УДК 004.89:004.415.2

РОЗРОБЛЕННЯ ІНТЕЛЕКТУАЛЬНОГО ВЕБЗАСТОСУНКУ ДЛЯ АНАЛІЗУ ТА АДАПТИВНОГО ПЛАНУВАННЯ ЗВИЧОК

Андрусенко О.В.[1]; Крісілов В.А., д.т.н., проф.[2]
[1,2] Національний університет «Одеська політехніка»
[1,2] Україна, Одеса
[1] oksana.andrusenko12345@gmail.com; [2] krisilov@op.edu.ua

Анотація. *Розроблено вебзастосунок для автоматизованого обліку, аналізу та планування звичок. Система поєднує клієнтський застосунок, хмарну базу даних і сервіс машинного навчання для прогнозування ризику пропуску дій та адаптації нагадувань. За результатами метаморфічного тестування і перевірки досягнуто показника якості F1-score = 0,83 та зменшено частку пропусків дій на 21,4%.*
Ключові слова*: вебзастосунок; планування звичок; штучний інтелект; машинне навчання; прогнозування ризику.*

Вступна частина. Значна частина застосунків для відстеження звичок орієнтована лише на фіксацію виконаних дій та відображення статистичних показників. Водночас тривалість формування автоматизованої поведінки суттєво варіюється (18–254 дні, у середньому 66 днів) і супроводжується високим ризиком пропуску дій на перших тижнях [1]. Аналіз поширених рішень (Habitica, Loop Habit Tracker, Habitify, Streaks, Productive) показав, що класичні системи працюють за детермінованим принципом безперервності серії і мають суттєві обмеження [2]: зниження чутливості користувача до сповіщень через надсилання нагадувань у фіксований час без урахування змін розпорядку дня, відсутність превентивної аналітики пропусків та обмеженість безкоштовної кросплатформної синхронізації даних.

Метою дослідження є зменшення кількості пропусків запланованих дій користувачами шляхом розроблення вебзастосунку з підсистемою штучного інтелекту для прогнозування ризику пропуску звичок та адаптації часу і частоти нагадувань.

Основна частина. На етапі специфікації визначено дев’ять сценаріїв використання системи та встановлено нефункціональні вимоги згідно з ISO/IEC 25010 [3]: цільова доступність сервісу ≥ 99%, час розрахунку прогнозу ≤ 3 с, інтегральний показник якості класифікації F1-score ≥ 0,78 і точність позитивних прогнозів Precision ≥ 0,75, перевищення базового евристичного правила на ≥ 10% та інтерпретованість кожної поради. За діаграмою Ішікави [4] визначено чинники трьох критичних ризиків: низької точності на малих вибірках (Р-01), збоїв інтеграції підсистем (Р-02) та зміни поведінки користувача (Р-03). Для їх мінімізації реалізовано блокування моделі за історії спостережень менше 14 діб («холодний старт») із переходом на евристичні правила, збереження планового часу у кожному записі журналу виконання, медіанну фільтрацію часових затримок, резервний контур на клієнті та погодження змін графіка користувачем.

Архітектуру системи побудовано за трирівневою клієнт-серверною моделлю [5]. Клієнтський рівень реалізовано як односторінковий застосунок (сервіси AuthService, HabitService, StatisticsService, MlAnalysisService), а хмарний рівень базується на Firebase Authentication і базі даних Cloud Firestore та містить чотири колекції (users, habits, habit_logs, recommendations), пов’язані за ідентифікатором idUser.

Підсистему інтелектуального аналізу реалізовано мовою Python (FastAPI, scikit-learn, pandas, numpy). Модуль FeatureExtractor за 30-денним журналом фіксації дій формує вектор

числових ознак: частку пропусків за останні 7 і 14 діб, тривалість поточної безперервної серії, середнє часове відхилення фактичної відмітки від планового часу у хвилинах та частку пропусків у вихідні дні. Класифікатор RiskClassifierModel на основі алгоритму випадкового лісу (Random Forest) обчислює ймовірність пропуску у діапазоні [0; 1] і визначає головний фактор ризику. Найбільшу вагу у прогнозі мають середнє часове відхилення відмітки (0,42) та частка пропусків за 7 діб (0,31). За медіанним зміщенням часу відміток система розраховує рекомендований час нагадування, а сервіс AiExplanationService формує текстове пояснення поради.

Верифікацію виконано методом метаморфічного тестування за п'ятьма відношеннями: перестановка порядку ознак (MR1.2), додавання нейтрального атрибута (MR2.1), дублювання підмножини записів (MR3.2), додавання дій з аналогічним профілем затримок (MR4.2) та вилучення архівованих записів (MR5.2). На незалежній тестовій вибірці досягнуто значень показника якості F1-score = 0,83 та точності позитивних прогнозів Precision = 0,81 (перевищення евристичного правила на 14,5%) при середньому часі прогнозу 0,42 с. Експериментальна перевірка за участю 20 користувачів підтвердила скорочення середнього часового відхилення відмітки виконання на 64% та зменшення частки пропусків запланованих дій на 21,4%.

Висновки. Розроблено вебзастосунок для аналізу і планування звичок з інтелектуальною підсистемою прогнозування. Поєднання трирівневої архітектури з класифікатором на основі алгоритму Random Forest забезпечило показник якості F1-score = 0,83 при швидкодії 0,42 с та дозволило зменшити кількість пропусків запланованих дій на 21,4%.

Використання інструментів ШІ. Під час підготовки публікації використано мовну модель Google Gemini 3.1 Pro для покращення академічних формулювань (розділи «Вступна частина», «Основна частина», «Висновки») та перекладу анотації (розділ «Abstract»). У програмній реалізації застосовано модель Random Forest (scikit-learn) для класифікації ризику пропуску та Google Gemini API для генерації текстових пояснень рекомендацій.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

[1] Lally, P., van Jaarsveld, C. H. M., Potts, H. W. W., & Wardle, J. (2010). How are habits formed: Modelling habit formation in the real world. *European Journal of Social Psychology, 40*(6), 998–1009. https://doi.org/10.1002/ejsp.674

[2] Griply. (2026). *Best habit tracker apps in 2026: 13 tested and compared*. https://griply.app/compare/best-habit-tracker-apps

[3] TMAP. (n.d.). *Quality characteristics – ISO25010*. https://www.tmap.net/wiki/quality-characteristics-iso25010/

[4] Kumah, A., Nwogu, C. N., Issah, A.-R., Obot, E., Kanamitie, D. T., Sifa, J. S., & Aidoo, L. A. (2024). Cause-and-effect (fishbone) diagram: A tool for generating and organizing quality improvement ideas. *Global Journal on Quality and Safety in Healthcare, 7*(2), 85–87. https://doi.org/10.36401/jqsh-23-42

[5] Microsoft. (2023). *Common web application architectures*. Microsoft Learn. https://learn.microsoft.com/en-us/dotnet/architecture/modern-web-apps-azure/common-web-application-architectures

Andrusenko O.V., Krisilov V.A.

Development of an intelligent web application for habit analysis and adaptive planning

Abstract. *A web application has been developed for automated tracking, intelligent analysis, and planning of habits. The system combines a client application, a cloud database, and a machine learning service to predict the risk of missing actions and adapt reminders. Based on metamorphic testing and verification results, a classification quality score of F1-score = 0.83 was achieved, and the share of missed actions decreased by 21.4%.*

Keywords*: web application; habit planning; artificial intelligence; machine learning; risk prediction.*