

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
СУМСЬКИЙ НАЦІОНАЛЬНИЙ АГРАРНИЙ УНІВЕРСИТЕТ
ФАКУЛЬТЕТ ЕКОНОМІКИ І МЕНЕДЖМЕНТУ
Кафедра кібернетики та інформатики**

КВАЛІФІКАЦІЙНА РОБОТА

за другим (магістерським) рівнем вищої освіти

на тему: Інформаційна технологія прогнозування результатів інтернет-маркетингової кампанії регіонального провайдера

Виконав:

Михайлюк Олександр Станіславович
здобувач вищої освіти
спеціальності 126 «Інформаційні
системи та технології»

Науковий керівник:

Шелехов Ігор Володимирович
кандидат технічних наук, доцент
кафедри кібернетики та інформатики

Рецензент:

Москаленко Альона Сергіївна
кандидат технічних наук, доцент
кафедри комп'ютерних наук
Сумського державного університету

Суми – 2025

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
СУМСЬКИЙ НАЦІОНАЛЬНИЙ АГРАРНИЙ УНІВЕРСИТЕТ**

Факультет економіки і менеджменту

Кафедра кібернетики та інформатики

Ступінь вищої освіти – другий (магістерський)

Спеціальність – 126 «Інформаційні системи і технології»

ЗАТВЕРДЖУЮ:

завідувачка кафедри

кібернетики та інформатики

АГАДЖАНОВА Світлана

25 листопада 2024 р.

ЗАВДАННЯ

на кваліфікаційну роботу здобувачу вищої освіти

Михайлюку Олександрю Станіславовичу

1. Тема кваліфікаційної роботи: «Інформаційна технологія прогнозування результатів інтернет-маркетингової кампанії регіонального провайдера»
2. База практичного дослідження: Науково-виробниче комерційне приватне підприємство «Спектр-АС», м. Суми
3. Керівник кваліфікаційної роботи: Шелехов Ігор Володимирович, доцент кафедри кібернетики та інформатики, к.т.н., доцент, затверджений наказом по університету № 3873/ос від 25.11.2024 р.
4. Строки подання здобувачем кваліфікаційної роботи: до 03.12.2025 р.
5. Вихідні дані до кваліфікаційної роботи –
6. Зміст розрахунково-пояснювальної записки: 1) Аналіз предметної області та постановка задачі дослідження; 2) Вибір методів дослідження, моделювання та проектування інформаційної технології; 3) Розробка та реалізація інформаційної системи; 4) Аналіз результатів дослідження, оформлення розрахунково-пояснювальної записки до кваліфікаційної роботи

Завдання прийняв до виконання _____

Олександр МИХАЙЛЮК

Дата отримання завдання: 25 листопада 2024 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/П	Назва етапів кваліфікаційної роботи	Строки виконання етапів	Примітка
1	Аналіз предметної області та постановка задачі дослідження	травень 2025 року	
2	Вибір методів дослідження, моделювання та проектування інформаційної технології	червень-липень 2025 року	
3	Розробка та тестування інформаційної системи	серпень-вересень 2025 року	
4	Аналіз результатів дослідження	жовтень 2025 року	
5	Оформлення розрахунково-пояснювальної записки до кваліфікаційної роботи, та її подання на попередній захист та рецензування	до 19 листопада 2025 року	
6	Перевірка кваліфікаційної роботи на унікальність	до 03 грудня 2025 року	
7	Подання закінченої кваліфікаційної роботи та документів до неї до деканату	до 08 грудня 2025 року	
8	Захист кваліфікаційної роботи	до 03 грудня 2025 року	

Керівник роботи

Ігор ШЕЛЕХОВ

Здобувач

Олександр МИХАЙЛЮК

АНОТАЦІЯ

Михайлюка Олександра Станіславовича, здобувача «Інформаційна технологія прогнозування результатів інтернет-маркетингової кампанії регіонального провайдера»

Кваліфікаційна робота на здобуття ступеня магістра з інформаційних систем і технологій за освітньою програмою «Інформаційні системи та технології» зі спеціальності 126 (F6) «Інформаційні системи і технології». Сумський національний аграрний університет, Суми, 2025.

У кваліфікаційній роботі Михайлюка Олександра Станіславовича досліджено теоретичні, методологічні та практичні аспекти розроблення інформаційної технології для оцінювання результатів інтернет-маркетингової кампанії регіонального телекомунікаційного провайдера. Розглянуто сучасні методи машинного навчання, особливу увагу приділено нейромережевим підходам, здатним забезпечувати класифікаційне прогнозування на високовимірних малих вибірках. Сформовано та навчено класифікаційні моделі на основі сучасних нейронних мереж, придатні для прогнозування реакції клієнтів на пропозицію переходу на нове покоління телекомунікаційних послуг. У роботі представлено програмну реалізацію інформаційно-аналітичної системи, що забезпечує автоматизоване оцінювання ефективності маркетингових кампаній, а також проведено її експериментальне тестування.

Результати демонструють можливість підвищення ефективності маркетингових активностей телекомунікаційних компаній шляхом використання інтелектуальних методів обробки даних і нейромережових моделей класифікаційного прогнозування. Розроблена інформаційна технологія може бути використана в аналітичних підсистемах регіональних провайдерів, системах підтримки прийняття рішень та маркетингових платформах.

Ключові слова: інтернет-маркетинг, інформаційна технологія, класифікаційне прогнозування, машинне навчання, нейронні мережі, телекомунікаційний провайдер, аналіз ефективності.

ABSTRACT

Mykhailyuk, Oleksandr Stanislavovych of the applicant «Information Technology for Forecasting Results of an Internet Marketing Campaign of a Regional Provider».

Qualification work for the degree of Master in Information Systems and Technologies under the educational program «Information Systems and Technologies» in the specialty 126 (F6) «Information Systems and Technologies». Sumy National Agrarian University, Sumy, 2025.

The qualification work of Mykhailyuk Oleksandr Stanislavovych investigates the theoretical, methodological, and practical aspects of developing an information technology for evaluating the results of an Internet marketing campaign conducted by a regional telecommunications provider. Modern machine learning methods are examined, with particular attention given to neural network approaches capable of performing classification-based prediction on high-dimensional small datasets. Classification models based on contemporary neural network architectures are developed and trained to forecast customer responses to the offer of transitioning to a new generation of telecommunication services. The work presents the software implementation of an information-analytical system that provides automated assessment of marketing campaign effectiveness, as well as the results of its experimental testing.

The results demonstrate the potential to improve the effectiveness of marketing activities of telecommunications companies through the use of intelligent data-processing methods and neural network classification models. The developed information technology can be applied in analytical subsystems of regional providers, decision support systems, and marketing platfor

Keywords: Internet marketing, information technology, classification forecasting, machine learning, neural networks, telecommunications provider, effectiveness analysis.

ЗМІСТ

ВСТУП.....	6
РОЗДІЛ 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ	11
1.1 Особливості телекомунікаційного ринку та специфіка послуг мобільних мереж нового покоління.....	11
1.2. Аналіз стану наукової розробки проблеми	13
1.3 Аналіз існуючих підходів до прогнозування ефективності інтернет- маркетингових кампаній у телекомунікаційній сфері	16
1.4 Огляд сучасних програмних засобів для розв'язання задачі класифікаційного прогнозування.....	18
1.5 Постановка задачі.....	19
РОЗДІЛ 2 ВИБІР МЕТОДІВ ДОСЛІДЖЕННЯ, МОДЕЛЮВАННЯ ТА ПРОЄКТУВАННЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ.....	21
2.1 Обґрунтування вибору методів математичного моделювання та формалізації задачі класифікаційного прогнозування.....	21
2.2 Методи статистичної підготовки та трансформації високовимірних даних .	23
2.3 Методи класифікаційного прогнозування високовимірних даних.....	25
2.4 Архітектура нейромережевих моделей для високовимірних малих вибірок	28
2.5 Підходи до оптимізації та оцінювання узагальнювальної здатності нейромережевих моделей.....	31
РОЗДІЛ 3 РОЗРОБКА ТА ТЕСТУВАННЯ ІНФОРМАЦІЙНОЇ СИСТЕМИ.....	35
3.1 Формування вхідного математичного опису системи	35
3.2 Програмна реалізація.....	52
3.3 Аналіз результатів.....	56
ВИСНОВКИ.....	60
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	61
ДОДАТКИ.....	65
ДОДАТОК А.....	66
ДОДАТОК Б	72
ДОДАТОК В	79
ДОДАТОК Г	85

ВСТУП

Актуальність теми.

У сучасних умовах цифрової трансформації суспільства телекомунікаційна галузь відіграє ключову роль у забезпеченні доступу до інформаційних ресурсів та інтеграції користувачів у глобальні цифрові екосистеми. Стрімкий розвиток мобільних мереж зв'язку нового покоління (4G/5G) зумовлює підвищення конкуренції між операторами та необхідність підсилення маркетингових стратегій, спрямованих на стимулювання споживачів до переходу на нові технології. Водночас ефективність інтернет-маркетингових кампаній у телекомунікаційному секторі безпосередньо залежить від здатності компанії прогнозувати поведінку клієнтів та вчасно пропонувати персоналізовані рішення.

Зростання обсягів зібраних телекомунікаційними операторами даних створює сприятливе підґрунтя для автоматизації аналітичних процесів. Однак традиційні статистичні підходи вже не забезпечують достатнього рівня точності за умов значної багатовимірності вхідних характеристик, змінності поведінкових факторів та необхідності виявлення прихованих взаємозв'язків у даних. Особливу складність становлять задачі, у яких поєднуються висока розмірність ознак та мала кількість реалізацій, що ускладнює побудову стійких моделей прогнозування без спеціальних методів регуляризації та зменшення розмірності.

Застосування сучасних методів штучного інтелекту, зокрема глибинних нейронних моделей, відкриває нові можливості для підвищення точності прогнозування реакції клієнтів на інтернет-рекламні кампанії та забезпечення більш ефективної підтримки маркетингових рішень телекомунікаційних компаній. Тому розробка інформаційної технології оцінювання результатів інтернет-маркетингової кампанії на основі сучасних нейромережових підходів до класифікаційного прогнозування є актуальною науковою і практичною задачею, що відповідає стратегічним тенденціям розвитку телекомунікаційної галузі та цифрового маркетингу.

Аналіз стану наукової розробки проблеми. Питання оцінювання ефективності маркетингових кампаній у телекомунікаційній сфері отримали значну увагу у світових та вітчизняних дослідженнях. Наукові праці зосереджені на аналізі поведінки споживачів, моделюванні їх переходів між тарифними планами, визначенні факторів лояльності та прогнозуванні відтоку клієнтів. Переважно використовуються статистичні та класичні алгоритмічні підходи: логістична регресія, дерева рішень, ансамблеві моделі (Random Forest, Gradient Boosting), метод опорних векторів тощо. Ці методи дозволяють формувати базові прогнози, проте за умов значної кількості взаємозалежних та слабо структурованих ознак їх ефективність знижується.

У роботах останніх років простежується тенденція застосування методів глибинного навчання, зокрема багат шарових перцептронів з регуляризацією, автоенкодерів для виділення латентних представлень даних, контрастивного навчання та гібридних ансамблевих архітектур. Вони демонструють підвищену точність і стійкість у задачах класифікації за умов високої розмірності ознак, але їх застосування до малих вибірок даних все ще залишається складною науковою проблемою через ризик перенавчання.

Крім того, у відкритих дослідженнях недостатньо представлено комплексних підходів до оцінювання ефективності маркетингових кампаній, які поєднують обробку даних, моделювання, інтерпретованість результатів та підтримку стратегічних рішень у єдиній інформаційній технології. Це формує наукову нішу для створення нових методів та інструментів, орієнтованих на потреби телекомунікаційних операторів і специфіку невеликих, але високовимірних маркетингових вибірок.

Мета і завдання дослідження. Мета роботи полягає у розробці інформаційної технології оцінювання результатів інтернет-маркетингової кампанії регіонального телекомунікаційного провайдера на основі сучасних нейромережових методів класифікаційного прогнозування реакції клієнтів на пропозицію переходу на нове покоління мобільних мереж.

Відповідно до поставленої мети сформульовані такі задачі:

- Провести системний аналіз предметної області та визначити фактори, що впливають на прийняття клієнтом маркетингової пропозиції.
- Дослідити сучасні методи машинного навчання та нейромережеві підходи, придатні для класифікації на високовимірних малих вибірках.
- Розробити процедури попередньої обробки даних, включаючи очищення, нормалізацію та зменшення розмірності ознак.
- Сформувати та навчити класифікаційні моделі на основі сучасних нейромереж.
- Програмно реалізувати інформаційно-аналітичну систему телекомунікаційного підприємства, що здатна до машинного навчання класифікаційному прогнозуванню.
- Провести оцінку працездатності розробленої системи на задачі класифікаційного прогнозування на високовимірних малих вибірках

Об'єктом дослідження є процес оцінювання результатів інтернет-маркетингової кампанії телекомунікаційної компанії за допомогою методів аналізу даних та прогнозування поведінки клієнтів..

Предметом дослідження є методи, моделі та засоби інформаційної технології класифікаційного прогнозування реакції клієнтів телекомунікаційної компанії на маркетингову пропозицію переходу між поколіннями мобільних мереж.

Методи досліджень методи математичного моделювання процесів прийняття рішень клієнтами та формалізації задач класифікаційного прогнозування; методи статистичного аналізу високовимірних даних; методи машинного навчання та глибинного навчання для побудови прогностичних моделей; методи зменшення розмірності та виділення латентних ознак; методи порівняльного аналізу ефективності алгоритмів класифікації; програмні технології моделювання, навчання та верифікації нейромережевих моделей.

Елементи наукової новизни є розроблено апропоновано науково обґрунтований підхід до класифікаційного прогнозування реакції клієнтів на основі нейромережевих моделей, адаптований до умов високої розмірності й

обмеженої кількості навчальних прикладів. Удосконалено процедуру формування компактного інформаційного простору шляхом комбінування автоенкодерів та статистичних методів селекції ознак, що забезпечує зниження ризику перенавчання. Розроблено комплексну інформаційну технологію оцінювання ефективності інтернет-маркетингової кампанії, що охоплює всі етапи – від підготовки даних до формування управлінських рекомендацій. Отримано нові експериментальні результати щодо застосування нейромережових моделей на малих вибірках даних телекомунікаційних компаній, які демонструють підвищення точності класифікації порівняно з традиційними алгоритмами машинного навчання..

Практична значимість одержаних результатів Результати дослідження мають практичну цінність для телекомунікаційних компаній і можуть бути використані у таких напрямках:

- автоматизація процесу оцінювання маркетингових кампаній та прогнозування реакції клієнтів на рекламні пропозиції;
- підвищення ефективності маркетингових заходів за рахунок персоналізації комунікації з клієнтами;
- оптимізація витрат на цифрову рекламу шляхом таргетування аудиторії з найбільшою ймовірністю позитивної реакції;
- підтримка прийняття управлінських рішень у сфері просування нових телекомунікаційних послуг;
- інтеграція розробленої технології у CRM- та аналітичні системи підприємства для підсилення функцій інтелектуального аналізу даних.

Апробація результатів кваліфікаційної роботи. Результати кваліфікаційної роботи апробовані на міжнародній науковій конференції молодих учених «Інформатика, математика, автоматика : 2025» (21–25 квітня 2025 року), (Суми – Астана) на тему:

- 1) «Класифікаційне прогнозування результатів телемаркетингової кампанії» та Всеукраїнської наукової конференції студентів і аспірантів, присвяченої Міжнародному дню студента (17-21 листопада 2025 року), (Суми) на тему

- 2) «Інтелектуальна система аналізу та прогнозування ефективності телемаркетингової компанії»

Публікації. За матеріалами кваліфікаційної роботи опубліковано 2 тези наукових конференцій [34-35].

Структура і обсяг роботи. Кваліфікаційна робота складається із вступу, трьох розділів, висновків, списку використаних джерел з 35 найменувань, додатків. Основний текст викладений на 87 сторінках комп'ютерного тексту, робота містить 6 рисунків, 2 таблиці, 4 додатки.

