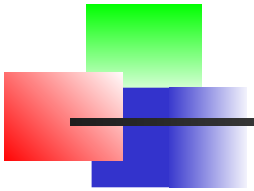

IA Embarquée

Introduction 2

P. Bakowski

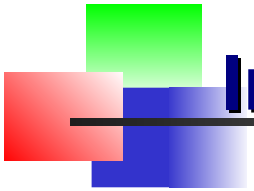

Intelligence Artificielle (IA) et IA Embarquée

- Introduction
- Matériel pour l'IA Embarquée
- Logiciel pour l'IA Embarquée
- **Laboratoire 0 – Introduction au Réseaux Neuronaux**
- Laboratoire 1 – Régression Linéaire et Polynomiale
- Laboratoire 2 – Réseaux Denses et Convolutifs (MNIST)
- Laboratoire 3 – Réseaux Auto-encodeurs
- Laboratoire 4 – Inférence avec des modèles entraînés
- Laboratoire 5 – Développement d'une Application

Introduction – IA, ML et DL

- Le **Machine Learning** est une technologie d'intelligence artificielle permettant aux ordinateurs d'apprendre **sans avoir été programmés** explicitement à cet effet.

- Pour apprendre et se développer, les ordinateurs ont toutefois **besoin de données** à analyser et sur lesquelles ils doivent **s'entraîner**.

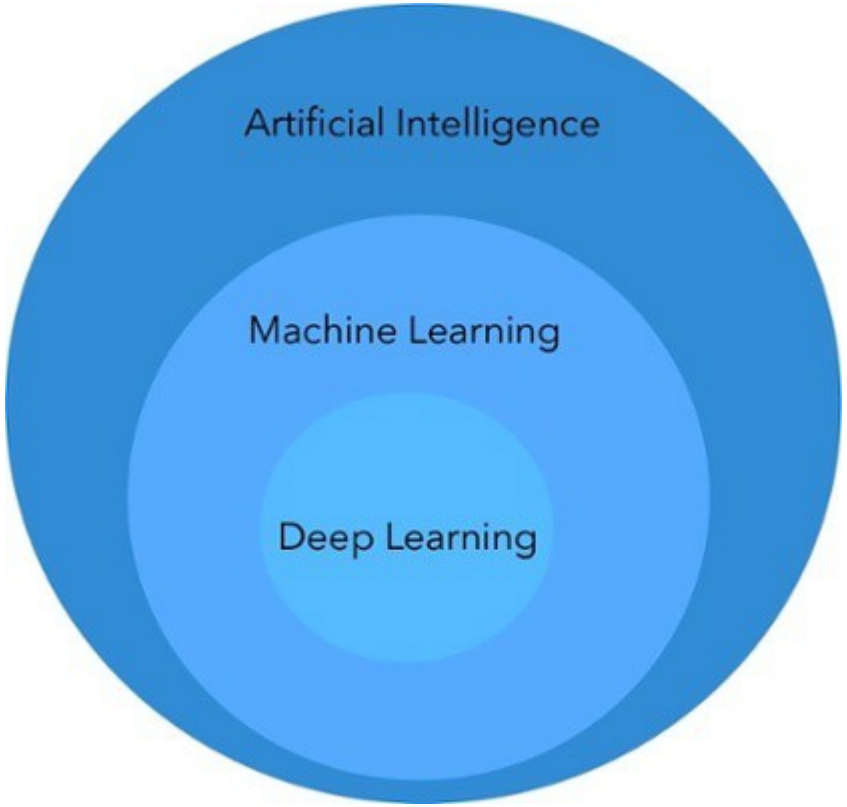

Introduction – IA, ML et DL

- L'**apprentissage profond** est un ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes **transformations non linéaires**.

- Ces techniques ont permis des progrès importants et rapides dans les domaines de l'analyse du **signal sonore ou visuel** et notamment de la **reconnaissance faciale**, de la **reconnaissance vocale**, de la **vision par ordinateur**, du traitement automatisé du langage.

Introduction – IA Embarquée

- Grâce à notre capacité à construire des machines intelligentes qui simulent l'intelligence humaine, les implications pour le progrès technologique dans de nombreux secteurs sont infinies. Alors, **quoi de mieux que l'intelligence artificielle** ?

- **Intelligence Artificielle Embarquée.**

- L'intelligence artificielle (IA) embarquée est l'application de **ML** et **DL** au **niveau de l'appareil** (*embedded device*)

- L'Appareil ou *embedded device* est un **SoC** ou un **FPGA** intégré sur une carte autonome – **SCB** (S*ingle Computer Board*)

- Exemples : Nvidia -Jetson Nano, Xavier, Google - CORAL, ..

Introduction – Logiciel

- Les logiciels fonctionnant sur le équipements IA embarquées sont (presque) les mêmes que ceux sur les équipements standards (PC, serveurs,..)
- **Langages :** C/C++ et Python
- **Packages :** PyNum, Ski-Learn, ..
- **Couches applicatives :** Keras, TensorFlow, PyTorch,..

  TensorFlow => TensorFlow Lite
- **Couches d'exécution** : CUDA, cuDNN, ..
- **OS** : Linux, FreeRTOS, ..

Introduction – Un Neurone

- Un **Neurone** est un mécanisme essentiel dans le développement des applications d'IA. Voici sa structure fonctionnelle :

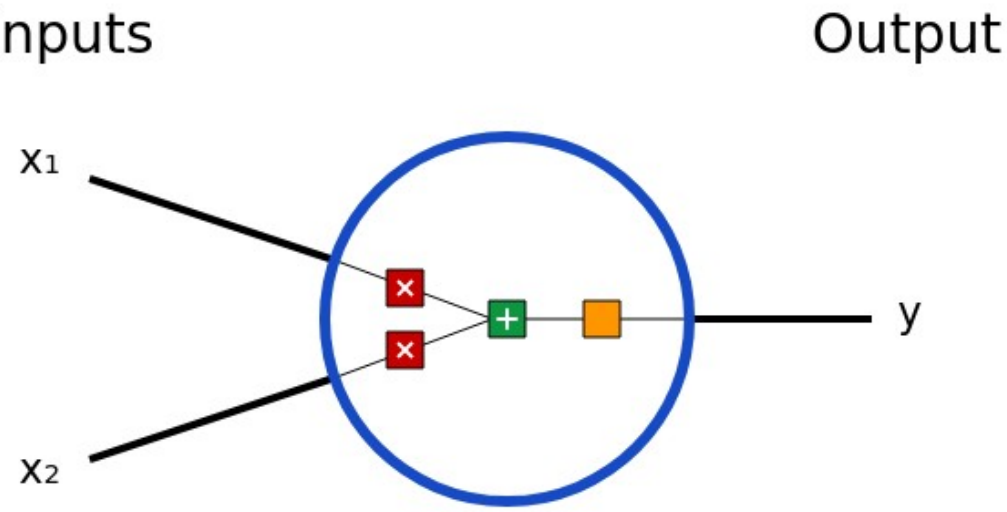

- **y = f(x1*w1+x2*w2+b)**
- où : **w1** et **w2** sont des **poids** (*weights*) et **b** est un **biais**

