

Correction Mines-Ponts 2024

1. Compression du message

1. 'a' peut être représenté 0, 'b' par 10 et 'c' par 11.

Il n'y aura pas d'ambiguïté : pour lire un caractère, on commence par lire un bit.

Si c'est 0, c'est que le caractère est un 'a' stocké sur un seul bit.

Si c'est 1, le caractère est stocké sur 2 bits, et la lecture du bit suivant nous indique si c'est un 'b' ou un 'c'.

```
2. def nbCaracteres(c,s):
    nb = 0      # Compteur du nombre d'occurences
    n = len(s)  # Longueur de la chaîne

    for i in range(n): # On parcourt chaque caractère de la chaîne
        if c == s[i]:  # Si c'est le bon
            nb += 1     # on incrémente le compteur

    return nb
```

3. Elle parcourt les caractères de la chaîne `s`.

Pour chaque caractère, s'il n'a pas déjà été rencontré (test de la ligne 6), on l'ajoute à la fin de la liste des caractères "rencontrés".

Pour l'exemple `s='abaabaca'`, on obtiendra la liste `['a', 'b', 'c']`
(`'a'` sera rencontré au premier passage, `'b'` au second et `'c'` au septième).

4. Les instructions des lignes 2, 3, 5, 7 et 8 sont en temps constants.

La boucle de la ligne 4 va être effectuée n fois (une fois par caractère de `s`) et à chaque fois on va faire le test de la ligne 6, qui demande un parcours de la liste `ListeCar` pour vérifier que `c` est nouveau ou pas.

S'il y a k caractères distincts, dans le pire cas le test aura un coût de l'ordre de k (comparer avec chacune des valeurs).

La complexité asymptotique dans le pire cas sera de l'ordre de nk .

5. Elle commence par créer la liste des caractères utilisés puis pour chaque caractère, crée un couple avec le caractère et son nombre d'occurrences et renvoie la liste des couples.

Par exemple avec `'babaaaabca'` on obtiendra `[ ('b',3), ('a',6), ('c',1) ]`.

Remarque: le premier caractère rencontré par `ListeCaracteres` est un `'b'` !

6. La ligne 3 a une complexité en nk .

On a ensuite une boucle à la ligne 4 qui va être effectuée k fois (une fois par caractère distinct).

Cette boucle exécute des instructions de temps constant, sauf l'appel à `nbCaracteres` qui a une complexité en n (la taille de la chaîne).

La boucle de la ligne 4 a donc une complexité en nk également, donc `analyseTexte` est en nk .

```
7. def analyseTexte(s):
    n = len(s)      # Longueur de la chaîne
    occ = {}        # Dictionnaire pour stocker les occurrences

    for i in range(n): # On parcourt chaque caractère de la chaîne
```

```

c = s[i]
if c in occ:      # On regarde si le caractère est déjà vu
    occ[c] += 1   # OUI: on incrémente
else:
    occ[c] = 1    # NON: on crée l'entrée

return occ

```

La complexité est en n : rechercher si un caractère est déjà vu est maintenant en temps constant comme le reste de la boucle.

8. **SELECT DISTINCT** auteur **FROM** corpus

9. **SELECT** symbole, **SUM**(nombreOccurrences)*1.0/total **AS** frequence
FROM caractere
JOIN occurrences **ON** caractere.idCar = occurrences.idCar
JOIN corpus **ON** corpus.idLivre = occurrences.idLivre
JOIN (**SELECT SUM**(nombreCaracteres) **AS** total
FROM corpus **WHERE** langue="Francais")
WHERE langue="Francais"
GROUP BY symbole

Il y a deux agrégations à faire : sommer les nombres de caractères (sur tous les livres en français) et sommer les nombres d'occurrences (par caractère).

Les deux ne peuvent pas se faire simultanément : il est donc nécessaire d'en "cacher" une dans une requête imbriquée.

