

## Лабораторна робота № 4

4 години

### **Тема: Методи та функції роботи з рядками. Регулярні вирази Python.**

**Мета:** Отримати практичні навички опрацювання текстових даних засобами методів, функцій та регулярних виразів мовою Python.

**Література:** <http://www.matfiz.univ.kiev.ua/userfiles/files/Pres21.pdf>

<http://blog.dzinko.org/2011/03/python.html> регулярні вирази Python.

### **Хід роботи.**

#### **Завдання виконати використовуючи методи роботи з рядками**

1. Задано текст із 3 речень. Скласти програму, яка визначає і виводить на екран:
  - a. всі його різні слова;
  - b. довжину його самого короткого слова;
  - c. букву а замінити на о та визначити кількість замін.
2. Напишіть програму, яка приймає від користувача рядок, і відображає цей рядок у верхньому і нижньому регістрах.
3. Дано рядок. Змініть регістр символів в цьому рядку так, щоб перша буква кожного слова була великою, а інші літери - малими.

#### **Завдання виконати використовуючи методи роботи з регулярними виразами.**

4. Задано текстову змінну з 5 речень. Використовуючи регулярні вирази визначте:
  - a. кількість слів у тексті,
  - b. слова, що починаються на голосну та їх кількість,
  - c. слова що починаються на приголосну,
  - d. з вашого тексту виберіть три будь яких слова і визначте позиції їх розміщення.
  - e. з тексту виберіть слово і замініть його на ваше прізвище.
5. Задано текстову змінну з 6 слів. Отримайте список символів без пробілів та список перших двох букв кожного слова. Зі списку символів створіть новий список який буде включати всі символи крім «а», «б».
6. Створити текстовий рядок в якому використати назви мов програмування. Використовуючи регулярний вираз отримати список назв мов програмування використаних у тексті.
7. Задайте рядок зі списком електронних адрес та їх власників. Зі створеного списку виберіть домени електронних адрес.


8. Задано текст в якому є деякі послідовності цифр що повторюються (наприклад: 333334 333 123 2334). Знайти всі числа, в яких зустрічаються послідовності цифр 5 довжиною від 2-х до 3-х символів.
9. Задано рядок в якому відображається час (год:хв:сек) та дата в повному форматі. Отримайте список часу та дат. Отримайте список годин та років.
  
10. У тексті зустрічаються ідентифікатори `contig` називаються як NODE\_1, NODE\_2 тощо. Вважається за краще, щоб їх називали contig1, contig2 тощо. Створити текстовий рядок з цими змінами.
11. Розробити алгоритм програми, що перевіряє коректність введення поштового індексу засобами регулярних виразів за варіантом, що надано в табл. 1.

Табл. 1 – Індивідуальні варіанти завдання

Варіант	Країна	Алгоритм формування індексу
1	Сполучені Штати Америки	Числовий код з дев'ятьма цифрами. Після п'ятої опціонально тире
2	Нідерланди	Чотири цифри. Перша цифра не нуль. Після опціонального пропуску код з двох літер
3	Італія	П'ять цифр. Попереду опціонально “V-“ чи “I-“.
4	Індія	Шість цифр. Перша цифра не нуль. Опціонально пропуск після третьої
5	Польща	Дві цифри, дефіс, три цифри
6	Іспанія	П'ять цифр. Після третьої цифри опціональний пропуск. Попереду опціонально “I-“.
7	Великобританія	Від 5 до 8 цифр і літер, що розділені пропуском. Наприклад, AA9A 9AA
8	Латвія	Чотири цифри Попереду опціонально “V-“ чи “I-“.
9	Македонія	Чотири цифри. Перша від 1 до 7
10	Португалія	Чотири цифри, дефіс, три цифри, пропуск, назва регіону до 25 літер

### Методичні рекомендації.

Регулярні вирази (regular expressions) – сучасна система пошуку текстових фрагментів у електронних документах, що заснована на спеціальній системі запису зразків для пошуку.



