

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХЕРСОНСЬКИЙ НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ

Вороненко М. О.
Литвиненко В. І.
Вишемирська С. В.

**ПРОЄКТУВАННЯ
СТАТИЧНИХ ТА ДИНАМІЧНИХ МОДЕЛЕЙ
НА ОСНОВІ БАЙЄСІВСЬКИХ МЕРЕЖ**

Навчальний посібник

Хмельницький – Херсон
2024

УДК 004.9:519.26](075.8)

B75

*Рекомендовано до друку Вченою радою
Херсонського національного технічного університету
протокол №3 від 29.10.2024 р.*

Рецензенти:

- Осипенко В.В.** д.т.н., професор Кафедри комп'ютерної інженерії та електромеханіки Київського національного університету технологій та дизайну
- Терентьєв О.М.** д.т.н., доцент кафедри ММСА Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського», провідний науковий співробітник ІТГП НАНУ.
- Калініна І.О.** д.т.н., професор (б. в. з.) кафедри інтелектуальних інформаційних систем Чорноморського національного університету імені Петра Могили

Вороненко М. О., Литвиненко В. І., Вишемирська С. В.

B75 Проектування статичних і динамічних моделей на основі байєсівських мереж : навчальний посібник / Вороненко М. О., Литвиненко В. І., Вишемирська С. В. – Херсон: Книжкове видавництво ФОП Вишемирський В. С., 2024. – 339 с.

ISBN 978-617-8187-32-3 (електронне видання)

Навчальний посібник присвячено висвітленню сучасних підходів до моделювання процесів довільної природи за допомогою байєсівських мереж, які сьогодні успішно використовуються для розв'язання задач прогнозування, передбачення, медичної і технічної діагностики, прийняття управлінських рішень, автоматичного керування. Розглянуто теорію побудови байєсівських мереж, яка включає задачі навчання структури мережі та формування ймовірного висновку на її основі. Наведено практичні методики побудови структури мережі на основі статистичних даних і експертних оцінок. Розглянуто приклади розв'язання практичних задач моделювання, прогнозування і прийняття рішень. Наведено перелік відомих програмних продуктів та їх виробників для побудови та застосування мереж Байєса. Книга рекомендується як навчальний посібник для студентів, аспірантів та викладачів, а також спеціалістів у галузі розв'язання задач ймовірного математичного моделювання, прогнозування, передбачення, інформація стосовно яких представлена статистичними даними та експертними оцінками.

УДК 004.9:519.26](075.8)

ISBN 978-617-8187-32-3 (електронне видання)

© Вороненко М.О., 2024
© Литвиненко В. І., 2024
© Вишемирська С.В., 2024
© ХНТУ, 2024
© ФОП Вишемирський, 2024

ЗМІСТ

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ.....	7
ВСТУП	10
РОЗДІЛ 1. ОГЛЯД ІСНУЮЧИХ МЕТОДІВ ПОПЕРЕДНЬОЇ ОБРОБКИ ДАНИХ.....	14
1. 1. Типи даних. Методи передобробки даних.	15
1.1.1. Підготовка даних	18
1.1.2. Побудова і валідація моделі	19
1.1.3. Оцінка і трактування результатів	19
1. 2. Методи класифікації даних.....	21
1. 3. Методи кластеризації даних складної природи.....	25
1.3.1. Ієрархічні методи кластеризації	29
1.3.2. Неієрархічні методи кластеризації.....	34
1. 4. Методи нормалізації даних.....	39
1. 5. Ймовірнісні методи моделювання і аналізу даних.	42
1.5.1. Формула Байєса	49
1.5.2. Граф-теоретичне представлення байєсівської мережі	55
1.5.3. Логічний висновок в байєсових мережах.....	61
1.5.4. Алгоритми класифікації на основі байєсових мереж.....	67
1. 6. Огляд сучасних методів моделювання даних в задачах машинного навчання	73
1. 7. Переваги і недоліки байєсівського підходу.....	76
Висновки до розділу 1.....	80
РОЗДІЛ 2. ТЕХНОЛОГІЯ РОЗРОБКИ СТАТИЧНИХ БАЙЄСІВСЬКИХ МЕРЕЖ	86
2. 1. Огляд програмних засобів, що можуть бути використані при роботі з мережами Байєса.	87
2.1.1. Опис інструментального середовища GeNIa його технічна та інтерфейсна реалізація.	98
2.1.2. Типи вузлів в GeNIe Modeler	105
2. 2. Типи байєсівських мереж.....	106

2. 3. Технологія побудови статичної байєсівської мережі	109
2.3.1. Дискретизація, як один з методів передобробки даних.....	113
2.3.2. Етап навчання параметрів.....	117
2.3.3. Алгоритми пошуку структури байєсівської мережі.....	118
2.3.3.1. Алгоритм Path Condition (PC).	119
2.3.3.2. Алгоритм Наївного Байєсу	125
2.3.3.3. Алгоритм Жадібного проріджування (Greedy).....	126
2.3.3.4. Алгоритм TAN	128
2.3.3.5. Алгоритм Розширеного Наївного Байєсу (ANB).....	131
2.3.3.6. Навчання мереж Байєса з прихованими вершинами	132
2. 4 Методи визначення і підвищення точності моделі.....	136
2.4.1. Канонічні вузли Noisy-MAX	138
2.4.2. Діагностичні вузли. Меню Diagnosis	140
2.4.3. Аналіз чутливості	148
2.4.4. Критерії оцінки якості роботи методів побудови імовірнісного висновку.....	151
2. 5. Сценарний аналіз «What-if».....	152
Висновки до розділу 2.....	155

РОЗДІЛ 3. ПРОЄКТУВАННЯ ЙМОВІРНІСНИХ МОДЕЛЕЙ

НА ОСНОВІ СТАТИЧНИХ БАЙЄСІВСЬКИХ МЕРЕЖ	159
3. 1. Галузі застосування ба'єсових мереж	160
3. 2. Оціночна ймовірнісна модель якості правоохоронного сервісу на основі статичної байєсівської мережі.....	163
3.2.1. Опис вхідних даних.....	164
3.2.2. Процес передобробки даних.....	165
3.2.3. Концептуальна модель байєсової мережі	167
3.2.4. Побудова байєсової моделі в програмному середовищі Genie2.3 Academic. Навчання параметрам. Валідація	168
3.2.5. Сценарний аналіз.....	173
3. 3. Комп'ютерна інформаційна система для оцінювання і прогнозування стану інтернет-магазину малого підприємства.	177
3.3.1. Опис вхідних даних.....	179

3.3.2. Побудова байєсової моделі в програмному середовищі Genie2.3 Academic	181
3.3.3. Сценарний аналіз	186
3. 4. Прогностична модель економічного зростання країни на базі статичної байєсової мережі.....	188
3.4.1. Проведення аналізу показників економічної діяльності та визначення вхідних даних	190
3.4.2. Концептуальна модель	192
3.3.3. Побудова байєсової моделі в програмному середовищі Genie2.4 Academic на вузлах General.....	195
3.4.4. Моделювання з використанням вузлів Noisy-MAX.....	196
3.4.5. Аналіз моделювання статичної байєсової мережі на вузлах Noisy-MAX.	198
Висновки до розділу 3.....	204
РОЗДІЛ 4. РОЗРОБКА ЕКСПЕРТНОЇ СИСТЕМИ З ВИКОРИСТАННЯМ МЕРЕЖ БАЄЙСА	207
4.1. Поняття експертної системи.....	208
4.1.1. Характеристики експертної системи.	210
4.1.2. Класифікація експертних систем.....	213
4.1.3. Переваги експертних систем, побудованих за допомогою байєсівських мереж.	218
4. 2 Застосування Байєсових мереж в експертних системах	222
4.2.1. Проектування експертної системи діагностування нейропатологій з використанням байєсівської мережі довіри.	222
4.2.2. Проектування експертної системи діагностування пневмонії з використанням байєсівської мережі довіри.	238
Висновки по розділу 4	270
РОЗДІЛ 5. ПРОЄКТУВАННЯ ДИНАМІЧНИХ МОДЕЛЕЙ НА ОСНОВІ БАЄСІВСЬКИХ МЕРЕЖ.....	272
5. 1. Поняття динамічних байєсівських мереж.....	273
5.1.1. Довірчі мережі.	274
5.1.2. Поняття сепарабельних моделей. Формальний опис динамічних мереж Байєса.	275

5. 2. Технологія побудови динамічної байєсової мережі.....	278
5.2.1. Обробка пропущених значень.....	279
5.2.2. Технологія побудови динамічної байєсової мережі в GeNIe.	280
5.2.3. Приєднання даних за період часу, введення доказів на часові вузли.....	283
5.2.4. Перевірка моделі та підвищення точності.....	284
5. 3. Різновиди динамічних байєсівських моделей і галузі їх застосування	285
5. 3. Динамічна байєсівська модель оцінки якості правоохоронного сервісу.	287
5. 4. Модель прогнозування економічного зростання країни за допомогою динамічних байєсівських мереж.....	293
Висновки до розділу 5.....	304
ВИСНОВКИ	305
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	308

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

БМ	Байєсівська мережа
DBSCAN	Просторова кластеризація додатків із шумом на основі щільності (Density-Based Spatial Clustering of Applications with Noise)
OPTICS	Впорядкування точок для визначення структури кластеризації (Ordering Points To Identify the Clustering Structure)
GeNie	Graphical Network Interface
САГ	Спрямований ациклічний граф
СЦГ	Спрямований циклічний граф
ПБК	Примітивний (наївний) Байєсів класифікатор
ДБМ	Динамічна байєсівська мережа
MDL	Принцип описання мінімальної довжини
ЕМ	Алгоритм максимізації математичного очікування
ML	Максимальна правдоподібність
РС	Алгоритм умовного шляху (Path Condition)
GTT	Алгоритм навчання структури жадібного товстого проріджування
TAN	Алгоритм навчання структури (Tree Augmented Naive Bayes)
ANB	Алгоритм навчання структури розширеного наївного байєсу
LOOCV	Метод кросс-валідації Leave-One-Out Cross-Validation
ООБМ	Об'єктно-орієнтована байєсівська мережа

СРТ	Таблиця умовних ймовірностей
ВВП	Валовий внутрішній продукт
ЕС	Експертна система
ЕОМ	Електронно-обчислювальна машина
ІЛАЕ	Міжнародної Протиепілептичної Ліги
ЕЕГ	Електроенцефалограма
ПСП	Протисудомних препаратів
СШ	Системи штучного інтелекту
МРТ	Магніто-резонансна томографія
ЕКГ	Електро-кардіограма
ШОЕ	Швидкість осідання еритроцитів
ІДЗ	Ітеративний діхотомайзер
ЄС	Європейський Союз

ВСТУП

Проектування ймовірнісних моделей на основі байєсівських мереж є однією з найсучасніших та ефективних технік в області аналізу даних та штучного інтелекту. Байєсівські мережі, що базуються на теорії ймовірностей та статистиці, дозволяють моделювати складні залежності між змінними та враховувати невизначеність у даних. Динамічні моделі, зокрема динамічні байєсівські мережі, розширюють ці можливості, додаючи вимір часу та дозволяючи аналізувати зміни станів системи в часовому вимірі. Це робить їх незамінними у багатьох галузях, включаючи фінансовий аналіз, медицину, екологію, машинне навчання та інші. Наприклад, у фінансовому секторі вони використовуються для моделювання ризиків та прогнозування ринкових тенденцій, у медицині – для діагностики та прогнозування розвитку захворювань, в екології – для моделювання змін клімату та впливу екологічних факторів. У кожній з цих областей байєсівські мережі дозволяють отримати більш глибоке розуміння процесів та приймати більш обґрунтовані рішення.

Впровадження таких моделей вимагає не тільки глибокого розуміння математичних основ, але й навичок програмування та роботи з великими обсягами даних. Сучасні програмні інструменти, такі як Netica, TensorFlow Probability, PyMC3, програмне середовище GeNie та інші надають дослідникам потужні засоби для побудови та тестування статичних і динамічних байєсівських мереж. Вони дозволяють автоматизувати складні обчислення та візуалізувати результати, що значно спрощує процес аналізу та інтерпретації даних.

Проектування динамічних моделей на основі байєсівських мереж широко застосовуються у реальних проектах і є потужним інструментом для аналізу складних систем з урахуванням невизначеності та часових змін, що відкриває нові можливості для наукових досліджень та практичних застосувань.

Перший розділ посібника присвячено основам теорії мереж Байєса. Розглядаються методи попередньої обробки даних, теорема Байєса, граф-теоретичне представлення і типи зв'язків у

мережі, стандартизований математичний запис мереж Байєса, переваги і недоліки байєсівського підходу.

Другий розділ присвячено огляду програмних засобів, що можуть бути використані при роботі з мережами Байєса, наведено опис інструментального середовища GeNIa, його технічна та інтрефейсна реалізація. Розглянуті основні типи байєсівських мереж, етапи побудови статичної ймовірнісної моделі, методи дискретизації даних, навчання параметрів, алгоритми пошуку структури мережі, методи підвищення точності моделі, сценарний аналіз «What-if».

У третьому розділі розглянуто галузі застосування байєсових мереж. Значна увага приділена їх практичному застосуванню в якості інструмента інтелектуального аналізу даних. Запропоновано кілька практичних прикладів побудови мережі Байєса з використанням відомих вибірок даних, а саме: оціночна ймовірнісна модель якості правоохоронного сервісу на основі статичної байєсівської мережі, комп'ютерна інформаційна система для оцінювання і прогнозування стану інтернет-магазину малого підприємства, прогностична модель економічного зростання країни на базі статичних байєсівських моделей.

Четвертий розділ присвячений практичним питанням розробки експертних систем на основі байєсівських мереж. Розглянуто поняття і класифікація експертних систем. Запропоновано практичні приклади побудови медичних систем діагностування.

У п'ятому розділі розглядаються місце та роль динамічних байєсівських мереж в технологіях інтелектуального аналізу даних. Наведено приклади застосування мереж Байєса при побудові прогностичних динамічних моделей у галузях економіки та правоохоронного сервісу.

Видання розраховане на наукових працівників, викладачів, аспірантів, студентів вищих навчальних закладів, а також широке коло читачів, які цікавляться питаннями прогнозування та ймовірнісного моделювання і може бути корисним при викладанні таких навчальних дисциплін, як «Інтелектуальний аналіз даних»,

«Дискретна математика», «Імовірнісне моделювання», «Навчання і міркування за допомогою байєсівських мереж» та ін.

Усвідомлюючи те, що процеси і механізми розвитку ймовірнісного моделювання набувають подальшого вдосконалення, автори будуть вдячні за слушні побажання, зауваження та пропозиції. Ми запрошуємо студентів, магістрів і аспірантів упродовж навчальних семестрів в процесі вивчення курсів за спеціальностями 122 Комп'ютерні науки і 126 Інформаційні системи та технології брати активну участь у нових дослідженнях, у створенні і розбудові змісту практичних і лабораторних робіт курсу «Навчання і міркування за допомогою байєсівських мереж», параграфів і окремих розділів другого видання навчального посібника, вносити корисні корективи і стати ініціаторами багатьох задач та їх розв'язків, методів, алгоритмів і моделей.

РОЗДІЛ 1

ОГЛЯД ІСНУЮЧИХ МЕТОДІВ ПОПЕРЕДНЬОЇ ОБРОБКИ ДАНИХ

1. 1. Типи даних. Методи передобробки даних.

Що потрібно знати, для того щоб займатись аналізом даних? Є три основні компоненти. В першу чергу це знання предметної області, що дозволяє зрозуміти, які проблеми потребують першочергового вирішення. Друге – це знання математики та статистики. Вони дозволяють формалізувати рішення, перевести його в алгоритм та оцінити, яка ймовірність отримати результат. Оскільки зараз є можливість застосовувати величезні обчислювальні потужності, тому вміння програмувати - третій компонент - є важливим для побудови моделей. Звісно, наявні дані спершу потрібно належним чином підготувати. Цей процес і складає «передобробку даних».

Розв'язання задач математичного моделювання, прогнозування, передбачення, менеджменту, автоматичного керування та багатьох інших, виконується в умовах наявності невизначеностей довільної природи та різних типів. Невизначеності зумовлені відсутністю необхідних об'ємів інформації про досліджувані процеси, пропусками даних, наявністю збурень станів та шумів вимірів, повністю або частково невідомою структурою об'єкта та іншими факторами. Найпоширенішими видами невизначеностей, які зустрічаються у процесі побудови математичних моделей процесів і об'єктів різної природи, є структурні, статистичні і параметричні невизначеності [296].

Сьогодні немає універсальних процедур врахування невизначеностей більшості існуючих типів, які можна успішно застосовувати при розв'язанні згаданих практичних задач. Існуючі методи обробки невизначеностей дають можливість враховувати деякі конкретні типи невизначеностей з метою підвищення якості остаточного результату. Велику допомогу у боротьбі з невизначеностями надають методи інтелектуального аналізу даних, до яких відносять нейронні мережі, нечітку логіку, нейро-нечіткі системи, байєсівські мережі та інші моделі байєсівського типу, еволюційні методи, інформований пошук та дослідження

просторів, спрямовані на розв'язання оптимізаційних задач, математичну логіку, дерева рішень та деякі інші. Але перш ніж переходити до моделювання, наявні дані потрібно привести до виду, який дозволить ефективно здійснити це моделювання [296].

Сучасні масиви даних, до яких можуть бути застосовані ті чи інші методи Data Mining, можуть характеризуватись великою кількістю ознак, що формують ознаковий простір великої розмірності. Тому актуальним є завдання зниження розмірності такого простору до розмірності, що дозволяє без зайвих труднощів здійснювати обробку даних та/або їхню візуалізацію. Вирішення такої задачі називають оптимізацією ознакового простору або пошуком значущих ознак (англ. Feature Selection). Попередня обробка даних є найважливішим етапом, від якості виконання якого залежить можливість отримання якісних результатів всього процесу аналізу даних.

Feature Selection полягає у виборі найбільш інформативних, корисних ознак та виключення з розгляду неінформативних ознак без трансформації вихідного простору даних [226,227]. Сучасний стан методів передобробки статистичних даних характеризується значним розвитком та вдосконаленням технік, спрямованих на підвищення якості та ефективності аналізу даних. Аналітичні технології, які ми можемо застосувати, є потужними, але вони висувають певні вимоги до даних, які вони використовують. Вони часто вимагають, щоб дані були у формі, відмінній від того, як вони надаються природним чином, в такому випадку знадобиться їх певне перетворення. Тому етап підготовки даних часто триває разом із розумінням даних, під час якого дані перетворюються у форми, які дають кращі результати [222].

Типовими прикладами підготовки даних є їх перетворення у табличний формат, видалення або визначення відсутніх значень і представлення у різних типах. Деякі методи інтелектуального аналізу даних розроблені для символічних і категоріальних даних, а інші обробляють лише числові значення. Серед основних методів, що використовуються, варто відзначити:

- обробка пропущених даних,

- методи обробки аномальних значень в наборах даних,
- фільтрація,
- методи згладжування даних,
- нормування,
- класифікація,
- кластеризація,
- трансформація даних.

Для виконання таких перетворень доступні стандартні техніки та практичні правила. Дослідники часто витрачають значний час на початку процесу, визначаючи змінні, які будуть використовуватись при моделюванні. Це один із головних моментів, коли в гру вступають людська креативність, здоровий глузд і знання. Іноді результат моделювання напряду залежить від того, наскільки добре аналітики структурують задачі, відбирають змінні, не допускають «витоків» [132].

Використання сучасних інструментів машинного навчання та штучного інтелекту дозволяє автоматизувати процес передобробки, що знижує ризик людських помилок та підвищує точність результатів. Крім того, новітні програмні засоби, такі як Python та R, надають дослідникам потужні бібліотеки для обробки та аналізу даних, що сприяє швидкому та ефективному виконанню складних завдань. Усе це створює міцну основу для проведення якісних статистичних досліджень та прийняття обґрунтованих рішень. В самому загальному вигляді аналіз даних включає наступні етапи:

I. **Підготовка (передобробка) даних:** спершу дані потрібно підготувати, тобто зібрати, очистити та відібрати ті, які будуть потрібні для побудови моделі. Цей процес займає близько 90% часу і називається процесом передобробки даних.

II. **Моделювання:** ми будуємо модель та валідуємо її результати.

III. **Трактування та оцінка результатів:** презентація результатів, яка включає трактування, оцінку та ситуаційний аналіз “what-if”. На цьому етапі ми демонструємо на яке питання ми шукали відповідь, які тенденції розвитку і взаємозалежності

показників нам вдалося відстежити. Також на цьому етапі ми робимо прогнозування яким чином зміниться результуючий показник, якщо вплинути на інші показники, що залежать від нього.

1.1.1. Підготовка даних

Матриця даних – це стартовий елемент для аналізу даних. Зазвичай йому передуює етап збору, очищення та представлення у табличному вигляді. По рядках таблиці можуть знаходитись: респонденти, суб'єкти, учасники, спостереження. По стовпцях - характеристики кожного запису (тобто змінні). Також важливо звертати увагу на одиниці виміру і яким чином були зібрані ці дані. Для того, щоб описати вміст таблиці даних в більш зрозумілій формі використовують узагальнення та опис типових чи середніх значень. Для цього важливо знати тип даних. Класифікація даних, що використовуються при аналізі, наведена на рисунку 1.1:




Рис.1.1 Класифікація типів даних для проведення аналізу.

1.1.2. Побудова і валідація моделі

Результатом моделювання є певна модель, що демонструє закономірності в даних. Етап моделювання показує як методи інтелектуального аналізу даних застосовуються до даних. Важливо мати певне розуміння фундаментальних ідей інтелектуального аналізу даних, включаючи різновиди методів і алгоритмів, які існують.

1.1.3. Оцінка і трактування результатів

Трактування результатів чи не найважливіша частина дослідження. Невірне трактування результатів дослідження призводить до маніпуляцій. Детальніше про це можна прочитати у книзі Darell Huff "How to Lie with Statistics", яка була видана ще в 1954 році. Однак, іноді складається ситуація, що й правильне дослідження може мати двояке трактування. Метою етапу трактування є ретельна оцінка результатів аналізу даних і отримання впевненості в тому, що вони дійсні та надійні, перш ніж рухатися далі.

Якщо ми досить уважно розглянемо будь-який набір даних, ми знайдемо закономірності, але вони можуть не витримати ретельного вивчення. Моделі та шаблони, отримані з даних, мають бути справжніми закономірностями, а не просто аномаліями вибірки. Можна розгортати результати одразу після аналізу даних, але це недоцільно; зазвичай набагато простіше, дешевше, швидше та безпечніше спочатку перевірити модель у контрольованій лабораторії чи на емуляторі. Етап оцінювання також допомагає переконатися, що модель задовольняє результуючій цілі.

Нагадаємо, що основна мета науки про дані— це підтримка прийняття рішень, і що ми починаємо аналізувати, зосередившись на проблемі, яку хотіли б вирішити. Зазвичай рішення для аналізу даних є лише частиною більшого рішення, і його потрібно оцінювати саме так. Крім того, навіть якщо модель проходить суворі перевірки в «лабораторії», можуть бути зовнішні

міркування, які роблять її непрактичною. Наприклад, поширеним недоліком рішень виявлення (таких як виявлення шахрайства, виявлення спаму або моніторинг вторгнень) є те, що вони створюють занадто багато помилкових тривог. Модель може бути надзвичайно точною ($> 99\%$) за лабораторними стандартами, але оцінка в реальному контексті може виявити, що вона все ще створює занадто багато помилкових тривог, щоб бути економічно доцільною [143,146,147, 223]. Тому в даному прикладі важливими є відповіді на наступні питання: скільки коштуватиме надання персоналу для роботи з усіма цими помилковими тривогами? Якою буде вартість незадоволеності клієнтів?

Тож як бачимо, оцінка результатів інтелектуального аналізу даних включає як кількісні, так і якісні оцінки. Класифікація методів попередньої обробки даних представлена на рисунку 1.2.




Рис.1.2 Класифікація методів попередньої обробки даних.

Розглянемо більш детально такі методи передобробки даних як класифікація, кластеризація і нормалізація даних, оскільки ця інформація знадобиться нам для подальших досліджень.

1. 2. Методи класифікації даних

Сьогодні в машинному навчанні (Data Mining) є лише чотири основні напрями, які показані на рисунку 1.3.

Класичне навчання люблять ділити на дві категорії — з вчителем і без. Часто можна зустріти їх англійські назви — Supervised і Unsupervised Learning. У першому випадку у машини є якийсь учитель, який говорить їй як правильно. Розповідає, що на цій картинці кішка, а на цій собака. Тобто вчитель вже заздалегідь розділив всі дані на кішок і собак, а машина навчається на конкретних прикладах. У навчанні без учителя, машині просто вивалюють купу фотографій тварин на стіл і кажуть «розберися, хто тут на кого схожий». Дані не розмічені, у машини немає вчителя, і вона намагається сама знайти якісь закономірності [293]. Про ці методи ми і поговоримо нижче.

Очевидно, що з учителем машина навчиться швидше і точніше, тому в бойових задачах його використовують набагато частіше. Ці задачі діляться на два типи:

- а. *класифікація* - передбачення категорії об'єкта, і
- б. *регресія* - передбачення місця на числовій прямій.

Класифікація є найбільш простим та одночасно найбільш часто розв'язуваним завданням Data Mining і відноситься до стратегії навчання з вчителем (supervised learning), яке також називають контрольованим або керованим навчанням. З огляду на поширеність завдань класифікації необхідно чітко розуміння суті цього поняття.

Під *класифікацією* будемо розуміти віднесення об'єктів, спостережень, або подій до одного з заздалегідь відомих класів [295].




Рис. 1.3 Типи машинного навчання [293].

Класифікація поділяє об'єкти за заздалегідь відомою ознакою: шкарпетки за кольорами, документи за мовами, музику за жанрами. Завданням класифікації є передбачення категоріальної залежної змінної (тобто залежною змінною, яка є категорією) на основі вибірки неперервних та / або категоріальних змінних [295]. Наприклад, можна передбачити, хто з клієнтів фірми є потенційним покупцем певного товару, а хто - ні, хто скористається послугою фірми, а хто - ні, та інше. Цей тип завдань відноситься до завдань бінарної класифікації, в них залежна змінна може приймати тільки два значення, наприклад, так чи ні, 0 або 1.

Інший варіант класифікації виникає, якщо залежна змінна може приймати значення з деякої множини визначених класів. Наприклад, коли необхідно передбачити, яку марку автомобіля захоче купити клієнт. У цих випадках розглядається множина класів для залежної змінної.

Класифікація може бути одновимірною (за однією ознакою) та багатовимірною (за двома та більше ознаками). Багатовимірна класифікація була розроблена біологами при вирішенні проблем дискримінації для класифікації організмів. Однією з перших робіт, присвячених цьому напрямку, вважають роботу Р. Фішера (1930 р.), в якій організми поділялися на підвиди залежно від результатів вимірювань їх фізичних параметрів. Біологія була та залишається найбільш затребуваним та зручним середовищем для розробки багатовимірних методів класифікації.

Класифікація вимагає дотримання наступних правил:

- ✓ на кожному кроці поділу необхідно застосовувати тільки одну основу;
- ✓ розподіл має бути пропорційним;
- ✓ члени поділу повинні взаємно виключати один одного, їх обсяги не повинні перехресуватися;
- ✓ розподіл має бути послідовним.

Розрізняють:

- *допоміжну (штучну)* класифікацію, яка проводиться по зовнішній ознаці та служить для додавання множини предметів, процесів, або явищ потрібного порядку;

- *природну* класифікацію, яка проводиться за істотними ознаками, що характеризує внутрішню спільність предметів та явищ. Вона є результатом та важливим засобом наукового дослідження тому, що передбачає та закріплює результати вивчення закономірностей класифікації об'єктів.

Тому, залежно від обраних ознак, їх поєднання та процедури поділу понять класифікація може бути простою і складною, як показано на рис.1.4.




Рис. 1.4. Види класифікації за ознаками.

Популярні алгоритми класифікації:

- I. Наївний Баєс,
- II. Дерева Рішень,
- III. Логістична Регресія,
- IV. К-найближчих сусідів,
- V. Метод Опорних Векторів.

Класифікація речей - найпопулярніша задача у всьому машинному навчанні. Машина в ній як дитина, яка навчається розкладати іграшки: роботів в один ящик, танки в інший. Для класифікації завжди потрібен учитель - розмічені дані з ознаками і

категоріями, які машина буде вчитися визначати за цими ознаками. Далі класифікувати можна що завгодно: користувачів за інтересами - так роблять алгоритмічні стрічки, статті за мовами і тематиками - важливо для пошукових систем, музику за жанрами - згадайте плейлисти, навіть листи у вашій поштової скриньці. До методів класифікації ми іще повернемося дещо пізніше у розділі 1.5.4.

Навчання без вчителя (Unsupervised Learning) було винайдено пізніше, аж у 90-ті, і на практиці використовується рідше. Але бувають задачі, де у нас просто немає вибору. Розмічені дані – це дорога рідкість. Але що робити якщо ми хочемо, наприклад, написати класифікатор автобусів - йти на вулицю руками фотографувати мільйон автівок і підписувати де який? В таких випадках можна спробувати навчання без учителя, яке все ж, частіше використовують як метод аналізу даних, а не як основний алгоритм [293]. Ми підійшли до поняття кластеризації.

1. 3. Методи кластеризації даних складної природи

Кластеризація розділяє об'єкти за невідомою ознакою. Кластеризація - це класифікація, але без заздалегідь відомих класів. Вона сама шукає схожі об'єкти та об'єднує їх в кластери. Кількість кластерів можна задати заздалегідь або довірити це машині. Схожість об'єктів машина визначає за тими ознаками, які ми їй розмітили - у кого багато схожих характеристик, тих давай в один клас.

Кластеризація дуже схожа на класифікацію і є логічним її продовженням, узагальненням задачі класифікації, коли набір класів наперед невідомий. Цей метод ще називають кластерним аналізом. Кластеризація відрізняється від класифікації тим, що для здійснення аналізу не вимагається мати окрему залежну змінну. Задачі розв'язується на початкових етапах дослідження, коли про дані мало що відомо. Її розв'язання допомагає краще усвідомити дані і в цьому сенсі задача кластеризації є описовою. Після визначення кластерів застосовуються інші методи інтелектуального

аналізу з метою встановлення, що означає таке розбиття і чим воно зумовлене.

Наприклад, цим методом користуються навіть діти, відрізняючи об'єкти за принципом схожості-несхожості. Саме так вони відрізняють круг від квадрата, чоловіків від жінок, кішок від собак. Іншим прикладом є задача сегментації ринку, в основі якої лежить припущення, що всі клієнти різні, проте їх можна за схожістю розділити на певну кількість груп.

Завдання кластеризації подібне до завдання класифікації, але її відмінність в тому, що класи досліджуваного набору даних заздалегідь не визначені [95]. Синонімами терміна "кластеризація" є "автоматична класифікація" та "таксономія" [229]. Кластеризація призначена для розбиття сукупності об'єктів на однорідні групи (кластери або класи). Якщо дані вибірки уявити як точки в просторі ознак, то задача кластеризації зводиться до визначення "згущень точок" [95]. Мета кластеризації - пошук існуючих структур. Кластеризація є описовою процедурою, вона не робить ніяких статистичних висновків, але дає можливість провести розвідувальний аналіз та вивчити "структуру даних".

Саме поняття "кластер" визначено неоднозначно: в кожному дослідженні свої "кластери". Перекладається поняття кластер (cluster) як "скупчення", "гроно" [233, 246]. Кластер також можна охарактеризувати як групу об'єктів, що мають спільні властивості [47]. Характеристиками кластера можна назвати дві ознаки: - внутрішня однорідність;

- зовнішня ізолюваність.

Відмінний приклад кластеризації - маркери на картах в Інтернеті. Коли ви шукаєте всі крафтові бари у Львові, машині доводиться групувати їх в кружечки з циферками, інакше браузер зависне в потугах намалювати мільйон маркерів.

Більш складні приклади кластеризації можна згадати в додатках iPhoto або Google Photos, які знаходять особи людей на фотографіях і групують їх у альбоми. Додаток не знає як звуть ваших друзів, але може відрізнити їх за характерними рисами обличчя. Це типова кластеризація. Правда для початку їм

доводиться знайти ці самі «характерні риси», а це вже тільки з учителем.

Питання, що задається аналітиками при вирішенні багатьох завдань, полягає в тому, як організувати дані в наочні структури, тобто розгорнути таксономії [230].

Найбільше застосування кластеризація спочатку отримала в таких науках як біологія, антропологія, психологія [261]. Для вирішення економічних завдань кластеризації тривалий час мало використовувалася через специфіку економічних даних та явищ [125]. У таблиці 1.1 наведено порівняння деяких параметрів завдань класифікації та кластеризації.

Таблиця 1.1

Порівняння завдань класифікації та кластеризації [295].

Характеристика	Класифікація	Кластеризація
Контрольованість навчання	Контрольоване	Неконтрольоване
Стратегія	Навчання з вчителем	Навчання без учителя
Наявність позначки класу	Навчальна множина супроводжується міткою, яка вказує клас, до якого належить спостереження	Мітки класу навчальної множини невідомі
Підстава для класифікації	Нові дані класифікуються на підставі навчальної множини	Наявність множини даних з метою встановлення існування класів або кластерів даних

Кластеризація - це метод машинного навчання, який використовується для групування даних в схожі за характеристиками групи, які називаються кластерами. На

рисунку 1.5 схематично представлені завдання класифікації та кластеризації.




Рисунок 1.5 Порівняння задач класифікації та кластеризації [293].

Слід зазначити, що в результаті застосування різних методів кластерного аналізу можуть бути отримані кластери різної форми. Наприклад, можливі кластери типу "ланцюжка", коли кластери представлені довгими "ланцюжками", кластери подовженої форми та інші, а деякі методи можуть створювати кластери довільної форми [153].

Різні методи можуть прагнути створювати кластери певних розмірів (наприклад, малих або великих) або припускати в наборі даних наявність кластерів різного розміру. Деякі методи кластерного аналізу особливо чутливі до шумів або викидів, інші - менш. В результаті застосування різних методів кластеризації можуть бути отримані неоднакові результати, це нормально та є особливістю роботи того чи іншого алгоритму. Дані особливості слід враховувати при виборі методу кластеризації. На сьогоднішній день розроблено більше сотні різних алгоритмів кластеризації [115].

Основні принципи кластеризації:

I. **Схожість:** Об'єкти в одному кластері повинні бути схожими один на одного за певними характеристиками.

II. **Відмінність:** Кластери повинні бути максимально відмінними один від одного.

III. **Зв'язність:** Об'єкти в одному кластері повинні бути зв'язаними один з одним.

Загальна класифікація методів кластеризації представлена на рисунку 1.6.




Рис. 1.6 Методи кластеризації [85].

1.3.1. Ієрархічні методи кластеризації

Агломеративна кластеризація - це метод, що заснований на групуванні кластерів за принципом «знизу-вгору» (однорівнева кластеризація), на кожному кроці об'єднуючи два кластери, які містять найближчу пару елементів, які ще не належать до одного кластера.

I. Алгоритм найближчого сусіда:

- Ініціалізація: кожен об'єкт сприймається, як окремий кластер.
- Повторення, поки не залишиться k кластерів:
 - Знайти два кластери з найближчими центрами.
 - Об'єднати два кластери з найближчими центрами.

II. Алгоритм найдальшого сусіда:

- Ініціалізація: кожен об'єкт сприймається, як окремий кластер.

- Повторення, поки не залишиться k кластерів:
 - Знайти два кластери з найдальшими центрами.
 - Об'єднати два кластери з найдальшими центрами.

III. Алгоритм середнього зв'язку:

- Ініціалізація: кожен об'єкт сприймається, як окремий кластер.

- Повторення, поки не залишиться k кластерів:
 - Знайти два кластери з найменшою середньою відстанню між об'єктами.
 - Об'єднати два кластери з найменшою середньою відстанню.

IV. Алгоритм повного зв'язку:

- Ініціалізація: кожен об'єкт сприймається, як окремий кластер.

- Повторення, поки не залишиться k кластерів:
 - Знайти два кластери з найменшою максимальною відстанню між об'єктами.
 - Об'єднати два кластери з найменшою максимальною відстанню.

Роздільна (дивізійна) кластеризація - це метод, який починається з об'єднання всіх точок даних в один кластер і рекурсивно розбиває кластери на менші підкластери на основі їхньої відмінності. Ці методи також відомі як кластеризація "зверху вниз". Така кластеризація починається з того, що всі точки даних об'єднуються в один кластер, а потім рекурсивно розбиваються на менші підкластери на основі їхньої відмінності. На відміну від агломеративної кластеризації, яка починається з кожної точки даних як окремого кластера та ітеративно об'єднує найбільш схожі пари кластерів, дивізійна кластеризація - це підхід "розділяй і володарюй", який розбиває великий кластер на менші підкластери. Ось приклади дивізійної кластеризації:

I. Алгоритм DIANA:

DIANA - це дивізійний метод кластеризації, який починається з одного кластера, що містить всі дані, і послідовно розбиває його на підкластери, доки не буде отримано бажану кількість кластерів.

Переваги:

- Можливість виявлення кластерів різної форми та розміру, оскільки об'єкти групуються послідовно на основі схожості.
- Не потребує визначення початкової кількості кластерів.

Недоліки:

- Чутливість до шуму та викидів в даних, оскільки вони можуть вплинути на вибір кластера для розбиття на ранніх етапах.
- Можливість потрапляння в локальний оптимум, оскільки алгоритм не шукає глобально оптимального розбиття.
- Обчислювальна складність може бути високою для великих наборів даних, оскільки необхідно обчислювати внутрішньокластерну дисперсію для всіх кластерів на кожній ітерації.

II. Алгоритм BIRCH:

Збалансоване ітеративне скорочення і кластеризація з використанням ієрархій (BIRCH) - це алгоритм кластеризації, який може кластеризувати великі набори даних, спочатку генеруючи невеликий і компактний підсумок великого набору даних, який зберігає якомога більше інформації. Проходить у дві фази:

- і. Фаза стиснення даних:
- ii. Фаза кластеризації:

Переваги:

- Ефективно працює з великими наборами даних завдяки стисненню інформації про дані на першому етапі.
- Здатний обробляти потокові дані по мірі їх надходження в режимі реального часу.
- Забезпечує ієрархічну структуру кластерів, дозволяючи користувачеві обрати рівень деталізації.

Недоліки:

- Може бути чутливий до вибору міри відстані.
- Якість кластерів залежить від вибраного методу кластеризації.
- Не завжди може знайти оптимальні кластери.

Порівняльна характеристика методів кластеризації представлена в таблиці 1.2.

Таблиця 1.2

Порівняння методів кластеризації [206].

№	Параметр	Агломеративна кластеризація	Дивізійна кластеризація
1.	Категорія	Підхід знизу-вгору	Підхід зверху вниз
2.	Підхід	Кожна точка даних починається у власному кластері, і алгоритм рекурсивно об'єднує найближчі пари кластерів, доки не буде отримано єдиний кластер, що містить усі точки даних.	Всі точки даних починаються в одному кластері, і алгоритм рекурсивно розбиває кластер на менші підкластери, поки кожна точка даних не опиниться у власному кластері.
3.	Рівень складності	Агломеративна кластеризація, як правило, є більш трудомісткою, особливо для великих наборів даних, оскільки цей підхід вимагає обчислення всіх попарних відстаней між точками даних, що може бути дуже дорогим для обчислень.	Порівняно дешевша, оскільки дивізійна кластеризація вимагає лише обчислення відстаней між підкластерами, що може зменшити обчислювальне навантаження.
4.	Інтерпретованість	Дендрограма показує процес злиття кластерів, а агломеративна кластеризація, як правило, дає більш інтерпретовані результати, оскільки користувач може вибрати кількість кластерів на основі бажаного рівня деталізації.	Роздільна кластеризація може бути складнішою для інтерпретації, оскільки дендрограма показує процес розщеплення кластерів, і користувач повинен вибрати критерій зупинки, щоб визначити кількість кластерів.

№	Параметр	Агломеративна кластеризація	Дивізійна кластеризація
5.	Реалізація	Scikit – learn пропонує кілька методів в зв'язку для агломеративної кластеризації, таких як "палата", "повна", "середня" та "одична",	Розділяюча кластеризація наразі не реалізована в Scikit-learn
6.	Викиди	Агломеративна кластеризація краще справляється з викидами, ніж дивізійна, оскільки викиди можуть бути поглинуті більшими кластерами	Роз'єднуюча кластеризація може створювати підкластери навколо викидів, що призводить до неоптимальних результатів кластеризації.
7.	Приклад	Ось деякі з застосувань, в яких використовується агломеративна кластеризація: Сегментація зображень, сегментація клієнтів, аналіз соціальних мереж, кластеризація документів, генетика, геноміка тощо, а також багато інших. Ось деякі з застосувань, в яких використовується агломеративна кластеризація: Сегментація зображень, сегментація клієнтів, аналіз соціальних мереж, кластеризація документів, генетика, геноміка тощо, а також багато інших.	Ось деякі з застосувань, в яких використовується дивізійна кластеризація: Сегментація ринку, виявлення аномалій, біологічна класифікація, обробка природної мови тощо.

1.3.2. Неієрархічні методи кластеризації

Неієрархічні методи кластеризації – це алгоритми, які розділяють множину об'єктів на кластери без формування ієрархічної структури. Ось одна з можливих класифікацій неієрархічних методів:

1. Засновані на центроїдах:

- а. *K-середніх (k-means)*: Об'єкти призначаються до кластерів, які мають найближчий центр.
- б. *K-medoids*: Схожий на k-means, але використовує фактичні об'єкти як центроїди, що робить його менш чутливим до викидів.

2. Засновані на густині:

- а. *DBSCAN* (Density-Based Spatial Clustering of Applications with Noise): Кластери формуються як області високої щільності, розділені областями низької щільності.
- б. *OPTICS* (Ordering Points To Identify the Clustering Structure): Схожий на DBSCAN, але видає упорядкований список кластерів замість простого розподілу.

3. Засновані на матрицях схожості:

- а. *Спектральна кластеризація*: Використовує властивості сингулярних векторів матриці схожості між об'єктами для розділення кластерів.
- б. *Affinity Propagation*: Обчислює "важливість" кожного об'єкта та вибирає екземпляри, які найкраще представляють кожен кластер.

4. Інші методи:

- а. *Алгоритм нечіткої кластеризації (Fuzzy C-means)*: Дозволяє об'єктам належати не тільки до одного, але і до декількох кластерів з різними ступенями належності.

Якщо розглядати на прикладі методи, що засновані на центроїдах, то стиснення зображень це дуже популярна на сьогодні задача. Зберігаючи картинку в PNG, ви можете встановити палітру, скажімо, в 32 кольори. Тоді кластеризація знайде всі «приблизно

червоні» пікселі зображення, вирахує з них «середній червоний» і замінить всі червоні на нього. Менше кольорів - менший файл.

Проблема тільки, як бути з кольорами типу Суан – такий колір ближче до зеленого чи синього? Тут нам допоможе популярний алгоритм кластеризації - метод к-середніх (K-Means). Ми випадковим чином кидаємо на палітру кольорів наші 32 точки, називаючи їх центроїдами. Всі інші точки відносимо до найближчого центроїду від них - виходить таке собі «сузір'я» з найближчих кольорів. Потім рухаємо центроїд в центр свого сузір'я і повторюємо поки центроїди не перестануть рухатися. Кластери виявлені, стабільні і їх рівно 32 як і треба було.

На рисунку 1.7 продемонстровано розв'язання завдання пошуку оптимальних місць розташування кіосків з кавою за допомогою кластеризації на центроїдах.

*Ставимо три кіоски з кавою оптимальним чином
(ілюструючи метод К-середніх)*




Рис.1.7. Розв'язання завдання пошуку оптимальних місць розташування кіосків з кавою за допомогою кластеризації на центроїдах [293].

Шукати центроїди зручно і просто, але в реальних задачах кластери можуть бути зовсім не круглої форми. Ось ви геолог, якому потрібно знайти на карті схожі за структурою гірські породи - ваші кластери не тільки будуть вкладені один в один, але ви ще й не знаєте скільки їх взагалі вийде. До хитрих завдань потрібно застосовувати хитрі методи. Алгоритм DBSCAN, наприклад. Він сам знаходить скупчення точок і будує навколо кластери. Його легко зрозуміти, якщо уявити, що точки - це люди на площі. Знаходимо трьох людей, які знаходяться близько одне до одного, і пропонуємо їм взятися за руки. Потім вони починають брати за руку тих, до кого можуть дотягнутися. Так по ланцюжку, поки ніхто більше не зможе взяти когось за руку - це і буде перший кластер. Повторюємо, поки не поділимо всіх. Ті, кому взагалі нікого брати за руку - це аномалії, їх викидаємо, як показано на рисунку 1.8.




Рис.1.8. Алгоритм кластеризації DBSCAN [293].

Кожен з цих підходів має свої унікальні характеристики, переваги та недоліки. Вибір конкретного методу кластеризації залежить від властивостей даних та вимог конкретного завдання. Галузі використання неієрархічних методів кластеризації наступні:

I. **Сегментація ринку:** кластеризація клієнтів на групи зі схожими потребами чи поведінкою.

II. *Аналіз даних*: виявлення закономірностей і структур в даних.

III. *Біологія*: класифікація генів, білків та інших біологічних даних.

IV. *Обробка зображень*: сегментація зображень на області зі схожими характеристиками.

V. *Рекомендаційні системи*: для рекомендації користувачам продуктів, які їм можуть сподобатися.

VI. *Детектори аномальної поведінки*: поведінка користувача після реєстрації різко відрізняється від нормального? Заблокувати його і створити тикет саппорту, щоб перевірили бот це чи ні. При цьому нам навіть не треба знати, що є «нормальна поведінка» - ми просто вивантажуємо всі дії користувачів в модель, і нехай машина сама розбирається хто тут нормальний [85].

Тепер розглянемо варіант набору даних Фішера про ірис, що містить результати 150 обмірів трьох видів ірису (щетинний, різнокольоровий та віргінський) по 50 вимірів для кожного. Для кожної квітки вимірювалися довжина чашолистка, ширина чашолистка, довжина пелюстки і ширина пелюстки. На рисунку 1.9a показані точки без позначок класу. Інтуїтивно зрозуміло, що в даних є щонайменше два кластери, в нижньому лівому і в правому верхньому кутку. Крім того, якщо припустити, що «хороший» кластер має бути відносно компактным, то крапки у правому верхньому кутку хочеться розбити на два підкластери. Результуюче розбиття на три кластери показано на рисунку 1.9b. При цьому зазначимо, що ніхто не говорить, скільки має бути кластерів; ми самі повинні вибрати компроміс між складністю моделі та якістю апроксимації нею даних.

На рисунку 1.10 показано на тривимірному зображенні три різновиди ірисів, що розділені у просторі ознак. Особливо чітко виділяється ірис щетинистий, тоді як між різнокольоровим та віргінським ірисом є невелике перекриття. Зауважимо, що у загальному випадку дані не зводяться так легко до двох-або тривимірних візуальних характеристик. Зазвичай рішення про кластеризацію доводиться приймати у просторі ознак набагато

вищої розмірності, тому необхідно вдаватися до обчислювальних методів.




Рис. 1.9 (а) Діаграма розсіювання ознак, що стосуються пелюсток, в наборі даних про іріси. (b) Результат кластеризації без вчителя при $K = 3$. [294]




Рис. 1.10 Тривимірне зображення кластеризованих даних про Іріси [294].

1. 4. Методи нормалізації даних

Нормалізація – це процедура попередньої обробки навчальних, тестових та валідаційних вибірок, а також реальних даних, при якій значення ознак у вхідному векторі наводяться до певного заданого діапазону. Вихідні значення ознак можуть змінюватися в дуже великому діапазоні. Робота аналітичних моделей машинного навчання із такими значеннями змінних виявиться некоректною.

Нормалізація даних потрібна в наступних випадках, якщо:

- а) несумісність одиниць вимірів змінних може позначитися на результатах моделювання (наприклад, обчислення, засновані на різних за величиною даних);
- б) підсумкові звіти можуть бути покращені, якщо виразити результати у певних зрозумілих/сумісних одиницях.

Для більшості процедур машинного навчання необхідно, щоб всі ознаки були дійсними та «в одній шкалі». Так, в одному вхідному векторі можуть міститися значення, що відрізняються один від одного на кілька порядків. Нормування є необхідним початковим етапом обробки даних при системному використанні багатьох багатовимірних статистичних методів: зниження розмірності простору ознак, класифікації і т. п., особливо якщо змінні вимірюються в шкалах, що істотно різняться у значеннях.

Якщо зв'язок між початковим і кінцевим діапазонами виражається лінійною функцією, то нормування є *лінійним* (тобто значення ознак по всьому діапазону змінюються на одну й ту саму величину). Якщо використовується нелінійна функція (наприклад, експонента), то нормування є *нелінійним* (тобто значення ознак, що розташовані у різних частинах діапазону, змінюються по-різному). Класифікація методів нормалізації представлена на рисунку 1.11.

Будучи різними за фізичним змістом, дані сильно різняться між собою за абсолютними величинами. Більшість методів, на яких засновані майже всі алгоритми машинного навчання, дуже чутливі до шкалювання даних. Тому перед запуском алгоритмів

найчастіше виконується процедура нормалізації, або стандартизація.




Рис. 1.11 Класифікація методів нормалізації

Різниця між ними в тому, що нормалізація передбачає заміну номінальних ознак так, щоб кожна з них лежала у діапазоні від 0 до 1. Стандартизація ж має на увазі таку попередню обробку даних, після якої кожна ознака має середнє значення 0 та дисперсію 1. Щоб виконати нормалізацію даних, потрібно точно знати межі зміни значень відповідних змінних (теоретично можливі мінімальне та максимальне значення). Тоді їм і відповідатимуть межі інтервалу нормалізації.

Коли точно встановити межі зміни змінних неможливо, вони задаються з урахуванням мінімальних та максимальних значень наявної вибірки даних. При нормуванні потрібно знати теоретично можливий максимальний діапазон зміни величини. Однак, якщо він невідомий, то як вихідний діапазон доводиться використовувати різницю між мінімумом і максимумом, які спостерігаються. Основні методи нормалізації представлено в таблиці 1.3.

Таблиця 1.3

Методи нормалізації даних [297]

№	Тип нормалізації	Границі	Формули нормалізації та денормалізації
1	Лінійна нормалізація (метод мінімаксу)	[0, 1]	$\tilde{x}_{ik} = \frac{x_{ik} - x_{\min_i}}{x_{\max_i} - x_{\min_i}};$ $y_{jk} = y_{\min_j} + \tilde{y}_{jk}(y_{\max_j} - y_{\min_j});$
2		[-1, 1]	$\tilde{x}_{ik} = 2 \frac{x_{ik} - x_{\min_i}}{x_{\max_i} - x_{\min_i}} - 1;$ $y_{jk} = y_{\min_j} + (\tilde{y}_{jk} + 1)(y_{\max_j} - y_{\min_j})/2,$ где $x_{\min_i} = \min_{k=1..N}(x_{ik}); x_{\max_i} = \max_{k=1..N}(x_{ik})$.
3	Масштабування (лінійне шкалювання)	[a, b]	$\tilde{x}_{ik} = \frac{(x_{ik} - x_{\min_i})(b - a)}{x_{\max_i} - x_{\min_i}} + a;$ $y_{jk} = y_{\min_j} + \frac{(\tilde{y}_{jk} - a)(y_{\max_j} - y_{\min_j})}{b - a}.$
4	Стандартизація (z-нормалізація)	$[-3\sigma_{x_k}; 3\sigma_{x_k}]$	$\tilde{x}_{ik} = \frac{x_{ik} - \bar{x}_k}{\sigma_{x_k}}, \text{ где } \bar{x}_k = \frac{1}{n} \sum_{i=1}^n x_{ik},$ $\sigma_{x_k}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_{ik} - \bar{x}_k)^2.$
5	Десяткове масштабування	$[\min(x_{ik}/10^n); \max(x_{ik}/10^n)]$	$\tilde{x}_{ik} = x_{ik}/10^n; y_{jk} = \tilde{y}_{jk} * 10^n.$
6	Нелінійна нормалізація	[0, 1]	$\tilde{x}_{ik} = \frac{1}{e^{-a(x_{ik} - x_{ci})} + 1};$ $y_{jk} = y_{cj} - \frac{1}{a} \ln \left(\frac{1}{\tilde{y}_{jk}} - 1 \right),$
7		[-1, 1]	$\tilde{x}_{ik} = \frac{e^{a(x_{ik} - x_{ci})} - 1}{e^{a(x_{ik} - x_{ci})} + 1}; y_{jk} = y_{cj} - \frac{1}{a} \ln \left(\frac{1 - \tilde{y}_{jk}}{1 + \tilde{y}_{jk}} \right).$
8	М'яке (Softmax) шкалювання	$[-3\sigma_{x_k}; 3\sigma_{x_k}]$	$\tilde{x}_{ik} = \left(1 + \exp \left(-\frac{x_{ik} - \bar{x}_k}{\sigma_{x_k}} \right) \right)^{-1}$

Один із головних способів нелінійної нормалізації – використання сигмоїдної логістичної функції та гіперболічного тангенсу. У разі нелінійної нормалізації різні інтервали вихідного діапазону «стискаються» з різним ступенем, що в деяких випадках дозволяє досягти найкращого результату, підбираючи параметри, що керують формою нормуючої функції.

В нелінійних методах нормалізації основним методом при нормально розподілених даних є м'яке (Softmax) шкалювання. Для деяких даних характерний логарифмічний розподіл: більшість знаходиться поблизу середнього, але є й великі значення. Стандартизація або центрування призводить до нульового

середнього та одиничного стандартного відхилення. Стандартизація передбачає, що дані відповідають гауссівському розподілу. Але маємо пам'ятати, що при цьому знижується надійність результатів.

Нелінійні методи шкалювання мають особливості, які змінюють характер даних, так як вони вносять у дані властивості, яких не було у вихідних даних. Наприклад, нерівномірно розподілені дані стають рівномірно розподіленими, значення, які рідко зустрічаються, стають рівноправними зі значеннями, які зустрічаються часто.

1. 5. Ймовірнісні методи моделювання і аналізу даних.

Здатність встановлювати причинно-наслідкові зв'язки є наріжним каменем когнітивного розвитку людини. Наприклад, одним із перших причинно-наслідкових зв'язків, які вивчає дитина, є те, що іграшка падає, коли її відпускають. Дитина дізнається, що коли іграшка падає, мама кидається її підняти. Розташувавши два вивчені зв'язки в ієрархію, дитина може передбачити та спланувати послідовність подій, наприклад, винайти чудову гру «кидай-підбирай іграшку». З плином часу дитина вивчає складніші зв'язки між елементами навколишнього світу, але зберігається тенденція зв'язувати події в мережу причинно-наслідкових зв'язків. Слово "ймовірність" досить часто використовується в повсякденних розмовах та дискусіях, але при цьому в нього не завжди вкладають один і той самий сенс.

Теорія ймовірності оперує такими поняттями, як: *випробування, подія, ймовірність* (рис.1.12) Розглянемо класичний приклад із підкиданням монетки. Коли ми підкидаємо монетку, ми не можемо сказати "орлом" чи "решкою" вона впаде. Підкидання монетки - це випробування. **Випробування (експеримент)** – це сукупність умов, за яких спостерігається певне явище чи результат. Результатом у прикладі з монеткою є факт, що монетка впала "орлом" або "решкою". Випадання "орла" чи

"решки" - це подія. **Подією** називається факт, який в результаті експерименту може відбутись чи не відбутись. Якщо ми будемо підкидати цю монетку велику кількість разів (наприклад тисячу) і щоразу записувати результат, то зможемо оцінити ймовірність настання кожної події. **Ймовірність** – це чисельна міра впевненості в появі даної події внаслідок нового випробування (рис.1.12).

Випробування (експеримент)	Подія	Ймовірність
• сукупність умов, за яких спостерігається певне явище чи результат	• факт, який в результаті експерименту може відбутись чи не відбутись	• чисельна міра впевненості в появі даної події внаслідок нового випробування

Рис.1.12 Поняття, якими оперує теорія ймовірності.

В традиційній теорії ймовірності ступінь імовірності подій визначається через частоти їх появи. Якщо повторити підкидання монети, скажімо, 10000 разів, то ймовірність появи тієї чи іншої сторони монети збігається до значення 0,5. Нехай $P(A)$ – це ймовірність настання події A . Тоді справедлива нерівність:

$$0 \leq P(A) \leq 1. \quad (1.1)$$

Принцип практичної неможливості малої ймовірності подій: якщо випадкова подія має дуже малу ймовірність, то можна вважати, що в одиничному випробуванні подія не настане.

При застосуванні методу, що базується на частотах появи подій, припускається, що експеримент можна повторювати стільки разів, скільки необхідно. Однак, це не завжди можливо. Наприклад, якщо поставити запитання: "Яка ймовірність зустрічі землян з представниками неземних цивілізацій в наступному році?", то застосувати класичний підхід до визначення цієї ймовірності неможливо тому, що ми не можемо поставити і повторити експеримент. В такому випадку можна застосувати так званий суб'єктивний підхід, який дає можливість оцінити ймовірність одиночної події. Необхідно зазначити, що суб'єктивний підхід

базується на математично обґрунтованій теорії, а не на евристичних методах.

Термін «евристичний» стосується способу вибору цілі або напрямку в розв'язуванні задачі, правильність якого на кожному кроці невідома або не може бути підтверджена. Під евристичними розуміють методи, які дозволяють виконувати побудову моделі без здійснення повного перебору простору всіх можливих структур.

Розглянемо докладніше суть суб'єктивного підходу, яким оперує інструмент байєсівських мереж (БМ). В процесі дослідження та використання байєсових мереж використовують ступінь довіри до тієї чи іншої події. Якщо ступінь довіри до події дорівнює нулю, то ми не віримо, що ця подія станеться взагалі. Якщо ступінь довіри наближається до одиниці, ми впевнені, що подія станеться.

Закон великих чисел стверджує, що якщо ми будемо повторювати експеримент нескінченну кількість разів або принаймні достатньо багато разів, то частка настання нашої події до кількості випадків буде наближатися до реальної ймовірності настання цієї події. Таке трактування ймовірності має назву "**частотна інтерпретація**" і передбачає, що випробування можна здійснити достатньо велику кількість разів. Існує інший підхід до визначення ймовірності, так звана "**байєсівська інтерпретація**". Вона передбачає, що в нас є якась початкова ймовірність, наприклад корумпованості конкретного чиновника, і ми коригуємо цю ймовірність в залежності від фактів (для чиновника це можуть бути подані декларації, нерухоме майно). Сума ймовірностей всіх можливих подій, які можуть настати в результаті випробування (для монети це випадання орлом або решкою) дорівнює одиниці (рис.1.13).

Ймовірність кількох подій

Щоб оцінити ймовірність настання кількох подій, потрібно зрозуміти, як вони співвідносяться між собою. Події можуть бути:

- сумісні,
- несумісні,
- взаємовиключні (рис.1.14).

Частотна інтерпретація	Байєсівська інтерпретація
• $P(A)=m/n$ • $P(A)$ - ймовірність події A • m - кількість випадків, що сприяють настанню події A, • n - загальна кількість випадків	• оцінка ймовірності через суб'єктивну ступінь впевненості в настанні події через спостереження

Рис.1.13 Тракткування ймовірності.




Рис.1.14 Ймовірність настання кількох подій.

Студент може одночасно проходити курс статистики та англійської мови. Це приклад сумісних подій, де подія A - проходить курс статистики, подія B - проходить курс англійської мови. Формула для визначення ймовірності настання події A або події B, якщо події є сумісними:

$$P(A \text{ or } B) = P(A) + P(B) - P(A \text{ and } B). \quad (1.2)$$

Розглянемо приклад: було опитано 77882 людини з 57 країн світу. 36.2% погоджуються з твердженням "Чоловіки повинні мати більше прав ніж жінки". 13.8% з них мають університетську освіту.

3.6% опитаних належать до обох категорій. Яка ймовірність, що випадковим чином обрана людина має вищу освіту або погоджується з твердженням "Чоловіки повинні мати більше прав ніж жінки"? Події "випадковим чином обрана людина має університетську освіту" та "випадковим чином обрана людина погоджується з твердженням" є сумісними. Тому для обчислення ймовірності, що випадковим чином обрана людина з вищою освітою або погоджується з твердженням скористаємось формулою додавання ймовірностей для сумісних подій:

Тобто $P(A \text{ or } B) = P(A) + P(B) - P(A \text{ and } B) = 36.2\% + 13.8\% - 3.6\% = 46.4\%$.

Дві події є **незалежними(independent)**, якщо знання про настання однієї з них не дає можливості оцінити ймовірність настання іншої. Для прикладу, знання того, що надворі йде дощ не дає нам додаткової інформації для оцінки ймовірності виграти в лотереї. Для обрахування ймовірності настання одночасно **незалежних** подій A та B використовуємо формулу:

$$P(A \text{ and } B) = P(A) \times P(B). \quad (1.3)$$

Буває ситуація, коли події залежать одна від одної. Наприклад, у дощовий день ймовірність викликати таксі зменшується. Такі ймовірності називають **умовними(conditional)**. Можемо записати це так:

$$P(\text{викликали таксі} \mid \text{дощ}) = 0.4$$

$$P(\text{викликали таксі} \mid \neg \text{дощ}) = 0.8$$

Де знак $\neg$ означає заперечення. Крім того, також є ймовірність дощу в конкретному місті. Така ймовірність називається **апріорною**. Нехай ймовірність дощу в цьому місті дорівнює 0.7. Тоді, відповідно, $\neg \text{дощ} = 0.3$.

Для умовних ймовірностей ймовірність одночасного настання подій A та B обчислюється за формулою:

$$P(A \text{ and } B) = P(A \mid B) * P(B). \quad (1.4)$$

Якщо ми хочемо обчислити ймовірність викликати таксі, то спочатку оцінимо ймовірність викликати таксі, коли йде дощ і ймовірність цієї події, коли дощу нема.

