ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Projet 2A

Recherche de mots-clés dans les noms et contenus de fichiers

PORTE-MITATRE Cydony
DE PERMENTIER Thibault
DUBOIS Timothei
JANCI Fabien
MAHIER Awen

Sommaire

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Cadre du projet

Contextualisation

- Clients : GREYC et Gendarmerie
- EWF
- Go
- Objectifs
    - Faciliter l'exploration d'une archive EWF
    - Recherche mot clé dans le nom d'un fichier/dossier et dans son contenu

Contraintes

- Utilisation unique du système de fichier EXT4
- Choix limité des extensions de fichiers
- Séparation du code en sous-modules

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Organisation interne

Répartition des tâches

Répartition des tâches

Fabien	Lecture ZIP, contenu fichiers texte et noms
Cydony	Lecture PDF et CLI
Thibault	Lecture fichiers compressés, Lien EGOWF
Timothei	Lecture EWF et EXT4
Awen	Lecture EWF et EXT4, Lien entre les modules

Organisation interne

Méthodologie utilisée

Méthode d'organisation

Réunion tous les matins

Communication et rapport en fin de journée

Partage des différentes tâches

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Travail réalisé

Architecture micro-modules

Lecture de l'archive EWF

Architecture modulaire

Pré-requis client

Nombreux avantages:

- Réutilisabilité
- Indépendance des modules
- Agilité
- Résilience

Similaire à l'architecture Micro-Services

Lecture EWF / EXT4

Format EWF :

- Header
- Section

=> Section 'sector'

Format du disque EXT4

-> Group Descriptor

-> Inode

Bibliothèques GO-EWF et GO-EXT4

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Travail réalisé

Recherche de mots clés par types de fichiers

Algorithme de recherche de mots clés

- Dans le nom (parcours de l'arborescence archive EWF)
- Dans le contenu (archives compressées ou fichiers non-compressés)
- Structure commune des fonctions de recherche :
  - Paramètres :
    - Liste des mots clés
    - Arborescence / Contenu du fichier
    - Booléen verbose
  - Valeur de retour :
    - Dictionnaire[mot clé][liste d'emplacements]

```
(words []string, data []byte, verbose bool) map[string][]string
```

Fichiers compressés

- Office ou équivalent : majorité sont des ZIP camouflés
- Lecture du fichier XML de contenu
- Archives ZIP :
    - Ouverture et lecture récursive
    - Parcours de l'arborescence en récupérant :
        - Les noms des dossiers et fichiers
        - Les contenus des fichiers
    - Appel de la fonction de recherche correspondant à l'extension de chaque nom de fichier sur son contenu
    - Fusion de tous les dictionnaires obtenus en un seul output

HTML / XML / TXT

- Récupération du contenu d'un fichier texte quelle que soit son extension :
    - Parcours de chaque mot clé dans la liste en paramètre
    - Comparaison entre ce mot-clé et le contenu du fichier ligne par ligne
    - Normalise la ligne étudiée et le mot clé recherché avant de les comparer en retirant les accents
    - Ajoute au dictionnaire renvoyé, pour le mot clé correspondant :
        - Nombre d'occurrences dans le fichier si la verbose est désactivée
        - Les numéros de ligne du fichier où se situe au moins une occurrence, et le nombre d'occurrences pour cette ligne si la verbose est activée

PDF

- Bibliothèque : pdf
- ReaderPDF
- Découpage en page / lignes
- Pour chaque mot clé :
    - Récupération texte par ligne
    - Normalisation
    - Enregistrement (format verbose ou non)

