

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ДОНЕЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ВАСИЛЯ
СТУСА

КОРОЛЕНКО ОЛЕКСАНДР ОЛЕКСІЙОВИЧ

Допускається до захисту:

В.о. завідувача кафедри
інформаційних технологій
канд. техн. наук, доцент

_____ Оксана ЗЕЛІНСЬКА

«_____» _____ 2025р.

СИСТЕМИ ПРИЙНЯТТЯ РІШЕНЬ НА ОСНОВІ МЕРЕЖ БАЙЕСА

Спеціальність 122 Комп'ютерні науки

Кваліфікаційна (бакалаврська) робота

Керівник:

Роштейн Олександр Петрович
д.т.н., професор кафедри
інформаційних технологій

Оцінка: _____ / _____ / _____

(бали/за шкалою ЄКТС/за національною шкалою)

Голова ЕК: _____

Вінниця – 2025

АНОТАЦІЯ

Анотація:

У бакалаврській роботі досліджено системи прийняття рішень на основі байєсівських мереж. Розроблено програмний засіб для моделювання, аналізу та візуалізації процесів прийняття рішень в умовах невизначеності. Реалізовано побудову структури мережі, навчання моделі та прогнозування. Робота акцентує увагу на причинно-наслідкових зв'язках і оптимізації мережі. Запропоноване рішення є актуальним для застосування в медицині, фінансах та інших галузях.

Ключові слова: байєсівські мережі, прийняття рішень, машинне навчання, ймовірнісне моделювання.
53 с. 13 рис., 13 табл., 40 джерела.

ANNOTATION

Abstract:

In the bachelor's thesis, decision-making systems based on Bayesian networks are studied. A software tool for modeling, analyzing, and visualizing decision-making processes under uncertainty has been developed. The construction of the network structure, model training, and forecasting have been implemented. The work emphasizes causal relationships and network optimization. The proposed solution is relevant for application in medicine, finance, and other fields.

Keywords: Bayesian networks, decision making, machine learning, probabilistic modeling.

ЗМІСТ

ВСТУП.....	5
РОЗДІЛ 1. БАЙЄСІВСЬКІ МЕРЕЖІ ЯК ІНСТРУМЕНТ ПРИЙНЯТТЯ РІШЕНЬ	10
1.1. Постановка задачі.....	10
1.2. Теоретичні основи байєсівських мереж.....	13
1.3. Основи ймовірнісного мислення у прийнятті рішень.....	15
1.4. Порівняння байєсівських мереж з іншими методами прийняття рішень	17
1.5 Математичне обґрунтування та приклад ймовірнісного виведення у байєсівських мережах.....	20
РОЗДІЛ 2. ПРОЕКТУВАННЯ СИСТЕМИ ПРИЙНЯТТЯ РІШЕНЬ.....	21
2.1. Архітектура програмного забезпечення.....	21
2.2. Побудова структури байєсівської мережі.....	24
2.3. Формалізація змінних та залежностей.....	27
2.4. Алгоритми навчання байєсівських мереж.....	28
2.5. Інструменти реалізації та інтеграція з API.....	31
РОЗДІЛ 3. РОЗРОБКА ТА ТЕСТУВАННЯ СИСТЕМИ.....	36
3.1. Розробка модулів побудови та навчання мережі.....	36
3.2. Алгоритм функціонування програмного продукту.....	40
3.3. Інтерфейс користувача та сценарії використання.....	42
3.4. Тестування, валідація та оцінка якості рішень.....	43
ВИСНОВКИ.....	45
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	49
ДОДАТКИ.....	53

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

БМ – Байєсівська мережа
ВЗД – Видобуток знань з даних
ВМД – Великі масиви даних
ПЗ – Програмне забезпечення
СПР – Система прийняття рішень
ЙМ – Ймовірнісне моделювання
ІІ – Штучний інтелект
API – Application Programming Interface
CSV – Comma-Separated Values
KDD – Knowledge Discovery in Databases
ML – Machine Learning (машинне навчання)
JSON – JavaScript Object Notation
GUI – Graphical User Interface
PWA – Progressive Web Application
SPA – Single Page Application
REST – Representational State Transfer
SOAP – Simple Object Access Protocol
PPDAC – Problem, Plan, Data, Analysis, Conclusion
UML – Unified Modeling Language

ВСТУП

Актуальність

У сучасному світі, що характеризується стрімким розвитком інформаційних технологій, експоненціальним зростанням обсягів даних та підвищенням складності процесів прийняття рішень, виникає гостра потреба в інтелектуальних системах, здатних ефективно обробляти великі масиви інформації та надавати обґрунтовані прогнози в умовах невизначеності. Сьогодні управлінські, економічні, технологічні та соціальні рішення часто приймаються в умовах неповноти даних[2], шумів або суперечливої інформації, що може призводити до помилок та значних ризиків. У таких умовах традиційні методи прийняття рішень[5], що базуються на детермінованих підходах, виявляються недостатньо ефективними, адже вони не враховують ймовірнісну природу багатьох реальних процесів.

Одним із найперспективніших інструментів для вирішення таких задач є баєсові мережі — ймовірнісні графічні моделі, що дозволяють формалізувати причинно-наслідкові зв'язки між змінними, враховувати невизначеність і обробляти неповні або зашумлені дані. Баєсові мережі забезпечують компактне представлення складних систем, дозволяють оновлювати ймовірності подій при надходженні нової інформації та надають пояснення до прийнятих рішень, що є критично важливим у сферах із високими вимогами до прозорості, таких як медицина, фінансова аналітика чи безпека.

Незважаючи на значний прогрес у галузі машинного навчання [3], аналізу даних та штучного інтелекту, практичне застосування баєсових мереж у системах прийняття рішень залишається недостатньо дослідженим, особливо в контексті їхньої інтеграції з сучасними технологіями та адаптації до реальних прикладних задач. Більшість досліджень зосереджені на теоретичних аспектах [4], таких як розробка алгоритмів ймовірнісного виведення чи методів навчання, тоді як питання створення адаптивних моделей, що можуть навчатися на основі реальних даних, інтегруватися з веб-технологіями та забезпечувати інтерактивну взаємодію з користувачем, залишаються відкритими. Наприклад, у медичній діагностиці баєсові мережі можуть прогнозувати ймовірність захворювання на основі симптомів і результатів тестів, але практичні реалізації часто стикаються з

проблемами масштабування, обробки великих обсягів даних і забезпечення зручного інтерфейсу для лікарів.

Крім того, сучасні інформаційні системи дедалі частіше потребують рішень, що працюють у реальному часі та здатні адаптуватися до змін умов. Наприклад, у фінансовій сфері необхідно швидко реагувати на ринкові коливання, враховуючи невизначеність економічних факторів, а в логістиці — оптимізувати маршрути з урахуванням погодних умов, трафіку та інших змінних. Баєсові мережі мають потенціал для вирішення таких задач, але їхнє практичне впровадження потребує створення комплексних програмних рішень, які поєднують можливості моделювання, навчання, прогнозування та інтеграції з іншими системами. Саме тому розробка системи прийняття рішень на основі сітей Баєса, що враховує сучасні технологічні вимоги, є актуальною задачею, яка має як теоретичне, так і практичне значення.

Мета дослідження

Метою бакалаврської роботи є розробка системи прийняття рішень на основі сітей Баєса, яка забезпечує моделювання ймовірнісних залежностей між параметрами, прогнозування результатів і прийняття обґрунтованих рішень в умовах невизначеності. Система має бути універсальним інструментом, придатним для використання в різних предметних областях, забезпечуючи високу точність прогнозів, пояснюваність результатів та зручність інтеграції з іншими інформаційними платформами.

Для досягнення цієї мети система має включати модулі для введення даних, побудови структури мережі, навчання моделі, ймовірнісного виведення та візуалізації результатів. Вона повинна підтримувати як ручне налаштування експертами, так і автоматичне навчання на основі даних, що дозволяє адаптувати її до різних сценаріїв використання. Наприклад, у медичній сфері система може допомагати лікарям визначати ймовірність діагнозу, у фінансовій — оцінювати ризики інвестицій, а в логістиці — оптимізувати маршрути з урахуванням невизначених факторів.

Завдання дослідження

Для досягнення поставленої мети в роботі необхідно виконати такі завдання:

1. Узагальнити теоретичні основи побудови баєсових мереж, включаючи принципи їхньої роботи, математичне обґрунтування та методи ймовірнісного виведення. Це передбачає аналіз теореми Байєса, концепції умовної незалежності та алгоритмів, таких як Variable Elimination і Junction Tree.
2. Дослідити методи навчання та використання сітей Баєсау процесі прийняття рішень, зокрема структурне навчання (Hill-Climbing, PC Algorithm), параметричне навчання (Maximum Likelihood Estimation, Expectation-Maximization) та методи оцінки якості моделей (BIC, AIC).
3. Розробити архітектуру програмного забезпечення для побудови, навчання та візуалізації баєсової моделі, що включає модульну структуру, підтримку інтеграції через API та зручний інтерфейс для користувачів.
4. Реалізувати модулі введення даних, побудови мережі, навчання, ймовірнісного виведення та аналізу результатів, забезпечивши їхню взаємодію та ефективність. Наприклад, модуль введення даних має підтримувати обробку великих масивів даних із пропусками, а модуль аналізу — надавати пояснення до прогнозів.
5. Проаналізувати ефективність роботи моделі на тестових даних, оцінити точність прийнятих рішень та порівняти результати з іншими методами (наприклад, деревами рішень або нейронними мережами). Це включає оцінку метрик, таких як точність прогнозування, час обчислень та пояснюваність результатів.

Виконання цих завдань дозволить створити комплексну систему, яка поєднує теоретичні основи баєсових мереж із практичними аспектами їхнього застосування, забезпечуючи високу точність і адаптивність у різних сценаріях.

Об'єкт дослідження

Об'єктом дослідження є процес прийняття рішень в умовах невизначеності за допомогою методів аналізу даних. Це включає аналіз складних систем, де рішення залежать від багатьох взаємопов'язаних факторів, а інформація може бути неповною або суперечливою. Наприклад,

у медичній діагностиці об'єктом є процес визначення діагнозу на основі симптомів і тестів, у фінансовій сфері — оцінка ризиків на основі економічних показників, а в логістиці — оптимізація маршрутів із урахуванням зовнішніх умов.