A - викликали таксі

B –дощ

Використавши формулу $P(A \text{ and } B) = P(A|B) * P(B)$ маємо:

$P(\text{викликали таксі}) = P(\text{викликали таксі і дощ}) + P(\text{викликали таксі і } \neg\text{дощ}) = P(\text{викликали таксі} \mid \text{дощ}) \times P(\text{дощ}) + P(\text{викликали таксі} \mid \neg\text{дощ}) \times P(\neg\text{дощ}) = 0.4 \times 0.7 + 0.8 \times 0.3 = 0.28 + 0.24 = 0.52.$

Поняття інформаційної залежності між об'єктами предметної області є природним для людського мислення. Люди мають тенденцію міркувати у термінах трирівневих зв'язків між факторами: фактор x впливає на y за допомогою z. Тому спроби сконструювати інтуїтивно-зрозумілу модель предметної області призводять до необхідності використання мови, здатної чітко виявляти та формулювати опосередковані залежності між факторами.

Теоретично ймовірності поняття інформаційної залежності моделюється у вигляді умовної залежності (чи відсутності умовної незалежності), яка описує, як наша впевненість у результаті певної події змінюється при отриманні нового знання про факти, за умови, що нам вже відомий деякий набір інших фактів.

Інтуїтивно зрозуміло, що потрібно представляти залежності між елементами у вигляді спрямованого шляху, що з'єднує ці елементи у графі. Якщо залежність між елементами x та y не є безпосередньою і здійснюється за допомогою третього елемента z, то логічно очікувати, що на шляху між x та y перебуватиме елемент z. Такі вузли-посередники «відсікатимуть» залежність між x та y, тобто можна моделювати ситуацію умовної незалежності між ними за відомого значення безпосередніх факторів впливу (рис.1.15).

Дві події є незалежними, якщо:	Дві події є залежними, якщо:
• знання про настання однієї з них не дає можливості оцінити ймовірність настання іншої: • $P(A B) = P(A)$	• знання про настання однієї з них змінює ймовірність настання іншої: • $P(A B) = (P(B A) P(A)) / P(B)$

Рис.1.15. Залежні і незалежні події.

Формули для розрахунку ймовірності кількох подій представлені на рисунку 1.16.




Рис.1.16 Розрахунок ймовірності кількох подій.

1.5.1. Формула Байєса




**Рис.1.17 Томас
Байєс
(1702–1761 рр.)**

Теорему (або формулу) Байєса розробив англійський священник і математик Томас Байєс [16]. Преподобний одним з перших зацікавився ймовірністю настання подій у майбутніх випробуваннях, ґрунтуючись на інформації про минулі випробування (рис.1.17). Саме теорема Байєса пов'язує апріорні та апостеріорні ймовірності причин після спостереження за наслідками. У 1763 році у посмертній роботі Т. Байєса "Опис методу розв'язання задачі в рамках доктрини випадкових подій" ("An Essay Towards Solving a Problem in the Doctrine of Chances"), опубліко-

ваній його товаришем Річардом Прайсом (Richard Price, 1723 – 1791 рр.) в п'ятдесят третьому номері лондонського журналу Філософського Королівського Товариства [16], було вперше застосовано поняття ймовірності в індуктивному сенсі і встановлені основи ймовірнісного судження та висновку. А практичне застосування теорема Байєса знайшла в теорії ймовірностей одразу після опублікування. Він першим запропонував застосування створеної ним теореми для коригування переконань на основі врахування свіжоотриманої інформації.

Сутність байєсівської парадигми полягає в наступному: якщо дослідник знаходить нову інформацію, то з'являється основа для вимірювання ймовірностей, зумовлених пов'язаними подіями. При докладному вивченні складних соціально-економічних систем, у яких наявний обов'язковий облік високого ступеня невизначеності, байєсівський підхід є дуже актуальним і перспективним. На його основі розроблено математичний апарат, який дозволяє поєднувати вже існуючі апріорні уявлення про об'єкт з вибірковою інформацією. У результаті дослідник має в своєму розпорядженні апостеріорну функцію щільності розподілу ймовірностей, яка відноситься до параметра або до перевірки гіпотез. Крім того, в умовах нічим не обмеженого зростання обсягу

вибірки байєсовські оцінки збігаються з класичними оцінками. Застосування байєсівської теореми має передумови, головною з яких є наявність певних співвідношень між ймовірностями тих явищ, які мають неоднаковий характер і специфікації на необхідному рівні будь-якого явища. Слід виділити деякі особливості теореми Байєса:

а) абсолютно всі параметри та величини вважаються випадковими: конкретне значення тих чи інших параметрів досліднику невідоме - це означає, що параметри випадкові з погляду незнання дослідника;

б) теорема Байєса застосовується навіть і за нульового обсягу вибірки: у такому разі значення апостеріорного (результуючого) та апріорного (початкового) розподілів рівні;

с) щоб оцінити невідомі змінні, застосовують апостеріорні розподіли: пошук розв'язання задачі з оцінювання певної величини – визначення апостеріорного розподілу даної величини;

д) головний інструмент підходу – формула Байєса, діють правила:

- *sum – rule*: якщо $A_1, \dots, A_k$ – події, що виключають одна одну, то одна з них завжди відбувається;
- *product – rule*: будь-яку спільну щільність можна завжди розбити на множники.

Теорема (формула) Байєса – одна з головних теорем елементарної теорії ймовірностей, що дозволяє визначити ймовірність тієї чи іншої події за умови, що сталася інша подія, статистично взаємозалежна з нею. Іншими словами, формула Байєса дає можливість більш точно перерахувати ймовірність за допомогою взяття до уваги не тільки вже відомої інформації, а й нової, отриманої під час спостережень. Формула Байєса виводиться з основних аксіом теорії ймовірностей, безпосередньо з умовної ймовірності.

Відмінна риса формули Байєса полягає в тому, що у її практичному застосуванні немає необхідності робити велику кількість розрахунків та різних обчислень. З цієї причини байєсовські оцінки активно почали застосовувати лише після революції в мережевих і комп'ютерних технологіях. Завдяки теоремі Байєса стає можливою зміна значення ймовірності,

заснованого на пізніше отриманих відомостях. Байєсовські методи виявилися ефективними при знаходженні рішень у сфері статистики та машинного навчання [190].

Формула Байєса являє собою модель раціонального вибору в умовах неточної або неповної інформації. Процес прийняття рішень може ґрунтуватися на двох протилежних методах – *дедукції* й *індукції*. Обираючи шлях дедукції, виходять із певної гіпотези або припущення про сутність події й припускають, що відбудеться згодом, якщо ця гіпотеза достовірна. Оскільки між гіпотезою й передбачуваним розвитком подій існує стійкий зв'язок, дедукція вважається об'єктивним методом, але вона лише підтверджує або спростовує запропоновану гіпотезу й не здатна створити нові знання.

Індуктивні міркування мають протилежну спрямованість: гіпотези будуються й оцінюються на підставі даних досвіду. В основі доказу лежить процес індукції, що відображає перехід від спостережень до закономірностей, що є їх основою. Переваги індуктивного методу аналізу полягають у тому, що за допомогою даних досвіду одержують додаткову інформацію про раніше невідомі явища, будують нові гіпотези й поглиблюють свої знання про зовнішній світ. Однак при цьому неминуче виникає так звана проблема індукції: не можна бути повністю впевненим у правильності доводів. Значно складніше функціонує індуктивна диференціальна діагностика, що реалізується у знаходженні ймовірності різних визначень, виходячи з наявної інформації й результатів проведених досліджень. Таким чином, дедуктивний метод надійніший і об'єктивніший, але менш продуктивний, ніж індуктивний [296].

Теорема Байєса виглядає наступним чином:

$$P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A)}, \quad (1.5)$$

де A та B – події;

$P(A) > 0$, ймовірність настання події A ;

$P(B)$ ймовірність настання події B ;

$P(B | A)$ ймовірність настання події B , якщо відбулася подія A ;

$P(A | B)$ ймовірність настання події A , якщо відбулася подія B .

Розберемо цю формулу більш детально з математичної точки зору. Саме процес обчислення ймовірностей є основою для прийняття рішень в умовах невизначеності. Розкриття невизначеності здійснюється у байєсових мережах шляхом обчислення ймовірностей станів вершин, що нас цікавлять, на основі наявної інформації про значення (частини) інших вершин мережі. Математичне підґрунтя для цього процесу визначає байєсівський підхід до аналізу невизначеності і відповідний йому апарат класичної теорії ймовірностей.

Основу байєсівського підходу складає поняття умовної ймовірності. Умовна ймовірність – це ймовірність настання події за умови настання іншої події. Умовна ймовірність $P(A|B) = x$ означає, що при умові виникнення B імовірність виникнення A дорівнює x . Спільна ймовірність наступу A і B визначається формулою повної ймовірності:

$$P(A, B) = P(A, B) \cdot P(B) = P(B|A) \cdot P(A). \quad (1.6)$$

Рівняння (1.6) є фундаментальним правилом числення ймовірностей і основою для *теорема Байєса*:

$$P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A)}. \quad (1.7)$$

Теорема Байєса застосовується, якщо існує інформація про залежні змінні (*свідомства*), а суть дослідження полягає у визначенні ймовірностей вихідних змінних (*причин*). Так, за умови наявності умовної ймовірності $P(B|A)$ виникнення деякої події B при умові, що має місце подія A , теорема Байєса дає розв'язок оберненої задачі – якою є ймовірність виникнення події A , якщо подія B відбулася? Дійсно, нехай $A_1, A_2, \dots, A_n$ – повна група несумісних взаємовиключних подій (чи альтернативних гіпотез). Апостеріорна ймовірність $P(A_j|B)$ кожної з подій $A_j, j = 1..n$ при умові, що сталася подія B , може бути знайдена через апріорну ймовірність A_j [64]:

$$P(A_j|B) = \frac{P(B|A_j) \cdot P(A_j)}{P(B)} = \frac{P(B|A_j) \cdot P(A_j)}{\sum_{j=1}^n P(B|A_j) \cdot P(A_j)}. \quad (1.8)$$

На основі цієї формули будуються мережі Байєса. Розглянемо на прикладі як застосувати формулу Байєса. В 2009 році найвищий відсоток захворюваності на ВІЛ/СНІД, що становить 25.9%, було зафіксовано в колишньому Свазіленді (з 2018 року країна переіменована на **Есватіні**). Для перевірки використовували тест ELISA, що є одним з найкращих та найточніших тестів. Для тих, хто хворий на СНІД, тест має точність 99.7%, для тих хто не хворий - 92.6%. Завдання полягає в наступному: якщо за результатами тесту людина ВІЛ-інфікована, яка ймовірність що вона дійсно хвора?

Розв'язок:

$P(\text{хвора}) = 0.259$ - апіорна можливість захворіти;

$P(\text{тест} + | \text{хвора}) = 0.997$ – ймовірність, що тест покаже позитивний результат, якщо людина хвора;

$P(\text{тест} - | \text{не хвора}) = 0.926$ ймовірність, що тест покаже негативний результат, якщо людина здорова;

Потрібно оцінити ймовірність що людина дійсно хвора, якщо тест показав позитивний результат, тобто знайти ймовірність $P(\text{хвора} | \text{тест} +)$.

За теоремою Байєса:

$$P(\text{хвора} | \text{тест} +) = \frac{P(\text{тест} + | \text{хвора})P(\text{хвора})}{P(\text{тест} +)}$$

Для обрахунку, нам не вистачає лише інформації яка ймовірність, що тест дасть позитивний результат для будь-якого жителя чи жительки **Есватіні**.

$$\begin{aligned} P(\text{тест} +) &= P(\text{тест} + | \text{хвора}) + P(\text{тест} + | \neg \text{хвора}) = \\ &= P(\text{тест} + | \text{хвора})P(\text{хвора}) + P(\text{тест} + | \neg \text{хвора})P(\neg \text{хвора}) \end{aligned}$$

$$P(\neg \text{хвора}) = 1 - P(\text{хвора}) = 0.741$$

$$P(\text{тест} + | \neg \text{хвора}) = 1 - P(\text{тест} - | \neg \text{хвора}) = 1 - 0.926 = 0.074$$

$$P(\text{тест} +) = 0.997 \times 0.259 + 0.074 \times 0.741 = 0.2582 + 0.0548 = 0.313$$

$$P(\text{хвора} | \text{тест} +) = \frac{P(\text{тест} + | \text{хвора})P(\text{хвора})}{P(\text{тест} +)} = \frac{0.997 * 0.259}{0.313} = 0.825$$

Хід розв'язку обчислення ймовірностей показаний на рисунку 1.14.

Якщо за результатами тесту людина ВІЛ-інфікована, яка ймовірність що вона дійсно хвора?



Рис. 1.18 Хід розв'язку обчислення ймовірностей з використанням теореми Байєса.

1.5.2. Граф-теоретичне представлення байєсівської мережі

Термін *“байєсівська мережа”* був запропонований американським вченим Джудом Перлом [216] у 1985 році з метою узагальнення трьох аспектів:

- об'єктивної природи вхідних даних;
- отримання достовірної інформації при застосуванні теореми Байєса;

- ідеї застосування аналізу причин та наслідків, запропонованої в 1763 році у посмертній роботі англійського священика Томаса Байєса [16]. Байєсівські мережі, що до цього часу застосовувалися під назвою "каузальні мережі" (causal network), тобто мережі з причинно-наслідковими зв'язками, з'явилися на стику двох наук:

- теорії ймовірностей;
- теорії графів [120,121].

Ідея впровадження байєсівських мереж полягає у представленні причинно-наслідкових зв'язків процесу у вигляді графа. Назву "байєсівські" мережі отримали завдяки застосуванню в каузальних мережах теореми Байєса. Математичний апарат байєсівських мереж був розроблений американським вченим Джудом Перлом у 1988 році [217]. Використання байєсівських мереж як інструменту інтелектуального аналізу даних передбачає розв'язання двох математичних задач:

- побудова структури БМ;
- формування ймовірнісного висновку.

Перша задача є задачею нелінійної поліноміальної складності. За допомогою рекурентної формули Робінсона можна обрахувати кількість всіх можливих нециклічних моделей, які потрібно проаналізувати. Проте на практиці через обмеження обчислювальних ресурсів повний перебір моделей можна здійснити лише для мережі з кількістю вузлів не більш ніж 7. Задача формування ймовірнісного висновку є складною і відноситься до задач прийняття рішень. Існуючі методи побудови

байєсівської мережі і формування висновку вимагають трудомістких обчислень, тому актуальними є пошук і розробка методів, що дозволяють зменшити обчислювальну складність при моделюванні процесів різної природи мережами Байєса.

Теорія графів, як інструмент дискретної математики, досить широко застосовується для моделювання процесів різної природи. Байєсові мережі – це графи з деякими спеціальними властивостями. Розглянемо основи побудови байєсових мереж у вигляді графів. По аналогії із словом “стан” слово “змінна” неоднозначне. “Змінна” в імовірнісному контексті дійсно означає змінну, а в граф-теоретичному контексті “змінна” означає атрибут. Якщо змінна приймає конкретне значення, то говорять, що має місце конкретна подія. В теорії оцінювання сигналів, аналізі часових рядів та багатьох інших випадках події називають *спостереженнями*.

Вершина БМ представляє дискретну випадкову змінну із скінченим числом станів, або неперервну гаусову випадкову величину. Зараз ми розглянемо БМ з дискретними змінними, для яких як синоніми вживаються назви „вузол” чи „вершина”. Ребра між вершинами представляють причинно-наслідкові зв’язки між ними.

Якщо вершина не має батьків (тобто не існує ребер, спрямованих до неї), вона буде характеризуватись таблицею безумовних імовірностей. У випадку дискретної вершини така таблиця містить розподіл імовірностей між усіма можливими станами цієї вершини. Якщо ж вершина має батьків (тобто одне чи декілька ребер, направлених до неї), то вона містить *таблицю умовних імовірностей*, кожна комірка якої містить умовну ймовірність перебування вершини у певному стані у випадку певної конфігурації станів усіх її батьків. Таким чином, число комірок таблиці умовних імовірностей дискретної вершини БМ дорівнює добутку кількості можливих станів цієї вершини на добуток кількостей можливих станів усіх її батьківських вершин.




Рис. 1.19 Тривіальна байєсова мережа [149].

Проста БМ, що зображена на рисунку 1.19, відображає причинно-наслідковий зв'язок між двома елементами деякої предметної області – A і B . Наявність причинного зв'язку змінних A до B означає те, що коли A знаходиться у деякому стані, це має вплив на стан B .

Випадкова дискретна змінна, яка відповідає вершині A , може знаходитись в одному з двох станів – a_1 , або a_2 . Вершина B має три можливих стани: b_1, b_2, b_3 . Таблиці умовних ймовірностей для цих вершин мають такий вигляд:

Таблиця 1.4

Умовні ймовірності для вершин тривіальної мережі.

A	$P(a_i)$	B	$P(b_i a_1)$	$P(b_i a_2)$
a_1	0.5	b_1	1	0.6
a_2	0.5	b_2	0	0.2
		b_3	0	0.2

Оскільки вершина A не має батьків, значення ймовірностей її станів не є залежними, про розподіл ймовірностей станів вершини A у такому разі говорять, що задані апріорні ймовірності її станів. Для вершини B , навпаки, ймовірності станів залежать від стану її батьківської вершини A :

- якщо A знаходиться у стані a_1 , то B знаходиться у стані b_1 ;
- якщо A знаходиться у стані a_2 , то ймовірність знаходження B у стані b_1 дорівнює 0,6, а у станах b_2 і b_3 дорівнює 0,2.

Отже, мережа Байєса представляє собою пару (G, P) , де $G = (V, E)$ – спрямований ациклічний граф на скінченній множині вершин V , поєднаних між собою сукупністю спрямованих ребер E , а P – множина (умовних) розподілів ймовірностей, що визначають мережу. Компонента B містить параметри

$$\Theta_{X^{(i)}|pa(X^{(i)})} = P(X^{(i)}|pa(X^{(i)}))$$

для кожного можливого значення $x^{(i)} \in X^{(i)}$ та $pa(X^{(i)}) \in Pa(X^{(i)})$, де $Pa(X^{(i)})$ позначає набір батьків змінної $X^{(i)} \in G$. Кожна змінна $X^{(i)} \in G$ представляється у вигляді вершини. Якщо розглядають більше одного графа, то для визначення батьків змінної $X^{(i)}$ в графі G використовують позначення $Pa^G(X^{(i)})$.

Повна спільна ймовірність мережі Байєса обчислюється за формулою:

$$P_B(X^{(1)}, \dots, X^{(N)}) = \prod_{i=1}^N P_B(X^{(i)} | Pa(X^{(i)})) \quad (1.9)$$

З математичної точки зору мережа Байєса – це модель подання існуючих і відсутніх імовірнісних залежностей. При цьому зв'язок $A \rightarrow B$ є причинним, коли подія A – причина виникнення події B , тобто коли існує механізм, відповідно до якого значення, прийняте A , впливає на значення, прийняте B . Мережу Байєса називають причинною (каузальною), коли всі її зв'язки є причинними.

БМ має наступні властивості:

- а) кожна вершина з множини V може приймати одне значення зі скінченної множини взаємовиключних значень (станів);
- б) кожній вершині $A \in V$ зі змінними-батьками $B_1, B_2, \dots, B_n$ поставлена у відповідність таблиця умовних імовірностей $P(A | B_1, B_2, \dots, B_n)$.

Якщо вершина A не має батьків, то замість умовних імовірностей автоматично використовуються безумовні ймовірності $P(A)$. Якщо дуги цього графа спрямовані, то його називають *спрямованим ациклічним графом* (САГ). Якщо спрямований граф містить хоча б один замкнений цикл, то його називають *спрямованим циклічним графом* (СЦГ). Приклади спрямованого ациклічного та циклічного графів показані на рисунку 1.20.

Спрямований ациклічний граф називають *одиначно з'єднаним*, якщо між будь-якими його двома змінними існує тільки один шлях, що їх з'єднує.

легко і прямолінійно (рис.1.21). Але всі практичні задачі приводять, як правило, до неоднозв'язаних графів. Такі задачі значно ускладнюють і уповільнюють реалізацію виводу. При побудові та використанні байєсової мережі необхідно чітко знати до якого класу відноситься конкретна змінна – до батьківських, дитячих чи до обох. Зауважимо, що вимога відсутності орієнтованих циклів у графі є суттєвою – для графів зі спрямованими циклами не запропоновано методів обчислення ймовірностей.




Рис.1.21 Однозв'язана (а) та неоднозв'язана (б) мережа.

В цілому, побудова і використання БМ складається з наступних кроків:

1. Збір даних і отримання експертних оцінок.
2. Формування бази даних і їх передобробка.
3. Генерування структури мережі: визначення вузлів і дуг.
4. Визначення апріорних ймовірностей подій.
5. Навчання мережі, навчання параметрів.
6. Оптимізація структури: підвищення точності мережевої моделі.
7. Використання мережі для класифікації, прогнозування, діагностики і т.п.
8. Представлення результатів у формі, зручній для користувача.

1.5.3. Логічний висновок в байєсових мережах

Перед тим, як дати опис практичних алгоритмів числення ймовірностей у байєсівських мережах, наведемо означення деяких характерних для теорії БМ понять. *Спільна ймовірність* (спільний розподіл ймовірностей) усіх вершин мережі є найповнішим статистичним описанням спостережуваних даних. Спільний розподіл представляється функцією багатьох змінних по числу досліджуваних змінних в задачі. У загальному випадку таке описання вимагає задавання ймовірності всіх допустимих конфігурацій станів всіх змінних, що не видається можливим для практичної реалізації. Байєсівська мережа представляє собою компактне представлення повної ймовірності – концепцію збереження інформації, на основі якої може бути обчислена повна ймовірність.

Ланцюгове правило є засобом обчислення повної ймовірності у байєсових мережах. Якщо БМ – байєсова мережа на множині вершин $U = \{A_1, A_2, \dots, A_n\}$, то спільний розподіл ймовірностей є добутком усіх умовних ймовірностей, визначених у БМ:

$$P(U) = \prod_i P(A_i | \text{par}(A_i)), \quad (1.10)$$

де $\text{par}(A_i)$ – множина (станів) батьківських вершин для A_i .

Умовна незалежність вершин байєсової мережі означає блокування впливу між цими вершинами. Змінні (множини змінних) A і C є незалежними при відомому стані змінної B , якщо:

$$P(A|B) = P(A|B, C). \quad (1.11)$$

Це означає, що якщо стан вершини B відомий, то ніяка інформація про C не змінює ймовірностей A .

d – роздільність (англ. *d – separation*) вершин A і B байєсівської мережі означає, що у разі введення нової інформації (свідчення) e має місце рівність:

$$P(A|B, e) = p(A|e). \quad (1.12)$$

Поняття d – роздільності є вираженням властивості людського мислення, що полягає у визначенні конфігурації причинних зв'язків між двома змінними таким чином, що нова інформація про одну змінну не змінює невизначеності іншої.

Маржиналізація означає підсумовування ймовірностей на реалізаціях усіх змінних, окрім обраних. Вона використовується для обчислення ймовірностей змінних, які нас цікавлять, на основі повної ймовірності:

$$P(A) = \sum_B P(A, B) \quad (1.13)$$

Логічний висновок в мережах Байєса означає обчислення умовних ймовірностей деяких змінних на основі наданої інформації про інші змінні.

Розповсюдження в БМ означає процес обчислення апостеріорних ймовірностей для тих вузлів мережі, які не є спостережуваними, на основі значень спостережуваних вузлів (тобто свідощів).

Концептуально можна виділити два підходи до побудови структури БМ і таблиць умовних ймовірностей [216]:

- I. отримання інформації від експертів предметної області;
- II. отримання інформації з даних.

Структура мережі найчастіше визначається експертами предметної області, хоча існують методи структурного навчання БМ на основі даних. Таблиці ймовірності, навпаки, часто генеруються на основі даних за допомогою статистичних методів. Проте слід підкреслити, що принципово суб'єктивний байєсівський підхід не вимагає „об'єктивності” ймовірностей, а тому дозволяє при формуванні таблиць умовних ймовірностей спиратися на суб'єктивні оцінки експертів. Слід також зазначити, що результати логічного висновку більш чутливі до якісної структури БМ, ніж до кількісних значень ймовірностей [118].

Послідовне застосування теореми Байєса для оновлення ймовірностей у БМ має суттєві недоліки:

- а) для того, щоб визначити наступний вузол для виключення, необхідно розглянути усю мережу повністю;

б) вплив свідoctва простежується лише на окремий вузол, для виключених вузлів він невідомий;

с) алгоритм концептуально послідовний, у той час як паралелізм видається більш адекватним для побудови життєздатних моделей людських міркувань.

У 1986 р. було опубліковано *алгоритм логічного висновку* у БМ, що дозволяє уникнути цих недоліків [216,217]. Для прийняття рішень результати логічного висновку є стійкими по відношенню до числових значень імовірностей [216]. Його сутність полягає у використанні поняття *повідомлення*, згідно з яким оновлення імовірностей вершин мережі здійснюється шляхом розсилання кожною вершиною мережі двох типів повідомлень про свій стан:

- 1) повідомлення батьківським вершинам – π -повідомлення;
- 2) повідомлення дочірнім вершинам – λ -повідомлення.

Міра довіри для події $X = x$ за цим алгоритмом розраховується як нормований добуток числового еквіваленту повідомлень $\lambda(x)$ і $\pi(x)$. Оглянемо основні концепції архітектури обміну повідомленнями для обчислення апостеріорних імовірностей. Якщо ми отримали новий розподіл $P^*(A)$ для вершини A у БМ, то фундаментальне правило числення імовірностей і маржиналізація можуть бути використані для обчислення нового розподілу B :

$$P^*(B) = \sum_A P(B|A) \cdot P^*(A). \quad (1.14)$$

Таким чином, розповсюдження в напрямку зв'язків досить просте. Можна розглядати це розповсюдження як повідомлення, надіслане від A до B . Це повідомлення є розподіл A , і на цій основі в B відбувається оновлення розподілу B . Оновлення довіри відбувається і в протилежному напрямку: інформація щодо B може бути використана для зміни міри довіри A . У БМ інструментом розповсюдження імовірностей в зворотному напрямку є теорема Байєса. Не вдаючись в подробиці, скажемо, що ця ситуація також може бути розглянута як розповсюдження розподілу від B до A у вигляді повідомлення. В вузлі A це повідомлення також використовується для оновлення міри довіри.

Розглянемо приклад БМ, граф якої є *деревом*. Повідомлення можуть надсилатися в обох напрямках, тобто вершина дерева X може надіслати повідомлення до будь-якої сусідньої вершини Y . Повідомлення, що надсилається, є поточним розподілом X , і вершина Y використовує це повідомлення для оновлення власного розподілу.

Нехай тепер вершини надсилають повідомлення не упорядковано, після чого на деякий час переходять в режим очікування. Може бути доведено, що у такому разі існує стан рівноваги (*стабільний стан*), в якому жодне подальше повідомлення не буде змінювати розподіл ймовірностей. Більше того, цей стабільний стан може бути досягнутий після скінченої кількості пересилань повідомлень, і у цьому стані кожна вершина буде зберігати коректний розподіл ймовірностей.

Пересилання повідомлень може бути впорядковане за допомогою наступного правила: *вершина X може надіслати повідомлення своєму сусіду Y , якщо X отримала повідомлення від усіх своїх інших сусідів*. У цьому разі листи дерева можуть розпочати надсилати повідомлення, і хоча б одна вершина буде мати можливість надсилання повідомлень до тих пір, поки повідомлення не буде надіслано по кожному ребру дерева уздовж обох напрямків. Доведено – якщо це сталося, то дерево знаходиться у стійкому стані.

Процес розповсюдження інформації ілюструє рисунок 1.22 на прикладі двох інстанційованих змінних, а відповідні результати зведено в таблиці 1.5.

Отже, в алгоритмі, що базується на повідомленнях, вплив кожного нового свідцтва розглядається як збурення, що розповсюджується по мережі шляхом обміну повідомленнями між сусідніми вершинами. Однак досягнення стійкого стану при застосуванні цього алгоритму, так само як і гарантія коректності результатів, вимагають існування деревоподібної структури мережі. БМ має бути полідеревом, тобто спрямованим ациклічним графом, в якому між будь-якими двома вершинами існує лише один маршрут без врахування напрямку ребер [117, 119].




Рис. 1.22. Схематичне представлення розповсюдження інформації між вузлами по мережі [287].

Таблиця 1.5

Процес розповсюдження інформації по мережі [287].

Рисунок	Опис
1.22 а	Ініціалізація дерева
1.22 б	Інстанціювання двох змінних. λ – повідомлення (стрілочки без заповнення) починають розповсюджуватись в напрямку кореневої змінної.
1.22 в	λ – повідомлення продовжують розповсюджуватись в напрямку кореневої змінної. Дві змінні, які отримали λ – повідомлення (з рис.1.22б), змінили рівні своєї довіри, а тому посилають свої π – повідомлення (стрілочки із заповненням) в напрямку змінних, представлених листками.
1.22 г	λ – повідомлення досягли кореневої змінної, для якої оновлюється рівень довіри. Відразу ж після оновлення коренева змінна посилає нові π – повідомлення в напрямку змінних-листіків. Разом з тим, π – повідомлення (з рис.1.22в) приходять до останніх змінних-листіків.

Рисунок	Опис
1.22 д	π – повідомлення кореневої змінної досягають змінних-листіків.
1.22 е	Ситуація така ж, як і на рис.1.22д: π – повідомлення досягають змінних-листіків і мережа переходить в стан рівноваги.

Це суттєве обмеження, оскільки переважну більшість реальних предметних областей неможливо змодельовати на графі без неорієнтованих циклів. Для того щоб обійти це обмеження, було запропоновано велику кількість методів. Наприклад, метод *обумовлення* (англ. *conditioning*) базується на тому, що будь-яка мережа з циклом може бути зведена до полідерава перебором станів кореневої вершини циклу (послідовним обумовленням цієї вершини). Коли вершина обумовлена, тобто знаходиться у певному стані, можна вважати, що вона більше не є частиною мережі, а замість неї розглянути стільки мереж, скільки станів ця вершина має. Після цього теорема Байєса дозволить обчислити умовні ймовірності станів цієї вершини при відомих розподілах імовірностей її сусідських (дочірніх) вершин. Таким чином, за даним методом доведеться обчислити стільки мереж, скільки станів має коренева вершина кожного циклу, а тому цей метод дуже уповільнює обчислення.

Інша ідея використовується в методі *кластеризації* (англ. *clustering*), що був запропонований у 1988 році [216] і розвинений у [162, 217]. Метод кластеризації схожий на метод розповсюдження в деревах, що описаний вище. Однак, в ролі вершин дерева у ньому виступають не окремі вершини, а їх групи (кластери). За допомогою методів теорії графів аналізуються властивості незалежності вершин мережі і формується множина кластерів, які поєднуються у дерево. Отримане дерево має властивість *сполученого дерева* (*junction tree*): для кожної пари (V, W) вершин дерева усі вершини маршруту між V та W містять їх перетин $V \cap W$. Сполучене дерево, що отримане в результаті кластеризації вершин вихідного дерева, є полідеревом, і в ньому можна застосувати обмін

повідомленнями. Після отримання апостеріорних імовірностей для кластерів обчислюються ймовірності вершин вихідного дерева.

Для отримання полідерева з кластерів використовуються механізми сполучення батьківських вершин і перетворення, після якого в графі не залишається циклів, що складаються більше ніж з трьох вершин (триангуляції графа). Полідерево формується на основі графа, що отриманий внаслідок тріангуляції.

Поява і швидкий розвиток наближених методів пояснюються тим, що в загальному випадку при зростанні кількості змінних у байєсівській мережі точне обчислення ймовірностей є вкрай складним з обчислювальної точки зору [68, 162]. Однак, в практичних задачах широко використовуються саме наближені методи.

1.5.4. Алгоритми класифікації на основі байєсових мереж.

Отже, раніше ми з'ясували, що основна задача методу класифікації – встановити, до якого з класів відносяться ті чи інші дані, при цьому множина класів має бути заздалегідь визначена. Кожен клас володіє певними властивостями, що характеризують його об'єкти. Наприклад, в задачі виявлення кредитоспроможності клієнта банківський працівник оперує двома класами: «кредитоспроможний» і «некредитоспроможний». Віднести клієнта до однієї із груп допомагає аналіз ряду характеристик: віку, рівня доходів, місця роботи та інші. Це означає, що задача інтелектуального аналізу даних зводиться до того, щоб визначити один із параметрів об'єкта, аналізуючи значення інших його параметрів. На мові математики це звучить так: визначається значення залежної змінної «кредитоспроможність», яка може набувати значення так або ні за відомими значеннями незалежних змінних (вік, рівень доходу, місце роботи та інші). Для класифікації в Data Mining використовуються наївний Байєсівський класифікатор, дерева рішень, опорні вектори, метод к-середніх, алгоритми покриття та інші [85].

Мета процесу класифікації полягає в тому, щоб побудувати модель, яка використовує атрибути, що вже прогнозовані в якості вхідних параметрів та отримує значення залежного атрибута. Процес класифікації полягає в розбитті множини об'єктів на класи за певним критерієм [113]. Класифікатором називається деяка сутність, яка визначає, якому з визначених класів належить об'єкт по вектору ознак. Для проведення класифікації за допомогою математичних методів необхідно мати формальний опис об'єкта, яким можна оперувати, використовуючи математичний апарат класифікації. Таким описом в нашому випадку виступає база даних. Кожен об'єкт (запис бази даних) несе інформацію про деяку властивість об'єкта.

Нагадаємо, що основна задача методу класифікації – встановити, до якого з класів відносяться ті чи інші дані, при цьому множина класів має бути заздалегідь визначена. Кожен клас володіє певними властивостями, що характеризують його об'єкти. Методи класифікації для структурованих наборів даних поділяються на методи:

- a. дискримінантного аналізу,
- b. логістичної регресії,
- c. k -найближчих сусідів,
- d. неромережеві методи,
- e. метод наївного Байєса,
- f. метод опорних векторів,
- g. дерева класифікації,
- h. гомогенні ансамблеві методи на деревах.

Байєсову мережу можна використати для класифікації досить просто. Одну із змінних можна вибрати як основний клас, і всі інші розглядати як атрибути даного класу. Для обчислення маргінальних розподілів можна використати відомі методи виводу. В загальному випадку для навчання мережі можна скористатись будь-яким методом. Більшість відомих методів спрямовані на апроксимацію спільного розподілу ймовірностей множини випадкових змінних $X = \{X_1, X_2, \dots, X_n\}$. Однак, для класифікації необхідно використовувати тільки маргінальний розподіл змінної основного класу, що передбачає використання

ускладнених підходів до навчання БМ [50]. Розглянемо найбільш важливі результати, які відносяться до побудови БМ для класифікації. Будемо користуватись наступними позначеннями:

B – байєсова мережа на випадкових змінних $\{X_1, \dots, X_n\}$,
 $B = \langle S, \theta \rangle$;

S – спрямований ациклічний граф, який представляє структуру мережі;

θ – параметри байєсової мережі;

X_i – дискретна змінна, яка має r_i можливих конфігурацій $\{x_i^{(1)}, \dots, x_i^{(r_i)}\}$;

$\mathbf{Pa}_i$ – множина, яка включає p батьків змінної X_i , $\{\mathbf{pa}_{i_1}, \dots, \mathbf{pa}_{i_p}\}$, кожна з яких має q_i можливих конфігурацій $\{\mathbf{pa}_i^{(1)}, \dots, \mathbf{pa}_i^{(q_i)}\}$;

$D = \{D_l\}$, $l = 1, \dots, N$ – множина сесій (даних) навчання (без пропусків);

N – число сесій тренувальних даних, $\|D\| = N$;

N_{ijk} – число випадків (сесій) в D , коли випадкова змінна X_i має конфігурацію k , а її батьки, $\mathbf{Pa}_i$ мають конфігурацію j ;

N_{ij} – число випадків (сесій) в D , коли батьки випадкової змінної X_i мають конфігурацію j , $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$;

$F = \{F_k\}$, $k = 1, \dots, M$ – множина ситуацій, які необхідно розпізнавати; при цьому $D_l = \{a^{(l)}, c^{(l)}\}$, де $a = \{x_1, \dots, x_{n-1}\}$ – конфігурація змінних, що використовуються як атрибути;

C – змінна, що представляє собою клас, $C \equiv X_n$;

$\mathbf{A}$ – множина змінних-атрибутів $\mathbf{A} = \{A_1, \dots, A_{n-1}\}$, де $A_i \equiv X_i$, $i = 1, \dots, n-1$;

$\mathbf{c} = \{c^{(1)}, \dots, c^{(N)}\}$ – множина значень класу і $\mathbf{a} = \{a^{(1)}, \dots, a^{(N)}\}$ – множина значень атрибутів, які в сукупності відповідають сесії навчання $D = [\mathbf{a}, \mathbf{c}]$;

γ – множина атрибутів, залежних від змінної класу C ;

λ – множина атрибутів, незалежних від змінних класу C ;

$\|\mathbf{X}\|$ – кардинальність, число елементів множини $\mathbf{X}$;

$q(S, D)$ – функція якості структури байєсової мережі; чим більшим є значення q , тим краще структура S відображає множину тренувальних даних D .

Байєсів підхід до класифікації

Задача класифікації полягає в тому щоб коректно віднести до визначеного класу деякий об'єкт, який характеризується рядом атрибутів або параметрів [50]. За міру якості класифікатора досить часто приймають середню похибку класифікації (або прогнозу), яка визначається за формулою:

$$e = \frac{1}{M} \sum_{k=1}^M [c(k) - \hat{c}(k)] \quad (1.15)$$

де $c(k)$ – правильно заданий клас; $\hat{c}(k)$ – прогноз класу для k -го набору даних.

Якщо метою розв'язку задачі є мінімізація похибки прогнозування класу, то з теорії прийняття рішень відомо, що необхідно вибрати такий клас C^j щоб максимізувати апостеріорну ймовірність визначення класу $p(c^j | a^j, \mathbf{a}, \mathbf{c})$. Це середня апостеріорна ймовірність визначення (прогнозування) коректного класу для C^j із усіх можливих структур S^h :

$$\begin{aligned} p(c^j | a^j, \mathbf{a}, \mathbf{c}) &= \sum_{S^h} \int_{\theta_s} p(c^j | a^j, S^h, \theta_s) p(S^h, \theta_s | \mathbf{a}, \mathbf{c}) d\theta_s = \\ &= \sum_{S^h} p(S^h | \mathbf{a}, \mathbf{c}) \mathbf{E}_{\theta_s | S^h, \mathbf{a}, \mathbf{c}} (p(c^j | a^j, S^h, \theta_s)), \end{aligned} \quad (1.16)$$

де суму необхідно знаходити на всьому просторі усіх можливих структур мережі S^h ; $p(S^h | \mathbf{a}, \mathbf{c})$ – апостеріорна ймовірність конкретної мережевої структури, яка використовується як ваговий коефіцієнт в процесі усереднення. Крім того,

$$p(S^h, | \mathbf{a}, \mathbf{c}) \propto \int_{\theta_s} p(\mathbf{c} | \mathbf{a}, S^h, \theta_s) p(S^h, \theta_s) d\theta_s, \quad (1.17)$$

$$\mathbf{E}_{\theta_s | S^h, \mathbf{a}, \mathbf{c}} (p(c^j | a^j, S^h, \theta_s)) = \int_{\theta_s} p(c^j | a^j, S^h, \theta_s) p(\theta_s | S^h, \mathbf{a}, \mathbf{c}) d\theta_s, \quad (1.18)$$

де $p(S^h, \theta_s)$ – апіорна ймовірність належності класу у просторі допустимих ймовірнісних мереж; $p(\mathbf{c} | \mathbf{a}, S^h, \theta_s)$ – правдоподібність тренувальної вибірки.

Таким чином, стратегія побудови алгоритму класифікації на основі байєсової мережі ґрунтується на проектуванні евристичних процедур, призначених для визначення єдиної структури або множини структур.

Примітивний Байєсів класифікатор

Найпростіший варіант методу, який використовує байєсівську класифікацію, є «наївна» класифікація чи наївно-байєсівський підхід [50]. З допомогою цього підходу розв'язуються багато завдань класифікації. "Наївна" класифікація досить проста для розуміння. Найменування «наївна» походить із припущення про незалежність ознак один від одного. «Наївна» класифікація має такі основні властивості:

- використання всіх змінних та наявність абсолютно всіх зв'язків між цими змінними;
- всі змінні однакові за значимістю;
- усі змінні статистично незалежні.

Перше застосування байєсівської класифікації відбулося на початку ХХІ ст., коли вона була використана для персональної фільтрації спаму. Творцем першого фільтра є Пол Грем. Для коректної роботи цього алгоритму потрібно було виконання таких вимог:

1) класифікований об'єкт повинен мати достатньо ознак. Цій умові задовольняють усі слова більшості листів користувача, крім коротких і тих, що рідко використовуються;

2) постійне поповнення набору "спам - не спам". Ця умова працює коректно в локальних поштових клієнтах, тому що потік «не спаму» у кінцевого клієнта найчастіше є постійним, а якщо й є зміни, то вони відбуваються не стрімко. Але всі клієнти сервера по-різному визначають потік «не спаму», адже один і той самий лист може виступати для одного з них спамом, а для іншого він може бути не спамом. З огляду на цю обставину, якість класифікації у разі фільтрації листів дуже знижується. Примітивний (наївний) Байєсів класифікатор (ПБК) детально описаний в роботі [247].

Раніше всі спам-фільтри працювали на алгоритмі наївного Баєса (рис.1.23).




Рис. 1.23 Спам-фільтр на базі примітивного байєсового класифікатора [293].

Машина рахувала скільки разів слово «кредит» зустрічається в спамі, а скільки разів на нормальних листах. Множила отримані дві ймовірності за формулою Баєса, складала результати всіх слів і ось, - у нас машинне навчання!

Простота його побудови, ефективність та низькі значення похибок привели до широкої популярності його застосування. ПБК має фіксовану структуру та параметри для налагодження його функціонування. Така структура може бути представлена у вигляді байєсової мережі, в якій вузол класу є батьківським вузлом для всіх вузлів-атрибутів, а вузли-атрибути не зв'язані ребрами. Іншими словами, в ПБК змінні-атрибути є умовно незалежними для даної змінної класу. Однак, таке припущення у більшості випадків є нереальним, наївним.

Пізніше спамери навчилися обходити фільтр Байєса, просто вставляючи в кінець листа багато слів з «хорошими» рейтингами і фільтрувати спам стали іншими алгоритмами. Але метод назавжди залишився в підручниках як найпростіший, красивий і один з перших практично корисних [293].

Сьогодні галузі використання методів класифікації надзвичайно широкі:

- а) визначення мови;
- б) пошуку схожих документів;
- с) аналізу тональності;
- д) розпізнавання рукописних букв і цифр;
- е) визначення підозрілих транзакцій.

1. 6. Огляд сучасних методів моделювання даних в задачах машинного навчання

Причинно-наслідкове моделювання дозволяє зрозуміти, які події чи дії насправді є впливовими, а які ні. Класифікація, регресія та причинно-наслідкове моделювання, як правило, здійснюються за допомогою контрольованих методів. Зіставлення подібності, прогнозування посилок і зменшення даних також можуть бути присутні. Кластеризація, групування спільного розташування та

профілювання, як правило, не контролюються. Основні принципи аналізу даних, які ми представимо, лежать в основі всіх цих технологій. Нагадаємо, що існує два основні підкласи контрольованого інтелектуального аналізу даних:

I. Класифікація

II. Регресія.

Регресія передбачає числову ціль, тоді як класифікація включає категоричну (часто двійкову) ціль. Розглянемо проблеми покупки товарів, які ми можемо вирішити за допомогою контрольованого аналізу даних:

1. «Чи придбає цей клієнт послугу S1, якщо отримає стимул I?» Це проблема класифікації, оскільки вона має двійкову ціль (клієнт або купує, або ні).

2. «Який пакет послуг (S1, S2 чи жодного) клієнт, ймовірно, придбає, якщо отримає стимул I?» Це також проблема класифікації з тризначною метою.

3. «Скільки цей клієнт буде користуватися послугою?» Це проблема регресії, оскільки вона має числову ціль [44].

Розв'язання задач прогнозування в задачах машинного навчання вимагає використання сучасної методології системного аналізу до існуючих підходів та методів моделювання і прогнозування, коректної побудови математичних моделей процесів різної природи на основі сучасних розробок в галузі ймовірісно-статистичних методів і теорії оцінювання. Більшість сучасних методів прогнозування [13, 116, 135, 160, 196, 207, 221, 260] не передбачають застосування системного підходу до розв'язання задач прогнозування та не дають відповіді на основне запитання: як організувати процес обробки нелінійних та нестаціонарних даних таким чином, щоб отримати кращі оцінки прогнозів в умовах наявності невизначеностей різних типів (структурних, параметричних та статистичних).

Ці невизначеності зумовлені нестаціонарністю процесу, розвиток якого прогнозується, пропусками даних, неякісними зашумленими даними, наявністю екстремальних значень [45, 114, 152, 156, 175, 242, 263, 286].

Тому необхідно розробляти нові процедури (схеми, підходи) для прогнозування та для оцінювання моделей і прогнозів, які забезпечать якість прогнозування та отримання прийнятних оцінок прогнозів в умовах наявності невизначеностей та недостатньо високої інформативності статистичних даних [99, 116].

В процедурах машинного навчання необхідно використовувати методи моделювання та прогнозування з позиції системного підходу. Він ґрунтується на аналізі процесу, який досліджується, встановленні типів наявних характерних невизначеностей, оцінюванні структури і параметрів моделі та прогнозів на основі побудованої моделі. Тобто нам потрібен підхід ймовірнісного моделювання. До характерних ознак ймовірнісного моделювання відносяться:

1. Ідентифікація та максимально можливе врахування невизначеностей при моделюванні та прогнозуванні.
3. Адаптація математичних моделей до даних, що обробляються.
4. Врахування нестационарності та нелінійності процесів, що досліджуються системою.
6. Застосування валідації для підвищення точності моделі.
7. Застосування аналізу чутливості для відсікання нечутливих вузлів та зв'язків.
8. Оптимізація структури і параметрів прогностичних моделей.
9. Сценарний аналіз результатів моделювання.

Моделі даного типу повинні включати повне уявлення динаміки нелінійних і нестационарних систем на основі спостережуваних фактичних даних.

Сьогодні байєсівський підхід є найпоширенішим з методів обробки *нелінійностей* та *нестационарностей* [287].

Розрізняють два основні сценарії застосування байєсівських мереж:

1. **Описовий аналіз.** Предметна область відображається у вигляді графа, вузли якого репрезентують поняття, а спрямовані дуги, що відображаються стрілками, ілюструють безпосередні

залежності між цими поняттями. Зв'язок між поняттями x та y означає, що знання значення x допомагає зробити більш обґрунтоване припущення про значення y . Відсутність безпосереднього зв'язку між поняттями моделює умовну незалежність між ними при відомих значеннях деякого набору понять.

2. Класифікація та прогнозування. Байєсівська мережа, допускаючи умовну незалежність низки понять, дозволяє зменшити кількість параметрів спільного розподілу, уможливлюючи їхню довірчу оцінку на наявних обсягах даних.

До методології байєсівського підходу відносять наступні методи:

- а) рекурсивне байєсівське оцінювання:
 - фільтрація,
 - прогнозування,
 - згладжування змінних;
- б) приховані марківські моделі;
- в) оптимальні рекурсивні фільтри Калмана;
- г) гранулярні фільтри;
- д) статичні байєсівські мережі;
- е) динамічні байєсовські мережі;
- ж) моделі марківської локалізації;
- з) байєсівські карти;
- и) байєсівський метод обробки даних та прийняття рішень на основі ієрархічних моделей;
- й) байєсівська регресія;
- к) узагальнені лінійні моделі;
- л) байєсівські структурні часові ряди [23-27, 33, 34, 98, 129, 130, 142, 174, 193, 203, 210, 225, 235-237, 244, 286, 288].

1. 7. Переваги і недоліки байєсівського підходу

Теорія побудови байєсових мереж базується на припущенні, що події є вичерпними і не перетинаються. Якщо ця умова не виконується, то результати застосування мережі будуть

неточними. Сила байєсового методу полягає в тому, що апріорні ймовірності можна уточнювати (оновлювати) у відповідності до реалій протікання процесу, що досліджується [190].

Головна перевага байєсовського підходу – застосування будь-якої апріорної інформації щодо модельованих параметрів. Початкові ймовірності "переглядаються" з використанням вибірових даних, що відображаються у вигляді апостеріорного розподілу оцінок параметрів або змінних моделей. Концепція байєсових мереж полягає в оновленні ймовірностей при надходженні додаткової інформації. Математичним підґрунтям цього процесу є теорема Байєса. Байєсову мережу можна розглядати як множину формул Байєса, яка використовується при прийнятті рішень. Однак, для мережі необхідно розробляти також алгоритм розповсюдження ймовірностей, тобто, уточнення спільних ймовірностей на основі поточної інформації. Наведені вище визначення утворюють базис для розробки алгоритму розповсюдження.

На відміну від систем, заснованих на правилах, метод оновлення ймовірностей у байєсових мережах є фундаментальним, і, якщо модель і інформація є коректними, він обчислить нові ймовірності правильно відносно аксіом класичної теорії ймовірностей.

Інформацію може отримувати кожен вузол (змінна) мережі, оскільки метод оновлення ймовірностей є інваріантним відносно напрямку розповсюдження інформації по ребрам мережі. Таким чином, байєсова мережа, як основа, наприклад, експертної системи, значно розширює можливості аналізу і прийняття рішень, оскільки дозволяє робити і прямий, і зворотний логічний висновок одночасно. Крім того, одночасне введення інформації про стани декількох вузлів не змінює алгоритму обробки мережі, що дає можливість виключити ситуації логічної суперечності, які часто мають місце в подібних випадках для інших методів.

Побудова байєсової мережі вимагає докладних знань причинно-наслідкових зв'язків між подіями предметної області. Така ситуація має місце, наприклад, у задачах аналізу зображень,

машинного розпізнавання рукописних текстів чи інших задачах, якість розв'язання яких залежить переважно від досвіду. Якщо йдеться про систему, яка має надавати можливість використання завчасно отриманих експертних знань, а тим більше таких, що мають інтуїтивну складову, то в такому випадку моделювання краще виконувати за допомогою байєсової мережі. Крім того, байєсова мережа так само може навчатись. Суть навчання мережі полягає в коригуванні ймовірностей при отриманні нової інформації про сукупність станів її вузлів.

Використання БМ для аналізу даних дозволяє враховувати та використовувати будь-які вхідні дані – експертні оцінки і статистичну інформацію. Перевагами використання БМ є представлення взаємодії між факторами процесу у вигляді причинно-наслідкових зв'язків, завдяки чому досягається максимально високий рівень візуалізації і, як наслідок, чітке розуміння суті взаємодії факторів процесу між собою. Саме це відрізняє БМ від інших методів, що застосовуються для побудови прогностичних моделей. Також перевагами БМ є можливості врахування невизначеностей статистичного, структурного і параметричного характеру, побудова моделей за наявності прихованих вершин і при неповних спостереженнях, а також формування висновку за допомогою різних методів: наближених і точних.

Нарешті, байєсові мережі в експертних системах мають такі значні переваги, як можливість обчислювального трактування алгоритмів логічного висновку, гнучкість процесу розповсюдження інформації і врахування рівня суб'єктивізму експертів.

БМ використовуються для моделювання предметних областей, які характеризуються невизначеністю. Невизначеність може бути спричинена недостатнім розумінням предметної області, неповним знанням її стану у момент прийняття рішення, випадковим характером механізмів, що визначають поведінку цієї області, впливом випадкових збурень або ж комбінацією усіх перелічених факторів. Підсумуємо переваги і недоліки байєсівських мереж у таблиці 1.6.

Таблиця 1.6

Основні переваги і недоліки байєсівських мереж

Переваги мереж Байєса:	Недоліки байєсівських мереж:
• для використання байєсовського підходу достатньо знання апріорної інформації;	• перемножувати умовні ймовірності потрібно лише у тому випадку, якщо всі вхідні змінні справді незалежні статистично;
• байєсовський підхід є способом використання суб'єктивних ймовірнісних оцінок;	• безпосередня обробка безперервних змінних неможлива: їх необхідно перетворити на інтервальну шкалу, щоб атрибути стали дискретними, проте ці перетворення можуть призвести до втрати значної частини закономірностей;
• зв'язки моделі встановлюються між усіма змінними. Завдяки цьому надається можливість легко обробляти випадки, у яких відсутні значення тих чи інших параметрів;	• у наївно-байєсівському підході на результат класифікації не впливає комбіноване значення пар різних атрибутів. Вплив надають лише індивідуальні значення вхідних змінних;
• мережі Байєса досить легкі у розумінні. Вони дають можливість проведення аналізу за сценарієм «що, якщо» при прогностичному моделюванні;	• визначення всіх взаємодій у мережах Байєса для складних систем не завжди можливе;
• байєсівські мережі можуть поєднувати закономірності, виведені як зі статистичних даних, так і з знання експертів, отримані фактичним шляхом;	• підхід Байєса вимагає знання множини умовних ймовірностей, які зазвичай одержують експертними методами. Застосування програмного забезпечення ґрунтується на експертних оцінках.
• практичне застосування байєсівських мереж допомагає уникнути зайвого ускладнення моделі.	

Висновки до розділу 1

Отже, ми з'ясували, що БМ є графічними моделями причинно-наслідкових зв'язків за умов невизначеності. Висновок у БМ дотримується математичного правила, відкритого англійським математиком Томасом Байєсом. Байєсовська логіка порівнювалася з функціонуванням та принципом навчання людського мозку. Простіше кажучи: кожне спостереження, яке ми робимо, використовується для оновлення нашого колишнього (попереднього) переконання, що призводить до нового, покращеного розуміння. Правило Байєса використовується ітеративно, тобто кожне нове спостереження додатково оновлює наші колишні знання, які використовуються так само, як раніше нові. Байєсівську логіку також називають «зворотною логікою», оскільки вона може використовуватися не тільки для прогнозування подій з урахуванням факторів, але і для визначення ймовірних причин, що ґрунтуються на подіях, які спостерігаються. Це забезпечує ефективне системне навчання та робить байєсовські моделі потужним інструментом аналізу та прогнозування.

БМ має два представлення: графічне та числове. Графічне представлення - це ациклічний граф, який описує відносини, позначені спрямованими дугами, між змінними. Співвідношення визначаються у чисельному поданні шляхом заповнення специфічних для конкретних вузлів таблиць ймовірностей з умовними розподілами ймовірності. Ці розподіли містять інформацію про ймовірність того, що змінна знаходиться в певному стані залежно від стану її батьківських змінних. Для визначення числових залежностей може застосовуватися безліч різних методів, починаючи з детермінованого моделювання, чи прямого використання «жорстких даних» шляхом використання різних алгоритмів навчання. На переконання, що майбутні події обмінюються з низкою попередніх спостережень, статистичні розподіли частот також можуть бути використані. У випадках, пов'язаних із даними або ресурсами, виявлення ступеня переконаності осіб, які вважаються експертами аналізованого

питання, БМ сьогодні широко використовуються. Це часто є значущою альтернативою, оскільки аналіз зазвичай розглядає рідкісні події або рівень небажаного потенціалу розвитку в майбутньому, але ще не матеріалізується. Іноді потреба в оцінці може бути критичною, але ресурси для розподілу часу та грошей обмежені. У таких випадках систематичне подання експертних знань є особливо цінним інструментом. У БМ кожна змінна-батько пояснює частину невизначеності у її дочірній змінній. БМ дозволяє вивчати розподіл ймовірності кожної змінної при переважному стані знання, який може бути визначений шляхом блокування певних змінних у фактичному або гіпотетичному стані. Ця дія відповідно оновлює розподіл ймовірності інших змінних.

Кажуть, що ймовірнісні мережі (також відомі як причинні мережі та байєсові ймовірнісні мережі) пропонують математично обґрунтований формалізм для представлення ймовірносної інформації. Розробляються ефективні алгоритми для створення висновків з інформації, представленої в ймовірнісній мережі. БМ успішно застосовуються в самих різних областях інженерії знань, що вказує на їхню суттєву практичну значимість.

Привабливість байєсівських мереж полягає в тому, що вони дозволяють нам виразити причинно-наслідкові зв'язки або напрямок впливу між компонентами систем за допомогою представлення у вигляді графів. А саме: вузли на графі є змінними, що представляють елементи системи, а ребра показують напрямок впливу. Ієрархія зв'язків у мережі дозволяє нам моделювати взаємодії у великих складних системах у компактний спосіб, який легко сприймає людський мозок. Проте причинно-наслідкові зв'язки не завжди детерміновані. У той час як закон гравітації зміцнює знання дитини про те, що всі тверді предмети падають без опори, вона також дізнається, наприклад, що темні хмари іноді приносять дощ, а іноді проходять повз них без краплі води. Таким чином, виникає уявлення про невизначеність результату. Оскільки вивчені зв'язки стають складнішими і, можливо, до уваги береться більше змінних, модель світу стає більш уточненою, а прогнози точнішими. За допомогою супутникових зображень і

комп'ютерного моделювання ми можемо краще прогнозувати погоду, але елемент невизначеності зазвичай залишається, оскільки часто або непрактично, або неможливо врахувати «все». Байєсовські мережі також враховують цю притаманну нашому життю невизначеність. Вона виражається у формі таблиць умовної ймовірності або функцій щільності ймовірності, що описують зв'язки між змінними.

Таким чином, байєсівські мережі спираються на ті ж фундаментальні принципи, що й людське навчання та представлення знань. На відміну від людського мозку, якому потрібні мільйони років еволюції для розвитку нейронних зв'язків, необхідних для підтримки будь-яких нових моделей, байєсівські мережі можна швидко вивчати та аналізувати за допомогою комп'ютерів. Надаючи байєсівській мережі вхідні дані, ми можемо делегувати комп'ютерам завдання «міркувати» про ймовірність результату, таким чином автоматизуючи процес «мислення» та забезпечуючи обробку великих обсягів даних.

Єдина проблема, яка залишається, полягає в тому, що, коли ми вдосконалюємо наші моделі світу, складність обчислень виходить з-під контролю. Хоча передбачення дощу на основі кольору хмари може бути не завжди точним, його легко отримати. Прогноз, заснований на аналізі метеосистеми в цій області, є більш уточненим, але може вимагати розподіленого комп'ютерного моделювання.

Оскільки навіть потужні суперкомп'ютери мають обмежені ресурси, обчислення точних відповідей у складних моделях стає просто неможливим. Тоді ми можемо або спростити модель, або застосувати алгоритм, який обчислює відповідь швидше, але з меншою точністю.

БМ можна розглядати як свого роду синтез сценаріїв, де враховуються всі можливі комбінації подій, де можна ставити їх у залежність від того, наскільки вони можливі. У порівнянні з традиційними моделями, вони забезпечують більшу гнучкість. Сценарій можна обробляти як частково, так і повністю, що дозволяє шукати найкращі рішення, навіть якщо ми не знаємо,

який із включених прогнозів буде реалізовано. Оскільки продуктивність навіть досить складних дискретних ідентифікаторів пов'язана з новітніми комп'ютерами, великі питання ситуаційного аналізу «що-якщо» можуть бути протестовані і зіставлені в розумні терміни. Завдання моделювання каузальних зв'язків полягає у вивченні причинно-наслідкових зв'язків у системі для отримання уявлення про те, як найкраще її контролювати. Якщо представлено ілюстрацію її графічної структури, то логіка причинно-наслідкової моделі зрозуміла. Прозоре зображення системи призводить до мінімальної двозначності, яка допомагає зрозуміти, як виникають ризики та взаємозв'язки.

Мета аналізу рішень полягає не тільки в тому, щоб знайти дію, яка дає найбільшу очікувану корисність, але й допомогти особі, яка приймає рішення, краще зрозуміти систему та її функціонування. БМ – це потужні інструменти для аналізу. Вони дозволяють інтегрувати та взаємодіяти між матеріалами та методами, які, як вважається, знаходяться за межами один одного. Цей метод також дозволяє ефективно синтезувати роботу, що виконується в окремих проектах БМ, оскільки будь-які дві мережі, що мають щонайменше один ідентичний вузол, можуть бути взаємопов'язані з метою сформувати цілісну систему. Інтеграція розпочинає двосторонній потік інформації між підсистемами, що може дати цікаву інформацію про те, як вони взаємопов'язані.

Контрольні питання:

1. Які етапи включає в себе аналіз даних? Поясніть кожен етап.
2. Які існують типи даних? Наведіть приклади.
3. Класифікація методів попередньої обробки даних.
4. Що таке класифікація даних? Які методи класифікації даних ви знаєте? Наведіть приклади
5. Що таке кластеризація даних? Які методи кластеризації даних ви знаєте? Наведіть приклади
6. У чому полягає алгоритм кластеризації k-means? Для яких структур він застосовується? Вкажіть його переваги та недоліки.

7. У чому полягає алгоритм кластеризації DBSCAN? Для яких структур він застосовується? Вкажіть його переваги та недоліки.

8. Порівняйте методи класифікації та кластеризації. В чому їх схожість, а в чому відмінність?

9. В чому полягає сутність ієрархічних методів (або алгоритмів) кластеризації? Наведіть приклади.

10. В чому полягає сутність дивізійних методів (або алгоритмів) кластеризації? Наведіть приклади.

11. Наведіть приклади застосування неієрархічних алгоритмів кластеризації.

12. Порівняйте методи агломеративної та дивізійної кластеризації. В чому їх схожість, а в чому відмінність?

13. Що таке нормалізація даних? Які методи нормалізації даних ви знаєте. Наведіть приклади.

