

18. Adeolu O. Essential Guide to Python for All Levels Collection: Forging Ahead in Tech and Programming. 2024. 314 p.
19. Nocedal J., Wright S. Numerical Optimization. Springer Series in Operations Research and Financial Engineering. 2006. 664 p. DOI: <https://doi.org/10.1007/978-0-387-40065-5>.

Стаття надійшла 15.10.2024

Стаття прийнята 28.10.2024

УДК 004.62: 658.5

doi: 10.31498/2225-6733.49.1.2024.321179

© Сергієнко А.В.¹, Балалаєва О.Ю.², Гаркуша І.М.³, Платонов Д.М.⁴

РОЗРОБКА ТА ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ ІНФОРМАЦІЙНОЇ СИСТЕМИ ПАРСИНГУ САЙТІВ ІЗ ВИКОРИСТАННЯМ ФРЕЙМВОРКУ SELENIDE

Стаття присвячена дослідженню методів автоматизації збору даних із вебсайтів за допомогою технологій парсингу. У роботі описано основні переваги парсингу порівняно з ручним збором даних, наведено класифікацію існуючих парсерів, їх можливості, обмеження та застосування в реальних проєктах. Проведено детальний аналіз популярних комерційних та безкоштовних парсерів, таких як Import.io, Webhose.io, Dexi.io, Scraperhub, ParseHub, Visual Scraper, Spinn3r, 80legs, Scraper, OutWit Hub, з метою визначення їх переваг та недоліків у різних сценаріях використання. Особливу увагу приділено порівнянню фреймворків Selenium та Selenide, що широко застосовуються для автоматизації взаємодії з веббраузерами. Зроблено висновок про доцільність використання фреймворку Selenide завдяки його спрощеному синтаксису, можливостям роботи з динамічним контентом та підтримці інтелектуального очікування. У статті представлено розробку власного парсера на базі Selenide, орієнтованого на потреби малих і середніх підприємств із обмеженим бюджетом. Система побудована на сучасному технологічному стеку, що включає Java 11, Python, PostgreSQL, Angular 12, Docker, Gradle, Kafka, Node.js. Детально описано архітектуру програми, взаємодію між модулями, а також реляційну модель бази даних для зберігання отриманих даних. Запропонований підхід дозволяє налаштовувати парсер для роботи з різними типами сайтів, забезпечує високу швидкість збору та обробки інформації, а також гнучкість у налаштуванні параметрів вибірки. Створений інструмент надає можливість використовувати технології контейнеризації для спрощення розгортання та підтримки додатка. Результати роботи можуть бути використані для реалізації ефективних інформаційно-пошукових систем та автоматизації рутинних процесів збору даних, що особливо актуально для компаній, які прагнуть оптимізувати свої бізнес-процеси та зменшити витрати.

Ключові слова: парсинг, парсер, сайт, вебдодаток, інформаційно-пошукова система, дані, Selenium, Selenide.

¹ канд. техн. наук, доцент, ДВНЗ «Приазовський державний технічний університет», м. Дніпро/Маріуполь, ORCID: 0000-0003-1328-2572, sergienko_a_v@pstu.edu

² канд. техн. наук, доцент, ДВНЗ «Приазовський державний технічний університет», м. Дніпро/Маріуполь, ORCID: 0000-0003-1461-4399, balalaeva_e_u@pstu.edu

³ канд. техн. наук, доцент, НТУ «Дніпровська політехніка», м. Дніпро, ORCID: 0000-0003-1190-1501, garkusha.i.m@nmu.one

⁴ магістр, ДВНЗ «Приазовський державний технічний університет», м. Дніпро/Маріуполь, platonov_d_m@pstu.edu

A. Serhiienko, O. Balalaieva, I. Garkusha, D. Platonov. Development and research of the efficiency of a website parsing information system using the Selenide framework. The article is devoted to the study of methods for automating data collection from websites using parsing technologies. The paper describes the main advantages of parsing compared to manual data collection, provides a classification of existing parsers, their capabilities, limitations and application in real projects. A detailed analysis of popular commercial and free parsers, such as Import.io, Webhose.io, Dexi.io, Scraperhub, ParseHub, Visual Scraper, Spinn3r, 80legs, Scraper, OutWit Hub, is carried out in order to determine their advantages and disadvantages in various usage scenarios. Particular attention is paid to the comparison of the Selenide and Selenium frameworks, which are widely used to automate interaction with web browsers. The conclusion is made about the feasibility of using the Selenide framework due to its simplified syntax, capabilities for working with dynamic content and support for intelligent waiting. The article presents the development of a custom parser based on Selenide, focused on the needs of small and medium-sized enterprises with a limited budget. The system is built on a modern technology stack, including Java 11, Python, PostgreSQL, Angular 12, Docker, Gradle, Kafka, Node.js. The program architecture, interaction between modules, and the relational database model for storing the obtained data are described in detail. The proposed approach allows you to configure the parser to work with different types of sites, provides high speed of information collection and processing, as well as flexibility in configuring sampling parameters. The created tool provides the opportunity to use containerization technologies to simplify the deployment and support of the application. The results of the work can be used to implement effective information search systems and automate routine data collection processes, which is especially important for companies that seek to optimize their business processes and reduce costs.

Keywords: web parsing, web parser, web site, web application, information search system, data, Selenium, Selenide.

