

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ  
імені ІГОРЯ СІКОРСЬКОГО»**

**Радіотехнічний факультет**

**Кафедра радіоконструювання та виробництва радіоапаратури**

До захисту допущено:

В.о. зав.кафедрою

 – Євгеній НЕЛІН

\_\_\_\_\_ 20\_\_ р.

**Дипломний проєкт**

**на здобуття ступеня бакалавра**

**за освітньо-професійною програмою «Інтелектуальні технології  
мікросистемної радіoeлектронної техніки»**

**за спеціальністю 172 «Телекомунікації та радіотехніка»**

**на тему: «Виявлення дефектів електронного модуля за допомогою  
згорткової нейронної мережі»**

Виконав:

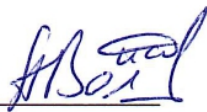
студент IV курсу, групи PI-71

Клюско Володимир Юрійович



Керівник:

Старший викладач Адаменко Володимир Олексійович



Рецензент: к.т.н., доцент каф. РТПС

Сушко Ірина Олександрівна

\_\_\_\_\_

Засвідчую, що у цьому дипломному  
проєкті немає запозичень з праць інших  
авторів без відповідних посилань.

Студент 

Київ – 2021 року

**ПОЯСНЮВАЛЬНА ЗАПИСКА**  
**до дипломного проекту**

на тему: “Виявлення дефектів електронного модуля за допомогою  
згорткової нейронної мережі”

Київ — 2021 року

**Національний технічний університет України  
«Київський політехнічний інститут імені Ігоря Сікорського»**

**Радіотехнічний факультет**

**Кафедра радіоприймання та оброблення сигналів**

Рівень вищої освіти – перший (бакалаврський)

Спеціальність – 172 «Телекомунікації та радіотехніка»

Освітньо-професійна програма «Інтелектуальні технології мікросистемної радіoeлектронної техніки»

ЗАТВЕРДЖУЮ

В.о.зав. кафедрою

*С. Нелін* Євгеній НЕЛІН

«\_\_» \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ**

**на дипломний проєкт студенту**

**Клюску Володимиру Юрійовичу**

1. Тема проєкту «Виявлення дефектів електронного модуля за допомогою згорткової нейронної мережі», керівник проєкту Адаменко Володимир Олексійович, старший викладач, затверджені наказом по університету від «18» травня 2021 р. №1205-с
2. Термін подання студентом проєкту 11 червня 2021 року
3. Вихідні дані до проєкту Датасети для навчання нейронних мереж; Середовище реалізації нейронної мережі: Google Colaboratory; Середовище створення анотацій датасету: Roboflow; Архітектура згорткової нейронної мережі Yolov5 Pytorch.
4. Зміст пояснювальної записки Типи дефектів друкованої плати. Способи перевірки наявності радіoeлементів на друкованій платі. Обґрунтування вибору нейронної мережі. Підготовка, аналіз та вибір даних для розпізнавання дефектів. Вибір архітектури нейронної мережі. Реалізація пошуку дефектів. Результати виконання навчання.

5. Перелік графічного матеріалу (із зазначенням обов'язкових креслеників, плакатів, презентацій тощо Принцип роботи згорткової нейронної мережі; Структура датасету; Алгоритм роботи мережі; Архітектура нейронної мережі.

6. Дата видачі завдання 12 квітня 2021 року

#### Календарний план

| № з/п | Назва етапів виконання дипломного проєкту      | Термін виконання етапів проєкту | Примітка |
|-------|--|---------------------------------|----------|
| 1     | Аналіз дефектів електронного модуля            | 16.05 — 18.05                   |          |
| 2     | Огляд існуючих рішень                          | 19.05 — 21.05                   |          |
| 3     | Огляд типів нейронних мереж                    | 22.05 — 24.05                   |          |
| 4     | Аналіз та вибір набору даних                   | 25.05 — 28.05                   |          |
| 5     | Обґрунтування вибору архітектури мережі        | 29.05 — 31.05                   |          |
| 6     | Реалізація пошуку дефектів                     | 01.06 — 05.06                   |          |
| 7     | Аналіз результатів навчання мережі             | 06.06 — 07.06                   |          |
| 8     | Оформлення текстової та графічної документації | 08.05 — 11.06                   |          |

Студент



Володимир КЛЮСКО

Керівник



Володимир АДАМЕНКО

## АНОТАЦІЯ

Дипломний проект присвячено вирішенню задачі контролю на наявність дефектів, які можуть виникати в процесі виробництва та реалізації електронних модулів.

В процесі роботи виконано аналіз існуючих типів дефектів друкованих плат та компонентів електронного модуля. Розглянуто сучасні методи контролю перевірки наявності радіоелементів на платі та виявлення їх дефектів. Проведено пошук та аналіз наявних наборів даних для навчання штучних нейронних мереж. Синтезовано та навчено згорткову нейронну мережу, яка здатна виявляти компоненти на платі та порівнювати їх із еталонами.

Загальний обсяг роботи складає 58 сторінок, кількість рисунків — 32, посилань — 39, 1 додаток, 4 ілюстративні матеріали.

Ключові слова: згорткова нейронна мережа, дефекти, електронний модуль.

## ANNOTATION

The thesis project is dedicated to the solution of the problem of control of defects which may arise during the production and implementation of electronic modules.


During the work, an analysis of existing types of defects of printed circuit boards and components of the electronic module was carried out. Modern methods of control of presence of radio elements on PCB and identification thereof were considered. The search and analysis of available datasets for training of artificial neural networks were carried out. A convolutional neural network were synthesized and trained, which is able to detect components on the PCB and compare them with standards.

The total amount of the work is 58 pages, amount of illustrations - 32, links - 39, 1 addition, 4 illustrative materials.

Keywords: convolutional neural network, defects, electronic module.

## ЗМІСТ

|   |    |
|---|----|
| Перелік скорочень.....  | 3  |
| Вступ.....  | 4  |
| 1 Типи дефектів та способи перевірки наявності елементів на друкованій платі..... | 5  |
| 1.1 Типи дефектів друкованої плати.....   | 5  |
| 1.1.1 Дефекти провідного рисунку.....   | 5  |
| 1.1.2 Дефекти ізоляційного матеріалу.....   | 6  |
| 1.1.3 Дефекти металізації стінок отворів.....                                     | 7  |
| 1.1.4 Дефекти фінішних покриттів.....   | 8  |
| 1.2 Дефекти встановлення компонентів.....   | 8  |
| 1.3 Методи контролю перевірки наявності радіоелементів на платі...                | 11 |
| 2 Обґрунтування вибору нейронної мережі.....                                      | 19 |
| 2.1 Нейронні мережі. Задачі нейронних мереж.....                                  | 19 |
| 2.1.1 Класифікація.....   | 19 |
| 2.1.2 Передбачення.....   | 20 |
| 2.1.3 Розпізнавання.....  | 22 |
| 2.2 Типи нейронних мереж.....   | 22 |
| 2.2.1 За кількістю шарів.....   | 23 |
| 2.2.2 За напрямком розподілу інформації по синапсам між нейронами.....            | 24 |

|           |                |          |   |      |   |           |      |        |
|-----------|----------------|----------|---|------|---|-----------|------|--------|
|           |                |          |   |      | PI71.426469.001 ПЗ  |           |      |        |
| ЗМ.       | Лист           | № докum. | Підпис  | Дата | Виявлення дефектів<br>електронного модулю за<br>допомогою згорткової<br>нейронної мереж | Лім.      | Лист | Листів |
| Розробив  | Клюско В.Ю.    |          |  |      |   |           | 1    | 57     |
| Перевірів | Адаменко В. О. |          |   |      |   |           |      |        |
|           |                |          |   |      |   | PI-71 РТФ |      |        |
| Н. Контр. | Попсуй В. І.   |          |   |      |   |           |      |        |
| Затвердив | Адаменко В. О. |          |   |      |   |           |      |        |

|  |    |
|--|----|
| 2.2.3 За організацією навчання.....                                    | 25 |
| 3 Виявлення дефектів.....  | 27 |
| 3.1 Підготовка, аналіз та відбір даних для розпізнавання дефектів..... | 27 |
| 3.1.1 PCB-DSLR.....  | 27 |
| 3.1.2 PCB-METAL.....   | 30 |
| 3.1.3 FICS-PCB.....  | 32 |
| 3.2 Вибір архітектури мережі.....                                      | 36 |
| 3.2.1 YOLOv3 з використанням Darknet.....                              | 37 |
| 3.2.2 YOLOv5 з використанням PyTorch.....                              | 39 |
| 4 Реалізація пошуку дефектів.....                                      | 43 |
| 4.1 Підготовка даних та написання програми.....                        | 43 |
| 4.2 Результати виконання навчання.....                                 | 45 |
| Висновки.....  | 54 |
| Перелік джерел посилань.....   | 55 |
| Додаток А.....   | 59 |



## ПЕРЕЛІК СКОРОЧЕНЬ

ДП — друкована плата

ШНМ — штучна нейронна мережа

ЗНМ — згорткова нейронна мережа

YOLO — you only look once

mAP — mean average precision

GPU — graphics processing unit

PCB — printed circuit boards

FICS — Florida Institute for Cybersecurity

METAL — Micro Electronics Taken Apart Logically

DSLR — Digital single-lens reflex camera

CNN — convolutional neural network

CSP — Scalling Cross stage Partial network

|     |      |          |        |      |                    |      |
|-----|------|----------|--------|------|--------------------|------|
|     |      |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |      |          |        |      |                    | 3    |
| Зм. | Лист | № докум. | Підпис | Дата |                    |      |

## ВСТУП

Автоматизація виробництва електронних модулів (друкованих вузлів) є невід'ємною складовою сучасного виробництва радіоелектронної апаратури. Важливим етапом виробництва електронних модулів є контроль за відсутністю дефектів, які можуть виникати на різних етапах виробництва.

Завчасно знаходити дефекти є дуже важливою задачею, адже при встановленні несправних електронних модулів в завершені прилади не тільки підвищить загальні витрати на виробництво та сервісне обслуговування радіоелектронної апаратури, а й можуть спричинити травмування кінцевого користувача такою апаратурою.

В нинішній час йде тенденція до зменшення електронного модулю та наявних на йому компонентів для більшої компактності пристрою, в якому вони будуть міститись. Малі габарити компонентів та висока щільність їх установки ставлять високі вимоги до якості зображення друкованої плати та до точності систем автоматичної перевірки дефектів. Тому виникає потреба в високоякісному наборі зображень для аналізу та в сучасній системі перевірки наявності дефектів на зображеннях.

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | РІ71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 4    |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

# 1 ТИПИ ДЕФЕКТІВ ТА СПОСОБИ ПЕРЕВІРКИ НАЯВНОСТІ ЕЛЕМЕНТІВ НА ДРУКОВАНІЙ ПЛАТІ

## 1.1 Типи дефектів друкованої плати

У виробництві друкованих плат, як і в будь-якій іншій сфері існує багато ситуацій які спричиняють виникнення дефектів. Знання найпоширеніших типів дефектів друкованої плати та електронного модулю дає можливість запобігання подальшої їх появи. Одними з найпоширеніших є дефекти пайки та компонентів друкованої плати. Далі будуть розглянуті деякі з цих дефектів.