14. Що означає нормування значень ймовірностей? Наведіть приклади.

15. Дайте визначення поняттям: випробування, подія, ймовірність. Наведіть приклади.

16. Дайте визначення поняття «принцип практичної неможливості малої ймовірності подій». Наведіть приклади.

17. Як ви розумієте термін «евристичний»?

18. В чому полягає закон великих чисел? Дайте трактування частотної і Байєсівської ймовірності.

19. Як підраховується ймовірність настання кількох подій? Наведіть приклади підрахунків.

20. Історія виникнення мереж Байєса. Ким був Томас Байєс і в якому столітті він жив? В чому полягає сутність байєсівської парадигми?

21. Дайте визначення апріорної, апостеріорної та умовної ймовірностей.

22. Дайте визначення формули Байєса. Виділіть особливості теореми Байєса.

23. Що таке мережа Байєса?

24. Яка головна мета побудови мережі Байєса?

25. Мережа Байєса має вигляд спрямованого чи неспрямованого графа?

26. Охарактеризуйте типи мереж Байєса. Чим вони відрізняються?

27. Поясніть формулу обчислення спільної ймовірності мережі Байєса. Наведіть приклад застосування.

28. Дайте визначення поняттям: спільна ймовірність (спільний розподіл ймовірностей), ланцюгове правило, умовна незалежність вершин, маржиналізація.

29. Поясніть своїми словами, що означає термін «ймовірнісний висновок».

30. Дайте означення ймовірнісного висновку у мережах Байєса. Наведіть приклади.

31. Які існують методи та алгоритми формування точного ймовірнісного висновку?

32. Яким ще може бути тип висновку, крім ймовірнісного?

33. Поясніть алгоритм формування точного ймовірнісного висновку на основі навчальних даних. Наведіть приклад використання.

34. Що таке наївний байєсівський класифікатор, його роль та місце серед методів розпізнавання? Приклади використання.

35. Поясніть по кроках алгоритм наївного байєсівського класифікатора. Наведіть приклад використання.

36. Які два основні сценарії застосування байєсівських мереж?

37. Які типи невизначеностей враховуються у мережах Байєса?

38. Які два типи навчання необхідно виконати для побудови мереж Байєса?

39. Чим відрізняються дискретні змінні від неперервних?

40. Чи може мережа Байєса містити одночасно дискретні і неперервні змінні?

41. Наведіть приклади сфер людської діяльності, у яких успішно використовуються мережі Байєса?

42. Наведіть недоліки і переваги використання мереж Байєса?

РОЗДІЛ 2

ТЕХНОЛОГІЯ РОЗРОБКИ СТАТИЧНИХ БАЙЄСІВСЬКИХ МЕРЕЖ

В цьому розділі ми розглянемо основні характеристики і особливості програмних додатків і середовищ роботи з байєсовими мережами, визначимо їх переваги та недоліки.

2. 1. Огляд програмних засобів, що можуть бути використані при роботі з мережами Байєса.

Програмний продукт BayesiaLab дуже зручне у використанні програмне середовище, розроблене французькою компанією Bayesia SA [291]. В програму інтегровано декілька методів для автоматичної побудови БМ та ймовірнісного висновку, особливий інтерес викликає швидкий та зручний метод SopLeq для побудови БМ. Програмне середовище використовується на платній основі. Ціна використання залежить від типу ліцензії та комплектації і коливається від 190€ за найдешевшу академічну версію до 88000€ за повну ліцензію на професійну версію. Існує можливість протестувати програмне середовище безкоштовно протягом першого місяця, але в цьому випадку недоступна функція зберігання результатів роботи. Приклад БМ, побудованої за допомогою програмного середовища *BayesiaLab*, представлений на рисунку 2.1.

Програмний продукт Netica розроблений компанією Norsys Software Corporation, Ванкувер (Канада) сьогодні є дуже популярним серед розробників. Компанія Norsys спеціалізується в розробці програмного забезпечення для байєсових мереж. Програмне середовище Netica – основне досягнення компанії, розробляється з 1992 року і стала комерційно доступною в 1995 році [291]. Нині Netica є одним з найширше використовуваних експертами інструментів для розробки БМ, що оснащена можливістю ймовірнісного виводу. Серед недоліків можна відзначити відсутність автоматичного проектування БМ за навчальними даними. Вартість академічної версії програми складає \$285, а комерційної \$685. Також доступна безкоштовна версія програми, але в цьому випадку максимально можливий розмір БМ для роботи та зберігання обмежується 15-тю

Hugin почав створюватися під час роботи над проектом ESPRIT для задачі діагностики нервово-м'язових захворювань. Потім компанія здійснила комерціалізацію результатів проекту і основного інструменту - програми Hugin. На сьогодні програмне середовище Hugin адаптоване в багатьох дослідницьких центрах компанії в 25 різних країнах, воно використовується у ряді різних областей, пов'язаних з аналізом рішень, підтримкою прийняття рішень, прогнозуванням, діагностикою, управлінням ризиками та оцінками безпеки технологій. Hugin є програмною реалізацією системи підтримки прийняття рішень на основі БМ і має дві версії Pro і Explorer. Система використовує два основні режими роботи:

- а) режим редагування і побудови мережі Байєса,
- б) режим заповнення таблиць умовних ймовірностей та побудови ймовірного висновку.

Ціна програми складає від 6426 до 50999 датських крон в залежності від типу ліцензії. Також є можливість користування безкоштовною версією програмного продукту, але в цьому випадку немає можливості автоматичної побудови БМ. Приклад мережі, побудованої за допомогою програмного середовища Hugin, представлений на рисунку 2.3.

Програмний продукт Bayes Net Toolbox for Matlab розроблений професором Кевіном Мерфі спеціально для системи Matlab і надається безкоштовно [291]. Всі модулі програми доступні користувачу. Існує можливість доповнювати програму своїми методами та модулями. Але платою за цю свободу є необхідність глибокого знання пакету Matlab та повне розуміння теорій БМ. Серед недоліків також треба відзначити відсутність зручного графічного інтерфейсу та можливості візуалізації результатів. Приклад БМ, побудованої за допомогою програмного середовища *Bayes Net Toolbox for Matlab* представлений на рисунку 2.4.

Програмний продукт MSBNx - безкоштовне програмне середовище, розроблене компанією MicroSoft [291]. Основний недолік – це відсутність можливості автоматичної побудови БМ за навчальними даними. Приклад БМ, побудованої за допомогою програмного середовища *MSBNx*, представлений на рисунку 2.5.




Рис. 2.3 Приклад мережі, побудованої за допомогою програмного середовища Hugin [291].




Рис. 2.4 Приклад БМ, побудованої за допомогою програмного середовища *Bayes Net Toolbox for Matlab* [77].





Рис. 2.5 Приклад БМ, побудованої за допомогою програмного середовища *MSBNx* [171].



Програмний продукт GeNie Modeler — це програмне середовище розробки графічних моделей прийняття рішень, яке було розроблене Лабораторією систем прийняття рішень Піттсбурзького університету між 1995 і 2015 роками [291]. Його назва та незвичне використання великих літер походить від назви Graphical Network Interface, наданої оригінальному простому інтерфейсу для SMILE, - бібліотеки класів для графічних ймовірнісних моделей і моделей теорії прийняття рішень. GeNie та SMILE спочатку були створені як основні інструменти навчання та дослідження в академічному середовищі та використовувалися в сотнях університетів по всьому світу. Більшість досліджень, проведених у Лабораторії систем прийняття рішень Піттсбурзького університету, потрапили в академічні версії обох програм. Завдяки своїй універсальності та надійності GeNie та SMILE стали дуже популярними та стали стандартами де-факто в академічних колах. Комерційні версії GeNie та SMILE сьогодні використовує низка урядових, військових та комерційних організацій.

У 2015 році була започаткована компанія BayesFusion, LLC, яка отримала ліцензію на GeNie від Піттсбурзького університету. Продовжуючи традицію Лабораторії систем прийняття рішень, вона надається безкоштовно академічній спільноті для наукового та навчального використання з метою просування теоретичних методів прийняття рішень у системах підтримки прийняття рішень. GeNie було широко протестовано в багатьох навчальних, дослідницьких і комерційних середовищах. Вона постійно вдосконалюється. Сьогодні вже відома четверта версія цього програмного продукту GeNie4.1.

GeNie написана для операційних систем Windows, але також працює на macOS (раніше OS X), під Wine і на Linux за допомогою Wine і дозволяє будувати моделі будь-якого розміру та складності, обмежені лише обсягом оперативної пам'яті комп'ютера. GeNie — це середовище ймовірнісного моделювання. Моделі, розроблені за допомогою GeNie, можна вбудовувати в будь-які програми та

запускати на будь-якій обчислювальній платформі за допомогою SMILE, який є повністю портативним [158].

Найсильнішим елементом GeNIe, який вигідно відрізняє її від великої кількості інших інструментів графічного моделювання, є дружній інтерфейс користувача. Хоча розробка теоретичних моделей прийняття рішень зазвичай займає величезну кількість часу, GeNIe скорочує зусилля на порядки. Водночас SMILE належить до найпростіших у вивченні та використанні, найнадійніших і найшвидших бібліотек для графічних моделей. Приклад БМ, побудованої за допомогою програмного середовища GeNIe2.3, представлений на рисунку 2.7.




Рис. 2.7 Приклад БМ, побудованої за допомогою програмного середовища GeNIe2.3 [158].

Класифікація і основні характеристики програмних продуктів роботи з БМ представлені в таблиці 2.1.

Програма GeNIe 2.0 є програмою вільного доступу, створена на базі технічної лабораторії Пітсбурзького університету. Призначена для графічної побудови мереж вірогідності, на основі модернізованого алгоритму Байєса. GeNIe 2.0 суміжна із такими програмами як Exel, Netika, Hugin, Ergo. Вбудована можливість прогнозувати розвиток подій, й графічно представляти отримані результати [158].

Таблиця 2.1.

Основні характеристики програмних продуктів роботи з БМ.

№	Назва	Ціна	Переваги	Недоліки
1.	<i>BayesiaLab</i>	академічна версія коштує 190 € професійна версія - до 88000 €	- зручність у використанні - інтегровано декілька методів для автоматичної побудови БМ та ймовірнісного висновку, - вбудовано швидкий та зручний метод SorLeq для побудови БМ. - можливість протестувати програмне середовище безкоштовно протягом тестового місяця, але в цьому випадку.	- повна ліцензійна професійна версія коштує дорого; - немає можливості зберігання результатів роботи протягом безкоштовного тестового місяця.
2.	<i>Netica</i>	академічна версія коштує \$285, комерційна - \$685	- можливість ймовірнісного виводу; - академічна версія коштує недорого.	- відсутність можливості автоматичної побудови БМ за навчальними даними. - безкоштовна версія програми дозволяє максимально можливий розмір БМ на 15 вершин, і максимально можливим розміром таблиці вибірки даних – 999 записів.
3.	<i>Hugin-Expert</i>	від 6426 до 50999 датських крон	- є програмною реалізацією системи підтримки прийняття рішень на основі БМ; - має дві версії Pro і Explorer;	при використанні безкоштовної версії програми немає можливості автоматичної побудови БМ.

№	Назва	Ціна	Переваги	Недоліки
			• використовує два основні режими роботи: 1-режим редагування і побудови мережі Байєса, 2-режим заповнення таблиць умовних ймовірностей та побудови ймовірнісного висновку. • є можливість користуватись безкоштовною версією	
4.	<i>Bayes Net Toolbox for Matlab</i>	безкоштовно	• програма надається безкоштовно; • всі модулі програми доступні користувачу; • існує можливість доповнювати програму своїми методами та модулями.	• необхідність глибокого знання пакету Matlab та повне розуміння теорій БМ; • відсутність зручного графічного інтерфейсу та можливості візуалізації результатів.
5.	<i>MSBNx</i>	безкоштовно	• програма надається безкоштовно.	• відсутність можливості автоматичної побудови БМ за навчальними даними
6.	<i>Bayesware Discoverer</i>	від \$3000 до \$8500	• автоматична побудова БМ за навчальними даними, • симуляційне порівняння декількох моделей на основі БМ, • використання алгоритму Bound and Collapse для випадку неповних даних, • заповнення таблиць умовних ймовірностей та побудова ймовірнісного висновку, робота з	• програма є платною. Вартість ліцензії коштує від \$3000 до \$8500.

6

№	Назва	Ціна	Переваги	Недоліки
			- категоріальними даними та неперервними змінними; - можливість безкоштовного використання програми протягом 30 днів без будь-яких обмежень функціональності.	
7.	<i>GeNIe Modeler</i>	безкоштовно	- написана для операційних систем Windows, але також працює на macOS, під Wine і на Linux за допомогою Wine; - дозволяє будувати моделі будь-якого розміру та складності, обмежені лише обсягом оперативної пам'яті комп'ютера; - можна вбудовувати в будь-які програми та запускати на будь-якій обчислювальній платформі за допомогою SMILE, який є повністю портативним; - є дружній інтерфейс користувача; - GeNIe скорочує час на виконання алгоритмів на порядки.	немає

2.1.1. Опис інструментального середовища GeNIe його технічна та інтерфейсна реалізація.

Робоче середовище GeNIe дозволяє розглядати мережу в різних видах, які доступні в меню "View". Є два режими роботи:

- I. Graph view (*Вид Графа*)
- II. Tree view (*Вид Дерева*).

Коли використовуються діагностичні характеристики GeNIe, доступні ще два додаткових види:

- III. Cost Graph View (*Вид Графа Вартості*),
- IV. Spreadsheet View (*Вид Електронної Таблиці*).

Розглянемо значення пунктів основного Меню:

Status Bar (Панель статусу) відображає яка кількість підтверджень і цільових вузлів була встановлена для активної моделі.

Case Manager (Менеджер Випадків) дозволяє користувачам створювати випадки для різних комбінацій підтверджень.

Output window (Вихідне вікно) – місце відображення повідомлень.

Програма GeNIe оснащена інтелектуальним діалоговим агентом, діалоговою системою підказок, урахує роботу із численними моделями за один раз. Кожна модель може мати необмежену кількість довільно вкладених підмоделей. Модель може розглядатися одночасно у вигляді графа (Graph view) й у вигляді дерева (Tree view).

У будь-який момент часу може бути активним тільки одне вікно в робочій області GeNIe (рисунок 2.8).

Graph view – основний вид

Розглянемо Graph view (вигляд графа), що є основним видом моделі в GeNIe. Цей режим відображає орієнтований граф, у якому кожний вузол представляє змінну й кожна дуга являє собою зв'язок між двома вузлами. Це інтуїтивне середовище для створення й редагування мереж, де ми одержуємо модель шляхом організації структури графів у явному виді. Модифікованим

варіантом Graph view є Cost Graph View (вигляд графа вартості). Graph view може ефективно розширюватися шляхом структурування моделі ієрархічно на більш деталізовані підмоделі. Приклад режиму Graph view показаний на рисунку 2.9.




Рис.2.8 Відкрити модель.




Рис.2.9 Приклад простої мережі у режимі Graph view.

Layout menu і кнопки в *Format toolbar* можуть бути використані, щоб змінювати властивості зовнішнього вигляду графа. Команди для відображення або видалення сітки, а також вирівнювання елементів у графі розташовані в *Layout menu*. *Format toolbar* містить кнопки для зміни шрифту, кольору й розміру назв вузлів і кнопки для виконання операцій вирівнювання в тексті й в елементах графа.

Вікно Graph view відкрито за замовчуванням щораз, коли відкривається або створюється нова модель. Воно виглядає як великий аркуш зі змінними, установленними в певні значення користувачем. Можна вибрати команду Open з меню File, щоб

відкрити збережений файл. Створити нову мережу дозволяє команда New з меню File.

Існує три способи закрити вікно Graph view:

1. Вікно Graph view може бути закрито за допомогою клацання на кнопці [X] у правому верхньому куті вікна Graph view.
2. Вибрати команду Close в меню File.
3. Вибрати команду Close Network з меню Network Popur в Tree View.

Якщо всі вікна відкритої мережі будуть закриті, тоді це преведе до закриття файлу, і якщо відбулись будь-які зміни в мережі, GeNIe дасть Вам попередження з діалоговим блоком показаним нижче.



Рис.2.10 Вікно збереження файлу.

Кожна байєсівська мережа відкривається на робочому полі у вигляді окремого графа в робочій області. Подвійне клацання у вільній області *Graph view* відкриє панель властивостей мережі *Network properties sheet*. Якщо ми клацнемо в будь-яке вільне місце області *Graph view* правою кнопкою миші відобразиться керуюче меню вузла Network pop-up, що може бути використано для модифікації різних властивостей мережі.

Робота з вузлами в Graph view.

Створення нових вузлів в Graph View відбувається шляхом вибору підходящого засобу з меню Tool або клацанням на відповідній кнопці в Standard Toolbar. Подвійне клацання на будь-якому вузлі відкриє панель властивостей вузла Node Properties Sheet. Клацання правою кнопкою миші на вузлі відобразить керуюче меню вузла Node pop-up. Воно може бути використано, щоб модифікувати властивості вузла.

За замовчуванням GeNIe відображає імена вузлів у межах іконок вузлів в Graph View. Якщо Ви хочете, щоб GeNIe замість

цього відображала ідентифікатори вузлів, виберіть **Identifiers** в меню **View**, щоб перемкнутись на ідентифікатори. Ідентифікатори повинні початися з букви й можуть містити тільки букви, цифри або знаки підкреслення і тільки англійською мовою (рисунк 2.11).



Рис.2.11 Вікно ідентифікаторів.

Робота з підмоделями в Graph view

Подвійне клацання на будь-який підмоделі в **Graph view** відкриє вид графа для цієї підмоделі. Ви можете вертатися до основної мережі шляхом мінімізації або закриття підмоделі кнопкою в правому верхньому куті вікна підмоделі. Клацнувши правою кнопкою миші на підмоделі можна відобразити керуюче меню **Submodel pop-up**, яке може бути використане для модифікації її властивостей.

Автоматичний формат елементів в Graph view

GeNIe підтримує функцію, що автоматично розташовує вузли в межах основного графа, або будь-якого вікна підмоделей, використовуючи два алгоритми у графовому форматі. Ця функція доступна за допомогою Алгоритмів **Spring Embedder** і алгоритму батьківського впорядкування **Parent Ordering** во вкладці **Graph Layout** в меню **Layout**.

Алгоритм **Spring Embedder** більш розумний і дає менші перетинання дуг і кращий формат графа. **Parent Ordering** є

простим алгоритмом для графа, він розташовує елемент моделі в спадному або висхідному порядку (рисунок 2.12).




Рис.2.12 Команди вибору моделі графу в меню Layout.

Виявлення вузла в межах моделі

Будь-який вузол може бути виявлений у мережі за допомогою команди Find в меню Edit або за допомогою комбінації клавіш Ctrl+F, як показано на рисунку 2.13.




Рис.2.13 Команда виявлення вузла Find в меню Edit.

Режим Cost Graph View

Cost Graph View є модифікованою версією режиму Graph View, що показує вартісну різницю між вузлами мережі. Нижче наведений приклад моделі, сконструйованої в Cost Graph View (рисунок 2.14).




Рис.2.14 Граф оцінювання вагомості.

Режим Cost Graph View може бути активований кнопкою  в Diagnosis Toolbar. У режимі перегляду Cost Graph View, ця кнопка буде недоступна. Повернутися в стандартний вид Graph View можна натисканням на кнопку  знову. Кнопка повертається у свою нормальну позицію і вказує, що ви знаходитесь у стандартному режимі Graph View.

Коли Cost Graph View буде запущено відбудуться наступної зміни:

1. Нормальні дуги темно-синього кольору між вузлами зникнуть, а дуги вартості червоного кольору між вузлами з'являться. Якщо дуги вартості не видимі, тоді вони ще не визначені.

2. Кнопка дуги Arc button  перетворюється на кнопку Cost Arc button  кнопки дуги вартості .

3. Пункт меню дуги вартості Cost Arc menu з'являється в меню Tool.

Можна обрати засіб Cost Arc tool з меню, клацаючи на кнопку Cost Arc button з панелі Standard toolbar і додавати вартісну залежність між вузлами подібно тому, як ми зазвичай додаємо звичайну дугу між вузлами.

Режим Tree View

GeNIe забезпечує альтернативний метод навігації моделі, що називається режим Tree view. Більшість дій, доступних в режимі Graph view, можуть також бути виконані з мережею у вигляді дерева. Незалежно від того, які зміни зроблені у вигляді дерева, вони автоматично і негайно відбиваються у вигляді графа. Вид дерева може також бути використаний для управління моделлю у

вигляді графа, коли, наприклад, потрібно відкрити вікно підмоделі. Інша важлива характеристика виду дерева полягає в тому, що Ви можете перерозподілити вузли між іншими підмоделями й мережами. Розглянемо основні елементи режиму Tree view.

Режим Tree view може бути відображений або схований за допомогою включення або вимкнення опції Tree у меню View (рисунок 2.15). Ви можете для цього також використовувати сполучення клавіш Ctrl+T. Панель Tree View може переміщатися з однієї позиції на іншу і може бути встановлена в будь-якому місці екрана. Нижче наведена типова панель Tree View.

Tree View на рисунку 2.15 показує 2 мережі, SimpleNet і TestNet. TestNet має два вузли, Node0 і Node1 (рисунок 2.16).





Рис.2.15 Дерево рішень. Рис.2.16 Типова Панель Tree View.

Робота з мережами, підмоделями й вузлами у Tree View.

Праве клацання на назві мережі, назві вузла або назві підмоделі відкриє відповідні меню: Network pop-up, Node pop-up і Submodel pop-up. Ці меню слугують для зміни властивості мережі, вузла або підмоделі.

Для переміщення вузлів між мережами й підмоделями можна обрати будь-яку кількість вузлів і підмоделей у дереві й перерозподіляти їх у будь-яку підмодель дерева. Можна також

виконувати операції перерозподілу також між іншими мережами. Якщо вузли з'являються в підмоделі, що перебуває в тій самій мережі, тоді вузли будуть переміщені на їхню нову позицію. Якщо вузли з'являються в іншій мережі або підмоделі іншої мережі, тоді вузли будуть скопійовані в їхню нову позицію.

2.1.2. Типи вузлів в GeNIe Modeler

GeNIe підтримує наступні типи вузлів:

а. дискретні випадкові:

- звичайні
- канонічні

б. детерміновані

с. вузли корисності

д. вузли підмоделі


е. діагностичні,



ф. інші.

В таблиці 2.2 наведена більш детальні інформація про деякі з них.

Таблиця 2.2

Типи вузлів в програмному середовищі *GeNIe Modeler* [158].

Вигляд у мережі	Назва вузла	Опис вузла
	Випадкові	Випадкові вузли, зображувані овалами, позначають довільні змінні. Є два основних типи дискретних випадкових вузлів: Звичайні General і канонічні Noisy-MAX (чи їх інша версія Noisy-OR). Розходження чи відмінності між цими вузлами в графі немає, тому що вони відрізняються тільки у визначенні своїх стохастичних розподілів. Вважається, що вузли Noisy-MAX надають більшу точність розрахунку ймовірності і підвищують адекватність моделі, але при цьому збільшується обчислювальна складність мережі.

Вигляд у мережі	Назва вузла	Опис вузла
	Детерміновані	Детерміновані вузли , зображувані подвійними овалами, позначають детерміновані змінні, тобто або постійні значення або значення, які алгебраїчно визначаються зі станів їхніх батьків.
	Вузли рішення	Вузли рішення , зображуються прямокутниками, позначають змінні, які перебувають під управлінням розробника й використовуються для моделювання вибору рішення розробника.
	Вузли величини	Вузли величини (або їх ще називають вузлами корисності), зображувані шестикутниками, позначають змінні, які містять інформацію про рішення намічених цілей і завдань. Вони відображають виражені переваги рішення для одержання результату над своїми прямими попередниками. Є два основних типи значення таких вузлів: <i>корисність</i> і <i>багатомірна корисність</i> . У графічному поданні вони один від одного не відрізняються. Вузли корисності визначають цифрову оцінку корисності, а багатомірні вузли корисності складаються з об'єднання вузлів корисності. Також багатомірні вузли корисності можуть містити тільки вузли корисності попередників.
	Вузли підмоделі	Вузли підмоделі , які зображають округленими прямокутниками, позначають підмоделі, тобто зв'язані групи змінних.

2. 2. Типи байєсівських мереж.

БМ класифікують на:

- дискретні*
- безперервні*
- динамічні,*
- гібридні* (рис. 2.17).




Рис. 2.17 Класифікація байєсівських мереж.

Характерною ознакою *дискретних БМ* є те, що кожна вершина в них є подія, яка описується випадковою величиною, що може мати кінцеве число станів. *Дискретні мережі Байєса* мають такі *властивості*:

- кожна вершина представляє собою подію, що описується випадковою величиною, яка може мати кілька станів;
- всі вершини, пов'язані з "батьківськими", визначаються таблицею умовних ймовірностей або функцією умовних ймовірностей;
- для вершини без "батьків" ймовірності її станів є безумовними (маргінальними).

Інакше кажучи, у байєсівських мережах довіри вершини представляють собою випадкові змінні, а дуги – ймовірнісні залежності, які визначаються через таблиці умовних ймовірностей. Таблиця умовних ймовірностей кожної вершини містить ймовірності станів цієї вершини за умови станів її "батьків".

Безперервні БМ – це мережі, вузли в яких описують стан змінної безперервного типу, а в багатьох випадках, події можуть приймати різні стани з певного діапазону, який містить безліч точок. Для опису безперервної змінної використовуються функції розподілу ймовірностей. Безперервні БМ частіше використовують для моделювання випадкових (або стохастичних) процесів в просторі станів з безперервним часом [272].

Динамічні БМ – мережі, у яких значення вузлів змінюються з часом. Динамічні мережі Байєса ідеально підходять для моделювання часових процесів. Їх перевага полягає в тому, що вони використовують табличне представлення умовних ймовірностей, що полегшує представлення різних нелінійних явищ [296].

Треба підкреслити, що термін "часова байєсівська мережа" (*temporal Bayesian network*) краще відображає суть, ніж "динамічна байєсівська мережа" (ДБМ) бо передбачає, що структура моделі не змінюється. Зазвичай параметри моделі не змінюються з часом, але до структури мережі завжди можна додати додаткові приховані вузли для опису поточного стану процесу [296]. Вони використовуються для опису того, як змінні впливають одна на одну з часом на основі моделі, отриманої з минулих даних. ДБМ можна розглядати як модель ланцюга Маркова з багатьма станами або дискретне наближення за часом диференційного рівняння з часовими кроками. Умовні ймовірності в динамічних БМ подаються в табличному вигляді [284, 285, 289, 291, 300, 302, 304, 305].

Гібридні БМ – це мережі, в яких вузли бувають як з дискретними, так і з неперервними змінними [298]. Але при використанні гібридних БМ існує ряд обмежень, а саме:

- дискретні змінні не можуть мати неперервних «батьків»;
- неперервні змінні повинні задовольняти закону розподілу, умовному на значеннях «батьків»;
- розподіл неперервної змінної X з дискретними батьками Y та неперервними батьками Z є нормальним розподілом (рис. 2.17).

Такоє існує ще один вид БМ - об'єктно-орієнтовані – про них ми поговоримо в розділі 3.

2. 3. Технологія побудови статичної байєсівської мережі

Побудова ймовірнісної мережі для заданої області знань ручним способом є задачею, що вимагає багато часу. Знання одного чи більше експертів щодо предметної області повинні бути представлені формалізмом ймовірнісної мережі, і, як тільки початкова структура БМ побудована, вона повинна бути перевірена і досліджена з метою подальшого поліпшення її характеристик. Цей процес повторюється до тих пір, поки подальше поліпшення характеристик стає неможливим. Автоматичне проектування ймовірнісних мереж за допомогою баз даних допомагає суттєво скоротити моделювання і цикл тестування мережі.

Алгоритми побудови ймовірнісних мереж, розроблені дотепер, можуть бути розділені на алгоритми, засновані на небаєсових методах, і алгоритми, засновані на методі Байєса (рисунок 2.18).



Рис. 2.18 Алгоритми побудови ймовірнісних мереж.

Небаєсові методи ґрунтуються на застосуванні статистичних тестів до баз даних з метою обґрунтування існування дуг у ймовірнісній мережі. Метод Байєса задає апріорний ймовірнісний розподіл над усіма можливими мережами з подальшим коригуванням цього розподілу на основі вивчення бази даних.

Потім вибирається мережа з найкращою скорегованою ймовірністю. Метод Байєса має кілька переваг над небаєсовими методами, а саме:

- а) для визначення умовної незалежності не використовуються статистичні тести;
- б) в такий спосіб уникається необхідність у використанні великих баз даних;
- в) для обраних алгоритмів використовується природний критерій зупинки замість довільного граничного значення;
- г) може бути отримано множину найбільш ймовірних мереж і включено апріорні знання щодо предметної області.

В основі методу Байєса лежить міра якості, яка є загальною ймовірністю існування мережі конкретної структури після вивчення бази даних. Якщо ми розглянемо міру якості мережі, яка базується на принципі описання мінімальної довжини (MDL-міра), то з'ясуємо, що MDL-принцип походить з теорії кодування, де він застосовується з метою пошуку якомога коротшого описання бази даних за допомогою невеликого числа параметрів. MDL-міра може розглядатися як апроксимація міри Байєса, і, в такий спосіб, є баєсовською інтерпретацією. Вона має кілька переваг над мірою Байєса [63,281].

Технологія побудови БМ досить проста. Ми визначаємо байєсівську мережу як спрямований ациклічний граф, вузли якого відповідають поняттям предметної області, а дуги – безпосереднім стохастичним зв'язкам між ними. Для ймовірнісного розподілу на множині значень вузлів графа ми визначаємо гіпотези про умовну незалежність, факторизацію та поділ відповідної байєсівської мережі. Потім ми доводимо еквівалентність цих гіпотез, що дозволяє користуватися єдиною гіпотезою, яка накладає обмеження на множину параметрів імовірнісного розподілу вузлів в мережі. Ці обмеження відповідають умовній незалежності між вузлами, пов'язаними в мережі через маршрути, що проходять через множини, які розділяють ці вузли.

Потім ми вводимо відношення еквівалентності на множині мереж Байєса: мережі еквівалентні, якщо містять один і той самий

набір висловлювань про поділ. Еквівалентним мережам відповідають однакові гіпотези щодо умовної незалежності. Ми доводимо дві різні необхідні та достатні умови еквівалентності мереж. Мережі еквівалентні тоді і лише тоді, коли вони мають однаковий скелет та v -структури. Мережі еквівалентні тоді і лише тоді, коли одну мережу можна отримати з іншої за допомогою кінцевого числа звернень покритих дуг.

Далі ми отримуємо оцінку максимальної правдоподібності для параметрів мережі. Для того щоб описати байєсівську мережу треба визначити структуру її графа і параметри кожного з вузлів. Цю інформацію отримують з консолідованих даних або з експертних оцінок. Проводимо навчання параметрам, навчання структури мережі за допомогою алгоритмів навчання и робимо оцінку структури байєсівської мережі [228]. Далі ми використовуємо методи пошуку оптимальної з точки зору обраної метрики структури байєсівської мережі. Проводимо валідацію і підвищуємо точність моделі за допомогою аналізу чутливості і діаграм впливу. Повторна валідація і повторне навчання параметрів покажуть нам результуючу точність БМ. На останньому кроці ми проводимо сценарний аналіз і визначаємо тенденції впливу показників. Етапи розробки Байєсової мережевої моделі представлені на рисунку 2.19 і включають у себе наступні кроки:

Визначення вхідних даних. Вхідні дані можуть бути двох видів: дискретні статистичні дані, неперервні статистичні дані або експертні оцінки. В залежності від того з якими даними ми маємо справу ми будемо задавати початкові параметри мережі.

Процес передобробки даних включає приведення початкових даних до вигляду, необхідному для дослідження.

Побудова концептуальної моделі – не є обов'язковим етапом. Іноді, в залежності від постановки проблеми побудова концептуальної моделі допомагає визначитись з показниками і взаємозв'язками між ними.



Рис. 2.19. Етапи розробки байєсової мережевої моделі.

Навчання структури БМ. На цьому етапі можна скористатись алгоритмами пошуку структури, або побудувати структуру мережі вручну.

Навчання параметрів – обов’язковий етап, в ході якого мережа навчається початковим параметрам. Проводиться кожного разу, коли оновлюються дані, або змінюються параметри і зв’язки між ними у мережі [228].

Валідація - обов’язковий етап, в ході якого мережа тестується і визначається точність і адекватність моделі. Проводиться кожного разу, коли оновлюються дані, або змінюються параметри і зв’язки між ними у мережі;

Аналіз чутливості показує які вузли мережі і зв’язки між вузлами не є чутливими, тобто не реагують на зміни.

Підвищення адекватності моделі досягається видаленням нечутливих вузлів і зв’язків, зміною типу ключових вузлів на Noisy-MAX, але тут потрібно бути обережним, тому що разом з цим експоненційно збільшується обчислювальне навантаження на модель та ін.

Повторне навчання параметрів проводиться після видалення зайвих вузлів.

Повторна валідація проводиться після повторного навчання параметрів як необхідна процедура посилення адекватності моделі.

Сценарний аналіз "What-if" дозволяє визначити сценарії при яких можна здійснити вплив на результуючий показник або взаємний вплив на інші показники.

Дуже часто після передобробки даних відбувається етап побудови концептуальної моделі, яку отримують зі знань експертів. Концептуальна модель являє собою модель предметної області, що складається з набору взаємопов'язаних понять, які використовуються для опису цієї області, разом з властивостями й характеристиками, класифікацією цих понять, ознаками в даній області і законів протікання процесів в ній [296].

Змістовна (концептуальна) модель — це доволі абстрактна модель, що визначає структуру модельованої системи, властивості її елементів і причинно-наслідкові зв'язки, властиві системі і суттєві для досягнення мети моделювання [296]. Якщо концептуальна модель присутня, то її побудова відбувається перед пошуком структури статичної БМ. Розглянемо всі етапи окремо.

2.3.1. Дискретизація, як один з методів передобробки даних.

Спершу ми визначаємо топологію мережі і знаходимо значення параметрів всієї мережі. На цьому кроці можливі *два варіанти*:

1) структура мережі нам відома і тоді залишається перенести її у програмне середовище і заповнити таблиці умовних ймовірностей;

2) є лише навчальні дані.

У другому випадку побудова структури здійснюється за два кроки: на першому кроці будується топологія мережі з використанням, наприклад евристичного алгоритму, а на другому - обчислюють оцінки параметрів мережі, які максимально правдоподібні до навчальних даних. У випадку, коли навчальні дані

не задані або їх недостатньо, відбувається генерування псевдовипадкової вибірки за побудованою на першому кроці структурою мережі.

Одним із підходів до формування висновку у гібридній мережі Байєса може бути попередня дискретизація неперервних змінних (тобто зведення гібридної мережі до дискретної) і використання відомих алгоритмів формування висновку для простих БМ. Дискретизація змінної здійснюється у вигляді розбиття діапазону можливих значень на кілька інтервалів. Ідея підходу полягає у розділенні області кожної неперервної змінної на деяке певне кінцеве число множин. Наприклад, таку неперервну змінну, як «вік людини», можна розбити на 6 вікових проміжків:

0–18,
18–25,
25–35,
35–50,
50–70,
70+.

Таким чином, неперервна змінна «вік» представлена дискретною змінною, яка приймає одне з 6 значень. Після чого умовні ймовірнісні розподіли дискретизують і отримують дискретну модель, з якою набагато легше працювати [298]. Методи дискретизації представлені на рис. 2.20.




Рис. 2.20 Методи дискретизації.

Розглянемо метод динамічно-рівномірної дискретизації більш детально. Алгоритм виконання такої дискретизації представлений в таблиці 7.

Таблиця 7.

Покроковий алгоритм динамічно-рівномірної дискретизації [298].

Кроки	Опис
1.	Ініціалізація дискретизації $\Psi_x^{(0)}$ для кожної неперервної змінної $X \in \mathbf{X}$.
2.	Побудова структури об'єданого дерева для визначення кліків F і підмножин.
3.	Для $l=1$ до $\max\_it\_num$
4.	Обчислення таблиць ймовірностей вузлів $P^{(l)}(X pa\{X\})$ на $\Psi_x^{(l-1)}$ для усіх вузлів $X \in \mathbf{X}_\varrho$, що мають нову дискретизацію або, що є нащадками батьківських вузлів, що мають нову дискретизацію.
5.	Ініціалізація об'єданого дерева перемноженням таблиці ймовірностей для усіх вузлів у суттєвих учасниках кліків F
6.	Введення свідчення $X_E = e$ у об'єдане дерево.
7.	Виконання глобального розповсюдження по об'єданому дереву.
8.	Для усіх вузлів $X \in \mathbf{X}_\varrho$
9.	Маржиналізація/нормалізація для отримання дискретних апостеріорних ймовірностей $P^{(l)}(X X_E = e)$
10.	Обчислення відносної помилки ентропії $S_X^{(l)} = \sum_{w_j} E_j$, для $P^{(l)}(X X_E = e)$ на усіх інтервалах w_j у $\Psi_x^{(l-1)}$.
11.	Якщо $\{1 - \alpha \leq \frac{S_X^{(l-k)}}{S_X^{(l-k+1)}} \leq 1 + \alpha \text{ для } k=1,2,3\}$ // Правило зупинки стабілізація помилки ентропії//або $\{S_i^X < \beta\}$ // Правило зупинки низької помилки ентропії//.
12.	Тоді зупинка дискретизації для вузла X .

Кроки	Опис
13.	Інакше створення нової дискретизації $\Psi_X^{(l)}$ для кожного вузла X .
14.	Розщеплення на дві половини інтервалу w_j у $\Psi_X^{(l-1)}$ з найвищим значенням помилки ентропії.
15.	Поглинання послідовних інтервалів у $\Psi_X^{(l-1)}$ з найнижчим значенням помилки ентропії або тих, що мають нульову множину або нульову помилку ентропії.
16.	Кінець циклу якщо.
17.	Кінець циклу для.
18.	Кінець циклу для.

Процес здійснення ієрархічної дискретизації в програмному середовищі GeNIe представлений на рисунку 2.21.




Рис.2.21 Ієрархічна дискретизація даних

2.3.2. Етап навчання параметрів.

На наступному кроці відбувається додавання прихованої вершини до мережі. Якщо ця вершина вставляється між декількома існуючими, то видаляються попередні дуги між ними і створюються нові, які пов'язані з прихованим вузлом. Якщо необхідно додати приховану батьківську вершину, то просто створюється нова вершина і відповідні дуги.

На наступному кроці параметри прихованих вершин ініціалізуються початковими значеннями. Це можуть бути як випадково згенеровані значення, так і значення, які надаються експертом.

На завершальному кроці запускається ітераційний процес алгоритму ЕМ, який використовує попередньо згенеровану вибірку даних і результатом якого є оцінки невідомих параметрів прихованих вершин мереж Байєса.

Навчання параметрів потрібне до знаходження найбільш ймовірних змінних α , які можуть пояснити дані [2]. Здійснити навчання параметрів можна кількома способами. Припустимо, що $D = \{D_1, D_2, \dots, D_N\}$ - навчальні дані, де $D_1 = \{x_1[l], x_2[l], \dots, x_n[l]\}$ складається з примірників байєсівських мережевих вузлів. Параметр навчання визначається кількісно функцією логарифмічної правдоподібності $L_D(\alpha)$. Перевіряємо, якщо дані для навчання повні, тоді для обчислення застосовуємо такі рівняння:

$$L_D(\alpha) = \log \left\{ \prod_{l=1}^N P(x_1[l], x_2[l], \dots, x_n[l] : \alpha) \right\} \quad (2.1)$$

$$L_D(\alpha) = \log \left\{ \prod_{i=1}^n \prod_{l=1}^N P(x_i[l] | pa(x_i[l]) : \alpha) \right\} \quad (2.2)$$

Метод статистичної оцінки частіше використовують, якщо спостерігаються всі змінні. За цим методом обчислюється ймовірність події за частотою виникнення цієї події в базі даних.

При підході максимальної правдоподібності (ML) використовується наступна формула:

$$P(X_i = x_k | pa(X_i) = x_j) = \alpha_{i,j,k} = \frac{N_{i,j,k}}{\sum_k N_{i,j,k}} \quad (2.3)$$

де $N_{i,j,k}$ - кількість подій в базі даних, для яких змінна X_i знаходиться в стані x_k , а її «батьки» присутні в конфігурації x_j .

Є також метод навчання параметрів, при якому в якості апіорного розподілу параметрів використовується розподіл Діріхле. Тоді маємо застосувати наступну формулу:

$$P(\alpha) \propto \prod_{i=1}^n \prod_{j=1}^{q_i} \prod_{k=1}^{r_i} \alpha_{i,j,k} (\beta_{i,j,k} - 1) \quad (2.4)$$

де $\beta_{i,j,k}$ - параметри розподілу Діріхле, пов'язані з попереднім розподілом.

Підхід максимальної апостеріорної правдоподібності описується за допомогою такої формули:

$$P(X_i = x_k | pa(X_i) = x_j) = \alpha_{i,j,k} = \frac{N_{i,j,k} + \beta_{i,j,k} - 1}{\sum_k N_{i,j,k} + \beta_{i,j,k} - 1} \quad (2.5)$$

2.3.3. Алгоритми пошуку структури байєсівської мережі

Інтелектуальний аналіз даних (Data Mining) – це технологія виявлення прихованих взаємозв'язків всередині великих баз даних. Більшість інструментів інтелектуального аналізу даних ґрунтується на двох технологіях: машинне навчання (machine learning) і візуалізація (візуальне подання інформації). Байєсівські мережі поєднують у собі ці дві технології.

Навчання структури БМ здійснюється за допомогою алгоритмів пошуку. Більшість існуючих методів побудови структури БМ можна умовно розділити на дві категорії:

- на основі оціночних функцій (search & scoring)
- на основі застосування тесту на умовну незалежність (dependency analysis) [52, 53].

Ми розглянемо сім алгоритмів навчання структури БМ (рисунок 2.22).



Рис. 2.22 Алгоритми навчання структури БМ

2.3.3.1. Алгоритм *Path Condition* (PC).

Основною ідеєю алгоритму Умовного шляху (*Path Condition* або PC) є отримання набору умовно незалежних і залежних вузлів відповідно деяким статистичним тестам. PC перевіряє статистичні тести на умовну незалежність для всіх пар змінних, крім зазначених обмежень. Неорієнтований зв'язок додається між кожною парою змінних, у яких не було знайдено умовної незалежності. Отриманий таким чином неорієнтований граф називають каркасом навчальної структури [74]. Потім визначають пари зв'язків спрямованих таким чином, що вони зустрічаються в вузлі, і які забезпечують відсутність неспрямованих циклів. Наступним кроком знаходять напрямки зв'язків, які можуть бути отримані з таблиці умовних ймовірностей. Решта зв'язків будуть довільно спрямовані, гарантуючи, що орієнтованих циклів не виникне. В своїй роботі науковці Dempster та Druzdzel [74] експериментально підтвердили, що алгоритм PC досить стійкий до багатоваріантності. Для порівняння вони виконали пошук структури графа спочатку з використанням алгоритму PC, а потім використовуючи підхід Байєсівського пошуку.

Припустимо, що ми маємо множину змінних $X=(X_1, \dots, X_n)$ з глобальним розподілом ймовірностей по них P . Літерою A ми будемо позначати підмножину змінних X . За допомогою $I(A,B|C)$ будемо позначати, що множини A і B умовно незалежні з C . Алгоритм РС передбачає довірчі ймовірності. Це означає, що існує орієнтований ациклічний граф G , такий що відносини незалежності між змінними в X є точно такими, які представлені G за допомогою критерію d-поділу [74]. РС-алгоритм передбачає наявність процедури, яка здатна розпізнати, коли $I(A,B|C)$ верифікується (тестується) на графі G . Він спочатку намагається знайти скелет (що лежить в основі неорієнтованого графу), а на останньому кроці робить орієнтацію ребер. Псевдокод алгоритму визначення скелета такий:

1. Start with a complete undirected graph G'
2. $i = 0$
3. Repeat
4. For each $X \in X$
5. For each $Y \in ADJ_X$
6. Test whether $\exists S \subseteq ADJ_X - \{Y\}$
with $|S| = i$ and $I(X, Y | S)$
7. If this set exists
8. Make $S_{XY} = S$
9. Remove $X - Y$ link from G'
10. $i = i + 1$
11. Until $|ADJ_X| \leq i, \forall X$

В цьому алгоритмі ADJ_X представляє собою набір вузлів, суміжних з X в графі G' . Якщо множина незалежних значень вірна для графа, то між X та Y немає ніякого зв'язку, тоді й тільки тоді, коли існує підмножина S сусідніх вузлів X така, що $I(X, Y | S)$. Кожна пара змінних S_{XY} буде містити таку множину, якщо вона буде знайдена. Цей набір буде використовуватися на стадії апостеріорної орієнтації. Крок орієнтації буде продовжений шляхом пошуку наборів з трьох змінних $\{X, Y, Z\}$ таких, що ребра $X \rightarrow Z$, $Y \rightarrow Z$ знаходяться на графі за винятком ребра $X \rightarrow Y$. Тоді, якщо $Z \notin S_{XY}$, він орієнтує ребра з X в Z та з Y в Z , створюючи v -

структуру: $X \rightarrow Z \leftarrow Y$. Як тільки ці орієнтації виконуються, він намагається зорієнтувати інші ребра за двома основними принципами:

- не створювати цикли;
- не створювати нові v-структури.

Можливо, що орієнтація деяких ребер повинна бути обрана довільно. Якщо набір незалежних значень вірний графу, і у нас є ідеальний спосіб визначити, чи $\in I(X, Y \mid S)$, то алгоритм гарантує отримання графа еквівалентного вихідному (такому, який являє собою той же набір незалежних змінних). Однак на практиці жодна з цих умов не підтверджується. Незалежність визначається шляхом статистичних тестів незалежності. Статистичні тести мають помилки, і тоді, навіть якщо гіпотеза вірності є вірносправедливою, можливо, ми не відновимо вихідний граф. Через характер частих статистичних тестів існує тенденція завжди мати справу з незалежністю. Це одна з причин проведення статистичних випробувань в порядку зростання потужності множин, на які ми орієнтуємося. Крім того, що не відновлюється вихідний граф, ми можемо мати ще один побічний ефект - можливість визначення циклів при орієнтації v-структур.

Запуск Алгоритму PC в GeNie 2.0

Починаємо з повного неорієнтованого графу для всіх n змінних, з наявністю ребер між усіма вузлами. Для кожної пари змінних X і Y і кожної множини інших змінних S , змінні X і Y умовно незалежні, з огляду на S . Якщо це так, - видаляємо ребро між X і Y . Спробуємо зорієнтувати неорієнтовані ребра, погодивши це з вже орієнтованими ребрами і роблячи це рекурсивно, поки не буде більше орієнтованих ребер [158].

При запуску алгоритму PC в GeNie 2.2 з'являється вікно вбудованого редактора Knowledge editor. Діалог редактора знань дозволяє вводити знання домену, які допоможуть на етапі структурного навчання.

У діалоговому вікні «Редактор знань» (рисунок 2.23-2.24) ми можемо:

- намалювати силові дуги - ці дуги гарантовано будуть знаходитись в структурі мережі, яку ми навчаємо;
- заборонити дуги - ці дуги, як гарантується, будуть відсутні в навченій структурі;
- призначати змінні часовим рівням.

Примусові і заборонені дуги можна намалювати, натиснувши на початок координат і перетягнувши дугу до вузла призначення, аналогічно тому, як ми малюємо дуги в графічній площині режиму Graph View.

Правило про часові рівні просте: в результуючій мережі не повинно бути дуг від вузлів в більш високих ярусах до вузлів в нижніх ярусах. Малювати структуру потрібно з точки зору причинності:

- причинність ніколи не працює в зворотному напрямку,
- забороняється перехід дуги від змінних в більш пізніх часових рядах до змінних в більш ранньому часовому ряді.




Рис. 2.23 Діалогове вікно «Редактор знань».




Рис. 2.24 Діалогове вікно «Редактор знань».

Результатом роботи алгоритму навчання РС є редактор шаблонів «Pattern editor» (рисунку 2.25).




Рис.2.25 Діалогове вікно «Редактор шаблонів»


У діалоговому вікні Редактора шаблонів «Pattern editor» відображається клас еквівалентності байєсових мереж, який був отриманий з даних. У редакторі шаблонів є три типи дуг:

I. Неорієнтована – це дуга, яка не може бути орієнтована тільки на основі даних,

II. Спрямована – дуга, що є орієнтованою і позначає можливий причинний зв'язок між парою змінних,

III. Подвоєна - дуга, яка могла б не орієнтуватися виключно на дані з можливістю прихованої загальної причини.

Щоб перетворити структуру на ациклічний орієнтований граф (тобто на байєсову мережу), необхідно вибрати напрямок для кожної неорієнтованої і двоголової дуги. Це можна зробити натиснувши правою кнопкою миші на дузі і вибравши напрямок, як показано на рисунку 2.26:

Або клацнувши на кнопці *Create DAG* () , за допомогою якої вибирається напрямок кожної неорієнтованої дуги довільно, щоб отримати ациклічний спрямований граф. Натиснувши на кнопці *Learn parameters* () можна отримати повністю параметризовану байєсову мережу (рисунок 2.27).




Рис. 2.26 Байєсова мережева структура, що побудована за алгоритмом РС.




Рис. 2.27 Діалогове вікно Learning.

Як правило, це кінцевий продукт будь-якого алгоритму навчання. Можна повернутися з ациклічного орієнтованого графа байєсівської мережі на діалогове вікно «Редактор шаблонів», вибравши Show Pattern з меню *Learning*:

2.3.3.2. Алгоритм Наївного Байєсу

Алгоритм навчання Naive Bayes - це метод навчання наївної структури, який включений до категорії алгоритмів структурного навчання тільки тому, що він створює структуру та параметри байєсівської мережі безпосередньо з даних. Структура мережі Naive Bayes не вивчена, а скоріше фіксована за припущенням: змінна класу є єдиним батьком усіх функціональних змінних, що залишилися, і немає жодних інших зв'язків між вузлами мережі. Структура Naive Bayes передбачає, що функції незалежні від змінної класу, що призводить до неточностей, коли вони є незалежними (рисунок 2.28).




Рис. 2.28. Алгоритм Наївного Байєса.

Розглянемо алгоритм Наївного Байєсу, який розширює структуру байєсівської мережі S шляхом додавання до нього залежностей між вузлом класу C та вузлами-атрибути з множини γ . Цей алгоритм може бути використаний безпосередньо для створення структури простого Байєсового

класифікатора. Псевдокод алгоритму Наївного Байєсу наведено нижче.

Class-Depend(S, γ, D)

1. $\hat{S} \leftarrow S$
2. **for** кожної змінної $\gamma_i \in \gamma$ **do**
3. Додати спрямовану дугу ($C \rightarrow \gamma_i$) до структури мережі $\hat{S}$
4. **return** $\hat{S}$

Обчислювальні витрати на виконання оператора Class-Depend визначаються як

$$O_{\text{Class-Depend}} = \|\gamma\|, \quad (2.6)$$

де $\|\gamma\|$ – кардинальність множини γ .

2.3.3.3. Алгоритм Жадібного проріджування (*Greedy*)

Алгоритм навчання структури жадібного товстого проріджування (GTT або *Greedy*), що заснований на підході Байєсівського пошуку, був описаний у роботах Cheng [53,54]. GTT починається з порожнього графа і неодноразово додає дугу без створення циклу, що максимально збільшує граничний рівень правдоподібності $P(D|S)$, доки додавання дуги не призведе до позитивного збільшення (це фаза потовщення). Потім він багаторазово видаляє дуги, доки видалення дуги не призведе до позитивного збільшення $P(D|S)$ (це фаза витончення). Алгоритм досить ефективний за рахунок того, що він схильний до пастки локальних максимумів. Це універсальний метод навчання структури графа. Таблиці ймовірності заповнюються з допомогою максимізації очікувань [53,54].

Алгоритм *Greedy* реалізує “жадібний” пошук існування можливих дуг від C та змінною атрибуту A_i . Якщо всі атрибути залежать від змінної класу, то Байєсова мережа буде мати структуру розширеного простого Байєсового класифікатора. Однак, призначенням *Greedy* є визначення того, які з цих залежностей є дійсно необхідними. Крім того, на кожному кроці *Greedy* розширює розкрити структуру залежностей між змінною

класу та змінними атрибутів шляхом застосування оператора Augmenter. Він починає свою роботу з порожньої множини нащадків і на кожному кроці додає нового нащадка, який є оптимальним у відповідності із значенням міри q структури мережі. Нащадками вузла C є елементи множини γ , а множина λ містить ті змінні атрибутів, які не залежать прямо від C . Для кожної конфігурації нащадків γ_i залежності між змінними атрибутів $\mathbf{A}$ визначаються оператором Augmenter, що вибирається належним чином. Вхідною інформацією для оператора Augmenter є залежності між змінною класу C та змінними атрибутів $\mathbf{A}$, які представлені множиною $\gamma_{i-1} \cup \{X\}$. Він вивчає додаткові залежності між змінними атрибутів використовуючи множину тренувальних даних D . *Greedy* вибирає таку мережу, яка відповідає конфігурації нащадків λ_k з найбільшим значенням функції якості q . Псевдокод алгоритму виконання *Greedy* наведено нижче.

Greedy (D, q , Augmenter)

1. $\gamma \leftarrow \emptyset$ {множина змінних, які залежать від змінної класу}
2. $\lambda \leftarrow \mathbf{A} = \{A_1, \dots, A_{n-1}\}$ {множина змінних, які не залежать від змінної класу}
3. $\hat{q} \leftarrow -\infty$ {найбільше значення міри якості}
4. **for** $i = 1, \dots, n - 1$ **do**
5. Вибрати атрибут $A \in \lambda$, який максимізує міру якості $q(B, D)$, для мережі $B \leftarrow \text{Augmenter}(\gamma \cup \{A\}, \lambda \setminus \{A\}, D, q)$
6. **if** $q(B, D) > \hat{q}$ **then**
7. $\hat{B} \leftarrow B$
8. $\hat{q} \leftarrow q(B, D)$
9. $\gamma \leftarrow \gamma \cup \{A\}$
10. $\lambda \leftarrow \lambda \setminus \{A\}$
11. **return**

Обчислювальні витрати на виконання оператора *Greedy* частково залежать від витрат на обчислення міри якості q , яка

використовується для оцінювання якості створеної мережі Q , а також від витрат на реалізацію оператора Augmenter, тобто, $O_{Augmenter}$. Обчислювальні витрати на виконання кроків 1-3 алгоритму є постійними, а витрати на крок 5 визначаються за виразом: $\|\lambda\| \cdot (O_q + O_{Augmenter})$. Витрати на всі інші кроки в циклі **for** є постійними. Цей цикл повторюється $n - 1$ разів, а тому загальні обчислювальні витрати на виконання оператора визначаються за виразом:

$$O_{\text{совз}} = n^2 (O_q + O_{Augmenter}). \quad (2.7)$$

2.3.3.4. Алгоритм TAN

Оператор розширення дерева (Tree-Augmenter) доповнений найвісім Байєсом (TAN) заснований на підході Байєсівського пошуку, що описано у роботах Friedman.

Алгоритм навчання структури Tree Augmented Naive Bayes (TAN) починається з структури Naive Bayes (тобто тієї, в якій змінна класу є єдиним батьком усіх змінних об'єкта, що залишилися) і додає зв'язку між змінними ознаки для обліку можливої залежності між ними, обумовленої змінною класу (рисунок 2.29). Алгоритм накладає обмеження лише на один додатковий батьківський елемент кожної змінної функції (крім змінної класу, яка є батьківською для кожної змінної функції). Зауважте, що структура Naive Bayes передбачає наявність незалежності функції від змінної класу, що призводить до неточностей, коли вони не є незалежними. Алгоритм TAN є простим і, як було встановлено, працює гарантовано краще, ніж Naive Bayes.

Оператор розширення дерева (Tree-Augmenter) є узагальненням простого Байєсового класифікатора на розширеному дереві, TAN, розглянутого в роботі [90]. Різниця полягає в тому, що в даному випадку не вимагається щоб всі вузли-атрибути залежали від вузла класу C . Операнд γ задає атрибути, які залежать від змінної класу, а операнд λ задає додаткові атрибути для розширення мережі, які не залежать від вузла класу.




Рис.2.29. Структура Tree Augmented Naive Bayes [90].

Цей оператор будує розширене дерево використовуючи розширений алгоритм, запропонований в роботі [90]. Різниця в даному застосуванні полягає в способі обчислення взаємної інформаційної функції. Оскільки деякі вузли залежать від змінної класу, то ця інформація використовується при обчисленні умовної взаємної інформації. В наступних формулах використовується умовна (відносно змінної класу C) або безумовна ймовірність для змінних X, Y , в залежності від того, чи вони входять в множину γ чи ні:

$$I_{\gamma} = \begin{cases} \sum_{x,y} p(x,y|c) \cdot \log \frac{p(x,y|c)}{p(x|c)p(y|c)} & \text{якщо } X \in \gamma \wedge Y \in \gamma, \\ \sum_{x,y} p(x,y|c) \cdot \log \frac{p(x,y|c)}{p(x|c)p(y)} & \text{якщо } X \in \gamma \wedge Y \notin \gamma, \\ \sum_{x,y} p(x,y|c) \cdot \log \frac{p(x,y|c)}{p(x)p(y|c)} & \text{якщо } X \notin \gamma \wedge Y \in \gamma, \\ \sum_{x,y} p(x,y|c) \cdot \log \frac{p(x,y)}{p(x)p(y)} & \text{якщо } X \notin \gamma \wedge Y \notin \gamma. \end{cases} \quad (2.8)$$

Псевдокод цього алгоритму наведено нижче.

Tree-Augmenter (D, q , Augmenter)

1. $G \leftarrow \emptyset$

2. **for** кожної пари змінних $\{A_i, A_j\} \subset \gamma \cup \lambda$ таких, що $A_i \neq A_j$ **do**
 $w_{ij} \leftarrow I_\gamma(A_i, A_j)$
3. додати неспрямовану дугу $(A_i - A_j)$ до графа G
4. $T \leftarrow \text{Maximum-Spanning-Tree}(G, \mathbf{w})$
5. упорядкувати дуги неспрямованого дерева T , вибираючи один вузол за кореневий і встановлюючи напрямки всіх дуг від нього. Потім перетворити його в байєсівську структуру S .
6. $\hat{B} \leftarrow \text{Class-Depend}(S, \gamma, D)$
7. **return** $\hat{B}$

Обчислювальні витрати

Цикл на кроці 2 повторюється $\frac{1}{2} \|\gamma \cup \lambda\| (\|\gamma \cup \lambda\| - 1)$ разів.

Витрати на обчислення взаємної інформації на кроці 3 залежать від станів, які можуть приймати атрибути A_i і A_j . Якщо максимально можливе число станів дорівнює $r_{\max}$, то витрати на реалізацію кроку 3 складуть $r_{\max}^2$, на крок 2 $O_2 = \|\gamma \cup \lambda\|^2 r_{\max}^2$.

Тут припускається, що алгоритм породження максимального дерева (Maximum-Spanning-Tree) реалізується за допомогою алгоритму Пріма [90]. Витрати на реалізацію алгоритму Пріма при використанні методу сортування Фібоначчі складають $E + V \log(V)$, де E – число ребер; V – число вузлів графа G . В даному випадку:

$$E = \frac{1}{2} \|\gamma \cup \lambda\| (\|\gamma \cup \lambda\| - 1), \quad V = \|\gamma \cup \lambda\|,$$

$$O_5 = O\left(\frac{1}{2} \|\gamma \cup \lambda\| (\|\gamma \cup \lambda\| - 1) + \|\gamma \cup \lambda\| \log(\|\gamma \cup \lambda\|)\right) = \|\gamma \cup \lambda\|^2, \quad (2.9)$$

$$O_6 = \|\gamma \cup \lambda\|^2,$$

$$O_7 = \|\gamma\|,$$

$$O_2 + O_5 + O_6 + O_7 = O(\|\gamma \cup \lambda\|^2 r_{\max}^2),$$

тобто, обчислювальні витрати на реалізацію оператора розширення дерева складають:

$$O_{\text{Tree-Augmenter}} = \|\gamma \cup \lambda\|^2 r_{\max}^2. \quad (2.10)$$

2.3.3.5. Алгоритм Розширеного Наївного Байєсу (ANB)

Алгоритм навчання структури розширеного наївного байєсу (ANB) є методом навчання напівнаукової структури, заснований на підході Байєсівського пошуку. Алгоритм ANB починається зі структури Наївного Байєса (тобто, в якій змінна класу є єдиним батьком усіх змінних функцій, що залишилися) і додає зв'язок між змінними ознаки для обліку можливої залежності між ними, обумовленої змінною класу. Немає жодних обмежень на кількість додаткових підключень, що входять до кожної з функціональних змінних, якщо це не накладається одним з параметрів алгоритму. Зауважте, що структура Naive Bayes передбачає, що функції незалежні від змінної класу, що призводить до неточностей, коли вони не є незалежними. Алгоритм ANB простий і, як було встановлено, працює надійно краще ніж Naive Bayes.

Алгоритм Розширеного Наївного Байєсу ANB розкриває залежності між змінною класу C та змінними атрибутів A_i , але він додатково видаляє (проріджує) атрибути, які не виявляються залежними від змінної класу перед застосуванням оператора Augmenter. Фактично, алгоритм виконує вибір атрибутів, визначає ті атрибути, які не сприяють розв'язку задачі класифікації, та видаляє їх з класифікуючої мережі. При цьому припускається, що застосовується процедура розширення дерева. Псевдокод цього алгоритму наведено нижче.