Постановка проблеми. У сучасному світі швидкий доступ до структурованої інформації є ключовою вимогою для ефективного функціонування бізнесу. Вебсайти виступають основним джерелом актуальних даних, які можуть використовуватися для маркетингових досліджень, аналізу конкурентів або оптимізації внутрішніх процесів, проте ручний збір даних вже давно є неефективним через значні витрати часу та високу ймовірність помилок. Це обумовлює зростання попиту на автоматизовані інформаційно-пошукові системи парсингу, які дозволяють отримувати великий обсяг необхідних даних у зручному форматі з мінімальним втручанням людини. Доцільність використання парсерів обумовлена швидкістю їх роботи, можливістю складання вибірки за багатьма параметрами та налаштування парсингу з певною періодичністю, а також не лише відсутністю помилок у звітах, а й рекомендаціями щодо виправлення помилок на сайті. На сьогоднішній день існує багато сервісів для парсингу, які можуть бути як хмарними, так і коробковими версіями. Водночас слід зазначити, що існуючі інструменти мають низку обмежень, пов'язаних із складністю налаштування, недостатньою гнучкістю або високою вартістю, що створює труднощі для малих і середніх підприємств. Тому актуальною задачею є розробка власного парсера, для чого необхідно проаналізувати сферу застосування парсингу, обрати необхідний функціонал, а також провести дослідження ефективності роботи створеного парсера.

Аналіз останніх досліджень і публікацій. Import.io пропонує розробникові легко формувати власні пакети даних, для чого необхідно тільки імпортувати інформацію з певної вебсторінки й експортувати її в CSV. Це дозволяє збирати інформацію з тисячі вебсторінок дуже швидко, при цьому не написавши ні рядка коду, а також створювати тисячі API згідно з заданими вимогами. Тариф Starter призначений для простих випадків використання, таких як видалення даних зі статичних сайтів, та включає тільки базові функції. Даний тариф містить 5 000 запитів на місяць та вартує від 199 доларів на місяць. Тариф Standard дозволяє працювати з більш складнішими завданнями, такими як робота з динамічними сайтами, капчами або аутентифікацією, містить 20 000 запитів та коштує від 599 доларів на місяць. Разом з веб інструментом доступні безкоштовні застосування для Windows, Mac OS X і Linux для створення екстракторів і пошукових роботів. Import.io підходить для швидкого збору даних, але може бути недостатньо потужним

для складних або масштабних проєктів. Даний інструмент може мати труднощі з обробкою сайтів із динамічним контентом, а зміна структури сайту може зламати налаштування імпорту.

Webhose.io [1] забезпечує прямий доступ в реальному часі до структурованих даних, отриманих у результаті парсингу тисяч онлайн джерел. Цей парсер здатний збирати вебдані на більш ніж 240 мовах і зберігати результати в різних форматах, у тому числі в XML, JSON і RSS. Webhose.io представляє собою вебзастосування для браузера, що використовує власну технологію парсингу даних, яка дозволяє обробляти величезні об'єми інформації з численних джерел з єдиним API. Webhose пропонує безкоштовний тарифний план за обробку 1 000 запитів в місяць і 50 доларів за преміальний план, що покриває 5 000 запитів в місяць. Webhose.io робить фокус на текстовому контенті, тому не дуже підходить для вилучення мультимедіа (зображень чи відео).

Dexi.io [2] (попередня назва CloudScraper) здатний парсити інформацію з будь якого вебсайту і не вимагає завантаження додаткових застосувань, як і Webhose, а редактор самостійно встановлює своїх пошукових роботів і отримує дані в режимі реального часу. Користувач може зберегти зібрані дані в хмарі, наприклад, Google Drive і Box.net, або експортувати дані у форматах CSV або JSON. CloudScraper забезпечує анонімний доступ до даних, пропонує ряд проксі-серверів, які допомагають приховати ідентифікаційні дані користувача. CloudScraper зберігає дані на своїх серверах впродовж 2 тижнів, потім архівуючи їх. Сервіс пропонує 20 годин роботи безкоштовно, після чого він коштуватиме 29 доларів в місяць. Dexi.io підходить для автоматизації веб-скрейпінгу без глибоких технічних знань, але для великих або специфічних проєктів можуть знадобитися додаткові налаштування чи ресурси.

Scrapinghub (зараз Zyte) [3] представляє собою хмарний інструмент парсингу даних, який допомагає вибирати і збирати необхідні дані для будь-яких цілей. Scrapinghub використовує Crawlera, розумний проксі-ротатор, оснащений механізмами, здатними обходити захисту від ботів. Сервіс здатний справлятися з великим обсягом інформації і захищеними від роботів сайтами. Scrapinghub перетворює вебсторінки в організований контент. Базовий безкоштовний пакет дає доступ до одного пошукового робота (обробка до 1 Гб даних, далі – 9 доларів в місяць), преміальний пакет надає чотирьох паралельних пошукових ботів. Scrapinghub варто використовувати для професійного вебскрейпінгу, але даний сервіс може бути складним і затратним для простих задач чи новачків.

ParseHub [2] може парсити один або багато сайтів з підтримкою JavaScript, AJAX, сеансів, cookie і редиректів. Сервіс використовує технологію самонавчання і здатний розпізнати складні документи в мережі, після чого генерує вихідний файл у тому форматі, який потрібний користувачеві. ParseHub існує окремо від вебзастосування в якості програми робочого столу для Windows, Mac OS X і Linux. Програма дає безкоштовно п'ять пробних пошукових проєктів. Тарифний план Преміум за 89 доларів дозволяє 20 проєктів і обробку 10 000 вебсторінок за проєкт. ParseHub добре підходить для початківців і невеликих проєктів, але може виявитися недостатньо потужним для масштабного або складного скрейпінгу.