Introduction – Un Neurone

y = f(x1*w1+x2*w2+b)

3 choses se passent ici :

Tout d'abord, chaque entrée (**x1** et **x2**) est multipliée par un poids **w1** et **w2**:

x1∗w1 et **x2∗w2**

Ensuite, toutes les **entrées pondérées** sont additionnées avec un **biais b** :

(x1∗w1)+(x2∗w2)**+b**

Enfin, la somme passe par une **fonction d'activation** :

y=f(x1∗w1+x2∗w2+b**)**

Introduction – Un Neurone

$$y = f(x1*w1+x2*w2+b)$$

La **fonction d'activation** est utilisée pour transformer une entrée illimitée en une sortie qui a une forme agréable et prévisible.

Une fonction d'activation couramment utilisée est la fonction **sigmoïde** (ou **ReLU - Rectified Linear Unit**):

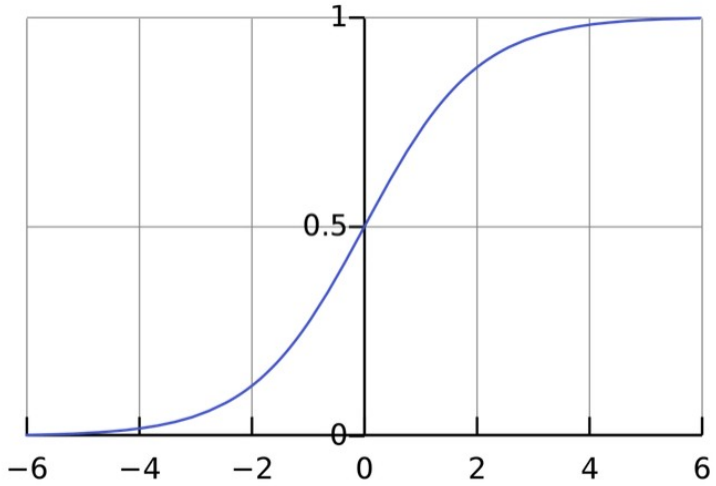

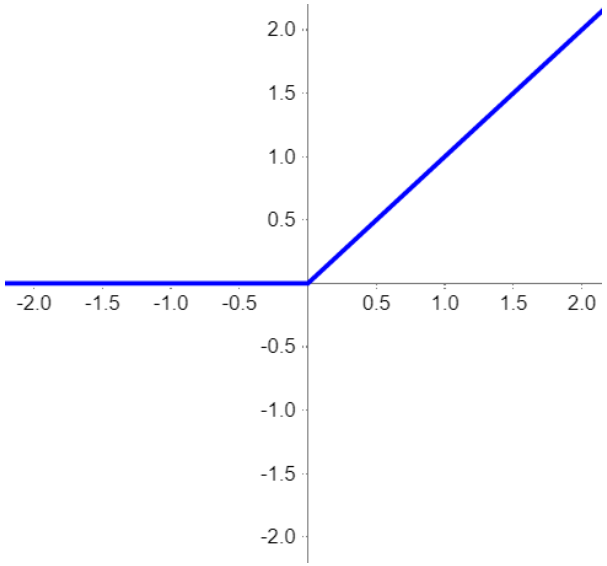

Un exemple simple

- Supposons **un neurone à 2 entrées** qui utilise la fonction d'activation **sigmoïde** et possède les paramètres suivants :

- **w=[0,1]** et **b=4 ou w=[0,1] signifie w1=0 et w2=1**

- Donnons au neurone une entrée de **x=[2,3]**. Nous utiliserons le **produit scalaire** (· **- dot**) pour écrire les choses de manière plus concise :

- **(w·x)+b=((w1∗x1)+(w2∗x2))+b=0∗2+1∗3+4=...**

- **y=f(w·x+b)=f(7)=...**

- En sachant que **f(x)** est **1/(1-e^-x)** calculez vous même le résultat.

Codage d'un neurone

```
import numpy as np

def sigmoid(x):
  return 1 / (1 + np.exp(-x))

class Neuron:
  def __init__(self, weights, bias):
    self.weights = weights
    self.bias = bias

  def feedforward(self, inputs):
    total = np.dot(self.weights, inputs) + self.bias
    return sigmoid(total)

weights = np.array([0, 1]) # w1 = 0, w2 = 1
bias = 4                   # b = 4
n = Neuron(weights, bias)

x = np.array([2, 3])       # x1 = 2, x2 = 3
print(n.feedforward(x))    # 0.9990889488055994
```

Codage d’un neurone

- **Pour cet exemple n**ous utiliserons la plateforme Google Colab

Qu'est-ce que **Colaboratory** ?

Colaboratory, souvent raccourci en "Colab", vous permet d'écrire et d'exécuter du **code Python** dans **votre navigateur**.

Il offre les **avantages** suivants :