### 1.1.1 Дефекти провідного рисунку

**Поглиблення** — зменшення товщини провідного шару, внаслідок чого зменшується міжсекційна зона провідника.

**Звуження** — зменшення ширини провідника в порівнянні з заданим значенням на відстані, що значно переважає ширину провідника. Причиною даного дефекту може бути неправильний розподіл температурного та часового режимів виробництва, виникнення повітряних бульбашок в електrolіті.

**Розширення** — збільшення ширини провідника в порівнянні з заданим значенням на відстані, що значно переважає ширину провідника. Виникає внаслідок забруднення поверхні текстоліту, механічного пошкодження та викривлення внаслідок деформації друкованої плати. Зменшення відстані між провідниками може призвести до електричного дефекту або до зміни ємності контуру.

**Розрив** — відсутність провідного матеріалу в локалізованій зоні, внаслідок чого відбувається порушення електричного зв'язку провідника. Цей дефект виникає від наявності областей провідного рисунку, що не покриті гальванічно нанесеним металорезистом (або при пошкодженні

|     |      |          |        |      |
|-----|------|----------|--------|------|
|     |      |          |        |      |
| Зм. | Лист | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

5

металорезисту під час міжопераційного транспортування та в процесі травлення міді з незахищених місць)[1].

**Тріщина** — відсутність провідного матеріалу в локалізованій зоні в межах провідника. Характерною особливістю дефекту є значна перевага довжини над його шириною. Причиною дефекту є вплив вологи, що визначається відносною вологістю повітря, температурою та тривалістю дії.

**Зміщення центру отвору** — відхилення отворів відносно центрів провідного рисунка. Якість отворів залежить від режимів свердління, геометрії та якості різальних кромek свердла. Значно впливає точність виготовлення фотошаблону, похибка встановлення заготовки на свердлильному верстаті.

**Зміна геометрії контактної площадки** — це відхилення геометрії контактної площадки від концентричного кола. Причиною виникнення являється невідповідність розмірів контактних площадок, що виконуються у вигляді кільця. Їх діаметр має бути більшим за діаметр отвору.

### **1.1.2 Дефекти ізоляційного матеріалу**

**Плями** — білі плями з'являються нижче поверхні базового матеріалу. Поява цього дефекту в базовому матеріалі з шарів тканинних волокон, в якому пучки розділені в місцях перетину тканини. Слід зазначити, що вплив такої плям не є значним.

**Тріщини** — внутрішній дефект, що проявляється в базовому матеріалі при розплетенні волокон тканини, при якому по скловолокну, структурою якого є нитка або джгут, можуть виникати тріщини вздовж нитки. Причиною є механічне пошкодження [2].

**Розшарування** — розділення між шарами в рамках базового матеріалу, між матеріалом та фольгою. Найкраще використовувати текстоліт, ймовірність його розшарування дуже невисока.

**Пузиріння** — локалізоване збільшення і віддалення між будь-якими шарами, або між базовим матеріалом та фольгою або захисним покриттям.

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 6    |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

Цей дефект виникає при впливу вологи в внутрішніх міжшарових порожнечках. Діелектричного матеріалу, що накопичується в процесі збереження або експлуатації.

**Викривлення** — деформація, що характеризується циліндричною або сферичною кривизною, при якому якщо друкована плата (ДП) має прямокутну форму її чотири кути лежать в одній площині. Виникає від допущених помилок під час визначення профілю пресування, неправильної збірки заготовки перед пресуванням. Нерівномірність товщини міді та незбалансованість рисунку провідників у внутрішніх шарах також викликає даний дефект.

### **1.1.3 Дефекти металізації стінок отворів**

**Задирки на краях контакту** — являються причиною зниження точності деталі, зниження точності контролю розмірів. Задирки перешкоджають збірці виробів, порушують експлуатаційні характеристики виробу. Основною причиною цього дефекту є пошкодження свердла з недопустимим зносом країв. На розміри задирки впливають фізико—математичні характеристики оброблювального матеріалу, геометрія інструменту та заготовки, параметри експлуатації леза та режим різання.

**Шорсткість поверхні** — нерівності на боковій стінці отвору. Розплавлення епоксидної смоли склотекстоліту з утворенням на стінках епоксидних плям через недотримання режиму роботи зі свердлом.

**Недостатня кількість металізації** — відсутність або мала кількість металізації. Причиною дефекту є погана розсіювальна здатність електроліту, порушення режимів осадження (часу, відхилення в складі електроліту, наявність задирок на краях).

**Нерівномірний розподіл шару** — нерівномірний розподіл шару металізації по глибині отвору. Нерівності країв осадженого металорезисту.

**Порушення контакту** — порушення контакту шару металізації з внутрішніми отворами контактними площадками багатшарових друкованих

|     |     |          |        |      |                    |           |
|-----|-----|----------|--------|------|--------------------|-----------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист<br>7 |
| Зм. | Лис | № докум. | Підпис | Дата |                    |           |

плат. Розігрів і плавлення епоксидної смоли через недотримання режимів свердління смоли на торці внутрішніх контактних площадок викликають даний дефект.

**Неметалізовані ділянки** — утворення порожнеч при електрохімічній металізації, що спричиняють порушення електричного контуру, а також знижують міцність зчеплення контактної площадки з підложкою. Виникають ділянки від порушення режимів свердління та поганої очистки отворів після проведення свердління.

#### 1.1.4 Дефекти фінішних покриттів

**Діаметр отворів** — звуження отворів при свердлінні механічними свердлами, а також спотворення результатів лазерного або плазмового свердління. Якість отворів залежить від режимів свердління (до режимів свердління, зокрема, належать: швидкість різання, величина подачі і глибина різання) [3].

**Припідняті ділянки** — ділянки можуть затримувати домішки в процесі монтажу і являються небажаними для монтажу.

**Напливи** — товщина сплаву на друкованих платах за вимогами стандарту повинна бути в межах 10...12 мкм. У випадку, коли товщина сплаву буде більшою за 15 мкм, то при його оплавленні буде спостерігатись краплеутворення і напливи в отворах, що ускладнить монтаж радіoeлектронних компонентів на плату [4].

**Незмочування** — обмеження розтікання припою на контактні поверхні з залишком без змочування області поверхні базового металу. Як наслідок — утворення корозії, оксидної плівки на поверхні металу. Визначається умовами експлуатації, способом зберігання.

#### 1.2 Дефекти встановлення компонентів

Перевірка правильності компонентів на платі являється не менш важливою, аніж перевірка цілісності самої друкованої плати. Лише один

|     |      |          |        |      |                    |      |
|-----|------|----------|--------|------|--------------------|------|
|     |      |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |      |          |        |      |                    | 8    |
| Зм. | Лист | № докум. | Підпис | Дата |                    |      |

Компонент з дефектами може поставити під загрозу роботу всього електронного модуля.

SMD-елементи, що мають невеликі розміри і встановлені на на поверхні друкованої плати, можуть отримати пошкодження цілого елемента або контакту лише від незначної деформації. Однією з найбільш поширених являється проблеми пайки. Наприклад, багатошарові керамічні конденсатори можуть мати тріщини від тиску на них при монтажі або через велику дозачію припою (рис. 1.1). Найменше викривлення або удар призводить появу тріщин в компоненті. Дані дефекти непомітні для людського ока, тому під час тестування електронного модуля проводять внутрішньосхемне тестування.




Рисунок 1.1 — Тріщина конденсатора

Неправильне встановлення компоненту також може внести свої кореткиви в роботу електронного модуля. До того ж, під час тестування необхідно перевіряти вірність габаритів компоненту, правильність маркування та розміщення елемента на друкованій платі. Методи перевірки дефектів нерідко при порівнянні “правильної” та дійсної плати можуть помітити відсутність компоненту.

Припідняті компоненти на друкованій платі (англ. lifted component) можуть виникати під час пайки хвилею з ряду причин. Однією з причин може бути теплове навантаження на виводи. Звичайне збільшення часу занурення в хвилю усунуло проблему. На лямбда-хвилях можна збільшити

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
9

час контакту, налаштувавши при цьому зворотню хвилю. Неправильна кількість пайки також може призвести до даної проблеми. Окрім того, компоненти, що мають теплові вимоги інші, аніж друкована плата, можуть спричинити підйом під час хвильового контакту (рис. 2.1).




Рисунок 1.2 — Припіднятий компонент

Відсутність лише одного компоненту електронного модуля може спричинити неправильну роботу всієї системи. З появою автоматичного візуального контролю (більша частина роботи якого припадає на нейронну мережу, а не людину) більше уваги виділяється системам візуального контролю. Наявність компоненту можна перевіряти як просто на друкованій платі (під час її проектування перевірка футпрінтів відповідних компонентів), так і метод порівняння зображень, коли вже готовий функціонуючий електронний модуль перевіряється із тільки що виготовленим (рис. 1.3).


Операція порівняння двох зображень є доволі простою технікою сенс якої полягає в тому, що обидва зображення порівнюються піксель за пікселем, після чого виконується логічна операція XOR. Операція XOR застосовується як на еталонних, так і на тестових зображеннях.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |


PI71.426469.001 ПЗ

Лист  
10






(а) Знімок плати, що перевіряється



(б) Знімок правильної плати



(в) Знімок тестової плати



(г) Результат оператору XOR

Рисунок 1.3 — Порівняння еталонної плати та тестової плати на відсутність компонентів

Замикання внаслідок припою найчастіше з'являються в процесі пайки хвилею. Із зменшенням розмірів компонентів складніше знайти й необхідну пропорцію припою. Збільшення припою є одним із способів зменшити шанс появи короткого замикання.

### 1.3 Методи контролю перевірки наявності радіоелементів на платі

**Ручний візуальний огляд** — найпростіший та найпоширеніший спосіб перевірки друкованих плат. Хоч візуальний контроль може здатись

застарілим в порівнянні з його більш сучасними автоматизованими аналогами, є два обмеження, які вимагають від виробників розвивати та підтримувати високий рівень звичайного візуального контролю. По-перше згідно із стандартом USP <1970> будь-який альтернативний ручному

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

11

візуальному огляду метод повинен мати еквівалентну або ж кращу ефективність, порівняно з ручним візуальним контролем. Кваліфікацію виробників можна підняти швидше та простіше в порівнянні з іншими, тому його можна вважати базовим. По-друге, після повного візуального огляду перевіряється вибірка прийнятих одиниць кожної партії. Це гарантує, що рівень дефектів, що залишився, є статично прийнятним. Поточні збірники та нормативні акти вимагають проведення цієї перевірки вручну. Ручний візуальний контроль перевіряє наступні характеристики:

- товщина плати є правильною, та чи немає деформації поверхні;
- якість поверхні, перевірка наявності вм'ятин, подряпин, отворів на доріжках;
- перехідні отвори знаходяться в правильних положеннях. Перевірка, щоб вони відповідали технічним вимогам та не мали порожнеч;
- шорсткість та виступи контактних площадок;
- якість покриття. Перевірка флюсу для покриття та рівномірність, стійкість та правильність положення.

