

ЗАСТОСУВАННЯ ШТУЧНОГО ІНТЕЛЕКТУ ДЛЯ АВТОМАТИЗОВАНОГО АНАЛІЗУ РЕЗЮМЕ ТА ПІДТРИМКИ ПОПЕРЕДНЬОГО ВІДБОРУ КАНДИДАТІВ

Принделас Валентин Леонідович

студент групи МППм-1-26-1.4д,

Київського столичного університету імені Бориса Грінченка,

науковий керівник – д.т.н., проф. Бушма О.В.

ВСТУП

Під час первинного відбору фахівець має зіставити резюме різної структури з вимогами конкретної вакансії. Одна й та сама компетентність може бути названа по-різному або згадана лише в описі проєкту, тому перед порівнянням потрібно виділити навички, досвід, освіту, знання мов та інші професійні відомості. За кількох вакансій ця робота повторюється. Автоматизація дає змогу застосовувати однакові правила, але не повинна самостійно приймати кадрові рішення. Дослідження алгоритмічного добору персоналу вказують на ризик упередженості й потребу людського контролю [1; 2].

Для опрацювання напівструктурованих резюме використовують методи обробки природної мови (Natural Language Processing, NLP). Розпізнавання іменованих сутностей (Named Entity Recognition, NER) дає змогу виділяти з тексту назви організацій, посад, дат та інші значущі об'єкти [3]. На практиці такі методи поєднують із правилами, словниками та нейромережевими моделями. Підходи на основі правил легко перевірити, але вони залежать від повноти словника синонімів. Sentence-BERT формує векторні представлення тексту й допомагає знаходити змістово близькі формулювання [5; 6], однак один показник подібності не пояснює внесок конкретної вимоги у підсумкову оцінку.

Автоматизоване зіставлення кандидата з вакансією розвивається і як окремий напрям. У моделі PJFNN відповідність кандидата посаді (person-job fit) визначається через спільне представлення резюме та вакансії [4]. Великі мовні моделі (Large Language Models, LLM) можуть допомагати зі структуризацією варіативного тексту, але їх пряме використання для остаточного ранжування потребує обережності. JobFair показує необхідність вимірювати упередження під час найму [7], а дослідження зіставлення вакансій і резюме виявляють залежність результату від контекстних характеристик [8].

Актуальність роботи визначається потребою поєднати гнучке вилучення професійних відомостей із резюме та відтворюване багатокритеріальне оцінювання, де можна простежити внесок кожної вимоги. Автоматизація сама по собі не гарантує справедливості [2]. Рамка керування ризиками ШІ NIST (AI RMF) вимагає документування й контролю ризиків [9], а Регламент (ЄС) 2024/1689 відносить системи ШІ для працевлаштування та оцінювання кандидатів до високоризикових [10]. Тому мовна модель у запропонованому підході використовується для структурування даних, тоді як підсумкова оцінка обчислюється окремим детермінованим алгоритмом і залишається допоміжною для фахівця.

Метою дослідження є розроблення методу та програмних засобів структурування даних резюме, зіставлення професійного профілю кандидата з вимогами вакансії та формування відтворюваної й пояснюваної інтегральної оцінки для підтримки попереднього відбору.

Наукова новизна полягає в розділенні структуризації резюме та підсумкового оцінювання. Словниково-евристичне вилучення може доповнюватися великою мовною моделлю, однак кінцева оцінка обчислюється детермінованим багатокритеріальним алгоритмом. На відміну від підходів, де модель безпосередньо формує показник відповідності [4], тут окремо зберігається внесок кожного критерію, що робить результат відтворюваним і придатним до перевірки [7; 8].

Об'єктом дослідження є процес автоматизованого аналізу резюме та підтримки попереднього відбору кандидатів. Предметом дослідження є методи, алгоритми та програмні засоби вилучення й нормалізації професійних відомостей, формалізації вимог вакансії, багатокритеріального зіставлення, пояснюваного оцінювання та ранжування кандидатів.