1. Aucune configuration requise
2. Accès gratuit aux **GPU**/**TPU**
3. Partage facile

Codage d'un neurone

Page d'accueil

Votre notebook

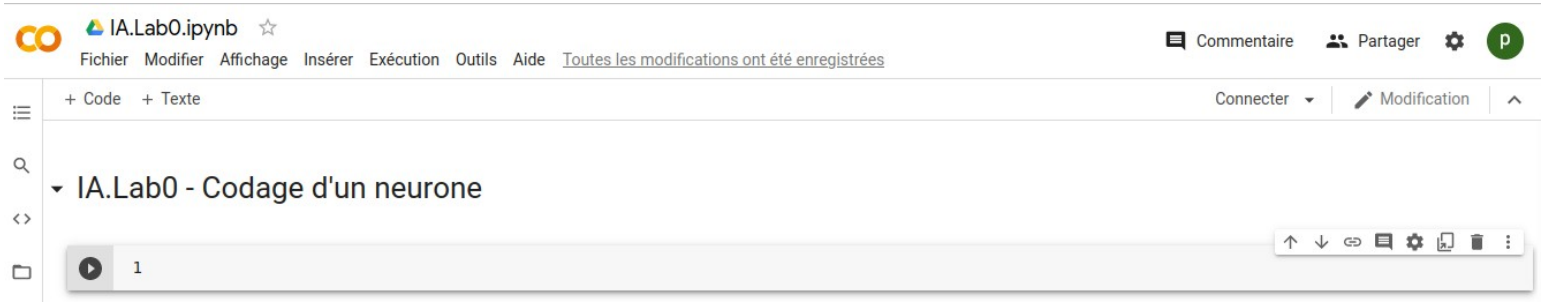

Codage d'un neurone

Notre premier exemple - neurone

A vous de référer cet exemple sur votre compte Google Colab

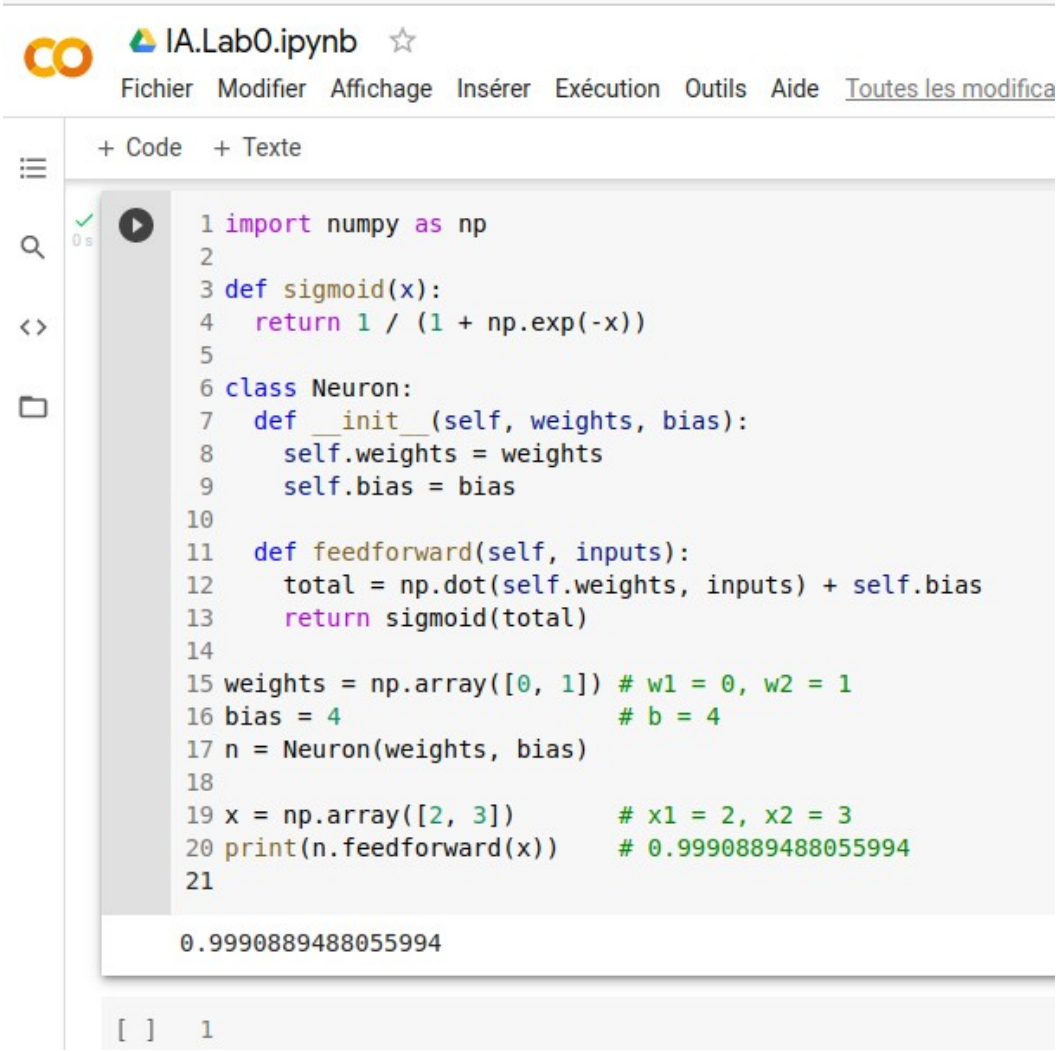

Un réseau de neurones (NN)

Un réseau de neurones n'est rien de plus qu'un **groupe de neurones connectés** entre eux. Voici à quoi pourrait ressembler un simple réseau de neurones :

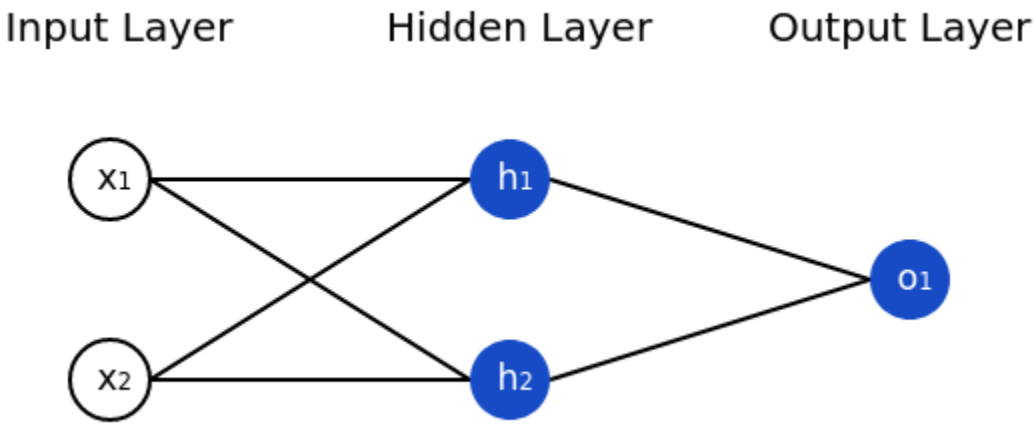

Ce réseau a 2 entrées, une couche cachée avec 2 neurones (**h1** et **h2**), et une couche de sortie avec 1 neurone (**o1**). Notez que les entrées de **o1** sont les sorties de **h1** et **h2**- c'est ce qui en fait un réseau.

Un exemple : Feed-Forward

Utilisons le réseau illustré ci-dessus et supposons que tous les neurones ont les mêmes poids **w=[0,1]**, le même biais **b=0** et le même fonction d'activation sigmoïde. Soit **h1**,**h2**,**o1** les sorties des neurones qu'ils représentent.