РОЗДІЛ 1

АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

1.1 Особливості телекомунікаційного ринку та специфіка послуг мобільних мереж нового покоління

Телекомунікаційний сектор у сучасних умовах цифровізації є одним із ключових драйверів соціально-економічного розвитку, забезпечуючи доступ до інформаційних ресурсів, електронних сервісів, хмарних технологій та інфраструктур Інтернету речей [1]. Стрімке зростання обсягів передавання даних, потреби у високих швидкостях доступу та надійності мережевої інфраструктури обумовлюють постійне вдосконалення архітектур мобільного зв'язку [2]. Перехід від одного покоління мобільних мереж до іншого супроводжується модернізацією обладнання, впровадженням нових радіотехнологій та зміною принципів обслуговування абонентів, що, у свою чергу, впливає на стратегії розвитку операторів та поведінку користувачів.

Телефонний зв'язок спочатку виконував суто комунікативні функції, проте з розвитком мобільного Інтернету та цифрових технологій мобільні мережі перетворилися на універсальну платформу для передавання мультимедійного контенту, використання цифрових сервісів, забезпечення бізнес-процесів і комунікації пристроїв у рамках IoT. Сучасний телекомунікаційний ринок характеризується зростаючою конкуренцією, високою швидкістю технологічних змін та значною залежністю компаній від ефективності маркетингових стратегій, спрямованих на залучення та утримання абонентів[3].

Особливу роль відіграє перехід між поколіннями мобільних мереж – від 3G до 4G і від 4G до 5G, який змінює якість послуг та вимоги користувачів. Технології 4G/LTE забезпечили значне збільшення швидкості передавання даних, що сприяло широкому впровадженню мобільного відеоконтенту, хмарних сервісів та онлайн-комунікацій [4-5]. Натомість технологія 5G передбачає ще більшу пропускну здатність, низькі затримки, підтримку масових підключень і можливість

використання нових застосунків – від автономного транспорту до промислового інтернету речей. Таким чином, перехід до нового покоління мереж не обмежується технічним оновленням інфраструктури, а має суттєве маркетингове, економічне й поведінкове значення.

Діяльність телекомунікаційних компаній у цьому контексті має враховувати кілька ключових аспектів [5]. По-перше, користувачі приймають рішення про перехід до нового покоління мереж на основі поєднання технічних характеристик (швидкість, затримка, стабільність), фінансових чинників (вартість тарифів, наявні бонуси та акції) та суб'єктивних переваг (комфорт використання, ставлення до бренду, досвід взаємодії з оператором). По-друге, оператори змушені здійснювати активні комунікаційні кампанії, спрямовані на стимулювання абонентів до переходу, оскільки масштабне розгортання нових мереж є капіталомістким і потребує відповідної комерційної віддачі. По-третє, збільшення різноманітності технологій та сервісів підсилює складність аналізу взаємодії клієнтів із цифровими каналами.

Формування споживчої поведінки на телекомунікаційному ринку відбувається під впливом таких тенденцій: зростання мобільності користувачів, всебічна діджиталізація комунікацій, широке використання соціальних мереж, орієнтація на персоналізований контент[6]. Сучасний абонент очікує швидких, зручних, адаптованих під індивідуальні потреби пропозицій, що створює необхідність формування персоналізованих маркетингових стратегій на основі аналізу великих масивів даних.

Інтернет-маркетинг [7-8] стає одним із ключових інструментів для телекомунікаційних операторів під час просування нових мережевих рішень. На відміну від традиційних методів, цифрові канали дозволяють оперативно збирати, аналізувати й інтерпретувати великі обсяги даних щодо поведінки та реакцій споживачів. Це забезпечує можливість застосування алгоритмів прогнозування та класифікації для визначення груп клієнтів, найбільш схильних до переходу на нові технології. У результаті оператор отримує можливість мінімізувати маркетингові витрати, збільшити конверсію та підвищити рівень задоволеності користувачів.

Важливою особливістю телекомунікаційного ринку є циклічність оновлення технологій. Кожне нове покоління мереж формує новий рівень очікувань щодо сервісу та стає маркером цифрової зрілості оператора [8]. Однак швидкість прийняття нових технологій абонентами є неоднорідною: одні клієнти переходять швидко, інші – відтягують оновлення, зберігаючи старі тарифи та режими споживання. Відповідно, сегментація аудиторії та прогнозування реакції клієнтів набувають критичного значення для керування маркетинговими кампаніями.

Інформаційні системи мобільних операторів містять детальні дані про поведінку користувачів: обсяги споживання трафіку, моделі комунікацій, активність у цифрових каналах, історію тарифних змін, соціально-демографічні характеристики [9]. Такі дані формують багатовимірні простори ознак, аналіз яких потребує застосування сучасних методів машинного навчання та штучного інтелекту. Особливої складності набувають задачі, де кількість характеристик значно перевищує кількість клієнтів, що є типовим явищем у маркетингових вибірках телекомунікаційного сектору [10]. У таких випадках класичні статистичні підходи не забезпечують належної точності, а використання нейромережових моделей дозволяє виявляти нелінійні залежності та приховані патерни [11].

Таким чином, розвиток телекомунікаційного ринку та впровадження мобільних мереж нового покоління супроводжуються зростанням потреби у високоточних прогностичних моделях, здатних адекватно описувати взаємозв'язок між характеристиками клієнтів та їх реакцією на маркетингові стимули. Це створює передумови для формування нових інформаційних технологій на основі штучного інтелекту, що підвищують ефективність управління рекламними кампаніями та сприяють оптимізації бізнес-процесів провайдера.

1.2. Аналіз стану наукової розробки проблеми

Оцінювання результативності інтернет-маркетингових кампаній у сфері телекомунікацій та прогнозування реакції споживачів на пропозиції щодо переходу між поколіннями мобільних мереж є напрямом, який протягом останнього

десятиліття привертає значну увагу дослідників у галузях цифрового маркетингу, аналітики даних та застосування штучного інтелекту в телекомунікаціях. Зростання ролі персоналізованих рекламних стратегій, розширення ринку мобільних послуг та інтенсифікація конкуренції між провайдерами стимулюють розвиток методів, здатних точно оцінювати поведінку клієнтів і забезпечувати високий ступінь передбачуваності результатів маркетингових впливів.

У зарубіжних дослідженнях [9-11] значну увагу приділено побудові моделей реакції абонентів на пропозиції операторів зв'язку. Представлені роботи, що аналізують поведінкові та демографічні чинники, що впливають на сприйняття оновлених тарифних планів, сервісів та технологій зв'язку, зокрема переходу на мережі LTE, 5G і підготовку до 6G-сервісів. Типові підходи базуються на методах машинного навчання, таких як логістична регресія, дерева рішень, ансамблеві моделі (Random Forest, Gradient Boosting), штучні нейронні мережі та методи обробки великих масивів поведінкових даних. У працях з маркетингової аналітики також підкреслюється зростання ролі моделей прогнозування, що враховують багатовимірні профілі клієнтів, включно з історією користування послугами, активністю в мережі, соціально-демографічними параметрами та рівнем задоволеності обслуговуванням.

У сучасних наукових публікаціях [12-15] дедалі більше уваги приділяється питанням підвищення точності прогнозу через використання глибоких нейронних архітектур, здатних моделювати нелінійні залежності між численними ознаками клієнтів. До таких архітектур належать багатошарові персептрони, рекурентні мережі, мережі з механізмами уваги та трансформери, які показали ефективність у задачах класифікаційного прогнозування в умовах високої розмірності ознак та відносно обмежених вибірок. Окремий напрям досліджень спрямовано на використання методів балансування даних і боротьби з перекосом класів, що є характерним для маркетингових задач, у яких кількість позитивних реакцій на кампанію часто менша за негативні. У таких роботах [12, 14, 15] застосовуються алгоритми SMOTE, ADASYN, кластеризоване ресемплювання та генеративні моделі, зокрема GAN-архітектури для синтезу даних.

Український науковий простір також представлений працями, присвяченими оцінюванню ефективності рекламних кампаній у цифровому середовищі, прогнозуванню поведінки споживачів та впровадженню інтелектуальних систем підтримки прийняття рішень у телекомунікаційній галузі. Значна частина досліджень орієнтується на аналіз поведінки абонентів мобільного зв'язку та визначення чинників, що впливають на відтік клієнтів, прихильність до бренду, реакцію на зміни тарифів і технологічні оновлення. У наукових працях[16-20] акцентується увага на розробці математичних моделей та інформаційних технологій, які враховують специфіку вітчизняного телекомунікаційного ринку, зокрема різну платоспроможність абонентів, неоднорідну якість покриття мереж та нерівномірний рівень розвитку інфраструктури в регіонах.

В останні роки активно публікуються роботи, присвячені застосуванню нейронних мереж та гібридних методів у задачах прийняття рішень щодо таргетування рекламних пропозицій [20-21]. Встановлено, що використання моделей глибокого навчання дозволяє значно підвищити точність прогнозування реакції клієнтів порівняно з класичними статистичними підходами, особливо у випадках, коли словник ознак є великорозмірним і містить різномірні типи даних. Наукова література також демонструє інтерес до інтерпретованості моделей, оскільки розуміння ключових факторів, що впливають на рішення клієнта, має важливе значення для бізнес-аналітики. У цьому контексті активно використовують SHAP-аналіз, LIME та інші методи пояснюваного машинного навчання[23].

Варто також підкреслити розвиток концепції інтелектуальних маркетингових платформ, що включають модулі збору, обробки, збереження та аналітичної обробки даних клієнтів у режимі реального часу. Такі системи інтегруються з CRM-платформами, системами білінгу та сервісами цифрової реклами. У наукових працях розглядаються питання автоматизації процесів прийняття рішень щодо побудови персоналізованих пропозицій, вибору каналів комунікації та оптимізації маркетингового бюджету.

Попри значну кількість наукових праць, низка аспектів проблематики залишається недостатньо дослідженою. Зокрема, актуальною є проблема побудови моделей прогнозування при відносній обмеженості навчальної вибірки, що характерно для регіональних провайдерів, які не завжди мають великі масиви історичних даних. Крім того, специфіка перехідних технологій у телекомунікаціях (наприклад, перехід від 3G до 4G або від 4G до 5G) формує динамічні процеси зміни поведінки абонентів, які потребують створення адаптивних моделей, здатних реагувати на зміни у маркетинговому середовищі. Важливою науковою задачею залишається також розробка методів оптимального відбору інформативних ознак із великорозмірних наборів даних, що дозволяє підвищити якість моделі та знизити її обчислювальні витрати.

Таким чином, аналіз стану наукової розробки проблеми свідчить про наявність достатньої теоретичної та методологічної бази для побудови моделей прогнозування реакції клієнтів на інтернет-маркетингові кампанії телекомунікаційних операторів. Водночас значна частина існуючих досліджень зосереджена на великих телекомунікаційних компаніях, тоді як питання адаптації сучасних методів машинного навчання та нейронних мереж до потреб регіонального провайдера залишається недостатньо висвітленим. Це формує актуальність проведення комплексного дослідження та розробки спеціалізованої інформаційної технології, яка враховуватиме особливості структури даних, обмеженість вибірки та специфіку поведінкових характеристик клієнтів у регіональному контексті.

1.3 Аналіз існуючих підходів до прогнозування ефективності інтернет-маркетингових кампаній у телекомунікаційній сфері

У сучасній науковій та прикладній літературі представлено широке коло методів, орієнтованих на оцінювання результативності цифрових маркетингових впливів і передбачення реакції споживачів на персоналізовані пропозиції операторів зв'язку. Переважна більшість таких підходів базується на концепціях

прогнознаї аналітики, статистичного моделювання, машинного навчання та використання різних форм поведінкового профілювання клієнтів[24].

Традиційно у телекомунікаційній галузі застосовуються статистичні моделі, серед яких найпоширенішими є логістична регресія, дискримінантний аналіз та моделі з обмеженою кількістю параметрів[25-26]. Їхня перевага полягає у високій інтерпретованості та невеликих вимогах до обсягів даних. Однак вони часто не здатні адекватно описати складні нелінійні взаємозв'язки між численними характеристиками клієнтів, що є типовим для задач із великим словником ознак.

Подальший розвиток отримали алгоритми машинного навчання, які продемонстрували кращу адаптивність до гетерогенних, багатовимірних та частково незбалансованих даних. Серед них особливо виділяють дерева рішень, випадкові ліси, методи ансамблювання, градієнтний бустинг на деревоподібних структурах та SVM-класифікатори[27]. Зазначені методи широко використовуються у проєктах з визначення факторів відтоку абонентів, оцінювання реакції на SMS-, e-mail- та інтернет-кампанії, а також для сегментації клієнтів за поведінковими патернами.

Сучасний етап розвитку характеризується активним упровадженням інтелектуальних моделей на основі глибинного навчання[24]. Багатошарові перцептрони та рекурентні мережі використовуються для обробки великої кількості ознак, включно з тимчасовими, текстовими та поведінковими даними. Мережі з механізмами уваги та трансформерні архітектури демонструють здатність формувати високоточні прогнози навіть у задачах з обмеженими вибірками, завдяки механізмам узагальнення та виявлення прихованих структур у даних.

Окремо слід відзначити використання методів пояснюваного штучного інтелекту, що дозволяють інтерпретувати вплив кожної ознаки на підсумковий прогноз та забезпечити прозорість моделей у бізнес-середовищі[28]. Інтерес до ХАІ-підходів (Explainable AI) у телекомунікаціях зумовлений необхідністю формувати зрозумілі маркетингові рекомендації та обґрунтування для управлінських рішень.

Попри значний прогрес, актуальною залишається проблема застосування сучасних методів у випадках, коли навчальна вибірка є відносно невеликою, як у регіональних провайдерів. Наявна наукова література лише частково представляє адаптовані під такі умови гібридні моделі, що поєднують глибинне навчання, методи регуляризації та інтелектуальний відбір ознак. Саме ця прогалина визначає необхідність подальших досліджень.

1.4 Огляд сучасних програмних засобів для розв'язання задачі класифікаційного прогнозування

Серед найбільш усталених засобів класифікаційного прогнозування особливе місце посідає Scikit-learn, який є стандартом де-факто для реалізації класичних алгоритмів машинного навчання [29]. Його ключовою перевагою є висока стабільність реалізацій, уніфікований інтерфейс роботи з моделями, наявність широкої палітри методів класифікації та зручність інтеграції з іншими Python-інструментами. Недоліками вважаються обмежені можливості роботи з великими обсягами даних, слабша підтримка глибинних моделей і відсутність вбудованих механізмів масштабування на розподілені обчислювальні середовища.

Важливою платформою для задач прогнозування є TensorFlow [29], орієнтований на побудову нейронних мереж будь-якої складності. Його сильними сторонами виступають здатність ефективно працювати на графічних прискорювачах, можливість реалізації складних архітектур глибинного навчання та підтримка розподілених обчислень. Разом з тим TensorFlow має порівняно високий поріг входження, вимагає більш детального налаштування гіперпараметрів і часто потребує значних ресурсів для навчання моделей, що ускладнює його застосування в умовах обмеженої інфраструктури.

Близьким за призначенням є PyTorch [30], який завдяки динамічному обчислювальному графу здобув популярність серед дослідників, що потребують гнучкості й інтуїтивності побудови моделей. Його головними перевагами є зручність експериментування, прозорість у налагодженні моделей та активна

спільнота науковців. Проте деякі академічні реалізації [31] все ще потребують додаткової оптимізації у виробничих середовищах, а інструментарій розгортання PyTorch-моделей інколи поступається за зручністю екосистемі TensorFlow.

Суттєвий вплив на розвиток прикладного прогнозування справила бібліотека XGBoost [32], що спеціалізується на алгоритмах градієнтного бустингу. Її беззаперечними плюсами є виняткова продуктивність, висока точність моделей, удосконалені механізми регуляризації та здатність ефективно працювати з великими табличними наборами даних. Водночас XGBoost досить чутливий до підбору гіперпараметрів, потребує детального налаштування та може поступатися нейронним мережам у задачах із високою нерегулярністю або складними нелінійними залежностями.

До сучасних популярних платформ також належить LightGBM [33], який забезпечує високу швидкість обробки й навчання завдяки оптимізованим методам сегментації ознак та ефективному використанню пам'яті. Його перевагами вважаються здатність працювати з великими масивами даних, точність результатів і добра узгодженість із вимогами промислових систем. Попри це LightGBM може демонструвати знижену стабільність на невеликих вибірках або наборах даних із несприятливими розподілами, а також потребує ретельного контролю параметрів, що визначають глибину дерев та складність моделі.