VisualScraper [4] є програмним засобом для парсингу великих об'ємів інформації з мережі. Даний сервіс видобуває дані з декількох вебсторінок і синтезує результати в режимі реального часу, при цьому дані можна експортувати в формати CSV, XML, JSON і SQL. Користуватися і управляти веб-даними допомагає простий інтерфейс типу point and click. VisualScraper пропонує пакет з обробкою більше 100 000 сторінок з мінімальною вартістю 49 доларів в місяць. Є безкоштовне застосування, схоже на Parsehub, доступне для Windows із можливістю використання додаткових платних функцій.

Spinn3r [1] дозволяє парсити дані з блогів, новинних стрічок, новинних каналів RSS і Atom, соціальних мереж. Spinn3r має «оновлюваний» API, який робить 95% роботи по індексації. Це припускає вдосконалений захист від спаму і підвищений рівень безпеки даних. Spinn3r індексує контент, як Google, і зберігає витягнуті дані у файлах формату JSON. Інструмент постійно сканує мережу і знаходить оновлення потрібної інформації з безлічі джерел, користувач завжди має оновлювану в реальному часі інформацію. Консоль адміністрування дозволяє управляти процесом дослідження; є повнотекстовий пошук. Spinn3r робить фокус на медіаконтенті, він оптимізований для збору даних із новинних сайтів, блогів, соціальних медіа та RSS-стрічок, при цьому менш ефективний для збору інших типів даних.

80legs [5] представляє собою гнучкий вебінструмент парсингу сайтів, який можна достатньо точно підлаштувати під потреби користувача, при цьому сервіс є дуже потужним, він справляється з дуже великими обсягами даних і має функцію негайного витягання. Клієнтами 80legs є такі гіганти як MailChimp і PayPal. Опція «Datafiniti» дозволяє знаходити дані якнайшвидше, що забезпечує високоефективну пошукову мережу. Сервіс пропонує безкоштовний пакет – 10 000 посилань за сесію, який можна оновити до пакету INTRO за 29 доларів в місяць, що збільшує кількість посилань до 100 000 за сесію. 80legs підходить для масштабних, ресурсомістких завдань, але вимагає технічної підготовки та не є оптимальним для невеликих або простих проєктів.

Scraper [1] є розширенням для Chrome з обмеженими функціями парсинга даних, але воно корисне для онлайн-досліджень і експортування даних в Google Spreadsheets. Цей інструмент призначений як для новачків, такі для експертів, які можуть скопіювати дані у буфер обміну або сховище у вигляді електронних таблиць, використовуючи OAuth. Scraper – це безкоштовний інструмент, що працює прямо у браузері й автоматично генерує XPath для визначення URL, які треба перевірити. Сервіс досить простий: він не має повної автоматизації або пошукових ботів, як Import або Webhose, але це можна розглядати як перевагу для новачків, оскільки його не доведеться довго налаштовувати, щоб отримати потрібний результат. Scraper доцільно використовувати для простого та швидкого вилучення даних, але він не підходить для складних або масштабних проєктів.

OutWit Hub [6] – це доповнення Firefox з десятками функцій видобування даних, що може автоматично переглядати сторінки і зберігати інформацію у необхідному користувачеві форматі. Це один з найпростіших безкоштовних вебінструментів по збору даних, що не вимагають спеціальних знань в написанні кодів. OutWit Hub підходить для поміркованих завдань зі скрейпінгу, але може бути обмежений при роботі з великими або складними сайтами.

Аналіз існуючих готових сервісів показав, що доцільною є реалізація за допомогою фреймворку власного парсера, який включав би найчастіше затребуваний функціонал. Програмувати парсери самостійно можна за допомогою спеціальних бібліотек, що існують для мов програмування Python, JavaScript, Java. Бібліотеки на Python надають безліч ефективних і швидких функцій для парсингу [7]. Багато з цих інструментів можна підключити до готового застосування у форматі API для створення краулерів, що налаштовуються, а відкритий код мають наступні проєкти: BeautifulSoup, Selenium, Lxml. Для JavaScript теж існують готові бібліотеки для парсингу із зручними функціональними API: Cheerio, Osmosis, Apify SDK. У Java реалізовані різні інструменти і бібліотеки, а також зовнішні API, які можна використати для парсингу: Jsoup, Jaunt, HTMLUnit.

Огляд вищеперелічених бібліотек та фреймворків показав, що найбільш перспективною є розробка парсера за допомогою фреймворків Selenium та Selenide на базі мови програмування Java, при цьому останнім часом в проєктах частіше використовують інструмент Selenide замість Selenium Web Driver. Для остаточного вибору засобу розробки було проведено порівняльний аналіз роботи з фреймворками Selenium та Selenide [8].

Selenium є портативним фреймворком для автоматизації вебдрайверів, що надає інструменти для тестування вебзастосунків. Крім того, Selenium Testing Framework поставляється з предметно орієнтованою мовою (Selenese), що дозволяє писати тести на декількох мовах програмування: Groovy, C#, Java, PHP, Perl, Python, Scala і Ruby. Перевага таких тестів полягає в тому, що їх можна запускати в сучасних веббраузерах, і це дозволяє проводити тестування на різних операційних системах, таких як Windows, macOS і Linux. Серед можливостей даного фреймворку слід зазначити крос-браузерну автоматизацію та автоматизацію мобільних браузерів і нативних застосунків. Він пропонує низькорівневі API для детального управління браузером та підходить для створення інструментів автоматизації, таких як FluentLenium, Thucydides, Watir-webdriver. Selenium – велику спільноту та безліч ресурсів для навчання, є основою для багатьох інших інструментів автоматизації, але його використання вимагає детального знання роботи WebDriver та тайм-менеджменту. Selenium підходить для загальної автоматизації браузерів і тестування специфічних сценаріїв, але він не забезпечує вбудованих механізмів для роботи з динамічним контентом. Selenium надає широкі можливості для створення тестових рішень, але вимагає більше зусиль для управління тестами.