Даний метод має ряд переваг перед іншими способами перевірки. Завдяки своїй простоті він є недорогим, не потрібна наявність будь-якого спеціалізованого обладнання. До того ж даний метод проводиться досить швидко та може комбінуватись із деякими іншими методами.

Серед недоліків слід відзначити його неточність (через відсутність дорогого обладнання, яке оцифровує всі результати).

**Автоматичний візуальний контроль (AOI — Automated Optical Inspection)** — можна використовувати і спеціальний пристрій для візуального контролю. В даному випадку цей метод називається автоматизованим візуальним контролем. Система AOI проводить перевірку з використанням декількох джерел світла та використання однієї або декілька фотокамер чи відеокamer [5]. Джерела світла освітлюють плату під різними кутами. Після зроблених знімків чи відеоматеріалу система порівнює їх з

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 12   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

“правильними знімками”. Доступна як двовимірне (ширина та діаметр) так і тривимірне обладнання системи автоматичного візуального контролю. Тривимірне обладнання АОВІ являється новим та може додатково вимірювати і висоту компоненту. Даний спосіб контролю зображено на рис. 1.4.




Рисунок 1.4 — Автоматичний візуальний контроль

Автоматичний візуальний контроль виявляє такі ж дефекти, як і ручний візуальний контроль. Окрім того він може знаходити подряпини, розімкнуті ланцюги, неправильно встановлені або відсутні компоненти, неправильне маркування та багато інших дефектів. Цей метод є досить точним та може виявити багато несправностей. Він є швидшим, аніж ручний візуальний контроль і виключає можливість помилки людини. З недоліків слід виділити високу вартість устаткування (для виявлення більшої кількості дефектів необхідно зробити більші затрати), автоматичний візуальний контроль не можна використовувати для елементів, що знаходяться поза зоною видимості, також він не є ефективним для плат, що мають високу концентрацію компонентів (деякі з них можуть бути прихованими, або не зовсім помітними) [6].

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

13

**Внутрішньосхемне тестування (ICT — In-Circuit testing)** — перевірка компонентів на основі моделі конструкції. Це найнадійніший тип тестування друкованих плат. Двома загальноприйнятими методами внутрішньосхемного тестування є “ложе цвяхів” (з англ. bed of nails) та “літаючий зонд” (англ. flying probe) [7].

“Ложе цвяхів” — це спосіб перевірки дефектів за допомогою пінів типу “рого”, що контактують з кількома точками на друкованій платі. Ці піни нагадують собою ложе цвяхів (див. рис. 1.5.), звідси і мають таку назву. За допомогою цього методу можна виявити короткі замикання, обриви на схемі, нерівномірності паяльної маски, пошкоджені елементи та інші несправності друкованої плати [8].




Рисунок 1.5 — “Ложе цвяхів”

Як правило, техніка “ложе цвяхів” — це швидкий, недорогий метод випробувань, який підходить для масового виробництва, простих схем та аналогових плат. Проте цей спосіб тестування не являється ефективним при роботі зі складними за конструкцією платами, особливо з тими, що мають вузькі доріжки, SMD, BGA елементами.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
14



“Літаючий зонд” — метод тестування друкованих плат, що використовує інструмент для взаємодії елементами, що мають менший крок ніж простіші елементи (такі як піни SMD елементів) та мають розмір кроку 0,2 мм. На практиці використовується декілька зондів (показано на рис. 1.6.), щоб встановити контакт з пінами, контактними площадками, перехідними отворами та перевірити плату на короткі замикання, обриви та електричні параметри: полярність, опір, ємність [7].




Рисунок 1.6 — “Літаючий зонд”

Серед переваг цієї техніки над “ложею цвяхів” слід відзначити тестування кожного компонента індивідуально, низькі витрати на устаткування, можливість тестування світлодіодів. Проте метод “літаючий зонд” має більший час періоду випробувань циклу та вартість витрат на одиницю компонента, неможливість тестування роз’ємів та неактивних компонентів [9].

**Периферійне сканування** — вид структурного тестування друкованої плати з встановленими на ній компонентами. Широко використовується також термін “граничне сканування”. Назву взято з того, що відповідні

|     |      |          |        |      |
|-----|------|----------|--------|------|
|     |      |          |        |      |
| Зм. | Лист | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
15

мікросхеми можуть при певних умовах самі протестувати своє оточення (периферію) на наявність дефектів. Даний метод може перевіряти плату на наявність коротких замикань, обривів, западання на “0” чи на “1”, дефекти доріжок. Для застосування периферійного сканування необхідна наявність на платі компонентів, що його підтримують. Їх ще називають компонентами з JTAG-інтерфейсом.

**Рентгенівський контроль** — метод для виявлення дефектів, що непомітні людському оку. З розвитком технології поверхневого монтажу друковані плати стали більш складними. Плати можуть мати більш щільне заповнення компонентів, менші розміри компонентів та мати мікросхеми типу BGA або CSP в яких взагалі не видно припою. Для виявлення дефектів на таких масштабах краще всього підійде даний метод. Метод спирається на здатність матеріалів поглинати рентгенівські промені відповідно до їх товщини та атомного номера. Більш важкі матеріали, такі як припій, зазвичай поглинають більше рентгенівських променів і є більш помітними. Натомість легкі елементи, прикладом можна навести інтегральну схему, виглядають більш прозорими, оскільки поглинають менше рентгенівських променів. Таким чином рентгенівські промені можуть перевіряти пайку та з’єднання й виявляти структурні дефекти, такі як короткі замикання, обриви, недостатня кількість припою, надлишок припою та порожнечі. Окрім того можна виявити несиметричні зв’язки, злиття й утворення припоєм неправильної форми, провести аналіз пайки для виявлення таких дефектів припою як бульбашки, гребінці [10]. Даний спосіб представлено на рис. 1.7.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

16




Рисунок 1.7 — Рентгенівський контроль

Рентгенівський контроль ідеально підходить для перевірки плат, що містять елементи з конструкцією SMD, BGA, перевірки шарів плати, пайки, положення елементів. Дана технологія вимагає дорогого устаткування для взаємодії з малими за габаритами елементами.

**Функціональне тестування (англ. FCT Functional communication test)** — перевірка функціональності друкованої плати та її поведінку. Для кожної плати існує свій функціональний тест. Функціональні тестери, як правило, взаємодіють з друкованою платою через її крайній роз'єм (edge connector) або точки зонду. Це тестування моделює остаточне електричне середовище, в якому буде використовуватися ДП. Найпоширеніша форма функціонального тестування відома як “гарячий макет” (“hot mock-up”) перевіряє чи працює ДП належним чином. Перевагами даного методу є: імітування робочого середовища, що мінімізує дорогі витрати на устаткування; він є одним з найефективніших, порівнюючи його з іншими методами перевірки. Дане тестування вимагає великої кількості часу, проте з точки зору якості та довговічності він значно зберігає затрати в майбутньому.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

17

**Інші функціональні тести** — існують і інші види функціональних тестів, які вже націлені на конкретні задачі. Наприклад:

– Випробування на паяльність: забезпечує міцність поверхні та збільшує шанси на створення надійного паяного з'єднання.

– Тест на забруднення друкованих плат: виявлення речовин, що можуть забруднити плату спричинивши корозію.

– Аналіз мікросекції: знаходження термомеханічних пошкоджень, дефекти компоненту, замикання або обриви, помилки обробки через оплавлення припою [11].

### **Висновки до першого розділу**

В даному розділі розглянуто основні типи дефектів плати та наведено основні методи перевірки дефектів. Порівнюючи методи визначено, що одним із найефективніших способів для масового виробництва є автоматичний візуальний контроль. Проте існуючі методи візуального контролю потребують дуже точного позиціонування камер, які фотографують компоненти, щоб зображення компоненту максимально “співпало” з еталонним. Вирішити цю проблему можна додавши до таких автоматичних систем інтелектуальний алгоритм оброблення зображень. Одним з найефективніших способів оброблення зображень на сьогодні є використання штучних нейронних мереж (ШНМ), тому в наступному розділі більш докладно розглянемо ШНМ.

|     |      |          |        |      |
|-----|------|----------|--------|------|
|     |      |          |        |      |
| Зм. | Лист | № докум. | Підпис | Дата |

*PI71.426469.001 ПЗ*

*Лист*

*18*



## 2 ОБГРУНТУВАННЯ ВИБОРУ НЕЙРОННОЇ МЕРЕЖІ

### 2.1 Нейронні мережі. Задачі нейронних мереж

Штучна нейронна мережа (ШНМ) — популярні методи машинного навчання, що імітують механізм навчання в біологічних організмах. Нейрони пов'язані між собою за допомогою аксонів і дендритів, а сполучені області між аксонами і дендритами називаються — синапси. Нейронна мережа — послідовність нейронів, що пов'язані один з одним синапсами. Одна з особливостей нейронних мереж, що вони здатні не лише аналізувати, а й запам'ятовувати різну інформацію. Нейронні мережі також мають високу стійкість до зашумлених даних, а також можуть класифікувати шаблони на яких вони не були навчені.

Задачі нейронних мереж:

#### 2.1.1 Класифікація

Являється одним з найважливіших завдань інтелектуального аналізу даних. Вона вирішується за допомогою аналітичних моделей, що називаються класифікаторами. Перевагами цього типу задачі являється простота алгоритмів та методів її реалізації в порівнянні з іншими технологіями аналізу даних. Розроблено багато типів класифікаторів для яких використовуються як статичні дані (логістична регресія, дискримінантний аналіз,) так і методи машинного навчання (нейронні мережі, дерева рішень, метод k-найближчих сусідів, машинні опорні вектори). Класифікатори, в основі яких лежать машинне навчання, не потребують оцінки параметрів розподілу вихідних даних [12]. Як правило, вони простіші в реалізації і використанні, аніж параметричні. Серед переваг використання нейронних мереж в якості класифікаторів можна виділити:

— Нейронні мережі являються самонавчальними моделями, процес навчання практично не потребує втручання користувача;

|     |      |          |        |      |
|-----|------|----------|--------|------|
|     |      |          |        |      |
| Зм. | Лист | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

19

- Нейронні мережі є універсальними апроксиматорами, що дозволяють апроксимувати будь-яку неперервну функцію з прийнятною точністю;
- Нейронні мережі є нелінійними моделями, що дозволяє ефективно вирішувати задачі класифікації навіть при відсутності лінійної роздільності класів (див. рис. 2.1)




Рисунок 2.1 — Лінійна роздільність класів; лінійно роздільні класи (а);  
лінійно нероздільні класи (б)

Задача класифікації може поєднуватись і з іншими завданнями (наприклад при знаходженні об'єктів на зображенні спочатку виконується задача розпізнавання після чого йде розв'язок задачі класифікації).

