

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Київський національний університет будівництва і архітектури

**ІНФОРМАЦІЙНІ СИСТЕМИ
ДІАГНОСТИКИ В БУДІВНИЦТВІ**

Методичні вказівки та завдання
до проведення лабораторних занять
для здобувачів першого (бакалаврського) рівня вищої освіти
за спеціальністю 126 «Інформаційні системи та технології»

Київ 2024

УДК 004.93

I-74

Укладач Л.О. Терейковська, д-р техн. наук, доцент

Рецензент С.Д. Бушуєв, д-р техн. наук, професор

Відповідальна за випуск Л.О. Терейковська, д-р техн. наук,
доцент

*Затверджено на засіданні кафедри інформаційних технологій
проектування та прикладної математики, протокол № 1 від 5 серпня
2024 року.*

В авторській редакції.

Інформаційні системи діагностики в будівництві : методичні
I-74 вказівки та завдання до проведення лабораторних занять / уклад.:
Терейковська Л.О. – Київ: КНУБА, 2024. – 24 с

Містять теоретичні відомості, вказівки до виконання та завдання до проведення лабораторних робіт з дисципліни «Інформаційні системи діагностики в будівництві».

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

ЗМІСТ

Загальні положення.....	4
Лабораторна робота 1. Розробка та дослідження програмного модулю використання продукційних правил для діагностування будівель.....	5
Лабораторна робота 2. Розробка та дослідження програмного модулю виділення об'єктів в задачах діагностики в будівництві.....	15
Список використаних джерел.....	24

ЗАГАЛЬНІ ПОЛОЖЕННЯ

Дисципліна «Інформаційні системи діагностики в будівництві» забезпечує формування у студентів компетенцій, необхідних для розв'язання практичних задач професійної діяльності, пов'язаних з розробленням, вдосконаленням та експлуатацією інформаційних систем діагностики в будівництві.

Завдання дисципліни, до складу якої входить змістовний модуль 1 «Базові положення в області діагностування в будівництві» та змістовний модуль 2 «Застосування нейронних мереж в задачах діагностування в будівельній галузі», включають вивчення теоретичних основ і методів діагностування в будівництві, вивчення підходів до розробки застосування нейромережових засобів діагностування та розробки і використання відповідних програмних засобів.

У цих методичних вказівках наведено завдання, короткі теоретичні відомості та порядок виконання двох лабораторних робіт, пов'язаних з розробкою програмного модулю використання продукційних правил для діагностування будівель та програмного модулю виділення об'єктів в задачах діагностики в будівництві. Виконання цих лабораторних робіт забезпечує можливість закріплення теоретичного матеріалу щодо застосування нейронних мереж в задачах діагностування в будівельній галузі. Контрольні запитання, представлені в кінці кожного розділу методичних вказівок, допоможуть закріпити знання, сприяють самоперевірці та поглибленому розумінню матеріалу.

ЛАБОРАТОРНА РОБОТА №1
РОЗРОБКА ТА ДОСЛІДЖЕННЯ ПРОГРАМНОГО МОДУЛЮ
ВИКОРИСТАННЯ ПРОДУКЦІЙНИХ ПРАВИЛ ДЛЯ
ДІАГНОСТУВАННЯ БУДІВЕЛЬ

Мета роботи: оволодіння навичками розробки та використання нейромережових засобів для діагностування будівель, навчання яких реалізується із застосуванням продукційних правил.

Теоретичні відомості

В загальному випадку продукційне правило в області діагностування будівель може бути описане за допомогою виразу виду [1]:

$$\text{If } x_1 \in [X_1^{\min}, X_1^{\max}] \wedge \dots \wedge x_K \in [X_K^{\min}, X_K^{\max}] \text{ then } Y, \quad (1.1)$$

де x_k – k -ий діагностичний параметр; $[X_k^{\min}, X_k^{\max}]$ – заданий діапазон значень для k -го діагностичного параметру; K – кількість діагностичних параметрів; Y – результат продукційного правила.

У лівій частині (*If*-частина) заданого виразом (1.1) продукційного правила визначається діапазон значень кожного із діагностичних параметрів. Права частина (*then*-частина) описує результат продукційного правила, асоційований з висновком про технічний стан будівлі, якщо умова, задана в *If*-частині, є істиною.

В експертних системах діагностування будівель набір продукційних правил формує базу знань, яка використовується для визначення поточного технічного стану або його прогнозування в майбутньому.

До переваг експертних систем такого типу відносять:

- Зрозумілість отримання результуючого рішення у випадку невеликої кількості діагностичних параметрів.

- Можливість оперативного оновлення системи, що реалізується за рахунок введення нових правил, отриманих на базі експертних знань.

Разом з тим, таким експертним системам притаманний суттєвий недолік, який полягає у відносно низьких узагальнюючих можливостях системи, що обумовлені складністю опису процесу прийняття рішень в умовах багатоваріативності комбінацій діагностичних параметрів.

Перспективним шляхом виправлення вказаних недоліків являється використання нейронних мереж, пристосованих до навчання з застосуванням продукційних правил. Однією із найбільш апробованих мереж даного типу являється ймовірнісна нейронна мережа (PNN) [1].

Функціонування ймовірнісних нейронних мереж базується на передумові, що вирішення задач класифікації та регресії можливе завдяки оцінці щільності ймовірності сумісного розподілу вхідних та вихідних даних. В задачах класифікації виходи нейронної мережі інтерпретуються як оцінки ймовірності того, що образ належить деякому класу. Для вирішення таких задач нейронна мережа повинна оцінити щільність ймовірності віднесення образу до кожного із класів, порівняти ці ймовірності між собою та вибрати найбільш ймовірний клас. Сумарну функціональну оцінку щільності ймовірності можливо розрахувати як суму вказаних функцій. Найчастіше в якості ядерної функції використовують функцію Гауса.

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

Елемент шару образів пов'язаний тільки з тим елементом шару додавання, якому відповідає клас образу. Для прикладу, на рис. 1 показана структура мережі PNN, яка призначена для віднесення невідомого образу до одного з трьох відомих класів – А, В або С. Передбачається, що на вхід нейронної мережі будуть подаватись параметри графічних образів розміром $l \times h$ пікселів. Кількість входів мережі PNN дорівнює числу ознак класу і визначається так:

$$K = l \times h. \quad (1.2)$$

Показана на рис. 1 мережа складається з чотирьох шарів нейронів:
- Вхідний шар (L_{in}) – призначений виключно для отримання вхідної інформації. Нейронам даного шару притаманна лінійна функція активації:

$$y = x, \quad (1.3)$$

де x – вхідний сигнал; y – вихідний сигнал.