Selenide побудований на основі Selenium та спеціалізується на спрощенні автоматизації UI-тестів. Даний фреймворк інтегрується з Selenium WebDriver, має простий синтаксис для взаємодії з елементами сторінки та орієнтований на написання лаконічного коду. Він може вирішувати проблеми динамічного контенту та таймаутів за допомогою інтелектуального очікування, а також забезпечує високоабстраговані API. Selenide обирають, коли потрібні швидкі, стабільні та легко підтримувані UI-тести, адже даний фреймворк спрощує процес тестування завдяки вбудованим рішенням для поширених проблем (таймаути, Ajax).

За результатами проведеного аналізу ефективності парсингу сайтів було зроблено вибір на користь Selenid, оскільки спеціально розроблений для тестування вебзастосунків і широко відомий як інструмент автоматизації веббраузера, а також забезпечує підтримку крос-браузерної автоматизації, автоматизації нативних застосунків, автоматизації мобільних браузерів тощо.

Метою роботи є дослідження автоматизації отримання даних із сайтів, які є різними за характером, за допомогою парсера, що створений за бази фреймворку Selenid та працює за модифікованою технологією.

Виклад основного матеріалу. У даній роботі було розроблено систему, що отримує дані з сайту за допомогою парсингу. Для реалізації проекту використовується наступний стек технологій: СУБД PostgreSQL, фреймворк Angular 12, а також Docker, Docker-compose, Gradle, Selenid, Node.js, Npm, Kafka; мови програмування Java 11 та Python. Angular — один з найпопулярніших і сучасних фреймворків (бібліотек) JavaScript, що розвивається Google. За допомогою нього можна швидко створювати складні й динамічні інтерфейси на сайтах. Docker – програмне забезпечення для автоматизації розгортання і управління застосунками в середовищах з підтримкою контейнеризації, контейнеризатор застосунків.

Схему взаємодії програмних модулів додатку наведено на рисунку 1.




Рис. 1 – Схема взаємодії програмних модулів

Реляційна модель даних наведена на рисунку 2.

Процес виконання додатку передбачає наступні кроки:

- запускається консоль, здійснюється перехід в директорію проекту, виконується команда запуску контейнерів
- сканер-контейнер підключається до hub-контейнеру, а hub-контейнер – до firefox;
- сканер зберігає отримані дані в базі даних;
- клієнт-контейнер робить запит до порталу-контейнеру, який отримує збережену в базі даних інформацію та виводить її в клієнтську частину додатку.




Рис. 2 – Реляційна схема бази даних інформаційно-пошукової системи парсингу сайтів

Програма сканера працює в контейнері докера, незалежно від програми порталу, а знайдена інформація зберігається в БД PostgreSQL (рисунок 3).

```

    Hub
    to org.seleniumhq.jetty9.util.log.StdErrLog
    hub | 08:39:24.105 INFO [Hub.start] - Selenium Grid hub is up and run
    ning
    hub | 08:39:24.107 INFO [Hub.start] - Nodes should register to http://
    /172.21.0.2:4444/grid/register/
    hub | 08:39:24.107 INFO [Hub.start] - Clients should connect to http:
    //172.21.0.2:4444/wd/hub
    hub | 08:39:37.234 INFO [DefaultGridRegistry.add] - Registered a node
    http://172.21.0.3:5555
    hub | 08:39:57.523 INFO [RequestHandler.process] - Got a request to c
    reate a new session: Capabilities {acceptInsecureCerts: true, browserN
    ame: firefox, version: }
    hub | 08:39:57.529 INFO [TestSlot.getNewSession] - Trying to create a
    new session on test slot {server:CONFIG_UUID=16c94ffd-3293-48a9-bd65-
    fd78097e8be5, seleniumProtocol=WebDriver, browserName=firefox, maxInst
    ances=2, moz:firefoxOptions={log={level=info}}, platformName=LINUX, ve
    rsion=88.0, applicationName=, platform=LINUX}

    Firefox
    d: "/usr/bin/firefox" "--marionette" "--foreground" "--no-remote" "--profile" "/t
    mp/rust_mozprofilelw7IZa"
    Firefox | [GFX1-]: glxtest: libpci missing
    Firefox | [GFX1-]: glxtest: libEGL missing
    Firefox | [GFX1-]: glxtest: libEGL missing
    Firefox | 1623573598216 Marionette INFO Marionette enabled
    Firefox | console.warn: SearchSettings: "get: No settings file exists, new pr
    ofile?" (new Error("", "(unknown module)"))
    Firefox | 1623573600195 Marionette INFO Listening on port 4177
    Firefox | 1623573600313 Marionette WARN TLS certificate errors
    will be ignored for this session
    Firefox | 08:40:00.342 INFO [ProtocolHandshake.createSession] - Detected dial
    ect: W3C
    Firefox | 08:40:00.386 INFO [RemoteSession$Factory.lambda$performHandshake$0]
    - Started new session b98a0815-6cca-4386-9299-25c355b8cc3e (org.openqa.seleni
    um.firefox.GeckoDriverService)

    Scanner
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Added connection org.postgresql.jdbc.PgConnection@3e
    5f95b3
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Added connection org.postgresql.jdbc.PgConnection@30
    987c08
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Added connection org.postgresql.jdbc.PgConnection@34
    a7fec3
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Added connection org.postgresql.jdbc.PgConnection@71
    a57633
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - After adding stats (total=5, active=1, idle=4, waiti
    ng=0)
    scanner | INFO o.s.o.j.LocalContainerEntityManagerFactoryBean - Initialized JPA EntityManagerFactory for persistence u
    nit 'default'
    scanner | INFO o.s.s.c.ThreadPoolTaskScheduler - Initializing ExecutorService 'taskScheduler'
    scanner | INFO dplatonov.scanner.ScannerApplication - Started ScannerApplication in 5.749 seconds (JVM running for 6.66
    )
    scanner | INFO dplatonov.scanner.Parser - Start download HTML
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Pool stats (total=5, active=0, idle=5, waiting=0)
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Fill pool skipped, pool is at sufficient level.
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Pool stats (total=5, active=0, idle=5, waiting=0)
    scanner | DEBUG com.zaxxer.hikari.pool.HikariPool - HikariPool-1 - Fill pool skipped, pool is at sufficient level.
    
```