*Регулярні вирази використовують символ зворотної косої риски ('\') для позначення спеціальних форм або для дозволу використання спеціальних символів без звернення до їхнього особливого значення.*

## Метасимволи

**[...]** Набір символів

**[^...]** Негативний клас символів. Відповідає будь-якому символу, не укладеному у квадратні дужки

**\** Повідомляє про спеціальну послідовність (також може використовуватися для екранування спеціальних символів)

• Будь-який символ (крім символу нового рядка)

**^** Починається з

**\$** Закінчується на

**\*** Нуль або більше випадків

**+** Один або кілька випадків

**?** Нуль чи одне входження

**{}** Рівно вказана кількість входжень

**{n,m}** Відповідає щонайменше «n», але з більше «m» повторень попереднього символу.

**|** Чергування. Відповідає символам до або після |

**()** Захоплення та угруповання

**(xyz)** Група символів. Відповідає символам xyz у цьому порядку.

**Спеціальна послідовність** - це коли за символом \ слідує один із символів у списку нижче, яка має особливе значення:

**\A** Повертає збіг, якщо вказані символи знаходяться на початку рядка

**\b** Повертає збіг, у якому зазначені символи знаходяться на початку або наприкінці слова

**\B** Повертає збіг, у якому зазначені символи присутні, але НЕ на початку (або наприкінці) слова

**\d** Повертає збіг, у якому рядок містить цифри (числа від 0 до 9)

- \D** Повертає збіг, у якому рядок НЕ містить цифр
- \S** Повертає збіг, у якому рядок містить символ пробілу
- \S** Повертає збіг, в якому рядок НЕ містить пробілу
- \w** Повертає збіг, у якому рядок містить будь-які символи слова (символи від a до Z, цифри від 0 до 9 та символ підкреслення \_ )
- \W** Повертає збіг, в якому рядок НЕ містить символів слова
- \Z** Повертає збіг, якщо вказані символи знаходяться в кінці рядка

**Set (Набір)** – це набір символів усередині пари квадратних дужок [] зі спеціальним значенням:

- [arn] Повертає збіг, у якому є один із зазначених символів (a, r або n)
- [a-n] Повертає збіг для будь-якого символу нижнього регістру в алфавітному порядку від a до n
- [^arn] Повертає збіг для будь-якого символу, ЗА ВИКЛЮЧЕННЯМ a, r і n
- [0123] Повертає збіг, в якому присутня будь-яка із зазначених цифр (0, 1, 2 або 3)
- [0-9] Повертає збіг для будь-якої цифри від 0 до 9
- [0-5][0-9] Повертає збіг для будь-яких двоцифрових чисел від 00 до 59
- [a-zA-Z] Повертає відповідність для будь-якого символу в алфавітному порядку від a до z, у нижньому регістрі АБО у верхньому регістрі
- [+] У наборах + \*. | () \$ {} знак не має особливого значення, тому [+] означає: повернути збіг для будь-якого символу + у рядку

*Модуль re надає набір функцій/методів, які дозволяють нам шукати рядок зі збігом:*

- findall() — Повертає список, що містить усі збіги
- search() — Повертає об'єкт Match, якщо десь у рядку є збіг
- split() — Повертає список, в якому рядок був поділений при кожному збігу
- sub() — Замінює один або кілька збігів рядком
- subn() — Робить те саме, що й sub(), але повертає новий рядок і кількість замін
- match() — Шукає збіг з початку рядка
- finditer() - Шукає всі збіги з pattern, повертає ітератор
- compile() — Компілює regular expression, на виході отримуємо об'єкт, до якого можна застосовувати всі перелічені функції
- fullmatch() — Перевіряє, що весь рядок відповідає описаному регулярному виразу
- flags (прапори) — Вказуються у функціях, впливають на поведінку регулярного вираження

## Контрольні запитання

1. Що таке регулярний вираз?

2. Яку функціональність надає модуль `re`?
3. Що таке шаблони регулярних виразів та для чого вони використовуються?
4. Який синтаксис можна використовувати для побудови регулярних виразів?
5. Що працює швидше – рядкова функція чи аналогічний регулярний вираз?
6. Як створювалася теорія регулярних виразів?
7. Що вважається найпростішим регулярним виразом?
8. Що таке вираз у квадратних дужках?
9. Яке значення має дефіс у регулярному виразі?
10. Яке значення має символ `^` у регулярному виразі?
11. Яким чином реалізовані розгалуження у регулярних виразах?