1 Introduction

*La recherche d'**algorithmes de compression** est ancienne en informatique, avec deux buts visés :*

- ***gagner de l'espace** en réduisant l'espace de stockage ;*
- ***gagner du temps** en réduisant le temps de transfert des données.*

Les progrès technique ont permis d'améliorer notablement les capacités de stockage et les débits des liaisons mais avec le développement d'Internet, les données numériques sont de plus en plus nombreuses, on parle de Big Data. Ces données jouent un rôle de plus en plus important pour l'analyse et la prise de décision (data mining), le divertissement (flux video ...) ou l'entraînement des algorithmes d'apprentissage (machine learning). Il donc est important de disposer de bons algorithmes de compression.
*En informatique, toutes les données sont représentées au plus bas niveau sous forme de bits, huit bits formant un octet. Un **algorithme de compression** prend en entrée un flux d'octets de taille B et renvoie un flux d'octets compressés de taille $C(B)$. Il est d'autant plus performant que le **ratio de compression** $\frac{C(B)}{B}$ est petit. Évidemment, un tel algorithme est utile seulement si on connaît un **algorithme de décompression** capable de restituer le flux d'octets initial à partir du flux compressé.*
On distingue deux catégories d'algorithmes de compression :

- *Les **algorithmes de compression sans perte** d'information dont nous étudierons un exemple dans ce mini-projet et qui exploitent des redondances dans les données sources pour réduire l'espace (images, textes ...)*
- *Les **algorithmes de compression avec perte** pour les informations traitées par nos sens : une perte d'information est tolérée si elle ne réduit pas de façon significative la qualité de la perception (d'une image, d'un son ...)*

Plan du projet :

- ***Partie A** : développer des outils de conversion de textes, d'images, d'entiers en flux d'octets.*
- ***Partie B** : découverte de l'algorithme de compression RLE.*

2 Cahier des charges

1. *Les programmes de chaque partie doivent être rassemblés dans des fichiers différents nommés `partieA.py` et `partieB.py`.*
2. *Chaque fonction de `partieA.py` ou `partieB.py` doit passer le test correspondant dans les programmes de tests `test_partieA.py` et `test_partieB.py` fournis sinon cela doit être mentionné dans le code source sous forme de commentaires.*
3. *Les réponses aux questions qui ne nécessitent pas de code doivent être fournies dans le code source sous forme de commentaire en les préfixant par le numéro de la question.*
4. *Chaque fonction doit être documentée avec une `docstring`.*
5. *Les parties les moins évidentes du code doivent être commentées de façon pertinente.*
6. *Un code client permettant de tester le programme ou les fonctions principales doit être fourni.*

3 Partie A : boîte à outils

L'objectif de cette partie est de nous outiller avec des fonctions de conversions (dans les deux sens) de textes (type `str`*) ou d'images (avec le module* `PIL`*) en flux d'octets (de type* `bytes`*) qui seront compressés puis décompressés par l'algorithme présenté en partie B.*

1. Extraire l'archive `DM-Compression.zip` dans un répertoire du même nom. Elle contient :
   - les deux squelettes de code `partieA.py` et `partieB.py`.
   - les deux fichiers de tests `test_partieA.py` et `test_partieB.py`.
   - des ressources (textes, images ...) utilisées pour tester le code
2. Renommer le répertoire en `DM-Compression_Eleve1_Eleve2` avec les noms des membres du groupe séparés par des tirets bas (surtout pas d'espace). Par la suite on appellera ce répertoire le répertoire de base du projet.
3. Exécuter le script `partieA.py`. Si le module `PIL` n'est pas installé, une erreur s'affiche, il faut alors l'installer en suivant la documentation en ligne sur :

   https://pillow.readthedocs.io/en/stable/installation.html

```
1 from PIL import Image
```

4. Compléter la fonction `index_premiere_occurence(element, tab)` en respectant la spécification donnée dans la `docstring`.

