

SOWID – EDYCJA TEKSTU I STRUKTURY DANYCH.

PAWEŁ JÓZIAK
WYDZIAŁ MATEMATYKI I NAUK INFORMACYJNYCH
POLITECHNIKI WARSZAWSKIEJ

- Nigdy nie wykonuj poleceń metodą *copy&paste*. Przepisz je ręcznie!
- Nie redukuj pracy nad zadaniem do przeczytania go. Wykonaj je i upewnij się, że rozumiesz jak i dlaczego wynik jest taki, jak na ekranie. Zajrzyj do prezentacji bądź zapytaj prowadzącego, jeśli coś nie będzie jasne.
- Linia zaczynająca się od \$ reprezentuje prompt zwykłego użytkownika (nie przepisuj go!). Komendą jest to, co następuje po nim.
- Ostrożnie ze spacjami: nie dodawaj ich więcej ani nie usuwaj takowych, jeśli są!

1. SERIALIZACJA

- (a) Sprawdź, jak w różnych metodach serializacji można zserializować obiekt `null` (aka `None`). Ile bajtów jest do tego potrzebne, w zależności od metody?¹
- (b) Spróbuj zserializować prosty słownik w pythonie, za pomocą
- `pickle`
 - `marshal`
 - `msgpack`
 - `json`
 - `yaml`
 - `dicttoxml`

Która metoda jest najefektywniejsza? Która jest najmniej efektywna?

2. AWK/VIM

- (a) Wprowadź do terminala poniższą instrukcję:
- ```
$ awk '{print "Witaj w instruktażu komend awk"}'
```
- Jak on działa?<sup>2</sup> Jak go zakończyć?<sup>3</sup>
- (b) Jaką opcję można ustawić separator pól?<sup>4</sup>? Jak pewnie pamiętasz, wiele plików konfiguracyjnych UNIXa korzysta z : jako separatora pól. Spróbuj:
- ```
$ awk -F: '{print $1}' /etc/passwd
```
- Jak on działa?⁵ Zmodyfikuj powyższy przykład, by uzyskać podobny efekt dla pozostałych istotnych informacji, np. grupy podstawowe.

```
1https://en.wikipedia.org/wiki/Comparison_of_data_serialization_formats albo ręcznie:  
$ python -m venv lab8venv && source lab8venv/bin/activate && pip install msgpack pyyaml  
$ cat test.serialization.py  
import marshal; import pickle; import msgpack; import json; import yaml;  
dump_info = {".pkl": ("wb", pickle.dump), ".mkl": ("wb", marshal.dump), ".mpk": ("wb",  
msgpack.dump), ".json": ("w", json.dump), ".yaml": ("w", yaml.dump)};  
for extension, (mode, dump_fun) in dump_info.items():  
    with open("null"+extension, mode) as fh:  
        dump_fun(None, fh)  
$ python3 test.serialization.py
```

²Dla każdej linii *stdin* sprawdzany jest domyślny warunek (prawda), a potem wykonywana instrukcja wypisująca *Witaj w instruktażu komend awk*.

³Albo `<CTRL> <C>` (`SIGINT`) albo `<CTRL> <D>` (`EOF`)

⁴`-F`

⁵Wypisuje pierwsze pole – tj. `username` – każdego wpisu do `/etc/password`

- (c) Przygotuj poniższy jednolinijkowy skrypt, i zapisz go jako `testscript`:

```
{print $1 " home at " $6}
```

Dlaczego w powyższym pliku używamy nawiasów klamrowych { i }?⁶ Odpal

```
$ awk -F: -f testscript /etc/passwd
```

Jaki jest wynik działania skryptu?⁷
- (d) Napisz skrypt `awk`, który będzie parsował zawartość plików jak `/etc/passwd`, lecz będzie je wyświetlał jako `tsv` (*tab-separated values*), tj.: zmieni separator z dwukropka (:) na tabulację (\t).⁸
- (e) Użyj sekcji `BEGIN` żeby napisać skrypt działający jak `cat`, lecz dopisujący nagłówek o treści: *Raport treści*⁹
- (f) Zmodyfikuj powyższy skrypt, aby uzyskać efekt pisanie również numeru linii przed linią.¹⁰ A na końcu niech pojawi się zsumaryzowana liczba słów.¹¹
- (g) Rozszerz powyższy skrypt dalej: spraw, aby w nagłówku pojawił się napis informujący o nazwie pliku (np. *Raport treści plik.txt*).¹²
- (h) Napisz skrypt `awk` (którego później użyjesz do plik `/etc/passwd`), który wyświetli informacje jak w pytaniu 2(c), lecz jedynie te linie będą wyświetlone, w których pole informujące o Powłoce zawiera faktyczną powłokę¹³
- (i) Drugi raz to samo: wyświetl tylko informacje o faktycznych użytkownikach (nie kontach systemowych)¹⁴
- (j) Zapisz poniższe dane do pliku `teamlist.csv`:
- ```
Name,Team,First Test,Second Test,Third Test
Tom,Red,5,17,22
Joe,Green,3,14,22
Maria,Blue,6,18,21
Fred,Blue,2,15,23
Carlos,Red,-1,15,24
Phuong,Green,7,19,21
Enrique,Green,3,16,20
Nancy,Red,9,12,24
```

Napisz skrypt `awk`, który policzy średni wynik każdego ucznia, średni wynik każdego testu oraz średni wynik każdego zespołu (Team). Uwaga: ujemni wynik reprezentuje, że osoba była nieobecna na danym teście, i wynik nie powinien być brany pod uwagę przy liczeniu średnich.

