

# IFT 603-712 : Devoir 4

## Travail par équipe de 2 ou 3

Remettez votre solution aux numéros 1 et 2 en format pdf ou manuscrit (et scanné) via [turninweb](#). Même chose pour le code.

**1- [1.5 points]** Nous avons vu dans le cours que l'opération Softmax est représentée par l'équation mathématique suivante :

$$y_{\vec{w}_i}(\vec{x}) = \frac{e^{a_i}}{\sum_c e^{a_c}}$$

où  $a_i$  est la sortie du i-ème neurone de sortie et que la fonction de perte entropie croisée (*cross-entropy*) est

$$E_D(W) = - \sum_{n=1}^N \sum_{k=1}^K t_{kn} \ln y_{\vec{w}_i}(\vec{x}_n)$$

où  $t_{kn}$  est la cible du n-ième élément de la base de données d'entraînement. Donner l'équation du gradient de la fonction de perte par rapport à  $a_i$  ainsi que toutes les étapes mathématiques pour arriver à ce résultat.


**2- [1.5 points]** On vous demande de classier les quatre (4) modèles de véhicules suivantes : (1) voitures sports, (2) voitures familiales, (3) camionnettes, (4) camions lourds. Pour ce faire, vous disposez pour chaque véhicule des cinq caractéristiques suivantes : (i) longueur, (ii) poids, (iii) accélération 0-100 km/h, (iv) prix, (v) consommation d'essence. Dans ce contexte et considérant qu'on vous fournit un ensemble d'entraînement, expliquez (a) ce qu'est une distribution de vraisemblance et comment vous pourriez la calculer, (b) ce qu'est la distribution a priori et comment vous pourriez la calculer et (c) dites s'il est raisonnable ou non d'émettre l'hypothèse que la distribution

$$p(\text{consommation d'essence} | \text{voitures sports})$$

est gaussienne. Justifiez bien vos réponses.

**3- [2 point]** Une entreprise d'assainissement des eaux vous engage pour l'aider à mieux analyser ses échantillons d'eau. Chaque échantillon possède une fiche signalétique indiquant une concentration en plomb. Dans les échantillons d'eau propres à la consommation, on mesure en moyenne 1 microgramme de plomb par litre. Cependant, les échantillons impropres à la consommation ont des concentrations en plomb pouvant aller jusqu'à 5 à 15 microgrammes par litre. Cependant, comme la compagnie n'a aucune compétence en analyse de données, elle s'appuie sur l'avis d'un expert pour déterminer si un échantillon d'eau est potable ou non.

- À l'aide d'une **base de données** annotée, d'une distribution **exponentielle** (voir figure suivante) et d'une distribution **gaussienne**, dites comment vous procéderiez pour obtenir la distribution de vraisemblance de chaque classe (indice: l'espérance mathématique d'une distribution exponentielle est  $1/b$  où  $b$  est le paramètre mentionné à la figure suivante).
- À l'aide de ces deux distributions, donnez un algorithme de maximum de vraisemblance vous permettant de classier un nouvel échantillon sur la base de sa concentration en plomb.



**4- [5 points]** Programmez des réseaux de neurones à 1 et 2 couches afin d'avoir un classifieur linéaire et un classifieur non linéaire telle qu'illustré au chapitre 7 du cours. Pour ce faire, vous devez implanter un entropie croisée (*cross-entropy*) avec une couche *Softmax* à la fin du réseau. Le classifieur non linéaire exige l'implantation d'un réseau avec une couche d'entrée, une couche cachée et une couche de sortie. Le code est contenu dans le fichier **devoir4.zip** via le site web du cours.

Les algorithmes doivent être implémentés à l'intérieur des fichiers pythons **linear\_classifier.py** et **two\_layer\_classifier.py** qui contiennent déjà une ébauche et des mentions **TODO** aux endroits où vous devez ajouter du code. L'exécution des fonctions et des classes associées à ces fichiers se fait via le notebook **Devoir4.ipynb**. Comme vous le verrez, ce notebook contient bon nombre de « sanity checks » mentionnés tout au long du cours.

**Note 1 :** bien que vide, le code du notebook fonctionne déjà. Pour vous en convaincre, vous n'avez qu'à taper la commande suivante dans un terminal :

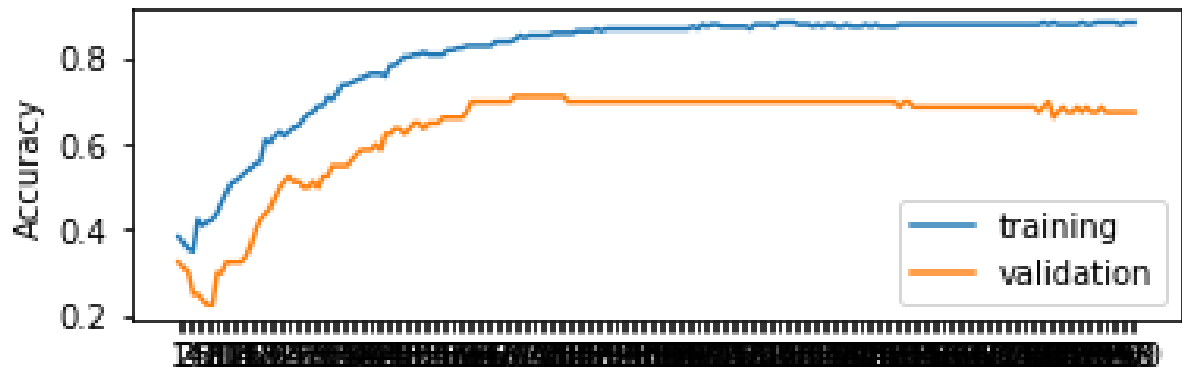

```
jupyter notebook
```

Et de sélectionner le fichier **Devoir4.ipynb**.

**Note 2 :** le code des devoirs (ainsi que des notebooks) a été testé avec python 3.5 sous Linux.

**Note 3 :** il est recommandé de rédiger son code dans un ide tel spyder ou pycharm.

**Note 4 :** voici de quoi devrait avoir l'air votre solution pour le modèle non linéaire appliqué aux données « Ncircles » 4 classes :



Frontières de décision