   Vérifier si la fonction passe le test unitaire `test_index_premiere_occurence` dans `test-partieA.py`.

```
def index_premiere_occurence(element, tab):
    """
    Parametres :
        element de type quelconque (le même que les éléments de tab)
        tab un tableau d'éléments de même type
    Valeur renvoyée:
        l'indice de la première occurence de element dans tab
    """
```

5. Compléter la fonction `hex_to_decimal(hexadecimal)` en respectant la spécification donnée dans la `docstring`.

   Vérifier si la fonction passe le test unitaire `test_hex_to_decimal` dans `test_partieA.py`.

```
def hex_to_decimal(hexadecimal):
    """
    Parametres :
        hexadecimal de type str représentant un entier en base 16
    Valeur renvoyée:
        représentation décimale de hexadecimal sous forme d'entier de
            type int
    """
```

6. Compléter la fonction `decimal_to_hex(n)` en respectant la spécification donnée dans la `docstring`.
Vérifier si la fonction passe le test unitaire `test_decimal_to_hex` dans `test-partieA.py`.

```
def decimal_to_hex(n):
    """
    Parametres :
        n de type int
    Valeur renvoyée:
        représentation de n en base 16 sous forme de chaîne de caractè
            res
        on rajoute un 0 à gauche si un seul chiffre en base 16
    """
    rep = ''
    #à  compléter
```

7. `partieA.py` contient ensuite trois fonctions de conversion entre les types `str` des chaînes de caractères et `bytes` des flux/séquences d'octets qui seront manipulés par nos algorithmes de compression.

```
def str_to_bytes(chaine, encodage = 'utf8'):
    """
    Paramètres :
        chaine de type str, une chaine de caractères
        encodage un paramètre de type str fixant l'encodage, par défaut
            utf8
    Valeur renvoyée :
        un flux d'octets de type bytes obtenu par encodage de chaine
    """
    return chaine.encode(encoding = encodage)

def bytes_to_str(flux, encodage = 'utf8'):
    """
    Paramètres :
        flux d'octets de type bytes
        encodage un paramètre de type str fixant l'encodage, par défaut
            utf8
    Valeur renvoyée :
        une chaine de caractères de type str obtenue par décodage de
            flux
    """
    return flux.decode(encoding = encodage)

def hex_to_bytes(hexadecimal):
    """
    Paramètres :
        hexadecimal de type str représentant un nombre à 2 chiffres en
            base 16
    Valeur renvoyée :
        un octet de type bytes représentant le même nombre qu'
            hexadecimal
    """
```

```
    return bytes.fromhex(hexadecimal)
```

Pour comprendre leur fonctionnement, on donne ci-dessous quelques exemples, disponibles également dans l'interpréteur en ligne Basthon. On peut remarquer que les caractères imprimables de la table ASCII (ordinal Unicode inférieur à 128) sont représentés tels quels dans le type `bytes`.

Pourquoi n'est-ce pas le cas pour le caractère accentué `é` dans l'exemple ci-dessous ?

⚠ *Pour simplifier, nous travaillerons dans ce DM uniquement avec des chaînes de caractères de la table ASCII codés sur un octet.*

```
>>> [str_to_bytes(c) for c in ['1','a', 'A', 'é']]
[b'1', b'a', b'A', b'\xc3\xa9']
>>> [bytes_to_str(b) for b in [b'1', b'a', b'A', b'\xc3\xa9']]
['1', 'a', 'A', 'é']
>>> [hex_to_bytes(h) for h in ['00', '06', '0B','A1', 'FF']]
[b'\x00', b'\x06', b'\x0b', b'\xa1', b'\xff']
```

Complément

Les dernières fonctions outils fournies dans `partieA.py` permettent de convertir un fichier représentant une image en niveaux de gris (pixel sur un octet) en un flux d'octets de type `bytes` et réciproquement de convertir un flux d'octets en image (en précisant sa largeur et sa hauteur).
On utilisera ces fonctions comme des boîtes noires. Pour comprendre leur fonctionnement on donne ci-dessous un exemple d'exécution sur une image de 2×2 pixels représentant un damier : on extrait le flux d'octets de l'image source, on le transforme en remplaçant les octets par leur complémentaire à 255 puis on convertit ce flux de sortie en image.
Le test unitaire `test_image` fourni dans `test_partieA.py` permet de reproduire cet exemple.

```
In [7]: img = fichier_to_image('damier_2x2.png')

In [8]: img
Out[8]: <PIL.Image.Image image mode=L size=2x2 at 0x7FA724517340>

In [9]: img_bytes = image_to_bytes(img)

In [10]: img_bytes
Out[10]: b'\xff\x00\x00\xff'

In [11]: img_bytes_sortie = b''.join([(255 - img_bytes[k]).to_bytes(1,
     byteorder='little') for k in range(len(img_bytes))])

In [12]: img_bytes_sortie
Out[12]: b'\x00\xff\xff\x00'

In [13]: img_sortie = bytes_to_image(img_bytes_sortie, img.width, img.height
     )

In [14]: img_sortie
Out[14]: <PIL.Image.Image image mode=L size=2x2 at 0x7FA7240C4C40>
```

