.MNIST(
    root="data",
    train=True,
    download=True,
    transform=ToTensor()
)

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

train_dataloader = DataLoader(train_data, batch_size=64)
test_dataloader = DataLoader(test_data, batch_size=64)
```

Crearea modelului si definirea algoritmului de optimizare:

```
model = NeuralNetwork()
optimizer = torch.optim.SGD(model.parameters(), lr=1e-2)
```

Antrenarea retelei :

```
NUM_EPOCHS=10
device = "cuda" if torch.cuda.is_available() else "cpu" # decidem device-ul pe care sa il fo
model = model.to(device)
loss_function = nn.CrossEntropyLoss() # functia ce trebuie optimizata, cross entropia

model.train(True)
for i in range(NUM_EPOCHS):
    print(f"=== Epoch {i+1} ===")
    for batch, (image_batch, labels_batch) in enumerate(train_dataloader): # iteram prin ba
```

```
        image_batch = image_batch.to(device)
        labels_batch = labels_batch.to(device) #(batch_size, )
        print(image_batch.shape)
        print(labels_batch.shape)

        pred = model(image_batch) # procesam imaginile prin retea
        print(pred.shape)
        loss = loss_function(pred, labels_batch) # determinam functia de pieredere folosind
                                                  # si label-urile reale ale exemplelor de an

        # Backpropagation
        optimizer.zero_grad()
        loss.backward() # backpropagation
        optimizer.step() # optimizam parametrii retelei

        if batch % 100 == 0:
                loss = loss.item()
                print(f"Batch index {batch }, loss: {loss:>7f}")
```

Testarea performantei:

```
correct = 0.
test_loss = 0.
size = len(test_dataloader.dataset)
model.to(device)
model.eval()
with torch.no_grad():
        for image_batch, labels_batch in test_dataloader: # iteram prin datele de test

            image_batch = image_batch.to(device)
            labels_batch = labels_batch.to(device)
            pred = model(image_batch) # procesam imaginile folosind reteaua antrenata anter
            test_loss += loss_function(pred, labels_batch).item()
            correct += (pred.argmax(1) == labels_batch).type(torch.float).sum().item() # num


correct /= size
test_loss /= size
print(f"Accuracy: {(100*correct):>0.1f}%, Loss: {test_loss:>8f} \n")
```

Exercitii

1. Antrenati o retea de perceptroni care sa clasifice cifrele scrise de mana MNIST. Datele trebuie normalizate prin scaderea mediei si impartirea la deviatia standard. Antrenati pentru 5 epoci si testati urmatoarele configuratii de retele:

a. Definiti o retea cu un singur strat ascuns cu un singur neuron si folositi ca functie de activare tanh. Pentru optimizator folositi un learning rate de 1e-2.

b. Definiti o retea cu un singur strat ascuns cu 10 neuroni si folositi ca functie de activare tanh. Pentru optimizator folositi un learning rate de 1e-2.

c. Definiti o retea cu un singur strat ascuns cu 10 neuroni si folositi ca functie de activare tanh. Pentru optimizator folositi un learning rate de 1e-5.

d. Definiti o retea cu un singur strat ascuns cu 10 neuroni si folositi ca functie de activare tanh. Pentru optimizator folositi un learning rate de 10.

e. Definiti o retea cu 2 straturi ascunse cu 10 neuroni fiecare si folositi ca functie de activare tanh. Pentru optimizator folositi un learning rate de 1e-2.

f. Definiti o retea cu 2 straturi ascunse cu 10 neuroni fiecare si folositi ca functie de activare relu. Pentru optimizator folositi un learning rate de 1e-2.

g. Definiti o retea cu 2 straturi ascunse cu 100 neuroni fiecare si folositi ca functie de activare relu. Pentru optimizator folositi un learning rate de 1e-2.

h. Definiti o retea cu 2 straturi ascunse cu 100 neuroni fiecare si folositi ca functie de activare relu. Pentru optimizator folositi un learning rate de 1e-2 si momentum=0.9

```python
import os
import pandas as pd
from torchvision.io import read_image

class CustomImageDataset(Dataset):
    def __init__(self, annotations_file, img_dir, transform=None, target_transform=None):
        self.img_labels = pd.read_csv(annotations_file)
        self.img_dir = img_dir
        self.transform = transform
        self.target_transform = target_transform

    def __len__(self):
        return len(self.img_labels)

    def __getitem__(self, idx):
        img_path = os.path.join(self.img_dir, self.img_labels.iloc[idx, 0])
        image = read_image(img_path)
        label = self.img_labels.iloc[idx, 1]
        if self.transform:
            image = self.transform(image)
        if self.target_transform:
            label = self.target_transform(label)
        return image, label
```