

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Київський національний університет будівництва і архітектури

Конспект лекцій

з дисципліни «Інформаційні системи діагностики в будівництві»

для здобувачів першого (бакалаврського) рівня вищої освіти
за спеціальністю 126 «Інформаційні системи та технології»
освітньої програми «Інформаційні системи та технології»

д.т.н., проф. Терейковська Л.О.

Київ 2025

Змістовний модуль 1. Базові положення в області діагностування в будівництві

Лекція 1. Загальна характеристика інформаційних систем в області діагностування в будівництві

План:

1. Нормативна база в області діагностування в будівництві.
2. Загальна структура інформаційної системи діагностування.
3. Основні етапи діагностування в будівництві.
4. Характеристики відомих систем діагностики в будівельній галузі.

Питання 1. Нормативна база в області діагностування в будівництві

У сучасному будівництві системи діагностики відіграють ключову роль у забезпеченні надійності та довговічності об'єктів. Використання діагностичних моделей дозволяє оцінити технічний стан елементів будівельних конструкцій, виявити дефекти, а також прогнозувати подальший розвиток пошкоджень. Діагностування будівельних конструкцій - це процес оцінки технічного стану споруд з метою виявлення дефектів, визначення залишкового ресурсу та прийняття рішень щодо ремонту, підсилення або демонтажу.

Основні нормативні документи, що регулюють проведення діагностування в Україні:

1. ДСТУ-Н Б В.1.2-18:2016 «Настанова з оцінювання технічного стану будівель і споруд». Це один із ключових документів, що визначає класифікацію технічного стану: справний, працездатний, обмежено працездатний, аварійний. Описує процедуру обстеження: візуальну інспекцію, інструментальні методи, розрахунок несучої здатності, складання технічного звіту. Враховує вплив експлуатаційних, кліматичних та техногенних факторів.

2. ДБН В.1.2-14:2018 «Загальні принципи забезпечення надійності та конструктивної безпеки будівель і споруд». Визначає базові вимоги до безпеки будівельних конструкцій. Включає принципи довготривалої надійності, стійкості, захисту від прогресуючого руйнування. Передбачає обов'язковість обстеження при зміні функціонального призначення об'єкта, реконструкції або після дії надзвичайних факторів (землетрус, пожежа тощо).
3. ДСТУ Б В.2.6-200:2014 «Методи обстеження залізобетонних конструкцій». Регламентує процедури діагностування залізобетонних елементів (балок, плит, колон). Включає методики визначення міцності бетону (відбійні молотки, ультразвук, свердління кернів). Надає рекомендації щодо виявлення корозії арматури та тріщин.

Стандарт ISO 13822:2010 – Basis for design of structures - Assessment of existing structures. («Основи проектування конструкцій, включаючи оцінку стану вже збудованих об'єктів»). Цей стандарт надає загальні принципи і керівні вказівки щодо оцінки технічного стану та залишкової несучої здатності вже збудованих конструкцій. Він використовується при необхідності: продовжити термін експлуатації будівлі; визначити необхідність ремонту чи посилення; адаптувати будівлю до нових умов навантаження або функцій; оцінити наслідки ушкоджень, стихійних лих або аварій.

Нормативна база передбачає також вимоги до організацій, які проводять діагностику (наявність атестованого персоналу, сертифікованого обладнання, відповідних методик). Результати діагностування мають оформлятися у формі технічного звіту, що включає: опис конструкцій та їх дефектів; фотографічну фіксацію; висновок про технічний стан; рекомендації щодо подальшої експлуатації або ремонтних заходів. У випадку обстеження перед реконструкцією або зміною функції звіт стає обов'язковою частиною проектної документації.

Питання 2. Загальна структура інформаційної системи діагностування

Інформаційна система діагностування - це модульна програмно-апаратна система, яка виконує збір, зберігання, аналіз та інтерпретацію даних про технічний стан будівельних конструкцій.

1. Структурні компоненти системи

1.1 Підсистема збору даних (сенсорний рівень)

Джерела даних: сенсори деформацій (тензометрія), датчики вібрацій, температури, вологості, ультразвукові, електромагнітні прилади, візуальні дані (камери, БПЛА). Дані можуть надходити в реальному часі (моніторинг) або періодично (інспекції).

1.2 Підсистема попередньої обробки даних

Фільтрація шумів, нормалізація даних. Виявлення пропущених або некоректних значень. Структурування у формати, зручні для аналізу (таблиці, бази даних, графи).

1.3 Аналітичне ядро - використання математичних моделей.

1.3.1 Нейронні мережі (Neural Networks). Класифікація станів конструкцій за патернами даних. Розпізнавання візуальних дефектів (тріщин, плям, корозії) з фото/відео. Прогнозування зміни показників (деформації, осідання) у часі. Архітектури нейромереж:

- MLP (багатошарова перцептронна мережа) - для табличних даних.
- CNN (згорткова мережа) - для обробки зображень.
- RNN/LSTM - для аналізу динамічних рядів даних.

1.3.2 Марківські моделі (Markov Chains / Hidden Markov Models). Побудова ймовірнісної моделі деградації конструкцій. Оцінка перехідних ймовірностей між технічними станами. Наприклад, справний → задовільний → обмежено працездатний → аварійний. Прогнозування часу до критичного стану. Використовувані моделі:

- Дискретний марківський ланцюг для об'єктів із чітко фіксованими станами.
- Приховані марківські моделі - коли прямі вимірювання не дають повної картини.

1.4 Підсистема прийняття рішень (експертний рівень). Об'єднує результати аналізу з моделей (нейромереж, марківських моделей) у формі рекомендацій:

- «Потрібно посилення колони С1 протягом 6 місяців»;
- «Імовірність відмови в найближчі 2 роки - 15%».

Може мати нечіткий логічний модуль, що формалізує експертні знання. Наприклад, *"Якщо тріщина > 2 мм і арматура оголена, тоді ймовірний стан - аварійний з рівнем впевненості 0.9."*

1.5 Виведення результатів у вигляді: 3D-моделей конструкції з позначенням дефектів; графіків зміни параметрів у часі; карт ризику; цифрових паспортів конструкцій.

Користувач: інженер, технічний інспектор, керівник об'єкта.

База знань. Зберігає історичні дані обстежень. Використовується для навчання нових моделей, порівняння схожих об'єктів.

Потік даних у системі: Вимірювання → Передача до сервера → Попередня обробка → Аналіз нейромережею/Марківською моделлю → Результати виводяться → Прийняття рішення/формування звіту.

Переваги такої архітектури:

- Висока точність діагностики навіть у складних випадках.
- Прогнозування проблем ще до появи критичних дефектів.
- Застосування штучного інтелекту зменшує залежність від суб'єктивного людського фактору.
- Можливість віддаленого моніторингу в реальному часі.

Питання 3. Основні етапи діагностування в будівництві

Процес діагностування включає такі ключові етапи:

1. Визначення об'єкта обстеження та постановка завдання.
2. Візуальне обстеження.
3. Проведення вимірювань та інструментальних досліджень.
4. Фіксація дефектів.

5. Обробка та інтерпретація даних.
6. Аналіз результатів вимірювань.
7. Побудова моделей стану конструкцій.
8. Оцінка технічного стану.
9. Класифікація стану.
10. Розробка рекомендацій.
11. Ремонт, реконструкція, посилення або виведення з експлуатації.
12. Формування звіту.
13. Повна технічна документація за результатами діагностування.

Питання 4. Характеристики відомих систем діагностики в будівельній галузі

У сучасній практиці застосовуються як універсальні системи моніторингу, так і спеціалізовані рішення для окремих типів споруд:

1. Structural Health Monitoring Systems (SHMS). Використовуються для моніторингу мостів, хмарочосів, тунелів. Включають велику кількість сенсорів, працюють у режимі реального часу. Приклад: SHMS мосту «Золоті Ворота» у Сан-Франциско.

2. Trimble 4D Control. Геодезична система моніторингу зміщень. Висока точність позиціювання (до міліметра). Часто використовується для тунелів і гірничих робіт.

3. SCADA-системи (Supervisory Control and Data Acquisition). Забезпечують централізований контроль параметрів конструкцій. Мають модулі сповіщення про аварійні стани.

4. COWI Bridge Management System (Данія). Включає базу даних стану мостів по всій країні. Забезпечує планування інспекцій та ремонту.