Рис. 3 – Консоль запуску та роботи частин сканеру: Hub, FireFox, Scanner

Додаток Portal працює у контейнері докера, незалежно від програми сканера. Головна сторінка містить таблицю зі сканерами, кожному з яких користувачем задаються умови пошуку та параметри роботи сканеру (рисунок 4).




Рис. 4 – Головна сторінка системи

Для створення нового сканеру авторизований користувач задає ім'я сканеру та базову URL-адресу для пошуку і ланцюгу подій для доступу до потрібних даних. Для створення ланцюга подій (рисунок 5) необхідно зазначити назву тегу, його клас, а також дію, яку необхідно буде виконати (наприклад, натискання кнопки).

New Scanner Configs

Enter Scanner Name *

Enter URL *

Tag	Type	Action	Value	Delete
Enter tag * /html/body/div[1]/div[1]/hea	Enter type * xpath	Enter type * click	Enter type	
Enter tag * /html/body/div[1]/div[1]/hea	Enter type * xpath	Enter type * click	Enter type	
Enter tag * /html/body/div[1]/div[1]/hea	Enter type * xpath	Enter type * click	Enter type	
Enter tag * /html/body/div[1]/div[1]/hea	Enter type * xpath	Enter type * scan	Enter type	

Items per page:
1 - 4 of 4

<<
<
>
>>

+ Add new Step to Queue

Рис. 5 – Створення ланцюгу подій

З наведеного на рисунку 4 прикладу налаштувань видно, що сканер повинний буде перейти за URL: https://jobs.dou.ua/companies/ та знайти на HTML сторінці ланцюг тегів, що задані в чіткій послідовності із типом class: l-items; l-company; cn a; city; descr;. Останній тег має містити текст, який шукатиме парсер.

Для подальшого аналізу ефективності роботи сканера із обраними налаштуваннями пошуку та налаштуваннями самого парсера зручною опцією є експорт отриманих результатів у файл у форматах csv та xls (рисунок 6).

Java jobs from work.ua

Filter

No.	Start Date	Finish Date	Value
0	2022-12-13 06:11:35	2022-12-13 06:12:15	Відгукнутися Зберегти Ще Вакансія від 13 грудня 2022 Middle full stack developer (Java, JavaScript, ...
1	2022-12-13 06:11:35	2022-12-13 06:12:15	Відгукнутися Зберегти Ще Вакансія від 13 грудня 2022 Java developer TAC VIP фінанси, банки, страхува...

Items per page: 5 1 - 2 of 2

CSV

Рис. 6 – Експорт отриманих сканером даних у окремий файл

У рамках даної роботи було проведено дослідження парсингу даних з різних сайтів з використанням розробленого парсера Aggregator.

Для прикладу було поставлено задачу отримати дані по вакансіях з сайтів www.work.ua, www.jobs.dou.ua. Під час дослідження складності видобутку даних розробленим авторами парсером, аналізували кількість кроків, яка необхідна для виконання поставленого завдання для кожного з обраних сайтів. Для цього було створено два сканери з різними налаштуваннями за тегами та за переліком подій (рисунки 7-8).

Edit Scanner Configs

Enter Scanner Name *

Java jobs from work.ua

Enter URL *

<https://www.work.ua/>

Tag	Type	Action	Value	Delete
Enter tag	Enter type	Enter action	Enter value	
/html/body/header/section/c	xpath	click	Enter value	
Enter tag	Enter type	Enter action	Enter value	
/html/body/header/section/c	xpath	insert	java	
Enter tag	Enter type	Enter action	Enter value	
/html/body/header/section/c	xpath	clear	Enter value	
Enter tag	Enter type	Enter action	Enter value	
		pause	10	
Enter tag	Enter type	Enter action	Enter value	
/html/body/header/section/c	xpath	click	Enter value	

Items per page: 5 1 - 5 of 13

+ Add new Step to Queue

✓

✗

Рис. 7 – Налаштування сканера по www.work.ua

Edit Scanner Configs

Enter Scanner Name *

Java jobs from dou.ua

Enter URL *

https://dou.ua/

Tag	Type	Action	Value	Delete
Enter tag /html/body/div[1]/header/ul/	Enter type xpath	Enter action click	Enter value	
Enter tag /html/body/div[2]/div[1]/div[1]	Enter type xpath	Enter action click	Enter value	
Enter tag /html/body/div[2]/div[1]/div[1]	Enter type xpath	Enter action insert	Enter value java	
Enter tag /html/body/div[2]/div[1]/div[1]	Enter type xpath	Enter action click	Enter value	
Enter tag /html/body/div[2]/div[2]/div[1]	Enter type xpath	Enter action click	Enter value	

Items per page: 5 1 - 5 of 11

+ Add new Step to Queue

Рис. 8 – Налаштування сканера по www.jobs.dou.ua

Іншим параметром складності роботи алгоритму є кількість кліків, що здійснюється: чим більше кліків, тим складніше виконати видобуток даних. Кожний клік – це новий html-запит, який збільшує час виконання роботи парсера, тому що зажить від швидкості з'єднання, яке складно прогнозувати в теперішніх умовах.