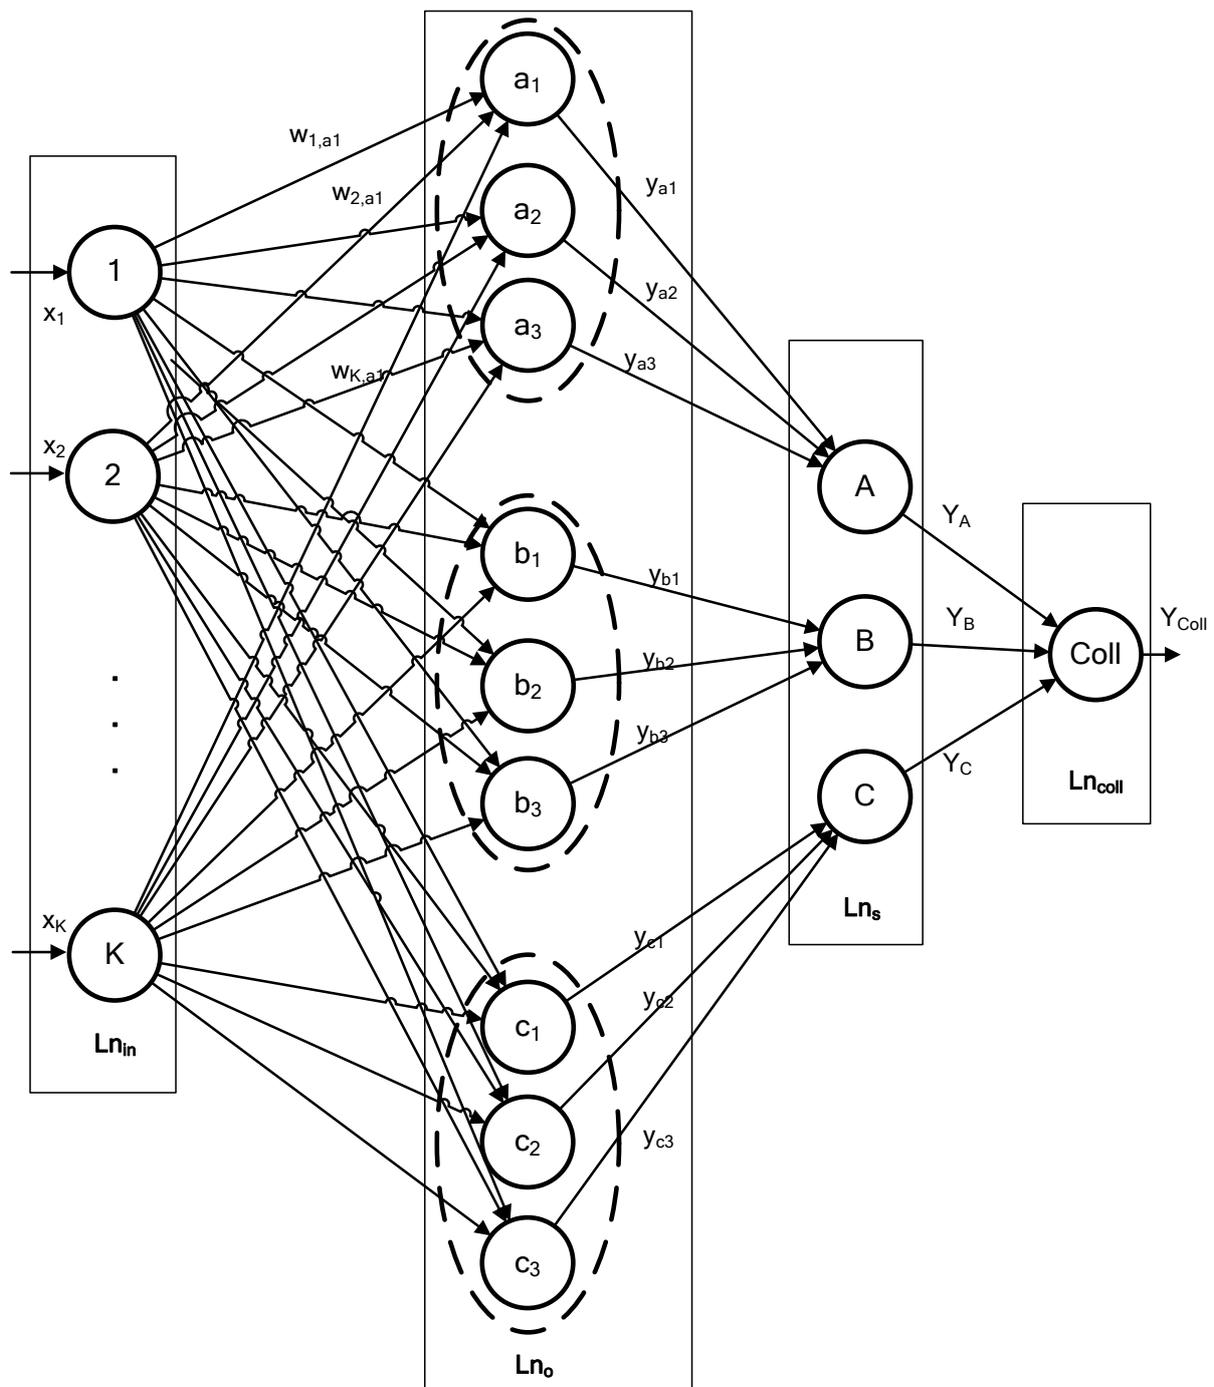


Рис. 1.1. Приклад структури PNN, призначеної для віднесення невідомого образу до одного з класів - A, B або C

- Шар образів (Ln_o). Нейрони даного шару в режимі навчання призначені для зберігання навчальних прикладів. В режимі розпізнавання нейрони даного шару генерують вихідний сигнал, величина якого свідчить про схожість невідомого образу з навчальним прикладом, з яким асоційовано даний нейрон шару образів.

- Шар додавання (Ln_s). Нейрони, котрі входять до складу даного шару,

в режимі розпізнавання інтегрують вихідні сигнали пов'язаних з ними нейронів шару образів. Нейрони шару додавання асоціюються з класами, що мають бути розпізнані.