ANB (D, q , Augmenter)

1. $\gamma \leftarrow \emptyset$ {множина змінних, які залежать від змінної класу}
2. $\lambda \leftarrow \mathbf{A} = \{A_1, \dots, A_{n-1}\}$ {множина змінних, які не залежать від змінної класу}
3. $\hat{q} \leftarrow -\infty$ {найбільше значення міри якості}
4. **for** $i = 1, \dots, n - 1$ **do**
5. вибрати атрибут $A \in \lambda$, який максимізує міру якості $q(B, D)$, для мережі $B \leftarrow \text{Augmenter}(\gamma \cup \{A\}, \{A\}, \emptyset, D)$
6. **if** $q(B, D) > \hat{q}$ **then**
7. $\hat{B} \leftarrow B$

8. $\hat{q} \leftarrow q(B, D)$

9. $\gamma \leftarrow \gamma \cup \{A\}$

10. $\lambda \leftarrow \lambda \setminus \{A\}$

11. return

Обчислювальні витрати на реалізацію оператора ANB розраховуються за формулою:







$$O_{\text{COB3}} = n^2 (O_q + O_{\text{Augmenter}}). \quad (2.11)$$

В таблиці 2.3. представлені результати проектування шести байєсівських мережевих моделей з використанням шести алгоритмів структурованого навчання.

2.3.3.6. Навчання мереж Байєса з прихованими вершинами

Переважаюча більшість досліджень виконується за припущення, що дані є повними, тобто значення (виміри) усіх змінних відомі для кожного варіанту моделювання. Однак це не зовсім реальні ситуації, адже приховані змінні відіграють ключову роль при розв'язанні багатьох практичних задач. Невідомий регулюючий механізм може бути ключем до підвищення якості аналізу біологічних та інших систем. Зв'язки між симптомами та іншими явищами можуть дати поштовх до розгадки прихованої фундаментальної проблеми при діагностуванні та управлінні складними системами. Навмисно чи ненавмисно замаскована економічна сила може бути причиною виникнення взаємно пов'язаних фінансових феноменів, які відіграють вирішальну роль для розвитку процесу моделювання [296]. Приховані змінні можуть відігравати роль деякого підсумкового механізму, що "перехоплює" інформацію із спостережуваних змінних та "спрямовує" її до іншої частини мережі. Тому введення і використання прихованих змінних при моделюванні може надати можливість значно спростити структуру моделі, що дозволить в результаті отримати високоякісний загальний ймовірнісний висновок.

Результати проектування шести байєсівських мережевих моделей з використанням
Таблиця 2.3
шести алгоритмів структурованого навчання.

Байєсівський пошук	РС	Жадібний	TAN	ANB	Наївний Байєс
 Input file: data1-discrete.txt Data rows: 15 Elapsed time: 0.002s Learning algorithm: PC Algorithm parameters: Max iterations: 50 Sample size: 10 Max search time: 0 No background knowledge EM Log Likelihood: -29.6505 Best score in iteration 0: -40.251 EM Log Likelihood: -37.0724	 Input file: data1-discrete.txt Data rows: 15 Elapsed time: 0.002s Learning algorithm: PC Algorithm parameters: Max iterations: 50 Sample size: 10 Max search time: 0 No background knowledge EM Log Likelihood: -29.6505 Best score in iteration 0: -40.251 EM Log Likelihood: -37.0724	 Input file: data1-discrete.txt Data rows: 15 Elapsed time: 0.002s Learning algorithm: Greedy Search Algorithm parameters: Iterations: 20 Max parent count: 0 Sample size: 50 Prior probability: 0.01 Seed: 0 Use accuracy as score: no No background knowledge Best score in iteration 0: -40.251 EM Log Likelihood: -37.0724	 Input file: data1-discrete.txt Data rows: 15 Elapsed time: 0.002s Learning algorithm: TAN Algorithm parameters: Max iterations: 50 Sample size: 10 Max search time: 0 No background knowledge EM Log Likelihood: -29.6505 Best score in iteration 0: -40.251 EM Log Likelihood: -37.0724	 Input file: data1-discrete.txt Data rows: 15 Elapsed time: 0.002s Learning algorithm: ANB Algorithm parameters: Max iterations: 50 Sample size: 10 Max search time: 0 No background knowledge EM Log Likelihood: -29.6505 Best score in iteration 0: -40.251 EM Log Likelihood: -37.0724	 Input file: data1-discrete.txt Data rows: 15 Elapsed time: 0.002s Learning algorithm: Naive Bayes Algorithm parameters: Max iterations: 50 Sample size: 10 Max search time: 0 No background knowledge EM Log Likelihood: -29.6505 Best score in iteration 0: -40.251 EM Log Likelihood: -37.0724

Байєсівські мережі з прихованими змінними – це чіткий приклад застосування системного підходу до розв’язання слабкоструктурованих задач. Знаходження причинно-наслідкових зв’язків, обробка неповних даних, отримання адекватної ймовірнісної моделі на виході – все це робить мережі Байєса ефективним інструментом системного аналізу. А головна потужність та цінність мереж Байєса у рамках системного підходу полягає у їх здатності виявляти неочевидні, нетривіальні та невідомі зв’язки між факторами, про які іноді самі експерти у відповідній предметній області не завжди можуть мати достатню уяву. Саме тому вони набули широкого застосування в найрізноманітніших сферах сучасного життя людини і продовжують активно досліджуватись та впроваджуватись у практику [296].

Навчання мереж Байєса з прихованими вершинами має свої особливості. Багато реальних задач характеризується наявністю прихованих змінних (так званих латентних змінних), які не є спостережуваними і доступними для навчання [296]. Наприклад, історії хвороби часто включають описи спостережуваних симптомів, лікування, що застосовується, і, можливо, результати лікування, але рідко містять відомості про безпосереднє спостереження за розвитком самого захворювання. Очевидне питання: "Якщо хід розвитку захворювання не спостерігається, то чому б не побудувати модель без нього"? Відповідь на це питання можна знайти на рис. 2.30, де показана невелика фіктивна діагностична модель для захворювання мозку. Існують три спостережувані фактори, що сприяють або перешкоджають розвитку захворювання, і три спостережувані симптоми. Передбачається, що кожна змінна має три можливі стани (наприклад, none (відсутній), moderate (помірний) і severe (серйозний)). Видалення прихованої змінної з мережі, наведеної на рис. 2.30. а), спричиняє створення мережі, показаної на рис. 2.30. б), і при цьому загальна кількість параметрів багаторазово збільшується.




Рис. 2.30. Ілюстрація використання прихованих змінних.

Приховані змінні важливі, але їх введення призводить до ускладнення задачі навчання. Наприклад, на рис. 2.30. а) не показано, як знайти в процесі навчання розподіл умовних ймовірностей для змінної Brain Disease, якщо задані її батьківські змінні, оскільки значення змінної Brain Disease у кожному випадку невідоме; така ж проблема виникає при пошуку в процесі навчання розподілів ймовірностей для симптомів. Таким чином, перевагами використання прихованих вершин у мережах Байєса є:

- значне спрощення структури мережі;
- зменшення кількості параметрів, необхідних для визначення мережі Байєса, а це в свою чергу дозволяє різко зменшити об'єм даних, необхідних для визначення у процесі навчання цих параметрів.

Недоліки використання прихованих вершин в мережах Байєса:

- ускладнення задачі навчання мережі Байєса;
- у разі невідомої структури мережі невирішеною залишається проблема визначення кількості прихованих вершин, місце їх розташування та кількість станів кожної з них.

Іноді інформація щодо прихованих вершин в мережах Байєса є. Проте в загальному випадку не має ніяких даних щодо прихованої вершини. Відповідно постає дві основні проблеми навчання мереж Байєса з прихованими вершинами:

1. Скільки станів повинна мати прихована вершина?
2. Як умовні ймовірності можуть бути знайдені без даних?

Кількість станів можна визначити експериментально. Оскільки прихована вершина насправді діє як випадкова причина, то очікувано, що кількість станів буде відповідати кількості станів вершин, які вона розділяє. Насправді, кількість станів можна встановити як максимальне з числа станів предків і нащадків і потім видаляти стани, якщо вони матимуть в остаточному випадку досить низькі ймовірності.

Процес навчання мережі Байєса складається із зовнішнього циклу, що є процесом пошуку структури, і внутрішнього циклу, що є процесом оптимізації параметрів. У разі повних даних внутрішній цикл виконується дуже швидко, оскільки при цьому досить лише витягнути інформацію про умовні частоти з набору даних. Якщо ж є приховані змінні, то для виконання внутрішнього циклу потрібно застосувати багато ітерацій алгоритму ЕМ або алгоритму на основі градієнта, а на кожній ітерації будуть обчислюватись розподіли апостеріорних ймовірностей в байєсівській мережі, що є досить складною задачею.

Таким чином, приховані змінні дозволяють різко зменшити кількість параметрів, потрібних для визначення байєсової мережі. А даний факт, у свою чергу, дозволяє різко зменшити об'єм даних, необхідних для визначення в процесі навчання даних параметрів [296].

2. 4 Методи визначення і підвищення точності моделі

Валідація байєсівської мережі - це процес оцінки ефективності моделі та перевірки її адекватності та точності. Цей процес дозволяє визначити, наскільки точно модель передбачає результати на нових даних, які не були використані під час навчання. Існує кілька методів валідації байєсівських мереж, серед яких:

Перехрестна валідація (Cross-validation) - цей метод полягає у розділенні доступних даних на декілька груп. Одна група використовується як тестовий набір даних, а решта - як тренувальний набір. Процедура повторюється декілька разів з різними групами даних. Результатом є середнє значення точності моделі на тестових даних з усіх ітерацій.

Валідація на зовнішніх даних (External validation) - цей метод полягає у використанні незалежного набору даних для перевірки ефективності моделі, яка була навчена на внутрішньому наборі даних.

Залишковий аналіз (Residual analysis) - цей метод полягає у перевірці залишків, тобто різниць між спостережуваними значеннями та прогнозованими значеннями моделі. Цей метод може використовуватися для виявлення систематичних помилок в моделі та їх усунення.

Bootstrapping - цей метод полягає у використанні багатьох рандомних підвибірок тренувального набору даних для навчання моделі та оцінки її ефективності на тестових даних. Результатом є середнє значення точності моделі на тестових даних з усіх ітерацій.

Крім стандартної крос-валідації, існують і інші методи, які можуть бути використані для тестування і підвищення точності байєсівських мереж. Наприклад, існує метод **Leave-One-Out Cross-Validation (LOOCV)**, де вся доступна вибірка даних по черзі використовується як тестовий набір, а решта - як тренувальний набір.

Також можна використовувати метод перехресної валідації **K-Fold Cross-Validation**, який полягає в розділенні даних на K груп, де K-1 груп використовується як тренувальний набір, а залишок - як тестовий. Основна мета цього методу полягає в забезпеченні оцінки точності моделі на незалежних даних. Процедура перехресної валідації полягає в розділенні доступних даних на декілька груп. Процедура повторюється декілька разів з різними групами даних. Наприклад, якщо ви використовуєте 5-кратну перехресну валідацію, то доступні дані розбиваються на 5 груп, і процедура повторюється 5 разів, де кожного разу одна з груп

використовується як тестовий набір, а решта - як тренувальний набір. Після кожної ітерації вимірюється точність моделі на тестових даних. Результатом є середнє значення точності моделі з усіх ітерацій. Переваги та недоліки цього методу представлені у таблиці 2.4.

Вибір конкретного методу валідації залежить від розміру доступної вибірки даних, кількості параметрів моделі та обчислювальних ресурсів, які доступні для використання. Однак, в будь-якому випадку, використання методів валідації є необхідним для забезпечення коректної оцінки точності та стійкості байєсівських мереж.

Таблиця 2.4

**Переваги та недоліки методу перехрестної валідації
"K-Fold Cross-Validation".**

Переваги	Недоліки
1. метод перехрестної валідації дозволяє використовувати весь доступний набір даних для тренування та тестування моделі, що забезпечує більш точні результати.	1. метод перехрестної валідації може займати значну кількість часу та ресурсів, особливо при великих обсягах даних або складних моделях.
2. цей метод дозволяє оцінити стійкість моделі до змін у тренувальному наборі даних.	2. при недостатній кількості даних метод перехрестної валідації може бути неефективним, оскільки кожна ітерація вимагає значних обчислювальних витрат.

2.4.1. Канонічні вузли Noisy-MAX

Канонічні ймовірнісні вузли, такі як вузли Noisy-MAX/OR, Noisy-MIN/AND, що реалізовані в GeNIe і запропоновані дослідками Henrion і Diez, є зручними інструментальними засобами розробки інтелектуального забезпечення та широко використовуються на практиці для підвищення точності і адекватності моделі. У літературі можна знайти дві різні, але

математично еквівалентні параметризації Noisy-OR/MAX. Вони часто називаються іменами дослідників, які їх запропонували [75, 106].

Параметри Noisy-MAX завантажуються у двовимірну таблицю. Перший вимір проходить через всі стани батьків, і другий вимір проходить через стани вузла Noisy-MAX. Порядок результатів у матриці передбачається спадний, зі станом «певні» для Noisy-MAX/OR завжди наприкінці. Параметри Noisy-MAX завантажуються в такий спосіб: починаючи з першого батька Noisy-MAX, кожний батьківський вузол призначає кількість елементів у вимірі рівному кількості виходів. За замовчуванням GeNIe ховає стовпці, які листуються на певні «батьківські» стани. Ви можете розглянути їх натискаючи кнопку .

Розглянемо формальний опис вузлів Noisy-MAX. Вузел Noisy-MAX, який за наявності змінної з шумом зводиться до Noisy-OR, складається з дочірнього вузла Y , що приймає n_Y можливих значень, які можуть бути позначені від 0 до n_Y-1 , та N батьків, $Pa(Y) = \{X_1, \dots, X_N\}$, які зазвичай є причинами Y . Кожен X_i має певне нульове значення, тож $X_i = 0$ це відсутність X_i . Дві основні аксіомы, що визначають Noisy-MAX [158]:

1. Коли всі причини відсутні, ефект також відсутній:

$$P(Y = 0 \mid X_i = 0_{[\forall_i]}) = 1 \quad (2.12)$$

2. Ступінь, досягнута Y , є максимумом ступенів, вироблених X , якщо вони діяли незалежно:

$$P(Y \leq y \mid x) = \prod_i P(Y \leq y \mid X_i = x_i, X_j = 0_{[\forall_{j,j \neq i}]}) \quad (2.13)$$

де x представляє певну конфігурацію батьків Y , $x = (x_1, \dots, x_N)$. Параметри для посилення $X_i \rightarrow Y$ – це ймовірність того, що ефект приймає певне значення Y , коли X_i приймає значення x_i , при умові що всі інші причини Y відсутні:

$$c_y^{x_i} = P(Y = y \mid X_i = x_i, X_j = 0_{[\forall_{j,j \neq i}]}) \quad (2.14)$$

Якщо X_i приймає значення n_{x_i} , кількість параметрів, необхідних для посилення $X_i \rightarrow Y$ дорівнює $(n_{x_i} - 1) \times (n_Y - 1)$ – відповідно до рівняння 1. Оскільки всі змінні, включені в Noisy-OR, є двійковими, для цієї моделі потрібно посилення лише на один параметр. Як альтернативу, можна визначити нові параметри:

$$C_y^{x_i} = P\left(Y \leq y \mid X_i = x_i, X_j = 0_{[\forall j, j \neq i]}\right) = \sum_{y'}^y C_y^{x_i} \quad (2.15)$$

так що рівняння 4 можна переписати як:

$$P(Y \leq y \mid x_1, \dots, x_n) = \prod_i C_y^{x_i} \quad (2.16)$$

Таблиця результуючих значень виходить з урахуванням того, що:

$$P(y \mid x) = \begin{cases} P(Y \leq 0 \mid x) & \text{if } y = 0 \\ P(Y \leq y \mid x) - P(Y \leq y-1 \mid x) & \text{if } y > 0 \end{cases} \quad (2.17)$$

2.4.2. Діагностичні вузли. Меню Diagnosis

Для досягнення цілей моделювання, що допомагає здійснити прогнозування або постановку діагнозу, тип вузлів може бути змінено на Diagnosis.

Діагностика є одним із найуспішніших додатків байєсівських мереж. Здатність методів представлення ймовірнісних знань виконувати суміш як прогнозного, так і діагностичного висновку робить їх дуже придатними для діагностики. Байєсівські мережі можуть об'єднувати спостереження, такі як схильності та фактори ризику, із симптомами та результатами випробувань. У цьому розділі розглядаються особливості GeNIe, які підтримують діагностичні програми.

Діагностична модель, побудована з використанням GeNIe, представляє різні компоненти системи, можливі симптоми, а також результати діагностичних тестів. Модель, по суті, відображає

можливі дефекти система (чи то природна система, така як людське тіло, або пристрій, створений людиною, такий як автомобіль, літак або копір), які можуть виявлятися в повідомленнях про помилки, симптомах та результатах випробувань. Використовуючи таку модель, GeNIe створює ранжований список найімовірніших дефектів та ранжований список найбільш інформативних та економічно ефективних тестів.

Коли в GeNIe діагностичні розширення увімкнені, з'являється додаткове меню, яке називається Діагностика (рисунок 2.31).




Рис. 2.31 Меню Діагностика.

Меню Діагностика пропонує такі команди:

Команда "Перегляд тесту" (клавіша F7) відкриває вікно "Testing window". Команда Spreadsheet відкриває уявлення Spreadsheet View для поточної мережі в окремому вікні. Параметр «Autoformat...» викликає діалогове вікно, що дозволяє встановити автоматичне фарбування вузлів на основі їх діагностичних властивостей. При натисканні кнопки «Defaults (За замовчуванням)» з'являється наступне меню (рисунок 2.32):

Команда Set as Defaults встановлює поточний вибір кольорів як кольори за замовчуванням для автоформатування.

Команда Restore Defaults відновлює налаштування кольору до стандартних налаштувань.

Команда Reset to Factory Settings (Скинути до заводських налаштувань) відновлює заводські налаштування кольору, які постачаються з GeNIe.

Підменю "Select Nodes (Вибрати вузли)" дозволяє вибрати всі вузли, що належать до одного з трьох типів діагностичних вузлів

Targets, Observations or Auxiliary nodes: "Цілі", "Спостереження" або "Допоміжні вузли".




Рис. 2.32 Меню встановлення фарбування вузлів.




Рис. 2.33 Підменю "Select Nodes (Вибрати вузли)" в Меню Діагностика.

Типове застосування цього вибору - спільне редагування кожного типу вузлів, наприклад, розфарбовування або відображення у вигляді гістограм.

Панель інструментів діагностики *Diagnosis toolbar*

Панель інструментів "Diagnosis" містить кнопки, які використовуються в рамках діагностичних розширень GeNIe. Діагностична панель вмикається за допомогою команди-перемикача *Toolbar/Diagnosis* у меню *View*. Діагностичні можливості GeNIe згруповані в меню *Diagnosis* і в панелі інструментів *Diagnosis Toolbar*. Панель інструментів діагностики відображається, лише якщо встановлено прапорець "*Network/Enable Diagnosis (Мережа / Увімкнути діагностику)*", як показано на рис.2.34.



 відкриває *Testing Window*;  переключитися між *Graph View* та *Cost Graph View*;  перейти між *Graph View* и the *Spreadsheet View*

Рис. 2.34 Діагностичні можливості GeNIe.

Під час завантаження моделі з діагностичною інформацією користувачеві пропонується увімкнути *Enable Diagnosis*. За замовчуванням опція вимкнена, щоб уникнути непотрібної складності інтерфейсу користувача, і залишається включеною після включення. Коли опцію «*Enable Diagnosis*» увімкнено, у рядку меню з'являється меню Діагностики, а на панелі інструментів додається панель *Diagnosis Toolbar*.

Налаштування властивостей вузлів для діагностичних цілей.

Найважливішим елементом діагностичних розширень є встановлення ролей, які різні вузли моделі грають у діагностиці. Кожен дефект, повідомлення про помилку, симптом та тест мають бути представлені як окремий вузол графічної причинно-наслідкової моделі, що лежить в основі діагностичної байєсівської мережевої моделі. Оскільки байєсовська мережева модель загального призначення не дозволяє встановити різницю між значеннями різних типів вузлів, розробник моделі повинен вказати, які з них представляють дефекти, які спостереження, а які можливі тести.




Рис. 2.35. Панель **Diagnosis Toolbar**.

Наприклад, вузли, що представляють компоненти, можуть мати стани, позначені як OK та Defective. Для вузлів, що представляють симптоми або повідомлення про помилки, стан може бути «Present» і «Absent». Для тестових вузлів стану можуть бути позначені як Passed та Failed. Вузли з'єднуються в байєсовську мережу за допомогою спрямованих посилань. Посилання зазвичай слідує причинно-наслідковому напрямку, тобто переходять від вузлів, які представляють можливі збої, до вузлів, що представляють спостереження, повідомлення про помилки, тести та симптоми. Посилання даного компонента на симптом може вказувати, що симптом може бути викликаний дефектами компонента. Посилання від компонента «тест» може вказувати на те, що тест може бути використаний для визначення того, чи є компонент несправним.

Діагностичні вузли поділяються на три класи:

I. Targets - Цілі (це аномалії, такі як відмови машин, збої або захворювання),

II. Observations - Спостереження (це симптоми, що спостерігаються або фактори ризику)

III. Auxiliary - Допоміжні (це додаткові змінні, які не є ні помилками, ні спостереженнями, але корисні).

Усі вузли мають бути типу Chance – випадкового типу для діагностики. Діалогове вікно Node properties може використовуватися для введення нових властивостей або зміни поточних властивостей одного вузла. Нижче наведено список описів вкладок, які призначені для діагностування. Опис інших вкладок можна знайти у розділі довідкового посібника Node properties.

Вкладки меню, які стосуються діагностики:

1. General,
2. Observation Cost,
3. Documentation.

Кожна вкладка має три кнопки знизу: ОК, Скасувати та Довідка. Після внесення змін до будь-якої вкладки натисніть ОК, щоб зберегти зміни. Щоб продовжити роботу з моделлю без збереження змін, просто натисніть кнопку «Скасувати». Зверніть увагу, що деякі зміни не можна скасувати, в цьому випадку кнопка "Скасувати" буде неактивна (рисунок 2.36).

Ми можемо бачити додаткові властивості, зазначені на вкладці «Загальні». Рядки таблиці становлять різні стани змінної. Щоб перейменувати стан, двічі клацніть на його ім'я та відредагуйте текст. Ім'я стану має відповідати синтаксису ідентифікаторів у мовах програмування - воно має починатися з літери, за якою слідує літери, цифри або символи підкреслення. У режимі діагностики кожному вузлу має бути присвоєний тип діагностики, який можна вибрати з таких варіантів:

- I. Цільовий вузол Target,
- II. Спостереження Observation
- III. Допоміжний вузол Auxiliary.

Цільові вузли Target символізують:

- збої,
- апаратні дефекти,
- порушення,
- несправності.

General tab




Рис. 2.36 Вікно властивостей вузла General.

Принаймні один стан цільового вузла має бути спроектовано як цільовий стан. Цільовий стан – це дефектний стан, тому всі стани, які не позначені як цільові, за замовчанням є нормальними станами.

Вузли спостереження Observation символізують повідомлення про помилки, симптоми чи результати тестів.

Допоміжні вузли Auxiliary - це решта вузлів, які не є ні помилками, ні спостереженнями. Зазвичай вони використовуються для зручності моделювання.

На додаток до трьох типів вузлів існує також два підтипи вузлів:

- рангові Ranked,
- обов'язкові Mandatory.

З шести комбінацій діагностичних типів та двох підтипів дозволено лише чотири:

a) вузли, що є ранжованими цілями Target Ranked вказують, що цільовий стан вузла має з'явитись у списку ранжованих цілей у діагностичному вікні Testing Window. Цільові компоненти Target Ranked ранжуються за ступенем їхньої ймовірності. Кожен з цільових станів Target цільового ранжованого Target Ranked збою буде вказано разом з його ймовірністю.

b) вузли спостереження Observation мають кілька можливих комбінацій підтипів. Однак обговорюватимуться лише три, оскільки вони найбільш актуальні для моделювання з використанням GeNIe. Спостереження Observation може бути встановлено у стан за замовчуванням, яке вважається початковим станом спостереження, і у разі спостереження не ранжирується.

c) вузли спостереження Observation Ranked є найпоширенішими вузлами спостереження. Вони ранжуються у вікні діагностичного Testing Window залежно від того, яку інформацію вони містять щодо помилок. Вони є спостереженнями, стани яких заздалегідь невідомі, але корисні для діагностики. Призначення вузла Observation Ranked полягає в тому, щоб з'ясувати, як спостереження оцінюється в порівнянні з іншими можливими спостереженнями, перш ніж воно буде виконано шляхом відображення списку, ранжованого з точки зору його ефективності при усуненні несправностей. Ці тести ранжуються на панелі Observation Ranked діагностичного вікна Testing Window.

d) обов'язкові спостереження Observation Mandatory є інформацією, яка повинна бути надана до початку усунення несправностей. Observation Mandatory може бути дія, умова тестування або будь-який інший фактор, який необхідно виконати або спостерігати до початку усунення несправностей.

2.4.3. Аналіз чутливості

Застосування аналізу чутливості БМ дозволяє встановити для кожного з параметрів мережі функцію, яка має вихідну ймовірність з точки зору досліджуваного параметра [43, 210, 256].

Розглянемо апостеріорну маргінальну ймовірність виду $y = p(a|e)$ для виведення ймовірності, де a - значення змінної A ; e - доступний доказ. Кожен з параметрів мережі має вигляд $x = p(b_i|\pi)$, де b_i - значення змінної B , а π - довільна комбінація значень множини батьків $\Pi = pa(B)$ з B .

Позначимо $p(a|e)(x)$ як функцію, яка має апостеріорну маргінальну ймовірність $p(a|e)$ в термінах параметра x . Надалі ми будемо припускати, що в аналізі чутливості, при зміні параметра $x = p(b_i|\pi)$ кожна з ймовірностей $p(b_j|\pi)$ відповідно змінюються. Функція $y(x)$, отримана в результаті аналізу чутливості, являє собою частку двох лінійних функцій по x .

Нехай p - функція ймовірності БМ над множиною змінних V . Нехай $y = p(a|e)$ та $x = p(b|r)$, тоді маємо:

$$y = \frac{p(a,e)(x)}{p(e)(x)} = \frac{\alpha x + \beta}{\gamma x + \delta} \quad (2.18)$$

де α, β, γ та δ - константи щодо x .

Спільна ймовірність $p(a, e)$ може бути виражена з точки зору x за формулою:

$$p(a,e)(x) = \left(\sum_{V:a,e} p(V) \right) (x) \quad (2.19)$$

де $\sum_{V:a,...,d} p(V)$ позначає підсумовування по змінним $V\{A,..., D\}$ з $A, ..., D \in V$ з фіксованими значеннями $a, ..., d$ відповідно.

Сума $\sum_{V:a,e} p(V)$ в вищенаведеному рівнянні може бути поділена на $n + 1$ окремих сум, так що перша сума включає в себе тільки члени зі значенням b_1 для B і стан π для Π , друга сума

включає в себе тільки умови зі значенням b_2 для B и Π в стані π і т. д., і остання сума включає в себе умови, що залишилися.

Тому, можна записати формулу:

$$\begin{aligned}
 p(a,e)(x) &= \left(\sum_j \sum_{V:a,e,b_j,\pi} p(V) + \sum_{V:a,e,\Pi \neq \pi} p(V) \right) (x) = \sum_j p(b_j | \pi)(x) \frac{\sum_{V:a,e,b_j,\pi} p(V)}{p(b_j | \pi)} + \sum_{V:a,e,\Pi \neq \pi} p(V) = \\
 &= x \frac{\sum_{V:a,e,b_i,\pi} p(V)}{p(b_i | \pi)} + \sum_{j \neq i} \left(\frac{p(b_j | \pi)}{1 - p(b_i | \pi)} - x \frac{p(b_j | \pi)}{1 - p(b_i | \pi)} \right) \cdot \frac{\sum_{V:a,e,b_j,\pi} p(V)}{p(b_j | \pi)} + \sum_{V:a,e,\Pi \neq \pi} p(V) = \\
 &= x \left(\frac{\sum_{V:a,e,b_i,\pi} p(V)}{p(b_i | \pi)} - \sum_{j \neq i} \frac{\sum_{V:a,e,b_j,\pi} p(V)}{1 - p(b_i | \pi)} \right) + \sum_{j \neq i} \frac{\sum_{V:a,e,b_j,\pi} p(V)}{1 - p(b_i | \pi)} + \sum_{V:a,e,\Pi \neq \pi} p(V)
 \end{aligned} \tag{2.20}$$

Для ймовірності $p(e)$ виводимо аналогічний вираз, підсумовуючи в наведеному вище висновку, за всіма значеннями змінної A замість того, щоб тримати її фіксованою в a . В результаті обчислення виразу $p(a,e)(x)$ та $p(e)(x)$, можна показати, що вихід $y = p(a|e)$ може бути записаний, як частка від двох функцій, які є лінійними по x .

Функція, що виражає апостеріорну кордонну ймовірність y в термінах одного параметра x характеризується не більше ніж трьома коефіцієнтами. Але ці вирази легко перенести для n параметрів. Аналіз чутливості використовується для того, щоб з'ясувати які вузли і зв'язки мають вплив у мережі, а які зовсім не є чутливими і ніяк не змінюються при зміні умов. Це можна спостерігати за допомогою діаграм впливу (рисунк 2.37).

Для проведення аналізу чутливості моделі тип результуючого вузла має бути змінено на тип Utility. Діаграма впливу показує ступінь залучення стану у вузлі, у результаті можна проаналізувати який стан має вирішальний вплив, а який не має впливу взагалі.

Діаграми впливу - це узагальнення БМ, здатне також вирішувати задачі підтримки прийняття рішень [121]. Один вузол охоплює рішення, які є альтернативними один одному. Якщо деякі рішення можуть бути реалізовані паралельно, їм надаються власні вузли. Вузли-утиліти мають посилатися на змінні, пов'язані з нашими завданнями. Критерії, за якими оцінюються рішення,

визначаються у службових вузлах, що виражають відносні переваги для всіх альтернативних виходів цільових змінних.




Рис.2.37 Приклад побудови діаграми впливу.

Ідентифікатор може обчислити очікувані утиліти всіх комбінацій варіантів рішення, враховуючи стан знань у мережі. Мережа може мати ієрархічну структуру, тобто іншу мережу, вбудовану в основну модель як окрема підмодель (рисунок 2.38). Ці моделі називаються об'єктно-орієнтованими байєсовськими мережами (ООБМ) [149]. ООБМ можна розглядати як ієрархічний опис більшої проблемної області [272]. ООБМ можна використовувати для «часового зрізу», щоб мати можливість створювати динамічні та адаптивні часові БМ, не зважаючи на вимоги до ациклічної структури [40, 123, 271]. Важливо відзначити, що еволюція системи знаходиться в центрі уваги, оскільки, як показано на рисунку 2.38, структура управління навколишнім середовищем є адаптивною системою, що самоналаштовується. Іншим способом використання ООБМ є створення «організаційних» моделей шляхом розкладання дуже складної глобальної моделі на підмережі [14,15,32, 202]. Основні переваги ООБМ полягає в тому, що, представляючи складну систему, що складається з кількох взаємопов'язаних підсистем, знання можуть

бути децентралізовані та структуровані на більш керовані елементи [271].




Рис. 2.38. Приклад комплексної моделі ООБМ

Аналіз чуттєвості, як метод, не завжди призводить до задовільних результатів. У випадках, коли БМ є нечутливою, для деяких мереж потрібно використовувати інші методи діагностики.

2.4.4. Критерії оцінки якості роботи методів побудови імовірнісного висновку.

Для оцінки якості роботи будь-якого методу побудови імовірнісного висновку можуть використовуватися такі величини як середньоквадратична похибка, KL-відстань або квадратична відстань Хеллінджера (Hellinger) [288]. Середньоквадратична похибка MSE розраховується за формулою:

$$MSE = \frac{1}{\sum_{X^{(i)} \in X \setminus E} card(A^{(i)})} \cdot \sum_{X^{(i)} \in X \setminus E} \left(\sum_{\forall x^{(i)} \in X \setminus E} (P(x^{(i)}|e) - \hat{P}(x^{(i)}|e))^2 \right) \quad (2.21)$$

KL - відстань D_K між значенням ймовірності $P(x^{(i)}|e)$ та оцінкою $\hat{P}(x^{(i)}|e)$

$$D_K(P(X^{(i)}|e), \hat{P}(X^{(i)}|e)) = \sum_{\forall x^{(i)} \in A^{(i)}} \left(P(x^{(i)}|e) \cdot \log \left(\frac{P(x^{(i)}|e)}{\hat{P}(x^{(i)}|e)} \right) \right) \quad (2.22)$$

KL - відстань D_K всієї БМ:

$$D_K(P, \hat{P}) = \frac{1}{card(X \setminus E)} \cdot \sum_{X^{(i)} \in X \setminus E} D_K(P(X^{(i)}|e), \hat{P}(X^{(i)}|e)) \quad (2.23)$$

Квадратична відстань Хеллінджера D_H між значенням ймовірності $P(x^{(i)}|e)$ та оцінкою $\hat{P}(x^{(i)}|e)$:

$$D_H(P(X^{(i)}|e), \hat{P}(X^{(i)}|e)) = \sum_{\forall x^{(i)} \in A^{(i)}} \left(\sqrt{P(x^{(i)}|e)} - \sqrt{\hat{P}(x^{(i)}|e)} \right)^2 \quad (2.24)$$

Квадратична відстань Хеллінджера D_H всієї БМ:

$$D_H(P, \hat{P}) = \frac{1}{card(X \setminus E)} \cdot \sum_{X^{(i)} \in X \setminus E} D_H(P(X^{(i)}|e), \hat{P}(X^{(i)}|e)) \quad (2.25)$$

В наведених формулах $X = \{X^{(1)}, \dots, X^{(N)}\}$ множина всіх вершин графа БМ G , де кожна j -та вершина мережі ($j=1, \dots, N$) має $A^{(j)} = \{0, 1, \dots, \alpha^{(j)} - 1\}$ ($\alpha^{(j)} \geq 2$) станів, запис $card(A^{(j)})$ означає потужність множини $A^{(j)}$ (кількість елементів з яких складається множина), $E \subset X$, $E=e$ -множина подій (інстанційовані вершини), $P(X^{(i)}|e)$ значення ймовірності вершини $X^{(i)}$ за умови відбуття події $E=e$, $\hat{P}(X^{(i)}|e)$ значення оцінки ймовірності.

2. 5. Сценарний аналіз «What-if»

Сценарний аналіз «What-if», як необхідна складова ймовірнісного моделювання і прогнозування, є важливим інструментом для прийняття рішень у різних галузях, включаючи фінансовий сектор (для аналізу можливих змін ринкових умов,

оцінки впливу економічних показників на фінансові результати компанії), бізнес-планування (при розробці стратегій розвитку компанії з урахуванням різних ринкових сценаріїв, оцінці впливу нових продуктів або послуг), управління проєктами (для оцінки впливу змін в ресурсах, термінах або вартості проєкту на його результати), екології та природоохоронної діяльності (для аналізу впливу змін клімату, природних катастроф або інших екологічних факторів на екосистеми та людську діяльність) та багато інших. Цей підхід дозволяє моделювати можливі сценарії та оцінювати наслідки рішень або подій, надаючи змогу організаціям краще підготуватися до майбутнього та мінімізувати ризики, або лікарю поставити більш точний діагноз, чи інвестору більш впевнено здійснити капіталовкладення.

Сценарний аналіз «What-if» базується на створенні декількох можливих сценаріїв розвитку подій та аналізі їх впливу на систему або процес. Основні принципи аналізу «What-if» включають:

1. *Визначення ключових змінних*: вибір основних факторів, які можуть змінюватися та впливати на результат. Це можуть бути економічні показники, ринкові умови, внутрішні ресурси компанії тощо.

2. *Розробка сценаріїв*: створення різних можливих сценаріїв, які включають зміну ключових змінних.

3. *Аналіз впливу*: оцінка впливу кожного сценарію на систему, яка може включати фінансові розрахунки, оцінку ризиків, моделювання наслідків тощо.

4. *Порівняння сценаріїв*: аналіз та порівняння результатів для різних сценаріїв з метою виявлення найбільш ймовірних або критичних подій.

5. *Прийняття рішень*: використання результатів аналізу для прийняття обґрунтованих рішень, розробки стратегій та планів дій.

Переваги сценарного аналізу «What-if»:

1. Підвищена готовність: сценарний аналіз допомагає організаціям підготуватися до можливих змін та непередбачених обставин.

2. Оцінка ризиків: метод дозволяє ідентифікувати та оцінити ризики, пов'язані з різними сценаріями, що сприяє розробці ефективних стратегій управління ризиками.

3. Прийняття обґрунтованих рішень: аналіз результатів різних сценаріїв надає керівникам та аналітикам більше інформації для прийняття зважених рішень.

Недоліки сценарного аналізу «What-if»:

1. Невизначеність даних: результати аналізу залежать від точності та повноти вихідних даних, що може впливати на надійність прогнозів.

2. Обмежена точність: навіть за умови ретельного аналізу, сценарії можуть не враховувати всі можливі фактори та їх взаємодії, що обмежує точність прогнозів.

Сценарний аналіз «What-if» є потужним інструментом для моделювання та оцінки впливу різних подій або рішень на систему. Його використання дозволяє організаціям підвищити готовність до майбутніх змін, знизити ризики та приймати більш обґрунтовані рішення. Незважаючи на певні складнощі та обмеження, сценарний аналіз залишається невід'ємною частиною стратегічного планування та управління в сучасному світі.

Висновки до розділу 2

З кожним роком стрімко зростає інформаційна лавина, що надходить з науки, бізнесу, соціальних мереж та інших джерел. На перший погляд вичерпну інформацію про будь-який об'єкт можна знайти просто і швидко, однак для виявлення дійсно корисної інформації, навіть експерту в певній галузі, необхідно докласти чимало зусиль, адже він повинен не лише проаналізувати великі масиви інформації, визначитися із вибором оптимальних для вирішення конкретної задачі методів та алгоритмів, виходячи як із своїх знань і досвіду, так і знань, що містяться у даних, що аналізуються.

Тому проблема, коли в процесі аналізу даних різної природи дослідник зустрічається з так званими невизначеностями, тобто неповнотою інформації про досліджуваний процес, значними впливами випадкових збурень і шумів вимірів, нестаціонарною структурою і параметрами процесів [296], стає дедалі актуальнішою. Тобто можна говорити про наявність структурних, статистичних і параметричних невизначеностей, які ускладнюють процес аналізу даних і погіршують якість остаточного результату — оцінок прогнозів та/або якості керування. Використання байєсових мереж для аналізу процесів різної природи, діяльності людини та функціонування технічних систем дозволяє враховувати та використовувати будь-які вхідні дані – експертні оцінки і статистичну інформацію.

Змінні, що використовуються у мережах, можуть бути як дискретними, так і неперервними, а характер їх надходження при аналізі та прийнятті рішення може бути і в режимі реального часу, і у вигляді статистичних масивів інформації та баз даних. Завдяки представленню взаємодії між факторами процесу у вигляді причинно-наслідкових зв'язків в мережі досягається максимально високий рівень візуалізації та чітке розуміння суті взаємодії факторів процесу між собою. Саме це відрізняє мережі Байєса від інших методів інтелектуального аналізу даних. Також перевагами мереж Байєса є можливості врахування невизначеностей

статистичного, структурного і параметричного характеру, побудова моделей за наявності прихованих вершин і при неповних спостереженнях, а також формування висновку за допомогою різних методів – наближених і точних. Загалом можна сказати, що мережі Байєса – це високоресурсний метод ймовірнісного моделювання процесів довільної природи з невизначеностями різних типів, який забезпечує можливість достатньо точного опису їх функціонування, оцінювання прогнозів та побудови системи управління.

Методологія байєсівського аналізу даних та експертних оцінок цілком узгоджується з логікою дій особи, що приймає рішення при аналізі процесів довільної природи, формуванні альтернатив і прийнятті рішень. Апріорна інформація про досліджуваний процес доповнюється даними експерименту, додатковою інформацією якісного або кількісного характеру, що може бути отримана з різних джерел, і на основі інтегрованих знань і даних формується апостеріорний ймовірнісний висновок стосовно змінних, параметрів, станів, ситуацій та ін. Байєсівські методи успішно застосовуються на всіх етапах аналізу даних при моделюванні, прогнозуванні та прийнятті рішень. На етапі попередньої обробки даних застосовують ймовірнісну фільтрацію спостережень, заповнення пропусків, на етапі моделювання – формування структур моделей і оцінювання їх параметрів, а на етапі формування альтернатив – обчислення ймовірнісних висновків за допомогою побудованих раніше моделей.

В цьому розділі розглянуто деякі принципи побудови байєсових мереж на основі аналізу поведінки процесів. Виконано аналіз інформаційних потоків, які мають місце між вузлами мережі. Наведено основні співвідношення, що описують процес розповсюдження ймовірностей по мережі при надходженні нової інформації. Важливо зазначити ключові етапи та підходи, які використовуються а процесі розробки байєсової мережевої моделі.

Спершу необхідно визначити структуру мережі, тобто встановити вузли та залежності між ними. Цей етап може

включати як експертні знання, так і автоматичні методи навчання структури з даних.

Далі слідує етап параметризації, де встановлюються ймовірнісні розподіли, що описують залежності між змінними. Тут використовуються як апріорні знання, так і емпіричні дані для калібрування моделей. Зокрема, методи максимальної правдоподібності або байєсівського оцінювання допомагають визначити параметри, що найкраще відповідають наявним даним.

Далі переходимо до валідації та аналізу чутливості, що дозволяють збільшити точність та адекватність моделі. Аналіз чутливості відбувається за допомогою діаграм впливу. За необхідності ми видаляємо з моделі зайві нечутливі вузли та зв'язки. Після цього переходимо до повторної валідації редуцированої мережі.

Сценарний аналіз дозволяє визначити вплив показників та їх взаємозв'язки, з'ясувати тенденції розвитку результуючого вузла.

Контрольні питання:

1. Які сучасні програмні засоби для роботи з байєсівськими мережами ви знаєте? Дайте опис та приклади використання.
2. В чому переваги використання програмного середовища GeNIe Modeler для побудови БМ?
3. Які типи вузлів використовуються в середовищі GeNIe Modeler?
4. Які типи БМ ви знаєте? Охарактеризуйте кожен тип.
5. Що таке дискретна мережа Байєса? Чим вона відрізняється від мереж інших типів?
6. Що таке динамічна байєсівська мережа, її роль та місце серед інших ймовірнісних методів? Наведіть приклади використання.
7. Назвіть особливості побудови динамічної мережі Байєса.
8. З яких етапів складається технологія розробки байєсової мережевої моделі?

9. Що ви розумієте під дискретизацією даних? Наведіть приклади.

10. Які ви знаєте методи дискретизації даних? В чому особливості кожного з них?

11. Що означає навчання мереж Байєса?

12. Наведіть типи навчання мереж Байєса залежно від структури та наявності спостережень. Якими методами вирішуються такі задачі навчання?

13. Що ви розумієте під структурою мережі Байєса?

14. Назвіть типи існуючих алгоритмів пошуку структури мережі Байєса.

15. Які опції та оператори процедури побудови мережі Байєса визначають тип мережі в GeNie?

16. Яким чином відбувається побудова топології мережі Байєса в GeNie?

17. Яким чином відбувається навчання параметрів мережі Байєса в GeNie?

18. Що таке приховані вершини в мережі Байєса? Які переваги використання прихованих вершин при моделюванні?

19. Яким чином можна перетворити приховану вершину у звичайну наявну?

20. Що таке канонічні вузли? Як їх побудувати в GeNie?

21. Які існують методи визначення і підвищення точності моделі?

22. Яка мета аналізу чутливості?

23. Які існують критерії оцінювання якості роботи методів побудови ймовірнісного висновку мережі Байєса?

24. В чому полягає сутність сценарного аналізу «What-if»?

РОЗДІЛ 3

ПРОЄКТУВАННЯ ЙМОВІРНІСНИХ МОДЕЛЕЙ НА ОСНОВІ СТАТИЧНИХ БАЙЄСІВСЬКИХ МЕРЕЖ

3. 1. Галузі застосування ба'єсових мереж

Ми вже з'ясували, що байєсівські мережі – це графічні структури, що служать для зображення ймовірнісних відносин між значним числом змінних, і структури, які необхідні, щоб здійснити ймовірнісний висновок, ґрунтуючись на представлених змінних [16, 87, 121, 200].

Вперше, байєсівський підхід був використаний на початку ХХІ ст. для персональної фільтрації спаму. Творцем першого фільтра є Пол Грем [190]. Принцип роботи персонального фільтра наступний: під час навчання фільтра для кожного слова в тексті вираховується та зберігається його «вага» — оцінка ймовірності того, що текст із цим словом — спам. У найпростішому випадку як оцінку використовують частоту: «поява в спамі/поява всюди». У складніших випадках використовується попередня обробка тексту: приведення слів до початкової форми, видалення службових слів, обчислення «ваги» для цілих фраз, транслітерація тощо.

Віднесення тексту до «спаму» чи «не-спаму» проводиться в залежності від того, чи перевищує його «вага» якусь планку, задану користувачем (зазвичай беруть 60-80 %). Після ухвалення рішення стосовно тексту в базі даних оновлюються «ваги» для слів, що входять до його складу.

В тепершній час байєсівський підхід застосовують при побудові медичних та технічних діагностичних систем, розпізнаванні статичних і динамічних об'єктів, прогнозуванні розвитку процесів в різних галузях досліджень.

Одна з альтернатив класичного статистичного аналізу даних заснована на суб'єктивістському байєсівському погляді на ймовірність. Важливим практичним наслідком прийняття байєсівського погляду на ймовірність є те, що він дозволяє почати з оцінки ймовірності, яка може бути уточнена шляхом спостереження. Це відкриває можливість застосування надійного статистичного аналізу до проблем, у яких дані недостатні або відсутні взагалі, і потрібно починати аналіз саме з ймовірнісної оцінки. Відомим інструментом, що використовується в

байєсівському моделюванні, є байєсівська мережа або її розширена версія з наявністю параметра часу, яка називається динамічною байєсівською мережею (ДБМ) [73, 138, 216].

Справа в тому, що класичні методи моделювання та прогнозування часових рядів обмежені в спроможності представляти загальні ймовірнісні залежності та нелінійності багатьох процесів. При використанні традиційних методів дослідники часто змушені боротися із складними проблемами у параметризованих моделях, що може привести до жертвування явно виражених знань предметної області заради простоти. Незважаючи на значні дослідження в минулому десятилітті в сфері логічного виводу з невизначеностями, була відзначена лише незначна взаємодія між статистиками, що вивчають аналіз часових рядів, та фахівцями з обчислювальної техніки, які вивчають представлення невизначених знань.

Відомо, що мережа довіри Байєса – це метод структурованого графічного представлення знань, що відображає в явній формі ймовірності залежності між змінними предметної області, з метою реалізації логічного виводу для процесів та систем з невизначеностями [216].

На сьогодні довірчі мережі – це основний компонент діагностичних систем для більшості реальних проблем. Методики ймовірнісного виводу в довірчих мережах та завдання довірчих мереж з'явилися у відповідь на розмаїття проблем, де використовуються довірчі мережі. Загалом, прикладні статистики визнали важливість графічних структур і фундаментальних понять умовної незалежності у багатовимірному аналізі категорійних даних [296].

До прогнозування звернулися тільки в останньому десятилітті завдяки співтовариству вчених, зайнятих логічним виводом із невизначеностями. Були розроблені методики, що звертаються до питання прогнозування і запропоновані декілька підходів для ймовірнісного логічного виводу з врахуванням залежності від часу та для часового логічного виводу в довірчих мережах і діаграмах впливу [68].

В даний час байєсівські методи знайшли застосування в багатьох сферах, таких як менеджмент [107], прийняття рішень в умовах невизначеності [157, 189], аналітика [76], машинне навчання [219], медичній діагностиці [266] та багато інших. Вони необхідні в будь-якій області, де потрібно встановлення невідомих змінних за допомогою використання структурних зв'язків та даних. Так, мережі Байєса можуть бути використані для дослідження причинних зв'язків та прогнозування будь-яких наслідків втручання в систему. Зараз широкого поширення набувають гібридні байєсовські мережі [10, 107]. Існує багато галузей реального світу, змодельованих як гібридні стохастичні процеси, які включають як неперервні, так і дискретні змінні. Такі процеси доступні у випадку супроводу цілей, завдань візуального супроводу, завдань розпізнавання швидкості тощо [59].

Будь-які значні досягнення в галузі автоматизованого проектування можуть призвести до негайних покращень продуктів та інновацій у широкому діапазоні областей, включаючи рекламу, інформатику в галузі охорони здоров'я, банківській справі, інтелектуальному аналізі інформації, техніці управління, обчислювальних системах, виробництві, електронній комерції [151]. Байєсівська оптимізація стала потужним вирішенням цих різноманітних проблем, пов'язаних з проектуванням [172]. В академічних колах це впливає на широкий спектр областей, включаючи інтерактивні інтерфейси користувача [35], робототехніку [198], моніторинг навколишнього середовища [195], видобуток інформації [268], комбінаторну оптимізацію [112, 269], автоматичне машинне навчання [20, 108, 240, 248, 252], сенсорні мережі [92, 243], адаптивний метод Монте-Карло [192], експериментальний дизайн [10] та навчання з підкріпленням [20].

При розробці програм найчастіше інженери-програмісти стикаються з безліччю варіантів. Зробивши цей вибір явним, байєсівська оптимізація може бути використана для побудови оптимальних програм, які працюють швидше або обирають найкращі обчислювальні рішення [109]. Більш того, оскільки різні компоненти програмного забезпечення зазвичай інтегруються для

створення більших систем, ця структура пропонує можливість автоматизації інтегрованих продуктів, що складаються з множини параметризованих програмних модулів.

Байєсівська оптимізація використовується для вирішення складних завдань комбінаторної оптимізації в кількох додатках. Один з підходів називається емпіричними моделями твердості, які використовують набір проблемних характеристик для прогнозування продуктивності алгоритму на конкретному екземплярі проблеми [168]. Основна ідея байєсівської оптимізації - побудувати модель, яку можна увесь час оновлювати та використовувати для прийняття оптимізаційних рішень. Байєсівська оптимізація за допомогою емпіричних моделей твердості зводиться до пошуку найкращого алгоритму, конфігурації [112, 269], налаштування наближених алгоритмів k -найближчих сусідів [197], для швидкої локалізації об'єктів на зображеннях [278], для покращення вилучення тексту [268] та для налаштування текстових уявлень для більш загальних текстових та мовних завдань [277].

Тепер детально розберемо практичні приклади реалізації статичних байєсівських мереж з наявністю прихованих вершин. Спершу розглянемо побудову ймовірнісної моделі оцінки рівня задоволеності населення якістю правоохоронного сервісу у програмному середовищі GeNie2.3 Academic.

3. 2. Оціночна ймовірнісна модель якості правоохоронного сервісу на основі статичної байєсівської мережі.

Аналіз звітних даних про кримінальні правопорушення дозволяє нам зробити ряд висновків про:

- 1) оцінку основних показників роботи, включаючи структурні зміни;
- 2) оцінку сумарної суспільної небезпеки;

3) виявлення «вузьких місць» і позитивних зрушень у кримінальній ситуації;

4) прогностні оцінки ефективності роботи поліції, а також якість правоохоронного сервісу;

5) ступінь задоволеності населення роботою правоохоронних органів.

Метою роботи є розробка та дослідження можливості застосування статичних байєсівських мереж для аналізу факторів, що впливають на якість роботи правоохоронних органів.

Байєсову мережу будемо проектувати згідно етапів, які були детально розглянуті в попередньому розділі п. 2.3. Технологія побудови статичної БМ, згідно з яким процес моделювання включає такі кроки:

1. Визначення вхідних даних;
2. Процес передобробки даних;
3. Побудова концептуальної моделі;
4. Навчання структури БМ;
5. Навчання параметрів;
6. Валідація;
7. Аналіз чутливості;
8. Підвищення адекватності моделі;
9. Повторне навчання параметрів;
10. Повторна валідація;
11. Сценарний аналіз "What-if".

3.2.1. Опис вхідних даних

Отже, розпочнемо з першого етапу «Визначення вхідних даних». Маючи набір відомих даних X (таких як кількість потерпілих, кількість конфіскованих предметів злочинної діяльності, кількість розкритих злочинів) необхідно визначити кінцеві характеристики Y (якість роботи правоохоронних органів).

Набір даних для експерименту було сформовано зі звіту про криміногенні правопорушення за період 10 місяців звітного року (січень-жовтень 2018), спрямованого органами правопорядку в

Херсонській області в генеральну прокуратуру України. З цих статистичних даних була виділена вибірка вхідних даних для побудови моделі, яка представлена в таблиці 3.1.

Таблиця 3.1.

**Вхідні дані для побудови моделі БМ оцінки роботи
правоохоронного сервісу [189].**

	X1	X12	X2	X21	X3	X31	X4	X41	X42	X43
січень	37802	37614	2416667,19	134404,28	412995,47	219549,83	12288	1143	16	104
лютий	69192	68819	2753678,51	221863,81	562553,78	347468,38	1203	2800	48	66
березень	98882	98326	3472276,73	314146,66	922132,25	599357,08	59826	4977	75	184
квітень	132930	132179	3783196,15	394800,55	990467,64	878711,38	83873	7166	214	274
травень	164795	163813	4548336,19	513282,86	113509412	993998,26	107580	9392	90	471
червень	193586	192399	5225675,85	783547,39	1442703,5	1111527,65	135477	1086	200	593
липень	227342	225943	6477326,45	1471590,88	1754490,16	2689445,99	158416	1357	235	723
серпень	258419	256806	7014359,32	1420251,61	1880414,89	1565553,27	181265	16867	272	814
вересень	282736	280950	7542760,3	1696219,97	1963561,22	1846907,03	205793	19436	291	949
жовтень	312986	311006	7875785,42	1869041,76	2208976,06	1926812,2	229147	21951	330	1047

3.2.2. Процес передоброби даних

Проводимо дискретизацію вхідних змінних, використовуючи функцію дискретизації в середовищі GeNie2.3 Academic, і визначаємо інтервали для ключових змінних. В експерименті беруть участь наступні показники:

1. Кількість потерпілих при вчиненні злочину (вузол X1). На цей вузол впливають два вузли: вузол X1.1, який показує кількість летальних випадків, вузол X1.2, який відображає кількість людей, що вижили. Рівень кількості потерпілих може приймати такі стани:

- s1: дуже низький - нижче 92838 чол.
- s2: низький - від 92838 до 147875 чол.
- s3: середній - від 147 875 до 202 912 чол.
- s4: високий - від 202 912 до 257949 чол.
- s5: дуже високий - 257949 і вище.

Можливий діапазон значень які може приймати вузол X1 коливається в діапазоні від 37802 до 312986 чоловік.

2. Вузол X2 відображає розмір матеріальних збитків, вузол X2.1 показує кількість відшкодованих з них, вузол X2.2 - кількість невідшкодованих матеріальних збитків. Розмір матеріальних збитків може приймати стани:

- s1: дуже низький - нижче 311 298 грн.
- s2: низький - від 311 298 до 4165766 грн.
- s3: середній - від 4165766 до 5851501 грн.
- s4: високий - від 5851501 до 7278559 грн.
- s5: дуже високий - 7278559 грн. і вище.

Можливий діапазон значень, які може приймати X2 коливається в діапазоні від 2416667,19 до 7875785,42 грн.

3. Вузол X3 являє кількість конфіскованих предметів злочинної діяльності, а вузол X3.1 - кількість поданих цивільних позовів.

- s1: дуже низький - нижче 742 343 грн.
- s2: низький - від 742 343 до 1288899 грн.
- s3: середній - від 12888899 до 1598597 грн.
- s4: високий - від 1598597-2086268 грн.
- s5: дуже високий - 2086268 грн. і вище.

Можливий діапазон значень які може приймати X2 коливається в діапазоні від 412995,47 до 2208976,06 грн.

4. І вузол X4 - це кількість зафіксованих злочинів. Він розпадається на вузли X4.1, X4.2 і X4.3 - кількість злочинів, розкритих національною поліцією, розкритих прокуратурою (включаючи військову прокуратуру) і розкритих органами безпеки і антикорупційним бюро, відповідно.

- s1: дуже низький - нижче 36057
- s2: низький - від 36057-71849
- s3: середній - від 71849-121528
- s4: високий - від 121528-193529
- s5: дуже високий - 193 529 і вище.

Можливий діапазон значень які може приймати X2 коливається в діапазоні від 12288 до 229147 злочинів.

3.2.3. Концептуальна модель байєсової мережі

Концептуальна модель являє собою модель предметної області, що складається з набору взаємопов'язаних понять, які використовуються для опису цієї області, разом з властивостями й характеристиками, класифікацією цих понять, ознаками в даній області і законів протікання процесів в ній. Це доволі абстрактна модель, що визначає структуру модельованої системи, властивості її елементів і причинно-наслідкові зв'язки, властиві системі і суттєві для досягнення мети моделювання. Концептуальна модель оцінки якості правоохоронного сервісу показана на рисунку 3.1.




Рис.3.1 Концептуальна модель ступеня задоволеності населення роботою правоохоронних органів [189].

3.2.4. Побудова байєсової моделі в програмному середовищі Genie2.3 Academic. Навчання параметрам. Валідація

В програмному середовищі Genie2.3 Academic, в робочій площині малюємо необхідні вузли по п'ять станів в кожному з вірогідністю 0,2 в кожному стані. Генеруємо файл даних на 100 рядків і отримуємо таблицю вхідних даних, яку можна представити в текстовому чи табличному вигляді (рисунок 3.2).

	X1	X12	X2	X21	X3	X31	X4	X41	X42	X43	Y
►	s4	s1	s2	s4	s5	s1	s2	s1	s4	s1	s3
	s3	s1	s4	s1	s1	s1	s1	s1	s4	s2	s4
	s3	s2	s1	s4	s5	s1	s5	s4	s5	s5	s1
	s1	s2	s5	s5	s5	s3	s5	s5	s1	s5	s1
	s1	s1	s3	s3	s1	s4	s5	s4	s5	s5	s3
	s4	s2	s2	s3	s1	s2	s2	s3	s4	s1	s3
	s3	s5	s1	s2	s2	s1	s5	s3	s4	s5	s5
	s3	s1	s4	s2	s2	s3	s4	s5	s3	s5	s5
	s2	s5	s3	s3	s4	s1	s5	s5	s1	s2	s1
	s4	s3	s5	s3	s5	s2	s5	s5	s5	s2	s4
	s1	s1	s5	s5	s2	s3	s5	s5	s4	s3	s5
	s4	s5	s2	s3	s5	s3	s5	s2	s1	s3	s5
	s1	s2	s1	s4	s3	s3	s2	s2	s5	s1	s4
	s4	s4	s4	s4	s1	s1	s5	s5	s3	s4	s1
	s1	s5	s1	s1	s1	s4	s3	s4	s4	s4	s1
	s4	s3	s2	s3	s2	s4	s2	s2	s5	s5	s2
	s2	s3	s3	s4	s2	s4	s5	s2	s1	s3	s5
	s2	s1	s3	s3	s3	s5	s4	s5	s5	s5	s3
	s5	s2	s5	s4	s3	s3	s3	s2	s4	s3	s1
	s1	s2	s4	s4	s2	s3	s2	s1	s2	s2	s2
	s3	s3	s4	s2	s5	s5	s1	s3	s2	s1	s5
	s1	s3	s2	s4	s2	s3	s5	s1	s5	s2	s3
	s2	s5	s2	s4	s4	s4	s5	s2	s3	s5	s3
	s4	s5	s1	s5	s2	s1	s4	s5	s5	s2	s1
	s3	s4	s3	s5	s5	s3	s3	s1	s1	s5	s2
	s4	s1	s2	s5	s2	s1	s3	s5	s4	s5	s5
	s3	s3	s2	s1	s3	s1	s5	s1	s5	s5	s2
	s4	s2	s1	s3	s3	s5	s3	s1	s3	s2	s1
	s2	s5	s1	s5	s2	s5	s4	s3	s5	s5	s1
	s3	s2	s5	s2	s2	s5	s2	s1	s1	s5	s3
	s3	s4	s4	s3	s2	s2	s1	s5	s3	s1	s1
	s4	s2	s2	s5	s5	s5	s1	s2	s4	s3	s4
	s4	s4	s5	s5	s5	s1	s1	s3	s1	s5	s5
	s1	s4	s3	s2	s3	s3	s3	s2	s4	s5	s3
	s3	s1	s5	s5	s2	s3	s3	s3	s5	s1	s5
	s4	s4	s1	s4	s5	s5	s2	s5	s5	s2	s1
	s3	s5	s5	s5	s2	s5	s4	s2	s5	s5	s3
	s4	s4	s5	s1	s1	s4	s1	s5	s4	s5	s4
	s1	s2	s3	s3	s2	s3	s5	s1	s2	s5	s4

Рис.3.2 Представлення даних в Genie2.3 Academic

Наступним кроком проводиться навчання нової мережі [2, 69]. Для цього ми застосуємо алгоритм РС, який будує первинну структурну моделі в наступному вигляді (рисунок 3.3):




Рис.3.3 Структурна модель БМ

Представимо схему згідно концептуальної моделі (рисунок 3.4):




Рис.3.4 Байєсова модель ступеня задоволеності населення роботою правоохоронних органів

Наступний крок – виконання навчання параметрам. Послідовність параметризації демонструє рисунок 3.5.





Рис.3.5 Послідовність процесу навчання параметрам в діалогових вікнах Geie2.3 Academic.

Як видно з рисунка 3.5 функція $\text{Log}(p) = -1587.566981$. Розпочинаємо процес валідації [103, 104]. Ми застосовуємо перехресну кросс-валідацію [163]. В процесі валідації беруть участь змінні X1, X2, X3, X4 та Y, як показано на рисунку 3.6 а) б).