### 2.1.2 Передбачення

Нейронні мережі також здатні виконувати задачу прогнозування, тобто передбачення майбутніх подій, прогнозування подальшого продовження ситуації. Головною ціллю передбачення являється оцінка можливого розвитку подій та зменшення ризику при прийнятті рішень. Хоч прогноз зазвичай виходить помилковим, проте величина помилки залежить від прогнозувальної системи.

ШНМ застосовується для вирішення задач прогнозування часових рядів — користувач обирає довільний часовий ряд, що має  $N$  відліків, та розбиває його на три множини: навчальну, тестувальну та контрольну вибірки, котрі

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
20

потім подаються на вхід мережі. Результатом даного передбачення являється значення часового ряду в необхідний момент часу. Для покращення якості прогнозування необхідно виконувати попередню обробку інформації. Тобто це кожна вибірка часового ряду, що являє собою дискретну функцію, що задана в інтервалі  $[0, N]$  з кроком 1, де  $N$  — максимальне значення аргументу даної функції. При вирішенні задач прогнозування ціль нейронної мережі в тому, щоб зробити прогнозування майбутньої реакції системи до її попередньої поведінки. Тобто, маючи уявлення про значення змінної в момент часу  $x$ , що базується на знанні значення функції в попередні моменти часу  $x(k-1)$ ,  $x(k-2)$ , ...,  $x(k-N)$ , можна спрогнозувати найбільш ймовірне значення послідовності  $\bar{x}(k)$  в поточний момент часу  $k$ . При виборі архітектури мережі зазвичай обираються декілька типів конфігурацій з різною кількістю елементів; серед типів нейронних мереж найбільш популярні наступні: багатoshаровий персептрон (MLP), радіально-базисна мережа (RBF), узагальнено-регресійною мережею (GRNN) (структуру даної мережі показано на рис. 2.2), мережа Вольтеррі і мережа Ельмана [13].

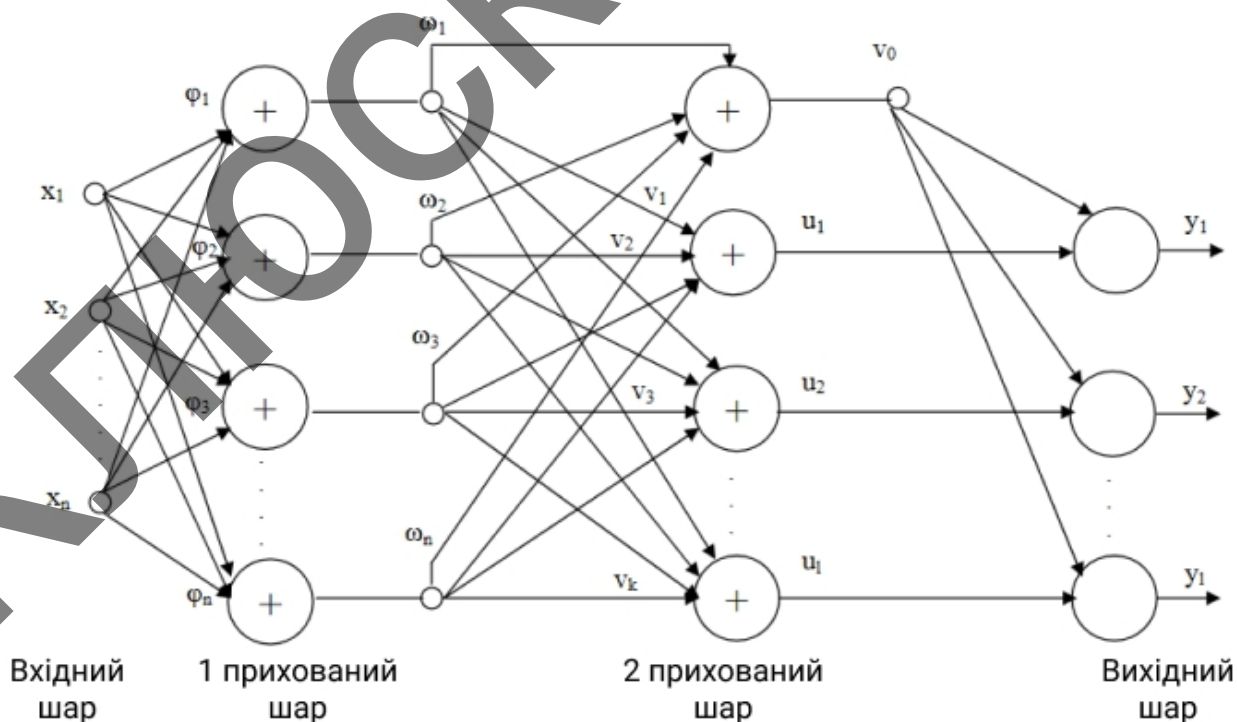


Рисунок 2.2 — Узагальнена структура мережі GRNN

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
21

Типовими прикладами даного методу являються: маски чутливості (англ. saliency mask), алгоритм LIME, SNAPley коефіцієнти

### 2.1.3 Розпізнавання

Нейронні мережі для розпізнавання зображень являються одним з найбільш популярних способів застосування нейронних мереж. Зазвичай, задача розпізнавання направлена на роботу нейронної мережі з зображеннями. Пошук об'єктів на фото почав розвиватись відносно недавно [15].

Виділяють наступні типи нейронних мереж для розпізнавання зображень:

- Багат шаровий перцептрон. Будується із 3 шарів і застосовує нелінійну функцію активації для класифікації даних.
- Згорткова. Має згорткові шари.
- Рекурсивна. Глибока нейронна мережа, яка формується застосуванням одним набором ваг рекурсивно над структурою для скалярних або структурованих передбачень.
- Рекурентна. Мережа, в котрій зв'язки між нейронами представляють собою напрямлені цикли.
- Довга короткочасна пам'ять (з англ. Long short-term memory — LSTM). Один з видів рекурентної мережі, котра дозволяє максимально точно моделювати часові послідовності, а також характерні для них залежності в довгостроковій перспективі.
- Sequence-to-Sequence. Модель мережі, котра складається з двох рекурентних нейронних мереж, що виконують функції кодувальника та декодера [16].

## 2.2 Типи нейронних мереж

Кожна ШНМ включає в себе перший шар нейронів, що

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

|      |
|------|
| Лист |
| 22   |

називається вхідним. Даний шар не виконує перетворення або обчислення, його задача — приймати і розподіляти вхідні сигнали по іншим нейронам [17]. Даний шар являється єдиним спільним для всіх нейронних мереж, натомість критеріями для поділу слугує вже подальша структура.

### 2.2.1 За кількістю шарів

**Одношарова нейронна мережа.** Являє собою структуру взаємодії нейронів, де сигнали з вхідного шару одразу направляються на вихідний шар, котрий не тільки перетворює сигнал, а й одразу дає відповідь.




Рисунок 2.3 — Схема одношарової нейронної мережі

На рисунку 2.3 показано схему одношарової нейронної мережі, де видно, що сигнали  $x_1, x_2, \dots, x_n$  надходять на вхідний шар, а потім сигнали розподіляються на вихідний шар звичайних нейронів. Над стрілками показані ваги відповідних зв'язків (вагові коефіцієнти) [18].

**Багатошарова нейронна мережа.** ШНМ, що складається з вхідного, вихідного і розташованого між ними одного (або декількох) прихованих шарів нейронів. Окрім вхідного та вихідного шарів дані нейронні мережі мають проміжні приховані шари. Багатошарові нейронні мережі являються більш функціональними та мають більше можливостей, ніж одношарові,

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
23

проте методи навчання нейронів прихованого шару розроблені відносно недавно [19]. Структура показана на рисунку 2.4



Рисунок 2.4 — Схема багатошарової нейронної мережі

Одним з прикладів багатошарової нейронної мережі являється згорткова нейронна мережа (ЗНМ), що буде більш детально розглядатись далі.

### 2.2.2 За напрямком розподілу інформації по синапсам між нейронами

**Нейронні мережі прямого поширення (однонаправлені).** В цій структурі сигнал переміщається по напрямку від вхідного шару до вихідного. Рух сигналу в зворотному напрямку не відбувається і взагалі не є можливим. Мережі прямого поширення вирішують задачі прогнозування, кластеризації і розпізнавання.

**Рекурентні нейронні мережі (з зворотнім зв'язком).** В даній нейронній мережі сигнал рухається в прямому і зворотному напрямках. Результат, що утворився на виході може повертатись на вхід. Вихід нейрона визначають ваговими характеристиками та вхідними сигналами. За допомогою даних нейронних мереж можна створити нейронні мережі, що мають властивості короточасної пам'яті, тобто можуть відновлювати або доповнювати сигнали.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
24

**Радіально базисні функції** (англ. Radial Basis Function Networks). Мережі, що використовують радіально-симетричні функції — найпростіший клас функцій. Характерна властивість даної функції полягає в тому, що відгук функції монотонно спадає (зростає) з віддаленням від центральної точки (прикладом можна навести функцію Гауса) [20].

**Нейронна мережа Кохонена.** Клас нейронних мереж, що виконують задачі кластеризації, класифікації та похідні від неї. Мережа складається всього з двох шарів — вхідного та вихідного (який ще називають шар Кохонена). В мережі Кохонена кожен нейрон вхідного шару пов'язаний з усіма нейронами вихідного, проте всередині шарів зв'язків немає. Вхідні нейрони не приймають участь в процесі навчання і обробки даних, а лише розподіляють вхідний сигнал по нейронам наступного шару.

### 2.2.3 За організацією навчання

**Навчання нейронних мереж з вчителем** (англ. supervised neural networks). Навчання з вчителем передбачає, що для кожного вхідного вектору з навчальної множини існує необхідне значення вихідного вектору. Дані вектори утворюють навчальну пару, ваги мережі змінюють до тих пір, поки для кожного вхідного вектору не буде отриманий прийнятний рівень відхилення вихідного вектору від цільового. Для нейронної мережі необхідний повний набір відсортованих даних. Тобто для кожного прикладу, що міститься в наборі даних є відповідь, яку і повинен отримати алгоритм. Навчання з вчителем націлене на задачі класифікації та регресії.

**Навчання нейронних мереж без вчителя** (англ. unsupervised neural network). Один із способів навчання нейронних мереж, в якому мережа виконує задачу без втручання експериментатора. Цей тип нейронної мережі найбільш підходящий для задач виявлення внутрішніх взаємозв'язків, залежності між об'єктами. Алгоритм намагається упорядкувати дані та описати їх структуру. Це може виглядати як групування даних в кластери або

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

25

таке упорядкування набору даних, при якому вони починають набувати певну систематизацію.