- Вихідний шар ($L_{n_{coll}}$) – призначений для генерації результатів розпізнавання невідомого образу. В класичному вигляді результатом розпізнавання являється назва класу, до якого мережа відносить невідомий вхідний образ.

Кількість нейронів шару образів мережі PNN дорівнює кількості навчальних прикладів, а кількість нейронів шару додавання дорівнює кількості класів, що мають бути розпізнані.

Нейрон шару образів пов'язаний тільки з тим нейроном шару додавання, якому відповідає клас образу. Тому вагові коефіцієнти зв'язків між нейронами шару додавання та пов'язаним з ними нейроном шару образів дорівнюють 1, а вагові коефіцієнти зв'язків між нейронами шару додавання та не пов'язаним з ними нейроном шару образів дорівнюють 0.

На рис. 1.1 зв'язки між нейронами шару образів та нейронами шару додавання, для яких вагові коефіцієнти дорівнюють 0, не показані. Вагові коефіцієнти зв'язків, що входять у вихідний елемент, дорівнюють 1, тобто

$$w_l = 1 \quad l = 1, 2, \dots, L, \quad (1.4)$$

де w_l – ваговий коефіцієнт зв'язку між l -им нейроном шару додавання та вихідним нейроном; L – кількість нейронів шару додавання.

Навчання мережі полягає у тому, що для синаптичних зв'язків, які входять в нейрон шару образів, вагові коефіцієнти встановлюються такими ж, як складові частини відповідного навчального прикладу, тобто

$$w_{i,j} = x_{i,j}, \quad (1.5)$$

де $w_{i,j}$ – ваговий коефіцієнт між i -им вхідним нейроном та j -им нейроном шару образів; x_i – значення i -го вхідного параметру навчального прикладу, що співвідноситься з j -им нейроном шару образів.

Таким чином, всі параметри мережі PNN безпосередньо визначаються навчальними даними. Вихідний сигнал довільного j -го нейрона шару образів розраховується так:

$$y_j = \sum_{k=1}^K \exp\left(\frac{-(w_{k,j} - x_k)^2}{\sigma^2}\right), \quad (1.6)$$

де x_k – k -та компонента невідомого образу, що дорівнює вихідному сигналу k -го вхідного нейрону; $w_{k,j}$ – ваговий коефіцієнт зв'язку між k -им вхідним та j -им нейроном шару образів; K – кількість компонент вхідного образу, що дорівнює кількості нейронів вхідного шару; σ – радіус функції Гауса.

Прийнято, що для більшості випадків можливо прийняти $\sigma = 0,5$. Разом з тим, в роботі [1] відзначено, що радіус функції Гауса не має значного впливу на результат розпізнавання. В нейронах шару додавання використовується лінійна функція активації виду:

$$y_{c,i} = x_{c,i}^{\Sigma}, \quad (1.7)$$

де $y_{c,i}$ – вихідний сигнал i -го нейрону шару додавання; $x_{c,i}^{\Sigma}$ – сумарний вхідний сигнал i -го нейрону шару додавання.

Вихідний сигнал n -го нейрону даного шару (Y_n) розраховується так:

$$Y_n = \frac{1}{I} \sum_{i=1}^I y_i, \quad (1.8)$$

де I – кількість нейронів шару образів, пов'язаних з n -им нейроном шару додавання; y_i – вихідний сигнал i -го нейрона шару образів, пов'язаного з n -им нейроном шару додавання.

Величина Y_n представляє собою результат віднесення вхідного образу до класу, який відповідає даному нейрону. Завданням вихідного елемента є тільки визначення нейрона шару додавання з максимальною активністю. Хоча результатом розпізнавання мережі PNN є тільки назва класу, до якого віднесено вхідний приклад, але величини Y_n вказують на приналежність невідомого вхідного прикладу до одного з класів.

Розглянемо застосування процедури використання мережі PNN для визначення очікуваного вихідного сигналу на прикладі розпізнавання 8 чорно-білих фігур, показаних на рис. 1.2.

у спрощеному вигляді вказані фігури можливо асоціювати з монохромними зображеннями пошкоджень. Показані на рис. 1.2 фігури записані в квадрат розміром 3x3. Таким чином, кількість вхідних параметрів PNN дорівнює 9. Кожна з фігур відповідає еталону класу, що має бути розпізнаний. Наприклад, еталони фігур F_1 та F_5 можливо записати за допомогою виразів (1.9) та (1.10)

$$|0,0,0,1,1,1,0,0,0| \rightarrow F_1, \quad (1.9)$$

$$|1,1,1,1,1,1,1,1,1| \rightarrow F_5. \quad (1.10)$$

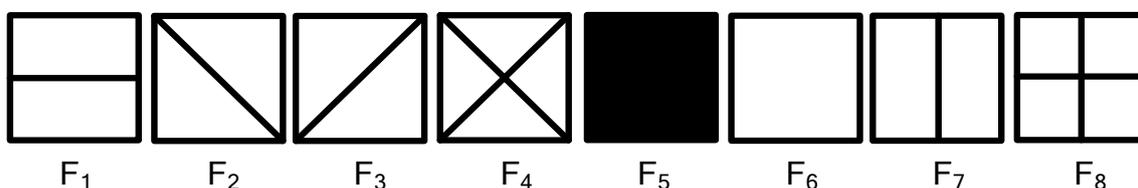


Рис. 1.2. Фігури, що співвідносяться з класами, які мають бути розпізнані

Параметри навчальних прикладів, що відповідають фігурам, наведеним на рис. 1.2, зведені в табл. 1.1.

Таблиця 1.1

Параметри навчальних прикладів

Номер прикладу	Вхідні параметри									Вихідний параметр
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	
1	0	0	0	1	1	1	0	0	0	F_1
2	1	0	0	0	1	0	0	0	1	F_2
3	0	0	1	0	1	0	1	0	0	F_3
4	1	0	1	0	1	0	1	0	1	F_4
5	1	1	1	1	1	1	1	1	1	F_5
6	0	0	0	0	0	0	0	0	0	F_6
7	0	1	0	0	1	0	0	1	0	F_7
8	0	1	0	1	1	1	0	1	0	F_8

Вагові коефіцієнти зв'язків мережі PNN, що відповідають навчальним прикладам, котрі представлені в табл. 1.1, наведені в табл. 1.2.