Завдання дослідження. Для досягнення мети необхідно сформувати інформаційну модель кандидата й вакансії; розробити спосіб вилучення та нормалізації професійних ознак; визначити критерії, ваги й правила точних, часткових та відсутніх відповідностей; створити алгоритм інтегрального оцінювання і пакетного ранжування; реалізувати локальний контур з можливістю додаткового використання великої мовної моделі; провести функціональну перевірку та визначити обмеження системи.

Методологія дослідження. З файла резюме вилучається текст і виконується доменна нормалізація зі збереженням позначень C#, C++ і CI/CD. Контактні та числові поля визначаються регулярними виразами, професійні характеристики — словниками, синонімічними відповідниками й евристичними; окрема модель NER не навчалася [3]. За потреби велика мовна модель повертає структуровані дані у форматі JSON, які проходять нормалізацію та перевірку. Ідентифікаційні дані не впливають на оцінку й можуть знеособлюватися перед зовнішнім запитом. Вакансія подається як набір категорій і ваг. Локальний алгоритм визначає точні, часткові та відсутні відповідності, додаткові компетентності, окремо оцінює досвід і освіту та формує загальну оцінку з поясненням. Функціональна перевірка охопила імпорт, виявлення дублів, зіставлення, контроль ваг, пакетні режими та відмови зовнішнього компонента III.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Розроблено настільний застосунок мовою Python з інтерфейсом PySide6 та локальною базою SQLite через SQLAlchemy. Модулі обробки підтримують PDF, DOCX, TXT, MD, CSV, HTML, XLSX, RTF, ODT і растрові зображення; для сканів може застосовуватися оптичне розпізнавання символів (OCR). Відомості про кандидата й конкретний файл резюме зберігаються окремо, тому нова версія документа не знищує сформований профіль. Точний дубль визначається за SHA-256, а професійний профіль надалі використовується для різних вакансій.

На рис. 1 показано послідовність роботи системи. Велика мовна модель може допомагати структурувати складні фрагменти тексту, але не визначає підсумкову оцінку. Обробка документів, база даних і бальне оцінювання працюють локально. Для зовнішньої обробки реалізовано підключення до OpenAI, Gemini, Anthropic, Ollama та сумісних сервісів із переходом до резервної моделі в разі помилки.



Рис.1. Послідовність автоматизованого аналізу резюме та формування результату

Для технічних навичок, інструментів, мов, особистісних і комунікаційних компетентностей, проєктів та сертифікатів застосовується спільне правило. Після нормалізації назв точний збіг дає 1 бал, часткове входження — 0,5 бала, а відсутня вимога — 0. Коефіцієнт 0,5 використано як проміжну оцінку часткової текстової відповідності, а не як універсальну міру семантичної близькості. Категоріальна оцінка має вигляд

$$S_{\text{c}} = 100 \cdot (M_{\text{c}} + 0,5 \cdot P_{\text{c}}) / N_{\text{c}}, \quad (1)$$

де M_{c} — кількість точних відповідностей, P_{c} — часткових, N_{c} — кількість вимог категорії.

Якщо вимог немає, категорія отримує 100 %, а наявні у кандидата значення фіксуються як додаткові компетентності. Тобто відсутній у вакансії критерій не зменшує оцінку; це потрібно враховувати під час аналізу середніх значень.

Досвід оцінюється як $S_{\text{exp}} = \min(100; 100 \cdot E / E_{\text{req}})$, де E — кількість років досвіду кандидата, E_{req} — мінімальна вимога вакансії. Освіта перевіряється за текстовим входженням. Ці правила прозорі, але спрощені: кількість років не відображає релевантності досвіду, а текстовий збіг не враховує ієрархію рівнів освіти.

Після цього категоріальні оцінки множаться на ваги. Технічні навички мають 30 %, досвід — 20 %, інструменти, мови, освіта та особистісні й комунікаційні компетентності — по 10 %, проєкти й сертифікати — по 5 %. Ваги можна змінювати для конкретної вакансії, але їх сума повинна дорівнювати 100 %. Інтегральна оцінка

$$S_{total} = \Sigma (S_c / 100) \cdot w_c, \quad \Sigma w_c = 100, \quad (2)$$

де w_c — вага категорії. Окремо зберігаються внесок кожної категорії, точні, часткові та відсутні відповідності й додаткові компетентності, тому S_{total} можна перевірити арифметично. Ваги задають пріоритети вакансії, а не є статистично навченими коефіцієнтами.

