

cocaClean

開発の意図

- ・ COCA samples のファイルには、以下の「ゴミ」が含まれていて、単語の処理をする際に「ゴミ」となる
 - ・ テキスト ID
 - ・ 匿名記号
 - ・ 段落記号
 - ・ html タグ
 - ・ @long, @longurl

開発方法

- ・ Copilot に指示を出してスクリプトの原案を作ってもらい修正する

指示のプロンプト

Python 言語で、フォルダー内の複数のテキストファイル(拡張子 ".txt")を対象に、以下の文字列を削除するスクリプトを書いてください。

削除した結果のファイル名は、それぞれ元のファイル名の後ろに ".cln" という拡張子を付けて保存して下さい。

そして、そのスクリプトを windows 上で実行できる exe ファイルにコンパイルする方法を教えてください。

- ・ その後の試行錯誤
 - ・ 削除文字列を正規表現で表記できるように修正

出力されたスクリプト

修正箇所

- ・ 指定するフォルダーをカレントディレクトリーに

```
folder_path = "."
```

- ・ 削除する文字列を正規表現で

```
remove_patterns = [r"(@ )+", r"%<¥/*[Pph]¥>", r"@@¥d{7}", r"%¥w+;", r"@long(url)*"]
```

- ・ まだゴミがあった。

```
remove_patterns = [r"(@ )+", r"%<¥/*¥s*[Pph]¥s*¥>", r"@@¥d{7}", r"&¥w+;", r"@long(url)*"]
```

- ・ 保存するファイル名の拡張子を修正

```
new_filename = filename.replace(".txt", ".cln.txt")
```

- ・ 終了を日本語でなく英語 "Done" に

修正後のスクリプト

実行ファイルにコンパイル

```
pip install pyinstaller  
pyinstaller --onefile cocaClean.py
```

使い方

- ・ 処理したいフォルダーにテキストファイルを入れておく
- ・ cocaClean.exe をダウンロードして、そのフォルダーに入れる
- ・ ダブルクリックして実行
- ・ 拡張子「.cln.txt」がついた変換済みファイルが保存される