5. Національні розробки (Україна). Система моніторингу мостів у Києві.

Лекція 2. Діагностичні моделі

План:

1. Загальна характеристика діагностичних моделей.
2. Моделі на основі нечіткої логіки.
3. Підходи до використання марківських моделей при діагностуванні.
4. Моделі на основі штучного інтелекту.

Питання 1. Загальна характеристика діагностичних моделей.

Сучасне діагностування будівель і споруд - це не лише збір даних про тріщини, деформації чи корозію, а й аналітична обробка великого обсягу інформації, прогнозування майбутнього технічного стану, автоматизований контроль без участі людини. Для цього традиційних інженерних методів вже недостатньо – використовуються інтелектуальні підходи, зокрема:

1. Марківські моделі. Дають змогу моделювати ймовірнісну деградацію конструкцій у часі. Враховують, що технічний стан об'єкта залежить не від усієї історії, а лише від попереднього стану (властивість Маркова). Наприклад: прогнозування переходу споруди з працездатного стану в аварійний - із розрахунком часу до відмови.

2. Нечітка логіка. У будівництві часто стикаємось із неповною або нечіткою інформацією: наприклад, «дефект значний», «тріщина помірна». Нечітка логіка дає змогу формалізувати експертні судження, перетворити їх у числову оцінку. Створюються нечіткі правила типу: "Якщо тріщина довга і розкрита, то стан конструкції - поганий із високою ймовірністю."

3. Штучні нейронні мережі. Нейромережі здатні виявляти складні закономірності між вхідними параметрами (наприклад, вологість, деформації, температура) та технічним станом конструкцій. Їх застосовують для: класифікації станів; прогнозування розвитку дефектів; обробки зображень (наприклад, аналіз фото тріщин); систем розпізнавання аномалій у режимі реального часу.

Питання 2. Моделі на основі нечіткої логіки.

Діагностичні моделі на основі нечіткої логіки (fuzzy logic) є ефективним інструментом для моделювання складних систем, у яких точні математичні залежності невідомі або описуються неточними (нечіткими) поняттями. У будівельній діагностиці це особливо актуально, оскільки оцінка стану конструкцій часто базується на експертних судженнях, що формулюються у вигляді термінів «задовільний», «незадовільний», «критичний» тощо.

Основні поняття нечіткої логіки:

- Нечітка множина (fuzzy set) - множина, в якій кожен елемент має ступінь належності в діапазоні $[0;1]$.
- Функція належності $\mu_A(x)$ - визначає, наскільки елемент x належить нечіткій множині A .

Наприклад, для оцінки деформації балки як «малої»:

$$\mu_{\text{мала}}(x) = \begin{cases} 1, & x \leq 1 \\ \frac{2-x}{1}, & 1 < x < 2 \\ 0, & x \geq 2 \end{cases}$$

Структура діагностичної системи на основі нечіткої логіки:

Етап 1. Перетворення вхідних фізичних параметрів (напруження, вологість, деформація тощо) у нечіткі значення за допомогою функцій належності.

Етап 2. Застосування бази правил типу:

If (напруження = високе) and (вологість = висока) then (стан = критичний)

Етап 3. Агрегація та композиція правил – комбінування результатів усіх правил у єдину оцінку.

Етап 4. Перетворення нечіткої оцінки у чітке число (наприклад, за методом центру ваги):

$$x^* = \frac{\int x \cdot \mu(x) dx}{\int \mu(x) dx}$$

Переваги нечітких моделей

- Гнучкість при роботі з неточними або експертними даними.

- Можливість інтерпретації результатів (на відміну від «чорного ящика» нейронних мереж).
- Простота оновлення системи (достатньо змінити правила або функції належності)

Обмеження нечітких моделей: вимагають ручного налаштування правил і функцій; не завжди підходять для великих обсягів динамічних даних.

Питання 3. Підходи до використання марківських моделей при діагностуванні.

Марківські моделі застосовуються для опису стохастичних процесів - таких, де майбутній стан системи залежить лише від поточного стану, а не від передісторії (властивість Маркова). Це дозволяє спростити моделювання складних технічних об'єктів, у тому числі й будівельних конструкцій, які з часом переходять з одного технічного стану в інший (наприклад, від «нормального» до «аварійного»).

Марківський процес моделюється як послідовність станів $S_1, S_2, \dots, S_n$, які змінюються в дискретні моменти часу:

$S = \{s_1, s_2, \dots, s_n\}$ - множина станів об'єкта (наприклад: справний, зношений, передаварійний, аварійний).

Ймовірність переходу зі стану i до стану j :

$$P_{ij} = P(S_{t+1} = s_j | S_t = s_i)$$

Вся система описується матрицею перехідних ймовірностей:

$$P = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1n} \\ P_{21} & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix}$$

Підходи до використання в діагностиці

1. *Діагностика на основі часу перебування у станах (дискретні марківські ланцюги).* Підходить для аналізу довготривалої поведінки об'єкта. Дозволяє оцінити імовірність переходу у критичний стан протягом фіксованого інтервалу експлуатації. Застосовується для прогнозування строку служби. Приклад: модель з чотирма станами: «нормальний», «задовільний», «незадовільний», «аварійний». За даними з експлуатації об'єкта формуються перехідні ймовірності.

2. *Безповоротні моделі з поглинаючим станом.* Один з можливих станів (наприклад, «аварійний») є поглинаючим: після потрапляння у нього система вже не змінюється. Дає змогу оцінити середній час до відмови (Mean Time To Failure, MTTF). Розрахунок середнього часу до поглинання:

$$\mathbf{t} = (I - Q)^{-1} \cdot \mathbf{1}$$

де Q - матриця перехідних ймовірностей для всіх непоглинаючих станів, I - одинична матриця, $\mathbf{1}$ - вектор одиниць.

3. *Контроль деградації з перехідними станами (марківські ланцюги з деградацією).* Використовується, коли об'єкт поступово зношується. Дозволяє враховувати швидкість деградації. Можна враховувати технічне обслуговування, яке частково повертає об'єкт у кращий стан.

4. *Марківські рішення (Markov Decision Processes, MDP).* Розширення звичайних марківських моделей із урахуванням управлінських рішень. Для кожного стану визначено набір дій, кожна з яких має свою ймовірність переходу та «нагороду» (вигоду або витрату). Використовується для оптимізації стратегії обслуговування, ремонту, інспекцій. Застосування MDP вимагає формалізації вартості відмов, обслуговування, простою тощо.

Джерела даних для побудови марківської моделі:

- Статистичні дані з технічного обстеження будівель.
- Дані сенсорів (наприклад, вібраційних датчиків).
- Історичні звіти про ремонт, аварії, обстеження.

- Інформація експертів (може використовуватись для первинного оцінювання ймовірностей).

Марківські моделі є потужним інструментом в діагностуванні технічного стану об'єктів у будівництві, особливо коли: важливо враховувати часову еволюцію стану; є невизначеність і ймовірнісний характер змін; потрібна оптимізація дій з обслуговування. Їх застосування дозволяє не лише здійснювати поточну оцінку стану конструкцій, але й прогнозувати розвиток несправностей та оптимізувати управління ресурсами на обслуговування та ремонт.

Питання 4. Моделі на основі штучного інтелекту.

З розвитком цифрових технологій дедалі більшого поширення набувають моделі на основі ШІ, зокрема нейронні мережі, алгоритми машинного навчання, нечіткі моделі та гібридні підходи. Основні види моделей на основі ШІ:

1. Нейронні мережі. Використовуються для розпізнавання образів, виявлення аномалій, прогнозування стану конструкцій. Переваги: здатність до навчання, узагальнення даних, робота з неструктурованою інформацією (зображення, сигнали). Недоліки: потреба в великому обсязі навчальних даних, складність інтерпретації результатів.

2. Нечітка логіка (fuzzy logic). Застосовується у випадках, коли стан об'єкта описується нечіткими поняттями ("добрий", "задовільний", "критичний"). Використовується для побудови експертних систем, що оперують знаннями у формі правил типу "IF-THEN".

3. Алгоритми машинного навчання (ML) Методи класифікації (Decision Trees, SVM, k-NN), регресії, кластеризації (k-means). Використовуються для аналізу великих обсягів даних, формування прогнозних моделей.