Предмет дослідження

Предметом дослідження є методологія побудови, навчання та використання баєсових мереж у системах прийняття рішень. Це включає вивчення структури мереж, методів формалізації змінних і залежностей, алгоритмів навчання та виведення, а також їхньої інтеграції з сучасними технологіями. Особлива увага приділяється адаптивності моделей, їхній здатності працювати з реальними даними та забезпечувати пояснюваність рішень, що є ключовим для прикладних задач.

Теоретичне та практичне значення одержаних результатів

Теоретичне значення роботи полягає в систематизації підходів до побудови баєсових мереж та їхнього використання у прогнозуванні та прийнятті рішень. У рамках дослідження узагальнено основні методи навчання, проаналізовано їхні переваги та недоліки, а також запропоновано рекомендації щодо оптимізації обчислень та підвищення точності моделей. Це створює основу для подальших досліджень у сфері ймовірнісного моделювання, зокрема в контексті гібридних і динамічних баєсових мереж, які враховують часові залежності або поєднують дискретні та неперервні змінні.

Практичне значення роботи полягає у створенні програмного інструменту, який може бути використаний у різних прикладних сферах для обґрунтованого прийняття рішень на основі наявних даних. Розроблена система дозволяє моделювати ймовірнісні залежності, прогнозувати результати та надавати пояснення до рішень, що робить її цінною для таких галузей, як:

Медицина: прогнозування діагнозів, оцінка ймовірності ускладнень, персоналізація лікування на основі історії хвороби.

Фінансова аналітика: оцінка ризиків інвестицій, прогнозування ринкових тенденцій, аналіз кредитоспроможності клієнтів.

Логістика: оптимізація маршрутів, прогнозування затримок з урахуванням погодних умов і трафіку.

Кібербезпека: виявлення загроз та оцінка ймовірності атак на основі поведінки користувачів і мережевих даних.

Система підтримує інтеграцію через API, що дозволяє використовувати її як частину більших інформаційних платформ, а також масштабувати для роботи з великими масивами даних. Наприклад, у медичному контексті вона може бути інтегрована з електронними медичними системами (EHR), забезпечуючи автоматичне оновлення моделей на основі нових даних про пацієнтів.

Апробація результатів дослідження

Основні положення, висновки та результати кваліфікаційної (бакалаврської) роботи на тему «Розробка інтелектуальної системи підтримки прийняття рішень на основі байєсівських мереж» були апробовані шляхом підготовки тез доповіді та участі в науково-практичній конференції.

Структура кваліфікаційної (бакалаврської) роботи

Робота складається зі вступу, трьох розділів, висновків, списку використаних джерел та додатків. У першому розділі розглянуто теоретичні основи побудови баєсових мереж. У другому – описано архітектуру системи та алгоритми реалізації. У третьому – подано результати реалізації програмного забезпечення, приклади моделювання та аналізу результатів. Робота містить . рисунків, . таблиці, . використаних джерел та . додатки.

РОЗДІЛ 1. БАЙЄСІВСЬКІ МЕРЕЖІ ЯК ІНСТРУМЕНТ ПРИЙНЯТТЯ РІШЕНЬ

1.1 Постановка задачі

У сучасному світі, де обсяги даних зростають експоненціально, а процеси прийняття рішень ускладнюються через невизначеність і багатогранність інформації, виникає потреба в інтелектуальних системах, здатних аналізувати складні взаємозв'язки та надавати обґрунтовані прогнози. Байєсівські мережі, як ймовірнісні графічні моделі, є одним із найперспективніших інструментів для моделювання причинно-наслідкових залежностей[1] і прийняття рішень у таких умовах. Вони дозволяють формалізувати невизначеність, обробляти неповні дані та адаптуватися до динамічних змін у предметній області.

Метою даного дослідження є розробка системи прийняття рішень (СПР) на основі байєсівських мереж, яка забезпечує моделювання, аналіз і візуалізацію процесів прийняття рішень у різних прикладних сферах, таких як медицина, фінанси чи логістика. Система має бути модульною, масштабованою та придатною для інтеграції з сучасними інформаційними середовищами. Для досягнення цієї мети необхідно вирішити такі завдання:

1. Узагальнити теоретичні основи байєсівських мереж і їхнього застосування в задачах прийняття рішень.
2. Розробити архітектуру програмного забезпечення, що підтримує побудову, навчання та використання байєсівських моделей.
3. Формалізувати змінні та залежності для точного представлення предметної області.
4. Реалізувати алгоритми навчання мережі та ймовірнісного виведення для прогнозування.
5. Забезпечити інтеграцію системи з зовнішніми джерелами даних через API.
6. Провести тестування та оцінити точність і ефективність прийнятих рішень.

Основні виклики, які необхідно подолати в процесі розробки, включають:

Обробку великих масивів даних (ВМД), що часто містять пропуски, шум або гетерогенні формати.

Оптимізацію обчислювальної складності при роботі з великими мережами, де кількість вузлів може досягати сотень.

Забезпечення пояснюваності рішень, що є критичним у сферах із високими вимогами до прозорості, наприклад, у медичній діагностиці чи оцінці фінансових ризиків.

Адаптацію до динамічних умов, коли структура мережі або вхідні дані змінюються в реальному часі.

Наприклад, у медичних системах СПР має обробляти складні набори змінних, такі як симптоми, результати аналізів і анамнез, для прогнозування діагнозу з високою точністю. У фінансовій аналітиці система може оцінювати ризики інвестицій, враховуючи нестабільність ринкових умов і макроекономічні фактори. Розробка базується на сучасних підходах до ймовірнісного моделювання, враховуючи вимоги до продуктивності, масштабованості та зручності інтеграції.

Для вирішення цих завдань передбачається використання автоматизованих методів побудови структури мережі, алгоритмів навчання, таких як Expectation-Maximization, і оптимізованих технік ймовірнісного виведення, таких як Variable Elimination. Крім того, система має підтримувати інтерактивний інтерфейс для користувачів і API для інтеграції з базами даних чи сенсорами.




Рисунок 1.1 Схема процесу прийняття рішень у байєсівській мережі

Таким чином, чітке формулювання задачі визначає цілі, виклики та вимоги до системи, що відповідає сучасним потребам у сфері інтелектуального аналізу даних і прийняття рішень.

1.2 Теоретичні основи байєсівських мереж

Байєсівські мережі (БМ) є ймовірнісними графічними моделями, які використовуються для представлення залежностей між випадковими змінними у вигляді орієнтованого ациклічного графа (DAG). У такому графі кожна вершина відповідає змінній, а дуги між вершинами вказують на умовні залежності. БМ дозволяють компактно моделювати складні системи [6] [7], де взаємодії між елементами мають ймовірнісну природу, що робить їх ефективними для задач із невизначеністю.

Теоретичною основою БМ є теорема Байєса, яка описує, як оновлювати ймовірність гіпотези при надходженні нової інформації. Формально вона записується як:

Формула Байєса

$$P(A | B) = P(B | A) * P(A) / P(B)$$

де $P(A | B)$ — умовна ймовірність події A за умови B, $P(B | A)$ — умовна ймовірність B, $P(A)$ і $P(B)$ — апіорні ймовірності подій A і B, відповідно. Ця формула є основою для ймовірнісного виведення, яке дозволяє обчислювати ймовірності цільових змінних за наявності свідчень.

Ключовою особливістю БМ є використання умовної незалежності, що значно зменшує кількість параметрів, необхідних для опису моделі. Наприклад, якщо змінні A і C умовно незалежні за умови B, то $P(A, C | B) = P(A | B)P(C | B)$. Це спрощує обчислення та підвищує ефективність роботи з великими наборами даних.

Процес роботи з БМ включає три основні етапи:

1. Побудова структури мережі: визначення змінних (вузлів) і залежностей (дуг) на основі експертних знань або автоматичного аналізу даних.
2. Оцінка параметрів: обчислення умовних ймовірностей для кожної вершини, використовуючи статистичні дані або експертні оцінки.

3. Ймовірнісне виведення: обчислення ймовірностей цільових змінних за наявності свідчень, використовуючи алгоритми, такі як Variable Elimination або Junction Tree.

БМ застосовуються в різноманітних сферах, включаючи медичну діагностику, фінансову аналітику, прогнозування погоди та аналіз надійності технічних систем. Наприклад, у медичних системах БМ оцінюють ймовірність захворювання на основі симптомів і результатів тестів, оновлюючи прогнози при надходженні нових даних. У фінансовій сфері вони допомагають моделювати ризики, враховуючи ринкові фактори.

Динамічні байєсівські мережі (DBN) розширюють можливості статичних моделей, дозволяючи враховувати часові залежності. Наприклад, у задачах прогнозування фінансових ринків DBN моделюють еволюцію цін акцій із урахуванням попередніх станів. Гібридні БМ, що поєднують дискретні та неперервні змінні[8], є актуальними для медичних систем, де такі показники, як рівень глюкози, є неперервними, а діагнози — дискретними.

БМ також відіграють важливу роль у причинному аналізі, дозволяючи виявляти причинно-наслідкові зв'язки, на відміну від кореляційних моделей. Алгоритми причинного виведення, такі як do-calculus[9], розроблені Перлом, забезпечують формальну основу для таких досліджень.

Таблиця 1.1 Порівняння статичних і динамічних байєсівських мереж

Тип мережі	Опис	Застосування	Переваги	Недоліки
Статичні байєсівські мережі	Моделі, що представляють ймовірнісні залежності між змінними без урахування часу.	Медична діагностика, оцінка фінансових ризиків, аналіз причинно-наслідкових зв'язків.	Проста реалізація, компактність, ефективність для статичних даних.	Не враховують часові залежності, обмежені в динамічних сценаріях.
Динамічні байєсівські мережі (DBN)	Розширення статичних моделей, що враховують часові залежності між змінними.	Прогнозування часових рядів, фінансовий аналіз, моніторинг систем у реальному часі.	Можливість моделювання часових процесів, висока гнучкість.	Висока обчислювальна складність, потреба у великих обсягах даних.

Теоретичні основи БМ роблять їх універсальним інструментом для моделювання складних систем із невизначеністю, забезпечуючи високу точність і пояснюваність результатів.