Que se passe-t-il si on passe l'entrée **x=[2,3]** ?

$$h1=h2=f(w\cdot x+b)=f((0*2)+(1*3)+0)=f(3)=0.9526$$

$$o1=f(w\cdot[h1,h2]+b)=f((0*h1)+(1*h2)+0)=f(0.9526)=0.7216$$

La sortie **o1** du réseau neuronal pour l'entrée **x=[2,3]** est de **0,72160.**

Codage du réseau : Feed-Forward

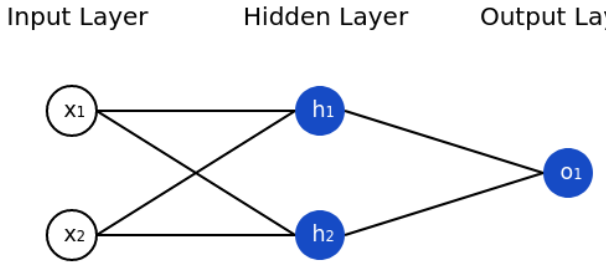

IA.Lab0.ipynb

Fichier Modifier Affichage Insérer Exécution Outils Aide Toutes les modifica

+ Code + Texte

```python
import numpy as np

def sigmoid(x):
  return 1 / (1 + np.exp(-x))

class Neuron:
  def __init__(self, weights, bias):
    self.weights = weights
    self.bias = bias

  def feedforward(self, inputs):
    total = np.dot(self.weights, inputs) + self.bias
    return sigmoid(total)

weights = np.array([0, 1]) # w1 = 0, w2 = 1
bias = 4                   # b = 4
n = Neuron(weights, bias)

x = np.array([2, 3])       # x1 = 2, x2 = 3
print(n.feedforward(x))    # 0.9990889488055994
```

```
0.9990889488055994
```

[ ] 1

+ Code + Texte

```python
import numpy as np

# ... code from previous section here

class OurNeuralNetwork:
  '''
  A neural network with:
    - 2 inputs
    - a hidden layer with 2 neurons (h1, h2)
    - an output layer with 1 neuron (o1)
  Each neuron has the same weights and bias:
    - w = [0, 1]
    - b = 0
  '''
  def __init__(self):  # no arguments, only internal values
    weights = np.array([0, 1])
    bias = 0

    # The Neuron class here is from the previous section
    self.h1 = Neuron(weights, bias)
    self.h2 = Neuron(weights, bias)
    self.o1 = Neuron(weights, bias)

  def feedforward(self, x):
    out_h1 = self.h1.feedforward(x)
    out_h2 = self.h2.feedforward(x)

    # The inputs for o1 are the outputs from h1 and h2
    out_o1 = self.o1.feedforward(np.array([out_h1, out_h2]))

    return out_o1

network = OurNeuralNetwork()
x = np.array([2, 3])
print(network.feedforward(x)) # 0.7216325609518421
```

```
0.7216325609518421
```

Formation d'un réseau de neurones, partie 1

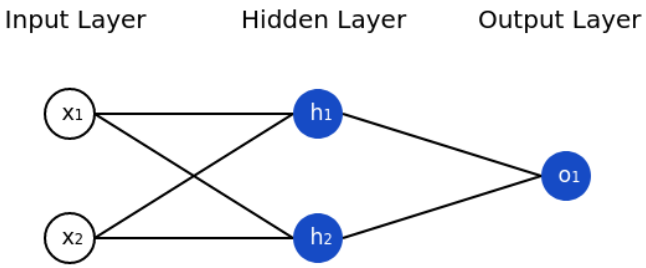

Disons que nous avons les mesures suivantes :

Name	Weight (lb)	Height (in)	Gender
Alice	133	65	F
Bob	160	72	M
Charlie	152	70	M
Diana	120	60	F

Fonction de perte (*loss*)

Avant de former notre réseau, nous avons d'abord besoin d'un moyen de **quantifier à quel point** il se comporte « bien » afin qu'il puisse essayer de faire « mieux ». C'est ça la **perte**.
Nous utiliserons la perte **erreur quadratique moyenne** (***Mean Square Error*** - **MSE**) :

$$\mathrm{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_{true} - y_{pred})^2$$

n est le **nombre d'échantillons**, qui est de **4** (Alice, Bob, Charlie, Diana).
y représente la **variable prédite**, qui est **le sexe**.
ytrue est la **vraie valeur** de la variable (la "bonne réponse").
Par exemple, **ytruey** pour **Alice** serait **1** (Femme).
ypred est la **valeur prédite** de la variable. C'est quelle que soit la sortie de notre réseau.
(ytrue−ypred)^2 est connu comme l'**erreur quadratique**. Notre fonction de perte prend simplement **la moyenne de toutes les erreurs au carré**.

Un exemple de calcul de perte

Disons que notre réseau affiche (prédit) **toujours 0** - en d'autres termes, il est sûr que tous les humains sont des hommes .

Quelle serait notre perte ?

$$\text{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_{true} - y_{pred})^2$$

Name	y_{true}	y_{pred}	$(y_{true} - y_{pred})^2$
Alice	1	0	1
Bob	0	0	0
Charlie	0	0	0
Diana	1	0	1

$$\text{MSE} = \frac{1}{4}(1+0+0+1) = \boxed{0.5}$$

Code : Perte MSE

Voici un code pour calculer la perte pour nous:

$$\text{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_{true} - y_{pred})^2$$

```python
import numpy as np

def mse_loss(y_true, y_pred):
  # y_true and y_pred are numpy arrays of the same length.
  return ((y_true - y_pred) ** 2).mean()

y_true = np.array([1, 0, 0, 1])
y_pred = np.array([0, 0, 0, 0])

print(mse_loss(y_true, y_pred)) # 0.5
```

```
0.5
```

Formation d'un réseau de neurones, partie 2

Notre objectif est de **minimiser la perte du réseau** de neurones.
Nous pouvons **modifier les pondérations et les biais** du réseau pour influencer ses prévisions, mais comment le faire de manière à réduire les pertes ?
Pour simplifier, supposons que nous n'ayons qu'Alice dans notre ensemble de données :

Name	Weight (minus 135)	Height (minus 66)	Gender
Alice	-2	-1	1

Dans ce cas, la perte d'erreur quadratique moyenne n'est que l'erreur quadratique d'Alice = 1 :

$$\begin{aligned} \text{MSE} &= \frac{1}{1}\sum_{i=1}^{1}(y_{true} - y_{pred})^2 \\ &= (y_{true} - y_{pred})^2 \\ &= (1 - y_{pred})^2 \end{aligned}$$

Formation d'un réseau de neurones, partie 2

Une autre façon de penser à la perte est en fonction des **poids** et des **biais**. Étiquetons chaque poids et biais de notre réseau :