Сформовані в результаті роботи сканерів файли, що містять видобуті з сайтів дані, наведені на рисунках 9-10.

	A	B	C	D	E	F	G	H	I	J
	Crated date	Start time	End time	Name	Url	Tags		Created by	1st modify date	Modify by
1							Вакансія від 22 листопада 2022 Middle full stack developer (Java, JavaScript, angular 2+) 110 000 грн Люкс Ассіст IT Дистанційна робота Повна зайнятість. Досвід роботи від 1 року. Вакансію зараз переглядає 1 шукач. Відгукнуться на вакансію, щоб бути серед перших! Отримати вакансію Компанія «Люкс-Ассіст» шукає fullstack розробника для проекту для міжнародної страхової компанії, з якою співпрацюємо вже більше 4-х років. Кількість проектів зростає, тому потрібен ще один фахівець. Робота в дружелюбній команді! Обов'язково потрібний вільний усякий вечір, володіння англійською мовою. Вимоги: • Java • JavaScript (angular 2+) • PostgreSQL SQL (не обов'язково, але буде плюсом) Умови праці: • повний робочий день • віддалена робота • оплачувані відпустки та лікарняні • оплата праці 90000-110000 гривні Чекаємо на ваше резюме			
2	11/22/2022 11:39PM	11/22/2022 1:00AM	11/22/2022 1:05AM	Java jobs from work.ua	https://www.work.ua/	<class="form-control jobseeker-search">insert="java"><class="btn btn-search">click;<class="card card-hover card-visited wordwrap job-link">click;repeat,<class="pagination hidden-xs",class="no-style">click;<class="card wordwrap">scan;				

Рис. 9 – Вихідний файл даних з парсингу сайту www.work.ua

	A	B	C	D	E	F	G	H	I	J
1	Crated date	Start time	End time	Name	Uri	Tags		Created by	modify date	Modify by
2	11/22/2022 11:39PM	11/22/2022 1:00AM	11/22/2022 1:10AM	Java jobs from dou.ua	https://jobs.dou.ua/	Micro Focus Boli sazancl kompani Micro Focus Caintoa IT korporacija zli uslovov pokaz 13000 onisrobimiviev, upo rozporbnee uproskov onetp Enterprise software y oenewtax DevOps, Security, Hybrid IT, BigData analytic. •Boli sazancl / Java / Kila 17 nectonasa 2022 Middle Java developer Kila, sazancl Job Description We are Ukraine R&D site of Software development company MicroFocus. More than 40,000 customers worldwide depend on solutions developed by more than 12,000 Micro Focus employees in 48 countries. Welcome to the team of professionals to work in friendly, family-style, innovative and stable environment. Must Have: •3+ years of hands-on experience working in core Java and advanced Java software development. •Strong Programming Skills in designing and implementation of multi-tier applications using Java, JDBC, REST API. •Strong analytical and problem-solving skills •Strong understanding of data structures, algorithms, OOPs concepts •Experience in working with Apache Tomcat application servers. •Strong experience in all the phases of software development life cycle including requirements gathering, analysis, design, implementation, deployment and support. •Experience in Java design patterns. •Experience in industry standard Relational databases particularly Oracle, SQL Server and Postgres. •Experience in software testing, Junit testing, regression testing, defect tracking and management •Experience with Search Technologies particularly Apache Lucene •Hands-on experience with build tools and technologies, like Gradle, Jenkins, Ant, etc.. •Experience with secure development. •Familiar with Source Control versioning, branching •Familiar with Agile methodologies. •Excellent written and verbal communication skills, and problem-solving skills. Technical Skills Java Technologies: Core Java, JDBC, Spring Framework, Swing Search Technologies: Apache Lucene Web Technologies: RESTFull API Database Technologies: Oracle, SQL Server and Postgres Operating Systems: Windows, Linux Source Control: StarTeam, GIT Build Tools: Gradle, Ant, Continuous builds, Jenkins We offer: •Possibility to work with highly qualified colleagues and possibility to work on interesting and challenging tasks and projects. •Opportunity to work in company that has strong position on the market and contribute to development of highly competitive				

Рис. 10 – Вихідний файл даних з парсингу сайту www.jobs.dou.ua

Проаналізовано результати виконання парсингу обох сайтів. Час виконання сканування сайтів склав 5 хвилин для www.work.ua та 10 хвилин для www.jobs.dou.ua. Загальна кількість вакансій на www.work.ua в категорії «ІТ, комп'ютери, інтернет» – 4220, на www.jobs.dou.ua – 4150.

Для виведення 14 вакансій по ключовому слову «java» з сайту www.work.ua для сканера потрібно було виконати 17 ітерацій, 2 з яких – циклічні ітерації з повтором по 6 і поверненням на одну сторінку, а також 3 теги. Усього сканер виконав 63 дій.