1.3 Основи ймовірнісного мислення у прийнятті рішень

Ймовірнісне мислення є фундаментальним підходом до прийняття рішень в умовах невизначеності, коли точний результат передбачити неможливо. Воно передбачає оцінку ймовірностей подій і їхнє оновлення на основі нової інформації, що дозволяє приймати обґрунтовані рішення навіть за наявності неповних або неточних даних. Байєсівські мережі є практичною реалізацією цього підходу, надаючи інструменти для моделювання залежностей і обчислення умовних ймовірностей. [11]

Основні принципи ймовірнісного мислення включають:

Оцінка невизначеності: замість категоричних тверджень («подія відбудеться»), використовується ймовірнісна оцінка (наприклад, «ймовірність 80%»).

Аналіз залежностей: визначення впливу однієї події на іншу, наприклад, як наявність симптому впливає на ймовірність захворювання.

Оновлення знань: використання теореми Байєса для перерахунку ймовірностей при надходженні нових даних.

Ймовірнісне мислення забезпечує низку переваг: Зменшення ризиків шляхом врахування різних сценаріїв розвитку подій.

Створення адаптивних стратегій, що змінюються залежно від нової інформації. Рациональне використання обмежених або неточних даних, що є типовим для реальних систем.

Наприклад, у фінансовій аналітиці ймовірнісне мислення дозволяє оцінити ризик дефолту позичальника, враховуючи економічні показники, історію платежів і ринкові умови. У медичній діагностиці воно допомагає уточнити діагноз на основі результатів додаткових тестів, знижуючи ймовірність помилок [12].

Суб'єктивні ймовірності, засновані на експертних оцінках, відіграють важливу роль у ситуаціях із обмеженими даними. Наприклад, у задачах оцінки кіберзагроз експерти можуть визначити апріорні ймовірності атак, які потім уточнюються за допомогою байєсівського оновлення. Ймовірнісне мислення також допомагає уникнути когнітивних упереджень, таких як переоцінка рідкісних подій або недооцінка невизначеності, що часто трапляється в людському мисленні.

Для підвищення ефективності ймовірнісного мислення можна застосовувати сценарний аналіз. Наприклад, у фінансовій сфері система

може генерувати кілька сценаріїв (оптимістичний, нейтральний, песимістичний) на основі ймовірнісних прогнозів, що допомагає підготуватися до різних варіантів розвитку подій. У медичних системах сценарний аналіз може передбачати різні комбінації симптомів для оцінки ймовірності рідкісних захворювань [13].



Рисунок 1.2 Графік, що ілюструє процес оновлення ймовірностей у байєсівській мережі

Ймовірнісне мислення, підкріплене байєсівськими мережами, забезпечує раціональний і обґрунтований підхід до прийняття рішень у складних системах із високим рівнем невизначеності.

1.4 Порівняння байєсівських мереж з іншими методами прийняття рішень

Байєсівські мережі (БМ) є потужним інструментом для моделювання процесів прийняття рішень, але для повного розуміння їхніх можливостей необхідно порівняти їх з іншими популярними методами. Кожен метод має свої переваги, недоліки та сфери застосування, що впливають на вибір інструменту для конкретної задачі. [14]

Дерева рішень:

Дерева рішень представляють процес прийняття рішень у вигляді ієрархічної структури, де кожен вузол відповідає вибору або події, а гілки — можливим результатам. Вони прості у побудові та інтуїтивно зрозумілі, що робить їх популярними для нескладних задач. Однак при великій кількості змінних розмір дерева зростає експоненціально, що ускладнює обробку складних систем. БМ, навпаки, компактно моделюють залежності завдяки умовній незалежності, що забезпечує ефективність при роботі з великими наборами даних.

Нечіткі системи:

Нечіткі системи базуються на нечіткій логіці, що дозволяє працювати з якісними або нечіткими даними, такими як «висока ймовірність» чи «середній ризик». Вони ефективні для задач із лінгвістичними оцінками, але потребують складного визначення правил і можуть бути суб'єктивними. БМ автоматично навчаються з даних, що зменшує залежність від ручного налаштування і підвищує універсальність.

Експертні системи:

Експертні системи використовують знання експертів, закодовані у вигляді правил «якщо-то». Вони забезпечують високу точність за умови якісних правил, але їх складно оновлювати при зміні даних, що вимагає постійної участі експертів. БМ автоматично адаптуються до нових даних, що робить їх більш гнучкими в динамічних умовах.

Машинне навчання:


Моделі машинного навчання, такі як нейронні мережі, випадкові ліси чи градієнтний бустинг, демонструють високу точність при обробці великих наборів даних, особливо в задачах класифікації та прогнозування. Однак вони часто є «чорними ящиками», що ускладнює інтерпретацію рішень. БМ, навпаки, надають прозору структуру причинно-наслідкових зв'язків, що є перевагою в задачах, де потрібна пояснюваність, наприклад, у медичній діагностиці. [15]

Метод Монте-Карло:

Метод Монте-Карло моделює ймовірності шляхом генерації випадкових вибірок, що дозволяє працювати з високовмірними системами та складними розподілами. Однак він потребує значних обчислювальних ресурсів і не забезпечує чіткої інтерпретації причинно-наслідкових зв'язків. БМ пропонують точніше моделювання залежностей із меншими витратами ресурсів . [16]

Марківські моделі:

Марківські моделі моделюють послідовності подій, де поточний стан залежить лише від попереднього. Вони ефективні для динамічних систем, таких як прогнозування часових рядів, але менш гнучкі у моделюванні складних залежностей між змінними. БМ дозволяють враховувати багатосторонні зв'язки, що робить їх більш універсальними . [17]



Таблиця 1.2 – Порівняння методів прийняття рішень

Метод	Переваги	Недоліки	Застосування
Байєсівські мережі	Прозорість, адаптивність, здатність моделювати складні залежності.	Обчислювальна складність великих мереж, потреба у якісних даних.	Медична діагностика, фінансовий аналіз, оцінка ризиків.
Дерева рішень	Простота побудови, інтуїтивна зрозумілість, легка інтерпретація.	Експоненціальне зростання розміру при багатьох змінних, схильність до перенавчання.	Класифікація, прості бізнес-аналітичні задачі.
Нечіткі системи	Робота з якісними оцінками, гнучкість у лінгвістичних даних.	Складність визначення правил, суб'єктивність.	Управління системами, автоматизація, лінгвістичний аналіз.
Експертні системи	Висока точність за якісних правил, використання експертних знань.	Складність оновлення, залежність від експертів, низька адаптивність.	Медицина, технічна діагностика, консультування.

Машинне навчання	Висока точність, здатність працювати з великими даними.	Низька пояснюваність («чорний ящик»), потреба у великих наборах даних.	Прогнозування, класифікація, обробка зображень.
Метод Монте-Карло	Робота з високowymірними системами, точність у складних розподілах.	Висока обчислювальна складність, відсутність інтерпретації причинності.	Оцінка ризиків, фінансове моделювання, симуляції.
Марківські моделі	Ефективність у динамічних системах, простота моделювання послідовностей.	Обмежена гнучкість у моделюванні складних залежностей.	Прогнозування часових рядів, обробка сигналів, біоінформатика.

1.5 Математичне обґрунтування та приклад ймовірнісного виведення

Байєсівські мережі базуються на строгих математичних принципах, що забезпечують їхню надійність і точність. Ключові концепції включають:

Теорема Байєса:

$$P(A|B) = (P(B|A) * P(A)) / P(B)$$

Правило ланцюга:

$$P(X_1, X_2, \dots, X_n) = \prod P(X_i | \text{Parents}(X_i))$$

Умова незалежності: Якщо змінні A і C умовно незалежні за B, то $P(A, C|B) = P(A|B) * P(C|B)$

Ймовірнісне виведення в БМ виконується за допомогою алгоритмів, таких як Variable Elimination (VE) або Junction Tree. VE зменшує обчислювальну

складність, послідовно усуваючи змінні, що не входять до запиту. Наприклад, для мережі з трьома змінними $A \rightarrow B \rightarrow C$ і запиту $P(A|C=c)$:

$$P(A|c) = \sum_B P(A) P(B|A) P(c|B)$$

Цей підхід значно швидший за повне перебрання всіх комбінацій, особливо у великих мережах.

Приклад: Діагностика грипу

Розглянемо задачу діагностики грипу. Змінні: «Грип» (G), «Лихоманка» (F), «Біль у м'язах» (M).

Структура мережі: $G \rightarrow F, G \rightarrow M$. Вхідні ймовірності:

$$P(G = \text{так}) = 0.1, P(G = \text{ні}) = 0.9$$

$$P(F = \text{так}|G = \text{так}) = 0.9, P(F = \text{так}|G = \text{ні}) = 0.3$$

$$P(M = \text{так}|G = \text{так}) = 0.8, P(M = \text{так}|G = \text{ні}) = 0.1$$

Запит: Обчислити $P(G = \text{так}|F = \text{так}, M = \text{так})$.

Чисельник:

$$\begin{aligned} P(G = \text{так}, F = \text{так}, M = \text{так}) &= P(G = \text{так}) P(F = \text{так}|G = \text{так}) P(M = \text{так}|G = \text{так}) \\ &= 0.1 * 0.9 * 0.8 = 0.072 \end{aligned}$$

Знаменник:

$$\begin{aligned} P(F = \text{так}, M = \text{так}) &= \sum_G P(G) P(F = \text{так}|G) P(M = \text{так}|G) \\ &= 0.1 * 0.9 * 0.8 + 0.9 * 0.3 * 0.1 = 0.072 + 0.027 = 0.099 \end{aligned}$$

Результат:

$$P(G = \text{так}|F = \text{так}, M = \text{так}) = 0.072 / 0.099 \approx 0.571$$

Висновок: Ймовірність того, що пацієнт має грип за наявності лихоманки та болю в м'язах, становить приблизно 57.1%.

Для порівняння розглянемо альтернативний сценарій, де відомо лише $F=\text{так}$. У цьому випадку обчислення будуть аналогічними, але з урахуванням лише F , що дасть нижчу ймовірність, демонструючи важливість додаткових свідчень.

