Lycée Privé Levavasseur — Saint-Denis

NSI 1re — Année 2020 - 2021

Les données structurées

Introduction

Les données constituent la matière première de toute activité numérique. Afin de permettre leur réutilisation, il est nécessaire de :

- les conserver de manière persistante.
- Les structurer correctement pour que l'on puisse les exploiter facilement pour produire de l'information.

Repères historiques :

- 1930 : utilisation des cartes perforées, premier support de stockage de données
- 1979 : création du premier tableur, VisiCalc.

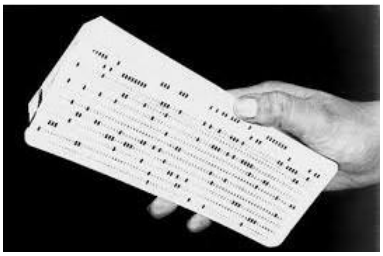

Les données - L'information

Définition :

• Les **données** sont des ensembles de **symboles** (mots, nombres, images, sons etc...) pour **représenter** le monde réel (objets événements etc...).
• Elles peuvent être **quantitatives** (âge, poids taille, température etc..) ou **qualitatives** (noms, prénom, adresse etc...)

Définition :

Une **information** est une **donnée interprétée**.
Une **information** = **données** + **modèle** d'interprétation.

Exemple :

Prenons la donnée suivante : 2 81 12 92 01208680.

C'est juste une série de chiffres...

Si maintenant on précise que c'est un numéro de sécurité sociale, on en déduit qu'il s'agit de celui d'une femme née en 1981 au mois de décembre dans le département 92 (haut de seine).

Exercice1 :

Expliquez ce schéma...

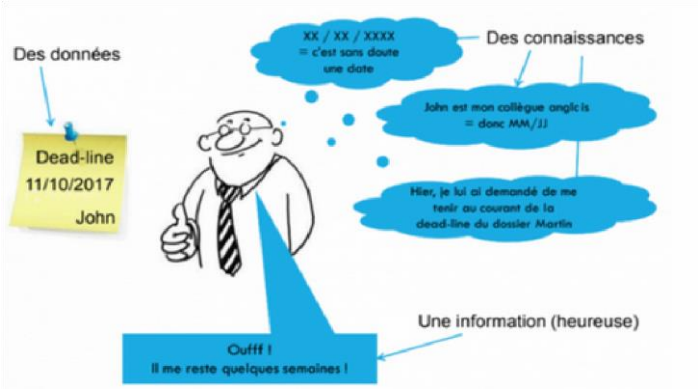

Les données structurées

Les données doivent être décrites, par un **descripteur** compréhensible pour celui qui veut les interpréter.
Prenons le cas d'une bibliothèque, et considérons un abonné.
Lors de son inscription celui-ci fournit des données (son **nom**, son **prénom**, son **adresse** et son **numéro de téléphone**), ces données seront associées aux **descripteur**s (**Nom**, **Prénom**, **Adresse**, **n-tel**).
On regroupe les données des abonnés dans une **table**, avec les mêmes **descripteurs**, on crée ainsi une **collection**.
On regroupe ensuite toutes les **collections** (livres, abonnés, emprunts, etc...) dans une **base de donnée**.

Accès aux données

Certaines données sont **accessibles à tous** (Open Data - le site data.gouv.fr propose des jeux de données libre d'accès) et d'autres sont **non accessibles**(privées ou sensibles..).
Certaines bases de données sont souvent comparées à l'or noir d'internet.
Les **données qu'elles contiennent** sont utilisées pour **analyser le comportement** des **internautes** afin de leur proposer tel ou tel produit lors de leur navigation.
De puissants algorithmes sont utilisés pour faire ces interprétations.

Représentation des données

Les données sont principalement représentées sous la forme de tableaux. On parle de données tabulaires.

Exemple d'une table listant des fruits vendus par un magasin.

Nom	Prix	Code
Banane	5.99€/kg	77
Pomme	2.99€/kg	99
Poire	7.99€/kg	170

Exercice2 :

Quels sont les descripteurs de la collection ci-dessus ?

Il existe **trois formats** pour représenter un tableau de données : les formats **CSV**, **XML** et **JSON**.

Le format CSV :

Le format **Comma-Separated Values** (**CSV**) est un format permettant de représenter des données tabulaires sous la forme de valeurs séparées par des virgules.
Le séparateur pourrait être un point-virgule ou tout autre caractère... Le tableau précédent est représenté comme ci-contre :

```
Nom,Prix,Code
Banane,5.99,77
Pomme,2.99,99
Poire,7.99,170
```

Le format XML :

Le format **eXtensible Markup Language** (**XML**) est un format qui utilise des balises pour structurer les données dans le fichier texte.
Les balises sont utilisées pour encadrer un contenu : il y a une balise ouvrante et un e balise fermante.

```
<data>
    <fruit>
        <Nom>Banane</Nom>
        <Prix>5.99</Prix>
        <Code>77</Code>
    </fruit>
    <fruit>
        <Nom>Pomme</Nom>
        <Prix>2.99</Prix>
        <Code>99</Code>
    </fruit>
    <fruit>
        <Nom>Poire</Nom>
        <Prix>7.99</Prix>
        <Code>170 </Code>
    </fruit>
</data>
```

Le format JSON :

Le format **JavaScript Object Notation** (JSON) est un format plus récent utilisé pour représenter des objets qui dérive de la notation des objets du langage JavaScript.
On remarquera une structure de dictionnaire qui contient une liste de dictionnaires.

```
{
    "data": [
        {
            "Nom": "Banane",
            "Prix": 5.99,
            "Code": 77
        },
        {
            "Nom": "Pomme",
            "Prix": 2.99,
            "Code": 99
        },
        {
            "Nom": "Poire",
            "Prix": 7.99,
            "Code": 170
        }
    ]
}
```

Exercice3 :

Réaliser "à la main" la représentation de ces données tabulaires dans les trois formats (CSV, XML et JSON)

Nom	Prénom	nombre de voix
Dupond	Émile	514
Dupont	Chloé	632
Dupons	Camille	421