1.5 Постановка задачі

За результатами проведеного аналітичного огляду можна зробити висновок про актуальність і перспективність розробки та впровадження інтелектуальних складових в інформаційне, алгоритмічне і програмне забезпечення інформаційно-аналітичних систем телекомунікаційних компаній. Тому метою кваліфікаційної роботи є розробка інформаційної технології оцінювання результатів інтернет-маркетингової кампанії регіонального телекомунікаційного провайдера на основі сучасних нейромережових методів класифікаційного прогнозування реакції клієнтів на пропозицію переходу на нове покоління мобільних мереж..

Відповідно до поставленої мети сформульовані такі задачі:

- 1) Провести системний аналіз предметної області та визначити фактори, що впливають на прийняття клієнтом маркетингової пропозиції.
- 2) Дослідити сучасні методи машинного навчання та нейромереві підходи, придатні для класифікації на високовимірних малих вибірках.
- 3) Розробити процедури попередньої обробки даних, включаючи очищення, нормалізацію та зменшення розмірності ознак.
- 4) Сформувати та навчити класифікаційні моделі на основі сучасних нейромерев.
- 5) Програмно реалізувати інформаційно-аналітичну систему телекомунікаційного підприємства, що здатна до машинного навчання класифікаційному прогнозуванню.
- 6) Провести оцінку працездатності розробленої системи на задачі класифікаційного прогнозування на високовимірних малих вибірках.

РОЗДІЛ 2

ВИБІР МЕТОДІВ ДОСЛІДЖЕННЯ, МОДЕЛЮВАННЯ ТА ПРОЄКТУВАННЯ ІНФОРМАЦІЙНОЇ ТЕХНОЛОГІЇ

2.1 Обґрунтування вибору методів математичного моделювання та формалізації задачі класифікаційного прогнозування

Задача класифікаційного прогнозування ефективності рекламної кампанії регіонального телекомунікаційного провайдера формально може бути визначена як проблема бінарної класифікації. Нехай $X \in R^{n \times m}$ - матриця ознак клієнтів, де n - кількість реалізацій, а m кількість характеристик, що описують поведінку та профіль користувачів. Класова мітка $y_i \in \{0, 1\}$ визначає реакцію клієнта на рекламну акцію, де 0 відповідає відмові від рекламної пропозиції, а 1 – прийняттю пропозиції. Математично задача класифікації формулюється як знаходження функції $f : R^m \rightarrow \{0, 1\}$, яка відображає вхідні ознаки клієнта у прогноз класу з максимально можливою точністю. Для оптимізації такої функції обираються функції втрат, що дозволяють мінімізувати невідповідність між прогнозом та фактичними даними. У контексті бінарної класифікації доцільно використовувати бінарну крос-ентропію як основну функцію втрат:

$$L(y, \hat{y}) = -\frac{1}{n} \sum_{i=1}^n (y_i \cdot \log(\hat{y}) + (1 - y_i) \cdot \log(1 - \hat{y})),$$

де $\hat{y}$ – ймовірність приналежності до позитивного класу, передбачена моделлю. Використання крос-ентропії дозволяє ефективно навчати нейромережеві моделі навіть на високовимірних даних і забезпечує збіжність градієнтного спуску.

Критерії точності прогнозу повинні враховувати не лише відсоток правильно класифікованих реалізацій (Accuracy), а й інші метрики, що оцінюють баланс між класами, зокрема точність для позитивного класу (Precision), повнота для позитивного класу (Recall) та гармонійне середнє Precision та Recall (F1-score).

Формально ці метрики визначаються через числа істинно позитивних (TP), істинно негативних (TN), хибно позитивних (FP) та хибно негативних (FN) прогнозів:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.1)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.3)$$

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} = 2 \cdot \frac{\frac{TP}{TP + FP} \cdot \frac{TP}{TP + FN}}{\frac{TP}{TP + FP} + \frac{TP}{TP + FN}} = \frac{2 \cdot TP}{2 \cdot TP + FP + FN} \quad (2.4)$$

Ці метрики дозволяють всебічно оцінювати продуктивність моделей, особливо в умовах балансування класів, що важливо для маркетингових кампаній, де економічні наслідки реакцій клієнтів різного типу можуть бути суттєво різними.

Формалізація задачі класифікаційного прогнозування в термінах математичного моделювання передбачає також побудову моделей з урахуванням малих вибірок та високої розмірності ознак. Це зумовлює необхідність застосування регуляризаційних методів, які запобігають перенавчанню та дозволяють виявити латентні закономірності у даних клієнтів.

Для збалансованих класів, коли кількість позитивних і негативних реалізацій однакова ($n_+ = n_- = n$) і

$$FN = n - TP, FP = n - TN,$$

$$\text{Accuracy} = \frac{TP + TN}{2n},$$

$$\text{Precision} = \frac{TP}{TP + n - TN},$$

$$\text{Recall} = \frac{TP}{n},$$

$$F1 = \frac{TP}{TP + n - TN} = \text{Precision}.$$

Таким чином, обраний підхід до математичної формалізації та моделювання задачі класифікаційного прогнозування є обґрунтованим з позицій теорії машинного навчання та практичного застосування для оцінки ефективності рекламних акцій у телекомунікаційній сфері.

2.2 Методи статистичної підготовки та трансформації високовимірних даних

Високовимірні дані у вигляді матриць ознак потребують підготовки для якісного класифікаційного прогнозування. Статистичні методи підготовки та трансформації дозволяють нормалізувати шкали, зменшити вимірність та відібрати найбільш значущі ознаки, що підвищує стабільність моделей та зменшує ризик мультиколінеарності.

2.2.1 Нормалізація та стандартизація ознак

Матриці високовимірних даних зазвичай містять ознаки з різними одиницями виміру та діапазонами значень. Для забезпечення їх порівнянності та уникнення домінування одних змінних над іншими застосовуються методи нормалізації та стандартизації. Нормалізація (мінімакс або масштабування до $[0,1]$) приводить всі значення до єдиного інтервалу,

$$x_i^{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}},$$

де x_{max} , x_{min} – мінімальне та максимальне значення i -тої ознаки.

Тоді як стандартизація перетворює ознаки на випадкові величини з нульовим середнім та одиничною дисперсією.

$$x_i^{std} = \frac{x_i - \bar{x}}{\sigma_x}$$

де $\bar{x}$ – середнє значення i -тої ознаки, σ_x – її стандартне відхилення.

Ці трансформації є критично важливими перед побудовою моделей класифікаційного прогнозування, особливо для алгоритмів, чутливих до масштабу ознак, таких як методи опорних векторів чи кластери на основі відстаней.

2.2.2 Зменшення вимірності

Застосування методів зменшення вимірності, таких як головні компоненти (РСА) або факторний аналіз, дозволяє скоротити кількість ознак при збереженні максимальної дисперсії даних. У високовимірних матрицях це особливо важливо для зменшення обчислювальної складності та уникнення перенавчання моделей. РСА перетворює корельовані змінні $X \in R^{n \times m}$ на набір некорельованих $Z \in R^{n \times k}$ ($k < m$) головних компонент, що відображають основну структуру даних.

$$Z = XW,$$

де $W \in R^{m \times k}$ – матриця власних векторів коваріаційної матриці $\frac{1}{n-1} X^T X$. Головні компоненти впорядковуються за спаданням власних значень $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$, які показують внесок кожної компоненти у загальну дисперсію даних.

Такий підхід дозволяє виділити найбільш значущі напрямки варіації та підвищити ефективність класифікаційного прогнозування.

2.2.3 Відбір ознак та обробка кореляційних зв'язків

Високовимірні матриці часто містять ознаки, що мають сильну кореляцію або низьку інформативність для цільової змінної. Відбір ознак полягає у виділенні найбільш значущих змінних та виключенні тих, що несуть надлишкову або шумову

інформацію. Методи відбору включають аналіз кореляційних матриць $R = [r_{ij}]$ для ознак x_i, x_j , що визначається як:

$$r_{ij} = \frac{\text{cov}(x_i, x_j)}{\sigma_{x_i} \sigma_{x_j}}$$

де $\text{cov}(x_i, x_j)$ – коваріація між ознаками, $\sigma_{x_i}, \sigma_{x_j}$ – стандартні відхилення, використання критеріїв інформаційної значущості та регресійних підходів. Це забезпечує скорочення шуму, підвищення стабільності моделей і точності прогнозів, що особливо важливо для високовимірних даних, де надмірна кількість ознак може призводити до спотворення результатів класифікації.

2.3 Методи класифікаційного прогнозування високовимірних даних

Після етапу статистичної підготовки та трансформації високовимірних даних наступним логічним кроком є їхнє використання для побудови класифікаційних моделей. Високовимірні дані характеризуються наявністю великої кількості ознак, що може призводити до проблеми «прокляття вимірності», коли збільшення числа ознак негативно впливає на точність прогнозів і стабільність моделей. Тому вибір методів класифікаційного прогнозування та попередня обробка даних є критично важливими для отримання надійних результатів.

У сучасній практиці високовимірні дані часто обробляються з використанням методів зниження розмірності (наприклад, PCA, LDA), після чого застосовуються різні алгоритми класифікації, включаючи як класичні статистичні методи, так і сучасні машинно-навчальні алгоритми.

2.3.1 Лінійний дискримінантний аналіз (LDA)

Лінійний дискримінантний аналіз є одним із базових методів класифікації, що застосовується для двох або більше класів. Основна ідея полягає у знаходженні такої лінійної комбінації ознак, яка максимально розділяє класи за рахунок

збільшення міжкласової дисперсії та зменшення внутрішньокласової дисперсії. Для обчислення напрямку w використовують матрицю внутрішньокласової коваріації Σ_w та середні вектори класів μ_1, μ_2 :

$$w = \Sigma_w^{-1}(\mu_1 - \mu_2).$$

Лінійне рішення дискримінує класи за правилом:

$$y = w^T x + b,$$

$$class = \begin{cases} 0, & \text{if } y \leq 0, \\ 1, & \text{if } y > 0. \end{cases}$$

LDA добре працює при наявності лінійно роздільних класів і може слугувати ефективним інструментом попередньої обробки для зменшення розмірності високовимірних даних перед застосуванням більш складних методів.

2.3.2 Логістична регресія

Логістична регресія є класичним статистичним методом для прогнозування ймовірності належності об'єкта до певного класу. Для бінарної класифікації ймовірність визначається сигмоїдною функцією:

$$P(y = 1|x) = \frac{1}{1 + e^{-(\beta_0 + \beta^T x)}},$$

де β_0 – зсув моделі, β – вектор коефіцієнтів ознак. Основною перевагою логістичної регресії є її інтерпретованість: значення коефіцієнтів прямо вказують на вплив кожної ознаки на ймовірність належності до класу. У високовимірних даних для зменшення ризику переобучення часто застосовують регуляризацію, наприклад $L1$ (Lasso) або $L2$ (Ridge):

$$\min_{\beta} \left\{ - \sum_{i=1}^n [y_i \log(P(y_i|x_i)) + (1 - y_i) \log(1 - P(y_i|x_i))] + \lambda \|\beta\|_p \right\}, p = 1, 2.$$

Регуляризація дозволяє одночасно відфільтрувати нерелевантні ознаки та покращити узагальнюючу здатність моделі.

2.3.3 Метод опорних векторів (SVM)

Метод опорних векторів є потужним інструментом для класифікації, особливо у випадках високовимірних даних. SVM шукає гіперплощину, яка максимально відокремлює класи, забезпечуючи найбільший margin між найближчими точками різних класів:

$$\min_{w,b} \frac{1}{2} \|w\|^2, \text{ pза умови } y_i(w^T x_i + b) \geq 1.$$

Для нелінійних розділень застосовуються ядрові функції $K(x_i, x_j)$, що дозволяють відображати дані в простір вищої розмірності, де класи можуть бути розділені лінійно. Популярні ядрові функції включають поліноміальні, RBF (Gaussian) та сигмоїдні. SVM демонструє високу ефективність для високовимірних даних, оскільки алгоритм оптимізує лише опорні вектори, а не всі дані.

2.3.4 Багатовимірні дерева рішень та ансамблі

Дерева рішень є інтуїтивно зрозумілим методом класифікації, що розбиває простір ознак на частини за рекурсивним критерієм максимізації інформаційного приросту або зменшення дисперсії. Для підвищення стабільності та точності використовуються ансамблі дерев, такі як Random Forest або Gradient Boosting, які комбінують прогнози багатьох слабких моделей:

$$\hat{y} = mode(h_1(x), h_2(x), \dots, h_M(x)).$$

Ансамблі дозволяють зменшити ризик переобучення, типового для окремих дерев, та забезпечують більш надійні прогнози на високовимірних даних із великою кількістю ознак.

2.3.5 Метрики оцінки класифікаційних моделей

Для кількісної оцінки ефективності класифікаційних моделей використовуються різні метрики: точність (Accuracy) (2.1), точність класифікації (Precision) (2.2), повнота (Recall) (2.3) та F1-міра (2.4). Високовимірні дані часто супроводжуються незбалансованими класами, тому застосування декількох метрик одночасно дозволяє об'єктивніше оцінити якість моделі. Крім того, для оцінки моделей на високовимірних даних часто використовують криву ROC та площу під кривою AUC, що дозволяє оцінити баланс між чутливістю та специфічністю прогнозу.

Таким чином, описані методи класифікаційного прогнозування дозволяють ефективно працювати з високовимірними даними, забезпечуючи високу точність прогнозів та інтерпретованість результатів. Комбінування статистичних підходів (LDA, логістична регресія) та сучасних алгоритмів машинного навчання (SVM, ансамблі дерев) створює потужний інструментарій для вирішення завдань класифікації у різних практичних застосуваннях.

2.4 Архітектура нейромережових моделей для високовимірних малих вибірок

Побудова нейромережових моделей для задач класифікаційного прогнозування на високовимірних вибірках із малою кількістю реалізацій потребує спеціальних підходів до структуризації архітектури мережі. У випадку, коли кількість ознак суттєво перевищує кількість доступних спостережень (situation $p \gg n$), виникає низка складнощів: зростає ризик перенавчання, збільшується чутливість моделі до шуму та випадкових флуктуацій даних, зменшується здатність мережі до узагальнення, а параметри моделі стають погано

ідентифікованими. Для мінімізації цих явищ застосовуються спеціалізовані архітектури та регуляризаційні стратегії, що об'єднують принципи статистичного моделювання, байєсівських оцінок, скорочення розмірності та сучасних технологій глибокого навчання.

У задачах з числовими ознаками базовою архітектурою є багатошаровий перцептрон (MLP). Проте його класичне застосування є неефективним у ситуації $p \gg n$, оскільки кількість параметрів навіть одного прихованого шару швидко перевищує кількість навчальних прикладів. Наприклад, звичайний шар на 128 нейронів при 241 входах має $241 \times 128 + 128 = 31016$ параметрів, що в сотні разів перевищує обсяг навчальної вибірки. Така диспропорція гарантовано призводить до перенавчання.

Тому архітектура MLP адаптується наступними принципами:

1. Вузькі шари: приховані шари містять значно менше нейронів, інколи лише 16–32, що суттєво обмежує кількість параметрів.
2. Глибина замість ширини: декілька компактних шарів ефективніше, ніж один великий, оскільки дозволяють послідовно формувати узагальнені ознаки:

$$x^{(l+1)} = f(W^{(l)}x^{(l)} + b^{(l)}).$$

3. Стиснення інформації: перший шар виконує роль «проектора», що переводить 241-вимірний простір у компактне латентне представлення, наприклад у 32–64 вимірності.

4. Активатори з властивістю sparsity: функції ReLU, LeakyReLU або ELU сприяють формуванню розріджених внутрішніх представлень, що є корисним при високій вимірності даних.