4. Гібридні моделі. Поєднання методів, наприклад, нейронна мережа + нечітка логіка (нейро-нечіткі системи). Покращують точність, надійність і адаптивність моделей.

Побудова діагностичних моделей

- Визначення вхідних параметрів (температура, вологість, напруження, деформація).
- Збір навчальних даних (з результатів обстежень, сенсорів, історичних записів).
- Навчання моделі, її валідація та тестування.
- Інтеграція в інформаційно-аналітичну систему діагностики.

Приклади застосування діагностичних моделей

- Оцінка стану залізобетонних балок на основі вібраційних характеристик (нейронні мережі).
- Виявлення тріщин у фасаді за допомогою комп'ютерного зору (згорткові нейронні мережі).
- Прогноз технічного стану дорожнього полотна на основі історичних даних експлуатації (машинне навчання).
- Класифікація дефектів у теплоізоляції (нечітка логіка).

Переваги та обмеження моделей III. Переваги: висока точність при достатній кількості навчальних даних; можливість роботи в реальному часі; адаптивність до нових умов експлуатації. Обмеження: висока складність реалізації; потреба у значному обсязі даних для навчання; низька прозорість прийнятих рішень (особливо у глибоких нейромережах).

Лекція 3. Марківські діагностичні моделі

План:

1. Види ланцюгів Маркова.
2. Математичне забезпечення марківського процесу.
3. Розрахунок перехідних ймовірностей ланцюга Маркова.
4. Приклади застосування ланцюга Маркова в області діагностування об'єктів в будівельній галузі.

Питання 1. Види ланцюгів Маркова.

Ланцюги Маркова застосовуються для прогнозування технічного стану об'єктів будівництва з метою забезпечення надійності та довговічності конструкцій. Приклади застосування:

1. Прогнозування залишкового ресурсу залізобетонних конструкцій.
2. Моніторинг мостів, тунелів та інших об'єктів інфраструктури.
3. Визначення оптимального терміну технічного обслуговування.
4. Підтримка ухвалення рішень у системах експертної діагностики.

Ланцюги Маркова - це математичні моделі, що описують послідовність станів системи, яка змінюється у часі за ймовірнісними законами, причому наступний стан залежить лише від поточного (а не від всієї історії). Основні види:

1. Дискретні ланцюги Маркова з дискретним часом
 - Час змінюється дискретно: $t = 0, 1, 2, \dots$
 - Використовуються, коли діагностика або моніторинг виконується з певною періодичністю.

Станами можуть бути: "справний", "задовільний", "аварійний" тощо.

2. Безперервні марківські процеси
 - Час - неперервний.
 - Застосовуються для систем, що змінюють стан у будь-який момент часу (наприклад, аварії в реальному часі).
3. Приховані марківські моделі (Hidden Markov Models, HMM)

- Справжній стан об'єкта не спостерігається безпосередньо, але можна зробити висновок на основі непрямих ознак (сигнали датчиків, шум, деформації тощо).
- Використовується у задачах розпізнавання технічного стану за сенсорними даними.

Питання 2. Математичне забезпечення марківського процесу.

Основні компоненти дискретного ланцюга Маркова:

1. Набір станів:

$S = \{s_1, s_2, \dots, s_n\}$, наприклад,

$S = \{\text{справний, задовільний, недопустимий, аварійний}\}$

2. Матриця перехідних ймовірностей P .

Кожен елемент P_{ij} - це ймовірність переходу зі стану i у стан j за один крок:

$$P = \begin{pmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ p_{n1} & p_{n2} & \dots & p_{nn} \end{pmatrix}, \quad \text{де } \sum_{j=1}^n p_{ij} = 1$$

3. Вектор початкового розподілу ймовірностей:

$$\pi^{(0)} = [\pi_1^{(0)}, \pi_2^{(0)}, \dots, \pi_n^{(0)}]$$

4. Розподіл ймовірностей після t кроків: $\pi^{(t)} = \pi^{(0)} \cdot P^t$

Питання 3. Розрахунок перехідних ймовірностей ланцюга Маркова

Щоб визначити ймовірність перебування системи в певному стані через t кроків, необхідно:

1. Задати початковий стан (вектор $\pi^{(0)}$)

$$\pi^{(0)} = [1, 0, 0, 0] \Rightarrow \text{система повністю справна на початку.}$$

2. Побудувати матрицю P за інженерними даними або експертною оцінкою. Приклад матриці:

$$P = \begin{pmatrix} 0.85 & 0.1 & 0.05 & 0 \\ 0 & 0.8 & 0.15 & 0.05 \\ 0 & 0 & 0.7 & 0.3 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

3. Обчислити розподіл за кілька кроків

$$\pi^{(1)} = \pi^{(0)} \cdot P, \quad \pi^{(2)} = \pi^{(1)} \cdot P = \pi^{(0)} \cdot P^2$$

Це дає змогу передбачити технічний стан об'єкта в майбутньому.

Питання 4. Приклади застосування ланцюгів Маркова в діагностиці будівельних об'єктів

Марківська модель прогнозує ризик руйнування, а поєднанні з нейронними мережами формує розширену експертну оцінку.

Приклад 1. Оцінка залишкового ресурсу конструкцій. На основі марківського моделювання визначають, з якою ймовірністю об'єкт залишатиметься справним через 5, 10, 20 років. Наприклад: для залізобетонної балки, яка зазнає корозії арматури.

Приклад 2. Прогнозування технічного стану. Після кожного обстеження оновлюється перехідна матриця. Це дозволяє уточнити, коли потрібен капітальний ремонт або підсилення конструкцій.

Приклад 3. Планування технічного обслуговування. Наприклад, якщо ймовірність переходу до стану «аварійний» протягом 2 років $> 20\%$, система автоматично формує план втручань.

Приклад 4. Моніторинг мостів, естакад, інфраструктурних об'єктів. Встановлені сенсори подають дані в реальному часі.

Змістовний модуль 2. Застосування нейронних мереж в задачах діагностування в будівельній галузі

Лекція 4. Передумови використання нейронних мереж в задачі діагностування

План:

1. Загальні підходи до застосування нейронних мереж в процесі діагностування.
2. Формулювання задачі діагностування як задачі класифікації образів.
3. Формулювання задачі діагностування як задачі кластеризації образів.

Питання 1. Загальні підходи до застосування нейронних мереж в процесі діагностування.

Сучасні будівельні об'єкти характеризуються складною структурою та багатофакторним впливом зовнішніх і внутрішніх умов. Ефективна діагностика їх технічного стану потребує обробки великого обсягу даних, які надходять від сенсорів, сканерів, ультразвукових приладів тощо.

Нейронні мережі - це один із найефективніших інструментів штучного інтелекту, що дозволяє виявляти складні залежності у великих масивах даних. У діагностиці технічного стану будівельних конструкцій нейронні мережі застосовуються для аналізу сигналів, даних сенсорів, візуальних зображень та іншої інформації, що характеризує технічний стан об'єкта. Завдяки здатності до навчання, нейромережі можуть узагальнювати досвід експертів або статистичні дані з обстежень, формуючи власну модель прийняття рішень.

Основні переваги нейромереж у діагностиці:

- автоматичне виявлення прихованих закономірностей;
- адаптивність до нових даних;
- здатність працювати з неповними або зашумленими даними;
- можливість вирішення задач, які важко формалізувати аналітично.

Питання 2. Формулювання задачі діагностування як задачі класифікації образів

Класифікація образів - один із базових підходів в машинному навчанні, коли об'єкт потрібно віднести до одного з наперед заданих класів. У випадку діагностики будівельних конструкцій «образом» виступає множина ознак, що описує стан об'єкта (наприклад, фото тріщини, спектр ультразвукової хвилі, вектор сенсорних показників).

Загальна постановка задачі

Маємо множину вхідних векторів $X=\{x_1, x_2, ..., x_n\}$, кожен з яких відповідає певному технічному стану, та відповідну множину міток класів $Y=\{y_1, y_2, ..., y_n\}$, де $y_i \in \{\text{Клас_1, Клас_2, ..., Клас_k}\}$. Задача полягає в тому, щоб побудувати функцію $f(x)$, яка для нового вектора ознак передбачає відповідний клас.