Як видно з рисунку 3.6 б) первісна точність результуючого вузла Y становить 24%. Аналіз чутливості проводився з використанням діаграм впливу [136, 138, 139]. Діаграма впливу показує найбільш чутливі параметри для обраного стану цільового вузла Y, відсортованого від найбільш чутливого до найменш чутливого [43].



а)

б)

Рис. 3.6 а) перехресна кросс-валідація б) результати валідації [189].

З отриманих результатів видно, що зв'язки від X1 до X1.1 і від X2 до X2.2 можна відсікти разом з вузлами X1.1 і X2.2. Вся справа в тому, що X1 - це кількість потерпілих серед загальної кількості населення, а X1.1 - це кількість тих, що вижили серед них. Ми робимо висновок, що на ступінь задоволеності (або незадоволеності) населення впливає кількість померлих серед потерпілих, а не кількість тих, що вижили. Теж саме з показником матеріальних збитків X2, кількість невідшкодованих збитків (X2.2) майже ніякого впливу на Y не робить, а насправді важлива лише кількість відшкодованих збитків (X2.1). Прибравши зайві вузли та зв'язки, уточнюємо модель. Результати повторного аналізу представлені на рисунку 3.7.




Рис. 3.7. Результуюча схема після відсікання вузлів і повторного аналізу чутливості.

Проводимо повторне навчання параметрам і валідацію (рисунок 3.8):




Рис. 3.8. Результати повторної валідації.

Точність результуючого вузла Y становить 69,23%.

3.2.5. Сценарний аналіз

В експерименті досліджується ступінь задоволеності населення якістю правоохоронного сервісу. Структурна модель (рисунок 3.9) складалася з наступних вузлів:




Рис.3.9 Структурна модель байєсової мережі рівня задоволеності населення якістю правоохоронного сервісу [189].

Опис масиву вузлів, що наявні в редуцированій моделі:

X1 -у потерпілих, з них:

X12 – вижили,

X2 - матеріальні збитки, з них:

X12 - відшкодовані,

X21 - не відшкодовані,

X3 - конфісковано предметів злочинної діяльності, і:

X31 - був пред'явлений позов,

X4 - зафіксовано злочинів, з них:

X41 - розкрито національною поліцією,

X42 - розкрито прокуратурою, в тому числі військовою прокуратурою,

X43 - органами безпеки і антикорупційне бюро,

Y - рівень задоволеності населення якістю правоохоронного сервісу.

Тип всіх вузлів Y, X1, X2, X3, X4, X11, X12, X21, X22, X32 і X42 - General.

Дана мережа є прикладом байєсівської мережі довіри – одного з найбільш поширених методів представлення знань з невизначеністю. За топологією вона є орієнтованим ациклічним графом. Вузли являють собою випадкові змінні, що можуть бути дискретними чи неперервними. Дуги відображають причинно-наслідкові зв'язки між змінними, "батьківські" вершини відображають причини, а "дочірні" – наслідки. Наприклад, кількість злочинів, що розкрито національною поліцією впливає на рівень задоволеності населення якістю правоохоронного сервісу. Основна задача такої мережі – отримати інформацію про недоступні для діагностування вузли через дані, що надходять у змінні та спостерігаються, і відомі залежності між ними. Дані залежності змодельовані за допомогою відповідних дуг. Мережа містить 11 вершин та 10 дуг. В якості ключових вершин обрано вершини: X1-X4. Кожній змінній мережі ставиться у відповідність таблиця умовних ймовірностей, у якій перераховані всі можливі значення змінної за прийняття її батьківськими вершинами певних значень.

В нашій мережі зібрані всі дані взаємозв'язків між досліджуваними вузлами. Модель розроблена для оцінки тенденцій, а не для отримання точних результатів, тому вона має деякі обмеження, включаючи ті, які властиві всім байєсовим мережам:

1. Неповнота моделі через відсутність деяких вузлів може впливати на результат.

2. Велика стійкість моделі веде до низької чутливості вихідних даних. Це говорить про необхідність введення процедури "зважування" вузлів.


У таблиці 3.2 представлені дані залежності Y від X_{21} (кількості відшкодованих матеріальних збитків) при X_2 максимум.

Таблиця 3.2.

Залежність Y від X_{21} [189].

	Y					X_{21}				
	S1	S2	S3	S4	S5	S1	S2	S3	S4	S5
Первинні стани	21	19	20	19	21	16	17	26	22	19
по X_2 мінімум	23	19	20	19	20	19	19	15	16	19
по X_2 максимум	20	18	20	20	22	16	6	26	22	36

З даних таблиці видно, що первинний стан змінився з 19% до 36% (рисунок 3.10).

**Рис.3.10. Кількість відшкодованих матеріальних збитків [189].**

Таблиця 3.3 показує, що максимальний рівень розкритих злочинів забезпечується:

- зростанням з 29 до 33% кількості розкритих злочинів національною поліцією;
- зростанням з 33 до 42% кількості розкритих злочинів прокуратурою (включаючи військову прокуратуру);
- зростанням з 36 до 40% кількості розкритих злочинів органами безпеки (рис.3.11).

Таблиця 3.3

Зведена кількість розкритих злочинів [189].

	X41					X42					X43				
	S4	S2	S4	S4	S5	S1	S2	S3	S4	S5	S1	S2	S3	S4	S5
Первинні стани	20	19	20	12	29	19	10	19	19	33	18	16	16	13	36
по X2 мінімум	14	23	18	14	31	14	14	23	23	27	27	5	23	5	40
по X2 максимум	24	15	19	10	33	28	5	15	10	42	10	19	19	5	40




Рис.3.11 Рівень розкритих злочинів [189].

В ході проведеного аналізу стає ясно, що тільки застосування комплексу заходів здатне привести до істотних позитивних результатів щодо збільшення ступеня задоволеності населення якістю роботи правоохоронних органів. Запропонований аналіз, заснований на байєсовому підході, лише підтверджує це. Зрозуміло, при цьому підході існує і ряд обмежень, про які вже згадувалось. Отже, моделювання дозволяє зробити наступні висновки:

1. Зі збільшенням кількості потерпілих при вчиненні злочинів ступінь задоволеності знижується;
2. Максимальний рівень розкритих злочинів забезпечується:

- зростанням з 29 до 33% кількості розкритих злочинів національною поліцією;
- зростанням з 33 до 42% кількості розкритих злочинів прокуратурою (включаючи військову прокуратуру);
- зростанням з 36 до 40% кількості розкритих злочинів органами безпеки.

3. Зростання кількості відшкодованих матеріальних збитків з 19 до 36% призводить до зростання ступеня задоволеності населення;

4. Для того, щоб ступінь задоволеності прагнув до максимуму необхідно витримувати такі умови:

- кількість матеріальних збитків, як і кількість потерпілих має весь час знижуватися;
- скільки, ким і як були розкриті злочини на ступінь задоволеності не впливають.

В роботі запропонована методологія використання байєсівської мережі для моделювання задоволеності населення роботою правоохоронних органів і розроблена методика інтерпретації отриманих результатів. Як практичний приклад виділено стратегії досягнення цілей, виконано моделювання цих стратегій на мережі. Результати моделювання можуть допомогти удосконалити систему правоохоронних органів.

3. 3. Комп'ютерна інформаційна система для оцінювання і прогнозування стану інтернет- магазину малого підприємства.

Ми вже знаємо, що байєсівська мережа може бути побудована як на основі експертних оцінок, так і на основі статистичних даних. Експертна інформація може використовуватися як для встановлення взаємозв'язків між випадковими елементами - тобто структури мережі, так і для отримання оцінок умовних ймовірностей, як наприклад в [36, 154, 211, 255].

В цьому дослідженні ми побудуємо комп'ютерну інформаційну систему для оцінювання і прогнозування стану

малого підприємства на основі імовірнісних методів формування статистичного висновку. Для розв'язку основної задачі необхідно створити мережу Байєса на множині зв'язаних подій $X_i, i = 1, \dots, n$ з відомими апіорними ймовірностями, тобто, побудувати ациклічний граф G , який характеризується множиною параметрів B ; дослідити характеристики отриманої мережі з метою її подальшого застосування до аналізу та оцінювання стану малого бізнесу. При цьому передбачається, що на події $X_i, i = 1, \dots, n$ впливають невизначеності різного характеру і природи, а також існують дані, що описують відповідні події, зв'язані з діяльністю малого підприємства.

На початку дослідження ми визначаємо фактори, які мали найбільший вплив на рівень ефективної роботи та безпеки онлайн-магазину із застосуванням експертних методів. В експертизі приймали участь експерти-фахівці та користувачі Інтернет магазинів.

Для погодженості експертної думки використаний множинний коефіцієнт конкордації K_0 , запропонований Кендаллом [137]. Формула коефіцієнта рангової кореляції Кендалла(T):

$$T = \frac{\text{число "сприятливих" пар} - \text{число "несприятливих" пар}}{\frac{n(n-1)}{2}} \quad (3.1)$$

Для визначення критеріїв оцінки діяльності інтернет магазину визначимо ваговий коефіцієнт важливості критерію, що розраховується за формулою:

$$W_j = \frac{x_{jcp}}{\sum jcp} \quad (3.2)$$

де $\sum jcp$ – сума середніх балів по всіх критеріям.

Розрахунок середньоквадратичного відхилення для кожного критерію здійснюється за формулою:

$$\delta_j = \sqrt{\frac{\sum (x_{ij} - x_{jcp})^2}{n}} \quad (3.3)$$

Розрахунок коефіцієнта варіації для кожного критерію визначається рівнянням:

$$V_j = \frac{\delta_j}{x_{jcp}} \quad (3.4)$$

Цей коефіцієнт дозволяє визначити, наскільки експертні думки є консистентними у відношенні до оцінюваних об'єктів або явищ. Він базується на порівнянні рангів, присвоєних кожним експертом, і враховує можливість випадкової згоди між ними.

3.3.1. Опис вхідних даних

Для оцінки, експертам (m) пропонувалося привласнити ранг (n) групам інформації. У таблиці 3.4 представлені найважливіші та найвпливовіші фактори на які звертали увагу експерти.

Таблиця 3.4

Результати експертного оцінювання безпеки інтернет магазину.

Показ- ники m	N групи факторів Опис	Експертні оцінки									
E1	Захист від DDoS-атак	9	9	10	10	9	10	9	10	9	10
E2	Швидкість завантаження сторінок	9	8	8	10	8	8	9	8	8	9
E3	Захист особистих даних	8	7	8	8	9	8	9	7	9	9
E4	Стабільність роботи сайту	9	8	7	9	8	7	8	8	7	9
E5	Рівень якості технологічного забезпечення	6	7	7	6	7	8	9	7	8	9
E6	Документація та відповідність стандартам	8	5	8	5	5	7	6	8	7	7
E7	Політика безпеки та рівень обізнаності персоналу	7	7	9	7	8	10	7	8	7	8
E8	Якість товарів та обслуговування	6	8	7	8	7	9	8	9	6	9
E9	Підтримка різних мов та валют	5	6	4	5	7	7	9	6	5	8
E10	Частота оновлення інформації на сайті	9	8	6	9	8	9	6	9	10	9
E11	Якість зображень та описів товарів	10	7	8	10	10	9	10	9	10	9
E12	Оцінки та відгуки клієнтів	6	9	8	6	6	8	9	7	9	9
E13	Безпека платежів	9	8	8	10	9	9	9	10	8	10
E14	Мобільна сумісність	8	8	6	9	7	9	8	7	9	9
E15	SEO оптимізація	9	9	7	9	7	7	8	6	8	9
E16	Комунікація з клієнтами	9	8	8	9	8	9	8	9	10	8
E17	Оптимізація пошуку та навігації по сайту	7	7	8	10	7	6	9	8	8	9
E18	Програми лояльності та знижки	6	4	6	8	9	5	8	7	9	6

Для розробки математичної моделі дослідження рівня функціоналу та ефективності інтернет-магазину скористаємось одним із найдієвіших математичних інструментів у теорії прийняття рішень при невизначеності - байєсовими мережами. Вони дозволяють оцінити вплив різних факторів на результативність системи, що є особливо корисним для аналізу складних систем, таких як інтернет-магазини ще й тому, що дозволяють обчислювати ймовірності настання подій за різноманітних обставин. Для розрахунку ймовірностей в мережі Байєса, скористаємось формулою умовної ймовірності:

$$P(A | B) = \frac{P(A \cap B)}{P(B)} \quad (3.5)$$

де A та B - події, $P(A | B)$ - ймовірність події A , якщо відомо, що подія B відбулася, $P(A \cap B)$ - ймовірність спільного виникнення подій A та B , $P(B)$ - ймовірність події B .

Погодженість думок експертів перевіряється за допомогою F -критерія Фішера. Де через (X_{ij}) позначено ранг j -го виду інформації ($j = \overline{1, n}$) у ранжуванні i -го експерта ($i = \overline{1, n}$). Щоб оцінити підготовленість експертів потрібно дотримуватися наступної умови:

$$\sum_{j=1}^n X_{ij} = 0,5n(n+1) \quad (3.6)$$

де: $\sum_{j=1}^n X_{ij}$ - сума рангів у ранжуванні j -го експерта.

Погодженість експертів при ранжуванні груп інформації оцінювалася коефіцієнтом конкордації (згоди):

$$K_0 = \frac{12S}{m^2(n^2-n)-m \sum_{i=1}^m T_i} \quad (3.7)$$

де: $S = \sum_{j=1}^n d_j^2$ - сума квадратів відхилень сум рангів, отриманих усіма групами інформації, від середньо - арифметичного сум рангів:

$$d_j = X_j - 0,5m(n+1) \quad (3.8)$$

де: d_j - відхилення суми рангів j -го виду від середнього значення сум рангів по всім видам;

$$T_j = \sum_{\mu=1}^n (t_{\mu j}^3 - t_{\mu i}) \quad (3.9)$$

де: $T_{\mu i}$ -число повторень μ -го рангу в ранжуванні i -го експерта. При $K_0 = 1$ думка експертів вважається повністю узгодженою. Для оцінки взаємного впливу наведених факторів побудуємо статичну БМ з урахуванням результатів експертних оцінок, наведених в таблицях 3.5.

Таблиця 3.5

Результати експертного оцінювання факторів.

Фактори впливу	Значний вплив	Незначний вплив
E1	0,75-1	0-0,7
E2	0,65-1	0-0,6
E3	0,6-1	0-0,55
E4	0,75-1	0-0,7
E5	0,7-1	0-0,65
E6	0,65-1	0-0,6
E7	0,45-1	0-0,7
E8	0,55-1	0-0,5
E9	0,75-1	0-0,7
E10	0,65-1	0-0,6
E11	0,76-1	0-0,5
E12	0,65-1	0-0,6
E13	0,7-1	0-0,65
E14	0,65-1	0-0,6
E15	0,75-1	0-0,7
E16	0,55-1	0-0,5
E17	0,5-1	0-0,45
E18	0,25-1	0-0,2

3.3.2. Побудова байєсової моделі в програмному середовищі Genie2.3 Academic.

Для моделювання граф-теоретичної моделі байєсівської мережі довіри оцінки ефективності роботи інтернет-магазину з акцентом на покращення рівня безпеки було використано програмне забезпечення Genie2.3 Academic.

В програмному середовищі Genie2.3 Academic, в робочій площині малюємо необхідні вузли по три стани в кожному з

вірогідністю 0,33 в кожному стані, після чого з таблиці експертних оцінок генеруємо файл даних на 100 рядків (рисунок 3.12):




Рис.3.12. Процес генерації файла даних в Genie2.3 Academic.

Отримуємо таблицю станів вхідних даних, яку можна представити в текстовому чи табличному вигляді (рисунок 3.13).

Наступним кроком проводиться побудова структурної схеми в робочому полі Genie2.3. В цьому дослідженні ми не використовували алгоритми пошуку структури, а будували структуру моделі вручну. Вузли мережі представляють різні фактори, що впливають на ефективність роботи інтернет-магазину, такі як захист від DDoS атак, захист даних та стабільність роботи сайту.

Кожен вузол представляє окремий фактор, що впливає на ефективність. Наприклад, вузли E1, E2 та E4 відповідають за захист від DDoS атак, захист даних та стабільність роботи сайту відповідно. Стрілки між вузлами показують причинно-наслідкові залежності. Вихідні значення кожного вузла впливають на ймовірності результативних вузлів, зокрема, на ефективність. Граф будується шляхом додавання вузлів та встановлення зв'язків між ними відповідно до причинно-наслідкових залежностей. Наприклад, вузли E1, E2 та E4 мають прямий вплив на результуючий вузол Efficiency.

Network33 (2)2 – Блокнот

Файл Правка Формат Вид Справка

E1	E10	E11	E12	E13	E14	E15	E16	E2	E3	E4	E5	E6	E7	E8	E9	Y
s1	s2	s2	s1	s2	s3	s2	s3	s1	s1	s1	s2	s2	s2	s2	s1	
s3	s2	s3	s1	s3	s1	s3	s3	s2	s1	s3	s2	s1	s3	s1	s2	s1
s2	s3	s1	s2	s1	s1	s3	s2	s3	s2	s3	s1	s3	s1	s2	s1	s1
s3	s1	s3	s1	s1	s3	s3	s2	s2	s3	s2	s3	s3	s3	s3	s2	s2
s2	s2	s2	s1	s3	s3	s2	s2	s3	s2	s3	s1	s3	s3	s2	s3	s1
s3	s2	s3	s2	s2	s1	s1	s1	s2	s2	s3	s2	s3	s1	s1	s2	s1
s2	s2	s2	s3	s2	s1	s1	s3	s3	s2	s3	s3	s2	s2	s2	s3	s1
s2	s1	s1	s1	s2	s3	s1	s1	s1	s1	s2	s1	s1	s3	s1	s1	s1
s1	s1	s3	s3	s1	s1	s3	s2	s1	s2	s3	s3	s1	s2	s2	s2	s1
s2	s3	s1	s3	s2	s1	s1	s1	s1	s1	s1	s3	s3	s1	s3	s1	s1
s3	s2	s1	s2	s2	s1	s3	s3	s1	s1	s1	s3	s2	s1	s1	s3	s1
s1	s2	s2	s1	s3	s2	s1	s1	s1	s2	s3	s2	s1	s2	s1	s3	s1
s1	s3	s1	s2	s3	s3	s1	s2	s1	s2	s2	s2	s1	s1	s1	s2	s1
s2	s1	s1	s3	s1	s1	s3	s3	s2	s2	s1	s3	s2	s2	s1	s2	s1
s2	s3	s1	s1	s2	s2	s1	s1	s1	s2	s3	s2	s2	s1	s1	s2	s1
s3	s1	s1	s2	s1	s1	s1	s2	s3	s3	s3	s2	s2	s3	s2	s3	s1
s3	s3	s1	s2	s2	s2	s1	s1	s2	s2	s3	s3	s3	s1	s1	s1	s1
s1	s1	s1	s3	s3	s3	s1	s2	s3	s1	s1	s2	s3	s1	s1	s3	s1
s2	s1	s2	s1	s2	s3	s1	s1	s1	s1	s3	s2	s3	s1	s1	s3	s1
s2	s2	s3	s3	s2	s3	s3	s2	s3	s1	s1	s3	s1	s1	s2	s2	s2
s2	s2	s1	s1	s2	s1	s1	s3	s3	s1	s1	s3	s2	s1	s1	s1	s1
s1	s3	s1	s3	s2	s1	s1	s1	s2	s3	s1	s1	s3	s2	s1	s1	s1
s3	s2	s1	s1	s1	s1	s3	s1	s2	s1	s1	s2	s3	s3	s2	s3	s1
s1	s2	s1	s2	s3	s1	s2	s1	s1	s1	s1	s2	s3	s2	s2	s3	s1
s3	s2	s1	s3	s2	s1	s2	s3	s2	s1	s3	s2	s1	s3	s2	s2	s1
s1	s2	s1	s3	s3	s3	s2	s2	s2	s1	s2	s2	s2	s2	s1	s2	s1
s3	s2	s2	s3	s3	s1	s3	s1	s2	s3	s2	s2	s2	s1	s1	s3	s1

Рис.3.13. Фрагмент таблиці станів вхідних даних в текстовому вигляді.




Рис.3.14 Послідовність параметризації мережі в програмному середовищі Genie2.3.

Для кожного вузла визначається таблиця умовних ймовірностей (СРТ), яка показує ймовірність кожного стану вузла

в залежності від станів вузлів-предків. Наприклад, ймовірності для вузла Efficiency залежать від станів вузлів E1, E2 та E4. Наша мета – дослідити результуючий вузол Efficiency і визначити умови, за яких ефективність магазину буде максимальною. Наступний крок – виконання навчання параметрам. Послідовність параметризації демонструє рисунок 3.14.

Розпочинаємо процес валідації. Ми застосовуємо перехресну кросс-валідацію на k -кроків. Зазвичай процес кросс-валідації займає від однієї до 3-х хвилин. Після проведення первинної параметризації та валідації був використаний аналіз чутливості. За допомогою діаграми впливу з'ясовано, що вузли: E6-10, E12, E18 не є чутливі, тому ми вилучаємо їх з мережі. Прибравши зайві вузли та зв'язки, уточнюємо модель. Результати повторного аналізу представлені на рисунку 3.15.





Рис. 3.15 Результуюча схема після відсікання вузлів і повторного аналізу чутливості.

Проводимо повторну валідацію і отримуємо точність моделі 95% , як показано на рисунку 3.16 а) б).

Маємо структурну схему редуцированої статичної БМ оцінки ефективності роботи інтернет-магазину, представлену на рисунку 3.17.



а) б)
Рис. 3.16. а) перехресна кросс-валідація, б) результати валідації.




Рис.3.17. Структурна моделі БМ оцінки ефективності роботи інтернет- магазину.

3.3.3. Сценарний аналіз

Проведемо сценарний аналіз нашої моделі. З початкової структурної схеми (рисунок 3.17) ми бачимо, що початкова ефективність нашого магазину 7%. Якщо показники: захист від DDoS-атак, швидкість завантаження сторінок, захист особистих даних, безпека платежів, якість зображень та описів товарів та комунікація з клієнтами посилити до максимального рівня, то результируючий показник ефективності роботи інтернет-магазину вдасться підвищити на 13% (з 7% до 20%), як показано на рисунку 3.18.




Рис.3.18 Тенденції зростання ефективності роботи магазину.

Для досягнення максимальної ефективності роботи інтернет-магазину з акцентом на покращення рівня безпеки (тобто результируючий вузол має бути 100%) потрібно виконати наступні умови (рисунок 3.19):

1. Посилити швидкість завантаження сторінок і безпеку платежів (показники E2 і E13) на 10%,

2. Мобільну сумісність, SEO оптимізацію та оптимізацію пошуку та навігації по сайту (показники E14,E15 і E17) потрібно збільшити на 13%,

3. Стабільність роботи сайту (E4) має стати більш ефективною на 17%,

4. Захист особистих даних та рівень якості технологічного забезпечення (показники E3 і E5) мають бути вдосконалені на 22%,

5. Якість зображень та описів товарів та комунікацію з клієнтами (показники E11 і E16) потрібно збільшити на 26%,

6. Захист від DDoS-атак (показник E1) має бути збільшений на 32% (рис.3.19).




Рис.3.19. Умови досягнення максимальної ефективності роботи інтернет-магазину.

На основі проведеного дослідження ми можемо сформулювати наступні рекомендації для інтернет-магазину:

1. Забезпечити високий рівень захисту від DDoS атак для всіх компонентів системи з метою підвищення його на 32%.

2. Впровадити сучасні технології для підвищення захисту персональних даних клієнтів.

3. Забезпечити безперебійну роботу сайту шляхом регулярного моніторингу та підтримки.

На основі проведеного аналізу можна зробити висновок, що покращення рівня безпеки є ключовим фактором для досягнення загального підвищення ефективності роботи інтернет-магазину. Зокрема, заходи щодо підвищення захисту від DDoS атак, захисту даних клієнтів та забезпечення стабільності роботи сайту мають значний позитивний вплив на ефективність. Інвестиції в безпеку не лише знижують ризики, але й підвищують довіру клієнтів, що сприяє зростанню продажів та покращенню репутації магазину. Виконання цих рекомендацій допоможе інтернет-магазинам підвищити свою ефективність і забезпечити стійке зростання.

3. 4. Прогностична модель економічного зростання країни на базі статичної байєсової мережі.

Економічне зростання країни відбувається завдяки впливу на нього певних факторів, що дозволяють збільшити валовий внутрішній продукт (ВВП) національної економіки, підвищити реальний обсяг виробництва, його ефективність. Знаючи їх і впливаючи на них, можна збільшити темпи економічного зростання. При цьому потрібно пам'ятати, що економічне зростання не вирішує всі проблеми населення країни. Наприклад, на рівень бідності в країні впливають не стільки величина ВВП і обсяги виробництва, скільки сформовані механізми розподілу національного доходу.

У сучасних умовах прогноз глобального зростання означає прогрес у напрямку підвищення рівня життя населення та створення достатньої кількості гідних робочих місць. Певне уповільнення зростання світової економіки за останній рік супроводжувалося різким уповільненням міжнародних торгових потоків та глобальної виробничої діяльності. На тлі зростання тарифів та швидких змін торгової політики довіра бізнесу

погіршилася, гальмуючи зростання інвестицій у більшості регіонів України. Пом'якшення попиту також вплинуло на світові ціни на товари, зокрема на нафту та промислові метали. В загальному вигляді зміст економічного зростання можна представити у вигляді цілей та показників, за допомогою яких оцінюється ступінь досягання цих цілей (рисунок 3.20).



Рис. 3.20 Зміст процесу економічного зростання країни.

Моделювання економічного розвитку країни з урахуванням усіх відповідних змінних є досить складним з теоретичної точки зору, оскільки характеризується складними структурами залежності. Обчислювальні проблеми також очевидні, оскільки аналіз великих баз даних вимагає тривалого часу обробки і може бути здійснений тільки при наявності адекватної комп'ютерної

інфраструктури. Коли ресурси обмежені і дослідження ведуться на основі відкритих даних, існує потреба в моделях, які можуть за своєю суттю ідентифікувати залежності на основі мінливості різних функцій і при цьому можуть додатково використовувати експертні знання для підвищення передбачуваності моделей. Для вирішення даної проблеми найбільш адекватним обчислювальним інструментом є байєсівські мережі.

Хоча байєсівська теорія не вирішує всіх проблем імовірнісного мислення, вона дала вченим міцну основу для подання і прагматичного аналізу невизначеності.

3.4.1. Проведення аналізу показників економічної діяльності та визначення вхідних даних

Перш за все, необхідно проаналізувати дані, які нададуть нам змогу розробити стратегію дій та концепцію вирішення поставлених перед нами завдань. В якості експериментальних даних для оцінки економічного зростання України були взяті макроекономічні показники, що враховують статистичні можливості і модифікацію існуючих методів дослідження фінансової діяльності підприємства. Вихідні дані для моделювання представлені в таблиці 3.6.

Таблиця 3.6.

Вихідні дані для дослідження [265].

Позначення вузла в моделі	Опис економічного показника
X1	Рівень інноваційного розвитку країни
X11	Частка підприємств, що займаються інноваціями
X12	Частка виручки від інноваційних підприємств
X13	Рентабельність операційної діяльності промислових підприємств, %
X2	Рівень фінансового розвитку країни
X21	Позики в національній валюті терміном на 5 років резидентам (без урахування депозитних корпорацій), середня вартість, млн. грн

Позначення вузла в моделі	Опис економічного показника
X22	Позики резидентам в іноземній валюті (крім депозитних корпорацій) строком на 5 років, середня вартість, млн. грн
X3	Зовнішні інвестиції в економіку
X31	Прямі іноземні інвестиції в Україну
X32	Процентні ставки за строковими депозитами, %
X4	Внутрішній економічний потенціал
X41	Середня схильність населення до економії
X42	Середньорічний курс долара, грн
Y	Рівень економічного зростання (номінальний ВВП у фактичних цінах)

У нашій роботі ми використовуємо набір статистичних даних, взаємопов'язаних між собою, що складаються з 14 показників за період 2007-2020 роки. Матриця показників розділена на чотири блоки, що найбільш повно характеризують фінансову економічну та ділову активність підприємств, а також перебіг економічних процесів в країні (таблиця 3.6). Результуючий показник Y - це інтегральний показник рівня економічного зростання України.

Основною проблемою є налаштування параметрів з урахуванням природи взаємин між вузлами і попереднє визначення умовних ймовірностей вузлів-предків мережі з подальшою валідацією отриманої моделі. Мета моделювання полягає в тому, щоб оцінити можливість та основні тенденції (або умов), за наявності яких можливий подальший економічний ріст країни.

В якості вихідних даних ми взяли: рівень інноваційного розвитку, рівень фінансового розвитку, зовнішній та внутрішній потенціал країни, які, на нашу думку, могли б служити критеріями до нашого дослідження.

При розробці БМ було використане програмне середовище GeNIe 2.4 Academic. Первісна Байєсова мережева модель побудована на вузлах General. В мережі використовується 5 ключових вузлів (X1-X4) та один результуючий вузол Y. Кожний з вузлів має по п'ять станів. Наприклад, для вузла X1 стани дискретизації розподіляться наступним чином:

s1: нижче-85879;
s2: 85879-114478;
s3: 114478-150998;
s4: 150998-218982;
s5: 218982 і вище.

Динаміка змін вихідних показників за спостережуваний період представлена в таблиці 3.7. Слід зазначити, що внаслідок специфіки роботи БМ всі висновки даної моделі, щодо шуканої інформації носять імовірнісний характер і представлені у вигляді рангового за значеннями ймовірності вірності того чи іншого висновку списку [265].

3.4.2. Концептуальна модель

Математичну модель, яка при аналізі фінансових, інвестиційних та економічних показників підприємства допомогла б оцінити рівень економічного зростання країни, вимагає наявності вихідних даних. Методи байєсових мереж, з певним ступенем ймовірності, дозволяють досягти поставленої мети.

Маючи вхідні показники, такі як: рівень технологічності (інноваційності), рівень фінансової забезпеченості (фінансовий розвиток), індикатор зовнішнього інвестування, внутрішній інвестиційний потенціал, які взаємодіють між собою, необхідно спроектувати статичну байєсову мережу оцінки можливості економічного зростання країни.

Основна перевага байєсівських мереж при вирішенні завдань діагностування технічного стану полягає в їх здатності одночасно виконувати як передбачувальні функції, так і класифікаційні функції. Інформація, що поширюється у напрямку зв'язків у БМ, має передбачувальну здатність, тому що дозволяє робити висновки про можливі наслідки будь-яких змін у роботі окремих підсистем.

Концептуальна модель забезпечення процесу економічного зростання країни в контексті байєсівських мереж може бути представлена таким чином (рисунок 3.21).

Таблиця 3.7. Динаміка змін вихідних показників за спостережуваний період [265].

	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Y	Номинальний ВВП (у факт. цінах)	441452	544153	720731	948056	913345	1079346	1299991	1404669	1465198	1586915	1988544	2383182	2982920
X1	Рівень технологічності (інноваційності)	0.253	0.355	0.440	0.390	0.260	0.308	0.352	0.307	0.295	0.210	0.188	0.218	0.399
X11	Питома вага підприємств, що здійснюють інновації	0.082	0.1	0.115	0.108	0.107	0.115	0.128	0.136	0.136	0.121	0.166	0.143	0.166
X12	Питома вага виторгу підприємств, що здійснюють інновації до загальної величини виторгу	0.065	0.067	0.067	0.059	0.048	0.038	0.038	0.033	0.033	0.025	0.005	0.007	0.059
X13	Рентабельність операційної діяльності промислових підприємств, %	0.016	0.035	0.058	0.049	0.018	0.035	0.047	0.034	0.03	0.016	0.042	0.066	0.034
X2	Рівень фінансової забезпеченості (фінансового розвитку)	0.335	0.365	0.180	0.280	0.414	0.338	0.273	0.222	0.197	0.215	0.163	0.143	0.168
X21	Кредити в національній валюті строком від 5 років, надані резидентам (крім депозитних депозитних корпорацій), середньорічне значення, МЛН грн	41802	51979	13590	34691	41311	47002	53498	62168	68997	72530	90300	116728	146944
X22	Кредити в іноземній валюті строком від 5 років, надані резидентам (крім депозитних депозитних корпорацій), середньорічне значення, МЛН грн	46798	67256	64037	124453	185337	171670	159721	125079	104503	132053	142275	139388	252627
X3	Рівень забезпечення зовнішніми інвестиційними ресурсами (зовнішнє інвестування)	0.995	1.000	1.000	0.998	0.760	0.978	0.940	0.978	0.592	0.175	0.513	0.529	0.487
X31	Прямі іноземні інвестиції в Україну (потік)	7808	5604	9891	10913	4816	6495	7207	8401	4499	410	3284	2202	1526
X32	Процентні ставки за залученими строковими депозитами у національній валюті, %	0.147	0.197	0.1	0.116	0.159	0.158	0.147	0.184	0.18	0.197	0.182	0.149	0.18
X4	Рівень забезпечення внутрішніми інвестиційними ресурсами	0.512	0.445	0.567	0.587	0.586	0.578	0.616	0.543	0.516	0.305	0.330	0.335	0.305
X41	Середня щільність до заощадження	0.2028	0.2003	0.243	0.1951	0.1184	0.1479	0.1209	0.1177	0.1039	-0.0749	-0.0194	0.0362	0.0362
X42	Середньорічний курс долара, грн.	5.12	5.05	5.05	5.27	7.79	7.94	7.97	7.99	7.99	11.89	21.84	25.55	27.2




Рис.3.21 Концептуальна модель статичної Байєсової мережі для оцінки економічного зростання країни [265].

3.3.3. Побудова байєсової моделі в програмному середовищі Genie2.4 Academic на вузлах General.

Розв'язання задачі побудови мережі Байєса починається з дискретизації змінних. Використовуючи функцію дискретизації методом Uniform Weights ми визначаємо інтервали для ключових змінних (рисунок 3.22).




Рис.3.22. Результат дискретизації вузла X1 [265].

Наступний крок – виконання навчання параметрам. Послідовність параметризації і процес валідації. Ми застосовуємо перехресну кросс-валідацію методом Uniformise. В процесі валідації беруть участь ключові змінні: X1,X2,X3,X4 та Y.

Аналіз чутливості зазвичай проводиться за допомогою діаграм впливу. Після аналізу проводять повторну параметризацію та повторну валідацію мережі [265]. БМ цікаві для представлення знань, тому що дозволяють як висновок зверху вниз, так і висновок знизу верх, вони легко захоплюють думки експертів, і можуть навчатися на експертних даних, оновлюватися і персоналізуватися.

Ми проводимо, параметризацію, і валідацію мережі на вузлах General. Первісна загальна точність мережі склала 48,8%, точність результату склала 42%. З огляду на те, що однією з проблем при

розробці Байєсовських мереж, є експоненціальне зростання кількості параметрів в таблицях умовних ймовірностей, в цьому дослідженні пропонується методика застосування Noisy-MAX вузлів для моделювання економічних процесів.

3.4.4. Моделювання з використанням вузлів Noisy-MAX

На наступному етапі дослідження ми змінили тип всіх вузлів на Noisy-MAX з п'ятьма станами s1-s5, і результуючим вузлом Y.

Мережа залишається колишньою, файл з даними теж не змінюється. Проводимо навчання параметрам, а також первинну валідацію. Загальна точність мережі підвищилася на 6,6% (і склала 55,4%), точність результату підвищилася на 4% (і склала 46%), як показано в таблиці 2.8.

Далі ми проводимо аналіз чутливості мережі за допомогою діаграм впливу. Повторне навчання параметрам і повторна валідація привели до збільшення загальної точності на 2% (з 55,4% до 57,4%), а точність результату збільшилася на 14% (з 46% до 60%). Результати наведені в таблиці 3.8:

Таблиця 2.8

Порівняння результатів точності до і після аналізу чутливості [265].

	Первісна точність		Точність після аналізу чуттєвості	
	Загальна точність мережі,%	Точність результату,%	Загальна точність мережі,%	Точність результату,%
Вузли Noisy-MAX	55,4	46,0	57,4	60,0

Структурна модель статичної БМ економічного зростання країни представлена на рисунку 3.23. Пропонована модель не обмежується жорсткою односпрямованістю дій, а може використовуватися як для виявлення причинних характеристик, так і передбачення наслідків. Стрілки показують рух інформації між виділеними блоками. Всі показники X пов'язані з Y (наявність \ відсутність), також є взаємозв'язок даних між собою.




Рис.3.23 Статична Байєсова модель оцінки можливості економічного зростання країни [265].

3.4.5. Аналіз моделювання статичної байєсової мережі на вузлах Noisy-MAX.

Вибір адекватного алгоритму для використання в конкретній економічній задачі може виявитись доволі складним. В той час як можна використати різні алгоритми для виконання однієї і тієї ж самої задачі, кожний алгоритм дає різний результат, а деякі алгоритми можуть видавати більше одного типу результатів.

Якщо рівень кредитування підвищити всього на 1% (тобто X_{21} і X_{22} збільшити з 11% до 12%), фінансовий розвиток країни підвищиться на 87% (X_2 зросте з 13% до 100%) і досягне максимуму.

Якщо питома вага підприємств, які здійснюють інновації (X_{11} збільшиться з 13% до 44%) підвищити на 31%, при цьому питома вага прибутку цих підприємств збільшиться всього на 2% (X_{21} зростає з 37% до 39%), рівень технологічності та інновацій Україна зростає на 81% (X_1 зростає з 19% до 100%) і буде наближатись до максимуму, як показано на рисунку 3.24.




Рис. 3.24. Рівень технологічності та інновацій [265].

Якщо підвищити схильність населення до заощадження всього на 5% (збільшити X_{41} з 21% до 26%), при цьому відсоткові ставки по депозитах знизити на 12% (X_{42} зменшується з 34% до 22%), то внутрішній інвестиційний потенціал підвищиться на 93% і досягне максимуму, як показано на рисунку 3.25.




Рис.3.25. Внутрішній інвестиційний потенціал [265].

Підвищення кількості інвестицій в Україну на 21% (X32 збільшиться з 29% до 50%) і при цьому невелике зниження курсу долара на 7% (X31 зменшиться з 10% до 3%) призведе до підвищення внутрішнього інвестиційного потенціалу на 75% (X3 збільшується з 25 % до 100%).

При максимальному рівні зовнішнього інвестування, рівень інноваційності зросте на 4% (з 14% до 23%), прямі інвестиції в Україну збільшаться на 28% (з 19% до 47%), схильність населення до заощаджень зросте на 14% (з 28% до 42%).

Все це разом створить умови для збільшення економічного зростання країни, який підніметься на 42% (з 24% до 66%), як показано на рисунках 3.26 та 3.27.

При збільшенні рівня інновацій до максимуму, питома вага виторгу підприємств збільшиться на 7% (з 34% до 41%), і це в свою чергу призведе до економічного зростання країни на 12% (з 24% до 36%), як показано на рисунках 3.28 та 3.29.




Рис. 3.26. Умови економічної стабільності країни [265].




Рис.3.28. Збільшення рівня інновацій до максимуму [265].




Рис.3.27 Байєсівська модель економічної стабільності країни [265].




Рис. 3.29. Умови економічного зростання країни [265].

У даному дослідженні спроектована ймовірнісно-детермінована модель на основі статичних Байєсовських мереж з метою оцінки ступеня економічного розвитку України. В роботі пропонується методика застосування Noisy-MAX вузлів для моделювання економічних процесів. В ході ситуаційного аналізу з'ясовано, що якщо питома вага підприємств, які здійснюють інновації підвищиться на 31%, при цьому питома вага прибутку цих підприємств зросте всього на 2%, рівень технологічності та інновацій України зросте на 81% і досягне максимуму. Також за умови підвищення схильності населення до заощадження всього на 5% і зниженні при цьому процентних ставок за депозитами на 12%, внутрішній інвестиційний потенціал підвищиться на 93% і досягне максимуму.

Показано, що валідація з наступною верифікацією, а також використання вузлів Noisy-MAX забезпечують надійність моделі, а також значно підвищують точність отриманої БМ.

Висновки до розділу 3

В цьому розділі ми зосередились на практичному застосуванні байєсівського підходу і розглянули три приклади побудови байєсівських мереж.

В ході розробки і аналізу моделі оцінки ступеня задоволеності населення якістю роботи правоохоронних органів стає зрозуміло, що тільки застосування комплексу заходів здатне привести до істотних позитивних результатів щодо збільшення якості їх роботи. Ми розробили також методику інтерпретації отриманих результатів. Як практичний приклад виділено стратегії досягнення цілей, виконано моделювання цих стратегій на мережі.

Моделювання дозволяє зробити наступні висновки:

1. Зі збільшенням кількості потерпілих при вчиненні злочинів ступінь задоволеності знижується;

2. Максимальний рівень розкритих злочинів забезпечується:

- зростанням з 29% до 33% кількості розкритих злочинів національною поліцією;

- зростанням з 33% до 42% кількості розкритих злочинів прокуратурою (включаючи військову прокуратуру);

- зростанням з 36% до 40% кількості розкритих злочинів органами безпеки.

3. Зростання кількості відшкодованих матеріальних збитків з 19% до 36% призводить до зростання ступеня задоволеності населення;

4. Для того, щоб ступінь задоволеності прагнула до максимуму необхідно витримувати такі умови:

- кількість матеріальних збитків, як і кількість потерпілих має весь час знижуватися;

- скільки, ким і як були розкриті злочини на ступінь задоволеності не впливають.

Результати моделювання допоможуть удосконалити систему правоохоронних органів.

В цьому розділі також запропонована методологія використання байєсівської мережі для покращення рівня безпеки

роботи інтернет-магазину, що є ключовим фактором для досягнення загального підвищення ефективності його роботи. Зокрема, заходи щодо підвищення захисту від DDoS атак, захисту даних клієнтів та забезпечення стабільності роботи сайту мають значний позитивний вплив на ефективність. Інвестиції в безпеку не лише знижують ризики, але й підвищують довіру клієнтів, що сприяє зростанню продажів та покращенню репутації магазину.

У даному розділі спроектована ймовірнісно-детермінована модель на основі статичних Байєсовських мереж оцінки ступеня економічного розвитку України. З огляду на те, що однією з проблем, при розробці Байєсовських мереж, є експоненціальне зростання числа параметрів в таблицях умовних ймовірностей, в роботі пропонується методика застосування Noisy-MAX вузлів для моделювання економічних процесів. В ході ситуаційного аналізу з'ясовано, що якщо питома вага підприємств, які здійснюють інновації підвищиться на 31%, при цьому питома вага прибутку цих підприємств зросте всього на 2%, рівень технологічності та інновацій України зросте на 81% і досягне максимуму. Також за умови підвищення схильності населення до заощадження всього на 5% і зниженні при цьому процентних ставок за депозитами на 12%, внутрішній інвестиційний потенціал підвищиться на 93% і досягне максимуму.

Контрольні питання:

1. Галузі застосування БМ. Наведіть приклади.
2. Чи можна побудувати інтелектуальну систему підтримки прийняття рішень на основі байєсівських мереж? Відповідь обґрунтуйте.
3. Які задачі можна розв'язувати за допомогою систем підтримки прийняття рішень, побудованої з використанням байєсівських мереж?
4. Що може дуже ускладнити модель?
5. Які методи підвищення точності моделі ви знаєте? Наведіть приклади.
6. Наведіть приклади практичної реалізації байєсівських мереж, вкажіть на їх особливості.
7. Яку роль відіграють приховані вузли?
8. Яка особливість використання вузлів Nisy-MAX?

РОЗДІЛ 4

РОЗРОБКА ЕКСПЕРТНОЇ СИСТЕМИ З ВИКОРИСТАННЯМ МЕРЕЖ БАЄЙСА

4.1. Поняття експертної системи.

Експертна система (ЕС) – це інтелектуальна система, призначена для вирішення слабо формалізованих задач, на основі накопиченого в базі знань досвіду роботи експертів в проблемній області. Вона містить базу знань з набором правил і механізмом виводу, що дозволяє на підставі наданих користувачем фактів розпізнати ситуацію, поставити діагноз, сформулювати рішення або дати рекомендацію для вибору дії. Експертні системи є різновидом систем підтримки прийняття рішень, вони призначені для відтворення досвіду знань професіоналів високого рівня і застосування цих знань в процесі управління. Вони розробляються з використанням математичного апарату нечіткої логіки для експлуатації у вузьких областях застосування, оскільки це потребує великих комп'ютерних ресурсів для обробки і зберігання знань. В основі побудови експертних систем лежить база знань, яка ґрунтується на моделях представлення знань.

«Батьком експертних систем» вважають Едварда Фейгенбаума, який стверджував, що «інтелектуальні системи отримують свою владу від знань, якими вони володіють, а не від конкретних формалізмів і схем виведення, які вони використовують» [81]. Це твердження є ключем до розуміння ранніх експертних систем. До цього моменту дослідження були зосереджені на спробах розроблення ЕС для розв'язання проблем найбільш загального призначення [100]. Перші експертні системи були створені в 1970-х роках і набули широкого поширення в 1980-х роках. Вони були однією з перших справді успішних форм штучного інтелекту.

Разом з Фейгенбаумом стенфордські дослідники Едвард Шортліф, Брюс Б'юкенен і Рендалл Девіс намагалися визначити галузі, в яких досвід був би високо оцінений і комплексний, такі як діагностика інфекційних захворювань та ідентифікація невідомих органічних молекул. Експертні системи стали одними з перших по-справжньому успішних форм програмного забезпечення для штучного інтелекту [66, 181, 199, 209]. У сфері штучного інтелекту комп'ютерна система, яка імітує можливість приймати

рішення людиною, називається експертною системою [28]. Однак деякі експерти відзначають, що експертні системи не були частиною справжнього штучного інтелекту, оскільки вони не мають здатності навчатися незалежно від зовнішніх даних [131]. Система MYCIN, наприклад, була розроблена, щоб рекомендувати необхідну кількість антибіотиків залежно від ваги пацієнта [58]. Дослідження в Стенфордській медичній школі показали, що MYCIN пропонує прийнятну терапію приблизно в 69% випадків, краще, ніж експерти з інфекційних захворювань, яких оцінювали за тими ж критеріями.

У США в центрі уваги здебільшого були системи, засновані на правилах, насамперед системи, закодовані на середовищах програмування LISP, а потім на експертних оболонках, розроблених такими виробниками, як IntelliCorp [232]. Дослідження експертних систем набуло активного розвитку у Франції, де розробники зосереджувалися більше на системах, спроектованих в Prolog. Перевагою експертних оболонок системи було те, що вони були дещо легші для використання звичайним користувачем, не-програмістом. Prolog-середовища забезпечували значно повнішу реалізацію логіки першого порядку [80, 93].

У 1980-х роках експертні системи набули значного поширення. Університети пропонували курси експертних систем, великі компанії застосовували ці технології в повсякденній діяльності [213]. Міжнародний інтерес був викликаний проектом розроблення комп'ютерів п'ятого покоління в Японії і фінансуванням наукових досліджень в Європі.

У 1981 році була представлена перша IBM PC з операційною системою MS-DOS. Дисбаланс між відносно потужними чипами в дуже доступній ПК порівняно з набагато вищою ціною обчислювальної потужності в ЕОМ, які домінували в корпоративному IT-світі того часу, створив абсолютно новий тип архітектури корпоративних обчислень, відомої як клієнт-серверна модель [111]. Модель «клієнт-сервер» мала величезний вплив на ринок експертних систем. Експертні системи проникли в більшу частину світу бізнесу, вимагаючи нових навичок, яких багато IT-

відділів не мали і не були готовими розвивати. Вони були природним для нових ПК на основі оболонок, що обіцяли поставляти розроблення додатків в руки кінцевих користувачів та експертів. Із зростанням кількості виробників ПК і обчислювальних клієнт-серверів, таких як Intellicorp і Inference Corporation, вони змінили свої пріоритети розвитку ПК. До цих нових постачальників належать Aion Corporation, Neuron Data, Exsys і багато інших [5, 79].

Однак, дивлячись на експертні системи в реальних умовах роботи, виникають інші проблеми, такі як інтеграція, доступ до великих баз даних і продуктивність [137]. Медична експертна система CADUCEUS створена для діагностики інфекцій крові, а також внутрішніх захворювань. CADUCEUS могла розпізнавати до 1000 різних захворювань, а також розпізнавати наявність кількох супутніх захворювань. Нечітка медична діагностика в термінах збільшення кількості ознак і діагнозів представлена системами онлайн-діагностики. На сьогоднішній день існують медичні діагностичні онлайн-системи DNFS і AWDNFN, розроблені на основі W-neuron. Під час їх роботи буде гірший критерій ефективності AWDNFN, ніж у DNFS через довший час обробки з кращою діагностичною точністю [231].

У минулому багато авторів намагалися створити системи обчислювального інтелекту для діагностики, використовуючи набори даних із медичного репозитарію як вихідні дані [29, 167, 176, 220, 250]. Недоліками цих систем є неможливість обробки даних у режимі реального часу, фіксована кількість медичних ознак, низька швидкість конвергенції. У [169] запропоновано використання імовірнісних методів медичної діагностики, що підняло експертні системи на новий рівень розвитку.

4.1.1. Характеристики експертної системи.

Експертна система відрізняється від інших прикладних програм наявністю таких ознак [166]:

I. Моделює механізм мислення людини під час розв'язання задач в конкретній предметній галузі. Це істотно відрізняє експертні системи від систем математичного моделювання або комп'ютерної анімації. Однак, ЕС не повинні повністю відтворювати психологічну модель фахівця в цій області, а повинні лише відтворювати деякі методики розв'язання проблем, що використовуються експертом, за допомогою комп'ютера.

II. Система, окрім виконання обчислювальних операцій, формує певні висновки, базуючись на тих знаннях, якими вона володіє. Знання в системі, зазвичай, описані деякою спеціалізованою мовою і зберігаються окремо від програмного коду, що формує висновки. Компонент збереження знань прийнято називати *базою знань*.

III. Під час розв'язання задач основну роль відіграють евристичні і наближені методи, що, на відміну від алгоритмічних, не завжди гарантують успіх. Евристика є правилом впливу, що в машинному вигляді відображає деяке знання, набуте людиною разом із накопичуванням практичного досвіду розв'язання аналогічних проблем. Такі методи є наближеними у тому сенсі, що, по-перше, вони не потребують вичерпної вихідної інформації, а, по-друге, існує певний ступінь впевненості (або невпевненості) в тому, що запропонований розв'язок є правильним.

Експертні системи відрізняються і від інших видів програм із галузі штучного інтелекту трьома аспектами [41]:

A. Експертні системи застосовуються для предметів реального світу, операції з якими зазвичай вимагають великого досвіду, накопиченого людиною. Експертні системи мають яскраво виражену практичну направленість для застосування в науковій або комерційній сфері.

B. Однією з основних характеристик експертної системи є її швидкодія, тобто швидкість отримання результату, його достовірність і надійність. Дослідницькі програми штучного інтелекту можуть бути і не дуже швидкими, натомість, експертна система повинна за прийнятний час знайти розв'язок, що був би не гіршим за розв'язок, що може запропонувати фахівець в цій предметній області.

С. Експертна система повинна мати можливість пояснити, чому запропоновано саме цей розв'язок і довести його обґрунтованість. Користувач повинен отримати всю інформацію, необхідну йому для того, аби переконатись в обґрунтованості запропонованого розв'язку.

Є відоме твердження, що будь-яка експертна система – це система, заснована на знаннях, але остання не завжди є експертною. У системах, заснованих на знаннях, правила або евристики, за якими вирішуються проблеми в конкретній предметній області, зберігаються в базі знань. Давайте розберемо принцип роботи ЕС. Проблеми ставляться перед системою у вигляді сукупності фактів, що описують деяку ситуацію, і система за допомогою бази знань намагається вивести висновок з цих фактів.

Система функціонує в наступному циклічному режимі:

- вибір (запит) даних або результатів аналізів,
- спостереження,
- інтерпретація результатів,
- засвоєння нової інформації,
- висунення за допомогою правил тимчасових гіпотез,
- вибір наступної порції даних або результатів аналізів [303].

Такий процес продовжується до тих пір, поки не надійде інформація, достатня для остаточного висновку. Простіші системи, засновані на знаннях, функціонують в режимі діалогу, або режимі консультації. Після запуску система задає користувачеві ряд питань про розв'язувану задачу, які потребують відповіді "так" чи "ні". Відповіді служать для встановлення фактів, за якими може бути сформовано остаточний висновок.

У будь-який момент часу в системі міститься три типи знань:

- структуровані статичні знання про предметну область, після того як ці знання виявлені, вони вже не змінюються;
- структуровані динамічні знання – змінні знання про предметну область, які оновлюються у міру виявлення нової інформації;
- робочі знання, що застосовуються для розв'язання конкретного завдання або проведення консультації.

4.1.2. Класифікація експертних систем.

Класифікація експертних систем здійснюється за різними ознаками, в залежності від області застосування, проблеми, що вирішується тощо. Класифікація ЕС наведена на рисунку 4.1 [303].

Розглянемо деякі пункти класифікації більш детально (рисунок 4.1).

За метою створення ЕС поділяються на системи:

- для навчання фахівців;
- для вирішення задач;
- для автоматизації рутинних робіт;
- для тиражування знань експертів.

За ступенем складності структури експертні системи можуть бути:

• *Поверхневими* — подають знання про область експертизи у вигляді правил (умова → дія). Умова кожного правила визначає зразок деякої ситуації, при дотриманні якої правило може бути виконано. Пошук рішення полягає у виконанні тих правил, зразки яких зіставляються з поточними даними. При цьому передбачається, що в процесі пошуку рішення послідовність формованих у такий спосіб ситуацій не обірветься до одержання рішення, тобто не виникне невідомої ситуації, що не зіставиться з жодним правилом.

• *Глибинними* — крім можливостей поверхневих систем, мають здатність при виникненні невідомої ситуації визначати за допомогою деяких загальних принципів, справедливих для області експертизи, які дії варто виконати, а які ні.

За зв'язком з реальним часом ЕС поділяються на:

• *Статичні* - розробляються в предметних областях, у яких база знань та інтерпритовані дані не змінюються в часі. Вони стабільні, наприклад системи діагностування несправностей в автомобілі.

• *Квазідинамічні* інтерпретують ситуацію, що змінюється з деяким фіксованим інтервалом часу. Наприклад, мікробіологічні експертні системи, в яких знімаються лабораторні вимірювання з технологічного процесу один раз на 4-5 ч. та аналізується динаміка одержаних показників по відношенню до попереднього виміру.




Рис. 4.1 Класифікація ЕС [303].

• *Динамічні* працюють у поєднанні з датчиками об'єктів у режимі реального часу з постійною інтерпретацією даних, що надходять. Наприклад, система управління гнучкими виробничими комплексами, моніторинг у реанімаційних палатах і так далі.

За ступенем інтеграції з іншими програмами ЕС поділяються на:

Автономні експертні системи працюють безпосередньо в режимі консультацій з користувачем для розв'язання специфічних «експертних» завдань, вирішення яких не потребує застосування традиційних методів обробки даних. Наприклад, розрахунки, моделювання і так далі.

Гібридні експертні системи представляють програмний комплекс, агрегують стандартні пакети прикладних програм (наприклад, математичну статистику, лінійне програмування або системи управління базами даних) та засоби маніпулювання знаннями. Це може бути інтелектуальна надбудова або інтегроване середовище для вирішення складної задачі з елементами експертних знань.

За завданням, що розв'язується, ЕС поділяються на системи з:

- a. інтерпретації даних;
- b. діагностики;
- c. моніторингу;
- d. проектування;
- e. прогнозування;
- f. звідного планування;
- g. навчання;
- h. керування;
- i. підтримки ухвалення рішень [303].

Інтерпретація даних - це одне з традиційних завдань, що розв'язується за допомогою експертних систем. Під інтерпретацією розуміється визначення змісту даних, результати якого мають бути погодженими і коректними. Зазвичай передбачається проведення багатоваріантного аналізу даних. Наприклад:

- виявлення та ідентифікація різних типів океанських суден;
- визначення основних властивостей особистості за результатами психодіагностичного тестування [303].

Діагностика. Під діагностикою розуміється виявлення несправності в деякій системі. Несправність — це відхилення від норми. Таке трактування дозволяє з єдиних теоретичних позицій розглядати і несправність устаткування в технічних системах, і захворювання живих організмів, і природні аномалії. Важливою специфікою є необхідність розуміння функціональної структури («анатомії») діагностуючої системи. Наприклад:

- діагностика помилок в апаратурі та математичному забезпеченні ЕОМ;
- діагностика і терапія звуження коронарних судин. [303].

Моніторинг. Основне завдання моніторингу — безперервна інтерпретація даних в реальному масштабі часу і сигналізація про вихід тих або інших параметрів за допустимі межі. Головні проблеми, що можуть виникнути, це «пропуск» тривожної ситуації і інверсне «помилкове» спрацьовування. Складність цих проблем в розмитості симптомів тривожних ситуацій і необхідності обліку тимчасового контексту. Наприклад:

- контроль за роботою електростанцій (система СПРІНТ);
- допомога диспетчерам атомного реактора (система REACTOR);
- контроль аварійних датчиків на хімічному заводі (система FALCON) та інші [303].

Проектування. Проектування полягає в підготовці специфікацій на створення «об'єктів» із заздалегідь визначеними властивостями. Під специфікацією розуміється весь набір необхідних документів — креслення, пояснювальна записка і так далі. Основні проблеми - це здобуття чіткого структурного опису знань про об'єкт і проблема «сліду». Для організації ефективного проектування і, у ще більшому ступені, перепроjektування необхідно формувати не лише самі проектні рішення, але і мотиви їх прийняття. Таким чином, в завданнях проектування тісно зв'язуються два основні процеси, виконувані в рамках відповідної

експертної системи: процес виведення і процес пояснення. Наприклад:

- проектування конфігурацій EOM VAX — 11/780 в системі XCON (або R1), проектування БІС — CADHELP;
- синтез електричних ланцюгів в системі SYN та інші [303]

Прогнозування. Прогнозуючі системи логічно виводять імовірні наслідки з заданих ситуацій. У прогнозуючій системі зазвичай використовується параметрична динамічна модель, в якій значення параметрів «підганяються» під задану ситуацію, виводяться з цієї моделі, складають основу для прогнозів з ймовірними оцінками. Наприклад:

- передбачення погоди (система WILLARD);
- оцінки майбутнього врожаю (система PLANT);
- прогнози в економіці (система ECON) та інші [303].

Планування. Під плануванням розуміється знаходження планів дій, що відносяться до об'єктів, здатних виконувати деякі функції. У таких експертних системах використовуються моделі поведінки реальних об'єктів з тим, щоб логічно вивести наслідки планованої діяльності. Наприклад:

- планування поведінки робота (система STRIPS);
- планування промислових замовлень (система ISIS);
- планування експерименту (система MOLGEN) та інші [303].

Навчання. Системи навчання діагностують помилки при вивченні будь-якої дисципліни за допомогою EOM і підказують правильні рішення. Вони акумулюють знання про гіпотетичного «учня» з його характерними помилками, для подальшого діагностування слабкості в знаннях учнів і знаходження засобів для їх ліквідації. Крім того, вони планують спілкування з учнем залежно від його успіхів з метою передачі знань. Наприклад:

- вивчення мови програмування Лісп в системі «Вчитель Ліспу»;
- система PROUST — навчання мові Паскаль та інші [303].

У загальному випадку всі експертні системи, засновані на знаннях, можна розподілити на системи, що вирішують задачі аналізу, і на системи, які вирішують задачі синтезу. Основна відмінність задач аналізу від задач синтезу полягає в наступному:

якщо в задачах аналізу безліч рішень може бути перераховані і включені в систему, то в задачах синтезу безліч рішень потенційно будуються з рішень компонентів або підзадач. Задача аналізу — це інтерпретація даних, діагностика; до задач синтезу відносяться проектування, планування. Комбінованими задачами є: навчання, моніторинг, прогнозування.

Галузі застосування ЕС обширні: це прогнозування, планування, контроль і управління, навчання. ЕС є інструментом, що підсилює інтелектуальні здібності всієї системи в цілому, і:

- 1) консультує недосвідчених (непрофесійних) користувачів;
- 2) допомагає при аналізі різних варіантів прийняття рішення;
- 3) допомагає з питань, що належать до суміжних областей діяльності.

Найбільш широко і продуктивно ЕС застосовуються в бізнесі, виробництві, медицині, навчанні.

Розповсюдженими підходами до розробки ЕС є наступні:

- системи на основі правил,
- системи з використанням нейронних мереж,
- експертні системи на основі мереж довіри Байєса.

4.1.3. Переваги експертних систем, побудованих за допомогою байєсівських мереж.

Експертні системи відзначаються певними перевагами над людьми-експертами при їх використанні. Але навіть найкращі з існуючих експертних систем мають певні обмеження у порівнянні з людиною-експертом. В таблиці 4.1. вказані основні переваги і обмеження використання ЕС.

Таблиця 4.1.

Переваги і обмеження використання ЕС

Переваги	Обмеження використання ЕС
а) переважає можливість людини при вирішенні	а) більшість експертних систем не цілком придатні для широкого використання. Якщо користувач не

Переваги	Обмеження використання ЕС
надзвичайно громіздких проблем; б) не має упереджених думок, тоді як експерт може користуватися побічними знаннями і легко піддається впливу зовнішніх факторів; с) не робить поспішних висновків, нехтуючи певними етапами знайдення рішення; д) забезпечує діалоговий режим роботи; е) дозволяє роботу з інформацією, що містить символічні змінні; ф) забезпечує коректну роботу з інформацією, яка містить помилки, за рахунок використання ймовірнісних методів досліджень; г) дозволяє проводити одночасну обробку альтернативних версій; h) за вимогою пояснює хід кроків реалізації програми; і) забезпечує можливість обґрунтування рішення та відтворення шляху його прийняття [267].	має деякого досвіду роботи з цими системами, у нього можуть виникнути серйозні труднощі. Багато експертних систем доступні лише тим експертам, які створювали їх бази знань, тому паралельно потрібно розробляти відповідний користувацький інтерфейс, який би забезпечив кінцевому користувачу властивий йому режим роботи; б) «навички» системи не завжди «зростають» після сеансу експертизи, навіть коли проявляються нові знання; с) все ще залишається проблемою приведення знань, отриманих від експерта, до вигляду, який забезпечував би їх ефективно використання; д) експертні системи, як правило, не можуть набувати якісно нових знань, не передбачених під час розроблення, і тим більше, не мають здорового глузду. Людина-експерт під час розв'язання задачі зазвичай звертається до своєї інтуїції, якщо відсутні формальні методи рішення або аналоги розв'язування цієї проблеми [267].