<sup>6</sup>Bo to instrukcja, nie warunek.

<sup>7</sup>Dla każdego wpisu do `/etc/passwd` wypisze linijkę typu:

```
root home at /root
joziakp home at /home2/samba/joziakp
itd
```

<sup>8</sup>`BEGIN {FS="."; OFS="\t"} {$1=$1; print $0}`

<sup>9</sup>`$ awk 'BEGIN {print "Raport treści"} {print $0}' plik.txt`

<sup>10</sup>sama instrukcja: `{print NF, $0}`.

<sup>11</sup>całościowy skrypt:

```
BEGIN {words=0; print "Raport treści"}
{words+=NF; print NR, $0}
END {print "Liczba słów", words}.
```

<sup>12</sup>całościowy skrypt:

```
BEGIN {words=0; print "Raport treści", ARGV[1]}
{words+=NF; print NR, $0}
END {print "Liczba słów", words}.
```

<sup>13</sup>Można

- Napisać wyrażenie regularne na jedną z dostępnych powłok:

```
$7 ~ /\bin\/((ba|c|z|tc|k|z)?sh|mini)/
```

- Napisać wyrażenie regularne na jeden z typowych programów nie-powłok:

```
$7 ~ /\(usr\s)?bin\/(false|nologin|sync)/
```

<sup>14</sup>`$3>=1000`, czyli UID

Wynik wypisz w następujący sposób: w pierwszej linii, imiona powinny być wyjustowane do lewej w polu szerokości 10<sup>15</sup>, zaś średnie powinny być wpasowane w pole o siedmiu cyfrach wiodących, kropce i 2 miejscach dziesiętnych<sup>16</sup>.

### 3. JQ

- (a) Dane z przykładu 2j można wyreprezentować jako JSON na dwa sposoby: listę rekordów z kluczami jak kolumny, albo słownik kolumn z listą wartości. Przygotuj pliki pomocnicze na te 2 sposoby, zapisując do plików `teamlist_records.json` oraz `teamlist_values.json`.

```
$ cat teamlist_records.json
[{"Name": "Tom", "Team": "Red",
 "First Test": 5, "Second Test": 17, "Third Test": 22},
 {"Name": "Joe", "Team": "Green",
 "First Test": 3, "Second Test": 14, "Third Test": 22},
 {"Name": "Maria", "Team": "Blue",
 "First Test": 6, "Second Test": 18, "Third Test": 21},
 {"Name": "Fred", "Team": "Blue",
 "First Test": 2, "Second Test": 15, "Third Test": 23},
 {"Name": "Carlos", "Team": "Red",
 "First Test": -1, "Second Test": 15, "Third Test": 24},
 {"Name": "Phuong", "Team": "Green",
 "First Test": 7, "Second Test": 19, "Third Test": 21},
 {"Name": "Enrique", "Team": "Green",
 "First Test": 3, "Second Test": 16, "Third Test": 20},
 {"Name": "Nancy", "Team": "Red",
 "First Test": 9, "Second Test": 12, "Third Test": 24}]
$ cat teamlist_values.json
{"Name": ["Tom", "Joe", "Maria", "Fred", "Carlos", "Phuong", "Enrique", "Nancy"],
 "Team": ["Red", "Green", "Blue", "Blue", "Red", "Green", "Green", "Red"],
 "First Test": [5, 3, 6, 2, -1, 7, 3, 9],
 "Second Test": [17, 14, 18, 15, 15, 19, 16, 12],
 "Third Test": [22, 22, 21, 23, 24, 21, 20, 24]}
```

- (b) Napisz komendę `jq`, dzięki której dokonasz agregacji wszystkich wyników pierwszego testu, raz używając jednego formatu danych, raz używając drugiego formatu danych.
- (c) Napisz komendę `jq`, dzięki której dokonasz agregacji wyników drużyny *Red* – raz używając jednego formatu danych, raz używając drugiego formatu danych.
- (d) Spróbuj napisać komendę `jq`, która przetransformuje jedną reprezentację danych JSONo- wych w drugą.

### 4. YQ

- (a) Sprawdź, że wszystkie instrukcje `jq`, które rozwiązywały podpunkty zadania 3, działają też dla `yq`.
- (b) Jak wyświetlić plik `.json` w standardowej reprezentacji `.yaml`?

### 5. SED

- (a) Użyj wcześniej przygotowanego pliku `teamlist.csv` i spróbuj go spolszczyć (*Red* → *Czerwoni*, *Green* → *Zieloni* etc).
- (b) Spróbuj odtworzyć funkcjonalności `cat`, `head`, `grep` za pomocą instrukcji `sed`, podobnie jak zrobiliśmy to dla `awk`.

<sup>15</sup>`printf "%-10s", var`

<sup>16</sup>`printf "%7.2f", var`