**Часткове навчання** (англ. semi-supervised neural network). Навчальний набір даних має як розмічені (набори одиниць інформації з прописаними мітками, тегами) дані так і довільні. Цей метод найбільш підходящий, коли необхідно виділити з даних важливі ознаки, або коли занадто трудомістко виділити одразу всі необхідні властивості. Комбінуючи методи навчання алгоритми можуть навчатись робити розмітку даних самостійно.

### **Висновки до другого розділу**

Найбільш підходящою для знаходження дефектів електронного модуля являється згорткова нейронна мережа. Це можна пояснити тим, що в якості вхідних та вихідних даних в мережі виступає зображення. ЗНМ складається одразу з декількох шарів, вона чергує згорткові та субдискретизуючі шари. Обрана ШНМ буде розв'язувати задачу розпізнавання та виявлення компонентів на друкованій платі.

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 26   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |



## 3 ВИЯВЛЕННЯ ДЕФЕКТІВ

### 3.1 Підготовка, аналіз та відбір даних для розпізнавання дефектів

Існує не так багато загальнодоступних датасетів для проведення розпізнавання дефектів електронного модулю. Далі буде наведено приклади деяких з них.

#### 3.1.1 PCB-DSLR

Датасет, що підготовлений в Віденському технічному університеті, містить 748 зображень друкованих плат зроблених за допомогою професійної цифрової дзеркальної DSLR (Digital single-lens reflex camera) камери. Надано точну інформацію про сегментацію друкованих плат і про обмежувальну рамку для всіх мікросхем (9313 зразків). Датасет містить зображення 165 унікальних друкованих плат, що зняті під різними кутами (одразу декілька видів).

Для отримання точного набору даних побудовано систему підготовки зображень (рис. 3.1).




Рисунок 3.1 — Організація процесу підготовки зображення

|     |      |          |        |      |
|-----|------|----------|--------|------|
|     |      |          |        |      |
| Зм. | Лист | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

27

Ця система містить камеру DSLR Nikon D4 з об'єктивом 60 мм f/2,8 яка встановлена на відстані 107 см над конвеєрною стрічкою. Положення камери та об'єктив забезпечують повну видимість друкованих плат та елементів на одному зображенні. Професійна DSLR камера дає змогу робити зображення високої роздільної здатності та якості (для кращого виявлення компонентів та розпізнавання тексту). Для забезпечення постійного освітлення система прийому даних оточена прозорими фіранками, що блокують зовнішнє світло. Всередині системи поляризоване світло використовується для освітлення потоку відходів, що значно придушує дзеркальні відбиття [21].

165 друкованих плах взято з різних пристроїв (таких як: ПК, ноутбуки, планшети та інші електронні пристрої). На практиці складно встановити положення друкованих плат, тому для кожної плати зроблено по 3-5 зображень з різних ракурсів та положень. Окрім цього, даний датасет містить різні аспекти інформації про друковану плату. Для кожного зображення є інформація про сегментацію друкованих плат у формі двійкового зображення. Сегментація була проведена за допомогою методу GrabCut. Ця інформація буде корисною для отримання інформації про геометрію друкованих плат та для оцінки методів автоматичної сегментації. Окрім того, надається інформація про обмежувальну рамку для кожної мікросхеми на кожній платі. Для 1740 зразків також надається надписи, що зазначаються на схемах.

Загальна кількість унікальних маркованих мікросхем становить 2048. Зображені друковані плати значно відрізняються за розміром, їх мінімальний, медіанний та максимальний розміри становлять відповідно: 37,3 см<sup>2</sup>, 350,2 см<sup>2</sup>, 835,7 см<sup>2</sup>. Розміри друкованих плат були екстрапольовані з інформації про сегментацію тому є приблизними. Один з прикладів зображення з датасету показаний на рисунку 3.2

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 28   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |




Рисунок 3.2 — Зображення з датасету PCB-DSLR

Більшість друкованих плат містять менше 20 мікросхем, 42 друковані плати (що становить 25,5%) містять щонайбільше 3 мікросхеми, 84 друковані плати (50,9%) містять щонайбільше 9 мікросхем, 137 (83,0%) плат мають щонайбільше 19 мікросхем; найбільша кількість мікросхем на платі — 135 [22].




Рисунок 3.3 — Гістограма кількості мікросхем на одну плату

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
29

Даний датасет містить і багато більше зображень компонентів, проте основний акцент та анотації зроблені на мікросхеми.

### **3.1.2 PCB-METAL**

Датасет підготовлений працівниками університету Північної Кароліни Вілмінгтон. Зроблено 984 зображення із високою роздільною здатністю, 123 унікальні друковані плати, що містять анотації обмежувальних рамок для мікросхем (кількістю 5844), конденсаторів (3175), резисторів (2670) та котушок індуктивності (542). Даний датасет можна застосувати для задач розпізнавання (виявлення) компонентів, класифікація друкованих плат, витяг конструкції схеми та ін. PCB-METAL (PCB-Micro Electronics Taken Apart Logically) містить підходящі зображення для автоматичного виявлення елементів [23].

Плати для даного датасету взяті з різних електронних пристроїв, починаючи від комп'ютера і закінчуючи телефоном. Роздільна здатність достатня для деталізації навіть найменшого компонента поверхневого кріплення. Крім того, на відміну від описаного вище датасету (PCB-DSLR) даний не має на зображеннях частинок пилу, відсутній ефект розмитості, поганого освітлення. Система підготовки зображення (яка зображена на рис. 3.4) включає професійну цифрову дзеркальну камеру Canon EOS5D Mark II, що має діафрагму 5,6, матрицею КМОП 36x24 мм. В установку також входить професійна система освітлення InterfitEX 150. Друковані плати розміщені на білій дошці. Керування камерою та освітленістю відбувається одночасно за допомогою дистанційного управління. Дана система забезпечує постійне освітлення, таким чином можна уникнути проблем з зайвими тінями або дзеркальними відбиттями на дошці.

Датасет містить 123 унікальних зображень друкованих плат які сфотографовано як ззаду під кутами (0°, 90°, 180°, 270°) так і спереду, а отже для кожної плати зроблено по 8 зображень. Як додаток до цих вихідних

|     |     |          |        |      |                           |      |
|-----|-----|----------|--------|------|---------------------------|------|
|     |     |          |        |      | <b>PI71.426469.001 ПЗ</b> | Лист |
|     |     |          |        |      |                           | 30   |
| Зм. | Лис | № докум. | Підпис | Дата |                           |      |

зображень надано обмежувальні рамки (х, у, ширина, висота) для кожного компоненту та для всіх плат з 8 видами. Статистика наявності компонентів на друкованих платах відображена на рисунках 3.4 та 3.5.




Рисунок 3.4 — Гістограма кількості елементів; мікросхем на одну плату (а); резисторів на одну плату (б)

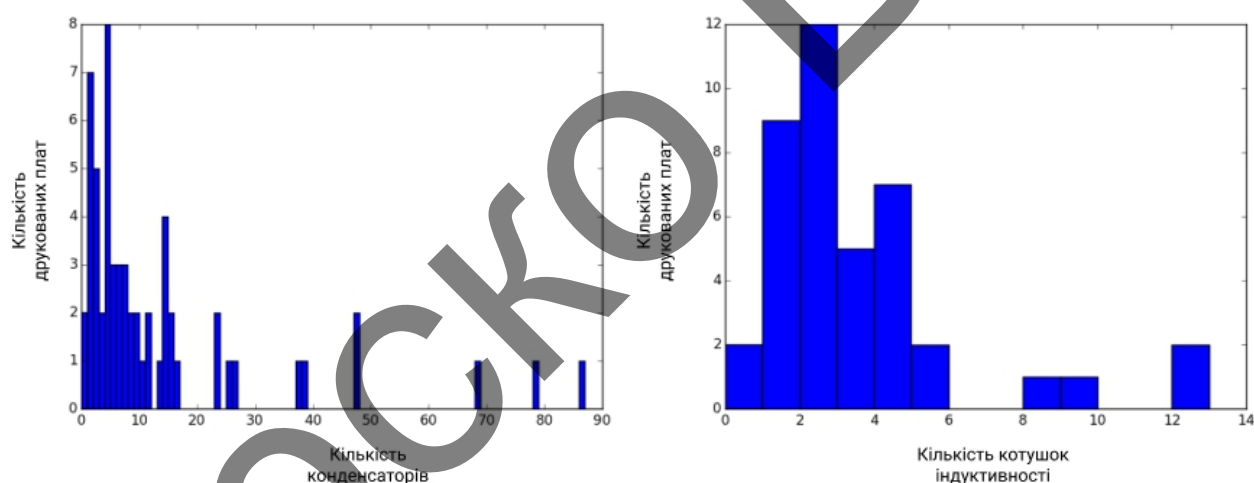


Рисунок 3.5 — Гістограма кількості елементів; конденсаторів на одну плату (а); котушок індуктивності на одну плату (б)

З графіків можна підмітити, що більшість плат мають менше 20 мікросхем та конденсаторів; резисторів та конденсаторів ще менше. Варто зазначити, є дві плати, що мають більше 120 резисторів кожна і три плати, що мають більше 70 конденсаторів. Найбільша кількість мікросхем (60 та більше) містяться на трьох платах. Друковані плати відрізняються одна від одної своїми розмірами та формами. Оскільки всі плати розташовані на білій

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
31

дошці, то стає легше застосовувати до таких зображень віднімання фону, виділення меж для утворення сегментації друкованих плат.




Рисунок 3.6 — Виявлення елементів за допомогою датасету PCB-METAL

Варто виділити, що даний датасет, як і більшість інших, містить нерівномірні дані, тобто значна перевага в кількості конденсаторів і резисторів над мікросхемами та котушками індуктивності.

### 3.1.3 FICS-PCB

Даний датасет включає в себе складні випадки з трьох змінних аспектів: освітленості, масштабу зображення та сенсору зображення (фотоматриця). FICS PCB (Florida Institute for Cybersecurity) був виготовлений викладачами Флоридського університету [25], датасет містить 9,912 зображень з 31 унікальними друкованими платами, що містять в сумі 77,347 компонентів [26].

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

32



Датасет був зібраний в лабораторії SeCurity and AssuraNce (SCAN) лабораторії в університеті Флориди, робота над підготовкою зображень проводиться й досі. Друковані плати були взяті з різних електронних пристроїв, окрім ПК, телефонів місце мають і плати з контролерів жорсткого диска, аудіопідсилювачів, моніторів. Плати відрізняються і за кольором, присутні: зелені, червоні, сині та чорні плати. Найменша плата має площу всього 7,2 см<sup>2</sup>, а найбільша — 523,2 см<sup>2</sup>. Для отримання зображень високої якості використовувалися одразу два типи датчиків зображення: цифровий мікроскоп та дзеркальна (DSLR) камера.


**Цифровий мікроскоп.** Цифровий мікроскоп дає змогу отримати зображення при умовах кількісного контролю освітленості та масштабування; цей пристрій широко використовується для контролю якості друкованих плат та аналізу відмов. Використано модель Leica DVM6 з нерухомим об'єктивом FOV43.65. Завдяки даному цифровому мікроскопу створено зображення розмірами 1600x1200 (в пікселях) з 10% перекриттям, область діапазону траєкторії становить 70x50 (мм). Якщо розмір плати більший за заданий діапазон, то її вручну переміщують для додаткового отримання даних, поки не буде повністю отримано зображення плати.