Приклад. Вхід: спектр вібрацій балки при навантаженні (вектор ознак).
Класи: {«нормальний стан», «мікротріщина», «критичне ушкодження»}.
Нейромережа навчається на прикладах і класифікує нові дані.

Нейронна мережа навчається на основі прикладів, де кожен вхідний вектор має мітку класу. Навчена модель може бути застосована для автоматичної оцінки нових даних. Найчастіше використовуються такі архітектури нейронних мереж:

- багатошаровий персептрон (MLP),
- згорткові нейронні мережі (CNN - для аналізу зображень)
- рекурентні мережі (RNN - для часових сигналів).

Питання 3. Формулювання задачі діагностування як задачі кластеризації образів

Коли мітки класів невідомі або діагностична інформація є новою (наприклад, об'єкт спостерігається вперше), використовують методи кластеризації. Це - задача без вчителя, де нейронна мережа або алгоритм виявляє групи подібних сигналів.

Одним з найпоширеніших підходів є використання самоорганізовних карт Кохонена (SOM). Цей тип нейромережі дозволяє візуалізувати структуру даних та виявляти аномалії або нові стани системи. Інший варіант - використання автокодерів (autoencoders) для зменшення розмірності даних перед подальшою кластеризацією методами типу k-середніх.

У діагностиці кластеризація використовується для:

- виявлення нових, невідомих типів ушкоджень;
- попереднього аналізу даних без участі експерта;
- визначення груп схожих станів конструкції для подальшої обробки.

Загальна постановка задачі

Є набір векторів $X = \{x_1, x_2, \dots, x_n\}$. Необхідно розбити їх на k кластерів $C_1, C_2, \dots, C_k$, де об'єкти в межах одного кластеру мають бути максимально схожими, а міжкластерна відстань - максимальною.

Приклад. Вхід: температурні та вібраційні характеристики з сенсорів по всій будівлі. Результат кластеризації: виділено 3 стани - нормальний, потенційно аварійний, критичний. Користувач або експерт надає інтерпретацію знайдених кластерів.

Методи кластеризації:

- k-середніх (k-means);
- DBSCAN (враховує щільність даних, виявляє шуми);
- Ієрархічна кластеризація;
- Autoencoder + кластеризація в латентному просторі - сучасний підхід з використанням глибинного навчання.

Нейронні мережі ефективно підтримують процес автоматизованої діагностики у будівництві. Класифікація дозволяє відносити конструкції до наперед відомих технічних станів. Кластеризація відкриває можливість виявлення нових, раніше не класифікованих сценаріїв пошкодження. Вибір методу залежить від наявності розмічених даних, типу вхідних ознак і цілей дослідження.

Лекція 5. Використання багат шарового персептрону в задачі діагностування

План:

1. Структура багат шарового персептрону.
2. Математичне забезпечення багат шарового персептрону.
3. Особливості навчання.
4. Визначення архітектурних параметрів багат шарового персептрону в задачі діагностування.

Питання 1. Структура багат шарового персептрону

В загальному випадку багат шаровий персептрон (БШП) представляє собою НМ, яка складається із декількох послідовно з'єднаних між собою шарів штучних нейронів. Типова структура БШП показана на рис. 1.




Рис. 1. Типова структура багат шарового персептрону

Зовнішня інформація спочатку поступає у вхідний шар, що складається тільки із сенсорних елементів (вхідних нейронів). Основними завданнями цього шару є прийом та розповсюдження вхідної інформації по іншим шарам НМ. Далі знаходиться один або декілька схованих шарів нейронів (СШН), в яких власне і відбувається основна обробка інформації. Результати цієї обробки відображаються у вихідному шарі. Відзначимо, що при підрахунках

кількості шарів вхідний шар не враховують. Наприклад, двошаровий персептрон (ДШП) складається із вхідного, одного схованого та вихідного шару. Як правило, кожен нейрон СШН приймає всі вихідні сигнали попереднього шару, а його вихідний сигнал надсилається всім нейронам наступного шару. Особливістю БШП є наявність тільки прямих гальмуючих або збуджуючих зв'язків між сусідніми шарами нейронів. При цьому кожен нейрон в СШН характеризується унікальним вектором вагових коефіцієнтів.

Для вхідних нейронів досить часто використовується лінійна, лінійна з погашенням від'ємних імпульсів та порогова функції активації.

Характеристики функцій активації штучних нейронів

Функція	Формула	Область використання
Лінійна	$F(NE T) = NE T \alpha$	Вхідні нейрони всіх типів НМ
Логістична (сигмоїдальна)	$F(NE T) = \frac{1}{1 + e^{-\alpha NE T}}$	Усі типи мереж з прямим поширенням сигналу, включаючи БШП
Лінійна з погашенням від'ємних імпульсів	$F(NE T) = \begin{cases} NE T \alpha, \exists NE T > 0, \\ 0, \exists NE T \leq 0 \end{cases}$	Вхідні нейрони всіх типів НМ
Порогова	$F(NE T) = \begin{cases} 1, \exists NE T \geq 0, \\ 0, \exists NE T < 0 \end{cases}$	Одношаровий персептрон, НМ Хопфілда
Гіперболічний тангенс	$F(NE T) = \frac{e^{\alpha NE T} - e^{-\alpha NE T}}{e^{\alpha NE T} + e^{-\alpha NE T}}$	Всі типи мереж з прямим розповсюдженням сигналу, включаючи БШП
Гаусова крива	$F(NE T) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{NE T^2}{2\sigma^2}}$	Проміжні нейрони для ймовірнісних НМ та РБФ
Гістерезис	$F(NE T) = \begin{cases} 1, \exists \theta > NE T, \\ NE T \alpha, \exists \theta > NE T > 0, \\ 0, \exists NE T \leq 0 \end{cases}$	НМ Хеммінга

Для схованих нейронів монотонні функції активації не впливають на результати розпізнавання даних. Але використання певного типу функції може підвищити інформативність результатів розпізнавання. Наприклад, сигмоїдальна функція активації дозволяє трактувати результати класифікації, як ймовірність віднесення вхідного образу до відповідного класу. Тому для схованих нейронів найчастіше використовують порогову та сигмоїдальну функцію активації.

Питання 2. Математичне забезпечення багатошарового персептрону

В більшості випадків вихідні елементи БШП виконують тільки розрахунок власних вхідних сигналів, тому функція активації для них не потрібна. Розрахунок основних параметрів j -го нейрону в l -му СШН можна провести так:

$$\begin{aligned} NET_j^l &= \sum_{i=1}^{K_j^l} w_{ij}^l x_{ij}^l, \\ OUT_j^l &= F(NET_j^l - \theta_j^l), \\ x_{ij}^{l+1} &= OUT_j^l, \end{aligned}$$

де i – номер входу, j – номер нейрону в шарі, l – номер СШН, K_j^l – кількість вхідних зв'язків j -го нейрону в l -му шарі, w_{ij}^l – ваговий коефіцієнт i -го входу j -го нейрону в l -му шарі, θ_j^l – пороговий рівень активації j -го нейрону в l -му шарі, x_{ij}^l – i -й вхідний сигнал нейрону в l -му шарі, F – функція активації, OUT_j^l – вихідний сигнал j -го нейрону в l -му шарі, NET_j^l – сумарний вхідний сигнал j -го нейрону в l -му шарі.

Відзначимо, що для першого СШН кількість вхідних зв'язків нейрону дорівнює кількості нейронів у вхідному шарі. Для інших СШН, K_j^l дорівнює кількості нейронів в попередньому СШН. Кожен СШН виконує нелінійне перетворення від лінійної комбінації сигналів попереднього шару. В цілому БШП може сформувати на виході довільну багатовимірну функцію (f), від

множини вхідних параметрів $\{x\}$:

$$f(x) = F\left(\sum_{i=1}^{K^N} w_i^N \dots \left(\sum_{i=1}^{K^2} w_i^2 F\left(\sum_{i=1}^{K^1} w_i^1 x - \theta^1\right) - \theta^2\right) \dots - \theta^N\right),$$

де x – вектор вхідних параметрів, w_i^N – вектор вагових коефіцієнтів нейронів в N -му шарі, θ^N – вектор порогів активації нейронів в N -му шарі, K^N – кількість вхідних зв'язків в N -му шарі, N – кількість схованих шарів.