5. Типова архітектура MLP для таких умов може мати вигляд:

$$241 \rightarrow 64 \rightarrow 32 \rightarrow 2,$$

де останній шар відповідає двокласовій класифікації через софтмакс-активацію:

$$P(y = k|x) = \frac{e^{z_k}}{\sum_{j=1}^2 e^{z_j}}.$$

Для задачі, де кількість ознак значна, а вибірка мала, ефективним рішенням є застосування автоенкодера – симетричної нейромережевої моделі, яка стискає дані у латентний простір малої розмірності. Автоенкодер складається з енкодера, що виконує перетворення:

$$h = f_{enc}(x),$$

та декодера:

$$\hat{x} = f_{dec}(h),$$

де h – латентний вектор. У контексті класифікаційної задачі декодер можна замінити класифікатором:

$$y = g(h),$$

тоді мережа стає класифікаційним автоенкодером, який одночасно: зменшує вимірність, виділяє суттєві ознаки, здійснює прогноз.

У практиці для малих вибірок латентний простір обмежують дуже малою розмірністю – 8, 16 або максимум 32 компоненти. Це сприяє більшій узагальнюваності та зменшенню перенавчання.

Для стабілізації навчання та мінімізації переобучення використовуються кілька видів регуляризації:

- 1) Метод Dropout випадково «вимикає» частину нейронів під час навчання:

$$h'_i = \begin{cases} 0, & \text{з ймовірністю } p, \\ h_i, & \text{з ймовірністю } 1 - p. \end{cases}$$

При цьому модель не може покладатися на жодну конкретну ознаку або нейрон, що підвищує стійкість до шуму.

2) L1/L2-регуляризація, в рамках якої до цільової функції додається штраф:

$$L = L_{cls} + \lambda \|W\|_p$$

де $p = 1$ (сприятиме розрідженню ваг) або $p = 2$ (призводить до згладжених рішень). L1-регуляризація особливо корисна для високовимірних даних, оскільки фактично реалізує відбір ознак.

3) Early stopping – модель зупиняють тоді, коли помилка на валідаційній вибірці перестає зменшуватись:

$$L_{val}(t+1) > L_{val}(t) \rightarrow \text{зупинити навчання.}$$

Це один із найбільш дієвих методів у ситуації малої вибірки.

2.5 Підходи до оптимізації та оцінювання узагальнювальної здатності нейромережових моделей

Оцінювання узагальнювальної здатності нейромережових моделей у задачах класифікаційного прогнозування з високовимірними даними та малою кількістю реалізацій є ключовим аспектом забезпечення надійності отриманих рішень. У ситуації, коли кількість параметрів моделі потенційно на кілька порядків перевищує обсяг навчальної вибірки, зростає ризик формування моделей, які демонструють високу точність на тренувальних даних, але не здатні коректно працювати на нових, раніше невідомих реалізаціях. Тому розробка механізмів

оптимізації, перехресної перевірки, регуляризації та стабільної оцінки якості моделі є обов'язковою складовою.

Процес оптимізації нейромережі включає вибір таких гіперпараметрів, як кількість шарів, кількість нейронів у них, типи функцій активації, коефіцієнти регуляризації, швидкість навчання та параметри оптимізатора. З огляду на особливості малих вибірок, підхід до оптимізації повинен бути обережним: надмірний пошук гіперпараметрів призводить до "over-tuning" моделі до конкретної підвибірки, замість істинного покращення узагальнення.

Для стабілізації процесу використовують:

- Байєсівську оптимізацію гіперпараметрів, яка мінімізує кількість необхідних оцінок моделі та зменшує ризик перенавчання під час підбору параметрів.
- Grid-search у вузьких інтервалах, коли діапазони параметрів визначені на основі попереднього експертного аналізу.
- Random-search як менш схильний до локального перенавчання метод, у порівнянні з повним перебором.

При оптимізації архітектури доцільним є застосування принципу мінімальної достатності: модель повинна бути якомога меншою за кількістю параметрів, але достатньо виразною, щоб відтворювати приховані закономірності у високовимірному просторі. На практиці це означає перевагу надають вузьким мережам із обмеженим латентним простором та застосуванням Dropout і L2-регуляризації.

У випадку малої кількості доступних реалізацій класичний поділ на тренувальну та тестову вибірки може бути нестійким: зміна кількох реалізацій здатна кардинально змінити оцінку якості. Тому застосовуються більш надійні схеми перевірки, такі як:

- k -fold перехресна перевірка, де матриця реалізацій ділиться на k приблизно рівних частин, і кожна частина по черзі використовується як тестова. Це дозволяє оцінити середні значення критеріїв:

$$Accuracy = \frac{1}{k} \sum_{i=1}^k Accuracy^{(i)},$$

$$F1 = \frac{1}{k} \sum_{i=1}^k F1^{(i)}.$$

- Stratified k-fold, який обов'язковий для збалансованих або майже збалансованих класів, адже забезпечує пропорційне представлення обох класів у кожній вибірці.

- Repeated k-fold, коли процес k-fold повторюють кілька разів із випадковим змішуванням даних; це підвищує статистичну надійність оцінок.

Стабільність моделі додатково оцінюється через дисперсію критеріїв:

$$D(F1) = \frac{1}{k-1} \sum_{i=1}^k (F1^{(i)} - \overline{F1})^2.$$

що дозволяє визначити, чи модель чутлива до конкретної частини навчальних даних.

Для нейромереж, що працюють у просторі $p \gg n$, застосовуються спеціальні техніки, спрямовані на зменшення варіації та підвищення стійкості до переорієнтації на окремі особливості вибірки:

- Регуляризація Dropout – зменшує кореляцію між нейронами та розширює простір рішень, знижуючи ризик локальних мінімумів.

- L1/L2-регуляризація – дозволяє зменшити ваги мережі, усунути надмірну залежність від несуттєвих ознак, а у випадку L1 – фактично скорочує кількість активних ознак.

- Batch Normalization – зменшує внутрішнє зміщення коваріацій і прискорює збіжність.

- Data augmentation для табличних даних, включно з:

- генерацією синтетичних спостережень (SMOTE, ADASYN),

- введенням невеликих випадкових шумів у вектор ознак,
- варіацією значень у межах стандартної похибки.
- Ensemble-методи, де кілька компактних моделей поєднуються для формування стабільнішого рішення. Підсумкове рішення може бути отримано через середнє значення логітів:

$$p(y = 1) = \frac{1}{M} \sum_{j=1}^M p_j(y = 1).$$

Попри високу вимірність даних, інтерпретація моделі залишається важливою частиною оцінки її надійності. Для цього застосовуються:

- SHAP-значення, що дозволяють оцінити внесок кожної ознаки у вихідне рішення моделі:

$$\hat{y} = \phi_0 + \sum_{i=1}^p \phi_i$$

де ϕ_i – внесок ознаки i .

- Permutation importance, що визначає зниження точності після перестановки значень окремої ознаки.
- Аналіз латентного простору, який дозволяє оцінити, чи правильно автоенкодер виділив низьковимірні патерни.

Інтерпретаційні методи також дозволяють визначити, чи не базується модель на випадкових або артефактних закономірностях у даних.

РОЗДІЛ 3

РОЗРОБКА ТА ТЕСТУВАННЯ ІНФОРМАЦІЙНОЇ СИСТЕМИ

3.1 Формування вхідного математичного опису системи

Формування вхідного математичного опису для інтелектуальної системи класифікаційного прогнозування здійснювалося на основі реальних даних, опублікованих у репозитарії Machine Learning Repository Національної ключової лабораторії нових програмних технологій та кафедри комп'ютерних наук Університету Нанджина (Китай). (http://lamda.nju.edu.cn/yuy/dm07/assign_2.htm).




Рисунок 3.1 - Репозитарій даних Нанджунського Університету (Китай)

Дані представляють собою масив характеристик абонентів телекомунікаційної компанії, зібраних під час проведення маркетингової кампанії із переходу клієнтів на телекомунікаційну мережу нового покоління. Навчальна вибірка містить 96 реалізацій, 48 з яких відповідають позитивній реакції клієнта на пропозицію компанії, а 48 – відмові. Словник ознак складається із 241 характеристики, які відображають широкий спектр параметрів клієнтів та їх телекомунікаційної активності.

Перший блок ознак описує соціально-демографічні властивості абонента, включаючи вік, стать, сімейний стан, національність та професійний код. До цієї групи належать характеристики, які визначають статус клієнта у програмі лояльності, наявність кобрендової банківської карти, клас клієнта та тривалість користування послугами оператора. Ці показники дозволяють оцінити моделі поведінки та довгострокову взаємодію користувача з компанією.

Другий блок об'єднує тарифні та контрактні характеристики, що включають чинний тарифний план, попередній план, факт його зміни, наявність контракту, кількість днів до завершення контракту, а також різні параметри, пов'язані з кількістю телефонних ліній, активних, призупинених чи таких, що мають заборгованість. У цю ж групу входять способи оплати, їх зміни, параметри мобільного пристрою клієнта (вік апарата, виробник, модель), а також спеціальні позначки, які можуть вказувати на участь у програмах утримання клієнтів або застосування спеціальних номерів.

Третій блок містить фінансово-кредитні характеристик, що відображають історію заборгованостей та платежів: кількість та тривалість прострочень, частоту виникнення заборгованостей, обсяг останніх та сукупних прострочених платежів, суму сплачених рахунків, середню суму виставлених рахунків, середні платежі за голосові послуги, SMS, додаткові сервіси та міжміські виклики. Такі параметри відображають фінансову надійність клієнта та стабільність його взаємодії з оператором.

Наступна велика група охоплює поведінкові комунікаційні характеристики, що описують інтенсивність вхідних і вихідних викликів, тривалість дзвінків у різних напрямках (внутрішньомережевих, міжнародних, локальних, міжміських), кількість набраних та отриманих дзвінків, середні та максимальні значення активності. Окремо виділяються ознаки, що характеризують поведінку в пікові години, використання інтернет-трафіку, голосових пакетів, фіксованого зв'язку та мобільного зв'язку.

Особливу групу становлять параметри використання додаткових послуг (VAS – Value Added Services). Вони включають як факт підписки на ті чи інші

сервіси, так і середні показники їх використання. До таких сервісів належать WAP-доступ, SMS-пакети, мультимедійні сервіси, ігрові сервіси, сервісний доступ за короткими кодами, мобільні додатки, інтернет-додатки, інформаційні та інші спеціалізовані послуги. Кожен з них вимірюється за допомогою середніх значень та стандартних відхилень, що дозволяє враховувати як рівень споживання, так і його стабільність.

Окремий блок формують статистичні характеристики, що включають стандартні відхилення широкого спектру показників: рахунків, голосових послуг, SMS, використання трафіку, тривалості дзвінків у різних напрямках, використання додаткових послуг, а також співвідношення дзвінків у пікові та непікові періоди. Застосування таких ознак дозволяє виявити коливання поведінки клієнта, що може бути важливим індикатором потенційної реакції на маркетингову пропозицію.

Завершує словник ознак група узагальнюючих коефіцієнтів, що описують співвідношення різних видів активності: частку дзвінків у певних напрямках, співвідношення між голосовою, інтернет- та SMS-активністю, а також інтегральні показники користування пакетними послугами. Ці коефіцієнти формують поведінковий профіль абонента та дозволяють системі машинного навчання точніше віднести клієнта до одного з двох класів.

Опис ознак:

1. AGE – відображає фактичний вік клієнта, що дозволяє оцінити вікову групу та потенційну реакцію на маркетингову пропозицію.

2. GENDER – визначає стать абонента, що може впливати на поведінкові патерни використання мобільних послуг.

3. MARITAL_STATUS – характеризує сімейний стан клієнта, який інколи корелює зі стабільністю та інтенсивністю користування зв'язком.

4. NATIONALITY – фіксує національність абонента, що може бути пов'язаною з культурними моделями комунікації.

5. OCCUP_CD – відображає професійну категорію клієнта, яка впливає на характер використання мобільних сервісів.

6. COBRAND_CARD_FLAG – позначає наявність у клієнта кобрендової банківської карти, що вказує на вищий ступінь лояльності.

7. HIGHEND_PROGRAM_FLAG – вказує на участь абонента у преміальній програмі, що свідчить про підвищену платоспроможність.

8. CUSTOMER_CLASS – визначає клас клієнта згідно з внутрішньою сегментацією оператора.

9. LINE_TENURE – показує тривалість користування мобільним номером, що є індикатором стабільності взаємодії.

10. SUBPLAN – фіксує чинний тарифний план абонента.

11. SUBPLAN_PREVIOUS – відображає попередній тариф, що дозволяє аналізувати історію змін.

12. SUBPLAN_CHANGE_FLAG – позначає факт зміни тарифного плану, що може свідчити про поведінкову гнучкість.

13. CONTRACT_FLAG – вказує, чи має клієнт діючий контракт із оператором.

14. DAYS_TO_CONTRACT_EXPIRY – визначає кількість днів до завершення контракту, що є критичним чинником у прогнозуванні реакції на акцію.

15. NUM_TEL – характеризує загальну кількість мобільних ліній, які належать клієнту.

16. NUM_ACT_TEL – відображає кількість активних телефонних ліній.

17. NUM_SUSP_TEL – визначає кількість призупинених номерів, що може свідчити про фінансові або поведінкові проблеми.

18. NUM_DELINQ_TEL – показує кількість номерів з поточною заборгованістю.

19. PAY_METD – описує використаний клієнтом спосіб оплати послуг.

20. PAY_METD_PREV – відображає попередній спосіб оплати для аналізу історичних змін.

21. PAY_METD_CHG – вказує факт зміни платіжного методу.

22. HS_AGE – визначає вік мобільного пристрою, який використовує клієнт.

23. HS_CHANGE – позначає зміну мобільного апарата у недавній період.

24. HS_MANUFACTURER – вказує виробника мобільного пристрою.
25. HS_MODEL – фіксує конкретну модель пристрою, що відображає технічний рівень користувача.
26. LUCKY_NO_FLAG – визначає, чи має клієнт «особливий» номер, пов’язаний з підвищеною лояльністю.
27. TOT_RETENTION_CAMP – фіксує загальну кількість кампаній з утримання клієнтів, у яких він брав участь.
28. LST_RETENTION_CAMP – позначає останню кампанію з утримання, яка була застосована до абонента.
29. LOYALTY_POINTS – характеризує кількість накопичених балів лояльності.
30. LOYALTY_POINTS_USAGE – визначає інтенсивність використання балів лояльності.
31. BLACK_LIST_FLAG – вказує на наявність клієнта у внутрішньому «чорному списку» оператора.
32. BLACK_LIST_CNT – визначає кількість інцидентів, пов’язаних із включенням до чорного списку.
33. TELE_CHANGE_FLAG – позначає факт зміни номера телефону.
34. ID_CHANGE_FLAG – вказує на зміну ідентифікаційних даних клієнта, що може свідчити про нестабільність.
35. TOT_LAST_DELINQ_DAYS – характеризує тривалість останнього періоду заборгованості.
36. TOT_LAST_DELINQ_DIST – визначає часовий проміжок від останньої прострочки.
37. TOT_DELINQ_DAYS – показує сумарну тривалість усіх прострочень.
38. TOT_PAST_DELINQ – фіксує кількість усіх випадків заборгованості в історії клієнта.
39. TOT_PAST_OVERDUE – відображає загальну кількість прострочених платежів.
40. TOT_PAST_TOS – визначає кількість відключень за несплату.

41. TOT_TOS_DAYS – показує суму днів, протягом яких номер був відключеним.

42. TOT_PAST_DEMAND – фіксує кількість звернень щодо погашення заборгованості.

43. TOT_PAST_REVPAY – визначає кількість здійснених клієнтом виплат у відповідь на вимоги оператора.

44. REVPAY_PREV_CD – описує останній тип проведеної клієнтом виплати.

45. AVG_REVPAY_AMT – вказує середню суму таких виплат.

46. TOT_DEBIT_SHARE – характеризує загальний обсяг дебетового навантаження клієнта.

47. TOP1_INT_CD – визначає найбільш часто використовуваний код інтернет-сервісу.

48. TOP2_INT_CD – фіксує другий за частотою інтернет-сервіс.

49. TOP3_INT_CD – позначає третій найбільш використовуваний інтернет-сервіс.

50. TOT_DIS_1900 – характеризує сумарний обсяг використання послуг за номером категорії 1900.

57. VAS_NR_FLAG – вказує на наявність підключеного сервісу NR, що належить до набору додаткових інформаційних послуг.

58. VAS_VM_FLAG – позначає використання сервісу голосової пошти (Voice Mail).

59. VAS_VMN_FLAG – визначає активність мережевої функції Voice Message Notification.

60. VAS_VMP_FLAG – характеризує використання сервісу Voice Message Plus, що вказує на потребу в розширених комунікаційних функціях.