Давайте розберемо переваги ЕС, розроблених за допомогою БМ. Концепція байєсівих мереж полягає в оновленні ймовірностей при надходженні додаткової інформації. Математичним підґрунтям цього процесу є теорема Байєса. На відміну від систем, заснованих на правилах, метод оновлення ймовірностей у

байєсівих мережах є фундаментальним, і, якщо модель і інформація є коректними, цей метод обчислить нові імовірності правильно відносно аксіом класичної теорії ймовірностей.

Інформацію може отримувати кожен вузол (змінна) мережі, оскільки метод оновлення ймовірностей є інваріантним відносно напрямку розповсюдження інформації по ребрам мережі. Таким чином, байєсова мережа, як основа експертної системи, значно розширює можливості аналізу і прийняття рішень, оскільки дозволяє робити і прямий, і зворотний логічний висновок одночасно. Крім того, одночасне введення інформації про стани декількох вузлів не змінює алгоритму обробки мережі, що дає можливість виключити ситуації логічної суперечності, які часто мають місце в подібних випадках для інших методів.

Побудова байєсової мережі вимагає докладних знань причинно-наслідкових зв'язків між подіями предметної області. Якщо йдеться про систему, яка має надавати можливість використання завчасно отриманих експертних знань, а тим більше таких, що мають інтуїтивну складову, то в такому випадку моделювання краще виконувати за допомогою байєсової мережі. Крім того, байєсова мережа так само може навчатись. Суть навчання полягає в корегуванні ймовірностей при отриманні нової інформації про сукупність станів її вузлів.

Нарешті, байєсові мережі в експертних системах мають такі значні переваги, як можливість обчислювального трактування алгоритмів логічного висновку, гнучкість процесу розповсюдження інформації і врахування рівня суб'єктивізму експертів.

Оцінювання процесів або подій спирається на результати конкурентного і ситуаційного аналізу. Конкурентний аналіз зазвичай використовується для аналізу зовнішньої ситуації, ситуаційний аналіз стосується поточної ситуації та його найближчого оточення [118].

Логічним виходом ситуаційного аналізу є оцінка привабливості стратегічних альтернатив (рисунок 4.2).

Ситуаційний аналіз

- Розгляд придатності поточної стратегії;
- Відносна оцінка конкурентного стану;
- Оцінка перспектив розвитку і підвищення ефективності.

Рис. 4.2 Оцінка привабливості стратегічних альтернатив

Експертна система має реалізувати процес стратегічного аналізу у режимі консультації з користувачем, надавши йому на основі акумульованого експертного досвіду свою оцінку привабливості стратегічних альтернатив. Реалізація цієї системи на основі байєсівських мереж довіри означає, що ми маємо побудувати мережу, виділивши у ній вхідні вузли (тобто такі, імовірності станів яких визначає користувач) і результуючі вузли. Далі, надавши станам вхідних вузлів певні значення, необхідно отримати ймовірності станів результуючих вузлів [267].

Ми вже згадували, що байєсові мережі є популярним імовірнісним інструментом для розв'язку задач моделювання процесів з невизначеностями, аналізу, класифікації і прогнозування. Діагностичні моделі є консультантами та помічниками для лікарів, допомагаючи їм уникнути власних помилок — через втому, знижену увагу або з іншої причини. Байєсівські мережі є ефективним, компактним та інтуїтивно зрозумілим способом представлення знань, пов'язаних із невизначеністю.

Зазвичай завданням систем медичної діагностики є визначення захворювання на основі даних про самопочуття пацієнта та результатів обстеження [62, 83, 150, 215]. На даний час розроблено безліч додатків байєсівських мереж у медицині, зокрема для діагностики патології лімфатичних вузлів [103], нервово-м'язової патології [275], хвороб серця [173], раку стравоходу [256], пневмонії в палатах інтенсивної терапії [177], у традиційній китайській медицині [270], лімфоми [75], анемії [178], позалікарняної пневмонії [273], зубного болю [8], легеневої емболії [48],

психіатричних хвороб [179], гіпертонії ат синдрому підліткової гіпертензії [57, 212, 262], для лікування антибіотиками пацієнтів із загальними бактеріальними інфекціями [67], для аналізу епідеміології туберкульозу [94, 165] захворювань [251].

4. 2 Застосування Байєсових мереж в експертних системах

4.2.1. Проектування експертної системи діагностування нейропатологій з використанням байєсівської мережі довіри.

Дослідження в галузі систем прогнозування сконцентрувалися на розробці та впровадженні тих систем та моделей, які здатні імітувати сфери діяльності людини, які потребують мислення, високого рівня майстерності та досвіду. Однією із таких сфер застосування є медицина. Ми створимо систему прогнозування, що дозволяє досягти ефективності медикаментозної терапії під час нервових нападів.

Системи ефективного діагностичного виводу, які використовують довірчі мережі для встановлення імовірності альтернативних гіпотез захворювань пацієнта, вже існують і широко використовуються. Наприклад, MUNIN, ALARM, Pathfinder, VPnet і QMR. Ці програми сфокусовані винятково на статичних предметних областях. Суттю медицини лікування у важких випадках є *термінове розпізнавання швидких змін у фізіологічному стані пацієнта та раннє втручання*.

Крім того, через те, що в цих програмах негнучка структура, такі моделі не мають спроможності працювати з невизначеністю в предметній області і не здатні швидко пристосовуватися до змін у зовнішніх умовах. Тому фізіологічні моделі занадто обмежені для того, щоб бути єдиними моделями, які використовуються у визначенні лікування у важких випадках.

В своєму дослідженні ми побудуємо експертну систему діагностування порушень нервової системи у пацієнтів, при цьому будемо дотримуватись стандартів та спиратись на міжнародні класифікації Міжнародної Протиепілептичної Ліги (ILAE) [275]. Відповідно до вимог ILAE: «Нейропатологія означає хронічне захворювання, що супроводжується патологічним порушенням роботи головного мозку внаслідок підвищення активності нейронів» [275]. Це поширена проблема невралгії, яка проявляється судомами – спонтанною появою м'язових спазмів і, в деяких випадках, втратою свідомості. Епізоди можуть бути різними і можуть мати інші симптоми у вигляді порушення чутливості нюхових, звукових і зорових рецепторів, а також галюцинації.

Хронічна нейропатологія – це порушення, яке розвивається під впливом зовнішніх подразників. Стан захворювання настільки складний, що точну причину його виникнення встановити неможливо. Джерелом пульсуючих розрядів є клітини, які ушкоджуються при ураженні ділянки мозку. Хвороба розвивається в контексті генетики, інших захворювань або подразників навколишнього середовища. Основні причини хронічної нейропатології такі [7]:

- ✓ черепно-мозкова травма;
- ✓ отруєння організму;
- ✓ кліщовий енцефаліт;
- ✓ захворювання судин;
- ✓ менінгіт;
- ✓ запальні гранульоми;
- ✓ пухлина або абсцес головного мозку.

Клінічна картина захворювання залежить від типу нападу та локалізації вогнища нападу. Перші ознаки хронічної нейропатології проявляються за 1-2 дні до нападу. У людини спостерігається порушення апетиту, головний біль, сон, дратівливість, загальне нездужання.

При легкому перебігу захворювання напади бувають рідко і мають ті ж симптоми. При важкій хронічній нейропатології може

бути 4-10 послідовних нападів на день. Такі пацієнти мають різноманітні симптоми, включаючи агресію, дезорієнтацію, психічний занепад і зміни особистості. Основні ознаки генералізованої нейропатології [7]:

- ✓ частота нападів може коливатися від десятків разів на день до одного разу на два роки;
- ✓ тяжкість і симптоми захворювання залежать від конкретного типу нейропатології, яких налічується понад 40.

Для встановлення діагнозу лікарям необхідно визначити причину нейропатології і тип нападу. Початкова діагностика полягає в обстеженні та огляді пацієнта. Важливою інформацією є наявність у родичів хронічної нейропатології, час першого нападу, його частота. Неврологічний огляд передбачає виявлення ознак патології: наявність головного болю та інших симптомів ураження головного мозку. Інші дослідження:

- ✓ магнітно-резонансна томографія дозволяє уникнути неврологічних розладів;
- ✓ електроенцефалограма (ЕЕГ) для реєстрації нейропатологічної активності мозку.

Лікування спрямоване на усунення симптомів, припинення нападів, повернення до нормального способу життя і подальшу відмову від медикаментів. Схема лікування складається фахівцем на основі комплексного обстеження, індивідуальних фізіологічних особливостей пацієнта та результатів аналізів. Так, лікарі призначають лікування після проведення численних досліджень, щоб визначити причину нейропатології, адже робота лікаря — не просто лікувати, авилікувати.

Не можна з упевненістю сказати, що нейропатологіявиліковна у всіх випадках, і іноді ліки можуть повністювилікувати нейропатологію, але в деяких випадках лікування може лише допомогти зменшити частоту нападів. Люди з невиліковною нейропатологією можуть не мати нападів, але вони повинні обмежити свою діяльність.

Пацієнтам з підозрою на нейропатологію призначають стандартні обстеження, в результаті проведення яких можливі три варіанти:

- а) приступи не мають неврологічного характеру (10-30%),
- б) прогресуючі макроструктурні ураження або метаболічні нервові захворювання (2-10%),
- с) наявна хронічна нейропатологія (70-80%).

Незважаючи на розвиток кількості протисудомних препаратів (ПСП) та підвищення ефективності хірургічного лікування, встановлення найбільш інформативних предикторів та їх комбінації як факторів можливостівилікувати конкретного пацієнта є одним з першорядних завдань сучасної неврології.

Метою роботи є розробка статичної байєсівської моделі прогнозування нейропатології у пацієнтів. Системи штучного інтелекту (СШІ), які використовують симптоми або ознаки виявлення захворювань, можуть поліпшити діагностику, особливо в умовах обмежених ресурсів. Неоднорідність таких СШІ створює постійну потребу в аналізі продуктивності інформування майбутніх досліджень.

Математичну модель, яка при обстеженні пацієнта пришвидшила би визначення групи, до якої належить пацієнт (піддається лікуванню або ні) і таким чином допомогла б заздалегідь обрати правильний метод лікування, вимагає наявності вихідних умов і даних, отриманих від хворого, які швидше за все не чітко визначені. Тому застосування класичних математичних методів у цій ситуації спотворює модель.

Методи байєсівських мереж з певним ступенем ймовірності дозволяють досягти поставленої мети, оскільки працюють з невизначеною та нечіткою інформацією.

Цей математичний апарат дозволяє формально описувати нечіткі поняття, якими користується пацієнт, відповідаючи на запитання лікаря. Наприклад, періодичність і сила болю описується такими нечіткими поняттями як "часто", "дуже часто", "рідко", "сильно", "слабко" або взагалі "не знаю".

На основі вивчення динаміки захворювання у пацієнтів з такою формою нейропатології, яка піддається лікуванню, були визначені наступні ознаки в анамнезі пацієнта [7]:

- наявність родичів з діагнозом «нейропатологія»,
- фебрильні судоми в анамнезі,
- травматичне ураження головного мозку,
- частота нападів більше 10 до початку лікування,
- відсутність відповіді при прийомі ПСП,
- перерви у лікуванні,
- психічна коморбідність, тобто наявність у пацієнта щонайменше двох розладів, кожен із яких може вважатися самостійним і діагностуватися незалежно один від одного.

Про виникнення можливості вилікувати пацієнта у майбутньому також свідчили деякі електроенцефалографічні показники:

- дифузні зміни на ЕЕГ,
- високий індекс нейропатологічної активності при фоновому записі ЕЕГ,
- осередкова нейропатологічна активність,
- поліморфізм нейропатологічних змін,
- наявність кількох вогнищ ураження клітин [275].

Важливу роль у виліковності хвороби за допомогою медичних препаратів грають також генетичні чинники. Вони визначають розвиток як самої нейропатології, так і поліморфізму рецепторів та транспортеру ПСП [275].

Спостереження за хворими з діагнозом " нейропатологія" тривало один рік - це час за який можна відтитрувати два ПСП до максимально можливих терапевтичних доз. Було обстежено 310 осіб, стаж захворювання у кожного пацієнта був щонайменше 1 рік. Середній вік хворих 29 ± 2 роки. Усі пацієнти пройшли такі обстеження:

- проведено клінічний огляд,
- визначено неврологічний та психічний статус,
- виконано магніто-резонансна томографія головного мозку,
- проведено рутинне ЕЕГ та відео-ЕЕГ,

- проведено опитування з метою встановлення анамнезу.

При необхідності, у деяких пацієнтів було скориговано медикаментозне лікування відповідно до прийнятих стандартів.

Мета моделювання полягає в тому, щоб з досліджуваної групи пацієнтів виділити тих, що піддаються лікуванню, та стійких до лікування. Ми виділили показники, які могли б бути критеріями (вхідними даними) для визначення прогнозу перебігу нейропатології у конкретного пацієнта (таблиця 4.2).

Всі пацієнти пройшли необхідні обстеження і кожен з них пройшов опитування для встановлення анамнезу. При необхідності деяким пацієнтам було скориговано медикаментозне лікування відповідно до прийнятих стандартів.

Мета роботи:

- (1) - розробити структуру статичної байєсівської мережі для прогнозування нейропатології;
- (2) - провести навчання параметрам та валідацію байєсівської моделі для перевірки взаємодії функціональних блоків;
- (3) - провести сценарний аналіз клінічних випадків з метою прогнозування стану кожного пацієнта окремо;
- (4) - проаналізувати сферу застосування розробленої системи прогнозування нервових розладів.

Вирішення проблеми встановлення діагнозу можливе на основі експертних оцінок та наявності статистичних даних. Наше завдання - допомогти в обробці даних, сформувані об'єктивні альтернативи та допомогти вибрати кращу альтернативу лікування за допомогою статичних байєсівських мережевих моделей [267]. Отримана байєсівська прогнозна система повинна мати гнучку структуру, яка передбачає введення нових вузлів для генерації ймовірного виведення. Раніше було багато спроб впровадити медичні системи прогнозування, які б давали більш менш достовірні результати і пропонували персональний інтелектуальний інструментарій, який надавав би допомогу медичним працівникам у встановленні діагнозу пацієнта [159].

Таблиця 4.2

Вхідні дані для дослідження [264].

Дані спостережень за пацієнтом										Лабораторні аналізи									
X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	Z1	Z2	Z3	Z4	Z5	Z6	Z7	Z8	Z9	Z10
Нейропатологічний статус в анамнезі	Нааявність \ відсутність нейропатології у родичів	Фебрильні судоми в анамнезі	Психічні розлади в анамнезі	Черепно-мозгова травма із змінами на мрт	Більше 10 нападів до початку лікування	Відсутність відповіді на першому нейропатологічному припадку	Перенесено інсульт	Ефективне лікування у родичів з нейропатологією	Позитивна відповідь на енцефалограмі після першого нейропатологічного приступу	Дифузні зміни на електроенцефалограмі	Високий індекс нейропатологічної активності	Вогнищева нейропатологічна активність	Поліморфізм нейропатологічних змін	Висока повільнохвильова електроенцефалограма	Бгато нейропатологічних вогнищ на електроенцефалограмі	Нааявність \ відсутність нейропатології на електроенцефалограмі	Немає \ присутні зміни на мрт	Генетичний аналіз на глікопротеїни p-gp1, p-gp2, scn1a	Тотальний моніторинг артеріального тиску

Коли база експертних знань бралася від одного експерта, то це не допомагало уникнути проблем пов'язаних з "усередненням" експертних оцінок. Для більш точного моделювання процесу встановлення діагнозу потрібно враховувати більше параметрів, що призводить до різкого зростання розмірності дерева рішень, а отже часу знаходження результату. Тож замість простого пошуку перебором мають використовуватись оптимізовані методи пошуку, що значно скорочує час виконання алгоритму та дає можливість при встановленні діагнозу врахувати велику кількість параметрів.

Вид структурної схеми статичної байєсівської мережі в програмному середовищі GeNie 2.3. представлений на рисунку 4.3. Згідно з представленою моделлю з лікуванням нейропатології може бути асоційовано безліч різноманітних понять, які його характеризують - як дані анамнезу, так і результати лабораторних досліджень. При цьому запропонована модель не обмежується жорсткою односпрямованістю дій, а може використовуватися як для виявлення причинних характеристик, так і передбачати наслідки.

Розв'язання завдання побудови мережі Байєса проводилося з використанням програмного середовища GeNie 2.3. Одночасно ми проводимо параметризацію, аналіз чутливості моделі та валідацію. В якості цільового вузла був прийнятий вузол, що визначає ймовірність наявності нейропатології у пацієнта.

Нехай вузли X_1 - X_{10} подають дані спостережень (анамнез хвороби). Вузли Z_1 - Z_{10} – лабораторні дослідження та отримані результати аналізів. Y – ймовірність наявності нейропатології у конкретного пацієнта.

Всі вузли мають по два стани:

- стан s_1 – означає відсутність цієї ознаки;
- стан s_2 – означає наявність цієї ознаки у клінічній картині.

Всі показники X і всі показники Z безпосередньо пов'язані з Y (наявність\відсутність), також є взаємозв'язок даних деяких досліджень з даними анамнезу. Тобто рух інформації між виділеними блоками відбувається наступним чином:

$$X1 \rightarrow Z2, X6 \rightarrow Z1, X5 \rightarrow Z7, X8 \rightarrow Z7, X2 \rightarrow Z9.$$

Слід зазначити, що внаслідок специфіки роботи байєсівських мереж усі висновки даної моделі, щодо інформації, що шукається, носять імовірнісний характер і представлені у вигляді ранжованого (за значеннями ймовірності вірності того чи іншого висновку) списку.

Остаточне рішення про підтвердження, чи є форма нейропатології виліковною чи ні, та призначення лікування пацієнту приймає лікар.




Рис.4.3 Структурна модель статичної байєсівської мережі визначення нейропатології у пацієнта [264].

В програмному середовищі Genie 2.3 дані можна представити в текстовому чи табличному вигляді. Наступним кроком проводиться навчання нової мережі, далі необхідно побудувати структуру мережі і виконати навчання параметрам [69, 2]. Далі проводяться навчання параметрам і первинна валідація [101,102]. Ми застосовуємо метод перехресної кросс-валідації [163]. Зазвичай процес кросс-валідації займає від однієї до 3-х хвилин.

Байєсова формула використовується в байєсівських мережах як інструмент висновку для пошуку розв'язання проблеми. Якщо байєсівська мережа використовується для розпізнавання

(ідентифікації) об'єктів, то багато факторів замінюються факторами або характеристиками конкретного об'єкта [70, 120, 126].

Вибір окремого набору екземплярів змінних має свої переваги та недоліки. Перевага цього представлення полягає в тому, що такий вибір запобігає зацикленню під час формування виводу. Якщо вихід не вибрано окремо, існує ризик того, що дані вплинуть одне на одного, і мережа стане нестабільною [151].

Недоліком такого представлення є збільшення витрат на обчислення. Однак переваги настільки великі, що виділення екземплярів змінних цілком виправдане. Остаточне рішення щодо підтвердження ефекту між даними та результатами аналізів, а також призначення лікування приймає лікар. Аналіз чутливості проводився з використанням діаграм впливу [136,138,139]. Діаграма впливу показує найбільш чутливі параметри для обраного стану цільового вузла Y , відсортованого від найбільш чутливого до найменш чутливого [43].

Побудувавши структуру самостійно або залучивши експертів для її побудови, дослідник отримує мережу Байєса певної топології. Використовуючи її, можна моделювати різноманітні ситуації, тобто задавати вершинам мережі Байєса деякі значення станів і отримувати найбільш ймовірні значення станів для інших вершин мережі.

Процес обчислення оцінки стану вершини на основі апріорної ймовірності про стани інших вершин мережі Байєса називають формуванням (обчисленням, отриманням) **ймовірнісного висновку**. Саме механізм побудови ймовірнісного висновку перетворює будь-яку мережу Байєса, яка описує відповідний процес, на повноцінну складову експертної системи.

Під час аналізу чутливості ми видаляємо вузли X_{21} , X_{25} , X_{36} , X_{44} разом із дугами, що їх з'єднують, оскільки вони не є чутливими. Тож, ми маємо клінічні спостереження за симптомами 310 пацієнтів, підкріплені проведеними аналізами. Ми взяли вибірку даних по 16-ти пацієнтам і проаналізували кожен конкретний клінічний випадок. Результати аналізу наведено у таблиці 4.3.

Таблиця 4.3
Результати аналізу лабораторних досліджень і клінічних спостережень
за симптомами пацієнтів [264].

№ п\п	Клінічні спостереження															
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
X1	0	1	1	1	0	0	1	1	1	0	1	0	1	1	1	0
X2	1	0	1	1	0	1	0	1	1	1	1	0	1	1	0	0
X3	0	0	1	0	0	0	1	0	0	0	0	0	1	1	0	0
X4	1	1	0	1	1	1	1	1	0	1	1	1	1	0	0	1
X5	0	0	0	1	0	1	1	0	1	0	1	1	1	0	0	0
X6	0	1	1	0	0	1	0	1	0	0	0	1	1	1	0	0
X7	1	1	0	1	0	0	1	1	0	1	1	0	0	0	1	0
X8	1	1	1	1	1	0	1	0	0	0	0	0	0	1	1	0
X9	1	0	0	0	1	1	1	1	1	1	1	0	1	1	0	1
X10	1	0	0	1	0	1	1	1	0	0	0	0	0	1	0	1
Z1	1	0	1	1	0	0	1	1	1	1	1	0	1	1	1	0
Z2	1	1	0	0	0	0	1	1	1	1	0	0	0	1	1	1
Z3	1	0	1	1	1	0	1	0	1	0	1	0	1	0	0	1
Z4	0	1	0	0	1	0	1	1	0	0	1	1	0	0	0	0
Z5	1	1	1	0	0	1	1	0	1	1	0	1	1	0	1	1
Z6	1	0	0	1	0	0	0	0	0	0	0	1	0	1	0	0
Z7	0	0	1	0	1	1	0	1	0	0	0	1	0	1	1	1
Z8	1	0	0	0	0	1	0	1	1	0	1	1	0	0	1	0
Z9	1	1	1	0	1	0	1	0	1	0	1	1	0	0	0	0
Z10	1	1	0	1	0	0	1	1	1	1	1	0	1	0	1	0
Y, %	так ні 25 75	так ні 25 75	так ні 25 75	так ні 25 75	так ні 25 75	так ні 50 50	так ні 25 75	так ні 25 75	так ні 25 75	так ні 25 75	так ні 75 25	так ні 75 25	так ні 25 75	так ні 75 25	так ні 25 75	так ні 25 75




Рис. 4.4 а), б). Результати моделювання за клінічним випадком 1[264].

Модель статичної байєсівської мережі, орієнтована на розв'язання завдання визначення чи є нервовий розлад у конкретного пацієнта, представлена на малюнках 4.4-4.7.

Розглянемо клінічний випадок 1. Як очевидно з таблиці 4.3 з ймовірністю 75% нейропатологія у пацієнта підтверджується, отже завдання лікаря постає в тому, щоб оцінити, чи він добре реагуватиме на стандартну схему медикаментозного лікування, чи ні (рисунок 4.4 а,б).


Розглянемо клінічний випадок 9. Як видно з таблиці 4.3 з ймовірністю 75% у пацієнт не підтверджується нейропатологія, тобто він потребуватиме альтернативних методів лікування, таких як: генетика, електрофізіологія, та інші (рисунок 4.5).

Розглянемо клінічний випадок 6. Як очевидно з таблиці 4.3 пацієнт має неоднозначний результат. Цей результат вимагає проведення додаткових аналізів та дослідження, оскільки зазвичай у такій ситуації лікар буде далі прояснювати клінічну картину (рисунок 4.6).


Як видно з таблиці 4.3, у 6 випадках їх 16 наявність нейропатології у пацієнтів з ймовірністю 75% була підтверджена (що становить 56,7% вибірки), у 9 випадках з 16 – ми говоримо швидше про відсутність нейропатології (37,3% випадків). В єдиному випадку з пацієнтом №9 ймовірність наявності нейропатології становить 50% до 50%.

БМ застосовують там, де потрібно моделювання ситуацій, що містять певну невизначеність. Використання причинно-наслідкового методу дозволяє більш просто оцінювати ймовірності подій.


В дослідженні запропоновано модель статичної байєсівської мережі для вирішення завдання прогнозу ефективності медикаментозної терапії при такому захворюванні як нейропатологія. Результати моделювання показали, що 56,25% пацієнтів піддаються стандартному лікуванню, 6,25% - мають спірний результат і в цьому випадку потребують додаткового обстеження, але 37,5% пацієнтів потребують альтернативних методів лікування нейропатології, таких як: генетика, електрофізіологія, а також хірургія нейропатології при можливості її проведення (рисунок 4.7).



а) б) Рис. 4.5 а), б). Результати моделювання за клінічним випадком 9 [264].



а) б) Рис. 4.6 а), б). Результати моделювання клінічного випадку 2 [264].






Рис.4.7. Результати аналізу клінічних спостережень за симптомами пацієнтів [264].

Враховуючи, що нейропатологія – це особлива форма захворювання, що характеризується високою смертністю та витратами на лікування, беручи до уваги високу частоту діагностичних помилок при виявленні цього захворювання та поширену практику неадекватного застосування ліків, ми змоделювали систему, яка може з певним ступенем вірогідності передбачити наявність або відсутність передумов для встановлення діагнозу. Це допоможе отримати рекомендації для практикуючих лікарів, дотримання яких покращить результати лікування нейропатології у осіб віком від 18 років.

Це дослідження може стати основою для розробки клінічних настанов/протоколів для діагностики та надання належної медичної допомоги дорослим пацієнтам з нейропатологією.

В побудованій байєсівській мережі зібрані всі дані взаємозв'язків між досліджуваними вузлами. Модель була розроблена для оцінки тенденцій, а не для отримання точних результатів, тому вона має деякі обмеження, включаючи ті, які властиві всім байєсовим мережам:

1. Неповнота моделі через відсутність деяких вузлів може впливати на результат.

2. Велика стійкість моделі веде до низької чутливості вихідних даних. Це говорить про необхідність введення процедури "зважування" вузлів.

3. Для моделювання використовуються як апріорні дані, засновані на анкетному опитуванні, так і експертні оцінки.

З огляду на те, що Баєсова мережа - це імовірнісний підхід, з наявністю різного роду невизначеностей, отримана модель адекватна досліджуваних процесів. Застосування моделі для реальних клінічних випадків дає висновки, що узгоджуються з пізнаннями та практичним досвідом одного з авторів. При цьому кількісна оцінка апостеріорних ймовірностей можливих діагнозів може служити лікарю як допоміжний засіб щодо остаточного діагнозу або наступних кроків для його уточнення. Поліпшення якості ймовірнісних оцінок моделі може бути досягнуто додаванням додаткових вхідних вузлів та навчанням мережі за допомогою статистичних даних.

4.2.2. Проектування експертної системи діагностування пневмонії з використанням байєсівської мережі довіри.

Термін «діагноз» (від грец. Diagnostikos – здатність розпізнавати) у медицині означає процес розпізнавання хвороби, що веде до остаточного діагнозу. Необхідно розрізняти методи та методику діагностичного процесу. Під діагностичними методами розуміється будь-який технічний прийом, за допомогою якого встановлюється (виявляється) будь-яка ознака патологічного процесу чи захворювання. Методика визначає порядок застосування цих методів, методи аналізу отриманих з їх допомогою ознак і включає ряд положень та правил, що накладаються на характер та напрямок мислення лікаря. Кожен з методів дослідження дозволяє виявити деяку інформацію про ту чи іншу характеристику патологічного процесу. Тільки зібравши

та узагальнивши дані всіх методів дослідження, лікар зможе сам діагностувати захворювання. Сучасна діагностика може бути лише комплексною [38].

В діагностиці давно сформувалися і створюються два підходи. Перший характеризує шлях дослідження, який складається з активного виявлення та оцінки клінічних симптомів, виходячи із закономірностей формування та розвитку патологічного процесу. Другий - встановити аналогію, коли на основі виявлених симптомів проводиться пошук образу, аналогії, копії раніше описаної, зазвичай класичної, тобто типової клінічної картини захворювання або патологічного процесу.

З погляду методології діагностики важливо зробити висновок про те, що різні методи дослідження пацієнта не призначаються лікарем «для підтвердження діагнозу», а проводяться їм свідомо з метою виявлення будь-якої важливої сторони патологічного процесу.

Пневмонією називають запалення легеневої тканини зазвичай інфекційного походження з переважним ураженням альвеол. Термін «пневмонія» поєднує велику групу хвороб, кожна з яких має свою етіологію, патогенез, клінічну картину, рентгенологічні ознаки, характерні дані лабораторних досліджень та особливості терапії. У загальному випадку пневмонія може бути:

- мікробною, що викликана мікробом, бактерією, вірусами, найпростішими;
- токсичною, викликана дією токсина;
- алергічною, яка виникає внаслідок алергічного процесу;
- аутоімунною, як аутоімунна реакція на подразник;
- опіковою,
- з променевою етіологією [191].

Основними методами діагностики є рентгенологічне дослідження легень та дослідження мокротиння, основним методом лікування є антибактеріальна терапія. Пізня діагностика та затримка з початком антибактеріальної терапії погіршують прогноз захворювання. У деяких випадках можливий летальний результат. За рік діагноз пневмонія ставиться понад 17 млн. осіб,

при цьому чоловіки хворіють на 30% частіше, ніж жінки. До особливих груп ризику слід віднести дітей до 5 років і людей похилого віку старше 65 років [245].

Пневмонія є причиною смертності 15% дітей віком до 5 років у всьому світі [274]. Від пневмонії помирає кожен 64-й хворий на цю небезпечну хворобу. Це захворювання дає небезпечні ускладнення різним органам хворої людини, тобто пацієнти з гіпертонією, діабетом та ішемічною хворобою серця схильні до ризику збільшення несприятливих результатів. Захворюваність на пневмонію залежить від багатьох факторів: рівня життя, соціального та сімейного стану, умов праці, контакту з тваринами, подорожей, наявності шкідливих звичок, контакту з хворими людьми, індивідуальних особливостей людини, географічної поширеності того чи іншого збудника.

Пневмонія залишається однією з найчастіших причин смерті дітей та людей похилого віку в наш час. Різко збільшується частота пневмоній у хворих у той час, поки вони лікуються в госпітальних установах з приводу іншого супутнього захворювання [245]. Діагностичні методи дослідження поділяються на основні (рентгенографія грудної клітки, мікроскопічне дослідження мокротиння з забарвленням за Грамом, посів мокротиння на живильні середовища, загальний та біохімічний аналіз крові, дослідження складу крові) та додаткові (комп'ютерна томографія грудної клітки, парацентез плевральної порожнини та біопсія плеври, бронхоскопія з біопсією, посів крові на живильні середовища, виявлення специфічних антитіл, біопсія легені та аналіз сечі) [245].

На підставі вивчення розвитку захворювань легень у пацієнтів було виявлено такі предиктори пневмонії:

- a) наявність алергії,
- b) серцева ішемія,
- c) стать,
- d) куріння,
- e) бронхіт,
- f) шкідливі умови праці,

g) вік.

На можливість розвитку пневмонії вказувала наявність у пацієнта деяких явних симптомів:

- a. тяжке дихання,
- b. прискорений пульс,
- c. аномалії на рентгенограмі,
- d. відхилення електро-кардіограмі (ЕКГ),
- e. набряк кінцівок,
- f. сухі хрипи.

Важливу роль в остаточній діагностиці пневмонії грають результати клінічних досліджень крові пацієнта на:

- еритроцити,
- гемоглобін,
- еозинофіли,
- моноцити,
- швидкість осідання еритроцитів (ШОЕ).

Наша робота буде складатись з двох етапів. На першому етапі даного дослідження нам необхідно:

- (1) – розробити структуру статичної байєсівської мережі для діагностування ознак пневмонії;
- (2) – провести навчання параметрам та валідацію байєсівської моделі для перевірки взаємодії функціональних блоків;
- (3) – провести сценарний аналіз клінічних випадків з метою прогнозування стану кожного пацієнта окремо;
- (4) – проаналізувати сферу застосування діагностичної системи.

Вирішення проблеми встановлення діагнозу можливе на основі експертних оцінок за наявності статистичних даних. Наше завдання – допомогти в обробці даних, сформувані об'єктивні альтернативи та вибрати найкращу альтернативу за допомогою статичних байєсівських мережевих моделей. Отримана система Байєса має гнучку структуру, яка передбачає введення нових вузлів для генерації ймовірного виведення.

Математична модель, яка при обстеженні пацієнта полегшить швидшу діагностику і, таким чином, допоможе заздалегідь обрати правильний метод лікування, потребує наявності початкових

даних, отриманих від пацієнта, які нажаль, чітко не визначені. Байєсовські мережеві методи з певною часткою ймовірності дозволяють досягти поставленої мети, оскільки працюють із розпливчастою та нечіткою інформацією. Цей математичний апарат дозволяє формально описувати нечіткі поняття, які використовує пацієнт, відповідаючи на питання лікаря.

Спостереження за хворими з попереднім діагнозом можливості пневмонії включало [245]:

- взяття клінічних аналізів на початку захворювання та через 7-10 днів від початку захворювання;
- спостереження за зміною симптомів пацієнта, включаючи скарги, з якими він звернувся, і симптоми, визначені лікарем;
- збір даних з історії хвороби пацієнта;
- взяття біохімічного аналізу крові;
- збір даних про умови життя та праці.

У дослідженні взяли участь 136 осіб різного віку, різного анамнезу та різного ступеня тяжкості захворювання. Ми відібрали вибірку даних для 16 клінічних випадків і розібрали кожен з них. Усім хворим проведено необхідні обстеження, кожному з них проведено опитування для встановлення анамнезу. При необхідності деяким пацієнтам коригували медикаментозне лікування відповідно до прийнятих стандартів.

Метою моделювання є з певним ступенем вірогідності підтвердити або спростувати прогноз діагнозу «пневмонія» у пацієнтів досліджуваної групи. Таблиця 4.4 містить опис вибраних параметрів, а індикатори, які є ключовими, виділені жирним шрифтом.

Байєсовська мережа може бути використана для визначення ймовірності того, що пацієнт хворий, за наявності або відсутності ряду симптомів на основі даних про зв'язок між симптомами та захворюваннями.

Маючи набір відомих даних X , таких як сухий кашель, наприклад, визначити невідомий параметр Y (діагноз). Одночасно ми проводимо аналіз чутливості моделі та повторну валідацію. Концептуальна модель експертної системи діагностування

пневмонії представлена на рисунку 4.8. Усі показники поділяються на 5 ключових блоків, які мають по два стани s_0 і s_1 :

- 1 блок (вузол X_1) – це скарги, з якими звернувся пацієнт;
- 2 блок (вузол X_2) – це анамнез хвороби пацієнта;
- 3 блок (вузол X_3) – це симптоматика, виявлена лікарем;
- 4 блок (вузол X_4) – це клінічний аналіз крові пацієнта;
- 5 блок (вузол X_5) – це біохімічний аналіз крові пацієнта.

Набір вихідних даних, а також детальний опис станів, які можуть приймати всі вузли, наведено в таблиці 4.4.

Ми змоделювали байєсівську модель мережі в програмному середовищі GeNIe 2.3 Academic version. Байєсовська модель будується вручну без використання будь-якого структурованого алгоритму навчання. У цьому програмному середовищі структурна модель статичної мережі виглядає так, як показано на малюнку 4.9.

Запропонована байєсовська мережа не обмежується односпрямованою дією і може використовуватися як для виявлення причинних ознак, так і для прогнозування наслідків. Проводиться аналіз інформаційних потоків (повідомлень), які проходять між вузлами мережі.

Стрілки вказують на потік інформації між вибраними блоками. Усі індикатори X пов'язані з результуючим вузлом Y , між індикаторами X існує зв'язок, проектуємо необхідні вузли:

- з ймовірностями 0,5 в кожному стані для вузлів з двома станами;
- з ймовірностями 0,33 в кожному стані для вузлів з трьома станами.




Рис.4.8 Концептуальна модель експертної системи діагностування пневмонії [267].

Таблиця 4.4.

Набір вихідних даних з описом станів [267].

No	Вузол	Назва	Опис стану
1.	X1	Скарги, з якими звернувся пацієнт	стан s0 означає відсутність скарг у пацієнта; стан s1 означає наявність скарг у пацієнта.
2.	X11	Загальна слабкість	стан s0 означає відсутність загальної слабкості у пацієнта; стан s1 означає наявність загальної слабкості у пацієнта.
3.	X12	Мокротиння	стан s0 означає відсутність мокротиння у пацієнта; стан s1 означає наявність мокротиння у пацієнта.
4.	X13	Задихка	стан s0 означає відсутність задихки у пацієнта; стан s1 означає наявність задихки у пацієнта.
5.	X14	Кашель	стан s0 означає відсутність кашлю у пацієнта; стан s1 означає наявність кашлю у пацієнта.
6.	X15	Підвищення температури тіла	стан s0 означає відсутність підвищення температури тіла у пацієнта; стан s1 означає наявність підвищення температури тіла у пацієнта.
7.	X2	Анамнез пацієнта	стан s0 означає відсутність відомостей з анамнезу, що підтверджують схильність до розвитку пневмонії у пацієнта; стан s1 означає наявність відомостей з анамнезу, що підтверджують схильність до розвитку пневмонії у пацієнта.
8.	X21	Наявність алергії	стан s0 означає відсутність алергії у пацієнта; стан s1 означає наявність алергії у пацієнта.

No	Вузел	Назва	Опис стану
9.	X22	Ішемічна хвороба серця	стан s0 означає відсутність ішемічної хвороби серця у пацієнта; стан s1 означає наявність ішемічної хвороби серця у пацієнта.
10.	X23	Стать	стан s0 означає жіночу стать пацієнта; стан s1 означає чоловічу стать пацієнта.
11.	X24	Куріння	стан s0 означає відсутність звички куріння у пацієнта; стан s1 означає наявність звички куріння у пацієнта.
12.	X25	Часті бронхіти	стан s0 означає відсутність кашлю у пацієнта; стан s1 означає наявність кашлю у пацієнта.
13.	X26	Шкідливі умови праці	стан s0 означає відсутність кашлю у пацієнта; стан s1 означає наявність кашлю у пацієнта.
14.	X27	Вік	s0 – відповідає віку до 35 років; s1 - відповідає середній віковій групі від 36 до 55 років; s2 - відповідає літній віковій категорії від 56 і вище.
15.	X3	Симптоматика, виявлена лікарем	стан s0 означає відсутність симптомів, що вказують на пневмонію в клінічній картині пацієнта; стан s1 означає наявність симптомів, що вказують на пневмонію, в клінічній картині пацієнта.
16.	X31	Жорстке дихання	стан s0 означає відсутність жорсткого дихання у пацієнта; стан s1 означає наявність жорсткого дихання у пацієнта.
17.	X32	Прискорений пульс	s0 – відповідає пульсу до 70 ударів в хвилину; s1 – відповідає пульсу від 71 до 90 ударів в хвилину; s2 - – відповідає пульсу від 91 удару в хвилину і вище.

No	Вузел	Назва	Опис стану
18.	X33	Відхилення в рентгенограмі	стан s0 означає відсутність відхилень на рентгенограмі у пацієнта; стан s1 означає наявність відхилень на рентгенограмі у пацієнта.
19	X34	Відхилення ЕКГ	стан s0 означає відсутність відхилень ЕКГ у пацієнта; стан s1 означає наявність відхилень ЕКГ у пацієнта.
20.	X35	Набряк кінцівок	стан s0 означає відсутність набряку кінцівок у пацієнта; стан s1 означає наявність набряку кінцівок у пацієнта.
21.	X36	Сухі хрипи	стан s0 означає відсутність сухих хрипів у пацієнта; стан s1 означає наявність сухих хрипів у пацієнта.
22.	X4	Клінічний аналіз крові	стан s0 означає відсутність відхилень від норми в аналізі крові пацієнта; стан s1 означає наявність відхилень від норми в аналізі крові пацієнта.
23.	X41	Еритроцити	s0 – вміст еритроцитів у крові до 3,6; s1 - вміст еритроцитів у крові від 3,65 до 4,6; s2 - вміст еритроцитів у крові від 4,65 и вище.
24.	X42	Гемоглобін	s0 – рівень гемоглобіну не перевищує 100; s1 - рівень гемоглобіну від 101 до 120 ; s2 - рівень гемоглобіну 121 і вище.
25.	X43	Еозинофіли	s0 – вміст лейкоцитів у крові до 6; s1 - вміст лейкоцитів у крові від 6,1 до 9; s2 - вміст лейкоцитів у крові від 9,1 і вище.

No	Вузол	Назва	Опис стану
26.	X45	Швидкість осідання еритроцитів ШОЕ	s0 – рівень ШОЕ до 10; s1 - рівень ШОЕ від 11 до 17 ; s2 - рівень ШОЕ 18 і вище.
27.	X5	Біохімічний аналіз крові	стан s0 означає відсутність відхилень від норми в аналізі крові пацієнта; стан s1 означає наявність відхилень від норми в аналізі крові пацієнта.
28.	X51	Білірубін	s0 – рівень білірубину в крові до 10; s1 - рівень білірубину в крові від 11 до 15; s2 - рівень білірубину в крові від 16 і вище.
29.	X54	Рівень глюкози	s0 – рівень глюкози у крові до 4,5; s1 - рівень глюкози у крові від 4,6 до 5,6; s2 - рівень глюкози у крові від 5,7 і вище.
30.	X55	Рівень білку	стан s0 означає відсутність жорсткого дихання у пацієнта; стан s1 означає наявність жорсткого дихання у пацієнта.
31.	Y	Пневмонія наявність/відсутність	стан s0 означає ймовірність відсутності діагнозу «пневмонія» у пацієнта; стан s1 означає ймовірність підтвердження діагнозу «пневмонія» у пацієнта.

Далі проводимо дискретизацію вихідних значень змінних за допомогою меню Data-Discretize спочатку по X_1 , потім по X_2 і так далі. Генеруємо файл даних на 100 рядків і будуємо структурну схему згідно концептуальної моделі, яка показана на рисунку 4.9.




Рис. 4.9. Структурна схема байєсівської мережі діагностування пневмонії [267].

Наступним кроком проводимо навчання параметрам і первинну валідацію. Далі відзначимо, що в силу специфіки байєсівських мереж усі висновки цієї моделі щодо шуканої інформації мають ймовірнісний характер і представлені у вигляді ранжованого списку (за значенням вірогідності достовірності конкретного висновку). Остаточне рішення про підтвердження взаємозв'язку між вихідними даними і результатами діагностики, а також про призначення лікування приймає лікар.

Щоб підготувати байєсівську мережу до процедури аналізу чутливості, ми перетворимо тип результуючого вузла Y із загального в службовий – змінимо General на Utility (рис. 4.10 а). Ми проводимо аналіз чутливості з метою виявити нечутливі вузли та нечутливі зв'язки між вузлами, а потім видалити їх із мережі. Це

економить обчислювальну потужність, а також час, що витрачається на обчислювальний алгоритм. Формула Байєса використовується в байєсівських мережах як засіб висновку для пошуку рішення. Якщо для розпізнавання (ідентифікації) об'єктів використовується байєсова мережа, то багато факторів замінюються факторами або характеристиками конкретного об'єкта.


Окремий вибір набору екземплярів змінних має свої переваги та недоліки. Перевагою цього представлення є те, що воно запобігає циклу при формуванні виводу. Якщо вихід не вибрано окремо, існує ризик того, що повідомлення впливатимуть одне на одного, і мережа стане нестабільною.

Недоліком цього представлення є збільшення витрат на обчислення. Однак переваги настільки великі, що виділення екземплярів змінних цілком виправдано. Остаточне рішення щодо підтвердження взаємозв'язку між даними забруднення та результатами аналізів, а також призначення лікування приймає лікар.

Під час аналізу чутливості ми видаляємо вузли X21, X25, X36, X44 разом з підключеннями, оскільки вони ні на що не впливають і не є чутливими.

Рисунок 4.10 а) показує байєсівську мережу під час аналізу чутливості (червоні кола вказують на видалені вузли), а рисунок 4.10 б) показує результуючу байєсовську мережу після видалення нечутливих вузлів і посилення. Проведемо повторне навчання параметрам і повторну валідацію. Отримана байєсівська мережа представлена на рис.4.10 б).

Статична байєсовська мережева модель, орієнтована на вирішення проблем раннього виявлення пневмонії в окремого пацієнта, представлена на малюнках 4.11-4.14. Давайте тепер проаналізуємо кожен конкретний клінічний випадок. Результати аналізу наведені в табл.4.5. Розглянемо клінічні випадки 7, 8 і 16. Як видно з таблиці 4.5, ймовірність того, що у пацієнта буде діагностована пневмонія, становить 83%, тобто до нього може бути застосована стандартна схема медикаментозного лікування для оздоровлення та подальшої реабілітації (рис.4.11).



Таблиця 4.5.
Результати аналізу клінічних спостережень за симптомами пацієнтів і лабораторних досліджень [267].

Показники		Клінічні випадки															
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Скарги пред'явлені пацієнтом	X1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	X11	1	1	0	1	0	1	1	1	1	1	1	1	0	1	1	1
	X12	1	1	0	0	0	0	0	0	0	0	1	1	0	1	0	1
	X13	0	0	1	0	0	0	0	1	0	0	0	1	0	0	0	1
	X14	1	0	0	1	1	1	1	1	1	0	1	1	1	1	0	1
Анамнез пацієнта	X15	1	1	1	0	0	1	1	1	1	1	1	0	1	0	1	1
	X2	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	X22	0	0	1	1	1	1	0	0	0	0	0	0	0	1	0	0
	X23	1	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0
	X24	1	0	0	1	0	1	1	1	1	1	1	1	1	1	1	0
Симптоми, визначені лікарем	X26	0	0	1	1	0	0	1	0	1	1	0	0	0	0	0	0
	X27	79	76	72	54	81	55	54	56	52	53	55	40	74	71	77	46
	X3	1	0	1	0	1	1	1	1	1	1	0	0	1	0	1	1
	X31	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0	0
	X32	92	85	150	90	102	90	90	90	90	90	92	88	90	92	90	88
Клінічний аналіз крові	X33	1	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0
	X34	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
	X35	0	0	1	0	1	0	0	0	0	0	0	0	1	0	0	1
	X4	1	1	1	1	1	0	1	1	1	0	1	1	0	0	0	0
	X41	4.4	4.3	4	4.6	4	4.5	3.7	4.3	4.3	4.7	4.8		4.23	4.37	4.2	4.7
Біохімічний аналіз крові	X42	142	134	121	141	155	158	107	130	137	171	151	5	127	136	126	148
	X43	11.6	7.5	5	6.5	8.8	5.9	6	9.5	4.8	5.7	14.5	160	5.2	10	6.1	7.3
	X45	4	3	3	3	6	8	4	2	3	4	10	8.9	3	2	5	3
	X46	11	21	28	19	9	4	16	14	17	4	9	8	8	7	9	3
	X5	1	0	1	1	1	1	0	0	1	0	1	11	0	0	1	0
Y, ймовірність пневмонії, %	X51	16	12	11	10.4	12	13.7	13		11.7	11.6	11.6	0	12.4		17.6	
	X52	28	33	61	44	39	39	29		44							
	X53	26	29	39	27	19	38	29		27							
	X54		4.3	5.5	4.3	5.8	7	9.3	4.2	3.7	4.4		5.4	4.8	5.7		4.2
	X55	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
Y, ймовірність пневмонії, %		64	50	64	25	64	31	17	17	64	83	25	25	83	87	31	83
		36	50	36	75	36	69	83	83	36	17	75	75	17	13	69	17





Рис. 4.11. Результати симуляції клінічних випадків 7, 8 та 16 [267].

Якщо поглянути на табл. 4.5, то в клінічних випадках 4, 11 і 12 з імовірністю 75% хворі мають запалення легень (пневмонію), тобто до них також може бути застосована стандартна схема медикаментозного лікування даного захворювання (рис. 4.12).





Рис. 4.12. Результати симуляції клінічних випадків 4, 11 та 12 [267].

Розглянемо клінічний випадок 2. Як видно з таблиці 4.5, у пацієнта неоднозначний результат. Цей результат вимагає додаткових аналізів і обстежень, так як зазвичай в такій ситуації лікар додатково уточнює клінічну картину (рис. 4.13).




Рис.4.13. Результати симуляції клінічного випадку 2 [267].

Як видно з таблиці 4.5, у 3 випадках із 16 пневмонію підтверджено з ймовірністю 83% (це 19% від загальної кількості клінічних випадків у розглянутому наборі), у 3 випадках з 16 підтверджено з ймовірністю 75% (це 19% від загальної кількості клінічних випадків). В 2 випадках з 16 діагноз «пневмонія» також підтвердився, але з ймовірністю 69% (це 13% від кількості загальних клінічних випадків у розглядуваному наборі). В єдиному випадку з клінічною картиною пацієнта № 2 ймовірність наявності/відсутності пневмонії становить від 50% до 50% (тобто 6% від загальної кількості клінічних випадків у розглянутому наборі). Такий результат вимагає додаткових аналізів і досліджень, так як зазвичай в такій ситуації лікар додатково уточнює клінічну картину. У всіх інших випадках мова йде скоріше про відсутність захворювання, ніж про наявність. Це означає, що в 3 випадках з 16 відсутність пневмонії у пацієнта підтверджено на 64%, ще в 3 з 16 випадків відсутність пневмонії у пацієнта підтверджена на 83%, причому в 1 випадку з 16 відсутність пневмонії у пацієнта не викликає сумніву на 87% (рис.4.14).




Рис.4.14 Результати аналізу клінічних спостережень за симптомами пацієнтів [267].

Тепер поведемо наше дослідження по іншому шляху. Ми розпочинаємо ЕТАП 2, де розглядатимемо різні види пневмонії як хронічну обструктивну хворобу легень. Основним завданням медичної діагностики є визначення можливих діагнозів на основі даних обстеження. Основні труднощі, з якими стикаються лікарі на етапі діагностики:

- кількість наявних захворювань перевищує кількість способів їх діагностики, що підвищує ризик помилкового діагнозу;
- неоднозначність діагнозу, тобто наявність супутніх захворювань, які сильно спотворюють картину симптомів;
- велика кількість показників, що також призводить до спотворення даних;
- відсутність індивідуального підходу до кожного пацієнта [253].

Особливістю медичної діагностики є те, що кваліфікований лікар для певної групи пацієнтів може чітко діагностувати будь-яке захворювання, але у кожного з пацієнтів може бути не одне захворювання, а декілька одночасно. Тобто у пацієнта може бути

декілька діагнозів (до кожного діагнозу лікар може призначити суб'єктивний рівень приналежності).

Також можуть бути ситуації, коли лікар не може діагностувати хворобу пацієнта через брак досвіду або через нетипові чи спотворені симптоми пацієнта. З точки зору обчислювального інтелекту ця ситуація є предметом активного навчання [128], коли діагностична система в процесі свого навчання обробляє як різноманітні спостереження, які точно знають значення навчального сигналу (еталонного сигналу), так і апріорі некласифіковані спостереження (режим самонавчання). Хронічна обструктивна хвороба легень сьогодні є причиною смертності дітей і людей похилого віку.

Моделювання та диференційна діагностика з урахуванням наявності кількох супутніх захворювань досить складні, оскільки характеризуються складною структурою залежностей. Обчислювальні проблеми також очевидні, оскільки аналіз великої бази даних вимагає тривалого часу обробки і може бути виконаний лише за наявності відповідної обчислювальної інфраструктури. Коли ресурси обмежені, а дослідження в основному базуються на відкритих даних, виникає потреба в моделях, які можна модифікувати залежно від мінливості функцій, і таким чином можна використовувати досвід для покращення передбачуваності моделі. Байєсівські мережі є найбільш придатними обчислювальними інструментами для цього.

Дослідження присвячене створенню системи, що дозволяє досягти ефективності медикаментозної терапії за наявності у пацієнта основного діагнозу та кількох супутніх діагнозів, що обтяжують перебіг захворювання. Завданням даної роботи є розробка методики побудови БМ при диференціальній діагностиці хронічного обструктивного захворювання легень.

Основний внесок полягає в наступному:

- (i) реалізація комплексної причинно-імовірнісної моделі для диференціальної діагностики трьох типів легеневих захворювань,
- (ii) розробка спеціальної методології для планування розробки байєсівських мереж для проблем диференціальної діагностики,

(iii) застосування кластерного аналізу за допомогою алгоритму MeanShift виявлення специфічних ознак, симптомів, лабораторних та інструментальних даних, характерних для досліджуваних форм захворювання,

(iv) використання алгоритмів оцінки інформаційної ентропії, що дозволило оцінити інформативність ознак щодо відповідного класу захворювання.

Таким чином, основна проблема пов'язана з підвищенням якості диференціальної діагностики в системах підтримки медичних рішень. Ключовою проблемою є підвищення якості диференціальної діагностики шляхом комплексного використання методів відбору найбільш інформативних ознак.

Другий етап дослідження буде проходити відповідно до схеми, представленої на рисунку 4.15.




Рис. 4.15. Етапи побудови експертної системи діагностування пневмонії за наявності супутніх захворювань [184].

Ми знаємо, що попередня обробка даних є вкрай важливим етапом, від якості виконання якого залежить можливість отримання якісних результатів всього процесу аналізу даних. В даний час використовується багато різних нечітких підходів до кластеризації даних [11, 12, 183]. Вони здатні ефективно кластеризувати дані в ситуаціях, коли кластери перекриваються,

припускаючи, що розмір кластера невеликий, тобто не містить аномальних викидів. Реальні набори медико-біологічних даних містять до 20% викидів. Дані цих показників дозволяють сформувати кластери, що дозволяють оцінити динаміку показників, спростити і прискорити процес діагностування. Існуючі методи оцінки біологічних умов базуються на аналізі масивів значень вимірюваних параметрів, заданих у векторній формі. Це можуть бути імунологічні, біохімічні, фізіологічні, цитогенетичні, цитоморфологічні та інші медико-біологічні дані.

Аналіз даних вимірювань індивідуального стану окремого організму полягає у визначенні приналежності цього стану до будь-якого із заздалегідь відомих станів (діагнозів). Кожен фахівець з певних видів захворювань ставить «свій» діагноз. Це пов'язано з об'єктивними причинами, пов'язаними з перекриттям і збігом різної кількості показників стану організму при різних діагнозах, і широким поширенням так званих полісиндромних станів.

Прийняття правильних та ефективних рішень у таких ситуаціях вимагає значних витрат часу та коштів на організацію консультацій висококваліфікованих спеціалістів. Найбільш жорсткими з точки зору процедур нечіткої кластеризації є так звані алгоритми нечіткої кластеризації, засновані на цільових функціях [12, 179, 180]. Вони здійснюють автоматичну класифікацію без вчителя за оптимізацією заздалегідь визначених критеріїв якості. У результаті цієї процедури утворені кластери мають форму гіперсфер, що суттєво обмежує можливість використання вищевказаних методів для обробки даних більш складної форми.

Існуючі методи оцінки біологічних умов базуються на аналізі масивів значень вимірюваних параметрів, заданих у векторній формі. Це можуть бути імунологічні, біохімічні, фізіологічні, цитогенетичні, цитоморфологічні та інші медико-біологічні дані. Оптимізація ознакового простору або пошук значущих ознак (англ. Feature Selection) для реалізованої задачі полягає у виборі найбільш інформативних, корисних ознак та виключення з розгляду неінформативних ознак без трансформації вихідного простору даних [226, 227].

У нашому дослідженні використовувався алгоритм ID3 (англ. Iterative Dichotomizer, ітеративний діхотомайзер), запропонований Д. Куінланом, який визначає черговість змінної та її атрибутів через їх інформаційну значущість (інформаційну ентропію) [182, 214]. Для цього слід знайти ентропію всіх невикористаних ознак та їх атрибутів щодо тестових примірників і вибрати той, для якого ентропія мінімальна, а інформативність навпаки є максимальною.

Ентропію при умові нерівноправних подій P_i знаходимо за відомою формулою Шеннона:

$$I = -\sum_i p_i \log_2 p_i, \quad (4.1)$$

де I – кількість інформації в битах, яку можна передати, використовуючи m елементів в повідомленні при n літер в аберці, причому $p_i = m/n$.

Алгоритм кластеризації MeanShift - це непараметрична техніка аналізу простору ознак для визначення місця розташування максимальної щільності ймовірності, так званий алгоритм пошуку моди [55, 182]. Алгоритм середнього здвигу в основному призначає точки даних кластерам ітеративно, точка, що зміщується, в напрямку найвищої щільності точок даних, то є центроїд кластера. Для непараметричної оцінки щільності розподілу даних однієї з найбільш широко використовуваних є оцінка Розениблатта-Парзена. Щільність оцінюється як сумарний вплив елементів виборки, при цьому вклад кожного елемента описується колоколоподібною функцією (ядром) $K(x)$, що залежить від відстані розташування до цього елемента. Формула для розрахунку оцінки щільності $f(x)$ з параметром згладжування (шириною пропускання) P у вільній точці x має вигляд:

$$\hat{f}(x) = \frac{1}{NP^d} \sum_{i=1}^N K\left(\frac{x - x_i}{P}\right). \quad (4.2)$$

У якості $K(x)$ можна використовувати класичне ядро Гаусса:

$$K_G\left(\frac{x - x_i}{P}\right) = \exp\left(-\frac{\|x - x_i\|^2}{2P^2}\right). \quad (4.3)$$

Однак на практиці, з метою скорочення обчислювальних витрат використовуються обмежені ядра, такі як, наприклад, ядро Епанечникова:

$$K_{Ep}\left(\frac{x-x_i}{P}\right)=\left(1-\frac{\|x-x_i\|}{P^2}\right) \cdot I\left(\|x-x_i\| \leq P^2\right), \quad (4.4)$$

де $I(x)$ - індикаторна функція.

У цьому підході кластери відповідають локальним максимумам функцій оцінки щільності (модам). А елементи даних групуються у кластери за допомогою процедури MeanShift [55], що сходяться по градієнту до відповідного локального максимуму. Ітеративна процедура починає свою роботу з точки x_0 , послідовно переміщується в точку здвигу $x_{k+1}=m(x_k)$ аж до збігів, де:

$$m(x)=\frac{\sum_{i=1}^N x_i \cdot K(x-x_i)}{\sum_{i=1}^N K(x-x_i)}. \quad (4.5)$$

Вектор $m(x)$ -х називається вектором «середнього здвигу» і його напрямок співпадає з направленням максимального зростання щільності в точці x .

Алгоритми кластеризації на основі процедури використання середнього підходу отримують якісні групи кластерів, однак основна проблема використання цього підходу є висока обчислювальна складність [55, 89]. Ми застосуємо методи Future selection, а також методи кластеризації за алгоритмом X-means/K-means для удосконалення рішення діагностичної задачі з отриманням більш точного результату.

У дослідженні взяли участь 137 пацієнтів різного віку, різного анамнезу та різного ступеня тяжкості захворювання. Набір даних описує результати клінічних досліджень пацієнтів, симптоми, показники попереднього обстеження та скарги, з якими пацієнт звернувся до лікаря. Усім пацієнтам встановлено попередній діагноз: хронічне обструктивне захворювання легень, у кожного хворого є ще два супутніх діагнози, які можуть ускладнити перебіг інфекції та лікування хворого. Наше першочергове завдання – виявити наявність супутніх діагнозів і спрогнозувати сценарії, за

яких ці діагнози можуть ускладнити перебіг захворювання або обтяжити проведену медикаментозну терапію. Загалом набір даних містить 104 параметри, які описують стан кожного з 137 пацієнтів.

У ситуаціях, коли медичні симптоми можуть включати аномальні виділення, перешкоди та інші артефакти, слід використовувати надійні онлайн-процедури, які дозволяють проводити послідовну самонавчальну діагностику за допомогою довільних кластерних діагностик. Ми провели попередню обробку даних за допомогою методів оптимізації Feature Selection і після кластеризації за алгоритмом MeanShift виявили ключові показники, які мають найбільший вплив (табл. 4.6). Серед них є відомі нам вхідні показники та невідомі показники, ймовірність появи яких нам необхідно визначити. Набір вихідних даних представлений у таблиці 4.6.

Таблиця 4.6.

Набір вхідних показників [184].

Позначення вузла	Опис	Схема взаємодії
x9	Задуха	
x18	Підвищення температури тіла	
x40	Шкідливі умови праці	
x47	Грудна клітка	
x50	Дихання ослаблене	
x51	Свистячі хрипи	
x52	Вологі хрипи	
x53	Сухі хрипи	
x57	Гучність хрипів	
x89	Вогнища інфекції	

Байєсівська модель була створена за допомогою програмного середовища GeNIe 2.4 Academic. Структурна статична байєсівська модель показана на рисунку 4.16 а)б). Байєсівська формула використовується в байєсівських мережах як засіб висновку для

пошуку рішення. Якщо для розпізнавання (ідентифікації) об'єктів використовується байєсова мережа, то багато факторів замінюються факторами або характеристиками конкретного об'єкта.