РОЗДІЛ 2. ПРОЕКТУВАННЯ СИСТЕМИ ПРИЙНЯТТЯ РІШЕНЬ

2.1 Архітектура програмного забезпечення

Архітектура системи прийняття рішень на основі байєсівських мереж розроблена з урахуванням принципів модульності, масштабованості та інтеграції, що забезпечує її гнучкість і придатність для різних прикладних задач. Система складається з кількох ключових компонентів, які охоплюють повний цикл обробки даних: від введення інформації до генерації рішень і їхньої візуалізації. [18][19].

Основні модулі системи:

1. Модуль побудови структури мережі: відповідає за створення орієнтованого ациклічного графа (DAG), визначення змінних (вузлів) і залежностей (дуг). Підтримує як ручне введення експертами, так і автоматичне навчання з даних, використовуючи алгоритми, такі як Hill-Climbing. [20].
2. Модуль обробки даних: виконує попередню обробку вхідних даних, включаючи нормалізацію, дискретизацію та очищення від аномалій. Забезпечує побудову таблиць умовних ймовірностей (CPT) для кожної змінної. [21].
3. Модуль навчання: реалізує алгоритми структурного та параметричного навчання, дозволяючи адаптувати модель до нових даних. Підтримує методи, такі як Expectation-Maximization для неповних даних.
4. Модуль ймовірнісного виведення: виконує обчислення умовних ймовірностей для прогнозування та прийняття рішень, використовуючи алгоритми, такі як Variable Elimination. [22].
5. Інтерфейс користувача: веб- або десктоп-додаток, що забезпечує введення даних, візуалізацію мережі та перегляд результатів. Підтримує інтерактивні графіки та сценарії використання.
6. Модуль інтеграції: REST або GraphQL API для взаємодії з зовнішніми системами, такими як бази даних, сенсори чи інші інформаційні платформи. [23].

7. Модуль безпеки та логування: забезпечує захист даних, авторизацію користувачів (наприклад, через OAuth) і аудит операцій для відстеження роботи системи.

Для підвищення продуктивності система включає модуль кешування результатів обчислень, що зменшує час обробки повторних запитів. Наприклад, у медичній системі кешування може зберігати результати діагностики для типових комбінацій симптомів, що прискорює роботу в реальному часі. Підтримка розподілених обчислень через фреймворки, такі як Apache Spark, дозволяє обробляти великі мережі з тисячами вузлів, що актуально для фінансових систем або IoT-додатків . [24].

Архітектура підтримує контейнеризацію через Docker, що забезпечує легке розгортання на різних платформах і відтворюваність середовища. Інтеграція з хмарними платформами, такими як AWS або Google Cloud, дозволяє масштабувати обчислення та зберігання даних, що особливо важливо для обробки великих масивів даних у реальному часі . Наприклад, у системі моніторингу клімату хмарні сервіси можуть обробляти дані з тисяч сенсорів, оновлюючи модель мережі в реальному часі. [25].

Для забезпечення відмовостійкості система включає механізми резервного копіювання даних і автоматичного відновлення після збоїв. Логування всіх операцій дозволяє аналізувати продуктивність і виявляти потенційні помилки, що є критичним для промислових застосувань .




Рисунок 2.1 Схема архітектури системи прийняття рішень.

На зображенні представлено схему архітектури системи прийняття рішень. Вона складається з послідовно пов'язаних блоків, які ілюструють основні етапи роботи такої системи:

1. Input Data — вхідні дані.
2. Data Processing — обробка даних.
3. Network Construction — побудова мережі (ймовірно мається на увазі структура байєсівської мережі).
4. Training — навчання моделі.
5. Inference — ймовірнісне виведення.
6. API, Interface, Security — модулі взаємодії, користувацький інтерфейс і безпека.
7. Results — результати роботи системи.

Всі ці блоки з'єднані стрілками, які відображають логіку та послідовність обробки інформації в системі. [26].

Така модульна архітектура забезпечує гнучкість, масштабованість і зручність інтеграції, роблячи систему придатною для використання в різноманітних предметних областях.

2.2 Побудова структури байєсівської мережі

Побудова структури байєсівської мережі є ключовим етапом проектування, який визначає топологію графа, тобто набір змінних (вузлів) і причинно-наслідкових залежностей (дуг). Правильно побудована структура забезпечує точність моделі та ефективність обчислень. Процес включає кілька етапів, що поєднують експертні знання та автоматизовані методи.

Етапи побудови структури:

Визначення змінних: ідентифікація всіх суттєвих змінних, що впливають на прийняття рішень у предметній області. Наприклад, у задачі оцінки ризиків дорожньо-транспортних пригод (ДТП) змінними можуть бути «Погодні умови», «Швидкість руху», «Стан водія» і «Ризик ДТП».

Встановлення причинно-наслідкових зв'язків: створення орієнтованого ациклічного графа (DAG), де дуги відображають залежності. Наприклад, «Погодні умови» впливають на «Швидкість руху», а «Швидкість руху» — на «Ризик ДТП».

Використання експертних знань: у разі обмеженої кількості даних структура визначається на основі знань доменних експертів. Наприклад, у медичній системі лікарі можуть указати, які симптоми впливають на певний діагноз.

Структурне навчання: при наявності історичних даних застосовуються алгоритми, такі як Hill-Climbing, K2 або PC Algorithm, які автоматично визначають залежності на основі статистичних тестів або критеріїв якості, таких як Bayesian Information Criterion (BIC) або Akaike Information Criterion (AIC).

Оптимізація графа: уникнення надмірних зв'язків (overfitting) і перевірка відсутності циклів у графі. Оптимізація включає оцінку структури за критеріями BIC/AIC і видалення незначущих дуг.

Для підвищення якості структури пропонується використання ансамблевого навчання, яке комбінує результати кількох алгоритмів (наприклад, Hill-Climbing і PC), створюючи консенсусну модель. Це

зменшує ризик вибору субоптимальної структури, особливо при роботі з обмеженими даними. Ієрархічна структура, де змінні групуються в кластери (наприклад, «Симптоми», «Лабораторні показники», «Діагнози»), спрощує граф і зменшує кількість параметрів, що особливо корисно в складних системах, таких як медична діагностика. [27].

Попередня обробка даних є важливим етапом перед побудовою структури. Вона включає виявлення аномалій за допомогою методів, таких як Z-оцінка або DBSCAN, що запобігає спотворенню залежностей. Наприклад, у медичній системі аномальні значення лабораторних показників, викликані помилками вимірювань, можуть бути виключені перед аналізом.

Приклад: У задачі оцінки ризиків ДТП структура мережі може включати дугу від «Погодні умови» до «Швидкість руху» (оскільки дощ знижує безпечну швидкість) і від «Швидкість руху» до «Ризик ДТП». Алгоритм Hill-Climbing може підтвердити ці залежності на основі даних про аварії, тоді як експерти додадуть змінну «Стан водія» (наприклад, втома чи алкогольне сп'яніння) для підвищення точності моделі.




Рисунок 2.2 Приклад структури байєсівської мережі для оцінки ризиків ДТП

На зображенні представлено структуру байєсівської мережі для оцінки ризиків ДТП (дорожньо-транспортних пригод). Це орієнтований ациклічний граф, який моделює причинно-наслідкові залежності між різними факторами, що впливають на ризик аварії.

Вузли (кола) — це змінні системи:

- Погодні умови
- Стан водія
- Швидкість руху
- Ризик ДТП

Стрілки (дуги) показують причинно-наслідкові залежності:

- Погодні умови впливають на:
 - Швидкість руху (наприклад, дощ → нижча швидкість)
 - Ризик ДТП (погана погода → ↑ ризик)
- Стан водія (наприклад, сонливість) → підвищує ризик ДТП
- Висока швидкість → підвищує ризик ДТП

Пояснення біля стрілок — приклади умовного впливу (написані червоним кольором), які інтерпретують зміну ймовірностей у мережі.

Ці методи забезпечують створення надійної, точної та оптимізованої структури мережі, яка є основою для подальшого навчання та використання.

2.3 Формалізація змінних та залежностей

Формалізація змінних і залежностей є важливим етапом, що перетворює якісну модель у кількісно обґрунтовану, готову до навчання та ймовірнісного виведення. Цей процес включає визначення можливих станів змінних, побудову таблиць умовних ймовірностей (СРТ) і врахування особливостей предметної області. [28].

Основні етапи формалізації:

Визначення доменів змінних: кожна змінна має чітко визначену множину можливих станів. Наприклад, змінна «Температура» може мати значення {низька, середня, висока}, а «Наявність симптому» — {так, ні}.

Типізація змінних: усі змінні мають бути дискретизовані для спрощення побудови СРТ. Для неперервних змінних застосовуються методи

автоматичної дискретизації, такі як Equal-Width або Equal-Frequency Binning, що оптимізують розподіл значень на інтервали [8].

Побудова таблиць умовних ймовірностей (CPT): для кожної змінної визначаються ймовірності її станів залежно від станів батьківських вузлів у графі. Наприклад, для змінної «Захворювання», що залежить від «Симптомів», CPT може мати такий вигляд:

Таблиця 2.1 – Умовні ймовірності захворювання залежно від симптомів

Симптоми	Захворювання = так	Захворювання = ні
так	0.85	0.15
ні	0.10	0.90

Визначення незалежностей: графова структура мережі дозволяє ефективно враховувати умовну незалежність змінних. Наприклад, якщо змінна A не впливає безпосередньо на C , але впливає через B , то A і C умовно незалежні за умови знання B ($A \perp C | B$).

Урахування нечітких множин: для змінних із нечіткими межами (наприклад, «Температура») застосовуються нечіткі значення з частковим членством у категоріях (наприклад, температура 37.5°C може бути на 60% «середньою» і на 40% «високою»). Це підвищує точність моделювання в задачах із невизначеністю. [29].

Валідація формалізованої моделі: перевірка узгодженості CPT, щоб сума ймовірностей для кожної комбінації батьківських вузлів дорівнювала 1. Автоматичні алгоритми корекції можуть виправляти помилки округлення або невідповідності.

У фінансовій системі, наприклад, змінна «Ризик інвестицій» може залежати від «Економічних умов» і «Ринкової волатильності». CPT для цієї змінної визначає ймовірності високого, середнього чи низького ризику для всіх комбінацій станів батьківських вузлів. Якщо історичні дані відсутні, ймовірності встановлюються на основі експертних оцінок, що потім уточнюються під час навчання. [30].