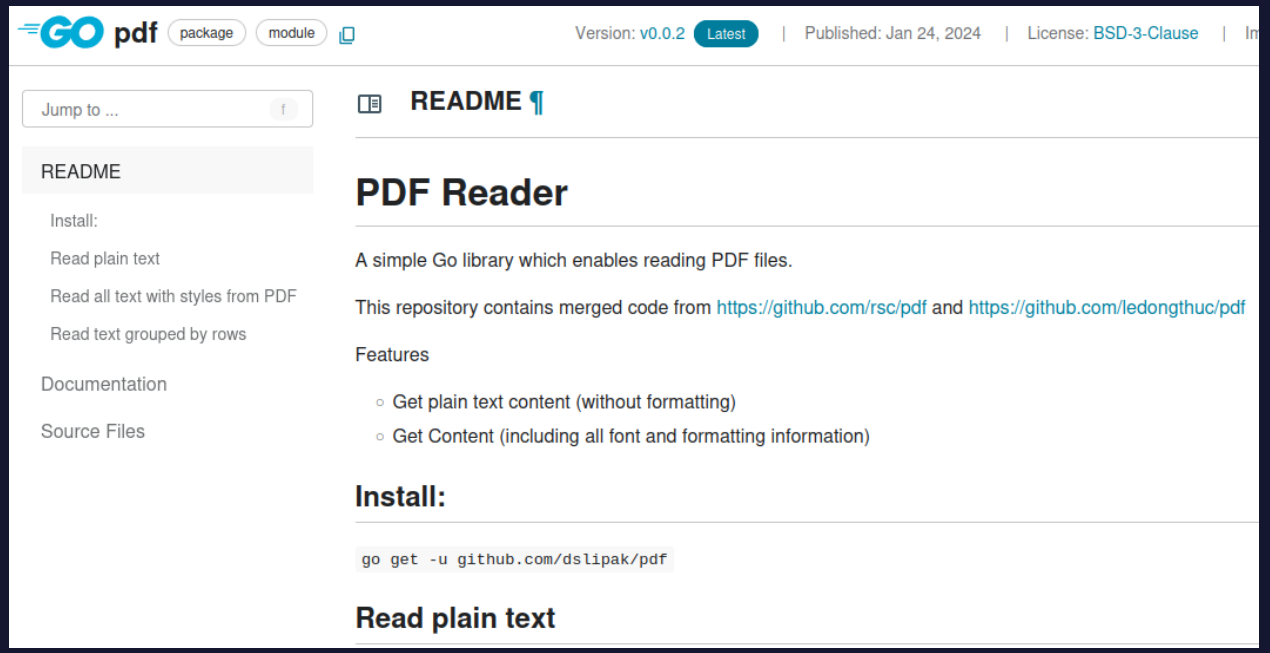

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Travail réalisé

Command Line Interface

searchEWF : commandes et flags

./searchEWF search <archive_EWF>

--*word* : mots clés

--*type* : extension fichiers

--verbose : format réponse

./searchEWF infoEWF <archive_EWF>

- *Nombre de secteurs par bloc*
- *Methode de compression*
- *Le Média (disque dur) ...*

=> SAUVEGARDE RESULTATS : *output.txt*

```
Start analysis
Analyzing ./segment/ewf_full.E01
EWF Information:
        Format : EnCase 6
        Sector Per Chunk : 64
        Chunk Size : 32768
        Error Granularity : 64
        Compression Method : unknown compression
        Compression Level : unknown compression
-----------------
Media Information:
        Media Size : 7340032 bytes
        Media Type : fixed disk
        Number Of Sectors : 14336
        Bytes per Sector : 512
-----------------
Digest hash information:
        Number of Hash Values : 1
        MD5 : 5be195f22760d04d4f91a6427f2e61d7
-----------------
```


```
>>./searchEWF search
Error: requires at least 1 arg(s), only received 0
Usage:
  searchEWF search <path_to_ewf_image> < -w word_to_search | -t file_extension> [--verbose] [flags]

Flags:
  -h, --help          help for search
  -t, --type string   File extension to search for (e.g., .txt, .docx)
  -v, --verbose       Display search results in the terminal
  -w, --word string   Word or pattern to search for
```

```
>>./searchEWF search segment/ewf_full.E01 -w "drogues compta"
EWF Image Path: segment/ewf_full.E01
Searching for word(s): [drogues compta]
Find in tous les crimes que j'ai commis.txt : compta -> 1 occurrence(s)
Find in 1-Fascination.txt : compta -> 14 occurrence(s)
Find in 1-Fascination.txt : drogues -> 1 occurrence(s)
Find in 1-Fascination.odt : drogues -> 1 occurrence(s)
Find in 1-Fascination.odt : compta -> 14 occurrence(s)
Find in 1-Fascination.pdf : drogues -> 1 occurrence(s)
Find in 1-Fascination.pdf : compta -> 14 occurrence(s)
Search completed: results saved in ./output.txt
>>
```

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Bilan : Objectifs du projet

Objectifs atteints

- Architecture modulaire
- Traitement des extensions choisies
- CLI claire
- Recherche avec différentes options
- Sauvegarde des résultats de recherche en .txt

Pistes d'amélioration

- Raccordement avec projet partenaire
- Portabilité
- Traitement de nouveaux types de fichiers
    - Cache navigateur
    - Images
    - Fichiers chiffrés

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

Retour d'expérience

Bilan

Communication

Répartition des tâches

Recherche documentaire

Compréhension

ENSI CAEN
ÉCOLE PUBLIQUE D'INGÉNIEURS
CENTRE DE RECHERCHE

MERCI

pour votre écoute

L'École des Ingénieurs Scientifiques