Таблиця 1.2

Величини вагових коефіцієнтів синаптичних зв'язків

Ln _o	Ln _{in}									Ln _s							
	x ₁	x ₂	x ₃	x ₄	x ₅	x ₆	x ₇	x ₈	x ₉	F ₁	F ₂	F ₃	F ₄	F ₅	F ₆	F ₇	F ₈
f1 ₁	0	0	0	1	1	1	0	0	0	1	0	0	0	0	0	0	0
f2 ₁	1	0	0	0	1	0	0	0	1	0	1	0	0	0	0	0	0
f3 ₁	0	0	1	0	1	0	1	0	0	0	0	1	0	0	0	0	0
f4 ₁	1	0	1	0	1	0	1	0	1	0	0	0	1	0	0	0	0
f5 ₁	1	1	1	1	1	1	1	1	1	0	0	0	0	1	0	0	0
f6 ₁	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
f7 ₁	0	1	0	0	1	0	0	1	0	0	0	0	0	0	0	1	0
f8 ₁	0	1	0	1	1	1	0	1	0	0	0	0	0	0	0	0	1

Після цього з використанням даних табл. 1.1 та табл. 1.2 була побудована структура мережі PNN, що показана на рис. 1.3.

Зазначимо, що в побудованій мережі PNN кожному класу відповідає лише один навчальний приклад, тому на рис. 1.3 всі нейрони шару образів позначені індексом 1.

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.

До переваг мережі PNN відноситься:

- Можливість проведення якісної класифікації на невеликих наборах учбових даних.
- Низька чутливість до помилкових даних в учбових наборах.
- Простота математичного забезпечення.
- Ймовірнісний зміст класифікації, що значно полегшує інтерпретацію отриманих результатів.
- Безітераційність навчання, що зумовлює короткий термін навчання та стабільність навчання.
- Простота програмної реалізації.