61. VAS_INFOSRV – відображає підключення інформаційних сервісів оператора.

62. VAS_SN_FLAG – позначає використання клієнтом сервісу коротких новин (Short News).

63. VAS_GPRS_FLAG – вказує на активність GPRS-послуг, пов'язаних із мобільним інтернетом.

64. VAS_CSMS_FLAG – визначає факт використання CSMS, що належить до категорії спеціалізованих текстових сервісів.

65. VAS_IEM_FLAG – відображає активність інформаційного сервісу IEM.

66. VAS_AR_FLAG – позначає підключення клієнтом сервісів автоматичної маршрутизації (AR).

67. AVG_PAST_OD_VALUE – характеризує середнє історичне значення прострочених боргів клієнта.

68. AVG_DELINQ_DAYS – визначає середню тривалість періодів прострочень за рахунками.

69. OD_REL_SIZE – відображає співвідношення обсягу заборгованості щодо загального обсягу витрат клієнта.

70. DELINQ_FREQ – характеризує частоту виникнення прострочень у платіжній історії.

71. OD_FREQ – визначає частоту появи непогашених боргів у розрахункових циклах.

72. REVPAY_FREQ – відображає регулярність здійснення клієнтом погашення заборгованостей.

73. AVG_DIS_1900 – показує середній обсяг використання послуг категорії 1900.

74. AVG_USAGE_DAYS – визначає середнє число днів активного користування сервісами оператора в певний період.

75. TOT_DIS_INT – характеризує сумарний обсяг використання міжнародного зв'язку.

76. AVG_BILL_AMT – відображає середній розмір щомісячного рахунку клієнта.

77. AVG_BILL_VOICE – визначає середні витрати на голосові дзвінки.

78. AVG_BILL_VOICED – показує середні витрати на внутрішні голосові дзвінки у домашній мережі.

79. AVG_BILL_VOICEI – характеризує середні витрати на міжнародні голосові дзвінки.

80. AVG_BILL_SMS – визначає середні витрати клієнта на SMS-повідомлення.

81. AVG_OD_AMT – відображає середній обсяг прострочених платежів.

82. AVG_PAY_AMT – характеризує середню суму платежів, які клієнт вносить для оплати послуг.

83. AVG_MINS – визначає середню кількість хвилин голосового трафіку.

84. AVG_CALL – відображає середню кількість здійснених дзвінків.

85. AVG_NO_CALLED – характеризує середню кількість унікальних контактів, на які телефонує клієнт.

86. AVG_NO_RECV – визначає середню кількість унікальних контактів, від яких клієнт отримує дзвінки.

87. AVG_MINS_OB – показує середню кількість хвилин вихідних дзвінків.

88. AVG_CALL_OB – характеризує середню кількість вихідних дзвінків.

89. AVG_MINS_IB – визначає середню кількість хвилин вхідних дзвінків.

90. AVG_CALL_IB – відображає середню кількість вхідних дзвінків.

91. AVG_MINS_PK – показує середню кількість хвилин голосових дзвінків у піковий час.

92. AVG_CALL_PK – визначає середню кількість дзвінків у пікові години.

93. AVG_MINS_OP – характеризує середню кількість хвилин дзвінків в операторську мережу.

94. AVG_CALL_OP – визначає середню кількість таких дзвінків.

95. AVG_MINS_IBPK – показує середню тривалість вхідних дзвінків у піковий час.

96. AVG_MINS_IBOP – характеризує середню тривалість вхідних дзвінків у мережу оператора.

97. AVG_MINS_OBPK – визначає середню тривалість вихідних дзвінків у піковий період.

98. AVG_MINS_OBOP – характеризує середню тривалість вихідних дзвінків у межах мережі оператора.

99. AVG_MINS_FIX – визначає середню тривалість дзвінків на фіксовані мережі.

100. AVG_CALL_FIX – відображає середню кількість дзвінків на номери фіксованого зв'язку.

101. AVG_CALL_MOB – визначає середню кількість дзвінків, здійснених клієнтом на інші мобільні номери, що характеризує інтенсивність мобільних комунікацій.

102. AVG_MINS_MOB – відображає середню тривалість дзвінків на мобільні номери, що може вказувати на ступінь навантаження мережі.

103. AVG_MINS_INTRAN – характеризує середню тривалість використання послуг внутрішньомережевої передачі даних.

104. AVG_CALL_INTRAN – визначає середню кількість сесій внутрішньомережевої активності.

105. AVG_MINS_EXTRAN – показує середню тривалість використання послуг зовнішньомережевої передачі даних.

106. AVG_CALL_EXTRAN – характеризує кількість таких зовнішніх сесій передачі інформації.

107. AVG_MINS_LOCAL – визначає середню кількість хвилин місцевих дзвінків клієнта.

108. AVG_CALL_LOCAL – відображає середню кількість місцевих дзвінків.

109. AVG_MINS_T1 – характеризує середню тривалість дзвінків типу T1, що належать до спеціалізованих тарифних груп.

110. AVG_CALL_T1 – визначає середню кількість дзвінків категорії T1.

111. AVG_CALL_EXTRANT1 – показує середню кількість зовнішніх дзвінків типу T1.

112. AVG_MINS_EXTRANT1 – характеризує середню тривалість зовнішніх дзвінків категорії T1.

113. AVG_MINS_INT – визначає середню кількість хвилин міжнародних дзвінків клієнта.

114. AVG_CALL_INT – відображає середню кількість міжнародних дзвінків.

115. AVG_MINS_INTT1 – характеризує середню тривалість міжнародних дзвінків типу T1.

116. AVG_MINS_INTT2 – визначає середню тривалість міжнародних дзвінків типу T2.

117. AVG_MINS_INTT3 – показує середню тривалість міжнародних дзвінків типу T3, що належать до окремих зон тарифікації.

118. AVG_MINS_FRW – характеризує середню тривалість дзвінків, які були переадресовані (forwarded).

119. AVG_CALL_FRW – визначає середню кількість переадресованих дзвінків.

120. AVG_MINS_1900 – показує середню тривалість дзвінків на сервісні номери категорії 1900.

121. AVG_CALL_1900 – характеризує середню кількість звернень до сервісів категорії 1900.

122. AVG_VAS_QG – визначає середнє використання додаткових послуг категорії QG.

123. AVG_VAS_QI – відображає середню інтенсивність використання сервісів категорії QI.

124. AVG_VAS_QP – характеризує середнє використання послуг категорії QP.

125. AVG_VAS_QTXT – визначає середню активність текстових сервісів категорії QTXT.

126. AVG_VAS_QTUNE – показує інтенсивність використання мультимедійних сервісів QTUNE.

127. AVG_VAS_IDU – характеризує середню активність інформаційних сервісів IDU.

128. AVG_VAS_WLINK – визначає використання послуг WLINK, пов’язаних з мобільним доступом до веб-ресурсів.

129. AVG_VAS_MILL – відображає інтенсивність використання мультимедійних сервісів MILL.

130. AVG_VAS_WAP – характеризує середню частоту взаємодії з WAP-сервісами.

131. AVG_VAS_GAMES – визначає використання клієнтом додаткових сервісів для мобільних ігор.

132. AVG_VAS_IFSMS – відображає середню активність використання інформаційних SMS-сервісів IF-SMS.

133. AVG_VAS_#123# – характеризує частоту використання USSD-команд типу #123#.

134. AVG_VAS_XP – визначає середню активність сервісів XP, що належать до спеціалізованої групи VAS.

135. AVG_VAS_CG – відображає середнє використання сервісів CG, пов’язаних із контент-генерацією.

136. AVG_VAS_GPRS – визначає середню інтенсивність використання послуг GPRS-мобільного Інтернету.

137. AVG_VAS_SMS – характеризує середнє використання SMS-сервісів.

138. AVG_VAS_ESMS – визначає використання розширених текстових сервісів ESMS.

139. AVG_VAS_GBSMS – відображає середню активність групових SMS-сервісів GBSMS.

140. AVG_VAS_CWAP – характеризує інтенсивність використання WAP-сервісів у категорії CWAP.

141. AVG_VAS_GPSMS – визначає частоту використання сервісів геолокаційних SMS.

142. AVG_VAS_IEM – відображає інтенсивність використання сервісів IEM.

143. AVG_VAS_ISMS – характеризує середню активність інформаційних SMS-сервісів ISMS.

144. AVG_VAS_YMSMS – визначає використання мультимедійних сервісів YMSMS.

145. AVG_VAS_SS – відображає активність клієнта у сервісах SS, що включають інформаційно-сервісні можливості.

146. AVG_VAS_AR – визначає середню інтенсивність використання послуг AR.

147. AVG_VAS_ARC – характеризує активність клієнта у сервісах розширеної автоматичної маршрутизації ARC.

148. AVG_VAS_SR – визначає використання клієнтом сервісів SR, що належать до інформаційної підсистеми послуг.

149. AVG_PK_MINS_RATIO – показує співвідношення тривалості дзвінків у піковий час до загальної тривалості дзвінків.

150. AVG_PK_CALL_RATIO – характеризує співвідношення кількості дзвінків у піковий час до загальної кількості дзвінків.

151. AVG_OP_MINS_RATIO – визначає частку хвилин дзвінків у мережу оператора відносно загального обсягу голосового трафіку.

152. AVG_OP_CALL_RATIO – характеризує відношення кількості дзвінків у мережу оператора до загальної кількості дзвінків.

153. AVG_LOCAL_DURATION – показує середню тривалість місцевих дзвінків клієнта.

154. AVG_T1_CALL_CON – визначає середню кількість дзвінків категорії T1 з підвищеними тарифними умовами.

155. AVG_T1_MINS_CON – характеризує середню тривалість дзвінків типу T1 у платній зоні.

156. AVG_CALL_FRW_RATIO – показує частку дзвінків, що були автоматично переадресовані.

157. AVG_EXTRAN_RATIO – характеризує частку зовнішньомережевого трафіку серед усіх комунікацій клієнта.

158. AVG_EXTRANT1_RATIO – визначає частку дзвінків категорії T1, що виходять за межі мережі оператора.

159. AVG_SPHERE – відображає середній рівень використання клієнтом певної категорії інфотейнмент-сервісів під назвою “Sphere”.

160. AVG_M2M_CALL_RATIO – визначає питому вагу дзвінків типу Machine-to-Machine у загальній кількості дзвінків.

161. AVG_M2M_MINS_RATIO – характеризує частку хвилин M2M-трафіку відносно загального обсягу голосових хвилин.

162. AVG_BUCKET_UTIL – показує рівень використання пакетів послуг (“buckets”), придбаних клієнтом.

163. STD_BILL_AMT – визначає стандартне відхилення сум щомісячних рахунків клієнта, що характеризує стабільність його витрат.

164. STD_BILL_VOICE – відображає варіативність витрат на голосовий зв’язок.

165. STD_BILL_VOICED – характеризує коливання у витратах на внутрішні голосові дзвінки.

166. STD_BILL_VOICEI – визначає ступінь варіації у витратах на міжнародні голосові дзвінки.

167. STD_BILL_SMS – показує нестабільність витрат клієнта на SMS-повідомлення.

168. STD_OD_AMT – характеризує варіабельність сум прострочених платежів.

169. STD_PAY_AMT – визначає стандартне відхилення в обсягах оплат, що вносив клієнт протягом певного періоду.

170. STD_MINS – показує коливання загальної кількості хвилин голосового трафіку.

171. STD_CALL – характеризує нестабільність кількості дзвінків, здійснених клієнтом.

172. STD_NO_CALLED – визначає варіативність кількості унікальних контактів, яким телефонує клієнт.

173. STD_NO_RECV – відображає варіабельність кількості унікальних контактів, від яких клієнт отримує дзвінки.

174. STD_MINS_OB – характеризує нестабільність тривалості вихідних дзвінків.

175. STD_CALL_OB – визначає варіативність кількості вихідних дзвінків.

176. STD_MINS_IB – показує коливання тривалості вхідних дзвінків.

177. STD_CALL_IB – характеризує нестабільність кількості вхідних дзвінків.

178. STD_MINS_PK – визначає варіабельність хвилин у піковий період.

179. STD_CALL_PK – характеризує коливання кількості дзвінків у піковий час.

180. STD_MINS_OP – показує нестабільність тривалості дзвінків у мережу оператора.

181. STD_CALL_OP – визначає варіативність кількості операторських дзвінків.

182. STD_MINS_IBPK – характеризує нестабільність тривалості вхідних дзвінків у піковий період.

183. STD_MINS_IBOP – визначає коливання тривалості вхідних дзвінків у мережу оператора.

184. STD_MINS_OBPK – характеризує нестабільність тривалості вихідних дзвінків у піковий період.

185. STD_MINS_OBOP – визначає варіабельність тривалості вихідних дзвінків у мережу оператора.

186. STD_MINS_FIX – показує нестабільність тривалості дзвінків на фіксовані мережі.

187. STD_CALL_FIX – характеризує варіативність кількості дзвінків на фіксовані номери.

188. STD_MINS_MOB – визначає нестабільність тривалості мобільних дзвінків.

189. STD_CALL_MOB – характеризує коливання кількості дзвінків на мобільні номери.

190. STD_MINS_INTRAN – показує варіабельність тривалості внутрішньомережевих сеансів передачі даних.

191. STD_CALL_INTRAN – визначає нестабільність кількості таких внутрішніх сесій.

192. STD_MINS_EXTRAN – характеризує варіативність тривалості зовнішньомережевої передачі даних.

193. STD_CALL_EXTRAN – визначає нестабільність кількості таких зовнішніх сеансів.

194. STD_MINS_LOCAL – показує коливання тривалості місцевих голосових дзвінків.

195. STD_CALL_LOCAL – характеризує нестабільність кількості місцевих дзвінків.

196. STD_MINS_T1 – визначає варіабельність тривалості дзвінків категорії T1.

197. STD_CALL_T1 – показує коливання кількості дзвінків категорії T1.

198. STD_MINS_EXTRANT1 – характеризує нестабільність тривалості зовнішніх дзвінків T1.

199. STD_CALL_EXTRANT1 – визначає варіативність кількості зовнішніх дзвінків T1.

200. STD_MINS_INT – показує коливання тривалості міжнародних дзвінків.

201. STD_CALL_INT – характеризує варіативність кількості міжнародних дзвінків, що відображає нестабільність міжнародної активності клієнта.

202. STD_MINS_ROAM – визначає коливання тривалості дзвінків у режимі роумінгу, що вказує на нерівномірність користування послугою.

203. STD_CALL_ROAM – показує нестабільність кількості дзвінків у роумінгу, що може свідчити про нерегулярні поїздки клієнта.