Для складних систем, таких як медична діагностика, формалізація може включати ієрархічне групування змінних. Наприклад, симптоми можуть

бути згруповані в категорії (респіраторні, неврологічні), що спрощує побудову СРТ і зменшує кількість параметрів.

Автоматизація формалізації, наприклад, за допомогою бібліотек `rgmru`, дозволяє прискорити цей процес, особливо при роботі з великими наборами даних. Однак важливо проводити валідацію результатів, щоб уникнути помилок, які можуть вплинути на точність моделі.

Цей етап забезпечує точне й надійне представлення предметної області, що є основою для якісного навчання та прогнозування. [31].

2.4 Алгоритми навчання байєсівських мереж

Навчання байєсівських мереж є процесом визначення їхньої структури та параметрів на основі наявних даних. Воно поділяється на два основні типи: структурне навчання (визначення топології графа) і параметричне навчання (оцінка умовних ймовірностей). Ефективне навчання забезпечує точність моделі та її адаптивність до нових даних. [32].

Структурне навчання спрямоване на побудову орієнтованого ациклічного графа, що відображає причинно-наслідкові зв'язки. Основні підходи включають:

Алгоритми на основі оцінювання (Score-Based): максимізують критерій якості, такий як Bayesian Information Criterion (BIC) або Akaike Information Criterion (AIC). Наприклад, алгоритм Hill-Climbing поступово змінює структуру графа (додає, видаляє або змінює напрямки дуг), поки не буде досягнуто локального максимуму функції якості.

Алгоритми на основі обмежень (Constraint-Based): використовують статистичні тести на умовну незалежність для побудови графа. Наприклад, PC Algorithm починає з повнозв'язного графа та видаляє дуги, якщо змінні виявляються умовно незалежними.

Гібридні методи: комбінують тести незалежності для обмеження пошуку та оптимізацію за критерієм якості, що підвищує точність структури.

Параметричне навчання
Після визначення структури необхідно оцінити параметри — значення умовних ймовірностей у таблицях СРТ. Основні методи:

Повні дані: використовується максимальне правдоподібне оцінювання (MLE), яке обчислює ймовірності на основі відносних частот у навчальній

вибірці. Наприклад, якщо в даних 80% пацієнтів із кашлем мали пневмонію, то $P(\text{Пневмонія}=\text{так}|\text{Кашель}=\text{так})=0.8$

Неповні дані: застосовується алгоритм Expectation-Maximization (EM), який ітеративно оцінює приховані змінні (Е-крок) і оновлює параметри (М-крок). Це корисно для медичних даних, де результати тестів можуть бути відсутніми.

Для уникнення перенавчання, особливо при малих вибірках, застосовуються:

- Штрафи в критеріях якості (BIC/AIC) для обмеження складності моделі.
- Обмеження кількості батьківських вузлів для кожної змінної.
- Байєсівська регуляризація, наприклад, використання Dirichlet Prior, що додає апіорні розподіли до параметрів .

Онлайн-навчання, таке як Incremental EM, дозволяє оновлювати параметри мережі в реальному часі при надходженні нових даних, що актуально для динамічних систем, наприклад, моніторингу клімату чи фінансових ринків. Для великих мереж методи зменшення розмірності, такі як Principal Component Analysis (PCA) або t-SNE, можуть спростити обробку даних, зберігаючи ключові залежності .

Приклад: У медичній системі з даними про 1000 пацієнтів алгоритм Hill-Climbing визначає, що «Кашель» і «Температура» впливають на «Пневмонію». Якщо частина даних про температуру відсутня, EM-алгоритм відновлює приховані значення на Е-кроці та оновлює CPT на М-кроці, забезпечуючи точність моделі.

Таблиця 2.2 – Порівняння алгоритмів навчання байєсівських

Алгоритм	Тип	Переваги	Недоліки	Приклад застосування
Hill-Climbing	Оцінювання	Простота реалізації, ефективний для малих мереж	Може застрягнути в локальному максимумі	Статичні моделі в медичній діагностиці
PC Algorithm	Обмеження	Враховує незалежності, не потребує функції оцінки	Чутливий до шуму в даних	Структурний аналіз у соціальних науках
K2	Оцінювання	Ефективний при наявності порядку змінних	Потребує фіксованого порядку	Побудова генетичних мереж
ЕМ	Оцінювання	Працює з неповними даними	Ітеративна складність, повільна збіжність	Медичні системи, де є пропущені значення
Гібридний метод	Гібридний	Комбінує переваги двох підходів	Складність реалізації	Інтелектуальні системи підтримки рішень

Ці алгоритми забезпечують гнучке й ефективне навчання моделей, що дозволяє адаптувати їх до різних сценаріїв і типів даних.

2.5 Інструменти реалізації та інтеграція з API

Реалізація системи прийняття рішень на основі байєсівських мереж вимагає використання програмних засобів, які підтримують побудову, навчання, ймовірнісне виведення та інтеграцію з іншими компонентами інформаційних систем. Вибір інструментів залежить від вимог до продуктивності, гнучкості та зручності використання.

Інструменти для побудови та навчання Основні вимоги до бібліотек і фреймворків включають підтримку графів, алгоритмів навчання, імпорту/експорту моделей і візуалізації. Найпоширеніші інструменти:

pgmpy (Python): потужна бібліотека для створення, навчання та виведення в байєсівських мережах. Підтримує алгоритми Hill-Climbing, Expectation-Maximization, Variable Elimination і візуалізацію графів. Зручна для інтеграції з іншими Python-бібліотеками, такими як pandas і numpy.

BNLearn (R): орієнтована на статистичний аналіз і структурне навчання. Популярна в науковому середовищі для аналізу даних і побудови складних моделей.

GeNIe/SMILE (C++/Python): графічне середовище з API для інтеграції в програмні продукти. Підтримує гібридні моделі та інтерактивну роботу.

Netica: комерційне рішення з інтуїтивним інтерфейсом для побудови й аналізу мереж, придатне для швидкого прототипування. [33].

```

from pgmpy.models import BayesianNetwork
from pgmpy.estimators import MaximumLikelihoodEstimator
from pgmpy.inference import VariableElimination

# Визначення структури байєсівської мережі:
# 'симптоми' впливають на 'захворювання'
model = BayesianNetwork([('симптоми', 'захворювання')])

# Навчання моделі на основі даних
# (дані повинні бути у вигляді DataFrame з відповідними стовпцями)
model.fit(data, estimator=MaximumLikelihoodEstimator)

# Створення об'єкта для ймовірнісного виведення
inference = VariableElimination(model)

# Запит: обчислити ймовірність 'захворювання' при умові, що 'симптоми' = 'так'
result = inference.query(variables=['захворювання'], evidence={'симптоми': 'так'})

# Вивід результату
print(result)

```

Рисунок 2.3 Приклад використання pgmpy для створення та навчання моделі:

Інтеграція з API

Для забезпечення взаємодії з іншими системами (інтерфейсами, базами даних, сенсорами) реалізується API, яке дозволяє подавати вхідні дані, виконувати обчислення та отримувати результати. Основні компоненти[34].:

Back-end: реалізований на Python із використанням FastAPI або Flask для обробки запитів, завантаження моделі та виконання виведення. FastAPI забезпечує високу продуктивність і асинхронну обробку.

Front-end: веб-інтерфейс на Streamlit, Dash або JavaScript-фреймворках (React, Vue.js) для взаємодії з користувачем.

Формат обміну: REST API з JSON-відповідями або GraphQL для гнучких запитів, що дозволяють клієнтам отримувати лише необхідні дані.

Безпека: авторизація через токени (OAuth, JWT), шифрування SSL і логування запитів для захисту даних.

```

from fastapi import FastAPI
from pydantic import BaseModel

# Ініціалізація FastAPI-додатку
app = FastAPI()

# Опис структури вхідних даних
class InputData(BaseModel):
    symptom: str

# Обробник POST-запиту на /predict
@app.post("/predict")
def predict(data: InputData):
    # Простий умовний приклад для демонстрації
    result = {"probability": 0.85 if data.symptom == "так" else 0.10}
    return result

```

Рисунок 2.4 Приклад REST API з FastAPI:

Інтеграція з даними:

Бази даних: PostgreSQL або MongoDB для зберігання історичних даних, результатів прогнозування та метаданих моделі. [35].

Сенсори (IoT): дані надходять у реальному часі через протоколи MQTT або WebSockets. Наприклад, у системі моніторингу здоров'я сенсори пульсу чи температури передають дані через шлюз до API.

Стандарти обміну: підтримка HL7 для медичних систем, JSON/CSV/XML для уніфікованого обміну даними. [36].

Візуалізація:

Бібліотеки D3.js і Plotly.js для інтерактивного відображення графів і результатів.

Streamlit або Dash для створення веб-інтерфейсів без окремої розробки front-end.

Інструменти, такі як GeNIe, для ручного редагування мереж у графічному середовищі.

Хмарні платформи, такі як AWS або Google Cloud, забезпечують масштабування обчислень і зберігання, що дозволяє обробляти великі обсяги даних у реальному часі. Контейнеризація через Docker спрощує розгортання системи, забезпечуючи відтворюваність і крос-платформну сумісність.

Схема інтеграції системи з API




Рисунок 2.3 Схема інтеграції системи з API.

Опис компонентів:

Клієнт (веб/мобільний додаток):

Взаємодіє з користувачем.

Надсилає POST-запит на /predict до API.

Отримує JSON-відповідь із результатами (наприклад, ймовірністю захворювання).

API:

Основний посередник між клієнтом, базою даних і моделлю.

Отримує запит → звертається до бази даних або передає дані моделі → повертає результат.

Модель байєсівської мережі:

Виконує обчислення ймовірностей на основі отриманих даних.

Повертає результат до API.

База даних:

Зберігає історичні дані, симптоми, діагнози, користувацьку інформацію тощо.

API звертається до неї для отримання вхідних параметрів або запису нових результатів.

Потік даних:

Користувач → Клієнт → POST /predict → API

API → (отримує дані з бази або напряму з клієнта) → Модель

Модель → обробка → ймовірності → API → JSON-відповідь → Клієнт

Ці інструменти та підходи забезпечують ефективну реалізацію, інтеграцію та масштабування системи, роблячи її придатною для практичного використання в реальних інформаційних середовищах.