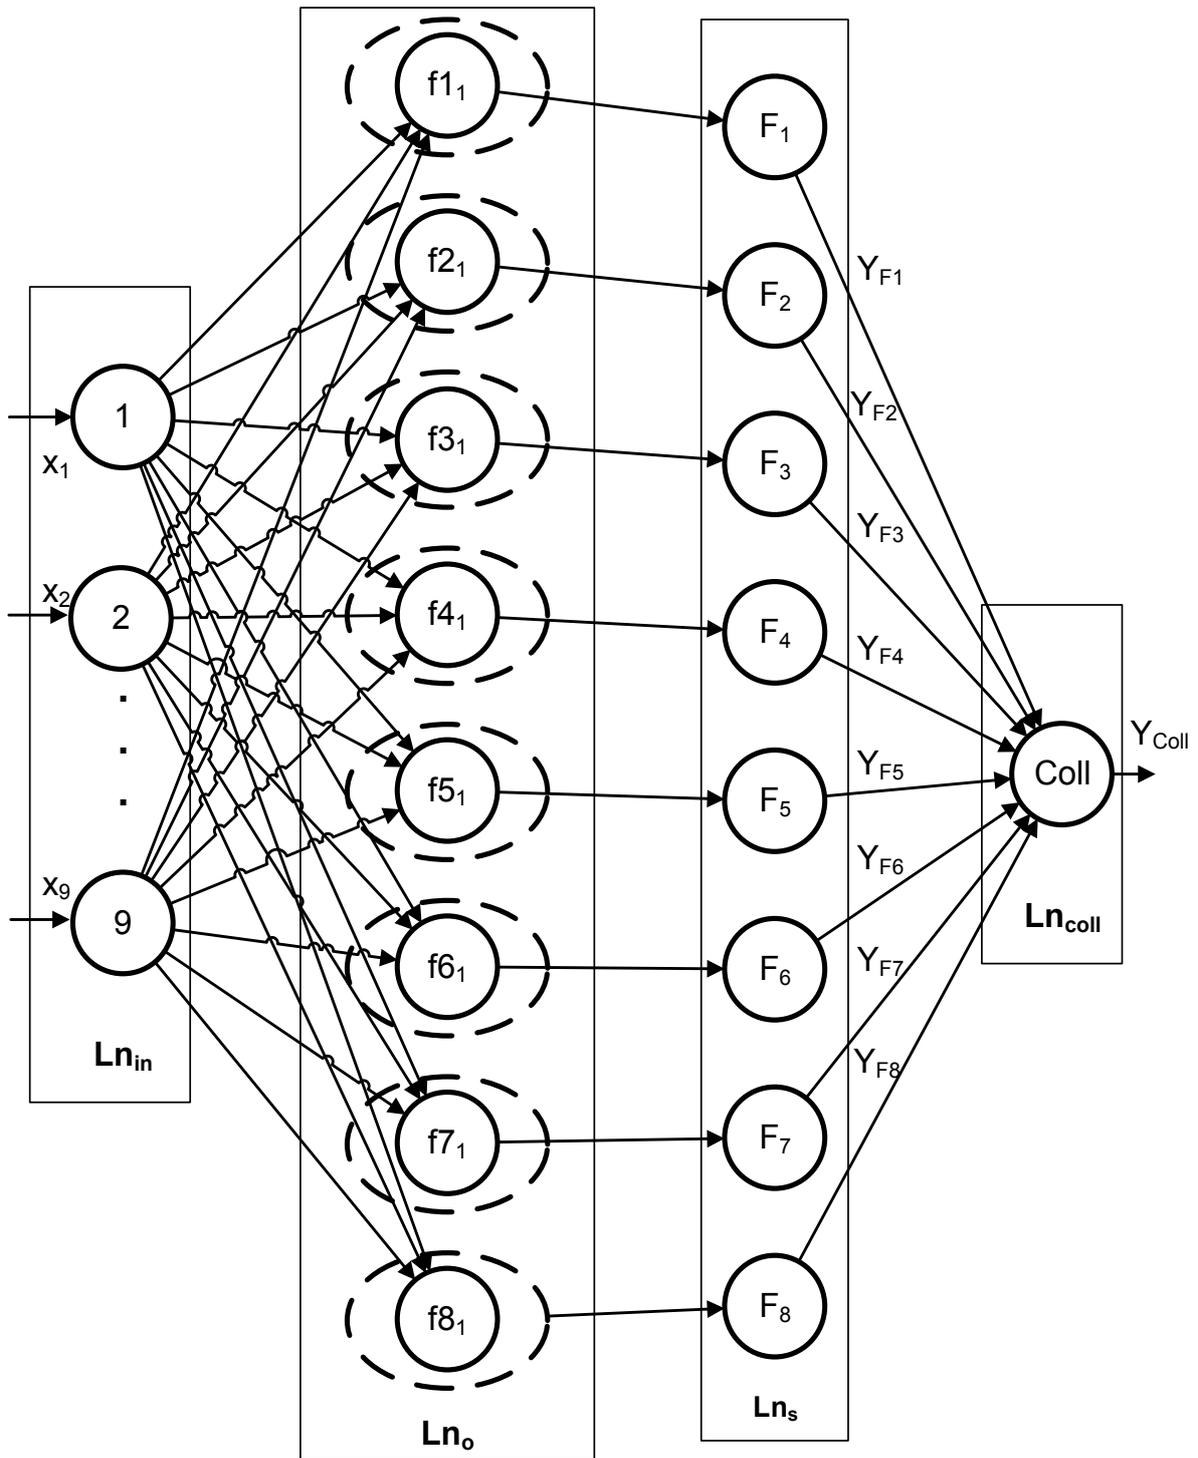


Рис. 1.3. Структура PNN для розпізнавання геометричних образів

Загальними недоліками мережі PNN є:

- Якісна класифікація образів можлива тільки в діапазоні навчальних даних. у класичному вигляді мережа не здатна проводити узагальнення та не володіє асоціативними властивостями.

- Потенційно висока обчислювальна ресурсоемкість. Причиною цього є те, що мережа PNN містить в своєму складі весь навчальний матеріал, а через це вона потребує великого обсягу пам'яті та повільно працює.

- Можливість використання тільки в задачах класифікації.

Відзначимо, що вказані недоліки не є критичним в багатьох задачах діагностування будівель. Наприклад, для вирішення проблеми ресурсоемкості мережу PNN можна реалізувати апаратними засобами.

Недоліки, пов'язані з поганим узагальненням результатів можна нівелювати за рахунок оптимізації множини навчальних даних та модифікації архітектури нейронної мережі. При цьому слід враховувати, що традиційною сферою використання мережі PNN є попередня обробка даних для виділення із них найбільш інформативних параметрів. Тому використання мережі PNN для вирішення практичних задач в області діагностування будівель має хороші перспективи. Однак для цього 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 нейронних мереж.

Хід виконання роботи

1. Ознайомитись з теоретичними відомостями.
2. Обрати та узгодити з викладачем множину зображень пошкоджень, що підлягають класифікації.
3. Використовуючи сформовану множину зображень розробити та узгодити з викладачем множину продукційних правил виду (1).
4. Базуючись на сформованій множині продукційних правил сформулювати навчальну та тестову вибірку.
5. Використовуючи математичне забезпечення, задане виразами (2-8), розробити програмне забезпечення, призначене для реалізації мережі PNN.
6. З використанням сформованої навчальної вибірки реалізувати навчання мережі PNN.
7. З використанням сформованої тестової вибірки реалізувати тестування мережі PNN.

8. Оцінити помилку розпізнавання мережі PNN на навчальній та тестовій вибірці.

9. Відповідно до діючих стандартів та правил, оформити звіт з лабораторної роботи, в якому відобразити:

- назву та мету лабораторної роботи;
 - характеристики навчальної та тестової вибірки;
 - приклад продукційних правил;
 - структурну схему побудованої мережі PNN;
 - помилку розпізнавання мережі PNN на навчальній та тестовій вибірці
- висновки щодо можливостей розробленого програмного забезпечення в області діагностування будівель;
- код розробленого програмного забезпечення.

Контрольні запитання

1. Що таке продукційне правило?
2. Назвіть переваги та недоліки експертних систем діагностування.
3. Охарактеризуйте структуру мережі PNN.
4. Чому дорівнює кількість вхідних та вихідних нейронів мережі PNN? Наведіть приклади.
5. Чому дорівнює кількість нейронів у шарі образів в мережі PNN?
6. Чому дорівнює кількість нейронів у шарі додавання в мережі PNN?
7. Охарактеризуйте функцію активації, що використовується у нейронах вхідного шару в мережі PNN?
8. Охарактеризуйте функцію активації, що використовується у нейронах шару образів в мережі PNN?
9. Охарактеризуйте функцію активації, що використовується у нейронах шару додавання в мережі PNN?
10. Опишіть механізм визначення вагових коефіцієнтів синаптичних зв'язків в мережі PNN.
11. Опишіть переваги мережі PNN.
12. Опишіть недоліки мережі PNN.
13. Опишіть процедуру навчання мережі PNN.
14. Опишіть функціонування мережі PNN в режимі розпізнавання.

ЛАБОРАТОРНА РОБОТА №2
РОЗРОБКА ТА ДОСЛІДЖЕННЯ ПРОГРАМНОГО МОДУЛЮ ВИДІЛЕННЯ
ОБ'ЄКТІВ В ЗАДАЧАХ ДІАГНОСТИКИ В БУДІВНИЦТВІ

Мета роботи: оволодіння навичками розробки та використання інструментального забезпечення для виділення об'єктів при діагностуванні в будівництві.

Теоретичні відомості

У сучасних умовах засоби розпізнавання зображень знаходять широке розповсюдження в інформаційних системах діагностування будівель [3, 6]. Одним із основних етапів розпізнавання зображень є реалізація семантичної сегментації, результатом якої є виділення на вхідному растровому зображенні цільового об'єкта, наприклад, дефекту будівлі [4, 7]. Проблематика семантичної сегментації ускладнюється через можливе часткове або повне перекриття цільових об'єктів, нечіткість їх кордонів, різноваріантність розмірів та розміщення. Внаслідок описаних труднощів, засоби семантичної сегментації зображень, що базуються на класичних методах, являються вузькоспеціалізованими і потребують значної модифікації навіть при незначних змінах умов застосування. Разом з тим, за останні декілька років зріс інтерес до нейромережових засобів виділення, що пояснюється доведеною ефективністю нейронних мереж при вирішенні подібних багатофакторних завдань. Типова схема функціонування нейромережової системи семантичної сегментації показана на рис. 2.1.