Fin de complément

4 Partie B : compression RLE

Complément

Méthode

Run Length Encoding est un algorithme efficace pour compresser des données contenant de longues séquences de valeurs répétées.
La chaîne de caractères `"ABBBAABBBB"` *peut ainsi être compressée en* `"1A3B2A4B"`.
Le principe est simple : on représente chaque séquence de caractères identiques par sa longueur suivie du caractère répété.
En pratique, on travaille sur des séquences d'octets, ainsi la séquence de 7 octets en notation hexadécimale : `\x00\x00\x00\xff\xff\xff\xff` *va être compressée en une séquence de 4 octets :*

$$\underbrace{\backslash x03}_{\text{répétition}} \overbrace{\backslash x00}^{\text{valeur}} \underbrace{\backslash x04}_{\text{répétition}} \overbrace{\backslash xff}^{\text{valeur}}$$

On fixe également une longueur maximale pour les répétitions : dans notre mini-projet, on choisit de les coder sur 1 octet soit au plus 255 *valeurs consécutives.*

Fin de complément

1. Compresser avec l'algorithme Run Length Encoding la séquence d'octets ci-dessous en notation hexadécimale. Donner la séquence compressé en notation décimale également.

```
\x00\x00\x0a\x0a\x0a\x0a\xff\x00\xff\xff\xff\xff\xff\xff\xff\xff\xff\xff\xff
```

2. Décompresser la séquence d'octets ci-dessous compressée avec l'algorithme Run Length Encoding :

```
\x02\xb1\x0a\x00\x01\xfc\x0f\x0a
```

3. Ouvrir le script `partieB.py`. Quel est le rôle de la première instruction ci-dessous ?

```
from partieA import *
```

Complément

Avant de traiter les questions suivantes, il faut se familiariser avec les objets de type `bytes`.
Consulter le tutoriel Exemples_Operations_Bytes.pdf et ce notebook Basthon.

Fin de complément

4. Compléter la fonction `decompresse_rle(flux)` en respectant la spécification donnée dans la `docstring`.
Vérifier si la fonction passe le test unitaire `test_decompresse_rle` dans `test_partieB.py`.

```
def decompresse_rle(flux_compresse):
    """
    Paramètre :
        flux_compresse de type bytes est un flux d'octets compressé avec
             l'algorithme RLE
    Valeur renvoyée :
        flux_sortie de type bytes qui est la décompression de
            flux_compresse
    """
    flux_sortie = b''
    "à  compléter"
    return flux_sortie
```

5. Compléter la fonction `compresse_rle(flux)` en respectant la spécification donnée dans la `docstring`.
Vérifier si la fonction passe le test unitaire `test_compresse_rle` dans `test_partieB.py`.

```
def compresse_rle(flux):
    """
    Paramètre :
        flux de type bytes est un flux d'octets
    Valeur renvoyée :
        flux_compresse de type bytes qui est la compression de flux avec
             l'algorithme RLE
    """
    courant = flux[0:1] #pour avoir un bytes
    compteur = 1
    flux_compresse = b'' #de type bytes
    for k in range(1, len(flux)):
       "à  compléter"
    return flux_compresse
```

6. Compléter la fonction `ratio_rle(flux, flux_compresse)` en respectant la spécification donnée dans la `docstring`.

```
def ratio_rle(flux_compresse, flux):
    """
    Paramètre :
        flux de type bytes est un flux d'octets
        flux_compresse de type bytes est un flux d'octets
    Valeur renvoyée :
```

```
        un nombre de type float représentant le ratio entre flux et
            flux_compresse
    """
    "à  compléter"
```