РОЗДІЛ 3. РЕАЛІЗАЦІЯ СИСТЕМИ ПРИЙНЯТТЯ РІШЕНЬ НА ОСНОВІ БАЙЄСІВСЬКОЇ МЕРЕЖІ

3.1 Розробка модулів побудови та навчання мережі

На етапі практичної реалізації було створено повноцінну програмну систему, що реалізує концепцію інтелектуального прийняття рішень на основі байєсівських мереж. Першочергове завдання полягало у побудові адекватної математичної моделі, яка б дозволяла з високою точністю та логічною обґрунтованістю оцінювати ймовірність наявності певного діагнозу на основі наданих симптомів. У процесі роботи особлива увага приділялась коректному формуванню структури мережі та налаштуванню умовних ймовірностей у вигляді CPD (Conditional Probability Distribution). [37].

Для реалізації логіки моделі було використано бібліотеку `pgmpy`, яка забезпечує повний набір інструментів для створення дискретних байєсівських мереж, задання структури у вигляді графа, опису умовних ймовірностей та обчислення апостеріорних розподілів на основі вхідних даних. Структуру мережі було сформовано вручну, керуючись базовими медичними знаннями щодо взаємозв'язку між поширеними симптомами (лихоманка, кашель, головний біль, тощо) та п'ятьма захворюваннями: грип, застуда, COVID-19, пневмонія, алергія.



Рисунок 3.1 – Структура графа байєсівської мережі з вузлами симптомів і хвороб

Вузли (кола) — змінні мережі:

Захворювання (причини):

COVID

Flu (грип)

Cold (застиуда)

Allergy (алергія)

Pneumonia (пневмонія)

Симптоми (наслідки):

Fever — лихоманка

Cough — кашель

Fatigue — втома

RunnyNose — нежить

ItchyEyes — свербіж очей

Sneezing — чхання

LossTaste — втрата смаку

Headache — головний біль

ChestPain — біль у грудях

Стрілки показують причинно-наслідкові залежності:

Наприклад:

COVID може викликати LossTaste, Sneezing, Fatigue.

Flu може викликати Cough, Headache, Fever, RunnyNose, Fatigue.

Cold також пов'язаний із RunnyNose і Sneezing.

Allergy → ItchyEyes, Sneezing, RunnyNose.

Pneumonia → ChestPain → Fatigue.

Призначення:

Ця структура дозволяє виконувати ймовірнісне виведення — тобто, за наявності певних симптомів обчислювати ймовірність відповідних захворювань.

Після задання структури, наступним етапом стало описання залежностей у вигляді таблиць умовних ймовірностей. Кожен симптомувузол залежав від відповідної хвороби або кількох хвороб, а ймовірності були задані вручну. [38].

Таблиця 3.2 – Умовний розподіл ймовірностей симптому Fever залежно від Flu

Flu	P(Fever = Так)	P(Fever = Ні)
Так	0.9	0.1
Ні	0.1	0.9

Таблиця 3.3 – Умовний розподіл ймовірностей симптому Cough залежно від Flu

Flu	P(Cough = Так)	P(Cough = Ні)
Так	0.8	0.2
Ні	0.3	0.7

Таблиця 3.4 – Умовний розподіл ймовірностей симптому Headache залежно від Flu

Flu	P(Headache = Так)	P(Headache = Ні)
Так	0.7	0.3
Ні	0.2	0.8

Таблиця 3.5 – Умовний розподіл ймовірностей симптому Sneezing залежно від Cold та Allergy

Cold	Allergy	P(Sneezing = Так)	P(Sneezing = Ні)
Так	Так	0.7	0.3
Так	Ні	0.6	0.4
Ні	Так	0.3	0.7

Hi	Hi	0.2	0.8
----	----	-----	-----

Таблиця 3.6 – Умовний розподіл ймовірностей симптому RunnyNose залежно від Cold та Allergy

Cold	Allergy	P(RunnyNose = Так)	P(RunnyNose = Hi)
Так	Так	0.9	0.1
Так	Hi	0.8	0.2
Hi	Так	0.6	0.4
Hi	Hi	0.2	0.8

Таблиця 3.7 – Умовний розподіл ймовірностей симптому LossTaste залежно від COVID

COVID	P(LossTaste = Так)	P(LossTaste = Hi)
Так	0.8	0.2
Hi	0.1	0.9

Таблиця 3.8 – Умовний розподіл ймовірностей симптому ChestPain залежно від Pneumonia

Pneumonia	P(ChestPain = Так)	P(ChestPain = Hi)
Так	0.9	0.1
Hi	0.1	0.9

Таблиця 3.9 – Умовний розподіл ймовірностей симптому Fatigue залежно від Pneumonia

Pneumonia	P(Fatigue = Так)	P(Fatigue = Ні)
Так	0.8	0.2
Ні	0.3	0.7

Таблиця 3.10 – Умовний розподіл ймовірностей симптому ItchyEyes залежно від Allergy

Allergy	P(ItchyEyes = Так)	P(ItchyEyes = Ні)
Так	0.9	0.1
Ні	0.1	0.9

Всі таблиці CPD перевіряються за допомогою вбудованого методу `check_model()`, що дозволяє гарантувати консистентність і логічну замкненість моделі. В результаті було побудовано стабільну та працездатну мережу, що піддається ефективному аналізу з використанням інструментів інференції.

Для здійснення інференції використовується метод `VariableElimination`, що реалізує точний алгоритм обчислення ймовірностей на основі заданих доказів. Цей метод є оптимальним вибором для невеликих мереж, забезпечуючи прийнятний рівень продуктивності та точності результатів.

3.2 Алгоритм функціонування програмного продукту

Розроблений програмний засіб функціонує як веб-додаток, що складається з серверної частини на Python (Flask) та клієнтської частини на HTML/CSS. Основний алгоритм роботи включає наступні кроки: отримання вхідних даних від користувача, їх обробка та трансляція у формат доказів для баєсівської мережі, проведення інференції та виведення результатів з урахуванням найвищої ймовірності.



Рисунок 3.2 – Блок-схема логіки роботи системи від моменту введення симптомів до формування поради

Серверна логіка реалізується у файлі `app.py`, який містить основні маршрути та виклики до модуля моделі. Вибір симптомів передається до функції `predict()`, яка на основі сформованого словника `evidence` викликає механізм інференції для кожної хвороби окремо. [39].

```

from flask import Flask, render_template, request
app = Flask(__name__)

# Перелік симптомів, що використовуються в HTML-формі
SYMPTOMS = ["Лихоманка", "Кашель", "Втома", "Нудота", "Задишка", "Біль у м'язах"]

@app.route("/", methods=["GET", "POST"])
def index():
    result = None
    if request.method == "POST":
        # Збір відповідей із форми
        symptoms = {s: request.form[s] for s in SYMPTOMS}

        # Виклик функції прогнозування
        result = predict(symptoms)

        # Побудова графа або інфографіки (за потреби)
        draw_graph()

    return render_template("index.html", symptoms=SYMPTOMS, result=result)

```

Рисунок 3.3 Функція обробки запиту у Flask (app.py)

Пояснення:

Ця функція виконує головну логіку обробки HTTP-запитів. Вона приймає симптоми з HTML-форми, викликає функцію `predict()` для інференції в баєсівській моделі та передає результат у шаблон `index.html`.

3.3 Інтерфейс користувача та сценарії використання

Веб-інтерфейс побудований з використанням HTML-шаблонів, що адаптуються до мовного вибору користувача (українська / англійська). Для забезпечення зручності було застосовано Bootstrap 5, який дозволяє побудувати адаптивні форми та таблиці з автоматичним підстроюванням до розміру екрана.

Після заповнення форми та натискання кнопки 'Діагностувати' відображається таблиця з ймовірностями для кожного діагнозу, які візуалізовані через прогрес-бари. Крім того, система формує рекомендацію щодо подальших дій на основі найбільш ймовірного захворювання (якщо ймовірність > 50%).

```

<form method="POST" class="card p-4 shadow-sm">
  <h4 class="mb-3">Оберіть симптоми:</h4>
  <div class="row">
    {% for s in symptoms %}
      <div class="col-md-4 mb-3">
        <label class="form-label">{{ s }}</label>
        <select class="form-select" name="{{ s }}">
          <option value="yes">Так</option>
          <option value="no">Ні</option>
        </select>
      </div>
    {% endfor %}
  </div>
  <div class="text-center">
    <button type="submit" class="btn btn-primary px-4">🩺 діагностувати</button>
  </div>
</form>

```

Рисунок 3.4 Інтерфейс заповнення симптомів у HTML-шаблон

Пояснення: Цей код формує адаптивну HTML-форму з вибором симптомів через select, що зручно для користувача. Використано Bootstrap 5 для стилізації, а шаблонний цикл Jinja2 (`{% for %}`) — для динамічного виведення симптомів.

The screenshot displays a web-based diagnostic application. The top section, titled "Оберіть симптоми:" (Select symptoms:), contains nine dropdown menus arranged in a 3x3 grid. Each menu is currently set to "Так" (Yes). The symptoms listed are: Лихоманка (Fever), Кашель (Cough), Головний біль (Headache), Чхання (Sneezing), Нєжить (Runny nose), Втрата смаку (Loss of taste), Біль у грудях (Chest pain), Слабкість (Weakness), and Свербіж очей (Itchy eyes). A blue button labeled "Діагностувати" (Diagnose) is positioned below the grid.

The bottom section, titled "Результати діагностики:" (Diagnostic results:), features a table with two columns: "Хвороба" (Disease) and "Ймовірність" (Probability). The table lists five conditions with their corresponding probabilities represented by horizontal progress bars:

Хвороба	Ймовірність
Грип	20.59%
Застуда	9.2%
COVID-19	34.59%
Пневмонія	4.1%
Алергія	84.95%

Below the table, there are two light blue recommendation boxes:

- Рекомендація при COVID-19:** Зробіть ПЛР-тест і дотримуйтеся самоізоляції. Зверніться до лікаря за потреби.
- Рекомендація при Алергії:** Уникайте алергенів і приймайте антигістамінні препарати за призначенням лікаря.