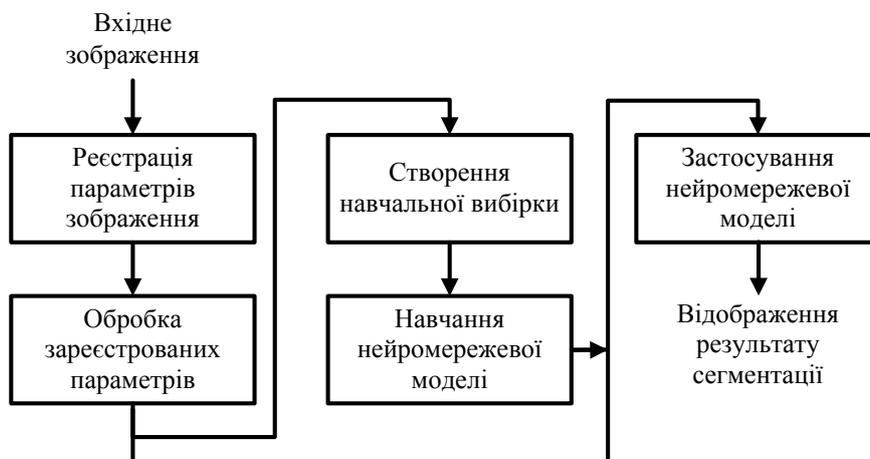


Рис. 2. 1. Типова структурна схема функціонування нейромережової системи семантичної сегментації растрових зображень

У випадку використання нейромережових технологій сегментації використовується нейромережева модель, що складається із кодера та декодера [2, 4]. Завданням кодера є визначення багатовимірного масиву ознак початкового зображення, а завданням декодера являється отримання обробленого зображення, у якого кожен із пікселів отримує маркер відношення до одного із виділених цільових об'єктів або фону. При цьому кодер та декодер представляють собою дещо модифіковані згорткові нейронні мережі (ЗНМ). Модифікація полягає у тому, що використовуються тільки ті блоки ЗНМ, які призначені для визначення значимих ознак, а повнозв'язні шари відсутні.

Розглянемо процедуру застосування нейронних мереж для сегментації зображень, що може бути представлена у наступному вигляді:

$$Im_{in} \xrightarrow{Pr} Im_{pr} \xrightarrow{NC} Fm \xrightarrow{ND} Im_{out}, \quad (2.1)$$

де Im_{in}, Im_{pr} – вхідне та оброблене зображення; \xrightarrow{Pr} – оператор попередньої обробки зображення; $\xrightarrow{NC}, \xrightarrow{ND}$ – оператори нейромережевого кодування та декодування зображення; Fm – кортеж матриць ознак, отриманий в результаті операції нейромережевого кодування зображення; Im_{out} – сегментоване зображення.

В свою чергу, Im_{in}, Im_{pr} та Im_{out} представляють собою матрицю виду:

$$Im_x = \left\| \begin{array}{ccccc} pt_{1,1}(x) & \dots & pt_{n,1}(x) & \dots & pt_{N,1}(x) \\ \dots & \dots & \dots & \dots & \dots \\ pt_{1,m}(x) & \dots & pt_{n,m}(x) & \dots & pt_{N,m}(x) \\ \dots & \dots & \dots & \dots & \dots \\ pt_{1,M}(x) & \dots & pt_{n,M}(x) & \dots & pt_{N,M}(x) \end{array} \right\|, \quad (2.2)$$

де $pt_{n,m}(x)$ – опис кольору пікселя з координатами (n, m) ; N, M – розмір зображення по горизонталі та по вертикалі; x – етап обробки.

Множина матриць ознак визначається так:

$$Fm = \{fm_1, \dots, fm_k, \dots, fm_K\}, \quad (2.3)$$

$$fm_k = \left\| \begin{matrix} \alpha_{1,1} & \dots & \alpha_{L,1} \\ \dots & \dots & \dots \\ \alpha_{J,1} & \dots & \alpha_{L,J} \end{matrix} \right\|_k, \quad (2.4)$$

де fm_k – матриця ознак, що співвідноситься з k -ою картою субдискретизації в останньому шарі згорткової нейронної мережі, що використовується в якості кодеру; K – кількість карт субдискретизації в останньому шарі згорткової нейронної мережі кодеру; $\alpha_{j,l}$ – значення ознаки в точці з координатами j, l для k -ої карти субдискретизації/згортки; L – розмір k -ої карти по горизонталі; J – розмір k -ої карти по вертикалі.

Зазначимо, що у випадку, коли останнім шаром ЗНМ кодеру є шар згортки, то у виразах (2.3, 2.4) fm_k співвідноситься з k -ою картою згортки.

Процес визначення нейромережових моделей кодеру та декодера на етапі їх проектування можливо описати так:

$$E \rightarrow \max, \quad (2.5)$$

$$E = \sum_{i=1}^I \alpha_i w_i, \quad \alpha_i \in \{\alpha\}, w_i \in \{w\}, \quad (2.6)$$

де E – функція ефективності засобів сегментації; I – кількість параметрів ефективності k_i – значення i -го параметру ефективності; α_i – ваговий коефіцієнт i -го параметру ефективності; $\{\alpha\}, \{w\}$ – множина вагових коефіцієнтів та множина параметрів ефективності.

Приблизний перелік параметрів оцінки ефективності засобів семантичної сегментації зображень наведено в табл. 2.1. Значення кожного із параметрів ефективності та значення їх вагових коефіцієнтів можливо визначити за допомогою методів експертного оцінювання, а їх значення можливо оцінити по бінарній шкалі 0 або 1. В якості показників ефективності доцільно використовувати точність (A) та обчислювальну ресурсоємність (Θ), що зумовлює необхідність модифікації виразу (2.5):

$$\begin{cases} A \rightarrow \max \\ \Theta \leq \Delta \end{cases} \quad (2.7)$$

Перелік параметрів оцінки ефективності нейромережових засобів семантичної сегментації зображень

Позначення	Характеристика параметру
w_1	Точність сегментації
w_2	Обчислювальна складність сегментації
w_3	Можливість маркування сегментів зображення
w_4	Можливість виділення декількох сегментів, що відповідають різним об'єктам
w_5	Можливість виділення сегментів, що відповідають об'єктам, які перекриваються
w_6	Можливість виділення деформованих об'єктів
w_7	Можливість виділення зсунутих об'єктів
w_8	Можливість виділення повернутих об'єктів
w_9	Термін навчання нейромережової моделі

Особливості задачі сегментації зображень зумовлюють необхідність застосування для оцінки точності показники, що відображають схожість геометричних об'єктів, наприклад коефіцієнт Жаккара:

$$J = \frac{|N \cap M|}{|N \cap M| + |N - M| + |B - N|}, \quad (2.8)$$

де N, M – області, що підлягають порівнянню.