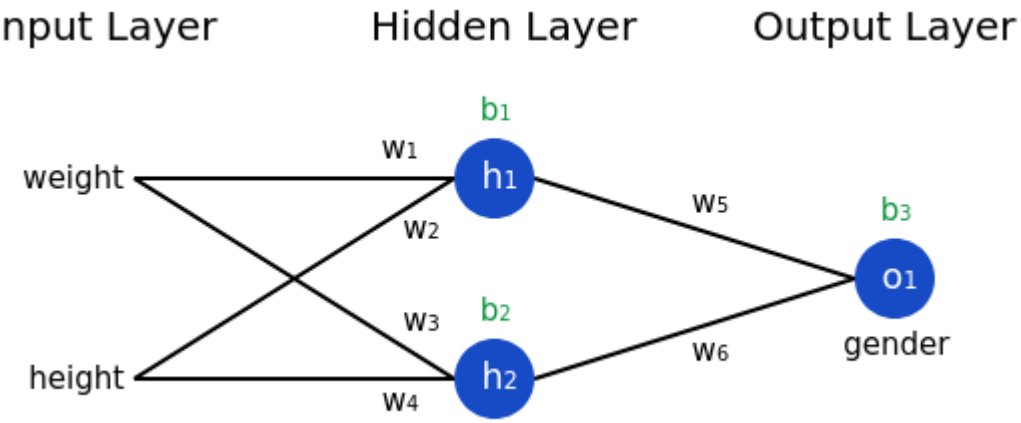

Ensuite, nous pouvons écrire la perte **L** sous la forme d'une **fonction multivariable** :

$$L(w_1, w_2, w_3, w_4, w_5, w_6, b_1, b_2, b_3)$$

Formation d'un réseau de neurones, partie 2

$$L(w_1, w_2, w_3, w_4, w_5, w_6, b_1, b_2, b_3)$$

Imaginez que nous voulions modifier **w1**. Comment la perte **L** changerait-elle si on changeait **w1** ?

C'est une question à laquelle la **dérivée partielle ∂L/∂w1** peut répondre. Comment le calcule-t-on ?

Pour commencer, réécrivons la **dérivée partielle** en termes de **∂ypred/∂w1** à la place :

$$\frac{\partial L}{\partial w_1} = \frac{\partial L}{\partial y_{pred}} * \frac{\partial y_{pred}}{\partial w_1}$$

Formation d'un réseau de neurones, partie 2

$$\frac{\partial L}{\partial w_1} = \frac{\partial L}{\partial y_{pred}} * \frac{\partial y_{pred}}{\partial w_1}$$

Nous pouvons calculer **∂L∂ypred** car nous avons calculé **L=(1−ypred)^2** ci-dessus :

$$\frac{\partial L}{\partial y_{pred}} = \frac{\partial (1 - y_{pred})^2}{\partial y_{pred}} = \boxed{-2(1 - y_{pred})}$$

Voyons maintenant quoi faire avec **∂ypred∂w1**. Tout comme avant, soit **h1**, **h2**, **o1** les sorties des neurones qu'ils représentent. Puis:

$$y_{pred} = o_1 = f(w_5 h_1 + w_6 h_2 + b_3)$$

f is the sigmoid activation function, remember?

Formation d'un réseau de neurones, partie 2

Voyons maintenant quoi faire avec **∂ypred∂w1**. Tout comme avant, soit **h1**, **h2**, **o1** les sorties des neurones qu'ils représentent. Puis:

$$y_{pred} = o_1 = f(w_5 h_1 + w_6 h_2 + b_3)$$

f is the sigmoid activation function, remember?

Puisque **w1** n'affecte que **h1** (pas **h2**), nous pouvons écrire:

$$h_1 = f(w_1 x_1 + w_2 x_2 + b_1)$$

$$\frac{\partial h_1}{\partial w_1} = \boxed{x_1 * f'(w_1 x_1 + w_2 x_2 + b_1)}$$

Nous faisons la même chose pour **∂h1∂w1** :

$$\frac{\partial y_{pred}}{\partial w_1} = \frac{\partial y_{pred}}{\partial h_1} * \frac{\partial h_1}{\partial w_1}$$

$$\frac{\partial y_{pred}}{\partial h_1} = \boxed{w_5 * f'(w_5 h_1 + w_6 h_2 + b_3)}$$

Formation d'un réseau de neurones, partie 2

C'est la deuxième fois que nous voyons **f'(x)** (le dérivé de la fonction sigmoïde) maintenant ! D**érivons-le** :

Nous utiliserons cette belle forme pour **f'(x)** plus tard.

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

$$f'(x) = \frac{e^{-x}}{(1+e^{-x})^2} = f(x) * (1 - f(x))$$

Succès. Nous avons réussi à décomposer **∂L∂w1** en plusieurs parties que nous pouvons calculer :

$$\boxed{\frac{\partial L}{\partial w_1} = \frac{\partial L}{\partial y_{pred}} * \frac{\partial y_{pred}}{\partial h_1} * \frac{\partial h_1}{\partial w_1}}$$

$$\frac{\partial L}{\partial y_{pred}} = \frac{\partial (1 - y_{pred})^2}{\partial y_{pred}} = \boxed{-2(1 - y_{pred})}$$

$$h_1 = f(w_1 x_1 + w_2 x_2 + b_1)$$

$$\frac{\partial h_1}{\partial w_1} = \boxed{x_1 * f'(w_1 x_1 + w_2 x_2 + b_1)}$$

$$\frac{\partial y_{pred}}{\partial w_1} = \frac{\partial y_{pred}}{\partial h_1} * \frac{\partial h}{\partial w_1}$$

$$\frac{\partial y_{pred}}{\partial h_1} = \boxed{w_5 * f'(w_5 h_1 + w_6 h_2 + b_3)}$$

Exemple : Calcul de la dérivée partielle

Nous allons continuer à prétendre que seule Alice est dans notre ensemble de données. (poids =135 (lb) et taille=66 (in) sont des valeurs moyennes)

Name	Weight (minus 135)	Height (minus 66)	Gender
Alice	-2	-1	1

Initialisons **tous les poids à 1** et **tous les biais à 0**. Si nous effectuons une propagation en avant (***feedforward pass***) à travers le réseau, nous obtenons :

$$\begin{aligned} h_1 &= f(w_1 x_1 + w_2 x_2 + b_1) \\ &= f(-2 + -1 + 0) \\ &= 0.0474 \end{aligned}$$

$$h_2 = f(w_3 x_1 + w_4 x_2 + b_2) = 0.0474$$

$$\begin{aligned} o_1 &= f(w_5 h_1 + w_6 h_2 + b_3) \\ &= f(0.0474 + 0.0474 + 0) \\ &= 0.524 \end{aligned}$$

Exemple : Calcul de la dérivée partielle

Le réseau génère **ypred=0,524**, ce qui ne favorise pas fortement **Male (0)** ou **Female (1)**.