Для виведення 14 вакансій по ключовому слову «java» з сайту www.jobs.dou.ua для сканера потрібно було виконати 8 ітерацій, 1 з яких – циклічна з повтором 13 разів і поверненням на одну сторінку, а також 3 теги. Усього сканер виконав 59 дій.

Для порівняння з відкритих джерел було взято дані про швидкість роботи двох парсерів, розроблених на C# та на ANTLR відповідно, а саме результати з тестувань двох проєктів: CoreFX-1.0.0-rc2 та Roslyn-1.1.1 із однаковими параметрами (лексер 12%; парсер – 88%). Завдання з обробки 7329 файлів із загальною кількістю рядків 2 286 274 та загальною кількістю символів 91 132 116 парсер Roslyn виконав за 4 секунди, а парсер ANTLR – за 25 секунди. Завдання з обробки 6527 файлів із загальною кількістю рядків 1 967 672 та загальною кількістю символів 74 319 082 парсер Roslyn виконав за 3 секунди, а парсер ANTLR – за 16 секунд (рисунк 11).

Сканування парсером Aggregator, розробленим в рамках даної роботи, проводиться по заголовках та по тегах. У проведеному дослідженні швидкість підключення є нестабільним показником, який за власними замірами склав 1 сек. для сайту www.work.ua та до 1,5 сек. для сайту www.jobs.dou.ua. Для сканування сайту www.work.ua час на підключення склав: $63 \cdot 1 = 63$ сек. Враховуючи загальний час 5 хв. = 300 сек., сумарно на обробку було витрачено $300 - 63 = 237$ сек., при цьому на обробку однієї операції – $237/63 = 3,76$ сек. Для сканування сайту www.jobs.dou.ua час на підключення склав $59 \cdot 1,5 = 88,5$ сек. Враховуючи загальний час 10 хв. = 600 сек., сумарно на обробку витрачено $600 - 88,5 = 511,5$ сек., при цьому на обробку однієї операції – $511,5/59 = 8,67$ сек. (рисунки 11-12).




Рис. 11 – Порівняння роботи розробленого парсера та інших відомих парсерів




Рис. 12 – Залежність часу роботи парсера від кількості операцій

Результати дослідження показали, що розроблений парсер Aggregator працює на ряду з розглянутими парсерами і має прямопропорційну залежність часу виконання від кількості проведених операцій. Хоча Aggregator не може конкурувати з такими гігантами, як Roslyn, проте його все ж можна використати для парсингу, оскільки його швидкість досить висока і складає від 3,23 до 8,67 секунд (у середньому 5,95 секунди), що лише в 1,98 разів повільніше за корпоративно розроблені парсери. Зважаючи на нестабільне інтернет-підключення, отриманий результат є прийнятним, що доводить ефективність роботи створеного парсера для поставлених умов.

Висновки

Таким чином, розроблено інформаційну систему парсингу сайтів. Вебдодаток розміщений на хостингу: <https://github.com/BearClumsy/aggregator> та є доступним в будь-який час доби через браузер. У роботі докладно проаналізовано 10 існуючих парсерів, виділено їхні переваги та недоліки, що дозволило поставити задачу для розробки власного парсера.

Основними функціональними можливостями розробленого вебдодатку є: додавання та редагування налаштувань сканерів, редагування налаштувань сканеру, отримання інформації поза заданими критеріями пошуку, формування звітів та експортування отриманих даних.

Для розробки використано наступний стек технологій: СУБД Postgres SQL, мови програмування Java 11 та Python, фреймворки Angular 12, Node.js, Npm, а також засоби з автоматизації роботи із проектом Docker, Docker-compose, Gradle, Selenide.

Розроблений парсер Aggregator працює на ряду з розглянутими парсерами і має прямопорційну залежність часу виконання від кількості проведених операцій. Швидкість його роботи складає від 3,23 до 8,67 секунд, що в середньому становить 5,95 секунд, що лише в 1,98 разів повільніше за відомі корпоративні додатки для парсингу статичного тексту. Зважаючи на те, що запропонований парсер використовується для сканування вебсторінок, а умови використання передбачали нестабільне інтернет-підключення, отриманий результат є прийнятним, а робота створеного парсера є ефективною.

Перелік використаних джерел:

1. Ratra R., Gulia P. Big Data tools and techniques: a roadmap for predictive analytics. *International Journal of Engineering and Advanced Technology (IJEAT)*. 2009. Vol. 9. Iss. 2. Pp. 4986-4992. DOI: <https://doi.org/10.35940/ijeat.B2360.129219>.
2. Tomar R.S. A Study on Web Scraping. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*. 2020. Vol. 8. Iss. 6. Pp. 1820-1824. DOI: <https://doi.org/10.15662/IJAREEIE.2019.0806020>.
3. Ateeq W. M. B., Al-Khalifa H. S. Intelligent framework for detecting predatory publishing venues. *IEEE Access*. 2023. Vol. 11. Pp. 20582-20618. DOI: <https://doi.org/10.1109/ACCESS.2023.3250256>.
4. EasySpider: EasySpider: A No-Code Visual System for Crawling the Web / Wang N., Feng W., Yin J., Ng S.-K. *WWW '23 Companion : Companion Proceedings of the ACM Web Conference 2023*, Austin, TX, USA, 30 April - 4 May 2023. Pp. 192-195. DOI: <https://doi.org/10.1145/3543873.3587345>.
5. A classification framework for data marketplaces / Stahl F., Schomm F., Vossen G., Vomfell L. *Vietnam Journal of Computer Science*. 2016. Vol. 3. Pp. 137-143. DOI: <https://doi.org/10.1007/s40595-016-0064-2>.
6. Kirichenko L., Radivilova T., Carlsson A. Detecting cyber threats through social network analysis: short survey. *SocioEconomic Challenges*. 2017. Vol. 1. Iss. 1. Pp. 20-34. DOI: <https://doi.org/10.21272/sec.2017.1-03>.
7. Exploring Web Scraping with Python / Sasi A., Deep A., Kumar K., Birla V. *Machine Intelligence and Smart Systems : Proceedings of the I International Conference*, Gwalior, India, 24-25 September 2020. Pp. 287-296. DOI: https://doi.org/10.1007/978-981-33-4893-6_26.
8. Selenide. Concise UI tests in Java. URL: <https://selenide.org/documentation/selenide-vs-selenium.html> (дата звернення: 28.08.2024).