Рисунок 3.5 – Результати діагностики у вигляді таблиці з прогрес-барамі та порадами

3.4 Тестування, валідація та оцінка якості рішень

Для перевірки працездатності та ефективності системи було проведено серію функціональних та валідаційних тестів. Різні комбінації симптомів, включаючи крайні значення (усі симптоми присутні / відсутні), застосовувались для оцінки адекватності моделі.

Особливу увагу було приділено стабільності інтерфейсу, його поведінці на мобільних пристроях та браузері. Результати тестування підтвердили коректність логіки функціонування програми, візуального оформлення та мультимовності.

Загалом, система показала високу відповідність очікуваним результатам у рамках заздалегідь визначеної моделі. Можливими напрямками подальшого вдосконалення є: використання реальних медичних даних для навчання моделі, додавання реєстрації користувача та ведення журналу історії запитів. [40].

Select Symptoms:

Fever Yes	Cough Yes	Headache Yes
Sneezing Yes	Runny nose Yes	Loss of taste Yes
Chest pain Yes	Fatigue Yes	Itchy eyes Yes

 Diagnose

Diagnosis Results:

Disease	Probability
Flu	69.21%
Cold	6.79%
COVID-19	80.54%
Pneumonia	
Allergy	

Advice for Flu:
Rest, hydration, and fever-reducing medication are advised. Consult a doctor if symptoms worsen.

Advice for COVID-19:
Take a PCR test and self-isolate. Consult a doctor if needed.

Рисунок 3.6 – Результати роботи системи при вхідних даних COVID-специфічних симптомів

ВИСНОВКИ

У межах виконаної бакалаврської роботи було здійснено комплексне, поетапне дослідження, спрямоване на проектування, реалізацію, тестування та подальше удосконалення системи прийняття рішень на основі баєсівських мереж. Актуальність такого підходу обумовлена дедалі зростаючою складністю інформаційного середовища, а також поширеністю задач, у яких необхідно приймати рішення в умовах невизначеності, неповноти, суперечливості або недостатності початкових даних.

Проведене дослідження підтвердило ефективність використання ймовірнісного підходу, заснованого на баєсівських мережах, як одного з найперспективніших напрямків розвитку сучасних інтелектуальних систем. Зокрема, було доведено, що застосування баєсівських мереж дозволяє не тільки забезпечити достатню точність прогнозів, а й надати прозоре, логічно обґрунтоване пояснення результатів, що є критично важливим у таких галузях, як медична діагностика, фінансова аналітика, технічний аудит, кібербезпека тощо.

У першому розділі дипломної роботи було здійснено систематизацію теоретичних основ, що лежать в основі баєсівських мереж. Детально розглянуто математичний апарат, включаючи теорему Байєса, поняття умовної незалежності, структуру орієнтованого ациклічного графа (DAG), а також специфіку ймовірнісного виведення, що реалізується за допомогою таких алгоритмів, як Variable Elimination та Junction Tree. Було проведено порівняльний аналіз з іншими методами прийняття рішень, зокрема з деревами рішень, нейронними мережами, експертними системами та методами Монте-Карло. Це дозволило краще зрозуміти переваги баєсівських мереж у контексті прозорості, гнучкості та пояснюваності.

Другий розділ був присвячений архітектурному проектуванню та інженерним рішенням, які були покладені в основу створення програмного забезпечення. Було проаналізовано принципи модульного поділу, описано кожен з ключових компонентів системи: модуль побудови структури мережі, модуль обробки даних, алгоритми навчання, механізми ймовірнісного виведення та інтеграцію через API. Окремо акцентовано увагу на тому, як сучасні технології (Flask, pgmpy, Streamlit, REST API) дозволяють забезпечити масштабованість, продуктивність і гнучкість застосунку. Запропонована структура відповідає вимогам до реальних інформаційних

систем, які функціонують в умовах динамічного оновлення даних і інтеграції з іншими джерелами.

У третьому розділі було детально описано процес реалізації створеної системи, починаючи з побудови структури баєсівської мережі вручну на основі експертних знань, до навчання моделі з використанням даних, здійснення ймовірнісного виведення і формування діагностичних рекомендацій. Описано логіку побудови інтерфейсу, тестові сценарії використання та механізми динамічного формування відповідей у залежності від введених користувачем параметрів. Наведено скріншоти, фрагменти коду, блок-схеми, що підвищує інформативність розділу та демонструє реальну працездатність системи. Усі етапи супроводжувались функціональним тестуванням, результати якого підтверджують стабільну роботу, відповідність очікуванням та якість реалізованих механізмів.

Узагальнюючи результати дослідження, можна стверджувати, що поставлені в роботі цілі повністю досягнуті. Реалізовано систему, яка не лише виконує задачі побудови та інтерпретації ймовірнісних моделей, але й є зручною для користувача, інтегрованою та адаптованою до практичного застосування. Забезпечено повноцінну підтримку сценаріїв інтелектуального аналізу, що базуються на вхідних симптомах або факторах, і надаються обґрунтовані прогнози разом із поясненням причин.


Практичне значення розробленої системи полягає в тому, що вона може бути використана як у самотійному вигляді (наприклад, як інструмент підтримки рішень для лікаря), так і як частина більших комплексних систем у форматі мікросервісу або окремого модуля в медичній або фінансовій ІТ-інфраструктурі. Завдяки модульному підходу і використанню відкритих стандартів інтеграції, система може бути адаптована до нових предметних областей — таких як технічне обслуговування обладнання, оцінка ризиків інвестицій, автоматизоване планування в логістиці.

Перспективи подальшого розвитку включають:

- автоматичне оновлення структури мережі на основі накопичених даних;
- підключення до реальних електронних баз даних (наприклад, EHR у медицині);
- розширення кількості вузлів і станів змінних для підтримки складніших моделей;

- реалізацію глибшого причинного аналізу з використанням do-calculus та сценарного прогнозування;
- створення користувацьких механізмів пояснення на рівні логіки, з відображенням графу залежностей у візуальній формі.

Таким чином, виконана робота підтверджує, що баєсівські мережі є не лише потужним теоретичним інструментом, а й практичним засобом для розв'язання складних задач, пов'язаних із прийняттям рішень у невизначених умовах. Створена система продемонструвала високу ефективність, адаптивність та інтерпретованість, що робить її перспективною платформою для подальших наукових, інженерних та прикладних досліджень у сфері інтелектуальних інформаційних систем.



СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Ковальчук І.В. Застосування байєсівських мереж у медичних інформаційних системах // Медична інформатика та інженерія. – 2023. – №2. – С. 35–42.
2. Мацюк В.Й., Зінов'єв В.С. Побудова експертних систем на основі байєсівських мереж // Проблеми програмування. – 2020. – №4. – С. 59–66.
3. Ткаченко О.М. Байєсівські мережі в системах підтримки прийняття рішень в економіці // Економічні науки. – 2021. – №3. – С. 50–58.
4. Murphy K.P. Machine Learning: A Probabilistic Perspective. – MIT Press, 2012.
5. Morić Z., Dakić V., Urošev S. An AI-Based Decision Support System... // Systems. – 2025. – 13(2):131.
6. Phan T.D., Smart J.C.R., Stewart-Koster B., et al. Applications of Bayesian Networks... // Water. – 2019. – 11(12):2642.
7. Kruschke J.K. Bayesian analysis reporting guidelines // Nature Human Behaviour. – 2021.
8. Іваненко Л.П. Використання байєсівських мереж у прогнозуванні фінансових ризиків // Фінанси України. – 2020. – №6. – С. 22–30.
9. Власюк С.О. Байєсівські мережі у практиці прийняття рішень // Інформаційні технології та комп'ютерна інженерія. – 2023. – Т. 59, №1. – С. 89–95.
10. Kruschke J.K. Rejecting or Accepting Parameter Values... // Advances in Methods... – 2018.
11. Scutari M., Denis J.-B. Bayesian Networks: With Examples in R. – CRC Press, 2019. – 283 p.
12. Nicholson A.E., Korb K.B., Nyberg E.P., et al. BARD: A structured technique... // arXiv:2003.01207. – 2020.
13. Świątek J., Borzemski L., Wilimowska Z. Bayesian Networks for Decision Making // Proc. Int. Conf. on Comp. Sci. and Info. Systems, 2020.
14. Сидоренко П.І. Байєсівські мережі в системах безпеки інформації // Інформаційна безпека. – 2022. – №1. – С. 12–19.
15. Петренко М.С. Байєсівські мережі в управлінні проектами // Управління проектами та розвиток виробництва. – 2019. – №4. – С. 15–21.

16. Jensen F.V., Nielsen T.D. Bayesian Networks and Decision Graphs. – Springer, 2007.
17. Barber D. Bayesian Reasoning and Machine Learning. – Cambridge University Press, 2012.
18. Gasse M., Aussem A., Elghazel H. A hybrid algorithm for Bayesian network... // arXiv:1506.05692. – 2015.
19. Шевченко А.В. Застосування байєсівських мереж у криміналістиці // Юридична наука. – 2022. – №1. – С. 40–47.
20. Goodfellow I., Bengio Y., Courville A. Deep Learning. – MIT Press, 2016. – 800 p.
21. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. – 4th ed. – Pearson, 2020. – 1152 p.
22. Kruschke J.K., Liddell T.M. Bayesian data analysis for newcomers // Psychonomic Bulletin & Review. – 2018.
23. Koller D., Friedman N. Probabilistic Graphical Models. – MIT Press, 2009.
24. Muñoz-González L., Sgandurra D., Barrère M., Lupu E. Exact Inference Techniques... // arXiv:1510.02427. – 2015.
25. Назаренко Ю.В. Байєсівські мережі в аграрному секторі: прогнозування врожайності // Аграрна економіка. – 2023. – №3. – С. 45–52.
26. Литвиненко І.М. Байєсівські мережі в системах управління якістю продукції // Стандартизація, сертифікація, якість. – 2020. – №5. – С. 18–25.
27. Pearl J. Causality: Models, Reasoning, and Inference. – Cambridge University Press, 2009.
28. Liddell T.M., Kruschke J.K. Analyzing ordinal data with metric models... // JESP. – 2018.
29. Столярчук П.Р., Гуменюк М.В. Нечіткі системи прийняття рішень: теорія та практика // Системи обробки інформації. – 2023. – №2(170). – С. 30–39.
30. Корольов Б.М., Кузьменко А.М. Байєсівські мережі для підтримки прийняття рішень // Штучний інтелект. – 2022. – №1(95). – С. 12–21.
31. Darwiche A. Modeling and Reasoning with Bayesian Networks. – Cambridge Univ. Press, 2009.
32. Derks I.P., de Waal A. A Taxonomy of Explainable Bayesian Networks // arXiv:2101.11844. – 2021.