Таким чином, БШП може розрахувати вихідний вектор y для деякого вхідного вектору x . Відповідно, умовою задачі, яка може бути поставлена БШП, повинна бути множина вхідних векторів (вхідних образів):

$$x \in \{x^1, \dots, x^i, \dots, x^S\},$$

де i – номер вхідного вектору, а S – кількість вхідних векторів.

Кожен із вхідних векторів складається із N_1 компонент, тобто:

$$x^i = \begin{pmatrix} x_1^i \\ \dots \\ x_{N_1}^i \end{pmatrix},$$

Як правило кількість компонент вхідного вектору дорівнює кількості нейронів у вхідному шарі. Вирішенням задачі буде множина вихідних векторів

$$y \in \{y^1, \dots, y^i, \dots, y^S\}.$$

Кожен з вихідних векторів складається із N_0 компонент:

$$y^i = \begin{pmatrix} y_1^i \\ \dots \\ y_{N_0}^i \end{pmatrix},$$

де N_0 – кількість нейронів у вихідному шарі персептрону.

Питання 3. Особливості навчання

Навчання БШП виконується методом "навчання з вчителем" та полягає в визначенні таких вагових коефіцієнтів зв'язків нейронів СШН, які дозволяють найкраще вирішувати поставлену задачу. Процес навчання

починається з ініціалізації вказаних вагових коефіцієнтів випадковими величинами. Після цього на вхід НМ подаються параметри, що відповідають відомим образам. Відзначимо, що з точки зору БШП відомий образ означає відомий набір значень вихідних параметрів. Якщо реальні вихідні параметри відрізняються від цих значень, то вагові коефіцієнти нейронів схованих шарів уточнюються за допомогою спеціальних алгоритмів. Найбільш популярним із них є алгоритм оберненого розповсюдження помилок, що базується на оцінці помилок нейронів i -го СШН, як зваженої суми помилок наступного $(i+1)$ шару. При цьому помилки останнього (вихідного) шару нейронів відомі.

Під час навчання інформація розповсюджується від нижніх шарів до верхніх, а оцінки помилок мережі в зворотному напрямку. Процес навчання багатоітераційний і полягає в мінімізації функції помилки персептрона на всій множині навчальної вибірки. Пошук мінімуму помилки може реалізовуватись методом градієнтного спуску.

Хоча алгоритм оберненого розповсюдження помилок знайшов широке практичне застосування, він має декілька серйозних недоліків. Основним недоліком є низька збіжність алгоритму, яка пояснюється тим, що в багатьох випадках локальний напрям градієнту не співпадає з напрямком до глобального мінімуму. При цьому уточнення вагових коефіцієнтів виконується незалежно для кожної пари образів із навчальної вибірки. Відповідно зменшення помилки персептрону для деякої пари образів може призвести до збільшення цієї ж помилки для інших пар. З цієї точки зору взагалі немає ніяких гарантій знаходження мінімальної помилки. Крім того, метод оберненого розповсюдження помилок може застосовуватись тільки при використанні гладких функцій активації нейронів СШН. Для зменшення вказаних недоліків використовуються модифікації методу, які полягають в застосуванні різних функцій оцінки помилки БШП та процедур визначення напрямку та величини кроку пошуку оптимуму. Достатньо відомі та апробовані методи пов'язаних градієнтів, Левенберга-Маркара, швидкого навчання за допомогою зменшення розмірності обчислень на базі

використання теорії рядів Вольтера, швидкого розповсюдження та дельта-метод. Також відомі вдалі спроби проводити навчання БШП за допомогою генетичних алгоритмів. В багатьох випадках перевагою цих методів є більш висока швидкість навчання відносно методу оберненого розповсюдження помилок. Однак не достатня точність цих методів, велика кількість управляючих параметрів, а також деякі обмеження на структуру БШП ускладнюють їх практичне використання. Крім того, в випадку великого обсягу навчальних даних, серед яких є надлишкові, точність визначення вагових коефіцієнтів нейронів за допомогою методу оберненого розповсюдження помилок є суттєво вищою. Доведено, що помилку апроксимації ДШП можливо оцінити так:

$$\varepsilon_a \sim \frac{N_x}{W},$$

де N_x - кількість компонент вхідного вектора (розмірність вхідного вектору), W - кількість синаптичних зв'язків.

Аналіз літературних джерел вказує на те, що збільшення кількості синаптичних зв'язків, а значить і нейронів в СШН, призводить до більш точної апроксимації невідомої функції. Негативною стороною збільшення кількості нейронів є виникнення перенавчання.

Загальна схема алгоритму зворотнього розповсюдження помилки:

1. Визначення допустимої похибки, навчального прикладу та ініціалізація вагових коефіцієнтів.
2. Розрахунок вихідного сигналу кожного із нейронів.
3. Розрахунок похибки навчання.
4. Порівняння похибки навчання з допустимою похибкою.
 - Якщо похибка не більша за допустиму, то навчання закінчується.
 - Якщо похибка навчання менша за допустиму, то перехід на п.5.
5. Розрахунок корегуючих параметрів.
6. Корекція вагових коефіцієнтів.
7. Перехід на п.2.

Питання 4. Визначення архітектурних параметрів багатошарового перцептрону в задачі діагностування

У задачах діагностики будівельних конструкцій необхідно аналізувати складні багатовимірні дані з сенсорів, візуальних спостережень, ультразвукових сигналів тощо. Один із популярних методів – використання БШП, що є базовим типом штучної нейронної мережі. Правильний вибір архітектурних параметрів БШП критично впливає на точність, швидкість навчання та здатність моделі узагальнювати нові дані.

Основні архітектурні параметри БШП:

1. Кількість входів (input layer).

Визначається числом ознак (сенсорних або обчислених параметрів), що описують технічний стан об'єкта.

Приклад: якщо для діагностики використовуються 5 типів сенсорних даних (вібрація, температура, вологість, тиск, акустика), то мережа має 5 входів.

2. Кількість прихованих шарів і нейронів.

Кількість прихованих шарів: найчастіше 1–2 шари є достатніми для більшості задач діагностики.

Кількість нейронів у шарі: залежить від складності задачі, кількості вхідних параметрів і кількості вихідних класів.

Емпіричні правила:

- кількість нейронів $\approx (\text{кількість входів} + \text{кількість виходів}) / 2$;
- бажано уникати надмірного збільшення нейронів, щоб не виникла переадаптація (overfitting);
- для складніших задач можна використовувати мережу з архітектурою типу "пляшкове горло" (bottleneck).

3. Функції активації


Використовуються для забезпечення нелінійності:

ReLU - стандарт для прихованих шарів;

Sigmoid або Softmax - для вихідного шару, залежно від типу задачі (бінарна чи багатокласова класифікація).


Функція ReLU

$$f(x) = \max(0, x)$$



Функція Sigmoid

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$



Функція Softmax

$$S(y)_i = \frac{\exp(y_i)}{\sum_{j=1}^n \exp(y_j)}$$




Рис. 2. Функції активації нейронів

4. Вихідний шар. Кількість нейронів = кількість класів або станів, які ми хочемо розпізнати.

Приклад:

- 2 стани (норма/ушкодження) → 1 вихід (з сигмоїдною активацією);
- 3 стани (норма/мікротріщина/критичне ушкодження) → 3 виходи з softmax.

Приклад практичної постановки. Задача: виявлення тріщин у залізобетонній плиті на основі спектральних даних вібрації.

Вхідні параметри: 10 характеристик з вібросенсорів.

Вихід: 3 класи стану конструкції.

Рекомендована архітектура:

- Вхідний шар: 10 нейронів
- Прихований шар 1: 16 нейронів (ReLU)
- Прихований шар 2: 8 нейронів (ReLU)
- Вихідний шар: 3 нейрони (Softmax)

Параметри слід оптимізувати експериментально (через крос-валідацію).

Варто проводити регуляризацію (Dropout, L2) для уникнення переадаптації. Важливо враховувати реальні обмеження: обсяг навчальних даних, апаратні ресурси, час реакції системи.

Лекція 6. Використання ймовірнісної нейронної мережі в області діагностування

План:

1. Структура мережі PNN.
2. Математичне забезпечення мережі PNN.
3. Визначення архітектурних параметрів PNN.