Для збільшення вибірки зображень виконано два набори зображень окремо для цифрового мікроскопа і для дзеркальної камери. Містяться зображення для різної інтенсивності кільцевого світла мікроскопа: 20, 40 та 60, де 60 — найкраще освітлення. Окрім того, є різні варіації масштабу (збільшення масштабу): 1x, 1,5x, 2x., де 1x найбільше поле зору (з англ. FOV — Field of View). Інші параметри мікроскопа: час експозиції — 101 мс, підсилення — 5, насиченість — 20 і кольорова гамма — RGB.

**DSLR (дзеркальна) камера.** Система збору зображень, що включає в себе DSLR камеру (модель Nikon D850), макрооб'єктив з фокусною відстанню 105 мм і штатив для стабілізації камери (об'єктив спрямовано вниз до друкованої плати). Встановлено режим затримки для зниження шуму від

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 33   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

вібрації камери до ручної обробки. Відстань між камерою та платами регулюється для кожної плат, таким чином для одна плата містить одне зображення. Проте для великих плат зроблено декілька зображень, щоб найменші компоненти були помітними на фото. Обидві системи для збору зображень продемонстровані на рисунку 3.7.



Система збору зображень з використанням цифрового мікроскопу



Система збору зображень з використанням DSLR камери

Рисунок 3.7 — Організація процесу збору зображень

Для завершення обмежувальних рамок для компонентів використано анотатор зображень VGG (VGG Image Annotator). Файли анотацій збережено в форматі .CSV і містять поля: назва зображення, розташування компонента, тип компонента, логотип (рис 3.8).

| image_name                                 | component_location   | component_type   | text_on_component | logo |
|--|--|------------------|-------------------|------|
| s8_p2_1x_40_ring_TileScan_001--Stage00.tif | {}{"name":"","rect":{"x":26,"y":658,"width":34,"height":54}}     | resistors,,no    |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage00.tif | {}{"name":"","rect":{"x":1491,"y":561,"width":60,"height":98}}   | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage03.tif | {}{"name":"","rect":{"x":474,"y":51,"width":29,"height":47}}     | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage03.tif | {}{"name":"","rect":{"x":701,"y":45,"width":31,"height":51}}     | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage03.tif | {}{"name":"","rect":{"x":753,"y":47,"width":31,"height":50}}     | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage03.tif | {}{"name":"","rect":{"x":832,"y":26,"width":150,"height":80}}    | resistors,3R3,no |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage03.tif | {}{"name":"","rect":{"x":1146,"y":20,"width":149,"height":85}}   | resistors,6R8,no |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":66,"y":584,"width":55,"height":98}}     | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":676,"y":534,"width":26,"height":51}}    | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":991,"y":537,"width":31,"height":53}}    | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":492,"y":1118,"width":31,"height":48}}   | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":718,"y":1112,"width":31,"height":54}}   | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":771,"y":1115,"width":31,"height":51}}   | capacitors,,no   |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":853,"y":1093,"width":147,"height":80}}  | resistors,3R3,no |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage02.tif | {}{"name":"","rect":{"x":1164,"y":1089,"width":149,"height":80}} | resistors,6R8,no |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage01.tif | {}{"name":"","rect":{"x":77,"y":137,"width":47,"height":29}}     | resistors,,no    |                   |      |
| s8_p2_1x_40_ring_TileScan_001--Stage01.tif | {}{"name":"","rect":{"x":60,"y":201,"width":69,"height":38}}     | capacitors,,no   |                   |      |

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
34



Рисунок 3.8 — Приклад анотацій (розміток елементів)

Кожен рядок містить інформацію окремо про один елемент на платі, де “image\_name” — ім’я файлу анотованого зображення, “component\_location” — координати пікселів для визначення границі обмежувальних рамок для компонента, “component\_type” — тип компонента (мікросхема, конденсатор, резистор, котушка індуктивності, транзистор або діод), “text\_on\_component” — маркування компонента, “logo” — двійковий запис про наявність логотипу для компонента. Датасет з використанням цифрового мікроскопу містить зображення одразу три варіації масштабу, проте анотації зроблені лише для одного.

В даному датасеті найменший компонент має площу 0,5 мм<sup>2</sup>, а найбільший — 256 мм<sup>2</sup>. Серед всіх зразків 11 друкованих плат мають понад 200 компонентів, що вказує на складність зображення та підкреслює велику кількість компонентів, що потрібно виявити та класифікувати. Наприклад, одна плата містить одразу 478 компонентів.

Порівнюючи всі 3 вище представлені датасети найкращим для використання буде FICS-PCB. Даний датасет містить одразу 6 типів компонентів і складні, по своїй будові плати. Окрім того зйомка відбувалась одразу з двох пристроїв: дзеркальної (DSLR) камери та цифрового мікроскопу (для якого додатково зроблено зображення з різним масштабуванням). Порівняння показано на рисунку 3.8

| Датасети  | Мікросхеми | Конденсатори | Резистори | Котушки індуктивності | Транзистори | Діоди |
|-----------|------------|--------------|-----------|-----------------------|-------------|-------|
| PCB-DSLR  | 9313       | —            | —         | —                     | —           | —     |
| PCB-METAL | 5844       | 3175         | 2670      | 542                   | —           | —     |
| FICS-PCB  | 3,243      | 36,639       | 33,182    | 1,292                 | 1,398       | 1,593 |

Рисунок 3.8 — Порівняння датасетів (по кількості елементів на друкованих платах)

### 3.2 Вибір архітектури мережі

Для вирішення завдання пошуку дефектів друкованого вузла необхідно вирішити задачу розпізнавання. Найкраще всього з цією задачею справляються згорткові нейронні мережі. Вони складаються з нейронів, що в свою чергу містять ваги і з'єднання. Нейрон, отримуючи вхідні дані, починає обраховувати скалярний добуток і використовує нелінійну функцію активації. Вага збільшує або зменшує силу сигналу на з'єднанні. Кількість параметрів значно менша ніж в інших типах мереж, проте ця мережа складається з багатьох шарів. Використовуються: згортковий шар, субдискретизуючий шар і персептрон. Далі наводяться популярні архітектури згорткових мереж [27].

R-CNN — одна з найперших моделей для вирішення задачі розпізнавання об'єктів на фото. На вхід мережі подаються різні області зображень і по цим областям ЗНМ робить передбачення. На даний момент часу архітектура являється застарілою, адже одне зображення проходить через мережу понад тисячу разів, що значно сповільнює час виконання [28].

Fast R-CNN — покращена версія попередньої архітектури, працює за схожим принципом, проте відмінністю являється подавання всіх зображень на вхід згорткової нейронної мережі, після чого починають формуватись області.

Faster R-CNN — відбувається зміна процедури генерації претендентів “selective search” на невелику нейронну мережу. В якості нейронної мережі може підійти VGG16 або ZF.

YOLO (з англ. You Only Look Once) — замість пошуку, а потім і перевірки об'єктів класифікатором зображення, при даному підході, розбивається рівномірною сіткою і для кожної комірки перевіряти наявність центру об'єкту, якого він класу та його точний прямокутник.

SSD — покращена версія попередньої архітектури. Проте в архітектурі YOLO характерні ознаки об'єктів брались з останнього згорткового шару

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

36

мережі, тоді як у SSD ознаки взяті з різних шарів, тому доволі малі об'єкти не втрачались.

### 3.2.1 YOLOv3 з використанням Darknet

Для розв'язання задачі знаходження цілісних компонентів на друкованій платі обрано тип архітектури YOLOv3. Мережу YOLO можна поділити на 3 частини:

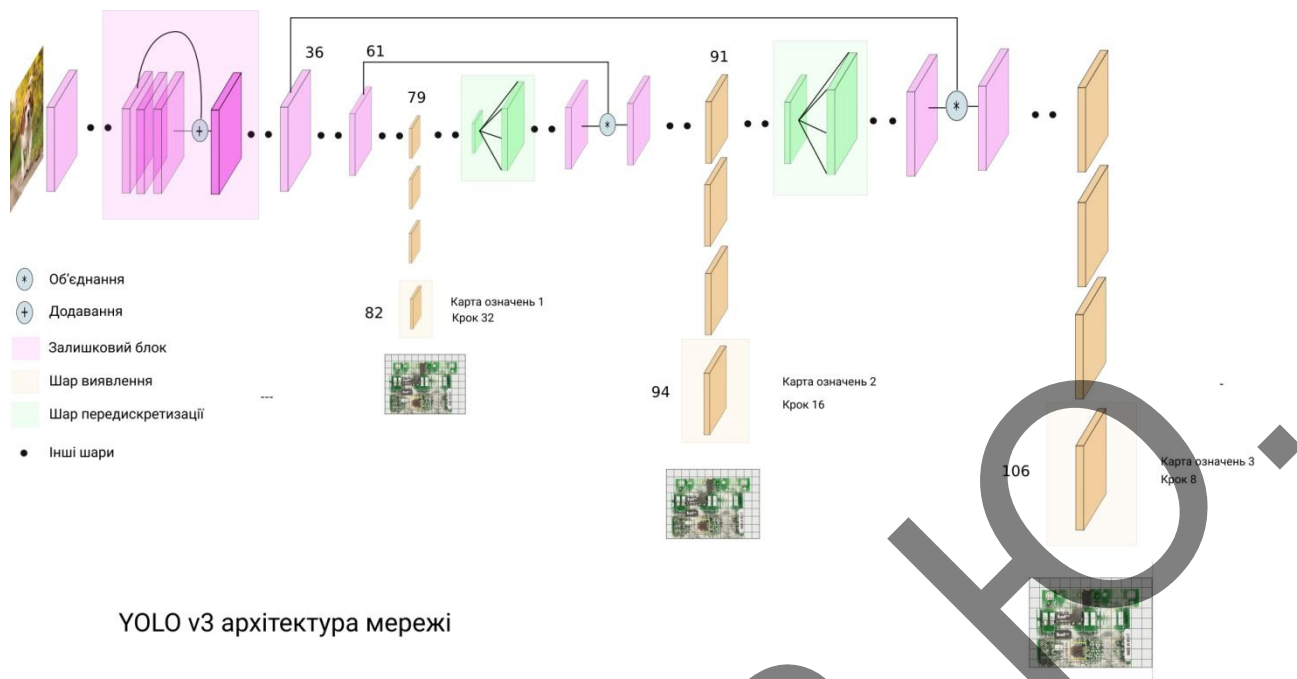
- Хребет (англ. backbone). ЗНМ, що узагальнює та формує характеристики зображення при різних деталізаціях.

- Шия (анг. Neck). Серія шарів для змішування та поєднання ознак зображення для подальшої їх передачі до прогнозування.