Calculons **∂L∂w1** :

$$\frac{\partial L}{\partial w_1} = \frac{\partial L}{\partial y_{pred}} * \frac{\partial y_{pred}}{\partial h_1} * \frac{\partial h_1}{\partial w_1}$$

$$\begin{aligned}\frac{\partial L}{\partial y_{pred}} &= -2(1 - y_{pred}) \\ &= -2(1 - 0.524) \\ &= -0.952\end{aligned}$$

$$\begin{aligned}\frac{\partial y_{pred}}{\partial h_1} &= w_5 * f'(w_5 h_1 + w_6 h_2 + b_3) \\ &= 1 * f'(0.0474 + 0.0474 + 0) \\ &= f(0.0948) * (1 - f(0.0948)) \\ &= 0.249\end{aligned}$$

$$\begin{aligned}\frac{\partial h_1}{\partial w_1} &= x_1 * f'(w_1 x_1 + w_2 x_2 + b_1) \\ &= -2 * f'(-2 + -1 + 0) \\ &= -2 * f(-3) * (1 - f(-3)) \\ &= -0.0904\end{aligned}$$

$$\begin{aligned}\frac{\partial L}{\partial w_1} &= -0.952 * 0.249 * -0.0904 \\ &= \boxed{0.0214}\end{aligned}$$

Nous l'avons fait! Cela nous indique que si nous augmentions **w1**, **L** augmenterait un tout petit peu en conséquence (2% de **w1**)

Entraînement : descente de gradient stochastique

Maintenant nous pouvons former (entraîner) un réseau de neurones !
Nous utiliserons un **algorithme d'optimisation** appelé **descente de gradient stochastique** (***Stochastic Gradient Descent***) qui nous indique comment modifier nos poids et biais pour minimiser les pertes.
Il s'agit essentiellement de cette **équation de mise à jour** :

$$w_1 \leftarrow w_1 - \eta \frac{\partial L}{\partial w_1}$$

η est une constante appelée **taux d'apprentissage** qui contrôle la vitesse à laquelle nous entraînons le réseau.
Tout ce que nous faisons est de **soustraire η*∂L∂w1** de **w1** :

Si **∂L∂w1** est **positif**, **w1** diminuera, ce qui fait **diminuer L**.
Si **∂L∂w1** est négatif, **w1** augmentera, ce qui fera **diminuer L.**

Si nous faisons cela **pour chaque poids et biais** du réseau, la perte diminuera lentement et notre réseau s'améliorera.

Entraînement : descente de gradient stochastique

Notre processus de formation (**entraînement**) ressemblera à ceci :

1. Choisissez un **échantillon de notre ensemble de données**.

C'est ce qui en fait une descente de gradient stochastique - nous n'opérons que sur **un échantillon à la fois**.

2. Calculer **toutes les dérivées partielles** de la perte par rapport aux **poids** ou aux **biais** (par exemple **∂L∂w1**, **∂L∂w2**, etc.).

3. Utilisez l'équation de **mise à jour** pour mettre à jour chaque poids et biais.

4. Revenez à l'**étape 1**.

Voyons-le en **action** !

$$w_1 \leftarrow w_1 - \eta \frac{\partial L}{\partial w_1}$$

Code : Un réseau de neurones complet

Il est enfin temps de mettre en place un réseau de neurones complet :

Name	Weight (minus 135)	Height (minus 66)	Gender
Alice	-2	-1	1
Bob	25	6	0
Charlie	17	4	0
Diana	-15	-6	1

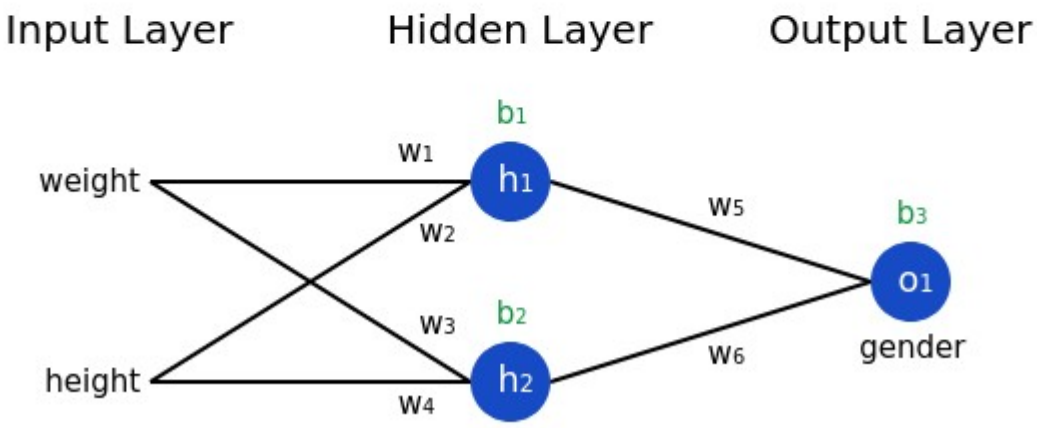

Code : fonctions utilitaires

IA.Lab0.ipynb ☆

Fichier Modifier Affichage Insérer Exécution Outils Aide Toutes les modifications c

+ Code + Texte

```
[ ]  1
```

```
0.5
```

```
1 import numpy as np
2
3 def sigmoid(x):
4   # Sigmoid activation function: f(x) = 1 / (1 + e^(-x))
5   return 1 / (1 + np.exp(-x))
6
7 def deriv_sigmoid(x):
8   # Derivative of sigmoid: f'(x) = f(x) * (1 - f(x))
9   fx = sigmoid(x)
10  return fx * (1 - fx)
11
12 def mse_loss(y_true, y_pred):
13  # y_true and y_pred are numpy arrays of the same length.
14  return ((y_true - y_pred) ** 2).mean()
15
```

Code : la classe OurNeuralNetwork

Méthodes :
__init__ et
feedforward :

IA.Lab0.ipynb ☆

Fichier Modifier Affichage Insérer Exécution Outils Aide Toutes les modifications ont

+ Code + Texte

```
class OurNeuralNetwork:

  def __init__(self):
    # Weights
    self.w1 = np.random.normal()
    self.w2 = np.random.normal()
    self.w3 = np.random.normal()
    self.w4 = np.random.normal()
    self.w5 = np.random.normal()
    self.w6 = np.random.normal()

    # Biases
    self.b1 = np.random.normal()
    self.b2 = np.random.normal()
    self.b3 = np.random.normal()

  def feedforward(self, x):
    # x is a numpy array with 2 elements.
    h1 = sigmoid(self.w1 * x[0] + self.w2 * x[1] + self.b1)
    h2 = sigmoid(self.w3 * x[0] + self.w4 * x[1] + self.b2)
    o1 = sigmoid(self.w5 * h1 + self.w6 * h2 + self.b3)
    return o1
```