Питання 1. Структура мережі PNN

Мережа PNN (Probabilistic Neural Network) - це вид штучної нейронної мережі, яка реалізує байєсівський класифікатор на основі функції Парзена (Parzen window). Функціонування таких ймовірнісних НМ базується на передумові, що вирішення задач класифікації та регресії можливе завдяки оцінці щільності ймовірності сумісного розподілу вхідних та вихідних даних. В задачах класифікації виходи НМ інтерпретуються як оцінки ймовірності того, що образ належить деякому класу. Для вирішення задач НМ повинна оцінити щільність ймовірності віднесення образу до кожного із класів, порівняти ці ймовірності між собою та вибрати найбільш ймовірний клас.




Рис. 2 Архітектурна схема мережі PNN

Мережа PNN складається із чотирьох шарів нейронів, кількість яких визначається структурою учбових даних. Кількість вхідних нейронів дорівнює

кількості ознак класу. Кількість елементів шару образів дорівнює кількості учбових образів. Кількість елементів шару додавання дорівнює кількості класів. Вхідний шар та шар образів складають повнозв'язну структуру.

Архітектурна схема мережі PNN, що розподілу образів на два класи А та Б показана на рис. 2. При цьому вектор образу складається із 3 компонент, а кількість учбових образів дорівнює 4. Образи, що відповідають нейронам №1, №2 та №3 відносяться до класу А, а образ №4 відноситься до класу Б. Позначення ВЕ означає вихідний елемент (нейрон) мережі. Елемент шару образів пов'язаний тільки з тим елементом шару додавання, якому відповідає клас образу.

Переваги PNN: можливість якісної класифікації на невеликих наборах учбових даних; низька чутливість до помилкових даних в учбових наборах; ймовірнісний зміст класифікації, що значно полегшує інтерпретацію вихідних результатів; безітераційність; простота математичного забезпечення та програмної реалізації.

Недоліки PNN: якісна класифікація образів можлива тільки в діапазоні навчальних даних; низька узагальнююча здатність; потенційно висока обчислювальна ресурсоемкість; можливість використання тільки в задачах класифікації; тривалий термін розпізнавання.

Недоліки, пов'язані з поганим узагальненням результатів можна нівелювати за рахунок оптимізації множини навчальних даних та модифікації архітектури НМ. Слід враховувати, що традиційною сферою використання мережі PNN є попередня обробка даних для виділення із них найбільш інформативних параметрів. Тому використання PNN для вирішення практичних задач має хороші перспективи. Однак необхідно організувати ефективну системи збору та обробки статистичної інформації, адаптувати мережу до розпізнавання як можна більш широкої номенклатури класів, пристосувати її до донавчання в процесі експлуатації для розпізнавання нових класів та інтегрувати PNN до сумісного використання з іншими типами НМ.

Питання 2. Математичне забезпечення мережі PNN

Правило класифікації образу x як k -го класу

$$h_k c_k f_k(x) > h_i c_i f_i(x), i \in \{N\},$$

де $\{N\}$ – множина всіх класів,

i – довільний клас,

h_k та h_i – апіорні ймовірності класифікації образу,

c_k та c_i – ціна помилки класифікації образу,

$f_k(x)$ і $f_i(x)$ – функції щільності ймовірності для класів k та i .

Активність j -го нейрону шару образів (θ_j^o) розраховується так:

$$\theta_j^o = \sum_{i=1}^N \exp\left(\frac{-(w_{i,j} - x_i)^2}{\sigma^2}\right),$$

де x – невідомий образ, x_i – i -а компонента невідомого образу, N – кількість компонент вхідного вектора-образу, σ – радіус функції Гауса.

Як правило, при вирішенні задач із області комп'ютерної діагностики величина радіусу функції Гауса лежить в межах від 0,1 до 1. Для спрощення розрахунків можливо прийняти, що $\sigma^2=0,5$.

Для зв'язків, що входять в елемент шару образів вагові коефіцієнти встановлюються такими ж, як складові частини відповідного учбового вектора-образу. Таким чином, всі параметри мережі PNN безпосередньо визначаються учбовими даними. Тому навчання мережі відбувається відносно швидко. Вагові коефіцієнти зв'язків, що входять в нейрони шару додавання та в вихідний елемент дорівнюють 1. Нейронам шару додавання характерна лінійна функція активації. Активність j -го нейрону шару сумування (θ_j^s):

$$\theta_j^s = \frac{\sum_{i=1}^N \theta_i^o}{N},$$

де N – кількість нейронів шару образів, пов'язаних з j -им нейроном шару додавання, θ_j^o – активність i -ого нейрону шару образів, пов'язаного з j -им нейроном шару додавання.

Значення активності нейрону шару сумування дорівнює ймовірності віднесення вхідного образу до класу, що відповідає даному нейрону. Задачею вихідного елементу є тільки визначення нейрону шару сумування з максимальною активністю. Тому на практиці вихідний елемент може бути реалізований не тільки як нейрон.

Важливим позитивним моментом процесу навчання мережі PNN є наявність тільки одного управляючого параметру навчання, значення якого вибирається користувачем. Фактично цим параметром є радіус функції Гауса. Вказано, що мережі PNN мало чуттєві до величини радіусу функції Гауса.

Питання 3. Визначення архітектурних параметрів PNN

Архітектурні параметри PNN:

1. Кількість нейронів у вхідному шарі (Input layer). Визначається розмірністю вхідного вектора ознак $\bar{x}$. Якщо ознак n , то вхідний шар має n нейронів.
2. Кількість нейронів шару образів (pattern layer) дорівнює кількості учбових образів.
3. Кількість елементів шару додавання (summation layer) дорівнює кількості класів.
4. Кількість нейронів у вихідному шарі (output layer)
5. Основний архітектурний параметр - ширина вікна згладжування σ
 - σ - параметр ширини ядра Парзена (гауссове ядро).
 - Визначає, наскільки локально або глобально узагальнюється інформація про шаблони.
 - Мале $\sigma \rightarrow$ модель "запам'ятовує" зразки (overfitting),
 - Велике $\sigma \rightarrow$ модель сильно згладжує (underfitting).

Підбір σ :

- Зазвичай підбирається за допомогою **крос-валідації** або емпірично.
- Іноді використовуються **різні** σ для різних класів або шаблонів.

Додаткові параметри, що впливають на архітектуру

- Попередня обробка ознак: стандартизація (z-score), нормалізація (мін-макс).
- Метрики відстані: зазвичай використовується евклідова, але можливе використання Манхеттенської або іншої метрики.
- Зважування шаблонів: шаблонні нейрони можуть мати ваги, що враховують достовірність джерела (у випадку нечітких або неточних правил).

Від правильного вибору цих параметрів залежить ефективність класифікації та здатність мережі до узагальнення.

Лекція 7. Використання експертних знань для навчання нейронних мереж

План:

1. Представлення експертних знань у вигляді продукційних правил.
2. Алгоритм внесення продукційного правила в мережу PNN.
3. Метод застосування продукційних правил в мережі PNN.

Питання 1. Представлення експертних знань у вигляді продукційних правил.

Продукційні правила - це основа експертних систем. Типовий приклад продукційного правила для визначення деякого класу:

$$\text{If } X_1 = a_1 \wedge X_2 = a_2 \wedge \dots \rightarrow Y,$$

де X_i – i -ий вхідний параметр, Y – вихід НМ.

Приклад для будівельної діагностики:

If вологість > 85% AND температура < 5°C THEN ймовірність корозії висока

Структура мережі PNN, що призначена для розпізнавання двох класів, показана на рис. 4.




Рис. 4 Структура PNN, що призначена для розпізнавання двох класів

Питання 2. Алгоритм внесення продукційного правила в мережу PNN.

Для внесення в PNN експертних знань про правило класифікації на класи А та В необхідно:

- визначити в шарі додавання два нейрони А та В, котрі співвідносяться з класами;
- внести в шар образів новий нейрон;
- співвіднести для нього вагові коефіцієнти вхідних зв'язків з величинами параметрів, які відповідають заданому прикладу;
- встановити для нового нейрону вихідний зв'язок з відповідним нейроном шару додавання А або В.

Оскільки PNN навчається на прикладах, продукційне правило потрібно перетворити у навчальні зразки:

1. Інтерпретація правила

Розшифрувати правило у вигляді вектора ознак $\bar{x}_r$ та відповідного класу C_k

2. Створення навчального зразка

Правило "IF ... THEN Клас А" $\rightarrow$ додається як точка $\bar{x}_r \in C_A$ до тренувального набору.