За умов використання one-hot кодування очікуваного вихідного сигналу та однакових розмірів вхідного та сегментованого зображення, вираз (2.8) деталізується так:

$$J = \frac{\sum_{i=1}^I n_i m_i}{\sum_{i=1}^I n_i + \sum_{i=1}^I m_i - \sum_{i=1}^I (n_i - m_i)}, \quad (2.9)$$

де I – кількість точок, що описують очікуваний вихідний сигнал нейромережової моделі; n_i – значення, характерне для i -го пікселя сегментованого зображення; m_i – значення, характерне для i -го пікселя очікуваного вихідного сигналу.

Дані літературних джерел [2, 5, 7] свідчать, що в нейромережових засобах, призначених для виділення об'єктів на растрових зображеннях, доцільно використовувати кодер, розроблений на базі LeNet-5, VGG, ResNet та GoogLeNet, що пояснюється їх високою ефективністю, апробованістю та наявністю доступного інструментарію для комп'ютерної реалізації. При цьому функціонал кодеру можливо описати за допомогою виразу виду:

$$F_C(\|R\|_{H,L,K}) = \{\|c_1\|_{X,Y}, \|c_2\|_{X,Y}, \dots, \|c_N\|_{X,Y}\}, \quad (2.10)$$

де F_C – функція кодування вхідного зображення; $\|R\|_{H,L,K}$ – трьохвимірний масив значень, елементи якого співвідносяться з вхідним зображенням; K – кількість кольорових каналів вхідного зображення; H, L – розміри вхідного зображення.

Враховуючи характеристики ЗНМ типу LeNet та особливості структури класичного нейромережевого кодера, вираз, що характеризує залежність показників точності та обчислювальної ресурсоемності кодеру від його конструктивних параметрів, можливо записати у вигляді:

$$\Theta, A = F(S, \|b\|, \|m\|, C, H, \|k\|), \quad (2.11)$$

де S – кількість стеків; $\|b\|$ – масив, що містить розміри ядер згортки; b_w – розмір ядра згортки для w -го стеку; $\|m\|$ – масив, що містить значення масштабних коефіцієнтів; m_w – значення масштабного коефіцієнту для w -го стеку; $\|k\|$ – масив, що містить кількість карт згортки; k_w – кількість карт згортки для w -го стеку; C – кількість кольорових каналів, що підлягають обробці; H – розмір вхідного зображення.

З урахуванням (2.7, 2.11), отримано вираз, що являється підґрунтям визначення конструктивних параметрів нейромережевого кодеру:

$$\begin{cases} A(S, \|b\|, \|m\|, C, H, \|k\|) \rightarrow \max \\ \Theta(S, \|b\|, \|m\|, C, H, \|k\|) \leq \Delta_\Theta \end{cases} \quad (2.12)$$

Для визначення значень, використаних у виразі (2.12) конструктивних параметрів, можливо використати принципи:

1. Кількість стеків прирівнюється до кількості рівнів розпізнавання експертом цільових об'єктів на зображенні, що підлягає аналізу;

2. Кількість карт згортки в згортковому шарі встановлюється рівним кількості значимих ознак, що розпізнаються на цьому ж рівні експертом.

Розглянемо механізм побудови нейромережевого декодера. Функціонування декодера, що полягає у відновленні сегментованого зображення, можливо описати за допомогою виразу виду:

$$F_D(\{\|c_1\|_{X,Y}, \|c_2\|_{X,Y}, \dots, \|c_N\|_{X,Y}\}) = \|r\|_{h,l,k}, \quad (2.13)$$

де F_D – функція декодування сегментованого зображення; $\|c_n\|_{X,Y}$ – масив значень, що співвідноситься з n -ою картою ознак останнього шару нейромережевого кодера; N – кількість карт ознак в останньому шарі нейромережевого кодера; X, Y – розмір карти ознак в останньому шарі нейромережевого кодера; $\|r\|_{h,l,k}$ – трьохвимірний масив значень, що співвідноситься з вихідним зображенням; k – кількість кольорових каналів вихідного зображення; h, l – розміри вихідного зображення.

Відповідно до відомих рішень [2, 4, 7], в основу розробки моделі нейромережевого декодера може бути покладено:

1. Підхід на основі одноетапного ресамплінгу вихідного зображення.
2. Підхід на основі багатоетапного ресамплінгу вихідного зображення.
3. Підхід на основі багатоетапного симетричного ресамплінгу вихідного зображення з інтеграцією симетричних наборів вагових коефіцієнтів.

При побудові декодера на базі першого підходу особливості його функціонування полягають в тому, що отриманий в результаті кодування вхідного зображення багатовимірний масив ознак за допомогою класичних процедур масштабування зображень видозмінюється до масиву, призначеного для опису зображення з виділеним об'єктом. Серед вказаних процедур масштабування однією із найбільш апробованих являється процедура бікубічної інтерполяції.

Підхід на основі багатоетапного ресамплінгу вихідного зображення полягає у тому, що отриманий на виході кодера багатовимірний масив ознак за допомогою ЗНМ видозмінюється до масиву, призначеного для опису зображення з виділеним об'єктом. Слід зазначити, що в загальному

випадку тип та параметри ЗНМ, що застосована для побудови декодера, можуть не співпадати з типом та параметрами ЗНМ, що використана для побудови кодера.

Підхід на основі багатоетапного симетричного ресамплінгу передбачає, що для розробки кодера і декодера використовуються однакові ЗНМ з дзеркально відображеною структурою. При цьому відповідні шари згортки кодера та декодера зв'язані між собою.

При побудові декодера на основі багатоетапного ресамплінгу або багатоетапного симетричного ресамплінгу визначити приблизні значення використаних конструктивних параметрів можливо, базуючись на принципах, наведених в описі моделі кодера.