Окремий вибір набору екземплярів змінних має свої переваги та недоліки. Перевагою цього представлення є те, що воно запобігає циклу при формуванні виводу. Якщо вихід не вибрано окремо, існує ризик того, що повідомлення впливатимуть одне на одного, і мережа стане нестабільною.




Рис. 4.16. Структурна модель байєсівської мережі за алгоритмом PC: а) вид Icon б) вид Bar chart [184].

Мережа містить десять вузлів:

1. X9 відповідає задусі пацієнта. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність задухи від пацієнта,
- s1 означає, що у пацієнта задуха.

2. X18 відповідає підвищеній температурі тіла пацієнта. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність інформації про підвищення температури тіла пацієнта,
- s1 означає наявність інформації про підвищення температури тіла пацієнта.

3. X40 відповідає шкідливим умовам праці, в яких працює пацієнт. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність шкідливої роботи,
- s1 означає наявність шкідливої роботи.

4. X47 – форма грудної клітини пацієнта. Цей індикатор має два стани s0 і s1:

- s0 відноситься до бочкоподібної форми грудної клітки пацієнта;
- s1 стосується округлої грудної клітки пацієнта.

5. X50 – дихання пацієнта ослаблене/не ослаблене. Цей індикатор має два стани s0 і s1:

- s0 означає, що дихання пацієнта не ослаблене;
- s1 означає, що дихання пацієнта ослаблене.

6. X51 відповідає хрипам/відсутності хрипів у легенях пацієнта. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність хрипів у легенях пацієнта,
- s1 означає хрипи в легенях пацієнта.

7. X52 означає наявність/відсутність вологих хрипів у легенях пацієнта. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність вологих хрипів у легенях пацієнта,
- s1 означає наявність вологих хрипів у легенях пацієнта.

8. X53 означає наявність/відсутність сухих хрипів у легенях пацієнта. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність сухих хрипів у легенях пацієнта,
- s1 означає наявність сухих хрипів у легенях пацієнта.

9. X57 відповідає результатам обстеження гучності хрипів пацієнта. Цей індикатор має два стани s0 і s1:

- s0 означає низьку гучність хрипів;
- s1 означає хрипи високої гучності.

10. X89 відповідає інформації, чи є вогнища запалення. Цей індикатор має два стани s0 і s1:

- s0 означає відсутність вогнищ запалення;
- s1 означає, що є вогнища запалення.

Залежність між вхідними показниками ми продемонстрували стрілками. Також на малюнку видно до якої групи показників відноситься кожен із вхідних індикаторів і три результуючі діагнози: Y1, Y2, Y3. Перебудуємо схему за ознаками і покажемо взаємний вплив показників на рисунку 4.17.




Рис. 4.17 Байєсівська мережа діагностики пневмонії при наявності супутніх захворювань [184].

Проводимо навчання параметрам і первинну валідацію за всіма вузлами. Для проведення аналізу чутливості перетворюємо тип вузлів Y на $Utility$. Точність прогнозу діагнозу $Y1=56\%$, прогнозу діагнозу $Y2=57\%$ прогнозу діагнозу $Y3= 61\%$. Отримана точність показників моделі представлена на рисунку 4.18.




Рис. 4.18 Точність показників моделі.

Залежності між показниками у структурній схемі отриманої байєсівської мережі показані в таблиці 4.7. Недоліком цього представлення є збільшення витрат на обчислення. Однак переваги настільки великі, що виділення екземплярів змінних цілком виправдано. Остаточне рішення щодо підтвердження взаємозв'язку між даними забруднення та результатами аналізів, а також призначення лікування приймає лікар. Тепер з'ясуємо, як зміниться ймовірність настання діагнозу в порівнянні з початковим рівнем? Чи буде посилено вплив якоїсь ознаки (симптому) чи її вплив буде, навпаки, ослаблений? У таблиці 4.7 наведено результати моделювання кожного конкретного випадку за вибіркою даних.

Таблиця 4.7

Результати аналізу клінічних спостережень за симптомами пацієнтів та лабораторних досліджень [184].

Умова	Результат	Опис випадків, які представляють інтерес
Клінічний випадок 1 X9max	X50 знижується на 11% (с 54 до 43) X52 підвищується на 3% (с 47 до 50) X57 підвищується на 3% (с 46 до 49) Y1 знижується на 3% (с 44 до 41) Y3 знижується на 10% (с 61 до 51)	Коли задуха максимальна (100%), ймовірність того, що дихання буде прискореним, знизиться на 11%. При цьому ризик встановлення діагнозу Y3 знизиться на 10%
Клінічний випадок 2 X18max	Y2 знижується на 6% (с 43 до 37) Y3 підвищується на 4% (с 61 до 65)	При досягненні максимально високого підвищення рівня температури тіла ризик встановлення діагнозу Y2 знизиться на 6%, а діагнозу Y3 підвищиться на 4%.
Клінічний випадок 3	Y2 підвищується на 7% (с 43 до 50)	Якщо професійна діяльність пацієнта проходить за наявності

Умова	Результат	Опис випадків, які представляють інтерес
X40max	Y1 знижується на 5% (с 44 до 39) Y3 підвищується на 2% (с 61 до 63)	максимально шкідливих умов праці ризик встановлення діагнозу Y2 зростає на 7%, а Y1 – на 5% знизиться
Клінічний випадок 4 X50min	Y1 знижується на 5% (с 44 до 43) Y3 підвищується на 4% (с 61 до 64) X9 підвищується на 10% (с 45 до 64)	За наявності ослабленого дихання ризик виникнення задухи зростає на 10%.
Клінічний випадок 5 X52max	Y2 знижується на 3% (с 43 до 40) Y3 підвищується на 6% (с 61 до 67)	За наявності яскраво виражених вологих хрипів ризик настання діагнозу Y3 збільшується на 6%
Клінічний випадок 6 X53max	Y1 знижується на 6% (с 44 до 38) Y2 підвищується на 4% (с 43 до 47) Y3 знижується на 2% (с 61 до 59)	За наявності у пацієнта яскраво виражених сухих хрипів ризик встановлення діагнозу Y1 знизиться на 6%, при цьому ризик встановлення діагнозу Y2 збільшується на 4%.
Клінічний випадок 7 X57max	Y2 підвищується на 5% (с 43 до 48) Y3 підвищується на 3% (с 61 до 64)	При максимальній гучності хрипів ризик встановлення діагнозу Y2 зростає на 5%

Тепер проаналізуємо кожен клінічний випадок. Рисунок 4.19 ілюструє випадок 1 з таблиці 4.7: коли задуха максимальна (100%), ймовірність того, що дихання буде прискореним, знизиться на 11%. При цьому ризик встановлення діагнозу Y3 знизиться на 10% (рис.4.19).




Рис. 4.19. Клінічний випадок 1 [184].

Клінічний випадок 2: при досягненні максимально високого підвищення рівня температури тіла ризик встановлення діагнозу Y2 знизиться на 6%, а діагнозу Y3 підвищиться на 4% (рис.4.20).




Рис. 4.20 Клінічний випадок 2 [184].

Клінічний випадок 3: якщо професійна діяльність пацієнта проходить за наявності максимально шкідливих умов праці ризик встановлення діагнозу Y_2 зросте на 7%, а Y_1 – на 5% знизиться (рис.4.21).




Рис. 4.21. Клінічний випадок 3 [184].

Клінічний випадок 6: за наявності у пацієнта яскраво виражених сухих хрипів ризик встановлення діагнозу Y_1 знизиться на 6%, при цьому ризик встановлення діагнозу Y_2 збільшується на 4% (рис.4.22).




Рис.4.22. Клінічний випадок 6 [184].

Хронічна обструктивна хвороба легень дає небезпечні ускладнення з боку різних органів хворої людини, тобто у групі ризику підвищеного несприятливого результату знаходяться хворі на гіпертонічну хворобу, цукровий діабет, ішемічну хворобу серця. Схильність на хронічне обструктивне захворювання легень залежить від багатьох факторів: рівня життя, соціального та сімейного стану, умов праці, контакту з тваринами, подорожей, наявності шкідливих звичок, контакту з хворими, індивідуальних особливостей людини, географічної поширеності певного збудника. Отримана експертна система може бути застосована для імовірнісних оцінок діагнозу як робочого інструменту щоденної лікарської практики. У майбутньому можна застосувати запропоновану модель до діагностики інших захворювань.

Висновки по розділу 4

В цьому розділі ми розглянули поняття експертної системи і з'ясували, що це інтелектуальна система, призначена для вирішення слабо формалізованих задач на основі накопиченого в базі знань досвіду експертів в проблемній області. Експертні системи є різновидом систем підтримки прийняття рішень, вони призначені для відтворення досвіду, знань професіоналів високого рівня і застосування цих знань в процесі управління.

Ми побудували дві експертні системи на основі моделі статичної байєсівської мережі:

а) для вирішення задачі прогнозу ефективності медикаментозної терапії при такому захворюванні як нейропатологія;

б) для вирішення задачі прогнозу настання такого захворювання як пневмонія.

Враховуючи, що нейропатологія – це особлива форма захворювання, що характеризується високою смертністю та витратами на лікування. Беручи до уваги високу частоту діагностичних помилок при виявленні цього захворювання та поширену практику неадекватного застосування ліків, ми змоделювали систему, яка може з певним ступенем вірогідності передбачити наявність або відсутність передумов для встановлення діагнозу. Результати моделювання прогнозу ефективності медикаментозної терапії при нейропатології показали, що 56,25% пацієнтів піддаються стандартному лікуванню, 6,25% - мають спірний результат і в цьому випадку потребують додаткового обстеження, але 37,5% пацієнтів потребують альтернативних методів лікування нейропатології, таких як: генетика, електрофізіологія, а також хірургія нейропатології при можливості її проведення.

Хронічна обструктивна хвороба легень дає небезпечні ускладнення з боку різних органів хворої людини, тобто у групі ризику підвищеного несприятливого результату знаходяться хворі на гіпертонічну хворобу, цукровий діабет, ішемічну хворобу серця.

Отримана експертна система може бути застосована для імовірнісних оцінок діагнозу як робочого інструменту щоденної лікарської практики. У майбутньому можна застосувати запропоновану модель до діагностики інших захворювань.

Контрольні питання:

1. Що таке Експертна система? Історія появи Експертних систем.
2. Які характеристики Експертних систем ви знаєте? Що відрізняє ці системи від інших?
3. Наведіть класифікацію експертних систем.
4. Які переваги експертних систем, що побудовані за допомогою БМ?
5. Нарисуйте структуру медичної діагностичної експертної системи на основі мереж Байєса.
6. Опишіть медичну експертну систему у вигляді мережі Байєса.

РОЗДІЛ 5

ПРОЄКТУВАННЯ ДИНАМІЧНИХ МОДЕЛЕЙ НА ОСНОВІ БАЄЄСІВСЬКИХ МЕРЕЖ

5. 1. Поняття динамічних байєсівських мереж.

Поняття динамічної байєсівської мережі (ДБМ), вперше введено дослідниками Діном і Каназава [72] в 1988 році і є розширенням статичних байєсівських мереж [21] для моделювання динамічних систем, що змінюються в часі. ДБМ дозволяє ймовірнісній графічній моделі описувати рівень невизначеності з безліччю додатків, націлених на зниження складності обчислень та обґрунтування того чи іншого рішення в невизначених ситуаціях. Аналіз дуже складних явищ і прийняття рішень в умовах невизначеності, де, наприклад, змінні сильно взаємопов'язані та/або дані неоднозначні, також є перевагами використання ДБМ [1].

Динамічні байєсовські мережі є узагальненою моделлю в просторі станів. Назва «динамічні» вказує не на залежність структури від часу, а тільки на залежність від способу моделювання процесу.

Динамічна байєсівська мережа може бути представлена у вигляді кількох статичних байєсівських мереж, взятих у певній хронологічній послідовності. Час може розглядатися як дискретна чи неперервна характеристика аналізованих процесів. Часто в дослідженнях передбачається, що час носить дискретний характер, і в системі зв'язків між часовими зрізами виконується правило Марківських ланцюгів. Навчання динамічних байєсівських мереж функціонально поділяється на:

- навчання структури графа;
- навчання параметрів вершин.

Навчання параметрів спрямоване на отримання початкового розподілу ймовірностей між всіма вершинами першого часового зрізу мережі. Процедура навчання структури проводиться на основі статистичного аналізу навчальної вибірки, що містить множину значень, які приймаються вершинами (вузлами) мережі [22].

5.1.1. Довірчі мережі.

Для формального опису ДБМ пригадаємо баєсовські довірчі мережі. Довірчі мережі – це графічні моделі умовної незалежності в багатовимірних системах. Довірчі мережі складаються з направленого ациклічного графу (НАГ) та набору функцій умовних імовірностей. Нехай $X_1, \dots, X_n$ представляють вузли графа, і нехай $\pi(X_i)$ позначає набір предків змінної X_i на графі. Вузли графа представляють собою змінні довірчої мережі, а спрямовані дуги графа відображають явні залежності між змінними. Задамо для кожної змінної X_i зв'язану з нею функцію (таблицю) умовних імовірностей та позначимо її $Pr[X_i | \pi(X_i)]$. Повний спільний розподіл імовірностей задається виразом [72]:

$$Pr[X_1, \dots, X_n] = \prod_{i=1}^n Pr[X_i | \pi(X_i)]. \quad (5.1)$$

Ймовірністний висновок у довірчих мережах полягає в обчисленні ймовірності, тобто $Pr[X = x | E = e]$ для будь-якого набору вершин x із X та за умови наявності інформації (фактів) e з множини E . Ймовірністний вивід у великих багатозв'язаних довірчих мережах досить важкий. Аналіз складності показує, що і строгий, і наближений алгоритми представляють в найгіршому випадку нерозв'язну задачу. Проте, для багатьох задач процедури наближеного виводу дають корисну оцінку майбутніх імовірностей за прийнятний обчислювальний час.

Є декілька недоліків використання довірчих мереж при прогнозуванні:

- якщо вузол у момент часу t має множину вузлів-предків у моменти часу $t-1, t-2, \dots$, то потреби в пам'яті для таблиць умовної ймовірності можуть бути величезними;
- якщо дані представлені багатовимірним часовим рядом, то довірча мережева модель може бути складною, із множинними залежностями з запізненнями і, отже, ймовірністний вивід для формування прогнозів буде повільним або навіть нездійсненним;

- крім вимог до об'єму пам'яті й обчислювальної складності, для великих таблиць умовних імовірностей навчальна послідовність повинна бути дуже великою, щоб досягти стійкої оцінки максимальної правдоподібності умовних імовірностей.

Це типові проблеми моделей прогнозування з довірчими мережами. Програми, що реалізують моделі мереж довіри, також зіштовхуються з цими проблемами. Вказані обмеження спонукають до розробки моделей причинно-наслідкової незалежності та диз'юнктивних взаємозв'язків, що істотно знижують вимоги до пам'яті для збереження таблиць умовних імовірностей. Однак, ці моделі, не відносяться до проблем нездійсненого виводу.

5.1.2. Поняття сепарабельних моделей.

Формальний опис динамічних мереж Байєса.

Адитивні моделі мереж довіри, як і моделі причинно-наслідкової незалежності, успадковують властивість із більш загального класу *сепарабельних моделей*. В сепарабельних моделях ми можемо виразити спільний вплив набору причин $X_1, \dots, X_p$ на залежну змінну Y у термінах впливів кожної причини окремо. Ми вважаємо, що для кожної причини X_i існує "виключений" стан, тобто стан, у якому X_i не впливає на значення. Ми позначимо ці відмінні стани через S_i^* . Таким чином, умовні ймовірності $Pr[Y|X_i, X_{i \neq j} = x_j^*]$ для $i = 1, \dots, p$ представляють собою ізольовані впливи кожного X_i на Y . Загалом, в сепарабельних моделях ми виражаємо спільний вплив причин на залежні змінні в термінах впливів наборів причин X_i , $i = 1, \dots, p$, які розбивають набір $\{X_1, \dots, X_p\}$. Ми представляємо ізольований вплив кожного набору X_i на Y за допомогою умовної ймовірності $Pr[Y|X_i, X_{i \neq j} = x_j^*]$.

Позначимо через y^* "виключений" стан змінної Y . Адитивна модель мережі довіри – це сепарабельна модель, що задовольняє умові:

$$Pr[Y = y | X_1, \dots, X_p] = \begin{cases} \sum_{i=1}^k \varphi_i Pr[Y = y | X_i, X_{j \neq i} = x_j^*] & \text{коли } y \neq y^* \\ 1 - \sum_{y' \neq y^*} Pr[Y = y' | X_1, \dots, X_k] & \text{коли } y = y^* \end{cases} \quad (5.2)$$

Параметри $\varphi_i \geq 0$ для $i = 1, \dots, k$ повинні задовольняти $\sum_{i=1}^k \varphi_i Pr[Y | X_i, X_{j \neq i} = x_j^*] \leq 1$. Більш точні обмеження на параметри залежать від предметної області.

По аналогії з іншими сепарабельними моделями, для задавання умовної ймовірності $Pr[Y | X_1, \dots, X_p]$ адитивної довірчо-мережевої моделі нам необхідно визначити тільки умовні ймовірності k ізольованих впливів. Таким чином, для довірчих мереж із двійковими значеннями ми зменшуємо розмір таблиці умовних імовірностей з 2^{p+1} до $\sum_{i=1}^k 2^{|X_i|+1}$. На відміну від інших сепарабельних моделей, адитивна декомпозиція умовних імовірностей дозволяє підвищити ефективність алгоритмів виводу на основі мереж довіри.

Розкладання умовної ймовірності $Pr[Y = y | X_1, \dots, X_p]$ в адитивні терміни $Pr[Y = y | X_i, X_{i \neq j} = x_j^*]$ – це особливий випадок адитивних моделей.

Адитивні моделі зберігають властивості, що роблять привабливими моделі лінійної регресії – вони адитивні в передбачувальних впливах, не обмежені припущенням про лінійність передбачувальних впливів. Нехай $X_{t-i} = \{x_{1,t-i}, \dots, x_{m,t-i}\}$. Аддитивна модель визначається як:

$$E\{y_t | X_t, \dots, X_{t-k}\} = \sum_{i=0}^k f_i(X_{t-i}), \quad (5.3)$$

де f_i – довільна функція. У такий спосіб формула (5.3), що виражає властивості адитивних моделей, виводиться безпосередньо з формули (5.2):

$$E[Y | X_1, \dots, X_p] = \sum_{i=1}^k f_i(X_i), \quad \text{де} \quad f_i(X_i) = \phi_i E[Y | X_i, X_{i \neq j} = x_j^*].$$

Можна помітити, що прихована Марківська модель є спрощеною ДБМ без причинно-наслідкових зв'язків. У ДБМ стан системи в часі відображається набором випадкових величин $X^t = X_1^t \dots X_n^t$. Якщо стан системи залежить тільки від попереднього стану ($k=1$), то система називається Марківським розподілом (Марківські ланцюги) першого порядку з параметром переходу $P(X^t|X^{t-1})$ [72]:

$$P(X^t|X^{t-1}) = \prod_i P(X_i^t|P_a(X_i^t)), \quad (5.4)$$

Якщо простір станів неперервний, то така модель називається фільтром Кальмана, в дискретному випадку – динамічною БМ. Структура ДБМ залишається незмінною у всіх часових зрізах. Зрізом називають поточний стан ДБМ в дискретний момент часу. Вершина в мережі може мати батька тільки в своєму поточному часовому зрізі, або в часовому зрізі, що безпосередньо йому передував.

Важливе розмежування повинно проводитися між ланцюгами ДБМ і Маркова. ДБМ показує, як змінні впливають один на одного з часом, тоді як ланцюжок Маркова показує, як розвивається стан всієї системи з часом. Таким чином, ДБМ проілюструє ймовірність зміни однієї змінної в залежності від іншої, і як кожна з окремих змінних буде змінюватися з часом. Ланцюг Маркова розглядає стан системи, яка включає стан кожної окремої змінної, що становить систему, і показує ймовірності зміни станів системи з плином часу. Тому ланцюг Маркова включає всі змінні, присутні в системі, коли дивиться на те, як ця система розвивається з часом. Ланцюги Маркова можуть бути отримані з ДБН, але кожна мережа представляє різні значення і ймовірності.

Є кілька переваг у створенні ДБМ. Після того, як мережа встановлена між часовими кроками, на основі цих даних може бути розроблена модель. Ця модель може бути використана для прогнозування майбутніх відповідей системи. Здатність прогнозувати майбутні відповіді також може бути використана для вивчення різних альтернатив для системи та визначення того, яка

альтернатива дає бажані результати. ДБМ також забезпечують відповідне середовище для модельних прогнозних контролерів і можуть бути корисними при створенні контролера. Ще однією перевагою ДБМ є те, що їх можна використовувати для створення загальної мережі, яка не залежить від часу. Після того, як ДБМ було встановлено для різних кроків часу, мережу можна згорнути, щоб видалити компонент часу та показати загальні зв'язки між змінними.

ДБМ складається з взаємопов'язаних часових зрізів статичних байєсівських мереж. Вузли в певний час можуть впливати на вузли на майбутньому часовому відрізку, але вузли в подальшому не можуть впливати на вузли в попередньому часовому відрізку. Причинно-наслідкові зв'язки через часові зрізи називаються тимчасовими зв'язками, користь від цього полягає в тому, що вони дають ДБМ однозначний напрямок причинності.

Для зручності обчислень передбачається, що змінні в ДБМ мають кінцеве число станів, які може мати змінна. Виходячи з цього, можуть бути побудовані таблиці умовних ймовірностей для вираження ймовірностей кожного дочірнього вузла, похідного від умов його батьківських вузлів.

5. 2. Технологія побудови динамічної байєсової мережі.

Побудова моделі ДБМ, строго кажучи, не вимагає даних, оскільки модель може у крайньому випадку, коли дані недоступні, повністю ґрунтуватися на суб'єктивних оцінках ймовірностей. Коли дані доступні, вони можуть потенційно поліпшити модель. Побудова моделі ДБМ складається з двох етапів:

- (1) визначення структури моделі;
- (2) визначення числових параметрів вузлів.

Структура моделі зазвичай кодує причинно-наслідкові зв'язки між змінними, тоді як числові параметри кількісно визначають ці відносини. Якщо даних немає, для кількісної оцінки моделі можна використовувати думку експертів. Однак це непросте завдання,

особливо якщо модель вимагає виявлення тисяч ймовірностей. Як структура, так і числові параметри моделі ДБМ можуть бути отримані безпосередньо з даних за допомогою алгоритмів навчання [63, 241].

Для моделі ДБМ ми можемо обрати годину, добу, місяць, рік чи кілька років як можливий перехідний інтервал між двома зрізами, що дозволить охопити кілька часових кроків.

5.2.1. Обробка пропущених значень.

Розберемо технологію опрацювання пропусків у таблицях значень СРТ. Що стосується моделі ДБМ, є дві ситуації, які слід розглянути з огляду на можливу наявність пропущених значень:

- (1) навчання числовим параметрам;
- (2) міркування з моделлю.

В обох випадках ДБМ можуть обробляти відсутні дані природним чином. Вивчення числових параметрів моделі ДБМ на основі неповних даних полегшується алгоритмом максимізації математичного очікування [74], який розроблений для роботи з відсутніми спостереженнями.

Вихідні дані моделі ДБМ включають апостеріорний розподіл ймовірностей для змінної відгуку в часі з урахуванням спостережуваних коваріат (*тобто* змінних, що статистично взаємопов'язані зі змінною, яка оцінюється). Цей підхід гнучкіший при обчисленні результатів щодо різноманітних запитів, *тобто* змінну відгуку можна легко змінити, а ризик можна розрахувати для будь-якої змінної моделі, що розглядається. Крім того, байєсівські мережі дозволяють обчислювати діагностичне значення для кожної коваріати. У програмному середовищі GeNIe (BayesFusion LLC, Піттсбург, США), яке ми використовуємо при побудові ймовірнісних моделей, воно засноване на крос-ентропії між кожною із спостережуваних коваріат та змінної відгуку. Таким чином, ми також можемо кількісно оцінити вплив кожної коваріати на результуючу змінну. Підхід ДБМ дозволяє індивідуально керувати досліджуваними параметрами та

обчислювати індивідуальний для кожного з них ризик на основі спостережуваних коваріат. Розрахунок індивідуального ризику для нового параметру досить простий: вся доступна інформація про нього вводиться в модель і миттєво генерується оцінка ризику, виражена апостеріорною ймовірністю [247].

Важливо відзначити, що не вся інформація про параметр має враховуватися. Крім того, ми можемо розрахувати оцінку ризику для різних змінних, що моделюються. Наприклад, ми можемо обчислити апостеріорну ймовірність для будь-якої змінної моделі, а не тільки для результуючої змінної. Моделювання ДБМ дозволяє поглянути на оцінки ризиків із різних точок зору. Наприклад, ми можемо ідентифікувати групи показників, які мають більш високий або нижчий ризик, враховуючи набір наявних значень [133, 190].

5.2.2. Технологія побудови динамічної байєсової мережі в GeNIe.

З огляду на те, що GeNIe [158] є областю реалізації ДБМ, процедура розробки динамічної моделі дуже схожа на процедуру, заплановану для статичних БМ (рис.5.1).




Рис.5.1 Етапи проектування динамічної байєсової мережі.

Відповідно, ми починаємо зі статичних БМ, що містять змінні (вузли) і залежності (дуги). Визначаючи таблицю умовних ймовірностей (CPT) вузлів, ми потім кількісно оцінюємо якісні фактори, що розглядаються і мають найважливіший вплив на те, як відбувається скупчення. Далі відбувається процедура нормування: у кожному стовпці CPT значення ймовірності нормуються на потрапляння в діапазон. В результаті сума ймовірностей в кожному стовпці повинна відповідати одиниці. Щоб отримати вищезгадані розподіли ймовірностей, в літературі існує кілька методів. Наприклад, якщо точне знання даних не під рукою, їх можна визначити на основі пропозицій відповідних експертів. Інший класичний метод полягає в використанні баз даних інцидентів.

Наступним кроком перетворення мережі в ДБМ буде визначення які вузли будуть нормованими, які будуть якірними та термінальними вузлами. Нормовані вузли залишаються статичними, значення яких змінюються у часі. Якірні і термінальні вузли оснащені часовими дугами і знаходяться в термінальній області. Термінальні вузли є ключовими, а якірний вузол – результуючим. Далі відбувається оснащення БМ часовими пластами і часовими дугами. На рисунку 5.2 показаний приклад ДБМ, спроектованої в GeNIe. Представлена мережа має один якорний вузол, Z1, два часових вузли, X3 і Y і часову пластину, що складається з двох часових кроків. Прямі жирні стрілки означають статичні дуги, тоді як світлі стрілки з мітками на них показують часові дуги.

Часова дуга з тегом «1» показує залежність дочірнього вузла в часі t від статусу батьківського вузла в часі. Вузол X3 з показаною часовою дугою сам по собі демонструє той факт, що стан вузла X3 на попередньому часовому кроці впливає на його поточний статус.

Спільна функція щільності ймовірності послідовності часових кроків може бути досягнута шляхом «розгортання» мережі до тих пір, поки не будуть підрізані краї (рисунок 5.3). Таким чином, тренд флуктуацій ймовірності для кожного вузла у всіх часових кроках може бути детально проаналізований. В області ДБМ фактичне

спостереження за подією називається доказом. Надаючи такі докази і оновлюючи мережу, вся мережа і ймовірності вузлів будуть змінюватись на кожному часовому кроці [158].




Рис.5.2 Приклад динамічної байєсової мережі, спроектованої в GeNIe.




Рис.5.3 Приклад ДБМ, розгорнутої на три часових кроки.

5.2.3. Приєднання даних за період часу, введення доказів на часові вузли.

ДБМ базується на об'єднанні аналізу баєсових часових рядів з узагальненням імовірісно-мережевого представлення та методів логічного виводу [205]. ДБМ успадкувала виразність довірчих мереж та ідеально підходить для предметних областей із категорійними змінними. Графічна структура залежностей у ДБМ представляє прямі причинні взаємозв'язки між цими змінними. Таким чином, шляхом приведення аналізу баєсовських часових рядів до динамічних моделей у вигляді довірчих мереж можна отримати моделі з явними залежностями, що більш реалістично описують динамічні процеси [68].

Таким чином, збагачені моделі та супутні обчислювальні методи дозволяють нам вийти за жорсткі класичні припущення про лінійність зв'язків між змінними, та про нормальність їх імовірнісних розподілів без надмірного зростання складності прогнозування. Ймовірнісний розподіл змінних прогнозування об'єднує невизначеності в моделі, обумовлені зовнішніми впливами та неявними невизначеностями причинно-наслідкових механізмів. На відміну від точкових прогнозів, з імовірностями альтернативних виводів тепер можна розглядати ризики альтернативних рішень.

Дві останні проблеми не унікальні для динамічних предметних областей, і дослідниками вже розроблені моделі, що долають принаймні проблему великих факторних таблиць. Адитивні довірчо-мережеві моделі є одним із таких підходів, що переводить визначення великих факторних таблиць у визначення декількох маленьких таблиць. Ці моделі належать більш загальному класу адитивних моделей, що апроксимують багатовимірні функції за допомогою підсумовування одномірних функцій. Крім того, адитивні моделі довірчих мереж також переборюють труднощі ймовірнісного виводу і, таким чином, вони дають раціональну відправну точку для розробки представлення знань у динамічних предметних областях.

Адитивні моделі довірчих мереж складають основу ДБМ. Адитивне розкладання не тільки спрощує визначення моделі, але і дає метод для оновлення їхніх прогнозувань, заснованих на нових фактах. Імовірністний вивід у ДБМ генерує розподіли ймовірності прогнозованих значень змінних предметної області, за умови часових рядів поточних спостережень. Адитивна структура робить логічний вивід і, отже, прогнозування ефективним.

Створення динамічної моделі дозволяє працювати з невизначеною інформацією і пристосовуватися до змін у зовнішніх умовах. Наприклад, навіть спокійний пацієнт може бути збуджений за допомогою повторюваних втручань із наступним збільшенням серцевого ритму, кров'яного тиску та кисневого споживання.

Як ми вже раніше з'ясували, головним обмеженням динамічних байєсівських моделей є необхідність дискретизації. Якщо предметна область містить тільки категоріальні змінні, тоді ДБМ представляє стійку і виразну модель для прогнозування. Однак, наявність неперервних змінних вимагає дискретизації і, отже, призводить до можливих втрат точності або появи зміщення в прогнозах, дещо втрачання адекватності моделі.

5.2.4. Перевірка моделі та підвищення точності.

Валідація моделей ДБМ зазвичай виконується на основі методів перехресної перевірки, таких як k-кратна перевірка або її особливий випадок, метод «виключити по одному» [204]. Моделі ДБМ дозволяють включати в аналіз як категоріальні, так і неперервні змінні.

Підходи ДБМ дозволяють проводити багатовимірний аналіз, що моделює відносини між змінними. Моделювання ДБМ є гнучким і дозволяє моделювати відносини між будь-якими змінними, включеними в аналіз, тобто може моделювати не тільки відносини між коваріатами та змінною відповіді, тобто ДБМ має велику гнучкість з точки зору індивідуальної оцінки ризику, ніж класичні статистичні підходи. Наприклад, в медичній діагностиці

ДБМ дозволяють розглядати оцінки ризику з різних точок зору та виявляти групи пацієнтів, які зазнають більш високого ризику розвитку захворювання.

В байєсівському підході, такому як моделювання ДБМ, рішення приймається на основі апостеріорної ймовірності, що генерується моделлю. Оскільки результатом байєсовського аналізу є апостеріорний розподіл ймовірностей, індивідуалізований для пацієнта, нескладно розширити аналіз функцією корисності та підтримати діагностичне рішення стосовно пацієнта, використовуючи як поточний стан його здоров'я, так і анамнез захворювання, результати лабораторних тестів, результати спосотережень.

5. 3. Різновиди динамічних байєсівських моделей і галузі їх застосування

Галузі використання динамічних байєсівських моделей надзвичайно широкі. Опис успішного використання ДБМ для розпізнавання мовлення наведено в [18, 283], результати прогнозування стану пацієнтів у відділенні інтенсивної терапії описані в [43]. У [60] описано моделювання каскадних ефектів в енергосистемі за допомогою ДБМ. У роботі [50] наведено ДБМ для прогнозування та діагностики аварій в атомних реакторах. У роботі [65] наведено методику використання ДБМ у процесі прийняття рішень, з добовим моніторингом та прогнозуванням декомпенсації у пацієнтів із хронічною серцевою недостатністю. [54] представили методологію моделювання фізіологічних процесів у серцево-судинній системі, а також глюкозо-інсулінової регуляції. У [39, 61, 71, 134] розроблено методику використання ДБМ для прогнозування погоди. Підтримку прийняття рішень в залежності від динамічної зміни клімату запропоновано у [201]. Модель байєсівської мережі для аналізу часу евакуації під час пожежі на судні представлено у [234]

Перевагою використання БМ є їх стійкість до неповної, неточної, зашумленої інформації, оскільки навіть у цьому випадку

результат відображатиме найбільш ймовірний результат подій [6, 106, 124].

Динамічні байєсовські мережі також добре зарекомендували себе як вигідний метод побудови різних типів екологічних моделей. Вони використовуються в дослідженнях з підтримки прийняття рішень [15, 78, 105, 127, 155], інтегрованому моделюванні [31, 37, 40, 42, 194, 202, 224, 259], для аналізу невизначеності, в реалізації заходів управління [96, 97, 279], для компіляції та формалізації експертних [164], в екологічному моделюванні [4, 15, 88, 254, 258, 259], для оцінки ризику в галузі інженерних досліджень [271].

Особливе місце займають динамічні байєсовські мережі, що моделюють процеси взаємодії людини і машини [56, 249], прогнозують землетруси [3], оптимізують роботу служб і правоохоронних органів [185, 188], слугують для оцінки ризиків інвестування [186], слугують для точного розташування транспортних засобів і координації доріг [30, 329], моделюють планування роботи медичного персоналу [91, 110, 170, 257].

Стосовно застосування в медицині є цікавий факт, який полягає в тому, що в той час як статичні байєсівські мережі використовувалися як інструменти моделювання майже три десятиліття, їхнє часове розширення, динамічні байєсівські мережі, знайшли своє застосування в медичному моделюванні лише в останнє десятиліття. Одне з практичних застосувань таких мереж у медицині - це NasoNet, система діагностики та прогнозування раку носоглотки [91] та ДБМ для лікування пацієнтів, які страждають на карциноїдну пухлину [257].

ДБМ також використовувалися в геноміці та протеоміці [19, 51] при прогнозуванні вторинної структури білка, [276] моделюванні фрагментації пептидів [141] та клітинних систем, [86] або в ідентифікації мереж регулювання генів за даними мікрочіпів [46, 122, 282].

Інші приклади використання ДБМ включають реконструкцію функціональних нейронних мереж з ансамблів спайкових поїздів

[82] або моделювання динаміки органної недостатності у пацієнтів у відділеннях інтенсивної терапії [218].

5. 3. Динамічна байєсівська модель оцінки якості правоохоронного сервісу.

Формування системи оцінки якості роботи правоохоронних установ мають як статичний, так і динамічний характер. Соціально-економічні процеси, які контролюють правоохоронні органи, як і багато явищ, що відбуваються в суспільстві, мають динамічний характер.

Індикатором, який характеризує роботу правоохоронних установ, є кількість розкритих злочинів. Абсолютне значення цього індикатора є змістовною характеристикою, яка потребує врахування кількості потерпілих, кількості матеріальних збитків, кількості конфіскованих предметів злочинної діяльності та кількості розкритих злочинних груп і поодиноких злочинів.

Дані індикатори є змінними, які спостерігаються в послідовні моменти часу. Як формалізований цільовий показник, що характеризує ступінь задоволеності населення роботою органів поліції та прокуратури, було обрано показник якості правоохоронного сервісу, який також змінюватиметься на кожному часовому проміжку.

Дане аналізоване соціальне явище характеризується як поточними значеннями, так і результатами попередніх періодів. Щоб уявити і проаналізувати соціальні явища, які змінюються в часі, нам необхідно використовувати модель, яка враховує взаємозв'язок між значеннями всіх показників в різні моменти часу. Для розв'язку цього завдання використаємо динамічні байєсовські мережі.

Мета дослідження – розробити модель оцінки роботи правоохоронних установ на основі статистичних індикаторів розкриття злочинів з використанням динамічної байєсівської мережі.

Обираємо для дослідження з набору відомих статистичних даних, такі показники як: кількість потерпілих, кількість конфіскованих предметів злочинної діяльності, кількість розкритих злочинів, які були отримані на різних часових інтервалах. Необхідно спрогнозувати значення індикатора якості роботи правоохоронних органів на різних часових проміжках.

Побудова динамічної БМ відбувається на основі навченої вже верифікованої статичної БМ, з точністю після останньої валідації – 69,23%, яка була розроблена, протестована і відлагоджена нами в Розділі 3 (рисунок 5.4).

Під час розробки ДБМ використовуємо програмне середовище Genie 2.1, що надає платформу для аналізу ДБМ з використанням доказів та значень, що спостерігаються [90]. Як вихідні дані розглядатимемо такі показники:

- X1 – кількість потерпілих,
- X1.1 – кількість потерпілих, які вижили,
- X1.2 – кількість смертей,
- X2 – кількість матеріальних збитків,
- X2.1 – кількість відшкодованих матеріальних збитків,
- X2.2 – кількість не відшкодованих матеріальних збитків,
- X3 – кількість конфіскованих предметів злочинної діяльності,
- X3.1 – кількість поданих цивільних позовів,
- X4 – кількість зафіксованих злочинів,
- X4.1 – кількість розкритих злочинів силами національної поліції,
- X4.2 – кількість розкритих злочинів силами прокуратури (включаючи військову прокуратуру),
- X4.3 – кількість злочинів, розкритих органами безпеки та антикорупційним бюро відповідно.

Дані взяті за період із 2000 по 2019 рік. Ми беремо статичну байєсівську мережу, що складається з 11-ти вузлів (рисунок 5.4), яка була навчена із застосуванням алгоритму структурного навчання РС. Далі визначаємо нормовані, якірні та термінальні вузли. Після цього перебудовуємо мережу з урахуванням наявності часової області.




Рис. 5.4 а) Статична БМ оцінки якості правоохоронного сервісу;
б) проведення аналізу чутливості для статичної БМ оцінки якості правоохоронного сервісу [189].

Якщо вважати вузли X_{12} , X_{21} , X_{31} , X_{41} , X_{42} , X_{43} нормованими статичними, значення яких змінюються у часі, ми отримаємо схему перебудови статичної БМ у динамічну БМ, представлену на рисунку 5.5.




Рис.5.5 Процес перебудови статичної БМ у динамічну БМ [185].

Після додаванні часових дуг та оновлення мережі отримаємо динамічну БМ якості роботи правоохоронних органів із наявністю часових дуг, яка продемонстрована на рисунку 5.6.

Припустимо вузли X_{12} , X_{21} , X_{31} , X_{41} , X_{42} , X_{43} є якірними статичними, значення яких можна розглядати як початкові умови або передумови, які передували нашим тимчасовим подіям. Припустимо Y це результуючий вузол - наша кінцева мета, яку ми гарантовано досягнемо. У такому разі ми отримаємо (рисунок 5.9):




Рис.5.6 Динамічна БМ якості роботи правоохоронних органів із наявністю часових дуг [185].




Рис.5.9 Динамічна БМ якості роботи правоохоронних органів за зміни початкових умов [185].

Загальновідомо, що є періоди спаду злочинності та є періоди підйому, коли працівникам органів правопорядку необхідно бути готовими до збільшення кількості вчинених злочинів, зростання кількості постраждалих тощо. У таких випадках необхідно забезпечити швидке реагування, подбати про додаткові кадрові та силові резерви.

Процес структурного та параметричного проектування мережі, заснований тільки на експертних оцінках, займає тривалий час і є трудомістким навіть для малих мереж. Також, будь-яка статична БМ, як наприклад [264], моделює просторові залежності, робить часовий прогноз. На відміну від системи, яка використовує введення з числової моделі як входу в статичну мережу для прогнозування значень ключових змінних, представлена ДБМ використовує значення ключових змінних для прогнозування майбутніх значень цих же змінних. Кінцевими користувачами представленої ДБМ є: правоохоронці, які прагнуть знизити рівень злочинності, звести до мінімуму кількість постраждалих та матеріальні збитки. У сфері правопорушень моніторинг – це додаткова можливість надати органам правопорядку та поліції своєчасну інформацію. Ми побудували інформаційну технологію використання динамічних байєсівських мереж для оцінки та моделювання якості роботи правоохоронних органів. Побудова мережі з багатьма змінними дугами, існуючими кожному за вузла, також складні. Однак у процесі розробки даної ДБМ, було з'ясовано, що чим більше доказів, то вище точність проектованої мережі.

5. 4. Модель прогнозування економічного зростання країни за допомогою динамічних байєсівських мереж.

В цьому розділі ми продовжимо дослідження, розпочате в розділі 3.4 цього посібника, де ми спроектували і дослідили статичну БМ економічного зростання країни і розширимо його на динамічні БМ.

Розвиток економіки можна розглядати як один із головних факторів процвітання та добробуту країни. Широке поширення технологій, широке впровадження індустріалізації та підтримка всіх видів інновацій сприяють зменшенню розриву між розвиненими країнами та країнами, що розвиваються. Головною потребою національної економіки є інноваційний розвиток підприємств. Економічні процеси – це динамічні стохастичні процеси, які:

- залежать від багатьох факторів і випадкових впливів різного характеру;
- мають багато обмежень і характеризуються різкою зміною динаміки та відповідних факторів;
- важко керовані.

Діяльність підприємства виявляє інновації шляхом трансформації та/або реформування виробництва шляхом застосування винаходів або різноманітних можливостей пошуку нових джерел сировини, можливих ринків збуту, випуску нових видів товарів, застосування модернізації виробництва тощо, тобто застосування новішої продукції. Інноваційна діяльність підприємства є тим фактором, який надає економіці динамічний характер і тому має двосторонній вплив: з одного боку, відкриває нові можливості для економічного розширення; з іншого боку, це вимагає радикальної зміни будь-яких традиційних напрямів подальшого розвитку [30].

Нині в Україні налічується 42 564 промислових підприємства, що становить 12,4% від їх загальної кількості. У країнах Європейського Союзу (ЄС) частка підприємств, які займаються

інноваційною діяльністю, становить близько 53%. Найбільша кількість інноваційних підприємств серед країн ЄС у Німеччині (79,3% від загальної кількості підприємств), найменша – у Болгарії (27,1% від загальної кількості підприємств) [292].

Теорії та моделі економічного розширення вважають пріоритетними шляхи, якими поточна економічна практика може вплинути на майбутні економічні події. Проблеми аналізу економічних даних наступні:

- завдання аналізу економічних даних важко формалізовані або погано структуровані;
- економічні дані характеризується неповнотою, неоднозначністю, невизначеністю як вхідних даних, так і правил їх перетворення;
- важко визначити єдиний формальний критерій вирішення проблеми;
- результати аналізу можуть бути кількісні та якісні;
- немає чітких рекомендацій щодо того, які методи та підходи краще використовувати для вирішення конкретних завдань;
- класичні методи та підходи, як правило, неефективні в умовах динамічних змін досліджувальних процесів.

Байєсові мережі були обрані інструментом аналізу в нашому дослідженні, оскільки вони дозволяють:

- поєднувати графічне зображення конкретного процесу з його ймовірнісним характером;
- аналізувати можливі варіанти розвитку процесу;
- контролювати правильний причинно-наслідковий зв'язок між окремими факторами;
- підвищити обґрунтованість рішень при аналізі складних проблемних ситуацій.

Створення динамічних імовірісно-детермінованих моделей на основі байєсівських мереж для оцінки міри економічного розширення України визначає актуальність і новизну результатів:

- (1) маючи доступний набір статистичних даних, ми застосовуємо ймовірнісний підхід динамічних байєсівських мереж. Це дозволяє нам відстежувати результати на кілька кроків вперед;

(2) результати експериментів дозволяють успішно виявити тенденції, за умов дотримання яких покращаться показники фінансового розвитку країни та внутрішнього інвестиційного потенціалу;

(3) ми визначимо умови, за яких підвищуватиметься рівень технологічності та інноваційності України.

Математична модель, яка при аналізі фінансових, інвестиційних та економічних показників галузей і підприємств допомогла б оцінити ступінь адаптованості (чи інноваційності) країни, потребує наявності вхідних даних. Методи байєсівської мережі з певною часткою вірогідності дозволяють досягти поставленої мети. При моделюванні та прогнозуванні фінансових процесів виникають проблеми, пов'язані з великою кількістю змінних, великими обсягами спостережень за відносно короткий проміжок часу. Враховуючи, що однією з проблем розробки байєсівських мереж є експоненціальне збільшення кількості параметрів в таблицях умовної ймовірності, у даній роботі пропонується методика застосування вузлів Noisy-MAX для моделювання економічних процесів. Метою роботи є розробка динамічних байєсівських мережевих моделей на основі вузлів noisy-MAX для аналізу тенденцій економічного розвитку країни з урахуванням часової складової.

В якості експериментальних даних для оцінки економічного розвитку України враховувалися макроекономічні показники, статистичні можливості та модифікація існуючих методів дослідження фінансової діяльності підприємства (табл. 5.1). Матриця показників поділена на чотири блоки, які найбільш повно характеризують фінансово-економічну та господарську діяльність підприємств, а також перебіг економічних процесів у країні. Існує 4 ключових вузла:

- X1 – ступінь адаптивності і технологічності (або інноваційності),
- X2 – ступінь фінансової безпеки (фінансового розвитку), грн
- X3 – зовнішній інвестиційний потенціал, грн.,
- X4 – внутрішній інвестиційний потенціал, грн.

Отриманий параметр Y є невід'ємною ознакою ступеня економічного розвитку України.

При побудові БМ бувають випадки, коли попередня структура мережі визначається емпірично (отримана від експертів або як результат застосування інших методів чи алгоритмів). Якщо конструкція невідома, то її потрібно побудувати. В обох випадках зі статистичною інформацією для побудови мережі зручно використовувати евристичний алгоритм Байєса, який у першому випадку коригує структуру мережі, а в другому – будує структуру мережі, яку потім можна модифікувати із застосуванням експертних знань.

У випадку, коли байєсовська мережа побудована, необхідно застосувати метод виведення. Якщо на початку дослідження у нас наявні ймовірності певних подій, то висновок робиться шляхом обчислення ймовірностей за теоремою Байєса. Якщо ймовірності подій не вказано, але є певна статистика (дані), то можна використати ймовірнісний алгоритм висновку на основі даних навчання.

Саме цей метод дає кращі результати, тому що задані заздалегідь ймовірності можуть змінюватися і підлаштовуватися навіть під сам процес виведення, але це ніяк не відобразиться в мережі. Це дозволяє уникнути ймовірнісного алгоритму висновку на основі даних навчання, запропонованого в [102].

Слід зазначити, що через специфіку байєсівських мереж усі результати моделі щодо шуканої інформації представлені у формі ранжованого списку (відповідно до значень ймовірності того чи іншого висновку) і мають ймовірнісний характер. Дані взяті за період з 2005 по 2018 рр. І представлені в таблиці 3.6 в розділі 3.4 навчального посібника. З концептуальною моделлю можна ознайомитись на рис. 3.21 так само в розділі 3.4. Динаміку зміни початкових параметрів за спостережуваний період представлено в таблиці 5.1. Усі вузли мають по п'ять станів: від s_1 до s_5 . Спочатку ми розробили статичну байєсівську модель, яка послужить початковим етапом для нашої динамічної мережі (див. рис. 5.10).

Таблиця 5.1.
Динаміка зміни вихідних показників за спостережуваний період [265].

	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018
Y	441452	544153	720731	948056	913345	1079346	1299991	1404669	1465198	1586915	1988544	2383182	2982920	2502130
X1	0.253	0.355	0.44	0.39	0.26	0.308	0.352	0.307	0.295	0.21	0.154	0.188	0.218	0.399
X11	0.082	0.1	0.115	0.108	0.107	0.115	0.128	0.136	0.136	0.121	0.152	0.166	0.143	0.166
X12	0.065	0.067	0.067	0.059	0.048	0.038	0.038	0.033	0.033	0.025	0.014	0.005	0.007	0.059
X13	0.016	0.035	0.058	0.049	0.018	0.035	0.047	0.034	0.03	0.016	0.009	0.042	0.066	0.034
X2	0.335	0.365	0.18	0.28	0.414	0.338	0.273	0.222	0.197	0.215	0.196	0.163	0.143	0.168
X21	41802	51979	13590	34691	41311	47002	53498	62168	68997	72530	72763	90300	116728	146944
X22	46798	67256	64037	124453	185337	171670	159721	125079	104503	132053	161182	142275	139388	252627
X3	0.995	1	1	0.998	0.76	0.978	0.94	0.978	0.592	0.175	0.513	0.669	0.529	0.487
X31	7808	5604	9891	10913	4816	6495	7207	8401	4499	410	2961	3284	2202	1526
X32	0.147	0.197	0.1	0.116	0.159	0.158	0.147	0.184	0.18	0.197	0.215	0.182	0.149	0.18
X4	0.512	0.445	0.567	0.587	0.586	0.578	0.616	0.543	0.516	0.305	0.279	0.33	0.335	0.305
X41	0.2028	0.2003	0.243	0.1951	0.1184	0.1479	0.1209	0.1177	0.1039	-0.075	-0.080	-0.019	0.0362	0.0362
X42	5.12	5.05	5.05	5.27	7.79	7.94	7.97	7.99	7.99	11.89	21.84	25.55	26.6	27.2

Для дослідження ми беремо цю статичну мережу (рисунок 5.10), яку розробили у розділі 3.4 цього посібника і додаємо часові вузли.




Рис. 5.10 Статична БМ оцінки можливості економічного зростання країни [265].

Далі визначаємо нормалізований і кінцевий вузли, а потім перебудовуємо мережу з урахуванням наявності часової області. Приймаємо, що вузли X11-X13, X21, X22, X31, X32, X41, X42 є нормованими статичними, значення яких не змінюються з часом при додаванні часових дуг. На вузлах X1 – X4 ми встановили часові дуги, і тепер попередні ймовірності враховуються на ключових змінних X1-X4. Після навчання параметрів, потрібно встановити періоди часу для всіх ключових змінних. Отримана динамічна мережа представлена на малюнку 5.11.




Рис. 5.11 Динамічна БМ економічного розвитку країни.

Вибір правильного алгоритму для розв'язання конкретного економічного завдання може бути досить складним. У той час як різні алгоритми можуть бути використані для виконання того самого завдання, кожен алгоритм генерує різний результат, а деякі алгоритми можуть генерувати більше ніж один тип результату [1, 21].

Проведемо аналіз ДБМ і визначимо основні тенденції економічного розвитку країни. Якщо зараз рівень кредитування зростає лише на 1% (тобто X21 і X22 зростуть з 11% до 12%), то на наступному кроці фінансовий розвиток країни зростає до 87% (X2 зростає з 13% до 100). %) і досягають максимуму, як показано на малюнку 5.12.




Рис. 5.12 Умови підвищення рівня фінансового розвитку країни.

Якщо зараз частка підприємств, які впроваджують інновації (X11 зростає з 13% до 44%), зростає на 31%, а частка прибутку цих підприємств зростає лише на 2% (X21 зросла з 37% до 39%), то рівень технологічності та інновацій Україна підвищиться до 81% на наступному часовому етапі (X1 збільшиться з 19% до 100%) і буде прагнути до максимуму, як показано на малюнку 5.13.




Рис. 5.13 Умови забезпечення максимального рівня технологічності та інноваційності України [Dynamic Bayesian Network Model of a Country's Economic Extension].

Якщо зараз підвищити схильність населення до заощаджень лише на 5% (підвищити X41 з 21% до 26%), а процентні ставки за депозитами знизити на 12% (X42 зменшити з 34% до 22%), то на наступного кроку внутрішній інвестиційний потенціал зростає до 93% і досягне максимуму (рисунок 5.14).




Рис. 5.14 Умови максимізації внутрішнього інвестиційного потенціалу [Dynamic Bayesian Network Model of a Country's Economic Extension].

Збільшення обсягу інвестицій в Україну зараз на 21% (X32 зросте з 29% до 50%) і незначне зниження курсу долара на 7% (X31 знизиться з 10% до 3%) призведе до збільшення внутрішнього інвестиційного потенціалу на 75% (X3 збільшується з 25% до 100%) на наступному часовому етапі, як показано на рисунку 5.15.




Рис. 5.15 Умови нарощування внутрішнього інвестиційного потенціалу [Dynamic Bayesian Network Model of a Country's Economic Extension].

Сучасний рівень розвитку промисловості та економіки України в цілому характеризується складними системами зв'язків і відносин, що склалися між об'єктами соціально-економічної діяльності. В умовах конкуренції, нестабільності та слабких фінансових ринків проблеми аналізу та планування економічного розширення, розвитку інновацій та підтримки інвестиційного потенціалу стають все більш актуальними.

В цьому дослідженні показано, що якщо частка підприємств, які впроваджують інновації, зросте на 31 %, а частка прибутку цих підприємств збільшиться лише на 2 %, то рівень технологічності та інноваційності України на наступному часовому кроці зросте до 81 % і буде прагнути по максимуму. Збільшення обсягу інвестицій в Україну на поточному кроці на 21% і незначне зниження курсу долара на 7% призведе до зростання внутрішнього інвестиційного потенціалу на 75% на наступному кроці.

Висновки до розділу 5

В цьому розділі ми розглянули поняття динамічної байєсівської мережі, її формальний опис, переваги використання, галузі, в яких застосовується таке моделювання. Динамічна байєсівська мережа може бути представлена у вигляді кількох статичних байєсівських мереж, взятих у певній хронологічній послідовності. Час може розглядатися як дискретна чи неперервна характеристика аналізованих процесів. Графічне представлення ДБМ корисне у концептуальному моделюванні, що дозволяє створювати проблеми дослідження та систематично вирішувати їх.

Ми побудували дві динамічні БМ: динамічну байєсівська модель оцінки якості правоохоронного сервісу, що може бути корисна працівникам органів правопорядку, а також експертам-криміналістам при виборі та кількісній оцінці вхідних та вихідних змінних. А також модель прогнозування економічного зростання країни за допомогою динамічних байєсівських мереж. Доведено, що збільшення обсягу інвестицій в Україну на поточному кроці на 21% і незначне зниження курсу долара на 7% призведе до зростання внутрішнього інвестиційного потенціалу на 75% на наступному кроці.

Контрольні питання:

1. Поняття динамічної байєсівської мережі.
2. Технологія побудови динамічної БМ в GeNIe.
3. Різновиди динамічних байєсівських моделей і галузі їх застосування
4. В чому перевага динамічних моделей над статичними?

ВИСНОВКИ

Динамічні байєсівські мережі – інструмент для синтезу знань, логіки та правил. Типові завдання, які розв'язуються за допомогою ДБМ складні та мультидисциплінарні за своєю природою. Модель, що враховує розвиток системи у часі повинна забезпечувати цілісне та мислиме уявлення про систему у фокусі і таким чином сприяти розумінню її динаміки та можливому реагуванню на аналізовані заходи управління. В навчальному посібнику продемонстровано, що байєсівські мережі як метод мають безліч властивостей і вони можуть бути використані для вирішення аналітичних задач, типових для цієї галузі.

Проектування комплексної інтегративної метамоделі – це мистецтво. Насамперед, пояснення логіки такого суб'єкта та обґрунтування всіх зроблених припущень – довга історія як така. Спроектовані фонові моделі та інші дослідження, безліч відповідних результатів, які мають бути представлені, фактичні кількісні показники аналізованого питання є лише одним аспектом.

Розвиток ДБМ також є своєрідним нескінченним процесом. Коли проектувальник продовжує вивчати тему та працює з експертами у цій галузі, його розуміння системи постійно оновлюється. За півроку роботи він може захотіти оновити модель. Таким чином, можна лише визнати, що нинішня версія є поточним станом знань і розуміння проблематики. Щоб досягти повної соціальної корисності, розроблені моделі ДБМ повинні використовуватися для сприяння ухваленню рішень у реальному житті. Одним із цікавих аспектів майбутніх досліджень було б вивчення передумов для того, щоб інструменти такого роду стали справжнім практичним використанням менеджерів.

Таким чином, моделі повинні мати можливість генерувати колективно найкращі рішення. Це підвищить відданість зацікавлених сторін, зменшуючи невизначеність, пов'язану з успіхом реалізації обраних заходів управління. Якесь золоте срібло буде гарним рішенням, коли будуть почуті як кінцеві користувачі, так і зацікавлені сторони, але остаточна модель все одно буде збудована незалежними вченими.

Прозорість та гнучкість ДБМ надають безліч можливостей для кінцевого користувача. Однак це несе велику відповідальність, оскільки - крім знання моделі - користувач повинен розуміти принаймні основи байєсовського висновку та ймовірнісного способу мислення. Якщо це не так, існує високий ризик хибних інтерпретацій. Вкрай важливо визнати у кожному стані моделі задані параметри, аби зрозуміти питання, на яке модель відповідає у цьому конкретному стані. Користувач також повинен розуміти зворотню логіку ДБМ, тобто механізм оновлення знизу вгору, оскільки ця характеристика іноді генерує результати, які на перший погляд можуть бути досить заплутаними.

Імовірнісне моделювання демонструє мультидисциплінарний підхід, оскільки охоплює такі галузі, як математика, статистика та соціологія, а також навчає спілкуватися з ними. Це нескінченний процес, тому що він починається з кожного нового проекту та ніколи не закінчується. Цікаво та захоплююче ознайомитися з методами роботи та культурою багатьох дисциплін. Спілкування та співробітництво з новими дослідниками прогресують щоразу, бо процес охоплює одні й ті самі основні елементи. Оскільки міждисциплінарні дослідні групи та проекти стають дедалі популярнішими.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Abramson B., Brown J., Edwards W., Murphy A., Winkler R. L. Hailfinder: A Bayesian System For Forecasting Severe Weather. *International Journal Of Forecasting*. 1996. Vol. 12. P. 57-71.
2. Ad Feelders, L. C. van der Gaag. Learning Bayesian network parameters under order constraints. *International Journal of Approximate Reasoning*. 2006. Vol. 42 (1-2). P. 37-53.
3. Agostinelli C., Rotondi R. Using Bayesian belief networks to analyze the stochastic dependence between interevent time and size of earthquakes. *Journal of Seismology*. 2003. Vol. 7. P. 281-299.
4. Aguilera P. A., Fernández A., Fernández R., Rumí R., Salmerón A. Bayesian networks in environmental modelling. *Environmental Modelling and Software*. 2011. Vol. 26. P. 1376-1388.
5. AI Expert Newsletter: W is for Winter. Архів оригіналу за 9 листопада 2013. Процитовано 9 грудня 2015.
6. Andreassen S., Woldbye M., Falck B., Andersen S. K. MUNIN – A causal probabilistic network for interpretation of electromyographic findings. In: *Proceedings of the International Joint Conference on Artificial Intelligence*, Milan, Italy. 1987. P. 366-372.
7. Andreassen S., Jensen F. V., Olesen K. G. Medical expert systems based on causal probabilistic networks. *International Journal of Bio-Medical Computing*. 1991. Vol. 28 (1-2). P. 1-30.
8. Aronsky D., Haug P. J. Diagnosing Community-Acquired Pneumonia with a Bayesian Network, *Proceedings of the AMIA symposium*. 1998. P. 632-636.
9. Aussem A., de Morais S. R, Corbex M. Analysis of nasopharyngeal carcinoma risk factors with Bayesian networks. *Artificial Intelligence in Medicine*. 2012. Vol. 54 (1). P. 53-62.
10. Azimi J., Jalali A., Fern X. Hybrid batch Bayesian optimization. *International Conference on Machine Learning*. 2012.
11. Badiani B., Messori A. Targeted Treatments for Pulmonary Arterial Hypertension: Interpreting Outcomes by Network Meta-analysis. *PharmD Heart, lung & circulation*. 2015. Vol. 25 (1). P. 46-52.
12. Battineni G., Sagaro G., Chinatalapudi N., Amenta F. Applications of Machine Learning Predictive Models in the Chronic Disease Diagnosis. *Journal of personalized medicine*. 2020. Vol. 10 (2). P. 21.

13. Bari A., Chaouchi M., Jung T. Predictive Analytics For Dummies. Paperback Bunko by Anasse Bari. 2014. 480 p.
14. Barton D. N., Saloranta T. Moe S. J., Eggestad H. O., Kuikka S. Bayesian belief networks as a meta-modelling tool in integrated river basin management. *Pros and cons in evaluating nutrient abatement decisions under uncertainty in a Norwegian river basin. Ecological Economics*. 2008. Vol. 66. P. 91-104.
15. Barton J., Haslett T. Analysis, Synthesis, Systems Thinking and the Scientific Method: Rediscovering the Importance of Open Systems. *Systems Research and Behavioral Science*. 2007. Vol. 24. P. 143-155.
16. Bayes T., Price R. An essay towards solving a problem in the doctrine of changes. *Philosophical transactions of the Royal Society of London*. 1736. Vol. 53. P. 370-418.
17. Bayesian Networks and Simulation Software for Risk Analysis and Decision Support. URL: <http://www.agenarisk.com>. (дата звернення: 10.09.2024).
18. Beinlich I. A., Suermondt H. J., Chavez R. M., Cooper G. F. The ALARM monitoring system // In: 2nd European Conference on Artificial Intelligence in Medicine – Proceedings. London, England. 1989. P. 247-256.
19. Bender C. et al. Dynamic deterministic effects propagation networks: learning signalling pathways from longitudinal protein array data. *Bioinformatics*. 2010. Vol. 26, № 18. P. i596-i602.
20. Bergstra J., Bardenet R., Bengio Y., K'egl B. Algorithms for hyperparameter optimization. *Advances in Neural Information Processing Systems*. 2011. P. 2546–2554.
21. Berliner M. L., Royle J. A., Wilke C. K., Milliff R. F. Bayesian Methods In The Atmospheric Sciences. *Bayesian Statistics*. 1998. Vol. 6. P. 83-100.
22. Bescos C., Schmeink A., Harris M., Schmidt R. Strategies in the use of static and dynamic bayesian networks in home monitoring // IEEE Benelux EMBS Symposium (December 6-7). 2007. P. 31-34.
23. Bidyuk P., Beglytsia V., Gozhyj A., Kalinina I. Using the Metropolis-Hastings algorithm in Bayesian data analysis procedures // In: 2019 IEEE 14th International Conference on Computer Sciences and

Information Technologies (CSIT). 2019. P. 98-101. DOI: 10.1109/STC-CSIT.2019.8929797.