3. Додавання до шару образів

Новий нейрон у шарі образів з центром у $\bar{x}_r$. Він буде активуватись, коли нові вектори схожі на $\bar{x}_r$.

4. Коригування параметра σ

Визначити ширину вікна Парзена (впливає на ступінь генералізації правила).

Питання 3. Метод застосування продукційних правил в мережі PNN.

1. Використовуючи технології обробки експертної інформації визначити:

- Множину параметрів, що описують класи, котрі мають бути розпізнані.
- Множину класів, котрі мають бути розпізнані.

- Множину продукційних правил.

2. Визначити множину вхідних параметрів PNN, що співвідносяться з параметрами, що описують класи.

3. Визначити в шарі додавання стільки нейронів, скільки класів повинна розпізнавати PNN.

4. Використовуючи наведений алгоритм навчання мережі визначити структуру та вагові коефіцієнти зв'язків.

Процес класифікації в PNN:

1. Подання вхідного вектора $\vec{x}$, тобто вектора ознак об'єкта, що потрібно класифікувати.

2. Обчислення відгуку шаблонів

Для кожного шаблону $\vec{x}_{ki}$

$$\phi(\vec{x}, \vec{x}_{ki}) = \exp \left(-\frac{\|\vec{x} - \vec{x}_{ki}\|^2}{2\sigma^2} \right)$$

3. Агрегація ймовірностей по кожному класу

$$P_k(\vec{x}) = \frac{1}{N_k} \sum_{i=1}^{N_k} \phi(\vec{x}, \vec{x}_{ki})$$

4. Вибір класу

$$\hat{C} = \arg \max_k P_k(\vec{x})$$

Лекція 8. Використання топографічної карти Кохонена для кластеризації образів при діагностуванні у сфері будівництва

План:

1. Задача кластеризації даних при діагностуванні.
2. Карта Кохонена.
3. Алгоритм самоорганізації карти Кохонена.

Питання 1. Задача кластеризації даних при діагностуванні.

У процесі технічної діагностики будівельних конструкцій збирається велика кількість даних: рівень деформацій, вологість матеріалу, температура, вібрації, результати неруйнівного контролю тощо. Більшість цих даних є непозначеними - тобто немає явної інформації про те, до якої категорії (класу) вони належать. У таких випадках застосовується кластеризація.

Мета кластеризації:

- Виявлення прихованих закономірностей у даних.
- Групування об'єктів з подібними характеристиками.
- Пошук аномальних зон (наприклад, ділянок конструкції з незвичними параметрами).
- Підготовка до подальшої класифікації або експертної оцінки.

Типові приклади кластеризації в будівництві:

- Поділ елементів конструкції за рівнем ушкоджень.
- Виявлення типових і нетипових режимів роботи конструкції.
- Групування за спектральними характеристиками вібрацій.

Питання 2. Карта Кохонена.

Карта Кохонена (SOM) - це нейронна мережа без вчителя, яка виконує кластеризацію шляхом самоорганізації. SOM проєктує багатовимірні дані на двовимірну сітку (наприклад, 10×10), зберігаючи топологію (відношення близькості між векторами).

Особливості карти Кохонена:

- Підходить для візуалізації високовимірних даних.
- Забезпечує кластеризацію без потреби у мітках (непідконтрольне навчання).

- Дає змогу будувати топологічну карту стану об'єкта.

Архітектура карти Кохонена:

Вхідний шар - вектор ознак $\vec{x} = (x_1, x_2, \dots, x_n)$.

Вихідний шар - двовимірна решітка нейронів, кожен з яких має власний ваговий вектор $\vec{w}_i$ тієї ж розмірності.




Рис. 5 Загальна структура карти Кохонена

Особливості навчання карта Кохонена:

- без вчителя (використовуються не марковані дані);
- алгоритм «переможець забирає все»;
- при корекції вагових коефіцієнтів нейрона враховується інформації щодо його розташування.

Особливості розпізнавання – можливість відображення результатів у вигляді топографічної карти.

Приклад застосування в будівництві. Задача: визначення типів

ушкоджень у залізобетонних конструкціях на основі даних вібраційного аналізу та вологості. Етапи вирішення: збір даних за допомогою сенсорів; побудова карти Кохонена; відображення на карті кластерів, що відповідають типам станів: "нормальний", "локальні мікротріщини", "ризик розшарування"; інженер отримує візуальну карту об'єкта з підсвіченими зонами підвищеного ризику.

Питання 3. Алгоритм самоорганізації карти Кохонена.

Алгоритм навчання карти Кохонена:

1. Визначається:

- Кількість вихідних нейронів (нейронів шару Кохонена) – K .
- Кількість вхідних нейронів – M .

2. Ініціалізація вагових коефіцієнтів, за умов:

- При нормалізації навчальних прикладів в межах від -1 до 1:

$$|w_{ij}| \leq \frac{1}{\sqrt{M}}$$

- При нормалізації навчальних прикладів в межах від 0 до 1:

$$0,5 - \frac{1}{\sqrt{M}} |w_{ij}| \leq 0,5 + \frac{1}{\sqrt{M}}$$

3. Подача навчального прикладу x_i та розрахунок:

$$R_j = \sqrt{\sum_{i=1}^M (x_i - w_{ij})^2}$$

4. Визначення нейрону переможця

$$\|x_i - w_{ij}\| = \min_j \{\|x_i - w_{ij}\|\}$$

5. Корекція вагових коефіцієнтів для нейрону переможця

$$w_{ij}^{(q+1)} = w_{ij}^{(q)} + v (x_i - w_{ij}^{(q)})$$

Цикл повторюється з кроку 3 до виконання умов закінчення:

- вичерпано задана гранична кількість епох навчання;
- не відбулося значної зміни вагових коефіцієнтів в межах заданої протягом останньої епохи навчання;
- вичерпано заданий граничний фізичний час навчання.

Алгоритм самоорганізації карти Кохонена:

1. Визначається початкова структура мережі, що складається з вхідних нейронів та одного вихідного нейрону, вагові коефіцієнти якого дорівнюють компонентам першого навчального прикладу.
2. Визначається критична відстань R_{max}
3. На вхід мережі подається навчальний приклад.
 - a. Розраховуються R_j
 - b. Визначається нейрон-переможець для якого $R_j = R_{min}$
4. Якщо $R_{min} \leq R_{max}$ то реалізується корекція вагових коефіцієнтів. В протилежному випадку в мережу додається новий нейрон вагові коефіцієнти якого дорівнюють компонентам вхідного вектору. Цикл повторюється з кроку 3 до виконання умов закінчення:
 - вичерпано заданий гранична кількість епох навчання;
 - не відбулося значного зміни вагових коефіцієнтів в межах заданої точності протягом останньої епохи навчання;
 - вичерпано заданий граничний фізичний час навчання.

Отже, кластеризація є ключовою при роботі з великою кількістю немаркованих даних у діагностиці будівель. Карта Кохонена - ефективний інструмент для виявлення структур у даних і побудови візуальних моделей стану. Самоорганізація дозволяє мережі адаптуватися до особливостей об'єкта без попередньої розмітки.

Лекція 9. Використання згорткової мережі VGG-16 для діагностування

План:

1. Структура згорткової мережі VGG-16.
2. Математичне забезпечення згорткової мережі VGG-16.
3. Використання мережі VGG-16 для виявлення дефектів будівель.

Питання 1. Структура згорткової мережі VGG-16.

VGG-16 - одна з найвідоміших глибоких згорткових нейронних мереж (CNN), запропонована в 2014 році групою Visual Geometry Group з Оксфордського університету.

Основна ідея - використання малих фільтрів 3×3 і послідовних блоків згортки з поступовим зменшенням просторових розмірів.

Число "16" вказує на кількість вагових шарів (13 згорткових + 3 повнозв'язні).




Рис. 6 Архітектура згорткової нейронної мережі VGG-16

Структура згорткової мережі VGG-16:

Етап	Шари	Характеристика
Вхід	-	Зображення 224×224×3
Блок 1	2× Conv(64) + MaxPooling	3×3 фільтри, stride=1
Блок 2	2× Conv(128) + MaxPooling	-
Блок 3	3× Conv(256) + MaxPooling	-
Блок 4	3× Conv(512) + MaxPooling	-
Блок 5	3× Conv(512) + MaxPooling	-
Класифікатор	FC-4096 → FC-4096 → FC-1000	Softmax

Після кожного блоку - max-pooling з ядром 2×2 (stride=2), що зменшує розмір зображення.