References:

1. R. Ratra, and P. Gulia, «Big Data tools and techniques: a roadmap for predictive analytics», *International Journal of Engineering and Advanced Technology (IJEAT)*, vol. 9, iss. 2, pp. 4986-4992, 2009. doi: 10.35940/ijeat.B2360.129219.
2. R.S. Tomar, «A Study on Web Scraping», *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, vol. 8, iss. 6, pp. 1820-1824, 2020. doi: 10.15662/IJAREEIE.2019.0806020.
3. W.M.B. Ateeq, H.S. Al-Khalifa, «Intelligent framework for detecting predatory publishing venues», *IEEE Access*, vol. 11, pp. 20582-20618, 2023. doi: 10.1109/ACCESS.2023.3250256.
4. N. Wang, W. Feng, J. Yin, and S.-K. Ng, «EasySpider: EasySpider: A No-Code Visual System for Crawling the Web», in *Proc. ACM Web Conference 2023*, USA, 2023, pp. 192-195. doi: 10.1145/3543873.3587345.
5. F. Stahl, F. Schomm, G. Vossen, and L. Vomfell, «A classification framework for data marketplaces», *Vietnam Journal of Computer Science*, vol. 3, p. 137-143, 2016. doi: 10.1007/s40595-016-0064-2.

6. L. Kirichenko, T. Radivilova, and A. Carlsson, «Detecting cyber threats through social network analysis: short survey», *SocioEconomic Challenges*, vol. 1, iss. 1, pp. 20-34, 2017. doi: 10.21272/sec.2017.1-03.
7. A. Sasi, A. Deep, K. Kumar, and V. Birla, «Exploring Web Scraping with Python», in Proc. I Int. Conf. «Machine Intelligence and Smart Systems», Gwalior, India, 2020, pp. 287-296. doi: 10.1007/978-981-33-4893-6_26.
8. Selenide. Concise UI tests in Java. [Online]. Available: <https://selenide.org/documentation/selenide-vs-selenium.html>. Accessed on: August 28, 2024.

Стаття надійшла 15.09.2024

Стаття прийнята 10.10.2024

УДК 004.4:004.94

doi: 10.31498/2225-6733.49.1.2024.321181

© П'ятикоп О.Є.¹, Гніденко В.А.², Воротнікова З.Є.³

МОБІЛЬНИЙ ЗАСТОСУНОК АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ОСОБИСТИХ ВИТРАТ

У сучасному світі все частіше використовуються електронні платіжні системи, мобільні додатки для платежів і цифрові банківські послуги, створюючи попит на більш точні та зручні інструменти для управління особистими витратами. Це дослідження представляє розробку інтелектуальної системи для аналізу та прогнозування особистих витрат, інтегрованої в кросплатформний мобільний додаток. Дослідження включає аналіз останніх досліджень та публікацій, які підтвердили, що впровадження аналітичних та інтелектуальних систем управління витратами значно підвищує ефективність фінансового контролю та дозволяє своєчасно приймати обґрунтовані рішення. Огляд літератури також показав, що інтеграція таких систем з мобільними додатками є актуальною, затребуваною та забезпечує зручність і доступність в управлінні фінансами. Для розробки мобільного додатку для аналізу та прогнозування особистих витрат на основі історичних даних користувачів були вивчені такі методи прогнозування, як експоненційно зважене ковзне середнє (EWMA) і лінійна регресія. Оцінка цих методів продемонструвала, що EWMA постійно досягає вищої точності, виміряної WAPE та MAPE. За результатами цього створено прототип мобільного додатку, який використовує історичні дані транзакцій, отримані через відкритий API від Monobank, класифікує витрати за категоріями та застосовує вибраний метод для надання користувачам персоналізованих прогнозів. Щоб забезпечити кросплатформну функціональність, мобільний додаток було розроблено з використанням технологій Dart і Flutter. Розроблений прототип має інтуїтивно зрозумілий інтерфейс із графічною візуалізацією результатів аналізу та прогнозу у вигляді діаграм та графіків. Запропонований підхід сприяє раціоналізації витрат, підвищує ефективність фінансового планування та підвищує фінансову грамотність користувачів.

Ключові слова: аналіз витрат, прогнозування, мобільний додаток, персональні фінанси, експоненційне згладжування, EWMA, лінійна регресія, WAPE, MAPE, Flutter.

¹ канд. техн. наук, доцент, ДВНЗ «Приазовський державний технічний університет», м. Дніпро, ORCID: 0000-0002-7731-3051, piatykop_o_je@pstu.edu

² магістр, ДВНЗ «Приазовський державний технічний університет», м. Дніпро

³ канд. техн. наук, доцент, ДВНЗ «Приазовський державний технічний університет», м. Дніпро, ORCID: 0000-0002-0746-5981, vorotnikova_z_j@pstu.edu