10. b correspond à l'intervalle $[0.2; 0.3[$. Cela se découpe en

- ba sur $[0.20; 0.22[$. (20% du début de $[0.2; 0.3[$)
- bb sur $[0.22; 0.23[$. (10% suivants)
- bc sur $[0.23; 0.25[$. (20% suivants)
- bd sur $[0.25; 0.29[$. (40% suivants)
- be sur $[0.29; 0.30[$. (10% restants)

ba correspond à $[0.20; 0.22[$, qui se découpe en

- baa sur $[0.200; 0.204[$. (20% du début de $[0.20; 0.22[$)
- bab sur $[0.204; 0.206[$. (10% suivants)
- bac sur $[0.206; 0.210[$. (20% suivants)
- bad sur $[0.210; 0.218[$. (40% suivants)
- bae sur $[0.218; 0.220[$. (10% restants)

Donc bac correspond à $[0.206; 0.210[$.

11. **def** codage(s):
 n = **len**(s)
 g,d = 0,1 # Intervalle initial

 # On parcourt chaque caractère de la chaîne
for i **in** **range**(n):

```

c = s[i]

# On calcule le nouvel intervalle avec le caractère courant
g,d = codeCar(c, g, d)

return g,d

```

12. ad correspond à $[0.10; 0.18[$, qui se découpe en

- ada sur $[0.100; 0.116[$. (20% du début de $[0.10; 0.18[$)
- adb sur $[0.116; 0.124[$. (10% suivants)
- adc sur $[0.124; 0.140[$. (20% suivants)
- add sur $[0.140; 0.172[$. (40% suivants)
- ade sur $[0.172; 0.180[$. (10% restants)

0.123 est dans le second intervalle, donc le caractère suivant est un 'b'.

13. Si on reprend le détail de la question 10, on voit que 0.2 peut correspondre à 'b', à 'ba', à 'baa', ...

Si on ne sait pas quelle est la longueur de la chaîne, on peut imaginer des partitions de $[0, 1[$ de plus en plus petite : un $x \in [0; 1[$ peut être vu comme un élément de n'importe laquelle des partitions... Donc être identifié comme une chaîne de longueur arbitraire.

14. **def** decodage(x):

```

s = '' # La chaîne à renvoyer
g,d = 0,1 # Intervalle initial

fini = False
while not fini: # On continue jusqu'à trouver le caractère final
    c = decodeCar(x, g, d)

    if c == '#':
        fini = True
    else:
        s = s + c # On ajoute le nouveau caractère
        # On calcule le nouvel intervalle pour le caractère suivant
        g,d = codeCar(c, g, d)

return s


```

2. Décodage du message

15. Il y a NK sommets (K sommets pour le caractère 0, K sommets pour le caractère 1, ..., K sommets pour le caractère $N - 1$).

Pour i allant de 0 à $N - 2$, chacun des K sommets de la couche verticale i a un arc vers chacun des K sommets de la couche verticale $i + 1$. Il y a donc $(N - 1)K^2$ arcs.

16. On obtient le graphe suivant:



Quelques explications :

- pour les trajets $\sigma \rightarrow S_{i,0}$, l'énoncé indique de pondérer par $E_{obs_{S_0,i}}$, c'est à dire $E_{2,i}$ puisque le premier caractère observé est un 2. On obtient donc les coefficients de la ligne "2" de la matrice E .
- pour les trajets $S_{i,0} \rightarrow S_{k,1}$, l'énoncé indique de pondérer par $E_{obs_{S_1,k}} P_{i,k}$, c'est à dire $E_{0,k} P_{i,k}$ puisque le second caractère observé est un 0.

17. À chaque niveau vertical, on a K possibilités (aller vers $S_{0,j}, S_{1,j}, \dots, S_{K-1,j}$), sauf au dernier où il n'y en a plus qu'une (aller vers τ).