На виході - класифікація зображень на 1000 класів (ImageNet), але при адаптації можна змінити вихід.

Питання 2. Математичне забезпечення згорткової мережі VGG-16.

1. Згортка (convolution). Згортковий шар обчислює:

$$y_{i,j}^{(k)} = \sum_{m=1}^M \sum_{u=1}^h \sum_{v=1}^w x_{i+u,j+v}^{(m)} \cdot w_{u,v}^{(k,m)} + b^{(k)}$$

x — вхідна ознака,

w — ваги фільтра,

b — зміщення (bias),

y — результат згортки (фільтроване зображення),

k — номер фільтра (каналу),

M — кількість вхідних каналів.

2. Активация ReLU (Rectified Linear Unit)

Застосовується після кожної згортки:

$$f(x) = \max(0, x)$$

ReLU додає нелінійність, прискорює навчання і зменшує проблему градієнтного затуехання.

3. Пулінг (max-pooling)

Зменшує просторові розміри ознак:

$$y_{i,j} = \max_{\substack{0 \leq u < p \\ 0 \leq v < p}} x_{i+u,j+v}$$

$p = 2$ для VGG-16 (ядро 2×2).

Пулінг зберігає важливу інформацію, зменшуючи обчислювальні витрати.

4. Повнозв'язні (fully-connected) шари

Формально:

$$y = f(Wx + b)$$

де W — матриця ваг, x — вхідний вектор, f — ReLU або Softmax.

5. Softmax (вихідна функція)

Для класифікації:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Забезпечує нормалізовану ймовірність належності до класів.

Питання 3. Використання мережі VGG-16 для виявлення дефектів будівель.

Мережа VGG-16 може бути адаптована для виявлення та класифікації дефектів у будівельних конструкціях на основі зображень:

- Тріщини, відшарування бетону, корозія арматури.
- Нерівності поверхні, волога, цвіль.

Підхід до використання

1. Збір даних

- Фотографії поверхні конструкцій з різними типами пошкоджень.
- Розмітка (наприклад, класи: "тріщина", "без дефекту", "корозія").

2. Використання VGG-16 як feature extractor

- Видаляємо останній шар класифікації (FC-1000).
- Залишаємо попередні шари — вони витягують високорівневі ознаки.

3. Додавання власного класифікатора

Наприклад, FC-256 → FC-4 (4 класи дефектів) → Softmax.

4. Навчання

- Проводиться донавчання (fine-tuning) на власному наборі зображень.
- Можливе замороження перших блоків для збереження узагальнених ознак.

Переваги використання VGG-16 у будівництві:

- Висока точність в задачах візуального контролю.
- Можливість автоматичного аналізу великої кількості зображень.
- Використання на мобільних пристроях або дронах.
- Інтеграція в системи моніторингу стану споруд (BIM, SCADA тощо).

Лекція 10. Використання згорткових нейронних мереж для діагностики бетонних конструкцій

План:

1. Визначення діагностичних параметрів.
2. Збір та обробка статистичних даних.
3. Приклади застосування згорткових нейронних мереж для діагностики бетонних конструкцій.

Питання 1. Визначення діагностичних параметрів.

Діагностичні параметри - це фізичні, геометричні або структурні характеристики об'єкта, які дають змогу: оцінити його технічний стан, виявити дефекти або ознаки зносу, класифікувати або кластеризувати об'єкти за станом.

Основні діагностичні параметри бетонних конструкцій:

Категорія	Параметри
Геометричні	розміри тріщин, площа ушкодженої ділянки
Фізичні	вологість, щільність, міцність бетону
Візуальні (зображення)	колірні аномалії, текстура поверхні
Акустичні	резонансні частоти, відгук на удар
Теплові	розподіл температури на поверхні (інфрачервона термографія)

Вибір параметрів залежить від:

- типу конструкції (мостові плити, перекриття, фундаменти),
- умов експлуатації (волога, температура),
- цілей діагностики (контроль якості, виявлення дефектів, прогноз руйнування).

Питання 2. Збір та обробка статистичних даних.

Статистична обробка:

1. Аналіз даних: перевірка повноти й достовірності, нормалізація/стандартизація параметрів.
2. Фільтрація шумів: медіанна фільтрація, згладжування сигналів.
3. Агрегація даних: побудова матриць ознак або карт зображень.
4. Анотація зображень: розмітка вручну або з допомогою експертів: позначення тріщин, плям, зон дефектів.

Питання 3. Приклади застосування згорткових нейронних мереж для діагностики бетонних конструкцій.

Приклад 1: Виявлення тріщин на бетонних плитах

Дані: Фото бетонної поверхні з різними типами тріщин (волосяні, глибокі, наскрізні).

Підхід:

- Розмітка тріщин на зображеннях.
- Побудова CNN з 3-5 згортковими шарами.
- Вивід: класифікація фрагмента як "тріщина" або "без дефекту".

Результат: точність 90–95% при достатній кількості навчальних даних.

Приклад 2: Сегментація ушкоджених ділянок. Автоматичне виявлення та локалізація тріщин на зображеннях бетонних конструкцій шляхом піксельної сегментації: кожному пікселю на зображенні присвоюється мітка "тріщина" або "фон".

Підхід: застосування U-Net або SegNet (архітектури CNN для семантичної сегментації). U-Net - типова згорткова нейромережа, розроблена для семантичної сегментації. Її особливість - симетрична U-подібна структура з encoder (стиснення) і decoder (розгортання) частинами.

Вхідні дані

RGB-зображення бетонної поверхні, розміром, наприклад, 256×256 пікселів.

Відповідна маска (ground truth) такого ж розміру, де:

0 - фон (бетон без тріщини), 1 - тріщина.

Структура U-Net:

Блок	Опис
Encoder	Серії згорток + ReLU + max pooling, зменшення розміру та витягування ознак
Bottleneck	Найглибший рівень: багаті, абстрактні ознаки
Decoder	Upsampling + згортки + skip-зв'язки із симетричними шарами encoder'a
Output	1 згортка 1×1 + сигмоїда (для сегментації на 2 класи: тріщина не тріщина)

Передобробка

- Адаптація всіх зображень до єдиного розміру (наприклад, 256×256).
- Нормалізація пікселів: значення $\rightarrow [0, 1]$.
- Аугментація: обертання, фліп, змінення контрасту для збільшення набору.

Алгоритм роботи

1. Навчання:

- Оптимізується **функція втрат (loss function)**:

$$\text{Binary Cross-Entropy (BCE)} = -[y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})]$$

- Альтернатива: **Dice Loss** або комбінація BCE + Dice.

2. Оптимізатор: Adam, початкове значення навчальної ставки (learning rate) ≈ 0.0001 .

3. Метрики:

- IoU (Intersection over Union):

$$IoU = \frac{TP}{TP + FP + FN}$$

- Dice coefficient:

$$Dice = \frac{2 \cdot TP}{2 \cdot TP + FP + FN}$$

Результати моделі

- Після навчання мережа здатна локалізувати тріщини на нових зображеннях, навіть за слабого контрасту або складної текстури фону.
- Візуально результат — маска, де білі пікселі відповідають тріщинам.
- В точних експериментах (наприклад, з набором Crack500) досягається:
 - Точність $> 90\%$ (IoU),
 - Висока стійкість до шуму фону.

Застосування у практиці

Сфера	Як використовується
Моніторинг мостів	Камери/дрони збирають зображення для аналізу
Інспекція тунелів	CNN U-Net автоматично знаходить дефекти
Контроль якості	Оцінка свіжозалитих плит на предмет поверхневих мікротріщин

Переваги U-Net для діагностики бетонних конструкцій:

- Піксельна точність - важливо для оцінки глибини/довжини тріщин.
- Можливість адаптації під різні типи поверхонь.
- Мала потреба в великій кількості навчальних прикладів (навіть 100–200 зображень з аугментацією може бути достатньо).
- Відкрите програмне забезпечення - реалізації в TensorFlow, PyTorch.