7. Compléter le script `partieB.py` avec un code client permettant de tester l'exemple fourni dans la page Wikipedia sur la compression Run Length Encoding.

```
Compression RLE d'un texte
Source :  WWWWWWWWWWWWBWWWWWWWWWWWWBBBWWWWWWWWWWWWWWWWWWWWWBWWWWWWWWWWWW
Flux d'octets :  b'WWWWWWWWWWWWBWWWWWWWWWWWWBBBWWWWWWWWWWWWWWWWWWWWWBWWWWWWWWWWWW'
Flux d'octets compressé :  b'\x0cW\x01B\x0eW\x03B\x17W\x01B\x0bW'
Sortie :  WWWWWWWWWWWWBWWWWWWWWWWWWBBBWWWWWWWWWWWWWWWWWWWWWBWWWWWWWWWWWW
Ratio de compression : 0.215385
```

8. Compléter le script `partieB.py` avec un code client permettant de compresser l'image en niveau de gris enregistrée dans le fichier `lena.png` : extraction du flux d'octets représentant l'image, compression de ce flux, affichage du ratio, décompression et conversion du flux de sortie en image. On utilisera les fonctions `fichier_to_image`, `image_to_bytes` et `bytes_to_image` définies dans `partieA.py`.

```
lena_img = fichier_to_image('lena.png')
flux = image_to_bytes(lena_img )
#à  compléter
lena_img_decompresse = bytes_to_image(flux_sortie, lena_img.width,
    lena_img.height)
lena_img_decompresse.save('lena-decompresse.png')
```

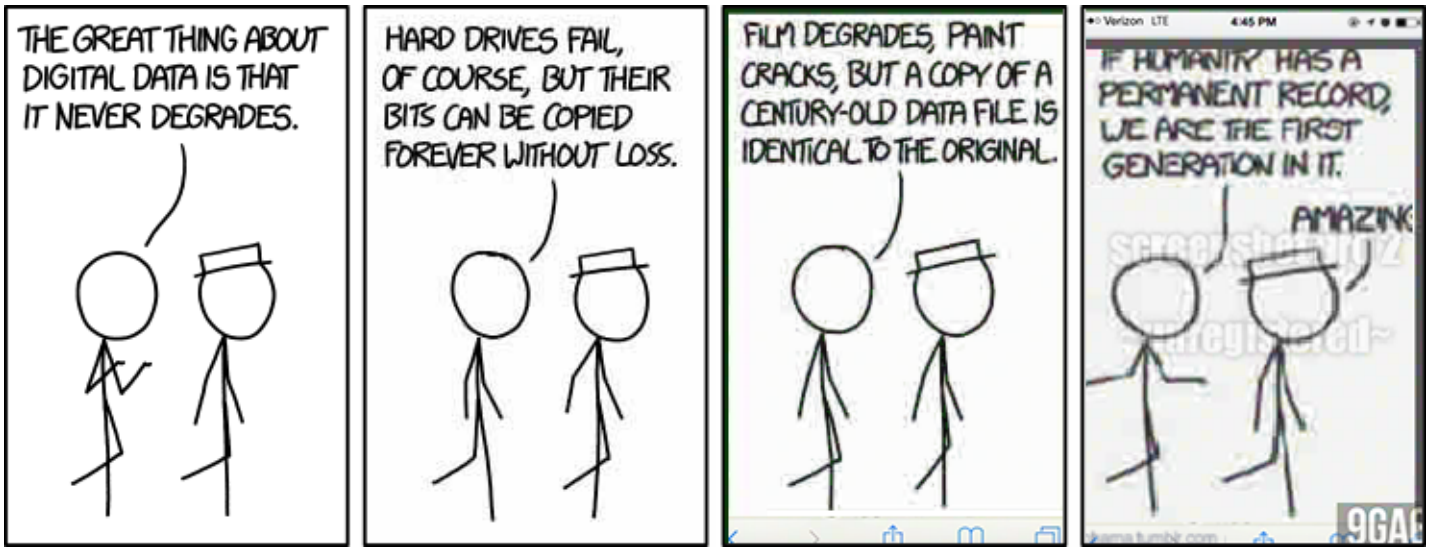

https://www.explainxkcd.com/wiki/index.php/1683:_Digital_Data