З урахуванням наведених підходів до побудови моделей кодера та декодера, загальну процедуру можливо описати за допомогою виразу виду:

$$\begin{aligned} & \langle \{u_{req}\}, \{u_{con}\}, \{NN_d\}, \{u_{CNN}\}, \{d\}, \{\alpha\}, \{w\}, \rangle \\ & \rightarrow \langle CNN_{type}^{enc}, CNN_{type}^{dec}, \{CNN^{enc}\}, \{CNN^{dec}\} \rangle, \end{aligned} \quad (2.14)$$

де $\{u_{req}\}$ – множина параметрів реєстрації; $\{u_{con}\}$ – множина вимог до результатів розпізнавання; $\{u_{obj}\}$ – множина, що містить опис виділених об'єктів; $\{NN_d\}$ – множина доступних типів ЗНМ; $\{u_{cnn}\}$ – множина параметрів доступних типів ЗНМ; $\{d\}$ – множина експертних даних, що можуть бути використані для побудови моделі кодера та декодера; $\{\alpha\}$ – коефіцієнти параметрів ефективності, що використовуються в виразі (6); $\{w\}$ – множина параметрів ефективності, що використовуються в виразі (6) та наведені в табл. 1; $CNN_{type}^{enc}, CNN_{type}^{dec}$ – тип ЗНМ, що використовується як базис побудови кодера та декодера; $\{CNN^{enc}\}, \{CNN^{dec}\}$ – параметри ЗНМ типу $CNN_{type}^{enc}, CNN_{type}^{dec}$, відповідно.

Зазначимо, що $\{u_{req}\}$ в значній мірі залежить від формату реєстрації (g_{rf}), роздільної здатності (g_{rs}) та розміру вхідного зображення (g_{sz}).

Таким чином, перелік завдань щодо побудови нейромережевого засобу семантичної сегментації зображення складається з:

- Визначення переліку параметрів зображень, що підлягають реєстрації.
- Формування параметрів навчальних прикладів.

- Визначення типу ЗНМ, що є найбільш ефективною в умовах поставленої задачі.

- Формування навчальної вибірки ЗНМ, обсяг якої повинен бути достатнім.

- Обґрунтування параметрів, що мають бути використані для оцінювання точності.

- Розрахунок значень конструктивних параметрів ЗНМ визначеного типу.

- Оцінка точності виділення та за необхідності уточнення архітектури ЗНМ.

Власне реалізація процедури семантичної сегментації зображення полягатиме у застосуванні розробленого нейромережевого засобу.

Хід виконання роботи

1. Ознайомитись з теоретичними відомостями.

2. Обрати та узгодити з викладачем зображення, що підлягають сегментації.

3. Спираючись на наведені теоретичні відомості, побудувати структурну схему та сформуванати математичне забезпечення нейромережевої моделі для семантичної сегментації зображень, що базується на багатоетапному симетричному ресамплінгу.

3. Використовуючи побудовану нейромережеву модель, розробити відповідне програмне забезпечення, призначене для семантичної сегментації зображень.

4. За допомогою розробленого програмного забезпечення провести експериментальні дослідження, спрямовані на верифікацію розробленої нейромережевої моделі. Для оцінювання точності використати (2.8, 2.9).

5. Відповідно до діючих стандартів та правил, оформити звіт з лабораторної роботи, в якому відобразити:

- назву та мету лабораторної роботи;

- структурну схему та математичне забезпечення розробленої нейромережевої моделі;

- рисунки, що ілюструють процеси визначення параметрів нейромережевої моделі;

- висновки щодо можливостей програмного забезпечення для семантичної сегментації зображень;

- код розробленого програмного забезпечення.

Контрольні запитання

1. Що таке згорткова нейронна мережа?
2. Передумови використання нейронних мереж для виділення об'єктів на зображенні.
3. Що таке кодер нейромережевої моделі, призначеної для виділення об'єктів на зображенні?
4. Що таке декодер нейромережевої моделі, призначеної для виділення об'єктів на зображенні?
5. Поясніть структуру нейромережевої моделі, призначеної для виділення об'єктів на зображенні.
6. Поясніть процес побудови декодера на основі одноетапного ресамплінгу.
7. Поясніть процес побудови декодера на основі багатоетапного ресамплінгу.
8. Поясніть процес побудови декодера на основі багатоетапного симетричного ресамплінгу.
9. Охарактеризуйте перелік завдань щодо побудови нейромережевого засобу семантичної сегментації зображення.
10. Охарактеризуйте процедуру визначення типу згорткової нейронної мережі.
11. Як оцінити точність виділення об'єкта на зображенні?
12. Як оцінити точність виділення об'єкта на зображенні у випадку one-hot кодування очікуваного вихідного сигналу та однакових розмірів вхідного та сегментованого зображення?

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. *Терейковська Л. О.* Методологія автоматизованого розпізнавання емоційного стану слухачів системи дистанційного навчання: дис. ... докт. техн. наук: 05.13.06. Київ, 2023. 395 с.
2. *Терейковський І.А., Чернишев Д.О., Корченко О.Г., Терейковська Л.О., Терейковський О. І.* Процедура застосування нейронних мереж для сегментації растрових зображень. Електронне фахове наукове видання "Кібербезпека: освіта, наука, техніка". 2022. Том 2, № 18. С. 25-38.
3. *Danishevskyy V, Gaidar A., Markert B.* Convolutional neural networks for the crack diagnostics in concrete structures. ICSBT 2024. E3S Web of Conferences 534, 01004.
4. *Dmitry A.* Segmentation Object Strategy on Digital Image. Journal of Siberian Federal University. Engineering & Technologies. 2018. № 11(2), pp. 213-220.
5. *Hu Z., Tereykovskiy I., Zorin Y., Tereykovska L., Zhibek A.* Optimization of convolutional neural network structure for biometric authentication by face geometry. Advances in Intelligent Systems and Computing. 2019. Vol. 754, pp. 567-577.
6. *Husein P., Joseph H., Mosavi A.* Deep Learning for Detecting Building Defects Using Convolutional Neural Networks. Sensors 2019, 19, 3556
7. *Shkurat O.* Image Segmentation Method Based on Statistical Parameters of Homogeneous Data Set. Advances in Intelligent Systems and Computing. 2020. Vol. 902, pp. 271–281.

Навчально-методичне видання

ІНФОРМАЦІЙНІ СИСТЕМИ ДІАГНОСТИКИ В БУДІВНИЦТВІ

Методичні вказівки та завдання
до проведення лабораторних занять
для здобувачів першого (бакалаврського) рівня вищої освіти
за спеціальністю 126 «Інформаційні системи та технології»

Укладач **ТЕРЕЙКОВСЬКА** Людмила Олексіївна

Комп'ютерне верстання *А. П. Селівестрової*

Ум. друк. арк. 1,39. Обл.-вид. арк. 1,5
Електронний документ. Вид № 44/V-24.

Виконавець і виготовлювач
Київський національний університет будівництва і архітектури

Проспект Повітряних Сил, 31, Київ, Україна, 03680

Свідоцтво про внесення до Державного реєстру суб'єктів
видавничої справи ДК № 808 від 13.02.2002 р