

BDD3 — Manipulation de tables & algorithme KNN

Données utilisées

Le tableau ci-dessous représente un extrait du jeu de données `employees` utilisé dans les exercices. Chaque employé est décrit par son expérience (en années), son niveau d'études (de 1 à 5), son sexe ('F' ou 'M') et son salaire (en euros).

experience	etudes	sexe	salaire
5	3	F	2400
3	3	M	2550
5	5	F	2500
3	5	M	2800
2	5	F	2300
2	3	M	2700

Dans les exercices suivants, la variable `employees` désigne ce tableau de dictionnaires, tel que défini dans `donnees.py`.

Partie 1 — Manipulation de tables

Exercice 1 — Fonction `salaire_moyen_condition`

La fonction `salaire_moyen_condition(employees, champ, valeur)` doit renvoyer le salaire moyen (type float) des employés dont le champ indiqué est égal à la valeur fournie. Elle renvoie `None` si aucun employé ne correspond.

1. Quel est le résultat attendu des appels suivants sur le tableau `employees` ci-dessus ? Justifiez brièvement.

```
salaire_moyen_condition(employees, 'sexe', 'F') →  
salaire_moyen_condition(employees, 'etudes', 3) →  
salaire_moyen_condition(employees, 'etudes', 10) →
```


2. Complétez l'implémentation de la fonction ci-dessous :

```
def salaire_moyen_condition(employees, champ, valeur):  
    salaires = []  
    for em in employees:  
        if _____:  
            _____  
    if _____:  
        return _____  
    return _____
```

3. Écrivez une assertion permettant de vérifier que la fonction renvoie None lorsque aucun employé n'a le niveau d'études 10.

Exercice 2 — Fonction effectif_par_sexe

La fonction `effectif_par_sexe(employees)` renvoie un dictionnaire avec deux clés 'F' et 'M' associées respectivement au nombre de femmes et au nombre d'hommes dans le tableau.

4. Quel résultat renvoie `effectif_par_sexe(employees)` sur le tableau ci-dessus ?

5. Écrivez le code complet de la fonction `effectif_par_sexe`.

6. Proposez une assertion permettant de tester que la fonction fonctionne correctement sur le tableau `employees`.

Partie 2 — Analyse des écarts de salaire

Exercice 3 — Fonction calcul_ecart_sexe

On définit l'écart de salaire moyen en pourcentage comme :

$$\text{écart} = (\text{salaire moyen hommes} - \text{salaire moyen femmes}) / \text{salaire moyen hommes} \times 100$$

Voici une version incorrecte de la fonction :

```
def calcul_ecart_sexe(employees):
```

```

moy_h = salaire_moyen_condition(employes, 'sexe', 'M')
moy_f = salaire_moyen_condition('employes', 'sexe', 'F') # ligne A
return moy_h - moy_f                                     # ligne B

```

7. Identifiez et expliquez les deux erreurs présentes dans cette fonction (ligne A et ligne B).

8. Écrivez deux assertions permettant de mettre ces erreurs en évidence :

- une assertion vérifiant que le résultat est None lorsqu'un seul sexe est présent dans la liste ;
- une assertion vérifiant que l'écart exprimé en pourcentage est bien compris entre 0 et 100.

9. Écrivez la version corrigée de la fonction calcul_ecart_sexe.

Partie 3 — Algorithme des k plus proches voisins (KNN)

On souhaite estimer le salaire d'un nouvel employé dont on connaît l'expérience, le niveau d'études et le sexe, en s'appuyant sur les données existantes.

Exercice 4 — Calcul de la distance entre deux employés

La distance entre deux employés $e1$ et $e2$ est calculée à partir de trois critères : le sexe (converti en entier : $F \rightarrow 1$, $M \rightarrow -1$), l'expérience et le niveau d'études, selon la formule de la distance euclidienne.

La fonction `sexe_vers_entier` est déjà écrite :

```
def sexe_vers_entier(e):
    if e['sexe'] == 'F':
        return 1
    else:
        return -1
```

10. Calculez à la main la distance entre les deux employés suivants. Montrez les étapes du calcul.

```
e1 = {'experience': 3, 'etudes': 3, 'sexe': 'F'}
e2 = {'experience': 5, 'etudes': 5, 'sexe': 'M'}
```


11. Complétez le code de la fonction `distance` ci-dessous :

```
from math import sqrt

def distance(e1, e2):
    s = 0
    s = s + _____
    s = s + _____
    s = s + _____
    return _____
```

Exercice 5 — Tri par insertion à partir d'une clé

On dispose du code suivant de tri par insertion classique (tri d'une liste de nombres) :

```
def tri_insertion(T):
    for i in range(1, len(T)):
        val = T[i]
        j = i
        while j > 0 and T[j-1] > val:
            T[j] = T[j-1]
            j -= 1
```

```
T[j] = val
return T
```

On souhaite adapter ce tri pour trier une liste de tuples (distance, indice) en utilisant le premier élément du tuple comme clé de comparaison. La signature sera :

```
def tri_insertion_cle(T):
    # trie T en comparant T[i][0] (la distance)
```

12. Expliquez, en quelques lignes, le principe du tri par insertion.

13. Écrivez le code de la fonction `tri_insertion_cle(T)` qui trie une liste de tuples (distance, indice) par ordre croissant de distance.

Exercice 6 — Proposition de salaire par proximité

On dispose des fonctions `distance`, `tri_insertion_cle` et `salaire_moyen`. On veut écrire la fonction `salaire_par_proximite(employees, e)` qui renvoie une estimation du salaire de `e` en moyennant les salaires des 3 plus proches voisins parmi `employees`.

14. Expliquez en langage naturel comment utiliser `tri_insertion_cle` pour trouver les `k` plus proches voisins d'un employé `e`.

15. Complétez le code de la fonction `k_plus_proches` ci-dessous en utilisant `tri_insertion_cle` :

```
def k_plus_proches(k, employes, e):
    e_d = _____
    _____ # tri
    voisins = []
    for i in range(k):
        _____
    return voisins
```

16. En utilisant les fonctions `k_plus_proches` et `salaire_moyen`, écrivez la fonction complète `salaire_par_proximite(employes, e)`.

17. Calculez à la main le salaire estimé pour l'employé suivant en utilisant les données du tableau en début de fiche. Montrez les distances calculées.

```
e_nouveau = {'experience': 3, 'etudes': 3, 'sexe': 'F'}
```