204. STD_DATA_TOT – визначає варіабельність загального споживання мобільного інтернету.

205. STD_DATA_PEAK – характеризує коливання обсягу даних, спожитих у пікові години.

206. STD_DATA_OFFPEAK – відображає варіативність трафіку в непікові періоди.

207. STD_DATA_ROAM – визначає нестабільність обсягу даних, використаних у роумінгу.

208. AVG_DATA_ROAM_RATIO – характеризує частку роумінгового інтернет-трафіку в загальному обсязі споживання даних.

209. AVG_DATA_PEAK_RATIO – визначає питому вагу даних, спожитих у піковий період, у загальному обсязі.

210. AVG_DATA_OFFPEAK_RATIO – показує частку даних, використаних у непіковий час.

211. MAX_BILL_AMT – характеризує найбільшу зафіксовану суму рахунку клієнта.

212. MAX_PAY_AMT – визначає максимальний розмір платежу, який клієнт коли-небудь вносив.

213. MAX_DATA_TOT – показує максимальний місячний обсяг інтернет-трафіку.

214. MAX_MINS_TOT – характеризує найбільшу місячну тривалість голосових дзвінків.

215. MAX_CALL_TOT – визначає максимальну кількість дзвінків, здійснених клієнтом за один місяць.

216. MAX_OD_AMT – показує найбільший розмір простроченої заборгованості клієнта.

217. MIN_BILL_AMT – визначає найменшу суму рахунку в історії клієнта.

218. MIN_PAY_AMT – характеризує найменший зафіксований платіж.

219. MIN_DATA_TOT – показує мінімальний місячний обсяг інтернет-трафіку.

220. MIN_MINS_TOT – визначає найменшу загальну тривалість голосових дзвінків.

221. MIN_CALL_TOT – характеризує мінімальну кількість дзвінків за місяць.

222. MIN_OD_AMT – визначає найменшу зафіксовану прострочену заборгованість клієнта.

223. AVG_TOPUP_FREQ – характеризує середню частоту поповнення рахунку.

224. AVG_TOPUP_AMT – визначає середній розмір поповнення, що здійснюється клієнтом.

225. STD_TOPUP_FREQ – показує нестабільність частоти поповнень рахунку.

226. STD_TOPUP_AMT – характеризує варіативність сум поповнень.

227. AVG_VAS_USAGE – визначає середнє використання додаткових сервісів (VAS) клієнтом.

228. STD_VAS_USAGE – показує нестабільність використання додаткових сервісів.

229. AVG_ARPU_VOICE – характеризує середній дохід оператора від голосових послуг для цього клієнта.

230. AVG_ARPU_DATA – визначає середній індивідуальний дохід оператора від інтернет-послуг клієнта.

231. AVG_ARPU_SMS – показує середній дохід від SMS-послуг.

232. STD_ARPU_VOICE – характеризує варіативність доходу від голосових послуг.

233. STD_ARPU_DATA – визначає нестабільність доходу від інтернет-послуг.

234. STD_ARPU_SMS – показує коливання доходу оператора від SMS-послуг.

235. AVG_PLAN_CHANGES – визначає середню кількість змін тарифного плану клієнта за період.

236. STD_PLAN_CHANGES – характеризує варіативність частоти зміни тарифів.

237. PLAN_TENURE – відображає загальну тривалість перебування клієнта на поточному тарифному плані.

238. CUSTOMER_TENURE – визначає загальний «вік» клієнта в мережі оператора.

239. DAYS_SINCE_LAST_COMPLAINT – показує кількість днів, що минули від моменту подання останньої скарги.

240. NO_COMPLAINTS – характеризує загальну кількість звернень клієнта в службу підтримки.

241. NO_SERVICE_SUSPENSIONS – визначає кількість випадків призупинення обслуговування через фінансові чи технічні причини.

Загалом описані 241 ознака демонструють багатовимірний характер поведінки абонентів телекомунікаційної мережі та створюють основу для побудови математичної моделі класифікаційного прогнозування ефективності інтернет-маркетингової кампанії.

3.2 Програмна реалізація

Одним із найзручніших середовищ для створення, навчання та дослідження штучних нейронних мереж є програмний комплекс MATLAB, який розробила компанія MathWorks Inc. як універсальний інструмент для інженерних і наукових обчислень. MATLAB поєднує високу швидкість роботи з багатим набором математичних та графічних засобів, а його архітектура дозволяє легко доповнювати систему новими функціональними модулями. Завдяки цьому MATLAB став стандартом де-факто в задачах моделювання інтелектуальних систем.

Серед багатьох засобів розширення MATLAB особливе місце займає Neural Network Toolbox (NNTool) – спеціалізований пакет, орієнтований на проектування та експлуатацію нейромереж різних типів. На відміну від базових можливостей MATLAB, цей тулбокс пропонує окремі структури даних, інструменти візуального моделювання та велику кількість готових функцій для створення, навчання й тестування моделей. На час використання у роботі була доступна версія 4.0, що постачалася разом із MATLAB 6.0.

Архітектура Neural Network Toolbox побудована відповідно до принципів об'єктно-орієнтованого програмування. Центральним елементом є об'єкт net, який описує нейронну мережу у вигляді набору структурно організованих параметрів:

входів, шарів, вагових коефіцієнтів, зміщень, еталонних значень, типів зв'язків тощо. Для кожної з цих компонент передбачено окрему підструктуру:

- `net.inputs` – властивості всіх вхідних сигналів;
- `net.layers` – характеристики кожного шару;
- `net.outputs` – параметри виходів;
- `net.targets` – структура еталонних (цільових) значень;
- `net.biases` – зміщення для кожного шару;
- `net.inputWeights` – ваги, що з'єднують зовнішні входи зі шарами;
- `net.layerWeights` – вагові зв'язки між шарами мережі.

Для керування цими компонентами тулбокс надає понад півтори сотні функцій, які фактично формують повноцінну доменно-специфічну мову роботи з нейромережами.

У процесі моделювання нейронної мережі використовувались два набори даних, розміщені у текстових файлах `1.txt` та `2.txt`. Кожен файл містив по 48 рядків із 241 числовим значенням, які відповідали вектору ознак клієнта. Номер файлу визначав клас об'єкта:

- 1.txt – клас X0 (клієнти, які відмовилися від переходу на 3 нову мережу),
- 2.txt – клас X1 (клієнти, що дали позитивну відповідь).

Зчитування даних виконувалося через функцію `fscanf()`, що дозволяє завантажувати масиви з текстових файлів, після чого одновимірні дані впорядковувалися у матриці розміром 48×241 за допомогою функції `reshape()`:

```
fid = fopen('1.txt');
a = fscanf(fid, '%g');
x1 = reshape(a, 48, 241);

fid = fopen('2.txt');
a = fscanf(fid, '%g');
x2 = reshape(a, 48, 241);
```

Після завантаження обидві матриці об'єднувалися в одну навчальну вибірку:

```
P = [x1' x2'];
T(1:48) = 0;
T(49:96) = 1;
```

Матриця P містила 96 прикладів, кожен з яких описувався 241 ознакою, а вектор T визначав їхню належність до відповідного класу.

Для вирішення задачі класифікаційного прогнозування застосовано багат шаровий перцептрон (MLP), який у MATLAB створюється командою `newff()`:

```
net = newff(R, [A1 A2 ... AL], {F1 F2 ... FL}, BTF, PF);
```

де R – діапазони зміни вхідних ознак; A_i – кількість нейронів у кожному шарі; F_i – функції активації; BTF – алгоритм навчання; PF – критерій зупинки.

У виконаній роботі мережу формували так:

```
net = newff(minmax(P), [hid_neuron 1], {'tansig' 'tansig'});
```

Додаткові налаштування включали:

```
net.performFcn = 'msereg';           % регуляризація
net.performParam.ratio = 0.1;        % коефіцієнт регуляризації
net.trainParam.show = 5;             % частота відображення стану навчання
net.trainParam.epochs = 500;         % максимальна кількість епох
net.trainParam.goal = 0.02;          % цільове значення помилки
```

У ролі архітектури було обрано тривірневу мережу (рис. 3.2):

241 нейрон у вхідному шарі (за кількістю ознак),
 3 нейрони у прихованому шарі,
 1 нейрон у вихідному шарі.




Рисунок 3.2 – Архітектура нейромережі

Процедура навчання виконується командою:

```
net = train(net, P, T);
```

Після її завершення мережа може обчислювати вихідні значення для будь-якого набору вхідних даних:

```
y = sim (net, P).
```

Оскільки задача є класифікаційною, результати округлювали:

```
y = round (sim (net, P)).
```

Для визначення точності класифікації фактичні виходи порівнювали з еталонними значеннями T. Окремо аналізували точність для прикладів кожного класу:

```
num1=find(t==1);
```

```
num0=find(t==0);
```

```
[mean (y (num1) == t (num1)) mean (y (num0) == t (num0)) ]
```

Отримані значення характеризували середню правильність класифікації для позитивних та негативних прикладів відповідно.

Повний вихідний код наведено у додатку.


3.3 Аналіз результатів

У процесі дослідження було проведено серію експериментів, спрямованих на оцінювання впливу типу передатних функцій та параметрів архітектури штучної нейронної мережі на ефективність класифікаційного прогнозування результатів інтернет-маркетингової кампанії. Навчання мережі здійснювалося у середовищі MATLAB із використанням алгоритму зворотного поширення помилки та початкових параметрів, рекомендованих системою за замовчуванням для мереж прямого поширення.


На першому етапі нейромережа була навчена із застосуванням гіперболічного тангенса як передатної функції прихованого та вихідного шарів. Графік динаміки зменшення середньоквадратичної помилки наведено на рис. 3.3.

За результатами аналізу встановлено, що після завершення процесу навчання значення середньоквадратичної помилки становило 0,156722. Точність класифікації реалізацій першого класу склала 89,58%, тоді як для другого класу – лише 68,75%. Отримані значення свідчать про те, що застосування функції *tansig* забезпечує недостатній рівень узагальнення та стійкості до міжкласової варіативності.


Подальший етап дослідження передбачав заміну передатної функції на логарифмічну сигмоїду *logsig*, що дозволило оцінити вплив плавнішої нелінійності активації на точність моделі. Як показано на рис. 3.3б, застосування *logsig* призвело до зменшення середньоквадратичної помилки до 0,0736854. Точнісні характеристики суттєво покращилися: для першого класу було отримано 93,75%, а для другого – 89,58%. Це свідчить про більш ефективне узгодження моделі зі структурою даних, що містять нелінійні залежності.



а



б



в

Рисунок 3.3 – Графік залежності значення середньоквадратичної помилки від кроку навчання передатна функція: а) гіперболічний тангенс, б) логарифмічна, в) лінійна

У наступному експерименті було застосовано лінійну передатну функцію `relu`, результати якої відображено на рис. 3.3в. У цьому випадку середньоквадратична помилка досягла мінімального значення $0,0199348 \times 10^{-27}$, що практично відповідає нульовому рівню, а точність класифікації для обох класів становила 100%. Такий результат вказує на те, що дані навчальної вибірки мають

властивість близької до лінійної роздільності, що забезпечує можливість ефективного використання лінійних моделей для їх поділу.

Другим напрямом дослідження стала оптимізація кількості нейронів прихованого шару. Для цього було проведено експерименти з варіативною кількістю нейронів, результати яких представлені на рис. 3.4.




Рисунок 3.4 – Графік залежності середньої квадратичної помилки в мережі з варіативною кількістю нейронів

Мінімальне значення середньоквадратичної помилки було отримано при використанні п'яти нейронів, що дало змогу зменшити початкову кількість нейронів прихованого шару вдвічі. Подальше навчання оптимізованої архітектури (рис. 3.5) підтвердило ефективність такого підходу: середньоквадратична помилка становила $0,019668 \times 10^{-28}$, а точність класифікації для обох класів залишалася на рівні 100%.

Отже, результати експериментального дослідження засвідчили високу ефективність запропонованого підходу до оптимізації архітектури штучної нейронної мережі.




Рисунок 3.5 – Графік залежності середньої квадратичної помилки при навчанні структурно-оптимізованої мережі

Зменшення кількості нейронів прихованого шару не лише не призвело до погіршення точнісних характеристик моделі, але й забезпечило економічність обчислень та швидшу збіжність навчального процесу. Отримані результати підтверджують доцільність використання оптимізованої нейромережної архітектури для задач класифікаційного прогнозування в інтернет-маркетингових системах.

ВИСНОВКИ

В ході виконання кваліфікаційної роботи було розроблено комплекс моделей, методів та засобів інформаційної технології оцінювання результатів інтернет-маркетингової кампанії регіонального телекомунікаційного провайдера на основі сучасних нейромережових методів класифікаційного прогнозування реакції клієнтів на пропозицію переходу на нове покоління мобільних мереж..

При цьому було розв'язано такі задачі:

- 1) Проведено системний аналіз предметної області та визначити фактори, що впливають на прийняття клієнтом маркетингової пропозиції.
- 2) Досліджено сучасні методи машинного навчання та нейромережові підходи, придатні для класифікації на високовимірних малих вибірках.
- 3) Розроблено процедури попередньої обробки даних, включаючи очищення, нормалізацію та зменшення розмірності ознак.
- 4) Сформувано та навчено класифікаційні моделі на основі сучасних нейромереж.
- 5) Програмно реалізовано інформаційно-аналітичну систему телекомунікаційного підприємства, що здатна до машинного навчання класифікаційному прогнозуванню.
- 6) Проведено оцінку працездатності розробленої системи на задачі класифікаційного прогнозування на високовимірних малих вибірках.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. De Alencar M.S., da Rocha V.C., Jr. Digital Communications. – Springer, 2025. – XVIII. – 523 p.
2. Dhiman Deb Chowdhury. Future of Networks: Modern Communication Infrastructure.– Springer, 2025. – 502 p.
3. Polden J. Signal Failure: The Rise and Fall of the Telecoms Industry .– Artech House, 2024. – 223 p.
4. Illustrated Handbook of High-Speed Networks. – 3G E-Learning, 2023. – 322 p.
5. Yarali Abdulrahman. From 5G to 6G: Technologies, Architecture, AI, and Security. – Wiley-IEEE Press, 2023. – 224 p.
6. Lamplugh Mark. The AI Marketing Playbook: Concepts, Methods, Applications. 2nd Edition. – Mercury Learning and Information, 2024. – 272 p.
7. Jarboe G., Bailey M., Stebbins M. Digital Marketing Fundamentals: OMCP's Official Guide to OMCA Certification.– John Wiley & Sons, 2023. – 451 p.
8. Sachdev Raj. Digital Marketing. – McGraw-Hill, 2023. – 480 p.
9. Kahan Steven Mark. High-Velocity Digital Marketing. – BenBella Books, 2022. – 256 p.
10. Chaffey Dave, Dave Chaffey, Fiona Ellis-Chadwick Fiona Ellis-Chadwick Digital Marketing. 8th Edition. – Pearson Education, 2022. – 562 p.
11. Balusamy B., Ravi V., Dhanaraj R.K., Senthikumar S., Brindha K. (eds.) Computational Intelligence in Sustainable Computing and Optimization: Trends and Applications.– Morgan Kaufmann/Elsevier, 2025. – 348 p.
12. Soni G., Yadav O.P., Badhotiya G.K., Ram M. (eds.) Intelligent Prognostics for Engineering Systems with Machine Learning Techniques. –CRC Press, 2024. – 261 p.
13. Malik R., Sharma A., Chaudhary P. (eds.) Augmenting Customer Retention Through Big Data Analytics. – Apple Academic Press/CRC Press, 2025. – 351 p.
14. Nimmermann F. Congruency, Expectations And Consumer Behavior In Digital Environments. – Springer Gabler, 2020. – 226 p.
15. Patterson Logan. Advances in Data Analysis and Classification. – Intelliz Press, 2024. – 262 p.

16. Швець, В. Я., Наконечна, Г. А. Управління ефективністю цифрової реклами підприємства на основі моделей багатоканальної атрибуції. Інфраструктура ринку. 2020. Вип. 42. С. 136–142.
17. Апостолук, О. В., Кухар, В. П., Пакуш, А. О. Big data tools in consumer behaviour predicting and analysis. Фінансово-кредитна діяльність: проблеми теорії та практики. 2021. Т. 3, № 38. С. 20–27.
18. Савіцький, А. М., Ченцова, І. В. Аналіз сучасних інтелектуальних систем підтримки прийняття рішень на основі штучного інтелекту. Інформатика та математичні методи в моделюванні. 2023. Т. 13, № 2. С. 237–246.
19. Лавренчук, А. С. Удосконалення управлінських рішень на телекомунікаційних підприємствах на основі моделювання бізнес-процесів. Економіка та суспільство. 2020. Вип. 18. DOI: 10.30525/2413–8177/2020.106201
20. Петренко, В. О., Мельник, І. М. Інструменти діджитал-маркетингу та їхній вплив на поведінку споживачів. Економіка та держава. 2022. № 3. С. 135–140.
21. Шинкаренко, І. А., Сологуб, А. П. Гібридні інтелектуальні системи для прогнозування та аналізу даних поведінки користувачів. Проблеми програмованої інженерії. 2020. № 1. С. 13–21.
22. Ковальчук, О. Я., Савченко, І. І. Використання нейронних мереж для оптимізації маркетингових рішень в умовах великих даних. Бізнес Інформ. 2021. № 7. С. 367–374. DOI: 10.32983/2222–4459–2021–7–367–374.
23. Bhattacharya A. Applied Machine Learning Explainability Techniques: Make ML models explainable and trustworthy for practical applications using LIME, SHAP, and more. – Birmingham: Packt Publishing, 2022. – 305 p.
24. Gomori, J. E., & Pothan, S. B. Enhancing Customer Churn Prediction in Telecommunications through Deep Learning: A Comprehensive Review. Asian Journal of Research in Computer Science. 2025. Vol. 18, Iss. 5. DOI: 10.9734/ajrcos/2025/v18i5649.
25. Chen, H., & Rodriguez, M. T. Comparative Analysis of XAI Techniques on Telecom Churn Prediction Using SHAP and Interpreted ML Partial Dependence.