Code : les datasets et la fonction zip()

Name	Weight (minus 135)	Height (minus 66)	Gender
Alice	-2	-1	1
Bob	25	6	0
Charlie	17	4	0
Diana	-15	-6	1

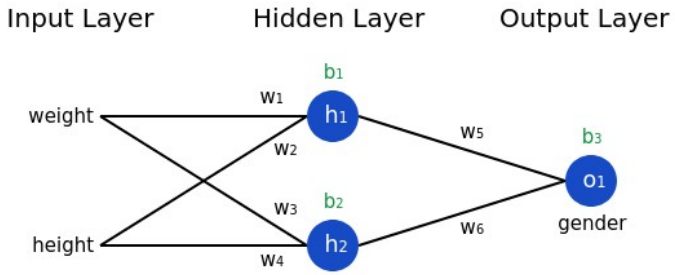


```
1 # Define dataset
2 data = np.array([
3   [-2, -1],  # Alice
4   [25, 6],   # Bob
5   [17, 4],   # Charlie
6   [-15, -6], # Diana
7 ])
8 all_y_trues = np.array([
9   1, # Alice
10  0, # Bob
11  0, # Charlie
12  1, # Diana
13 ])
14
15 list(zip(data, all_y_trues))
```

```
[(array([-2, -1]), 1),
 (array([25,  6]), 0),
 (array([17,  4]), 0),
 (array([-15,  -6]), 1)]
```

Code : faire une propagation - y_pred

Nous calculons la prédiction **y_pred**, par une **propagation** avec les valeurs de **w1,w2,b1** , **w3,w4,b2**, **w5,w6,b3** de la dernière époque :

```
38
39  def train(self, data, all_y_trues):
40    learn_rate = 0.1
41    epochs = 100 # number of times to loop through the entire dataset
42    for epoch in range(epochs):
43      for x, y_true in zip(data, all_y_trues):
44        # --- Do a feedforward (we'll need these values later)
45        sum_h1 = self.w1 * x[0] + self.w2 * x[1] + self.b1
46        h1 = sigmoid(sum_h1)
47        sum_h2 = self.w3 * x[0] + self.w4 * x[1] + self.b2
48        h2 = sigmoid(sum_h2)
49        sum_o1 = self.w5 * h1 + self.w6 * h2 + self.b3
50        o1 = sigmoid(sum_o1)
51        y_pred = o1
52
```

Code : calculer les dérivées partielles

Nous calculons les **dérivées partielles** pour les nouvelles valeurs de poids et de biais. **d_L_d_w1** représente la dérivée partielle de **L** sur **w1** :

```
53        # --- Calculate partial derivatives.
54        # --- Naming: d_L_d_w1 represents "partial L / partial w1"
55        d_L_d_ypred = -2 * (y_true - y_pred)
56        # Neuron o1
57        d_ypred_d_w5 = h1 * deriv_sigmoid(sum_o1)
58        d_ypred_d_w6 = h2 * deriv_sigmoid(sum_o1)
59        d_ypred_d_b3 = deriv_sigmoid(sum_o1)
60
61        d_ypred_d_h1 = self.w5 * deriv_sigmoid(sum_o1)
62        d_ypred_d_h2 = self.w6 * deriv_sigmoid(sum_o1)
63
64        # Neuron h1
65        d_h1_d_w1 = x[0] * deriv_sigmoid(sum_h1)
66        d_h1_d_w2 = x[1] * deriv_sigmoid(sum_h1)
67        d_h1_d_b1 = deriv_sigmoid(sum_h1)
68
69        # Neuron h2
70        d_h2_d_w3 = x[0] * deriv_sigmoid(sum_h2)
71        d_h2_d_w4 = x[1] * deriv_sigmoid(sum_h2)
72        d_h2_d_b2 = deriv_sigmoid(sum_h2)
73
```

Code : application d'un pas d'apprentissage

Nous modifions les valeurs de poids et de biais avec la valeur de taux d'apprentissage - ***ή*** (learn_rate=0.1):

$$w_1 \leftarrow w_1 - \eta \frac{\partial L}{\partial w_1}$$

$$\boxed{\frac{\partial L}{\partial w_1} = \frac{\partial L}{\partial y_{pred}} * \frac{\partial y_{pred}}{\partial h_1} * \frac{\partial h_1}{\partial w_1}}$$

```
73
74          # --- Update weights and biases
75          # Neuron h1
76          self.w1 -= learn_rate * d_L_d_ypred * d_ypred_d_h1 * d_h1_d_w1
77          self.w2 -= learn_rate * d_L_d_ypred * d_ypred_d_h1 * d_h1_d_w2
78          self.b1 -= learn_rate * d_L_d_ypred * d_ypred_d_h1 * d_h1_d_b1
79
80          # Neuron h2
81          self.w3 -= learn_rate * d_L_d_ypred * d_ypred_d_h2 * d_h2_d_w3
82          self.w4 -= learn_rate * d_L_d_ypred * d_ypred_d_h2 * d_h2_d_w4
83          self.b2 -= learn_rate * d_L_d_ypred * d_ypred_d_h2 * d_h2_d_b2
84
85          # Neuron o1
86          self.w5 -= learn_rate * d_L_d_ypred * d_ypred_d_w5
87          self.w6 -= learn_rate * d_L_d_ypred * d_ypred_d_w6
88          self.b3 -= learn_rate * d_L_d_ypred * d_ypred_d_b3
89
```

Code : application d'un pas d'apprentissage

Nous modifions les valeurs de poids et de biais avec la valeur de taux d'apprentissage - ***ή*** (learn_rate=0.1):

$$w_1 \leftarrow w_1 - \eta \frac{\partial L}{\partial w_1}$$

$$\boxed{\frac{\partial L}{\partial w_1} = \frac{\partial L}{\partial y_{pred}} * \frac{\partial y_{pred}}{\partial h_1} * \frac{\partial h_1}{\partial w_1}}$$

```
73
74          # --- Update weights and biases
75          # Neuron h1
76          self.w1 -= learn_rate * d_L_d_ypred * d_ypred_d_h1 * d_h1_d_w1
77          self.w2 -= learn_rate * d_L_d_ypred * d_ypred_d_h1 * d_h1_d_w2
78          self.b1 -= learn_rate * d_L_d_ypred * d_ypred_d_h1 * d_h1_d_b1
79
80          # Neuron h2
81          self.w3 -= learn_rate * d_L_d_ypred * d_ypred_d_h2 * d_h2_d_w3
82          self.w4 -= learn_rate * d_L_d_ypred * d_ypred_d_h2 * d_h2_d_w4
83          self.b2 -= learn_rate * d_L_d_ypred * d_ypred_d_h2 * d_h2_d_b2
84
85          # Neuron o1
86          self.w5 -= learn_rate * d_L_d_ypred * d_ypred_d_w5
87          self.w6 -= learn_rate * d_L_d_ypred * d_ypred_d_w6
88          self.b3 -= learn_rate * d_L_d_ypred * d_ypred_d_b3
89
```