Il y a donc K^{N-1} chemins. Si N devient trop grand, l'exploration exhaustive n'est plus envisageable (croissance exponentielle en N)

```
18. def maximumListe(liste):
    n = len(liste)
    M = liste[0]    # Le maximum (temporaire)
    arg = 0        # sa position

    for i in range(1,n):
        if liste[i] > M:    # On trouve un nombre strictement plus grand
            M = liste[i]   # On note ce nouveau candidat
            arg = i

    return M, arg
```

Remarque: en cas de maximum "multiple", on veut l'indice le plus petit possible, il faut donc bien mettre une inégalité stricte dans la boucle. Avec une inégalité large on aurait le dernier indice où le max apparaît.

```
19. def glouton(Obs, P, E, L, N):
    courant = initialiserGlouton(Obs, E, K)
    chemin = [ courant ]    # Caractère 0

    for j in range(0,N-1): # Recherche du caractère j+1
        # Proba d'aller de "i = courant" à "k" avec l'observation "obs[j+1]"
        i = courant
        obs = Obs[j+1]

        probas = [ E[obs][k] * P[i][k] for k in range(K) ]

        # Le max détermine le nouveau "courant"
        s, courant = maximumListe(probas)
```

```
chemin.append(courant)
```

```
return chemin
```

20. Cela revient à rechercher N fois (une fois par observation) un maximum dans une liste de K valeur. Cette recherche de maximum étant linéaire, la complexité est en NK .
21. L'initialisation fait choisir l'arc de poids 0.6.
On choisit ensuite l'arc de poids 0.5, ce qui donne un chemin de probabilité 0.03.
Or choisir l'arc 0.4 puis l'arc 0.9 donnerait un chemin meilleur de probabilité 0.036.
22. En passant au logarithme, maximiser $P = \prod p_k$ (où p_k noterait la probabilité de l'arc k d'un chemin) revient à maximiser $\sum \ln p_k$, ou autrement dit, à minimiser $\sum (-\ln p_k)$.

Si on remplace les poids p_k par les "distances" $(-\ln p_k)$ (qui sont des nombres positifs car les $p_k \in]0; 1[$), on est sur un problème de recherche de plus court chemin.

On peut utiliser l'algorithme de Dijkstra pour résoudre ce problème.

23.

```
def construireTableauViterbi(Obs, P, E, K, N):  
    T, argT = initialiserViterbi(E, Obs[0], K, N)  
  
    # Construction des chemins optimaux jusqu'au niveau j  
    for j in range(1,N):  
        # Calcul du chemin vers S(i,j)  
        for i in range(K):  
            probas = [ T[k][j-1] * P[k][i] * E[Obs[j]][i] for k in range(K) ]  
  
            # On note le max et son argument  
            T[i][j], argT[i][j] = maximumListe(probas)  
  
    return T, argT
```

24. Il faut regarder la dernière colonne pour trouver la meilleure proba (ici $1.8e-5$), le message termine par un 0.

Dans argT, la dernière colonne nous indique qu'on provenait de l'état 0.

On suit ensuite dans argT les prédecesseurs en remontant les colonnes (de droite à gauche): 1, 1, 2, 0, 0, 2, -1 (on est alors remonté jusqu'à σ)

Le message le plus probable serait donc 2 0 0 2 1 1 0 0.

25. La fonction `initialiserViterbi` commence par créer une liste de taille K , puis deux listes de listes de tailles NK (à l'aide d'une double boucle).
Il y a ensuite une boucle de taille K faisant des choses en temps constant.
La complexité temporelle et spatiale est donc en NK .

Ensuite la fonction `construireTableauViterbi` crée (ponctuellement) des listes de taille K et ne fait que modifier les listes doubles déjà créées : **la complexité spatiale n'augmente pas et reste de l'ordre de NK .**

Pour la complexité temporelle, on a une double boucle (nombre d'itérations $\simeq N \times K$) qui crée une liste de taille K , puis recherche un maximum par balayage : chaque passage a donc une complexité de l'ordre de K .

La complexité temporelle est donc de l'ordre de NK^2 .