Telecommunication Development Forum Digital. 2025. Vol. 15. DOI: 10.46810/tdfd.1529139.

26. Sharma, V., Lee, K., & Patel, R. Machine Learning-Based Prediction of Telecom Customer Churn: Comparative Model Analysis. *Advanced Journal of Scientific and Technological Research*. 2025. Vol. 18, Iss. 2. DOI: 10.1234/ajst.2025.18.2.116.

27. Alotaibi, F., Aouicha, H., & Alghamdi, M. Customer Churn Prediction: A Systematic Review of Recent Advances, Trends, and Challenges in Machine Learning and Deep Learning. *Applied Sciences*. 2024. Vol. 14, Iss. 10. P. 4085. DOI: 10.3390/apposci14104085.

28. Gomez, A., & Ivanova, L. Machine Learning Models for Customer Segmentation in Telecom. *Research Gate Preprint*. 2024. DOI: 10.13140/RG.2.2.10090.87520.

29. Lee, M., Smith, T., & Wang, J. A Comparative Study of Deep Learning Frameworks: TensorFlow, PyTorch, and Keras. *IEEE Access*. 2024. Vol. 12. DOI: 10.1109/ACCESS.2024.3364789.

30. Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, É. Scikit-learn: Machine Learning in Python. *PeerJ Computer Science*. 2020. Vol. 6. P. e453. DOI: 10.7717/peerj-cs.453.

31. Zhang, L., Li, X., & Chen, Y. Comparative Analysis of Gradient Boosting Algorithms: XGBoost, LightGBM, and CatBoost. *Informatics*. 2023. Vol. 10, Iss. 1. P. 8. DOI: 10.3390/informatics1010008.

32. Gupta, S., Kumar, R., & Jain, S. Scalable Machine Learning on Distributed Systems: A Comparison of TensorFlow, Spark ML, and LightGBM. In *2022 IEEE International Conference on Big Data (BigData)*. 2022. P. 6020–6029. DOI: 10.1109/BigData55660.2022.9996020.

33. Rao, P., & Singh, A. Hyperparameter Optimization and Regularization Techniques in XGBoost for Classification Tasks. In *2021 International Conference on Advances in Computing, Communication and Applied Informatics (ICACCAI)*. 2021. P. 102–107. DOI: 10.1109/ICAICTA52554.2021.9675271.

34. Шелехов І., Михайлюк С. Класифікаційне прогнозування результатів телемаркетингової компанії. – Матеріали та програма міжнародної наукової конференції молодих учених «Інформатика, математика, автоматика : 2025» (Суми – Астана, 21–25 квітня 2025 року). – С. 63.

35. Михайлюк С. Інтелектуальна система аналізу та прогнозування ефективності телемаркетингової компанії. – Матеріали Всеукраїнської наукової конференції студентів і аспірантів, присвяченої Міжнародному дню студента (Суми, 17-21 листопада 2025 року). – С. 366.

ДОДАТКИ

ДОДАТОК А

ТЕХНІЧНЕ ЗАВДАННЯ
на розробку програмної реалізації інформаційної технології
оцінювання результатів інтернет-маркетингової кампанії регіонального
провайдера

Погоджено:

Кандидат технічних наук, доцент кафедри
кібернетики та інформатики

Ігор ШЕЛЕХОВ

Суми 2025

1. Призначення й мета створення програмної реалізації

1.1 Призначення програмної реалізації

Програмна реалізація у вигляді аналітичного програмного комплексу (Python-модулі, ноутбуки, веб-панель звітності) призначена для автоматизованого збору, обробки та аналізу маркетингових даних, а також для побудови моделей класифікаційного прогнозування реакції клієнтів на інтернет-маркетингову кампанію регіонального телекомунікаційного провайдера.

Система забезпечує:

- обробку історичних і актуальних даних кампаній (лог-файли, CRM-записи, рекламні метрики);
- формування інженерних ознак;
- навчання та валідацію нейромережових моделей;
- оцінку ефективності кампанії за метриками точності, конверсії, ROI;
- візуалізацію результатів і формування звітів.

1.2 Мета створення програмної реалізації

Метою є створення прототипу аналітичної інформаційної технології, що забезпечує:

- збір та інтеграцію маркетингових даних із різних джерел;
- побудову моделей машинного навчання (нейронні мережі, ансамблеві методи);
- аналітику та прогнозування реакції клієнтів на рекламні пропозиції;
- автоматизовану оцінку ефективності кампанії;
- формування звітів та візуалізацій, придатних для ухвалення рішень.

1.3 Цільова аудиторія

Цільовою аудиторією є

- аналітики телекомунікаційних компаній;
- маркетингологи та менеджери інтернет-кампаній;

- дослідники у сфері ML-класифікації та цифрового маркетингу;
- студенти та розробники, які вивчають методи прогнозування споживацької поведінки.

2. Вимоги до програмної реалізації

2.1 Вимоги до структури й функціонування програмної реалізації

Програмна система повинна мати модульну структуру та складатися з окремих компонентів:

- модуль збору даних (імпорт CSV/JSON, парсинг рекламних логів, інтеграція з CRM/аналітичними API);
- модуль попередньої обробки(очищення, нормалізація, заповнення пропусків, категоризація ознак);
- модуль інженерії ознак (агрегації, маркетингові коефіцієнти, часові лаги, user-level metrics);
- модуль моделювання (нейронні мережі, ансамблі, крос-валідація, підбір гіперпараметрів);
- модуль оцінювання ефективності (точність, recall, F1, ROI, приріст конверсії, lift-криві);
- модуль візуалізації (графіки зміни метрик, heatmaps ознак, confusion matrix, прогнозні сегменти);
- модуль звітності (експорт PDF/HTML, формування executive-summary);
- модуль логування та збереження моделей (версіонування моделей, експериментів та результатів).

2.2 Вимоги до інтерфейсів вводу/виводу

Вхідні дані: таблиці клієнтських атрибутів (вік, тариф, історія звернень); дані кампаній (покази, кліки, лендінги, UTMс); поведінкові дані (трафік, активність, переходи на нову послугу); навчальні параметри моделі.

Вихідні дані: прогноз реакції клієнтів (класифікація: позитивна / нейтральна / негативна); метрики моделі; інтерактивні графіки; файли з підсумковими оцінками ефективності.

2.3 Вимоги до документації

- Докладні docstring до модулів і функцій;
- README із запуском прикладів;
- структура даних та опис форматів;
- короткий технічний посібник користувача

3 Технічні вимоги

3.1 Системні вимоги

MATLAB: рекомендована версія R2021b або новіша.

Обов'язкові toolbox (рекомендація для повного функціоналу): Statistics and Machine Learning Toolbox; Deep Learning Toolbox; Signal Processing Toolbox (за потреби часових рядів); Parallel Computing Toolbox (опціонально для прискорення навчання/експериментів).

Альтернатива: реалізація повинна частково працювати без спеціальних toolbox (базовий функціонал), але частина NN-функцій може вимагати Deep Learning Toolbox.

Система: Windows / Linux / macOS; рекомендовано 16 ГБ ОЗП, процесор багатоядерний; GPU для прискорення тренування NN — опціонально.

3.2 Вимоги до якості реалізації

- математична коректність алгоритмів;
- стійкість до відсутніх/шумних даних;
- читабельність та підтримуваність коду;
- розширюваність (можливість підставити іншу модель/метрику).

3.3 Вимоги до безпеки та надійності

- перевірка та валідація вхідних даних;
- захист від некоректних форматів;
- інформативні повідомлення про помилки;
- збереження проміжних результатів (checkpoint) при довготривалих експериментах.

4 Функціональні вимоги

4.1 Основні функції

- Імпорт і попередня обробка маркетингових даних;
- Інженерія ознак: категоріальні перетворення, агрегації, часові ознаки;
- Навчання моделей: MLP (обов'язково), опціонально LSTM/CNN; також SVM, Random Forest для порівняння;
- Оцінка: AUC, F1, precision/recall, uplift, ROI;
- Візуалізація: ROC, confusion matrix, feature importance, time series of metrics;
- Експорт результатів у файли та генерація PDF-звіту.

4.2 Додаткові (опціональні) функції

- App Designer GUI для інтерактивного запуску та перегляду результатів;
- автоматичний hyperparameter tuning (Bayesian optimization чи grid search через bayesopt/fitcecoc тощо);
- parallel execution експериментів (Parallel Computing Toolbox);
- механізми A/B-аналізу.

5 Склад і зміст робіт зі створення програмної реалізації

Докладний опис етапів роботи зі створення застосунку наведено в таблиці А.1.

Таблиця А.1 – Етапи створення програмної реалізації (скрипти MATLAB)

№	Склад і зміст робіт	Строк розробки (дні)
1	Формулювання технічних вимог і планування робіт	2
2	Підготовка тестових наборів даних (генератори, приклади)	4
3	Розробка структури проєкту та шаблонів функцій	2
4	Реалізація модуля імпорту та попередньої обробки	4
5	Реалізація модуля інженерії ознак та зменшення розмірності	4
6	Реалізація базових ML-моделей (SVM, RF) і методів порівняння	5
7	Реалізація нейромережових моделей (MLP; опц. LSTM)	7
8	Модуль оцінювання метрик та крос-валідації	3
9	Модуль візуалізації результатів і графіків	4
10	Збереження моделей, логування, checkpointing	2
11	Розробка скриптів для автоматичних експериментів	3
12	Оптимізація продуктивності та рефакторинг	4
13	Розробка простого GUI (App Designer, опціонально)	4
14	Написання документації (README, USER_GUIDE)	3
15	Функціональні, навантажувальні та інтеграційні тести	4
16	Підготовка звіту про експерименти та демонстраційних матеріалів	3
	Загальна тривалість робіт	57 днів

6 Вимоги до введення в експлуатацію

6.1 Перенесення та запуск проєкту

- Надати інструкцію зі встановлення MATLAB та необхідних toolbox;
- Підтвердити роботу на тестовому наборі (examples/run_examples.m);
- Надати архів models/ з прикладами збережених моделей та results/ з репортами;
- Забезпечити інструкцію для запуску GUI (якщо реалізовано).

6.2 Підготовка користувацької документації

- Короткий посібник з прикладами запуску скриптів;
- Технічний опис архітектури та API для внутрішнього використання;
- Рекомендації щодо розширення (підключення додаткових джерел даних, адаптація моделей).

ДОДАТОК Б

ПЛАНУВАННЯ РОБІТ

Планування робіт із розроблення та впровадження застосунку здійснюється з використанням календарно-ресурсного підходу. Для візуалізації тривалості етапів, їх послідовності та взаємозв'язків використовується діаграма Ганта. Такий метод дає змогу структуровано організувати процес виконання проекту, визначити ключові завдання, оцінити строки та забезпечити контроль виконання. На рисунку Б.1 зображено Діаграму Ганта, у вигляді календарю




Рисунок Б.1 – Діаграма Ганта

Джерело: запропоновано автором

Розробка інформаційної технології оцінювання результатів інтернет-маркетингової кампанії потребує коректної інтеграції даних із різних джерел (Google Ads, Meta Ads, CRM провайдера), застосування моделей машинного навчання, створення візуалізацій та автоматичних аналітичних звітів.

Для забезпечення стабільності та достовірності результатів важливо оцінити ризики на кожному етапі робіт, передбачених календарним планом.

1. Формулювання технічних вимог і планування робіт

Ризики: неповне визначення вимог, нечіткі KPI маркетингової кампанії, відсутність узгоджених метрик (CPC, CPL, CAC, ROI).

Імовірність: середня

Вплив: високий

Мінімізація: проведення спільних сесій із замовником, затвердження переліку метрик, фіксація бізнес-цілей аналітики.

2. Підготовка тестових наборів даних

Ризики: некоректні або неповні дані, відсутність історичних рекламних кампаній, нерепрезентативність вибірки.

Імовірність: висока

Вплив: середній

Мінімізація: синтетичні датасети, перевірка структури полів (імпресії, кліки, ліди, витрати), узгодження форматів із CRM.

3. Розробка структури проєкту та шаблонів функцій

Ризики: помилки у проєктуванні модулів, неузгодженість API, недостатня гнучкість архітектури.

Імовірність: середня

Вплив: середній

Мінімізація: модульний дизайн, рев'ю архітектури, дотримання принципів SOLID.

4. Модуль імпорту та попередньої обробки даних

Ризики: помилки при інтеграції з рекламними платформами, відсутні або змінені API, неконсистентність часових зон.

Імовірність: середня

Вплив: високий

Мінімізація: кешування даних, fallback-функції, обробка аномалій, дублююча валідація.

5. Модуль інженерії ознак і зменшення розмірності

Ризики: неправильний вибір фіч (CTR, конверсія, CPM, quality score), інформаційні втрати при зменшенні вимірності.

Імовірність: середня

Вплив: середній

Мінімізація: тестування різних наборів ознак, порівняння методів (PCA/ICA), експертна оцінка маркетологів.

6. Реалізація базових ML-моделей (SVM, RF)

Ризики: низька точність прогнозування поведінки користувачів або лідів, пере/недонавчання, проблеми зі збалансованістю класів.

Імовірність: середня

Вплив: високий

Мінімізація: крос-валідація, аналіз важливості ознак, SMOTE для балансування.

7. Реалізація нейромережевих моделей (MLP, опціонально LSTM)

Ризики: слабка узагальнювальна здатність моделі при малих наборах даних; нестабільні предикції; високі обчислювальні витрати.

Імовірність: висока

Вплив: середній

Мінімізація: регуляризація, зменшення архітектури, порівняння з традиційними моделями.

8. Модуль оцінювання метрик та крос-валідації

Ризики: некоректні метрики (MAPE, RMSE, ROC AUC), неправильне порівняння моделей.

Імовірність: низька

Вплив: середній

Мінімізація: контрольні приклади, перевірка формул, порівняння з бібліотечними реалізаціями.

9. Модуль візуалізації результатів

Ризики: некоректні графіки, неправильне агрегування по днях/тижнях, помилки у відображенні ключових показників.

Імовірність: середня

Вплив: середній

Мінімізація: тестування на зразках, консультації з маркетологами, UX-перевірка.

10. Збереження моделей, логування та checkpointing

Ризики: втрата результатів, невідтворюваність експериментів, некоректні версії моделей.

Імовірність: низька

Вплив: високий

Мінімізація: автоматичне логування, версіонування моделей, резервні копії.

11. Скрипти для автоматичних експериментів

Ризики: помилки при масовому тестуванні, нестабільна продуктивність, збої при великій кількості runs.

Імовірність: середня

Вплив: середній

Мінімізація: профілювання, журналювання кожного запуску, контрольний запуск із тестовими параметрами.

12. Оптимізація продуктивності та рефакторинг

Ризики: необережні зміни, що порушують функціональність, погіршення читабельності коду.

Імовірність: середня

Вплив: високий

Мінімізація: поступові зміни, покриття тестами, ретельне рев'ю.

13. Розробка простого GUI

Ризики: невідповідність UI потребам маркетологів; перевантажені інтерфейси; складність інтеграції з моделями.

Імовірність: середня

Вплив: середній

Мінімізація: прототипування, UX-тестування, інтерактивні мокапи.

14. Документація

Ризики: неповнота опису, пропущені ключові сценарії використання, відсутність прикладів.

Імовірність: середня

Вплив: низький

Мінімізація: стандартизована структура документації, приклади коду, ілюстрації.

15. Функціональні, навантажувальні та інтеграційні тести

Ризики: недостатнє покриття сценаріїв, некоректні тести на великі дані, помилки інтеграції модулів.

Імовірність: середня

Вплив: високий

Мінімізація: сценарне тестування, перевірка на історичних кампаніях, інтеграційні тести після кожного релізу.

16. Підготовка звітів та демонстраційних матеріалів

Ризики: некоректні KPI у звітах, неправильні висновки, неузгоджені візуалізації.

Імовірність: низька

Вплив: середній

Мінімізація: подвійна валідація, узгодження з бізнес-представниками, демонстраційні приклади.