24. Bidyuk P., Gozhyj A., Kalinina I. Probabilistic Inference Based on LS-Method Modifications in Decision Making Problems. *Lecture Notes in Computational Intelligence and Decision Making. Advances in Intelligent Systems and Computing*. 2020. Vol. 1020. P. 422-433. DOI: 10.1007/978-3-030-26474-1_30.

25. Bidyuk P., Gozhyj A., Kalinina I., Szymanski Z., Beglytsia V. The methods Bayesian analysis of the threshold stochastic volatility model // Proceedings of the 2018 IEEE 2nd International Conference on Data Stream Mining and Processing, DSMP 2018, Lviv. 2018. P. 70-75.

26. Bidyuk P., Gozhyj A., Kalinina I. Modeling military conflicts using Bayesian networks // 2018 IEEE 1st International Conference on System Analysis and Intelligent Computing, (SAIC 2018). 2018. № 8516861. P. 155-160. DOI: 10.1109/SAIC.2018.8516861.

27. Bidyuk P., Matsuki Y., Gozhyj A., Beglytsia V., Kalinina I. Features of Application of Monte Carlo Method with Markov Chain Algorithms in Bayesian Data Analysis. *Advances in Intelligent Systems and Computing*. 2020. Vol. 1080. P. 361–376. DOI: http://doi-org-443.webvpn.fjmu.edu.cn/10.1007/978-3-030-33695-0_25.

28. Bodyanskiy Y. Computational intelligence techniques for data analysis. *Lecture Notes in Informatics*, 2005, Vol. 5(72). P. 15-36.

29. Bojarczuk C., Lopes H., Freitas A., Michalkiewicz E. A constrained-syntax genetic programming system for discovering classification rules: application to medical data sets. *Artificial Intelligence in Medicine*. 2004, Vol. 1, № 10. P. 27-48.

30. Bonafede C. E., Giudici P. Bayesian networks for enterprise risk assessment. URL: http://arxiv.org/PS_cache/physics/pdf/0607/0607226v1.pdf. (дата звернення: 10.09.2024).

31. Borsuk M. E., Schweizer S., Reichert P. A Bayesian Network Model for Integrative River Rehabilitation Planning and Management. *Integrated Environmental Assessment and Management*. 2012. Vol. 8(3). P. 462–472.

32. Borsuk M. E., Stow C. A., Reckhow K. H. A Bayesian network of eutrophication models for synthesis, prediction, and uncertainty analysis. *Ecological Modelling*. 2004. Vol. 173. P. 219–239.

33. Bouchaffra D., Tan J. Protein Fold Recognition using a Structural Hidden Markov Model // Conference: 18th International Conference on Pattern Recognition (ICPR-2006), Hong Kong, China. 2006. DOI: 10.1109/ICPR.2006.949.

34. Boufounos P., El-Difrawy S., Ehrlich D. Hidden Markov Models for DNA Sequencing. 2002. URL: https://www.researchgate.net/publication/2567449_Hidden_Markov_Models_for_DNA_Sequencing. (дата звернення: 10.09.2024).

35. Brochu E., Brochu T., de Freitas N. A Bayesian interactive optimization approach to procedural animation design // In Proceedings of the 2010 ACM SIGGRAPH/Eurographics Symposium on Computer Animation. 2010. P. 103–112.

36. Brochu E., Cora V. M., de Freitas N. A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning. *Technical Report UBC TR-2009-23 and arXiv:1012.2599v1*. Dept. of Computer Science. University of British Columbia. 2009.

37. Bromley J., Jackson N. A., Clymer O. J., Giacomello A. M., Jensen F. V. The use of Hugin to develop Bayesian networks as an aid to integrated water resource planning. *Environmental Modelling and Software*. 2005. Vol. 20. P. 231-242.

38. Burnum J. F. Medical diagnosis Through semiotics. Giving meaning to the sign. *Annals of Internal Medicine*. 1993. Vol. 119(9). P. 939-943.

39. Cano R., Sordo C., Gutierrez J. M. Applications Of Bayesian Networks In Meteorology. *Advances In Bayesian Networks*, 2004. P. 309-327.

40. Carmona G., Varela-Ortega C., Bromley J. The Use of Participatory Object-Oriented Bayesian Networks and Agro-Economic Models for Groundwater Management in Spain. *Water Resources Management*. 2011. Vol. 25(5). P. 1509-1524.

41. Carol E. Brown, Daniel E. O'Leary, Introduction To Artificial Intelligence And Expert Systems [Архівовано 28 серпня 2008 у Wayback Machine.], переглянуто 7 лютого 2008.
42. Castelletti A., Soncini-Sessa R. Bayesian Networks and participatory modelling in water resource management. *Environmental Modelling and Software*. 2007. Vol. 22. P. 1075-1088.
43. Castillo E. F., Guti'erez J. M., Hadi A. S. Sensitivity analysis in discrete Bayesian networks // *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*. 1997. № 27(4). P. 412–423.
44. Cathy O'Neil, Rachel Schutt. *Doing Data Science*. O'Reilly Media, Inc., 2013. 368 p.
45. Cerliani M. Anomaly Detection with Extreme Value Analysis. URL: <https://towardsdatascience.com/anomaly-detection-with-extreme-value-analysis-b11ad19b601f>. (дата звернення: 10.09.2024).
46. Chaitankar V., et al. Time lagged information theoretic approaches to the reverse engineering of gene regulatory networks // *BMC bioinformatics*. – BioMed Central. 2010. Vol. 11. P. 1-14.
47. Chaudhari B., Parikh M. A Comparative Study of clustering algorithms Using weka tools. *International Journal of Application or Innovation in Engineering & Management (IJAIEEM)*. 2012. Vol. 1(2). P. 154-158.
48. Chattopadhyay S., Davis R.M., Menezes D.D., Singh G., Acharya R.U., Tamura T. Application of Bayesian classifier for the diagnosis of dental pain. *Journal of Medical Systems*. 2012. Vol. 36(3). P. 1425–1439.
49. Chavez R. M., Cooper G. F. KNET: Integrating hypermedia and normative Bayesian modeling // In: *Uncertainty in Artificial Intelligence 4*, North-Holland, Amsterdam. 1990. P. 339-349.
50. Cheeseman P., Freeman D., Kelly M., Taylor W., Stutz J. Bayesian classification // *Proceedings of AAAI*, St. Paul, MN. 1988. P. 607-611.
51. Chen X., et al. A dynamic Bayesian network for identifying protein-binding footprints from single molecule-based sequencing data. *Bioinformatics*. 2010. Vol. 26, № 12. P. i334-i342.

52. Cheng J., Bell D. A. Liu W. Learning belief networks from data: an information theory based approach // Proceedings of the sixth international conference on information and knowledge management (CIKM 1997), Las Vegas (Nevada), November 10-14. 1997. P. 325-331.

53. Cheng J., Greiner R., Kelly J., Bell D. A., Liu W. Learning Bayesian networks from data: an information-theory based approach. *The artificial intelligence journal (AIJ)*. 2002. Vol. 137. P. 43-90.

54. Cheng J., Druzdzel M. AIS-BN: An Adaptive Importance Sampling Algorithm for Evidential Reasoning in Large Bayesian Networks. *Journal of Artificial Intelligence Research JAIR-2000*. 2000. Vol. 13. P. 155-188.

55. Cheng Y. Mean Shift, Mode Seeking, and Clustering // IEEE Transactions on Pattern Analysis and Machine Intelligence — IEEE. 1995. Vol. 17(8). DOI:10.1109/34.400568.

56. Chickering D., Heckerman D. Efficient Approximations for the Marginal Likelihood of Bayesian Networks with Hidden Variables. *Machine Learning*. 1997. Vol. 29. P. 181-212.

57. Chiong J. R., Aronow W. S., Khan I. A., Nair C. K., Vijayaraghavan K., Dart R. A., Behrenbeck T. R., Geraci S. A. Secondary hypertension: current diagnosis and treatment. *International Journal of Cardiology*. 2008. Vol. 124(1). P. 6–21.

58. Chyrun L., Leshchynskyy E., Lytvyn V., Rzhеuskyi A., Vysotska V., Borzov Y. Intellectual Analysis of Making Decisions Tree in Information Systems of Screening Observation for Immunological Patients // CEUR Workshop Proceedings. 2019. Vol. 2362. P. 281-296.

59. Cobb B. R., Shenoy P. P. A Comparison of Bayesian and Belief Function Reasoning. Working Paper No. 292, University of Kansas School of Business (2002). URL: <http://citeseer.ist.psu.edu/cobb02comparison.html>. (дата звернення: 10.09.2024).

60. Codetta-Raiteri D., Bobbio A., Montani S., Portinale L. A dynamic Bayesian network based framework to evaluate cascading effects in a power grid. *Engineering Applications of Artificial Intelligence*. 2012. Vol. 25(4). P. 683-697.

61. Cofino A. S., Cano R., Sordo C., Gutierrez J. M. Bayesian Networks For Probabilistic Weather Prediction // *Proceedings Of The 15th European Conference On Artificial Intelligence*, Ios Press. 2002. P. 695-700.
62. Coiera E. W. Artificial Intelligence in Medicine: The Challenges Ahead. *Journal of the American Medical Informatics Association*. 1996. Vol. 3(6). P. 363–366.
63. Cooper G. F., Herskovits E. A bayesian method for the induction of probabilistic networks from data. Knowledge Systems Laboratory / Report KSL-91-02. November, 1993. 43 p.
64. Cooper G. F. The computational complexity of probabilistic inference using Bayesian belief networks. *Artificial Intelligence*. 1990. Vol. 42, № 2-3. P. 393-405.
65. Cooper G. F. Current research directions in the development of expert systems based on belief networks // *Applied Stochastic Models and Data Analysis*. 1989. № 5. P. 39-52.
66. Crevier. 1993. P. 145—62, 197–203.
67. Curiac D. I., Vasile G., Baniias O., Volosencu C., Albu A., Bayesian network model for diagnosis of psychiatric diseases // *Information Technology Interfaces, ITI '09. Proceedings of the ITI 2009 31st International Conference*. 2009.
68. Dagum P., Luby M. Appximating probabilistic inference in Bayesian belief networks is NP-hard. *Artificial Intelligence*. 1993. Vol. 45. P. 141-153.
69. Daly R., Q. Shen, Aitken S. Learning Bayesian networks: approaches and issues. *The Knowledge Engineering Review*. 2011. Vol. 26(2). P. 99–157.
70. Darwiche A. Modeling and Reasoning with Bayesian Networks. Cambridge : Cambridge University Press, 2009. 550 p.
71. de Kock M., Le H., Tadross M., Potgeiter A. Weather Forecasting Using Dynamic Bayesian Networks. Tech. Rep., University of Cape Town. 2008.
72. Dean T., Kanazawa K. Probabilistic temporal reasoning // *Proceedings of the Seventh AAAI National Conference on Artificial Intelligence*. 1988. P. 524-528.

73. Dean T., Kanazawa K. A model for reasoning about persistence and causation. *Computational intelligence*. 1989. Vol. 5, № 2. P. 142-150.
74. Dempster A. P., Laird N. M., Rubin D. B. Maximum likelihood from incomplete data via the EM algorithm. *Journal of the royal statistical society: series B (methodological)*. 1977. Vol. 39, № 1. P. 1-22.
75. Díez F. J., Miraa J., Iturraldeb E., Zubillagac S. DIAVAL, a Bayesian expert system for echocardiography. *Artificial Intelligence in Medicine*. 1997. Vol. 10(1). P. 59–73.
76. Ding J., Kramer B., Bai Y., Chen H. Backward Inference in Bayesian Networks for Distributed Systems Management. *Journal of Network and Systems Management*. 2005. Vol. 13, №. 4. P. 409-427.
77. Dominik Paprotny, Oswaldo Morales-Nápoles, Daniël T. H. Worm, Elisa Ragno. BANSHEE–A MATLAB toolbox for Non-Parametric Bayesian Networks. 2020. Vol. 12. URL: <https://doi.org/10.1016/j.softx.2020.100588>. (дата звернення: 10.09.2024).
78. Dorner S., Shi J., Swayne D. Multi-objective modelling and decision support using a Bayesian network approximation to a non-point source pollution model. *Environmental Modelling and Software*. 2007. Vol. 22. P. 211-222.
79. Dunn Robert J. (30 вересня 1985). Expandable Expertise for Everyday Users. InfoWorld. 7 (39): 30. Архів оригіналу за 19 березня 2015. Процитовано 13 березня 2011.
80. Durkin J. Expert Systems: Catalog of Applications. Intelligent Computer Systems, Inc., Akron, OH, 1993. 399 p.
81. Russo P. The rise of the expert company. *The Knowledge Engineering Review*. 1989. Vol. 4(1). P. 84-85. DOI: 10.1017/S0269888900004835.
82. Eldawlatly S., et al. On the use of dynamic Bayesian networks in reconstructing functional neuronal networks from spike train ensembles. *Neural computation*. 2010. Vol. 22, № 1. P. 158-189.
83. Esfandiari M., Babavaliana M. R., Moghadama A. M. E., Tabar V. K. Knowledge discovery in medicine: Current issue and future trend. *Expert Systems with Applications*. 2014. Vol. 41(9). P. 4434–4463.
84. Esposito D., Esposito F. Introducing Machine Learning. Pearson Education, EBook, 2020. 400 p.

85. Estivill-Castro V. Why so many clustering algorithms – A Position Paper // ACM SIGKDD Explorations Newsletter. 2002. Vol. 4(1). P. 65–75. DOI:10.1145/568574.568575.

86. Ferrazzi F., et al. Dynamic Bayesian networks in modelling cellular systems: A critical appraisal on simulated data // 19th IEEE Symposium on Computer-Based Medical Systems (CBMS'06). 2006. P. 544-549.

87. Fienberg S. E. When Did Bayesian Inference Become “Bayesian”? *Bayesian Analysis*. 2006. Vol. 1(1). P. 1-40.

88. Freeze R., James B., Massmann J., Sperling T., Smith L. Hydrogeological decision analysis: 4. The concept of data worth and its use in the development of site investigation strategies. *Ground Water*. 1992. Vol. 30(4). P. 574-588.

89. Freedman D., Kisilev P. Fast mean shift by compact density representation // Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2009. P. 1818-1825.

90. Friedman N., Murphy K., Russell S. Learning The Structure Of Dynamic Probabilistic Networks // Proc. Fourteenth Conference On Uncertainty In Artificial Intelligence. 1998.

91. Galan S. F., et al. NasoNet, modeling the spread of nasopharyngeal cancer with networks of probabilistic events in discrete time. *Artificial Intelligence in Medicine*. 2002. Vol. 25, № 3. P. 247-264.

92. Garnett R., Osborne M. A., Roberts S. J. Bayesian optimization for sensor set selection // ACM/IEEE International Conference on Information Processing in Sensor Networks. 2010. P. 209–219.

93. Романенко К. Еволюція штучного інтелекту (ШІ): Визначні моменти в історії та застосування. URL: <https://cases.media/article/evolyuciya-shtuchnogo-intelektu-shi-viznachni-momenti-v-istoriyi-ta-zastosuvannya>. (дата звернення: 10.09.2024).

94. Getoor L, Rhe J. T., Koller D., Small P. Understanding tuberculosis epidemiology using structured statistical models. *Artificial Intelligence in Medicine*. 2004. Vol. 30(3). P. 233–256.

95. Guha S., Rastogi R., Shim R. CURE: An Efficient Clustering Algorithm for Large Databases» // SIGMOD '98 Proceedings of the 1998

ACM SIGMOD international conference on Management of data, Seattle, Washington. 1998. P. 73-84.

96. Haapasaari P., Karjalainen T. P. Formalizing expert knowledge to compare alternative management plans: sociological perspective to the future management of Baltic salmon stocks. *Marine Policy*. 2010. Vol. 34. P. 477-486.

97. Haapasaari P., Michielsens C. G. J., Karjalainen T. P., Reinikainen K., Kuikka S. Management measures and fishers' commitment towards sustainable exploitation: a case study of Atlantic salmon fisheries in the Baltic Sea. *ICES Journal of Marine Science*. 2007. Vol. 64. P. 825-833.

98. Harvey A. Forecasting, Structural Time Series Models and the Kalman Filter. Cambridge: Cambridge University Press, 1990. 554 p. DOI:10.1017/CBO9781107049994.

99. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2nd ed. Springer-Verlag, 2009. 746 p.

100. Hayes-Roth F., Waterman D., Lenat D. Building Expert Systems: Addison-Wesley Publishing Company, 1983. 444 p.

101. Heckerman D. A Tutorial on Learning with Bayesian Networks, Innovations in Bayesian Networks. *Studies in Computational Intelligence*. 2008. Vol. 156. P. 33-82.

102. Heckerman D., Geiger D., Chickering D. M. Learning Bayesian networks: The combination of knowledge and statistical data. *Machine Learning*. 1995. Vol. 20(3). P. 197-243.

103. Heckerman D. Probabilistic similarity networks. *Networks*. 1990. Vol. 20. P. 607-636.

104. Heckerman D., Geiger D., Chickering D. M. Learning Bayesian Networks: The Combination of Knowledge and Statistical Data. *Machine Learning*. 1995. Vol. 20. P. 197-243. DOI: 10.1007/BF00994016.

105. Helle I., Lecklin T., Jolma A., Kuikka S. Modelling the effectiveness of oil combating from an ecological perspective - A Bayesian network for the Gulf of Finland; the Baltic Sea. *Journal of Hazardous Materials*. 2011. Vol. 185(1). P. 182-192.

106. Henrion M. Some practical issues in constructing belief networks // *Uncertainty in Artificial Intelligence 3* (North-Holland, Amsterdam, 1989). 1989. P. 161-173.

107. Heskes T. Generalized belief propagation for approximate inference in hybrid Bayesian networks // *Proc. 9th Int. Workshop Artificial Intelligence and Statistics (AISTATS)*. 2003. P. 30 -37.

108. Hoffman M., Shahriari B., de Freitas N. On correlation and budget constraints in model-based bandit optimization with application to automatic machine learning. *In AI and Statistics*. 2014. P. 365–374.

109. Hoos H. H. Programming by optimization. *Communications of the ACM*. 2012. Vol. 55(2). P. 70–80. URL: <http://ceur-ws.org/Vol-2608/>. (дата звернення: 10.09.2024).

110. Hulst I. R. J. Modeling Physiological Processes with Dynamic Bayesian Networks. Thesis Paper. University of Pittsburgh, 2006. 172 p.

111. Hurwitz J. Smart or Lucky: How Technology Leaders Turn Chance into Success: John Wiley & Son, 2011. p. 164.

112. Hutter F., Hoos H. H., Leyton-Brown K. Automated configuration of mixed integer programming solvers // *CPAIOR*. 2010. Vol. 6140. P. 186–202.

113. Hwang J., Lay S., Maechler M., Martin R., Schimert J. Regression modeling in back-propagation and projection pursuit learning // *IEEE Transactions on Neural Networks*. 1994. Vol. 5, № 3. P. 342-353.

114. Hyndman R., Athanasopoulos G. Forecasting: Principles and Practice. Econometrics & Business Statistics. 2nd edition, Monash University, Australia. Texts, 2018. 384 p. URL: <https://otexts.org/fpp2/>.

115. Jain A. K., Dubes R. C. Algorithms for Clustering Data, Englewood Cliffs, N.J. : Prentice-Hall, 1988. 334 p.

116. James G, Witten D., Hastie T., Tibshirani R. An Introduction to Statistical Learning. New York : Springer, 2013. 456 p.

117. Jensen F. V. Paradigms of Expert Systems. HUGIN Expert Software System : Online Developers Guide, 2005. 3 p. URL: <http://developer.hugin.com>

118. Jensen F. V., Lauritzen S. L. Probabilistic Networks : Techn. Report, Aalborg University, Denmark, 2000. 30 p.

119. Jensen F. V., Lauritzen S. L., Olesen K. G. Bayesian updating in causal probabilistic networks by local computations // *Computational Statistics Quarterly*. 1990. Vol. 4. P. 269-282.

120. Jensen F. V. Bayesian Networks and Decision Graphs : Springer, 2001.

121. Jensen F. V., Nielsen T. D. Bayesian networks and decision graphs : Springer, 2007. 457 p.

122. Jia Y., Huan J. Constructing non-stationary dynamic Bayesian networks with a flexible lag choosing mechanism. *BMC bioinformatics*. 2010. Vol. 11. P. 1-13.

123. Johnson S., Mengersen K. Integrated Bayesian Network Framework For Modelling Complex Ecological Issues. *Integrated Environmental Assessment and Management*. 2012. Vol. 8(3). P. 480–490.

124. Jone T. B., Darling M. C., Groth K. M., Denman M. R., Luger G. F. A Dynamic Bayesian Network for Diagnosing Nuclear Power Plant Accidents // *Proceedings of the Twenty-Ninth International Florida Artificial Intelligence Research Society Conference*. 2016. P. 179-184.

125. Joshi A., Kaur R. Comparative Study of Various Clustering Techniques in Data Mining. *International Journal of Advanced Research in Computer Science and Software Engineering*. 2013. Vol. 3(3). P. 55-57.

126. Judea P. Probabilistic Reasoning in Intelligent Systems. Morgan Kaufmann, 1988. 552 p.

127. Juntunen T., Rosqvist T., Kuikka S., Rytönen J. Assessment of oil combating technologies using Bayesian networks – an application in the Baltic Sea // *ICES CM 2005/S:02*. 2005. 25 p.

128. Kahramanli H., Allahverdi N. Design of a hybrid system for the diabetes and heart diseases. *Expert Systems with Applications*. 2008. Vol. 1-2, № 35. P. 82–89.

129. Kalinina I., Bidyuk P., Gozhyj A. Construction of Forecast Models based on Bayesian Structural Time Series // *International Scientific and Technical Conference on Computer Sciences and*

Information Technologies. 2022. P. 180-184. DOI 10.1109/CSIT56902.2022.10000484.

130. Kalinina I. A., Gozhyj A. P. Modeling and forecasting of nonlinear nonstationary processes based on the Bayesian structural time series. *Applied Aspects of Information Technology*. 2022. Vol. 5, № 3. P. 240-255. DOI: <https://doi.org/10.15276/aait.05.2022.17>.

131. Kaplan K., Haenlein M. Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*. 2019. P. 15-25.

132. Kaufman S., Rosset S., Perlich C., Stitelman O. Leakage in data mining: Formulation, detection, and avoidance. *ACM Transactions on Knowledge Discovery from Data (TKDD)*. 2012. Vol. 6(4). P. 15.

133. Kayaalp M. M. Learning Dynamic Bayesian Network Structures from Data: Ph.D. Dissertation // M. M. Kayaalp, G. F. Cooper. – University of Pittsburgh, 2003. 203 p.

134. Kayaalp M., Cooper G. A Bayesian Network Scoring Metric That Is Based on Globally Uniform Parameter Priors // *Uncertainty in Artificial Intelligence*. 2002. P. 251-258.

135. Kelleher J. D., Mac Namee B., D'Arcy A. Fundamentals of Machine Learning for Predictive Data Analytics. Algorithms, Worked Examples, and Case Studies : The MIT Press, Cambridge, Massachusetts, London, England, 2020. 798 p.

136. Kelly D. L., Smith C.L. Bayesian inference in probabilistic risk assessment — The current state of the art. *Reliability Engineering & System Safety*. 2009. Vol. 94 (2). P. 628–643.

137. Kendal S., Creen M. An introduction to knowledge engineering, London : Springer, 2007. 287 p.

138. Kjaerulff U. A computational scheme for reasoning in dynamic probabilistic networks // *Uncertainty in Artificial Intelligence*. – Morgan Kaufmann. 1992. P. 121-129.

139. Kjaerulff U. B., Madsen A.L. An Introduction to Bayesian Network and Influence Diagram. URL: <http://people.cs.aau.dk/~uk/papers/pgm-book-I-05.pdf>. (дата звернення: 10.09.2024).

140. Kærulff U. B., Madsen A. L. Bayesian Networks and Influence Diagrams: A Guide to Construction and Analysis. *Information Science and Statistics*. 2013. Vol. 22.

141. Klammer A. A., et al. Modeling peptide fragmentation with dynamic Bayesian networks for peptide identification. *Bioinformatics*. 2008. Vol. 24, № 13. P. i348-i356.

142. Klein D. Artificial Intelligence: Hidden Markov Model. Lecture notes, University of California Berkeley, URL: <https://perma.cc/V7U4-WPUA>. (дата звернення: 10.09.2024).

143. Kohavi R., Longbotham R. Online experiments: Lessons learned. *Computer*. 2007. Vol. 40(9). P. 103–105.

144. Kohavi R., Parekh R. Ten supplementary analyses to improve e-commerce web sites // Proceedings of the Fifth WEBKDD workshop. 2003. P. 29-36.

145. Kohavi R., Brodley C., Frasca B., Mason L., Zheng Z. KDD-cup 2000 organizers' report: Peeling the onion. *ACM SIGKDD Explorations*. 2000. Vol. 2(2). P. 86-93.

146. Kohavi R., Deng A., Frasca B., Longbotham R., Walker T., Xu Y. Trustworthy online controlled experiments: Five puzzling outcomes explained // Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2012. P. 786–794.

147. Kohavi R., Longbotham R., Sommerfield D., Henne R. Controlled experiments on the web: Survey and practical guide. *Data Mining and Knowledge Discovery*. 2009. Vol. 18(1). P. 140-181.

148. Koller D., Pfeffer. A. Object-oriented Bayesian networks // Proceedings of the Thirteenth Annual Conference on Uncertainty in Artificial Intelligence (UAI-97), Providence, Rhode Island. 1997. P. 302-313.

149. Koller D., Friedman N. Probabilistic Graphical Models. Principles and Techniques. London: MIT Press, 2009, 1207 p.

150. Kononenko I. Machine learning for medical diagnosis: history, state of the art and perspective. *Artificial Intelligence in Medicine*. 2001. Vol. 23(1). P. 89–109.

151. Korb K. B., Nicholson A. E. Bayesian Artificial Intelligence. Seco Chapman & Hall / CRC Computer Science & Data Analysis, 2011. 479 p.

152. Koren O., Koren M., Peretz O. A procedure for anomaly detection and analysis. *Engineering Applications of Artificial Intelligence*. 2023. Vol. 117, Part A, № 105503. 8 p. URL: <https://doi.org/10.1016/j.engappai.2022.105503>. (дата звернення: 10.09.2024).

153. Kruse R., Borgelt C., Klawonn F., Moewes C., Steinbrecher M., Held P. Computational Intelligence. A Methodological Introduction. Berlin : Springer, 2013. 490 p.

154. Kuikka S., Varis O. Uncertainties of climatic change impacts in Finnish watersheds: a Bayesian network analysis of expert knowledge. *Boreal Environment Research* 2. 1997. P. 109–128.

155. Kuikka S., Hildén M., Gislason H., Hansson S., Sparholt H., Varis O. Modelling environmentally driven uncertainties in Baltic cod (*Gadus morhua*) management by Bayesian influence diagrams. *Canadian Journal of Fisheries and Aquatic Sciences*. 1999. Vol. 56. P. 629–641.

156. Kumar S. Anomaly Detection Algorithms every Data Scientist should know. Comparing anomaly detection algorithms for Outlier detection. 2021. URL: <https://towardsdatascience.com/5-anomaly-detection-algorithms-every-data-scientist-should-know-b36c3605ea16>. (дата звернення: 10.09.2024).

157. Kuznyetsova N. Integrated approach to credit rating. // Int. Scientific Conf. “Intelligence, Integrity, Reliability”. 2010. P. 30–31.

158. Laboratory D. S. GeNIe & SMILE. 1998. URL: <http://genie.sis.pitt.edu/about.html#genie>. (дата звернення: 10.09.2024).

159. Landrum M. B., Normand S. L. T. Applying Bayesian ideas to the development of medical guidelines. *Statistics in Medicine*. 1999. Vol. 18(2), P. 117–137.

160. Lantz B. Machine Learning with R. Expert techniques for predictive modeling, 3rd Edition, Packt Publishing, 2019. 458 p.

161. Lauritzen S. L. Graphical Models. Oxford University Press, Oxford, UK, 1996. 308 p.

162. Lauritzen S. L., Spiegelhalter D. J. Local computations with probabilities on graphical structures and their application to expert systems. *Journal of the Royal Statistical Society*. 1988. Vol. 50, № 2. P. 157-224.

163. Lauritzen S. L. The EM algorithm for graphical association models with missing data. *Computational statistics and data analysis*. 1995. Vol. 19(2). P. 191-201.

164. Lecklin T., Ryömä R., Kuikka S. A Bayesian network for analyzing biological acute and longterm impacts of an oil spill in the Gulf of Finland. *Marine Pollution Bulletin* 62. 2011. P. 2822-2835.

165. Leibovici L., Paul M., Nielsen A.D., Tacconelli E., Andreassen S. The TREAT project: decision support and prediction using causal probabilistic networks. *International Journal of Antimicrobial Agents*. 2007. Vol. 30 (Suppl 1). P. S93-102.

166. Leith P. The rise and fall of the legal expert system. *European Journal of Law and Technology*. 2010. Vol. 1, Issue 1.

167. Lekkas S., Mikhailov L. Evolving fuzzy medical diagnosis of Pima Indians diabetes and of dermatological diseases. *Artificial Intelligence in Medicine*. 2010. № 50. P. 117-126.

168. Leyton-Brown K., Nudelman E., Shoham Y. Learning the empirical hardness of optimization problems: The case of combinatorial auctions // In Principles and Practice of Constraint Programming. 2002. P. 556-572.

169. Li D.-C., Liu C.-W., Hu S. C. A fuzzy-based data transformation for feature extraction to increase classification performance with small medical data sets. *Artificial Intelligence in Medicine*. 2011. Vol. 1, № 45. P. 45-52.

170. Li J., Aickelin U. A Bayesian Optimization Algorithm for the Nurse Scheduling Problem // Proc. Congress on Evolutionary Computation, Canberra, Australia. 2003. P. 2149-2156.

171. Li Peng-Cheng, Chen Guo-Hua, Dai Li-Cao, Zhang Li. A fuzzy Bayesian network approach to improve the quantification of organizational influences in HRA frameworks. *Safety Science*. 2012.

- Vol. 50, Issue 7. P. 1569-1583. URL: <https://doi.org/10.1016/j.ssci.2012.03.017>. (дата звернення: 10.09.2024).
172. Lizotte D., Wang T., Bowling M., Schuurmans D. Automatic gait optimization with Gaussian process regression // In Proc. of IJCAI. 2007. P. 944–949.
173. Long W. Temporal Reasoning for Diagnosis in a Causal Probabilistic Knowledge Base. *Artificial Intelligence in Medicine*. 1996. Vol. 8(3). P. 193–215.
174. Lott P. C., Korf I. StochHMM: a flexible hidden Markov model tool and C++ library. *Bioinformatics*. 2014. Vol. 30, Issue 11. P. 1625-1626. URL: <https://doi.org/10.1093/bioinformatics/btu057>. (дата звернення: 10.09.2024).
175. Lu T., Wang L., Zhao X. Review of Anomaly Detection Algorithms for Data Streams. *Applied Sciences*. 2023. Vol. 13, № 13. P. 6353. URL: <https://doi.org/10.3390/app13106353>. (дата звернення: 10.09.2024).
176. Lucas P. Bayesian networks in medicine : a model-based approach to medical decision making (2001). URL: <https://doi.org/10.1.1.22.4103>. (дата звернення: 10.09.2024).
177. Lucas P.J., de Bruijn N. C., Schurink K., Hoepelman A. A probabilistic and decision-theoretic approach to the management of infectious disease at the ICU. *Artificial Intelligence in Medicine*. 2000. Vol. 19(3). P. 251–279.
178. Lucas P. J. F., Boot H., Taal B. G. Computer-based decision-support in the management of primary gastric non-Hodgkin lymphoma, *Methods of Information in Medicine*. 1998. Vol. 37(3). P. 206–219.
179. Luciani D., Marchesi M., Bertolini G. The role of Bayesian Networks in the diagnosis of pulmonary embolism. *Journal of Thrombosis and Haemostasis*. 2003. Vol. 1(4). P. 698–707.
180. Luciani D., Cavuto S., Antiga L., Miniati M., Monti S., Pistolesi M., Bertolini G. Bayes pulmonary embolism assisted diagnosis: a new expert system for clinical use. *Emergency medicine journal*. 2007. Vol. 24(3). P. 157-164.

181. Luger G. Artificial Intelligence. Structures and Strategies for Complex Problem Solving: The Benjamin Cummings Publishing Company, Inc., 2005. 904 p.

182. Lughofer E. Single pass active learning with conflict and ignorance. *Evolving systems*. 2012. Vol. 4, № 3. P. 251-271.

183. Lytvyn V., Hryhorovych A., Hryhorovych V., Chyrun L., Vysotska V., Bublyk M. Medical Content Processing in Intelligent System of District Therapist // Proceedings of the 3rd International Conference on Informatics & Data-Driven Medicine (IDDM 2020), Växjö, Sweden, November 19–21. 2020. P. 415-429. URL: <http://ceur-ws.org/Vol-2753/paper29.pdf>. (дата звернення: 10.09.2024).

184. Lytvynenko V. I., Voronenko M. O., Kovalchuk O., Zhunisova U., Lytvynenko L. N. Bayesian methods application for the differential diagnosis of the chronic obstructive pulmonary disease. *CEUR Workshop Proceedings*. 2021. Vol. 2917. P. 851–862. URL: <http://ceur-ws.org/Vol-2917/paper48.pdf>. (дата звернення: 10.09.2024).

185. Lytvynenko V., Savina N., Voronenko M., Pashnina A., Baranenko R., Krugla N., Lopushynskyi I. Development of the Dynamic Bayesian Network to Evaluate the National Law Enforcement Agencies' Work // The crossing point of Intelligent Data Acquisition & Advanced Computing Systems and East & West Scientists (IDAACS-2019). 2019. P. 418-424.

186. Lytvynenko V., Naumov O., Voronenko M., Krejci J., Naumova L., Nikytenko D., Savina N. Dynamic Bayesian Networks Application for Evaluating the Investment Projects Effectiveness // Lecture Notes in Computational Intelligence and Decision Making. ISDMCI 2020. Advances in Intelligent Systems and Computing. 2021. Vol. 1246. P. 315-330. URL: https://doi.org/10.1007/978-3-030-54215-3_20. (дата звернення: 10.09.2024).

187. Lytvynenko V., Nikytenko D., Voronenko M., Krejci J., Savina N. Comparative Study of Noisy-MAX Nodes and General Nodes in Bayesian Network Models // Proceedings of the 4th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2020). Volume I: Main Conference Lviv, Ukraine, April 23-24, 2020. CEUR Workshop Proceedings 2604, CEUR-WS.org

2020. 2020. Vol. 2604. P. 56-66. URL: <http://ceur-ws.org/Vol-2604/> ISSN 1613-0073. (дата звернення: 10.09.2024).

188. Lytvynenko V., Savina N., Krejci J., Fefelov A., Lurie I., Voronenko M., Lopushynskyi I., Vorona P. Dynamic bayesian networks in the problem of localizing the narcotic substances distribution. *Springer, AISC*. 2019. Vol. 1080. P. 421-438.

189. Lytvynenko V., Savina N., Pyrtko M., Voronenko M., Baranenko R., Lopushynskyi I. Development, validation and testing of the Bayesian network to evaluate the national law enforcement agencies' work // Proc. 9nd Int. Conf. on Advanced Computer Information Technologies (ACIT' 2019). 2019. P. 252-256.

190. MacKay D. Information Theory, Inference, and Learning Algorithms. Cambridge University Press, 2003. 640 p.

191. Mackenzie G. The definition and classification of pneumonia. *Pneumonia*. 2016. Vol. 8, 14. 5 p. URL: <https://doi.org/10.1186/s41479-016-0012-z>. (дата звернення: 10.09.2024).

192. Mahendran N., Wang Z., Hamze F., Freitas N. Adaptive MCMC with Bayesian optimization. *Journal of Machine Learning Research - Proceedings Track*. 2012. Vol. 22. P. 751-760.

193. Maitra S. Prediction using Bayesian State Space Model. Stochastic and seasonal time-series prediction. 2020. URL: <https://towardsdatascience.com/natural-gas-price-prediction-using-bayesian-state-space-model-for-time-series-forecasting-f630dda1c808>. (дата звернення: 10.09.2024).

194. Mäntyniemi S., Haapasaari P., Kuikka S., Parmanne R., Lehtiniemi M., Kaitaranta J. Incorporating stakeholders' knowledge to stock assessment: Central Baltic herring. *Canadian Journal of Fisheries and Aquatic Sciences*. 2013. Vol. 70. P. 591-599.

195. Marchant R. and F. Ramos. Bayesian optimisation for intelligent environmental monitoring. In NIPS workshop on Bayesian Optimization and Decision Making, 2012.

196. Marsland S. Machine Learning: An Algorithmic Perspective. Palmerston North: Massey University, 2015. 452 p.

197. Martinez J., Little J. J., Freitas N. Bayesian optimization with an empirical hardness model for approximate nearest neighbour search // IEEE Winter Conference on Applications of Computer Vision. 2014.

198. Martinez-Cantin R., Freitas N., Doucet A., Castellanos J. A. Active policy learning for robot planning and exploration under uncertainty. *Robotics Science and Systems*. 2007.

199. McCorduck P., Cfe C. Machines Who Think. A Personal Inquiry into the History and Prospects of Artificial Intelligence. A K Peters/CRC Press : New York, 2004. 576 p.

200. McGrayne S. B. The theory that would not die: how Bayes' rule cracked the enigma code, hunted down Russian submarines, and emerged triumphant from two centuries of controversy. Yale University Press; MICHIELS. 2011. P. 228-233.

201. Molina J.-L., Pulido-Velázquez D., García-Aróstegui J. L., Pulido-Velázquez M. Dynamic Bayesian Networks as a Decision Support tool for assessing Climate Change impacts on highly stressed groundwater systems. *Journal of Hydrology*. 2013. Vol. 479. P. 113-129.

202. Molina J.-L., Bromley J., García-Aróstegui J. L., Sullivan C., Benavente J. Integrated water resources management of overexploited hydrogeological systems using Object-Oriented Bayesian Networks. *Environmental Modelling and Software*. 2010. Vol. 25. P. 383–397.

203. Moore A. Hidden Markov Models. Lecture notes, School of Computer Science, Carnegie Mellon University. URL: <https://perma.cc/K3HP-28T8>. (дата звернення: 10.09.2024).

204. Moore A. W., Lee M. S. Efficient algorithms for minimizing cross validation error // Machine Learning Proceedings. 1994. P. 190-198.

205. Murphy K.P. Dynamic Bayesian Networks: Representation, Inference And Learning. Thesis Paper. University Of California, Berkeley, 2002. 225 p.

206. Murty M. N., Jain A. K., Flynn P. J. Data clustering: a review. *ACM Computing Surveys*. 1999. Vol. 31(3). P. 264-323.

207. Nielsen A. Practical Time Series Analysis. Prediction with Statistics and Machine Learning. O'Reilly Media, Inc., 2019. 504 p.

208. Nikovski D. Constructing Bayesian networks for medical diagnosis from incomplete and partially correct statistics. *Knowledge and Data Engineering*. 2000. Vol. 12(4). P. 509–516.

209. Nilsson N. Artificial Intelligence: A New Synthesis. Morgan Kaufmann, 1998. 513 p.

210. Nur D., Allingham D., Rousseau J., Mengersen K., Mcvinish R. Bayesian hidden Markov Model for DNA segmentation: A prior sensitivity analysis. *Computational Statistics and Data Analysis*. 2009. Vol. 53, issue 5. P. 1873–1882. DOI: <https://doi.org/10.1016/j.csda.2008.07.007>.

211. O'Hagan A., Buck C. E., Daneshkhah A., Eiser J. R., Garthwaite P. H., Jenkinson D. J., Oakley J. E., Rakow T. Uncertain judgements: eliciting experts' probabilities. Wiley, 2006. 340 p.

212. Onusko E. Diagnosing secondary hypertension. *American Family Physician*. 2003. Vol. 67(1). P. 67–74.

213. Orfali R. The Essential Client/Server Survival Guide. New York: Wiley Computer Publishing, 1996. 676 p.

214. Quinlan J. R. Induction of Decision Trees. *Machine Learning*. 1986. Vol. 1(1). P. 81–106

215. Patel V. L., Shortliffe E. H., Stefanelli M., Szolovits P., Berthold M. R., Bellazzi R., Abu-Hanna A. The coming of age of artificial intelligence in medicine. *Artificial Intelligence in Medicine*. 2009. Vol. 46(1). P. 5–17.

216. Pearl J. A constrained propagation approach to probabilistic reasoning. *Uncertainty in Artificial Intelligence*. 1986. P. 357–370.

217. Pearl J. Probabilistic reasoning in intelligent systems: networks of plausible inference. San Mateo, CA (USA): Morgan Kauffmann Publishers, Inc., 1988. 550 p.

218. Peelen L., et al. Using hierarchical dynamic Bayesian networks to investigate dynamics of organ failure in patients in the Intensive Care Unit. *Journal of biomedical informatics*. 2010. Vol. 43, № 2. P. 273–286.

219. Plach M. Bayesian networks as models of human judgement under uncertainty: The role of causal assumptions in belief updating. *Kognitionswissenschaft*. 1999. Vol. 8, № 1. P. 30–39.

220. Polat K., Gunes S., Arshlan A. A cascade learning system for classification of diabetes disease: generalized discriminant analysis and

least square support vector machine. *Expert Systems with Applications*. 2008. № 34. P. 482–487.

221. Purkait N. Hands-On Neural Networks with Keras Design and Create Neural Networks Using Deep Learning and Artificial Intelligence Principles, Packt Publishing, EBook, 2019. 462 p.

222. Pyle D. Data Preparation for Data Mining. Morgan Kaufmann, 1999. 740 p.

223. Raeder T., Dalessandro B., Stitelman O., Perlich C., Provost F. Design principles of massive, robust prediction systems // Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2012. P. 1357-1365.

224. Rahikainen M., Helle I., Haapasaari P., Oinonen S., Kuikka S., Vanhatalo J., Mäntyniemi S., Hoviniemi K.-M. Towards Integrative Management Advice of Water Quality, Oil Spills, and Fishery in the Gulf of Finland: A Bayesian Approach. *Ambio*. 2014. Vol. 43(1). P. 115-123.

225. Ramanathan N. Applications of Hidden Markov Models. University of Maryland. Springer 2006. URL: <https://www.cs.umd.edu/~djacobs/CMSC828/ApplicationsHMMs.pdf>. (дата звернення: 10.09.2024).

226. Raymer M. L., Punch W. F., Goodman E. D., Kuhn L. A., Jain L. C. Dimensionality reduction using genetic algorithms // IEEE Transactions on Evolutionary Computation. 2000. Vol. 4 (2). P. 164-171.

227. Richards J. A., Xiuping Jia. Remote Sensing Digital Image Analysis: An Introduction. Berlin: Springer, 1999. 363 p.

228. Riggelsen C. Learning parameters of Bayesian networks from incomplete data via importance sampling. *International Journal of Approximate Reasoning*. 2006. Vol. 42. P. 69–83.

229. Roseline R., Jenitha G., Amirhtaraj H. Analysis and Application of Clustering Techniques in Data Mining. *International Journal of Computing Algorithm*. 2014. Vol. 3. P. 910-912.

230. Rutkowski L. Computational Intelligence. Methods and Techniques, Berlin-Heidelberg: Springer-Verlag, 2008. 514 p.

231. Sahan S., Polat K., Kodaz H., Gunes S. The medical applications of attribute weighted artificial immune system (AWAIS):

diagnosis of hearts and diabetes diseases // Proceedings of the 4th international conference on Artificial Immune Systems, Banff, AB, Canada. 2005. Vol. 3627. P. 456-468.

232.SAP News Desk. SAP News Desk IntelliCorp Announces Participation in SAP EcoHub. URL: <http://https://news.sap.com>. (дата звернення: 10.09.2024).

233.Sarmah S, Bhattacharyya D. An Effective Technique for Clustering Incremental Gene Expression data. *IJCSI International Journal of Computer Science Issues*. 2010. Vol. 7(3). P. 31-40.

234.Sarshar P., Radianti J., Granmo O-C., Gonzalez J. J. A Bayesian Network Model for Evacuation Time Analysis during a Ship Fire // IEEE Symposium Series on Computational Intelligence. 2013. P. 100-107.

235.Scott S. L., Varian H. R. Bayesian variable selection for nowcasting economic time series. *Economics of Digitization*, NBER Press, London, 2015. P. 119-136. DOI 10.7208/chicago/9780226206981.003.0004.

236.Scott S. L., Varian H. R. Predicting the present with Bayesian structural time series. *International Journal of Mathematical Modelling and Numerical Optimisation*. 2014. Vol. 5, P. 4–23. DOI: 10.1504/IJMMNO.2014.059942.

237.Scott S. L. Fitting Bayesian Structural Time Series with the BSTS R package. The Unofficial Google Data Science Blog, 2017. URL: <https://www.unofficialgoogledatascience.com/2017/07/fitting-bayesian-structural-time-series.html>. (дата звернення: 10.09.2024).

238.Sebastiani P., Ramoni M., Crea A. Profiling your Customers using Bayesian Networks. *ACM SIGKDD Explorations Newsletter*. 2000. Vol. 1(2). P 91-96. DOI:10.1145/846183.846205.

239.Smaili C., Najjar M. E., Charpillet F. Multi-sensor Fusion Method Using Dynamic Bayesian Network for Precise Vehicle Localization and Road Matching. *ICTAI*. 2007. Vol. 1. P. 146-151.

240.Snoek J., Larochelle H., Adams R. P. Practical Bayesian optimization of machine learning algorithms. *Advances in Neural Information Processing Systems*. 2012. P. 2951–2959.

241.Spirtes P., Glymour C., Scheines R. Causation, prediction, and search. MIT press, 2001. 546 p.

242. Srinath K. Anomaly Detection: Techniques to detect outliers. 2020. URL: <https://towardsdatascience.com/anomaly-detection-techniques-to-detect-outliers-fea92047a222>. (дата звернення: 10.09.2024).

243. Srinivas N., Krause A., Kakade S. M., Seeger M. Gaussian process optimization in the bandit setting: No regret and experimental design // International Conference on Machine Learning. 2010. P. 1015–1022.

244. Steel M. Bayesian Time Series Analysis. *Macroeconometrics and Time Series Analysis*. 2010. P. 35–45. URL: <https://perma.cc/578D-XCVH>. (дата звернення: 10.09.2024).

245. Stringer J. R., Beard C. B., Miller R. F., Wakefield A. E. A new name (*Pneumocystis jiroveci*) for *Pneumocystis* from humans. *Emerging Infectious Diseases*. 2002. Vol. 8, № 9. P. 891–896.

246. Suman P. Comparison and Analysis of Various Clustering Methods in Data mining On Education data set using the weak tool. *International Journal of Emerging Trends & Technology in Computer Science (IJETTCS)*. 2014. Vol. 3. P. 240–244.

247. Suzuki J. Learning Bayesian belief networks based on the MDL principle: an efficient algorithm using the branch and bound technique. // IEICE Trans. on Information and Systems. 1999. P. 356–367.

248. Swersky K., Snoek J., Adams R. P. Multi-task Bayesian optimization // Advances in Neural Information Processing Systems. 2013. Vol. 26. P. 2004–2012.

249. Tahboub K. A. Intelligent Human–Machine Interaction Based on Dynamic Bayesian Networks Probabilistic Intention Recognition. *Journal of Intelligent and Robotic Systems*. 2006. Vol. 45, № 1. P. 31–52.

250. Temurtas H., Yumusak N., Temurtas F. A comparative study on diabetes disease diagnosis using neural networks. *Expert Systems with Applications*. 2009. № 36. P. 8610–8615.

251. Theiss S., Rose G., Schwarz S., Grunwald J., Raith M. Predicting acute neurological diseases with Bayesian networks // Intelligent Systems Design and Applications (ISDA), 10th International Conference. 2010. Vol. 11. P. 121–125.

252. Thornton C., Hutter F., Hoos H. H., Leyton-Brown K. Auto-WEKA: Combined selection and hyperparameter optimization of classification algorithms // *Knowledge Discovery and Data Mining*. 2013. P. 847–855.

253. Turuta O., Perova I., Deineko A. Evolving flexible neuro-fuzzy system for medical diagnostic tasks. *International Journal of Computer Science and Mobile Computing IJCSMC*. 2015. Vol. 4(8). P. 475-480.

254. Uusitalo L. Advantages and challenges of Bayesian networks in environmental modelling. *Ecological Modelling*. 2007. Vol. 203(3-4). P. 312-318.

255. Uusitalo L., Kuikka S., Romakkaniemi A. Estimation of Atlantic salmon smolt carrying capacity of rivers using expert knowledge. *ICES Journal of Marine Science*. 2005. Vol. 62(4). P. 708–722.

256. Van der Gaag L. C., Coup'e V. M. Sensitivity analysis for threshold decision making with Bayesian belief networks // *AI*IA 99: Advances in Artificial Intelligence, Lecture Notes in Artificial Intelligence*. 2000. P. 37 – 48.

257. Van Gerven M. A. J., Taal B. G., Lucas P. J. F. Dynamic Bayesian networks as prognostic models for clinical patient management. *Journal of biomedical informatics*. 2008. Vol. 41, № 4. P. 515-529.

258. Varis O., Kettunen J. DAVID influence diagram processing system in environmental management. *Environmental Software*. 1988. Vol. 3(2). P. 81-84.

259. Varis O., Kuikka S. Joint use of multiple environmental assessment models by a Bayesian metamodel. *The Baltic salmon case. Ecological Modelling*. 1997. Vol. 102(2-3). P. 341-351.

260. Veiga M. H., Ged F. G. Mathematical Foundations of Machine Learning EBook, the University of Michigan, 2021. 175 p.

261. Verma M., Srivastava M., Chack N., Kumar D., Gupta G. A Comparative Study of Various Clustering Algorithms in Data Mining. *International Journal of Engineering Research and Applications (IJERA)*. 2012. Vol. 2(3). P. 1379-1384.

262. Viera J., Neutze D. M. Diagnosis of Secondary Hypertension: An Age-Based Approach. *Am Fam Physician*. 2010. Vol. 82(12). P. 1471–1478.

263. Vignotto E., Engelke S. Extreme value theory for anomaly detection – the GPD classifier. *SpringerLink*. 2020. Vol. 23. P.501-520. URL: <https://link.springer.com/article/10.1007/s10687-020-00393-0>.

264. Voronenko M., Zhunisova U., Smailova S., Lytvynenko L., Savina N., Mulesa P., Lytvynenko V. Using Bayesian Methods in the Task of Modeling the Patients' Pharmacoresistance Development // *IAPGOŚ*. 2022. Vol. 12(2). P. 77-82. DOI: 10.35784/iapgos.2968

265. Voronenko M. A., Nikytenko D. V., Krejci J. V., Savina N. B., Lytvynenko V. I. Assessing the possibility of a country's economic growth using static Bayesian network models // *Proceedings of the Third International Workshop on Computer Modeling and Intelligent Systems (CMIS-2020)*, Zaporizhzhia, Ukraine, April 27-May 1, 2020. P. 462-473.

266. Voronenko M., Lurie I., Boskin O., Zhunisova U., Baranenko R., Lytvynenko V. Using Bayesian Methods for Predicting the Development of Children Autism // *IEEE International Conference on Advanced Trends in Information Theory (ATIT'19)*, Kyiv, Ukraine, 2019. P. 525-529. DOI: 10.1109/ATIT49449.2019.9030523.

267. Voronenko M., Kovalchuk O., Lytvynenko L., Vyshemyrska S., Krak I. An Expert System Prototype for the Early Diagnosis of Pneumonia. *Lecture Notes on Data Engineering and Communications Technologies*. 2022, Vol. 77. P. 714–728. DOI: 10.1007/978-3-030-82014-5_49.

268. Wang Z., Shakibi B., Jin L., Freitas N. Bayesian multi-scale optimistic optimization // *Proceedings of the Seventeenth International Conference on Artificial Intelligence and Statistics*. 2014. Vol. 33. P. 1005–1014.

269. Wang Z., Zoghi M., Matheson D., Hutter F., Freitas N. Bayesian optimization in high dimensions via random embeddings // *International Joint Conference on Artificial Intelligence*. 2013. P. 1778–1784.

270. Wang X., Qu H., Liu P., Cheng Y. A self-learning expert system for diagnosis in traditional Chinese medicine. *Expert Systems with Applications*. 2004. Vol. 26(4). P. 557–566.

271. Weber P., Jouffe L. Complex system reliability modelling with Dynamic Object Oriented Bayesian Networks (DOOBN). *Reliability Engineering and System Safety*. 2006. Vol. 91. P. 149–162.

272. Weidl G., Madsenb A. L., Israelson S. Applications of object-oriented Bayesian networks for condition monitoring, root cause analysis and decision support on operation of complex continuous processes. *Computers and Chemical Engineering*. 2005. Vol. 29. P. 1996–2009.

273. Wiegerinck W. A. J. J., Kappen H. J., Braak E. W. M. T., Burg W. J. P. P., Nijman M. J., Neijt Y. L. O. Approximate inference for medical diagnosis. *Pattern Recognition Letters*. 1999. Vol. 20(11–13). P. 1231–1239.

274. World Health Organization. Pneumococcal vaccines. *Pneumococcal vaccines. Weekly Epidemiologic Record* 2003; 14:110-9

275. Xiang Y., Pant B., Eiseny A., Beddoes M. P., Poolez D. Multiply Sectioned Bayesian Networks For Neuromuscular Diagnosis. *Artificial Intelligence in Medicine*. 1993. Vol. 5(4). P. 293–314.

276. Yao X. Q., Zhu H., She Z. S. A dynamic Bayesian network approach to protein secondary structure prediction. *BMC bioinformatics*. 2008. Vol. 9. P. 1-13.

277. Yogatama D., Smith N.A. Bayesian optimization of text representations. arXiv preprint arXiv:1503.00693. 2015.

278. Zhang Y., Sohn K., Villegas R., Pan G., Lee H. Improving object detection with deep convolutional networks via Bayesian optimization and structured prediction // IEEE Computer Vision and Pattern Recognition Conference. 2015. 6 p.

279. Zhang Z., Kwok J., Yeung D. Surrogate maximization (minimization) algorithms for AdaBoost and the logistic regression model // Proceedings of the twenty-first international conference on machine learning (ICML 2004). 2004. 117 p.

280. Zhao Kai, Ying Shi, Zhang Linlin, Hu Luokai Achieving business process and business rules integration using SPL. *Future*

Information Technology and Management Engineering (FITME). 2013. Vol. 2. P. 329—332. DOI: 10.1109/fitme.2010.5656297.

281. Zheng Y., Kwoh C. K. Improved MDL Score for Learning of Bayesian Networks // Proceedings of the international conference on artificial intelligence in science and technology, AISAT. 2004. P. 98-103.

282. Zou M., Conzen S. D. A new dynamic Bayesian network (DBN) approach for identifying gene regulatory networks from time course microarray data. *Bioinformatics*. 2005. Vol. 21. № 1. P. 71-79.

283. Zweig G. G. Speech Recognition with Dynamic Bayesian Networks: a PhD dissertation. University of California, Berkeley, 1998. 169 p.

284. Аксой С. Параметричні моделі Частина IV: Байєсівські мережі вірувань. Весна 2007 року. URL: www.cs.bilkent.edu.tr/~saksoy/courses/cs551/slides/cs551_parametric4.pdf. (дата звернення: 10.09.2024).

285. Бен-Гал І. Байєсівські мережі. Кафедра промислової інженерії. Тель-Авівський університет. URL: <http://www.eng.tau.ac.il/~bengal/BN.pdf>, <http://www.dcs.qmw.ac.uk/~norman/BBNs/BBNs.htm>. (дата звернення: 10.09.2024).

286. Бідюк П. І., Гожий О. П. Ймовірісно-статистичні методи моделювання і прогнозування: монографія. Миколаїв: Вид-во ЧДУ ім. Петра Могили, 2014. 440 с.

287. Бідюк П. І., Калініна І. О., Гожий О. П. Байєсівський аналіз даних: монографія. Херсон: Книжкове видавництво ФОП Вишемирський В.С., 2021. 208 с.

288. Бідюк П. І., Терентьев О. М., Коновалюк М. М. Байєсівські мережі в технологіях інтелектуального аналізу даних. *Штучний інтелект*. 2010. №2, С. 104-113.

289. Го Хайпен. «Динамічні байєсівські мережі». Серпень 2002 року. URL: www.kddresearch.org/Groups/Probabilistic-Reasoning/258,1, Slide 1. (дата звернення: 10.09.2024).

290. Електронний ресурс URL: https://ukrayinska.libretexts.org/Інженерна/Промислове_та_системного_машинобудування/Книга%3A_Динаміка_та_контроль_хіміч

них_процесів_(Woolf)/13%3A_Статистика_та_ймовірність_фону/13.05%3A_Байєсівська_теорія_мережі. (дата звернення: 10.09.2024).

291. Електронний ресурс. URL: http://en.Wikipedia.org/wiki/Bayesian_network. (дата звернення: 10.09.2024).

292. Електронний ресурс. URL: <https://stat.gov.ua/uk/datasets/innovatsiyna-diyalnist-pidpryyemstv-1>. (дата звернення: 10.09.2024).

293. Електронний ресурс. URL: <http://mmf.lnu.edu.ua/ar/1739>. (дата звернення: 10.09.2024).

294. Електронний ресурс. URL: https://uk.wikipedia.org/wiki/%D0%86%D1%80%D0%B8%D1%81%D0%B8_%D0%A4%D1%96%D1%88%D0%B5%D1%80%D0%B0. (дата звернення: 10.09.2024).

295. Жернова П. Є. Нечітка кластеризація потоків даних за умов невідомої кількості кластерів: дис. ... канд. техн. наук : 05.13.23. Харків. 2019. 142 с.

296. Байєсівські мережі в системах підтримки прийняття рішень : навчальний посібник / Згуровський М. З., Бідюк П. І., Терентьев О. М., Просянкін-Жарова Т. І. Київ : ТОВ «Видавниче Підприємство «Едельвейс», 2015. 300 с.

297. Калініна І. О. Моделі та інформаційні технології ймовірно-статистичного аналізу нелінійних нестационарних процесів в задачах машинного навчання : дис. ... д-ра. техн. наук : 05.13.06. 2024. 344 с.

298. Кузнєцова Н. В. Динамічно-рівномірна дискретизація даних у гібридних мережах Байєса. *Вісник Хмельницького Національного Університету*. 2011. Т.3(180), №5. С. 247–251.

299. Нідермайер Д. Вступ до байєсівських мереж та їх сучасних застосувань. URL: <http://www.niedermayer.ca/papers/bayesian/bayes.html>. (дата звернення: 10.09.2024).

300. Ніл М., Фентон Н., Кравець М. Використання байєсівських мереж для моделювання очікуваних та несподіваних операційних втрат. *Аналіз ризиків*. 2005. Т. 25, №4. URL:

<http://www.dcs.qmul.ac.uk/~norman/papers/oprisk.pdf>. (дата звернення: 10.09.2024).

301. Джексон П. Введение в экспертные системы. М. : Вильямс, 2001. 624 с.

302. Сілі Р. Байєсівські мережі зробили легко. Тенденції розвитку додатків. 4 грудня 2007 р. URL: [www.adtmag.com/стаття.aspx?id=10271 &сторінка=](http://www.adtmag.com/стаття.aspx?id=10271&сторінка=). (дата звернення: 10.09.2024).

303. Субботін С. О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень : навч. посіб. Запоріжжя : ЗНТУ, 2008. 341 с.

304. Фрідман Н., Лініал М., Нахман І., Пеер Д. Використання байєсівських мереж для аналізу даних виразів. *Журнал обчислювальної біології*. 2000. Т. 7, № 3/4. С. 601–620. URL: www.sysbio.harvard.edu/csb/ramanathan_lab/iftach/papers/FLNP1Full.pdf. (дата звернення: 10.09.2024).

305. Черняк Є. Байєсівські мережі без сліз. *Журнал AI*. 1991. С. 10-21.

НАВЧАЛЬНЕ ЕЛЕКТРОННЕ ВИДАННЯ

**ВОРОНЕНКО Марія Олександрівна
ЛИТВИНЕНКО Володимир Іванович
ВИШЕМИРСЬКА Світлана Вікторівна**

Навчальний посібник

ПРОЕКТУВАННЯ СТАТИЧНИХ ТА ДИНАМІЧНИХ МОДЕЛЕЙ НА ОСНОВІ БАЙЄСІВСЬКИХ МЕРЕЖ

**ISBN 978-617-8187-32-3
(електронне видання)**



Підписано до видання 29.10.2024 р. Формат 60×84/8.

Гарнітура Palatino Linotype.

Ум. друк. арк. 39,53. Обл.-вид. арк. 42,51.

Замовлення № 3115.

Книжкове видавництво ФОП Вишемирський В.С.

Свідоцтво про внесення до державного реєстру суб'єктів видавничої справи:

серія ХС № 48 від 14.04.2005

видано Управлінням у справах преси та інформації

73000, Україна, м. Херсон, вул. Соборна, 2.

Тел. +38(050) 133-10-13.

e-mail: printvvs@gmail.com