- Голова (англ. head). Використовує функції шиї та виконує функцію прогнозування класу.

Це покращена версія архітектури, вона складається з 106 згорткових шарів і набагато точніше знаходить дрібні об'єкти. Darknet — фреймворк з відкритим вихідним кодом, підтримує розрахунки на базі CPU і GPU. Ваги, що були навчені архітектурою Darknet зберігає в форматі, що може бути доволі легко виявленим за допомогою різних методів на різних платформах. Головними перевагами даного фреймворку його простота, швидкість і він являється одним з найкращим для розпізнавання та виявлення об'єктів в режимі реального часу [29].

YOLO v3 використовує варіант Darknet, мережу, яка складається з 53 шарів й навчена на ImageNET. Для вирішення задачі розпізнавання на архітектуру накладається ще 53 шари, що дає в сумі 106-шарову згорткову нейронну мережу [30]. Архітектуру мережі показано на рисунку 3.9.



YOLO v3 архітектура мережі

Рисунок 3.9 — Архітектура згорткової нейронної мережі YOLO v3

Мережа має залишковий блок та розширеною вибіркою. Особливістю версії v3 являється виявлення об'єктів одразу в трьох масштабах. Тензор на виході вираховується за наступною формулою:

$$S \times S \times (B \times (5 + C)),$$

де  $S$  — розмір комірки сітки;  $B$  — кількість обмежувальних рамок (полів), що може передбачити комірка (клітинка) на розбитому зображенні; “5” — атрибути, набір із п'ятірок виду:  $(x, y, w, h, p)$ , тут:  $x, y$  — відносні координати центру об'єкта всередині комірки (тобто вираховується від лівого верхнього кута комірки  $(0,0)$  і до правого нижнього кута комірки  $(1,1)$ ),  $w, h$  — розміри об'єкта (розміри числа від 0 до 1 задаються відносно розмірів вихідного зображення),  $p$  — впевненість мережі в тому, що об'єкт присутній і його обмежувальна рамка задана правильно (тобто  $p$  являється вірогідністю наявності об'єкта в комірці і прогнозована прямокутником  $x, y, w, h$ );  $C$  — вірогідність того, об'єкт з центром в даній комірці належить відповідному класу [31].

YOLO v3 виконує прогнозування в трьох масштабах, які точно задаються шляхом зменшення вихідного зображення на 32, 16 та 8 відповідно.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
38

Перше розпізнавання відбувається 82-м шаром. Для перших 81 шарів зображення проходить вибірку нейронною мережею, а 81 шар має крок 32. Наприклад, при розмірі зображень  $416 \times 416$  карта ознак буде мати розмір  $13 \times 13$ . Одне з прогнозувань відбувається з використанням ядра (з англ. kernel)  $1 \times 1$ , що дає карту ознак  $13 \times 13 \times 255$ .

Карта ознак з шару 79 проходить через декілька згорткових шарів перед тим, як буде зменшена вдвічі до розмірів  $26 \times 26$ . Після чого дана карта ознак об'єднується з картою ознак 61 шару. Потім комбіновані карти проходяться декількома згортковими шарами  $1 \times 1$ , щоб позбавитись від деяких ознак з попереднього шару (61). Друге розпізнавання відбувається завдяки 94-му шару, отримуючи карту ознак  $26 \times 26 \times 255$ .

Схожі процеси відбуваються, коли карта ознак з 91 шару проходиться декількома згортковими шарами, перш ніж далі вона буде об'єднана з картою ознак шару 31. Як і в випадку раніше, декілька згорткових шарів  $1 \times 1$  йдуть наступними, щоб позбавитись знову від ознак з попереднього шару. Завершується все на 106-му шарі, де отримується карта ознак  $52 \times 52 \times 255$ .

Друковані плати з обраного датасету містять досить багато компонентів, деякі з них мають доволі малі габарити. Розпізнавання одразу на різних шарах допомагає вирішити проблему з малими за габаритами об'єктами. В описаній вище моделі шар  $13 \times 13$  відповідає за виявлення великих об'єктів, в той же час шар  $52 \times 52$  виявляє менші об'єкти, а шар  $26 \times 26$  виявляє середні об'єкти.

### 3.2.2 YOLOv5 з використанням PyTorch

YOLOv5 — являється першою з моделей сімейства YOLO, яка написана за допомогою фреймворку PyTorch. Одними з головних переваг даного фреймворку над архітектурою Darknet являється його гнучкість та більша керованість (тобто можливість швидше перенести код на нові дослідження). Архітектура моделі є досить схожою до попередньої версії — YOLOv3 на PyTorch, проте продуктивність мережі стала значно кращою [32]. Взагалі,

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 39   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

YOLOv5 [33], що реалізована на PyTorch і YOLOv4, яка реалізована на Darknet були випущені майже в один час, але для уникнення плутанини вони були поділені на четверту та п'яту версії.

Для нової версії YOLO характерне більш ретельне ставлення до навчальних процедур мережі. Зазвичай, даний процес обділений увагою на відміну від фінальних етапів прогнозування, проте важливість обох знаходиться на однаковому високому рівні. Збільшення даних — трансформація деяких початкових навчальних даних, щоб піддавати модель ширшому діапазону варіацій, аніж навчальний набір [34]. Складно зробити підбір даних, який буде точно описувати реальну ситуацію, тому коригування даних дозволяє змодельовати більше ситуацій, які можуть трапитись. Можна виділити наступні способи збільшення даних:

- Спотворення. Фотометричне спотворення — зміна яскравості контрасту, насиченості та шуму на зображенні. Геометричне спотворення — випадкове масштабування, обрізання, обертання зображення. Під час такого спотворення часто необхідно змінювати обмежувальну рамку. Обидві процедури коригують пікселі, що значить можливість відновлення початкового зображення.

- Оклюзія зображення. Випадкове стирання — техніка збільшення даних, що замінює ділянки зображення випадковими значеннями або середнім значенням пікселів навчального набору. Даний метод використовується для того, щоб завадити моделі запам'ятовувати навчальні дані та запобігти перенавчання. Виріз — під час навчання квадратні області є замаскованими. Області, що вирізаються являються прихованими лише для першого згорткової мережі. “Хованки” (з англ. hide and seek) — розбиття зображення сіткою розміром  $S \times S$  фрагменти зображення, які будуть заховані визначаються випадково. Дана процедура дозволяє моделі зробити припущення як виглядає об'єкт, не маючи при цьому прикладу повного зображення. Маска сітки — метод схожий до попереднього, різницею є

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
40

приховування фрагментів не випадковим чином, а в певній послідовності сіткою. Змішування (з англ. MixUp) — накладання пар зображень та їх міток на одне зображення.

YOLOv5 реалізував ще деякі способи збільшення даних:

- CutMix. Комбінування зображень під час якого вирізаються деталі з одного зображення й встановлюються на доповнене зображення. Даний метод змушує модель робити прогноз на основі значної кількості функцій.

- Мозаїчне збільшення даних. Поєднання одразу чотирьох навчальних зображень в одне в певних пропорціях. Це дозволяє ідентифікувати об'єкти в менших масштабах, ніж зазвичай.

- Згладжування маркування класу. Правильність розпізнавання об'єкту на фотографії задає йому вектор класів, значення даного вектору можуть змінити на 10% для того, щоб модель не мала прогноз 100% вгадування класу.

- Самостійне навчання. Метод, що використовує стан моделі для інформування про вразливі місця шляхом трансформації вхідного зображення. Спочатку зображення проходить через звичайний тренувальний етап, після чого сигнал втрат використовують таким чином, щоб він якомога більш пагубно вплинув на модель.

Автоматичне навчання якірних обмежувальних рамок (якірних коробок). Створення якірних коробок допомагає навчити мережу розпізнавати малі об'єкти, адже часто буває так, що при виявленні доволі дрібних об'єктів деякі з них можуть просто проігноруватись нейронною мережею.

Фреймворк PyTorch зменшує вдвічі точність з плаваючою точкою під час навчання з 32-бітової до 16-бітової точності. 16-бітна точність плаваючої точки значно пришвидшує час виведення моделі в YOLOv5 [33].

YOLOv5 формулює конфігурації моделі в .yaml, на відміну від файлів .cfg в архітектурі Darknet. Основна різниця між цими форматами полягає в тому, що файл .yaml ущільнюється, щоб просто вказати різні шари в мережі, а потім множить їх на кількість шарів у блоці.

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 41   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

Нові версії архітектури YOLO реалізують кістяк CSP для формулювання ознак зображення. CSP вирішує проблему дублювання градієнта в великих системах ConvNet, що призводить до меншої кількості параметрів і меншої кількості флопсів (визначення продуктивності комп'ютерів, скільки операцій виконує дана система). Це досить важливо для сімейства YOLO, адже швидкість виводу та невеликий розмір моделі являються ключовими.

### Висновки до третього розділу

Проаналізовано три загальнодоступних датасети, що містять дані для задач знаходження компонентів на друкованій платі. В якості даних для нейронної мережі обрано датасет, що містить одразу 31 друковану плату з різних пристроїв. Обраний датасет містить зображення, що були зроблені з двох інструментів: дзеркальної камери та цифрового мікроскопу. Датасет FICS-PCB містить 6 типів компонентів серед яких: конденсатори, резистори, мікросхеми, діоди, котушки індуктивності та транзистори. В наявності є і анотації, що включають в себе обмежувальні рамки для вказування положення елемента, сортування компонентів по класам.

Порівняно дві згорткові мережі з різними архітектурами, кращу швидкість має ЗНМ з архітектурою YOLOv5, що використовує фреймворк Pytorch. Даний тип архітектури обрано через його кращу динамічність в порівнянні з YOLOv3 на Darknet.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
42



## 4 РЕАЛІЗАЦІЯ ПОШУКУ ДЕФЕКТІВ

### 4.1 Підготовка даних та написання програми

Для навчання згорткової нейронної мережі обрано датасет FICS-PCB. Зроблено вибірку понад 440 зображень, статистику вмісту датасету показано на рис. 4.1. Зображення були поділені на 6 класів: конденсатори, резистори, діоди, мікросхеми, транзистори та котушки індуктивності, окрім того датасет містить 8 зображень друкованих плат [35].

Статистика даних



Рисунок 4.1 — Статистика даних в датасеті

Як можна побачити на рисунку дані розподілені нерівномірно. Це можна пояснити тим, що на платі немає чіткого відношення між компонентами і тим більше рівності в кількості цих елементів (наприклад на одній платі можуть бути присутні 48 резисторів і всього 2 мікросхеми). Нерівномірно розподілені дані навчаються також по-різному з різною точністю. Зображення поділено на 3 групи: зображення для проведення навчання, валідні зображення та зображення для проведення тесту. Розподілені зображення за відсотковим співвідношенням 70%, 20% і 10% відповідно.