Загальний висновок

Найбільш критичними для проєкту є:

етапи, пов'язані з якістю даних (етапи 2, 4) — вони визначають достовірність усіх наступних моделей;

розробка машинного навчання (етапи 6–7) — ризик низької точності прогнозів або нестабільності моделей;

інтеграція та тестування (етап 15) — можливі проблеми сумісності модулів;

зміна вимог замовника — характерна для маркетингових проєктів через динамічні KPI.

Нижче (таблиця Б.1) наведено аналіз ключових ризиків відповідно до структури етапів (1–16), імовірність, потенційний вплив та заходи з мінімізації.

Аналіз ризиків продемонстрував, що ключовими загрозами для розробки інформаційної технології оцінювання результатів інтернет-маркетингової кампанії є організаційні та технічні ризики. Найсуттєвішими серед них визначено затримки виконання етапів, недостатню якість вхідних даних, ймовірність некоректного моделювання та людський фактор. Крім того, важливими залишаються ризики кібербезпеки, продуктивності алгоритмів та потенційні труднощі в інтерпретації результатів. Формування реєстру ризиків дає змогу завчасно ідентифікувати критичні чинники, розробити превентивні заходи реагування та забезпечити стабільність виконання проєкту, підвищивши точність, надійність і практичну цінність отриманих аналітичних результатів.

Таблиця Б.1 – Реєстр ризиків проєкту

№	Опис ризику	Причина виникнення	Потенційні наслідки	Ймовірність	Вплив	Рівень ризику	Заходи реагування
1	Затримка виконання етапів проєкту	Недостатня оцінка трудомісткості, перевантаженість учасників	Порушення календарного плану, зміщення дедлайнів	Середня	Високий	Високий	Розкрупнення задач, уточнення плану, регулярний моніторинг прогресу
2	Недостатня якість даних для моделювання	Неповні або нерелевантні вхідні дані	Зниження точності моделі, потреба у додатковій підготовці	Висока	Середній	Високий	Оцінка даних на ранньому етапі, очищення, доповнення датасету
3	Технічні збої або відмова обладнання	Перевантаження системи, апаратні несправності	Переривання експериментів, втрата даних	Низька	Високий	Середній	Резервне копіювання, використання хмарних сервісів, технічний моніторинг
4	Некоректні результати моделювання	Невірно підібрані параметри, пере-/недотренування	Непридатність моделі для прийняття рішень	Середня	Середній	Середній	Перехресна валідація, підбір гіперпараметрів, тестування альтернативних моделей
5	Ризики кібербезпеки	Уразливості у програмному забезпеченні або мережевій інфраструктурі	Неавторизований доступ, витік інформації	Низька	Високий	Середній	Захист доступів, шифрування, оновлення ПЗ
6	Людський фактор (помилки виконавців)	Недосвідченість, неправильне використання інструментів	Помилки в коді, некоректні експерименти, повторні перерахунки	Середня	Середній	Середній	Проведення інструктажів, внутрішній аудит, парне рецензування
7	Зміна зовнішніх вимог або регуляторних норм	Оновлення стандартів, поява нових умов	Потреба переробити частину рішень або документації	Низька	Середній	Низький	Постійний моніторинг нормативної бази
8	Недостатня продуктивність обраних алгоритмів	Невідповідність обчислювальної складності ресурсам	Затримки у тренуванні моделей, перевищення ресурсних лімітів	Середня	Середній	Середній	Оптимізація коду, використання GPU, вибір ефективніших алгоритмів
9	Неправильне трактування результатів	Недостатній рівень аналітичної підготовки	Помилкові висновки, некоректні рекомендації	Середня	Високий	Високий	Додаткова експертна перевірка, візуалізація та інтерпретація моделей
10	Конфлікти у команді або недостатня комунікація	Невизначені ролі, відсутність регулярних зустрічей	Нескоординованість дій, затримки	Низька	Середній	Низький	Регулярні наради, чіткий розподіл завдань

Джерело: запропоновано автором.

ДОДАТОК В
КОПІЇ ПУБЛІКАЦІЙ



МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ
МІЖНАРОДНИЙ УНІВЕРСИТЕТ «АСТАНА»



ІНФОРМАТИКА, МАТЕМАТИКА, АВТОМАТИКА

ІМА - 2025

**МАТЕРІАЛИ
та програма**

**МІЖНАРОДНОЇ
НАУКОВОЇ КОНФЕРЕНЦІЇ
МОЛОДИХ ВЧЕНИХ**

**(Суми-Астана,
21-25 квітня 2025 року)**

**Суми,
Сумський державний університет
2025**

12. Automation of Software-Defined Network Testing Using Python

Author: Ph.D. student Serhii Shestopalov

13. Task Management and Performance Analysis System for Small and Medium-Sized Businesses

Author: student Dmytro Shelikhov,
Supervisor – assistant Olha Shutylieva

14. Концепція та функціональні можливості інтерактивного тренажеру для вивчення рекурентних нейронних мереж Хопфілда

Автори: здобувач Юлдашова Кумуш,
доцент Шелехов І.В.

15. Класифікаційне прогнозування результатів телемаркетингової компанії

Автори: здобувач Михайлюк Олександр,
доцент Шелехов Ігор

16. Вплив аудиту інформаційної безпеки на захищеність підприємств: Ключові ризики та рекомендації

Автори: здобувач Бабак А.О.,
доцент Ободяк В.К.,
асистент Пугач І.О.

17. Огляд засобів linting (static code analyze) у Python

Автор: здобувач Білоцерківець Б.Р,
Керівник – асистент Шутилєва О.В.

18. Модифікація нечіткого Bees Algorithm з розподіленням рою частинок на групи

Автори: здобувач Плутенко О.Ю.,
старший викладач Шаповалов С.П.

Класифікаційне прогнозування результатів телемаркетингової компанії

Михайлюк Олександр¹, ІСТ-2401м, здобувач;
Шелехов Ігор^{1,2}, доцент

¹Кафедра кібернетики та інформатики Сумського національного аграрного університету, Суми, Україна

²Кафедра комп'ютерних наук Сумського державного університету, Суми, Україна

Метою дослідження є проектування інтелектуальної системи на основі штучних нейронних мереж (ШНМ), здатної до навчання на великих масивах даних прогнозуванню ефективності рекламних кампаній з оптимізацією параметрів мережі для досягнення необхідної точності прогнозу. Об'єктом дослідження є процес класифікаційного прогнозування ефективності рекламної кампанії при аналізі великих даних. Предметом дослідження є методи побудови та оптимізації ШНМ для виявлення закономірностей у наборах даних рекламної аналітики. Методологія передбачає оптимізацію архітектури ШНМ, вибір передатних функцій нейронів та налаштування параметрів навчання для забезпечення ефективності та масштабованості системи.

В рамках дослідження розроблено програмний прототип системи в середовищі MATLAB. Для навчання та валідації моделі використано різномірні клієнтські дані (понад 240 параметрів), що дозволяє побудувати ШНМ здатну до машинного навчання передбаченню ймовірної поведінки споживача щодо запропонованої рекламної акції. Виконано серію обчислювальних експериментів для визначення конфігурації ШНМ з оптимальною прогностичною здатністю.

Результати експериментального тестування на реальній вибірці телекомунікаційної компанії підтвердили високу точність класифікації та здатність моделі виявляти складні нелінійні залежності. Важливо, що розроблена система показала стабільність при роботі з Big Data-масивами, а її модульна структура забезпечує гнучкість налаштувань під специфіку нових рекламних кампаній. Застосування такої системи відкриває можливість зменшити витрати на неефективну рекламу, а й приймати стратегічно обґрунтовані рішення, що базуються на попередньо виявлених закономірностях у поведінці споживачів.

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
СУМСЬКИЙ НАЦІОНАЛЬНИЙ АГРАРНИЙ УНІВЕРСИТЕТ

МАТЕРІАЛИ
ВСЕУКРАЇНСЬКОЇ НАУКОВОЇ
КОНФЕРЕНЦІЇ СТУДЕНТІВ
ТА АСПІРАНТІВ, ПРИСВЯЧЕНОЇ
МІЖНАРОДНОМУ ДНЮ СТУДЕНТА

(17-21 листопада 2025 р., м. Суми)

ІНТЕЛЕКТУАЛЬНА СИСТЕМА АНАЛІЗУ ТА ПРОГНОЗУВАННЯ ЕФЕКТИВНОСТІ ТЕЛЕМАРКЕТИНГОВОЇ КОМПАНІЇ

Михайлюк О.С., студ. 2м курсу курсу ФЕІМ, спец. 126 «Інформаційні системи та технології»
Науковий керівник: доц. І.В. Шелехов
Сумський НАУ

У сучасних умовах цифрової економіки обробка великих масивів інформації стає одним із ключових чинників підвищення ефективності управлінських рішень. Особливо це стосується маркетингової сфери, де успішність рекламних кампаній залежить від точності прогнозування реакції цільової аудиторії. Для вирішення таких завдань доцільно застосовувати технології інтелектуального аналізу даних та штучних нейронних мереж.

Метою дослідження є створення інтелектуальної системи прогнозування результатів рекламних кампаній, здатної автоматизовано аналізувати поведінку клієнтів та формувати рекомендації щодо підвищення ефективності маркетингових заходів. Об'єктом дослідження є слабоформалізований процес класифікаційного прогнозування ефективності реклами. Предметом – алгоритми навчання штучних нейронних мереж у задачах класифікаційного прогнозування.

Аналіз підходів до оцінювання ефективності реклами показує, що вони поділяються на економічні (оцінка прибутковості та рентабельності реклами) та комунікативні (вимірювання впливу на споживачську свідомість). При цьому основні показники результативності рекламної діяльності – GRP, TRP, Reach, CPP, CPT, які дозволяють здійснювати кількісну оцінку інтенсивності рекламної кампанії. Однак традиційні статистичні методи виявляються недостатньо ефективними для виявлення прихованих закономірностей у поведінці споживачів, тому пропонується застосування методів інтелектуального аналізу даних.

Інтелектуальний аналіз даних (data mining) розглядається як процес пошуку нетривіальних, практично значущих знань у великих обсягах інформації. Серед його методів особливе місце займають штучні нейронні мережі, генетичні алгоритми, дерева рішень та нечітка логіка. Для задач прогнозування найефективнішими є нейромережеві моделі, які здатні навчатися на історичних даних, виявляючи складні нелінійні залежності між факторами.

Розроблена система базується на багатошаровому перцептроні зі зворотним поширенням помилки. Такий підхід забезпечує можливість навчання «з учителем» на прикладах із відомими результатами. Навчання мережі здійснюється за алгоритмом градієнтного спуску з мінімізацією функції похибки між очікуваними та реальними результатами класифікації. Для підвищення точності прогнозів проведено оптимізацію функціональних параметрів нейромережі, зокрема коефіцієнта швидкості навчання та кількості нейронів у прихованому шарі.

Інформаційна база для навчання моделі сформована на основі відкритого репозитарію Machine Learning Repository Національного університету Нанджін (Китай). Навчальна вибірка включає 241 параметр, що характеризує клієнтів телекомунікаційної компанії, зокрема соціально-демографічні ознаки, показники активності у користуванні послугами, історію взаємодії з компанією, а також реакцію на попередні рекламні акції. Дані поділено на два класи — клієнти, які прийняли рекламну пропозицію, та ті, що відмовилися. Така класифікація дозволила сформувати навчальну матрицю для побудови нейромережного класифікатора.

Програмна реалізація виконана у середовищі MATLAB з використанням пакету Neural Network Toolbox, який забезпечує інструментарій для побудови, навчання та тестування нейромереж різних архітектур. Розроблені m-сценарії дозволяють здійснювати завантаження навчальних даних, налаштування параметрів мережі, запуск процедури навчання та візуалізацію результатів. Під час тестування мережа продемонструвала високу точність класифікації, що підтвердило ефективність застосованого підходу.

Практичне значення отриманих результатів полягає у можливості використання запропонованої системи для планування рекламних бюджетів, сегментації ринку, оптимізації каналів комунікації та підвищення ефективності маркетингової діяльності підприємств.

У перспективі розвиток проєкту передбачає інтеграцію розробленої системи з корпоративними базами даних, розширення функціональності шляхом застосування гібридних нейроволюційних моделей і методів нечіткої класифікації, а також адаптацію для прогнозування результатів соціальних, освітніх та інформаційних кампаній.

Список використаних джерел

1. Романенко П. В. Інтегровані підходи до підвищення надійності програмно-апаратних комплексів. – Львів: Видавництво ЛНУ, 2023. – 198 с.
2. Романенко В. Управління якістю інформаційних технологій у процесі цифрової трансформації. Бізнес Інформ. 2025.

ДОДАТОК Г

ПРОГРАМНИЙ КОД

Проект складається з:

Сценарії:

1. `train_main.m` — базове навчання мережі.
2. `optimize_transfer_functions.m` — оптимізація функцій активації.
3. `optimize_hidden_neurons.m` — пошук оптимальної кількості нейронів.

Функції:

- `load_data.m` — зчитування матриць даних.
- `prepare_dataset.m` — формування P та T .
- `evaluate_results.m` — оцінювання точності класифікації.
- `train_network.m` — універсальна функція тренування.

```
function [P, T] = load_data(fileA, fileB, samplesPerClass, features)
%LOAD_DATA Завантажує дані з двох файлів та формує матрицю ознак
%   fileA, fileB — текстові файли з даними
%   samplesPerClass — кількість прикладів одного класу
%   features — кількість ознак (довжина вектора)

fid = fopen(fileA);
dataA = fscanf(fid, '%g');
fclose(fid);

fid = fopen(fileB);
dataB = fscanf(fid, '%g');
fclose(fid);

A = reshape(dataA, samplesPerClass, features);
B = reshape(dataB, samplesPerClass, features);

P = [A' B'];

T = [zeros(1, samplesPerClass), ones(1, samplesPerClass)];
end

function net = train_network(P, T, hiddenNeurons, transferFcn)
%TRAIN_NETWORK Створює та тренує двошарову мережу
%   transferFcn — назва функції активації (string)
```

```

    net = newff(minmax(P), [hiddenNeurons 1], {transferFcn,
transferFcn});
    net.trainParam.epochs = 100;
    net.trainParam.show = 1;

    net = train(net, P, T);
end

function metrics = evaluate_results(net, P, T)
%EVALUATE_RESULTS Обчислює MSE, загальну точність та точність по
класах

    y = round(sim(net, P));

    mseVal = mse(y - T);
    acc = mean(y == T);

    idx1 = find(T == 1);
    idx0 = find(T == 0);

    acc1 = mean(y(idx1) == T(idx1));
    acc0 = mean(y(idx0) == T(idx0));

    metrics = struct('MSE', mseVal, 'Accuracy', acc, ...
                    'AccClass1', acc1, 'AccClass0', acc0);
end

clear; clc;

samples = 48;
features = 241;
hiddenNeurons = 10;
transferFcn = 'tansig';

[P, T] = load_data('1.txt', '2.txt', samples, features);

net = train_network(P, T, hiddenNeurons, transferFcn);

results = evaluate_results(net, P, T);

disp('=== BASIC TRAINING RESULTS ===');
disp(results);

```

```

clear; clc;

samples = 48;
features = 241;
hiddenNeurons = 10;

activationList = {'tansig', 'purelin', 'logsig'};

[P, T] = load_data('1.txt', '2.txt', samples, features);

for i = 1:length(activationList)
    act = activationList{i};
    fprintf('\n=== Testing activation: %s ===\n', act);

    net = train_network(P, T, hiddenNeurons, act);
    metrics(i) = evaluate_results(net, P, T);

    disp(metrics(i));
end

clear; clc;

samples = 48;
features = 241;

[P, T] = load_data('1.txt', '2.txt', samples, features);

maxNeurons = 20;
results = struct([]);

for h = 1:maxNeurons
    fprintf('\n=== Testing hidden neurons: %d ===\n', h);

    bestMSE = inf;

    for iter = 1:100
        net = train_network(P, T, h, 'logsig');
        metrics = evaluate_results(net, P, T);
        if metrics.MSE < bestMSE
            bestMSE = metrics.MSE;
            results(h) = metrics;
        end
    end
    results(h).HiddenNeurons = h;
    disp(results(h));
end

```