Пакетний аналіз підтримує порівняння одного кандидата з кількома вакансіями, кількох кандидатів з однією вакансією та повну матрицю. Якщо використовується велика мовна модель, професійні дані структуруються один раз, а подальше зіставлення виконується локально. Після зміни профілю або вимог вакансії збережений результат перераховується; примусовий режим дає змогу створити новий запис для регресійної перевірки.

Таблиця 1

Фактичні результати функціональної перевірки системи

Показник	Значення	Інтерпретація
Автоматизовані тести	44 успішно	Підтверджено проходження поточного набору модульних і регресійних перевірок
Кандидати / вакансії	11 / 28	Демонстраційний знімок локальної бази SQLite
Актуальні пари кандидат–вакансія	308	Повна матриця 11×28 для останнього результату кожної унікальної пари
Історичні записи аналізу	936	Містять повторні та примусові перерахунки; для поточного зрізу береться останній результат
Середня інтегральна оцінка S_{total}	75,57 %	Описує розподіл демонстраційного набору, а не точність штучного інтелекту
$S_{total} \geq 75 \% / \geq 90 \%$	159 / 76	Кількість пар у відповідних діапазонах шкали інтерфейсу
Зв'язки навичок / вимоги вакансій	99 / 166	Збережені зв'язки професійних навичок і структуровані вимоги вакансій

Дані табл. 1 підтверджують працездатність реалізованої послідовності обробки, але не прогностичну точність. Для 308 останніх унікальних пар середня оцінка S_{total} становить 75,57 %; 159 пар мають не менше 75 %, а 76 — не менше 90 %. Високі значення частково пояснюються тим, що категорія без вимог не зменшує оцінку. Незалежної експертної розмітки немає, тому точність класифікації (Assurance), точність позитивних прогнозів (Precision), повнота

(Recall) та F1-міра не визначалися. Для таких показників потрібен еталонний набір пар «кандидат–вакансія».

Обговорення результатів. За однакових даних кандидата, вакансії та ваг S_{total} не залежить від випадковості генеративної моделі, а користувач бачить внесок критеріїв. Це відрізняється від прямого формування рейтингу великою мовною моделлю, для якого дослідження фіксують ризик упередження [7; 8]. Помилка під час структуризації може спотворити вхідні ознаки, але її можна перевірити за вихідним резюме. Повторне використання професійного профілю зменшує кількість ручних операцій, проте якість оцінки все одно залежить від коректності вимог вакансії та обраних ваг.

Основні обмеження пов'язані з повнотою словника синонімів, можливими поверхневими збігами за входженням рядка, бінарним оцінюванням освіти та представленням досвіду лише кількістю років. Окремі модулі NER, TF-IDF і семантичних векторних представлень не реалізовані. 44 автоматизовані тести підтверджують роботу перевірених функцій, але не правильність кадрового прогнозу. Справедливість алгоритмічного оцінювання також потребує окремого аудиту [2; 7; 8]. Вилучення чутливих полів із формули та знеособлення даних перед зовнішнім сервісом зменшують ризик, але не усувають його; потрібні журналювання, людський контроль і репрезентативна перевірка [9; 10].

Подальші напрями дослідження. Для кращого розпізнавання близьких за змістом формулювань доцільно перевірити Sentence-BERT або інші моделі векторних представлень [6], зберігши категоріальне пояснення результату. Нормалізацію навичок і професій можна пов'язати з ESCO та O*NET [11; 12]. Після формування експертно розміченого еталонного набору можна обчислювати Precision, Recall, F1-міру, кореляцію ранжування та міжекспертну узгодженість. Окремо варто перевірити чутливість до ваг і порогів, стійкість ранжування, справедливість алгоритму та вплив структуризації великою мовною моделлю на кількість пропущених або помилково доданих ознак.