Code : calcul de perte, affichage

A la fin d'une (ou plusieurs) époque on fait une prédiction pour calculer la perte avec les poids et biais actuellement disponibles:

```
89
90        # --- Calculate total loss at the end of each epoch
91        if epoch % 10 == 0:
92          y_preds = np.apply_along_axis(self.feedforward, 1, data)
93          loss = mse_loss(all_y_trues, y_preds)
94          print("Epoch %d loss: %.3f" % (epoch, loss))
95
```

Notez que dans le cas ci-dessus on fait ce calcul toutes les 10 époques.

Code : instanciation et entraînement

Pour lancer le programme :

on **prépare les données**, **data**, **all_y_trues**

on **instancie** notre notre classe **OurNeuralNetwork** comme **network**

on **execute** la méthode **.train(data,all_y_trues)** de cette classe.

```
# Define dataset
data = np.array([
  [-2, -1],  # Alice
  [25, 6],   # Bob
  [17, 4],   # Charlie
  [-15, -6], # Diana
])
all_y_trues = np.array([
  1, # Alice
  0, # Bob
  0, # Charlie
  1, # Diana
])

# Train our neural network!
network = OurNeuralNetwork()
network.train(data, all_y_trues)

```

Code : résultat d'apprentissage

```
# Define dataset
data = np.array([
  [-2, -1],  # Alice
  [25, 6],   # Bob
  [17, 4],   # Charlie
  [-15, -6], # Diana
])
all_y_trues = np.array([
  1, # Alice
  0, # Bob
  0, # Charlie
  1, # Diana
])

# Train our neural network!
network = OurNeuralNetwork()
network.train(data, all_y_trues)

```

```
Epoch 0 loss: 0.315
Epoch 10 loss: 0.261
Epoch 20 loss: 0.204
Epoch 30 loss: 0.080
Epoch 40 loss: 0.058
Epoch 50 loss: 0.046
Epoch 60 loss: 0.037
Epoch 70 loss: 0.031
Epoch 80 loss: 0.027
Epoch 90 loss: 0.024
```

Code : modification des hyper-paramètres

Expérimentez avec le programme on modifiant ces **hyper-paramètres**:
- **taux d'apprentissage** : **learn_rate = 0.1**
- **nombre d'époques** : **epochs = 1000**

plus la fréquence d'affichage : **disp=epochs/10**

Ajoutez affichage avec les éléments du code:

```
import matplotlib.pyplot as plt

loss_arr=[]

loss_arr.append(loss)

plt.plot(loss_arr)
plt.show()
```

```
Epoch 0 loss: 0.253
Epoch 100 loss: 0.033
Epoch 200 loss: 0.015
Epoch 300 loss: 0.009
Epoch 400 loss: 0.006
Epoch 500 loss: 0.005
Epoch 600 loss: 0.004
Epoch 700 loss: 0.003
Epoch 800 loss: 0.003
Epoch 900 loss: 0.003
```

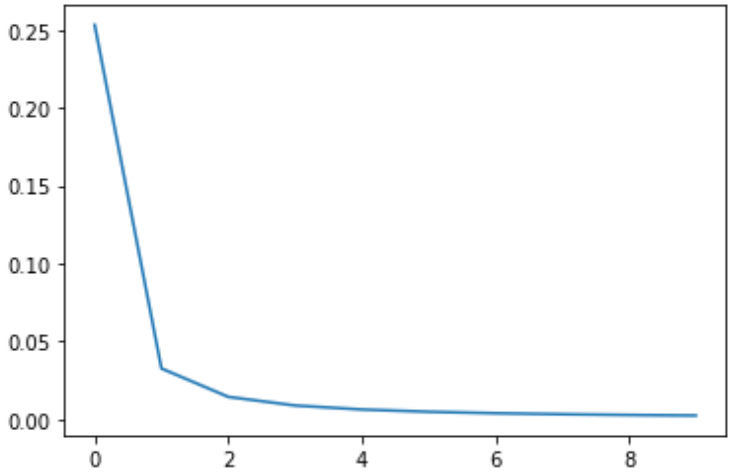

Code : prédictions

Nous pouvons maintenant utiliser le réseau pour prédire les sexes :

Attention : les valeurs de poids/taille de personnes dans les commentaires ne sont pas correctes !

```
# # Make some predictions
maria = np.array([-2, -1]) # 128 pounds, 63 inches
hugo = np.array([25, 6])  # 155 pounds, 68 inches
sophie = np.array([2, -1]) # 128 pounds, 63 inches
nico = np.array([32, 7])  # 155 pounds, 68 inches
print("Maria: %.3f" % network.feedforward(maria)) # 1 - F
print("Hugo: %.3f" % network.feedforward(hugo))   # 0 - M
print("Sophie: %.3f" % network.feedforward(sophie)) # 1 - F
print("Nico: %.3f" % network.feedforward(nico))   # 0 - M
```

```
Maria: 0.949
Hugo: 0.060
Sophie: 0.808
Nico: 0.060
```

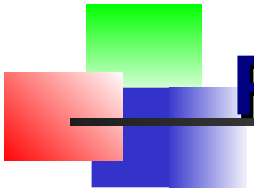

Résumé

Un petit récapitulatif de ce que nous avons fait :

1. Nous avons introduit les **neurones**, les éléments constitutifs des réseaux de neurones.
2. On a utilisé la **fonction d'activation sigmoïde** dans nos neurones.
3. Les réseaux de neurones ne sont que des **neurones connectés entre eux**.
4. La création d'un réseaux - jeu de données avec le **poids** et la **taille** comme **entrées** (ou **caractéristiques**) et le **sexe** comme **sortie** (ou **étiquette**).
5. Nous avons pris la connaissance des **fonctions de perte** et la perte d'**erreur quadratique moyenne** (MSE).
6. Nous avons réalisé que la **formation d'un réseau** ne fait que **minimiser sa perte**.
7. La **rétro-propagation** est utilisée pour calculer les **dérivées partielles**.
8. Nous avons utilisé la **descente de gradient stochastique** (SGD) pour entraîner notre réseau.
9. Nous avons fait une **prédiction**