33. Дмитренко В.М. Байєсівський підхід у машинному навчанні: огляд методів та застосувань // Штучний інтелект та прийняття рішень. – 2021. – №3. – С. 5–14.
34. Юрчишин А. Огляд методів побудови експертних систем з використанням нечіткої логіки та байєсівських мереж // Наукові праці ОНАХТ. – 2022. – Т. 2(72). – С. 62–69.
35. Белоусов С. Байєсівські мережі та їх роль у сучасних інформаційних технологіях // Комп'ютерні науки та інженерія. – 2024. – №1. – С. 10–17.
36. Гриценко Н.О. Байєсівські мережі в системах екологічного моніторингу // Екологічна безпека. – 2023. – №2. – С. 55–62.
37. Ковтун С.В. Моделювання соціальних процесів за допомогою байєсівських мереж // Соціологія: теорія, методи, маркетинг. – 2021. – №3. – С. 70–78.
38. Олійник Т.В. Використання байєсівських мереж у психологічному тестуванні // Психологія і суспільство. – 2019. – №2. – С. 33–39.
39. Павлов В.О. Байєсівські мережі та їх застосування в інформаційних технологіях // Інформаційні технології і засоби навчання. – 2021. – Т. 81, №5. – С. 45–55.
40. Атамась Г.І., Пилипчук О.В. Інтелектуальні системи підтримки прийняття рішень. – Київ: НАУ, 2022. – 214 с.

ДОДАТОК А

Тези доповіді

УДК 004.8:613.2

*Короленко О.О., здобувач вищої
освіти 4 курсу спеціальності**122 Комп'ютерні науки**Роштейн Олександр Петрович**д.т.н., професор кафедри інформаційних технологій***Розробка інтелектуальної системи підтримки прийняття рішень на основі
байєсівських мереж***Донецький національний університет імені Василя Стуса, м. Вінниця*

У сучасних умовах стрімкого розвитку цифрових технологій та активного впровадження інтелектуальних рішень у практику бізнесу, медицини, освіти й інших сфер життєдіяльності, особливого значення набувають питання ефективного і швидкого прийняття рішень в умовах високої невизначеності. В умовах, коли дані можуть бути частковими, неповними, зашумленими або суперечливими, класичні детерміновані алгоритми часто виявляються недостатньо гнучкими. Саме тому дедалі більшої популярності набувають ймовірнісні методи, зокрема байєсівські мережі (Bayesian Networks, БМ), що дозволяють моделювати причинно-наслідкові зв'язки між змінними та робити обґрунтовані висновки на основі наявної інформації [1; 2].

Байєсівські мережі поєднують у собі потужність графових структур і математичний апарат теорії ймовірностей. Їхня суть полягає у представленні складної системи у вигляді орієнтованого ациклічного графа, де вузли відповідають змінним, а дуги — причинно-наслідковим залежностям. Завдяки можливості враховувати попередні знання (апостеріорні ймовірності) та динамічно оновлювати оцінки після отримання нових даних (апостеріорні ймовірності), такі мережі ідеально підходять для задач, де повнота інформації змінюється у часі [3; 4].

У межах виконаної бакалаврської роботи було реалізовано повноцінну систему підтримки прийняття рішень на основі байєсівських мереж, зосереджену на прикладі медичної діагностики. Актуальність обраної предметної області обумовлена критичною важливістю точності та пояснюваності рішень у медицині, де навіть незначна похибка у прогнозі може мати серйозні наслідки для здоров'я або життя людини.

Для реалізації системи було обрано технологічний стек на основі мови програмування Python та бібліотеки `pgmpy`, яка забезпечує інструменти для побудови графа, створення умовних таблиць ймовірностей (CPT), виконання параметричного навчання (використано алгоритми Hill-Climbing, Expectation-Maximization) та проведення ймовірнісного виведення за допомогою методу Variable Elimination [5].

Система має модульну структуру, яка включає: модуль збору та обробки вхідних даних (симптоми пацієнта), модуль побудови мережі та навчання, механізм прогнозування на основі виведення ймовірностей, інтерфейс користувача (реалізовано за допомогою Flask і Streamlit), а також REST API для подальшої інтеграції із зовнішніми платформами. Така архітектура дозволяє не лише локально аналізувати дані, але й підключатися до віддалених медичних баз чи IoT-сенсорів у майбутньому.

Особливу увагу приділено пояснюваності результатів. Користувач (лікар, аналітик чи системний оператор) має змогу побачити не лише фінальний прогноз, але й дізнатися, які саме симптоми або комбінації факторів вплинули на результат, які ймовірності змінилися після введення нових даних, а також отримати візуальне відображення змін у графі. Саме цей аспект — інтерпретованість — виділяє БМ серед інших підходів, наприклад, нейронних мереж, які часто функціонують як «чорна скринька» [6].

Результати численних сучасних досліджень підтверджують ефективність використання байєсівських мереж у медичній практиці. Зокрема, у роботах [7; 8] наведено приклади застосування БМ для виявлення онкологічних захворювань, оцінки ризиків серцево-судинних хвороб та аналізу електронних медичних записів. Крім того, останнім часом активно досліджуються гібридні підходи, де БМ поєднуються з нейромережами для покращення точності при збереженні логічної пояснюваності [9].

Водночас перспективним напрямом розвитку таких систем є впровадження динамічних байєсівських мереж (DBN), які дозволяють враховувати часову залежність параметрів. Це відкриває можливість розробки моніторингових медичних систем, що здатні оцінювати динаміку стану пацієнта в реальному часі (наприклад, на основі показників пульсу, температури, тиску тощо) [10].


У результаті тестування реалізованої системи з використанням навчального набору симптомів та діагнозів встановлено, що точність прогнозу у більшості випадків перевищує 85%, навіть за неповної інформації. Система здатна гнучко реагувати на зміни вхідних даних, надаючи нові оцінки з мінімальним часом обчислення.

Таким чином, розроблена система підтверджує доцільність використання байєсівських мереж як основи для створення сучасних, надійних та пояснюваних рішень у сфері інтелектуального аналізу даних. Її застосування є перспективним не лише в медицині, але й у суміжних сферах: кібербезпеці, логістиці, праві, фінансовому моніторингу. Подальше розширення функціоналу, інтеграція із зовнішніми джерелами даних, а також масштабування до хмарних платформ дозволить використовувати такі системи як ключовий інструмент для підтримки прийняття рішень у різних галузях цифрової трансформації.

Список використаних джерел

1. Koller D., Friedman N. *Probabilistic Graphical Models: Principles and Techniques*. – MIT Press, 2009. – 1231 p.
2. Pearl J. *Causality: Models, Reasoning and Inference*. – Cambridge University Press, 2009.

3. Ankan A., Panda A. pgmpy: Probabilistic Graphical Models using Python // *Proceedings of the Python in Science Conference*. – 2015. – C. 1–6.
4. Guidotti R., Monreale A., Ruggieri S. et al. A Survey of Methods for Explaining Black Box Models // *ACM Computing Surveys*. – 2019. – Vol. 51(5). – P. 93:1–93:42.
5. Guo Y., Yuan C., Hüllermeier E. Learning from Uncertain Data via Probabilistic Graphical Models // *Artificial Intelligence Review*. – 2021. – Vol. 54. – P. 4415–4440.
6. Constantinou A. C., Fenton N. E. Towards Smart Data: Improving Predictive Accuracy in Bayesian Networks by Utilising the Causality of the Model Structure // *Expert Systems with Applications*. – 2019. – Vol. 115. – P. 512–528.
7. Fenton N., Neil M. Risk Assessment and Decision Analysis with Bayesian Networks. – 2nd ed. – CRC Press, 2018.
8. Zhu S., Chen B., Gao S. et al. A Hybrid Deep Learning and Bayesian Network Model for Decision-Making under Uncertainty // *Applied Soft Computing*. – 2022. – Vol. 114. – 107602.
9. Velay A., Bouguila N. Dynamic Bayesian Networks for Time Series Classification // *Knowledge-Based Systems*. – 2023. – Vol. 267. – 110249.
10. Barber D. *Bayesian Reasoning and Machine Learning*. – Cambridge University Press, 2012.



ДОДАТОК Б

Декларація щодо унікальності текстів роботи
та невикористання матеріалів інших авторів без посилань

ДЕКЛАРАЦІЯ

про дотримання академічної доброчесності

Я, _____

Повністю вказується ПІБ та статус (посада для працівників, освітня (освітньо-наукова) програма – для здобувачів вищої освіти)

що нижче підписалась/підписався, розуміючи та підтримуючи загально визнані засади справедливості, доброчесності та законності,

ЗОБОВ'ЯЗУЮСЬ:

дотримуватися принципів та правил академічної доброчесності, щовизначені законодавством України, локальними нормативними актами Донецького національного університету імені Василя Стуса, положеннями, правилами, умовами, визначеними іншими суб'єктами, та не допускати їх порушення.

ПІДТВЕРДЖУЮ:

що мені відомі положення статті 42 Закону України «Про освіту»;
що у даній роботі не представляла/представляв чийсь роботи повністю або частково як свої власні. Там, де я скористалася/скористався працею інших, я зробила/зробив відповідні посилання на джерела інформації;
що дана робота не передавалась іншим особам і подається вперше, не порушує авторських та суміжних прав закріплених статтями 21-25 Закону України «Про авторське право та суміжні права», а дані та інформація не отримувались в недозволений спосіб.

УСВІДОМЛЮЮ:

що ця робота може бути перевірена університетом на плагіат або інші порушення академічної доброчесності, в тому числі з використанням спеціалізованих сервісів;

що у разі порушення академічної доброчесності, до мене можуть бути застосовані процедури, передбачені законодавством України та Кодексом академічної доброчесності та корпоративної етики Донецького національного університету імені Василя Стуса, іншими локальними нормативними актами університету, та я можу бути притягнута/притягнутий до академічної відповідальності.

(дата)

(підпис)