ВИСНОВКИ

У розробленій системі дані з резюме після вилучення та нормалізації формують професійний профіль кандидата, який можна повторно зіставляти з різними вакансіями. Вимоги вакансії зберігаються за категоріями та мають ваги. Велика мовна модель може допомагати зі складними фрагментами тексту, однак підсумкову оцінку обчислює окремий локальний модуль.

Під час зіставлення система фіксує точні, часткові та відсутні відповідності, додаткові компетентності, окремо оцінює досвід і освіту та обчислює S_{total} як суму зважених внесків. Деталі зберігаються для пояснення результату. Пакетний режим охоплює три типові схеми порівняння, а після зміни профілю або вимог вакансії оцінка перераховується.

За результатами функціональної перевірки успішно виконано 44 автоматизовані тести й сформовано матрицю 11×28 , тобто 308 актуальних пар «кандидат–вакансія». У базі міститься 936 історичних записів аналізу. Середня оцінка 75,57 % характеризує демонстраційний набір, а не точність III. Через

відсутність незалежної експертної розмітки Accuracy, Precision, Recall і F1-міра не розраховувалися.

Отримано працездатний метод і програмну реалізацію для структурування резюме, зіставлення з вакансіями та пояснюваного багатокритеріального оцінювання. Подальша перевірка має охопити семантичне зіставлення, класифікації ESCO та O*NET, експертний еталон, аналіз чутливості й справедливості. Остаточне кадрове рішення має залишатися за фахівцем з добору персоналу.

ДЖЕРЕЛА

1. Pisanelli E. Your resume is your gatekeeper: Automated resume screening as a strategy to reduce gender gaps in hiring. *Economics Letters*. 2022. Vol. 221. Art. 110892. DOI: 10.1016/j.econlet.2022.110892.
2. Fabris A., Baranowska N., Dennis M. J. et al. Fairness and Bias in Algorithmic Hiring: A Multidisciplinary Survey. *ACM Transactions on Intelligent Systems and Technology*. 2025. Vol. 16, No. 1. Art. 16. P. 1–54. DOI: 10.1145/3696457.
3. Jehangir B., Radhakrishnan S., Agarwal R. A survey on Named Entity Recognition: datasets, tools, and methodologies. *Natural Language Processing Journal*. 2023. Vol. 3. Art. 100017. DOI: 10.1016/j.nlp.2023.100017.
4. Zhu C., Zhu H., Xiong H., Ma C., Xie F., Ding P., Li P. Person-Job Fit: Adapting the Right Talent for the Right Job with Joint Representation Learning. *ACM Transactions on Management Information Systems*. 2018. Vol. 9, No. 3. Art. 12. DOI: 10.1145/3234465.
5. Devlin J., Chang M.-W., Lee K., Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of NAACL-HLT 2019*. P. 4171–4186. DOI: 10.18653/v1/N19-1423.
6. Reimers N., Gurevych I. Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks. *Proceedings of EMNLP-IJCNLP 2019*. P. 3982–3992. DOI: 10.18653/v1/D19-1410.
7. Wang Z., Wu Z., Guan X. et al. JobFair: A Framework for Benchmarking Gender Hiring Bias in Large Language Models. *Findings of the Association for Computational Linguistics: EMNLP 2024*. P. 3227–3246. DOI: 10.18653/v1/2024.findings-emnlp.184.
8. Iso H., Pezeshkpour P., Bhutani N., Hruschka E. Evaluating Bias in LLMs for Job-Resume Matching: Gender, Race, and Education. *Proceedings of NAACL 2025: Industry Track*. P. 672–683. DOI: 10.18653/v1/2025.naacl-industry.55.
9. Tabassi E. Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1. National Institute of Standards and Technology, 2023. DOI: 10.6028/NIST.AI.100-1.
10. Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence. *Official Journal of the European Union*. 2024. URL: <https://eur-lex.europa.eu/eli/reg/2024/1689/oj> (дата звернення: 08.10.2026).
11. European Commission. European Skills, Competences, Qualifications and Occupations (ESCO): The ESCO Classification. URL: <https://esco.ec.europa.eu/en/classification> (дата звернення: 08.10.2026).
12. National Center for O*NET Development. O*NET Database. URL: <https://www.onetcenter.org/database.html> (дата звернення: 08.10.2026).