Для всіх зображень написано детальні анотації — вказано клас, назву, маркування компонентів, встановити обмежувальні рамки для них. Анотації були зроблені в середовищі Roboflow (рис. 4.2). Окрім того, до даного датасету додано 220 зображень для штучного збільшення даних. Ці

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

43

зображення мали штучно нанесені дефекти такі як: спотворення, поворот зображення, мозаїчне збільшення даних.

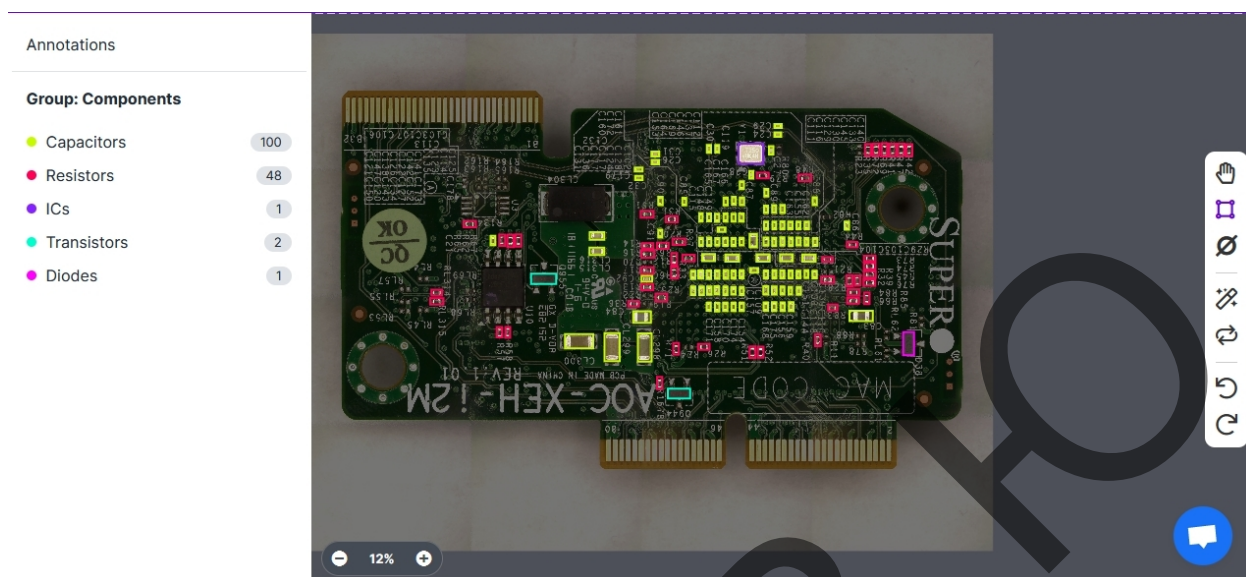


Рисунок 4.2 — Встановлення обмежувальних рамок для компонентів на платі

Код був написаний в середовищі Google Colaboratory з використанням ресурсів GPU (графічного процесора — graphics processing unit). Встановлені версії Python 3.6 та PyTorch 1.8.1 як необхідні вимоги для розробки з використанням архітектури YOLOv5. Взято конфігурацію моделі для навчання власного датасету та проведено 100 епох навчання (рис. 4.3).

```
Epoch   gpu_mem   box      obj      cls     total  targets  img_size
99/99    1.9G     0.04374  0.01334  0.01433  0.07141  23      416:
Class    Images   Targets   P        R        mAP@.5
all      39       39        0.727    0.976    0.836
Capacitors 39       17        0.898    1        0.995
Diodes    39       5         1        0.891    0.995
ICs       39       2         0.336    1        0.745
Resistors 39       13        1        0.987    0.995
Transistors 39       2         0.4      1        0.448

Optimizer stripped from runs/train/yolov5s_results/weights/last.pt, 14.8MB
Optimizer stripped from runs/train/yolov5s_results/weights/best.pt, 14.8MB
100 epochs completed in 0.116 hours.

CPU times: user 5.31 s, sys: 678 ms, total: 5.98 s
Wall time: 7min 19s
```

Рисунок 4.3 — Час, кількість епох та деякі з результатів тренування мережі

Як можна побачити процес навчання зайняв в сумі 7 хвилин та 19 секунд.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

44

## 4.2 Результати виконання навчання

Системи розпізнавання об'єктів роблять прогнози у вигляді обмежувальної рамки та мітки класу. Правильність (англ. accuracy) являється часткою правильних відповідей отриманих алгоритмом. Даний параметр широко використовується в нейронних мережах, але для згорткових нейронних мереж і для вирішення задачі розпізнавання та класифікації даних параметр не підходить. Це пов'язано з тим, що при розрахунку правильності не враховується нерівномірний розподіл даних. Тобто як в даному випадку, коли датасет містить 197 зображень конденсаторів і 18 зображень транзисторів, параметр правильності (accuracy) не покаже коректно успішність навчання нейронної мережі.

Проте для розрахунку успішності навчання використовуються інші параметри. Точність прогнозу означає який відсоток прогнозів під час навчання нейронної мережі вона зробила правильно. Тобто точність (з англ. precision) нейронної мережі вимірюється як:

$$\text{Точність} = \frac{\text{Правильні позитивні прогнози}}{\text{Правильні позитивні прогнози} + \text{Помилкові позитивні прогнози}},$$

де правильні позитивні прогнози — прогнозування, що дала ШНМ і які виявились істинними; помилкові позитивні прогнози — прогнози, що інтерпретувались нейронною мережею як правильні, але які виявились помилковими [36].

Для кожної обмежувальної рамки вимірюється перетин між прогнозованою та істинною обмежувальними рамками (рис. 4.4).

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

45

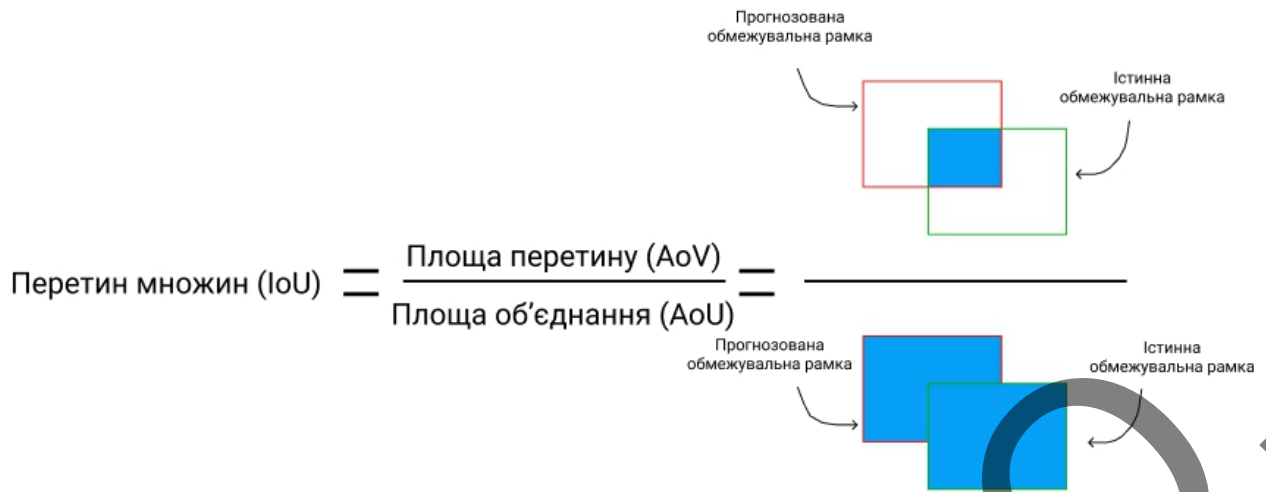


Рисунок 4.4 — Визначення значення перетину множин обмежувальних рамок

Ще одним важливим терміном являється повнота (recall). Повнота демонструє можливість алгоритму знаходити клас взагалі, в той час як точність показує вміння нейронної мережі відрізнати один клас від іншого. Повнота показує як добре алгоритм знаходить істинні значення (в розглянутому випадку це відображення наскільки добре мережа прогнозує положення обмежувальної рамки) [37].

$$\text{Повнота} = \frac{\text{Правильні позитивні прогнози}}{\text{Правильні позитивні прогнози} + \text{Помилкові негативні прогнози}},$$

де помилкові негативні прогнози — ШНМ не зробила прогноз знаходження об'єкту на певному місці, в той час як він там знаходився.

Точність і повнота, на відміну від правильності, не залежать від співвідношення класів, тому підходять і для даного випадку (обидва параметри показані на рис. 4.5).

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

46




Рисунок 4.5 — Точність (precision) та повнота (recall) нейронної мережі

Точність нейронної мережі становить 78%, в той час як повнота — 92%.

Алгоритми розпізнавання об'єктів серед яких є і YOLO використовують mAP (Mean Average Precision — значення середньої точності) для оцінки своїх моделей. В методах комп'ютерного зору mAP — це популярна метрика оцінки, яка використовується для виявлення об'єктів (тобто для задач локалізації та класифікації) [38]. Задача локалізації полягає в тому, щоб визначити місце розташування об'єкта (наприклад встановити обмежувальні рамки), а задача класифікації — повідомити якого класу об'єкт на зображенні. Значення середньої точності можна порахувати як площу кривої між значеннями точності та повноти (рис. 4.6).

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

47




Рисунок 4.6 — Інтерполяція точності та повноти

Проаналізувавши рисунок вище можна зробити припущення, що середнє значення точності буде становити трохи більше 80%. І справді значення mAP після тренування моделі становить 83% (рис. 4.7).




Рисунок 4.7 — Значення середньої точності

Значення mAP [0.5:0.95] означає середній mAP за різні пороги IoU (перетину множин, що вказано на рис. 4.4) від 0,5 до 0,95 з кроком 0,05 [39].

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист  
48

Функції втрат займають не менш важливе значення для правильного аналізу навчання нейронної мережі. Кожна помилка нейронної мережі спричиняє втрати в моделі для того щоб, щоб вона навчилася робити якомога більше правильних прогнозів. Втрати класу (class loss) — параметр, що показує наскільки правильно алгоритм встановив клас для шуканого об'єкту. Втрати рамки (box loss) показує наскільки добре знайдено центр об'єкту та наскільки успішно спрогнозовано обмежувальну рамку нейронною мережею. Обидві функції втрат показані на рис. 4.8.



Рисунок 4.8 — Функції втрат рамки та класу

Параметр objectness визначається за допомогою метрики перетину множин (IoU). Тобто objectness показує наскільки в двох об'єктів еталонного та прогнозованого співпадають обмежувальні рамки (рис 4.9).



Рисунок 4.9 — Функції втрат за параметром objectness

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

49



Після проведення навчання можна глянути деякі з прикладів виявлення. На рисунку нижче ЗНМ спрогнозувала, що компонент являється мікросхемою (ICs), поставила обмежувальну рамку і дала точність визначення в 0,72.



Рисунок 4.10 — Прогнозований мережею компонент

Після тренування на валідаційному наборі зображень ЗНМ встановила обмежувальні рамки як для компонентів окремо, так і для компонентів, що містяться на друкованій платі (рис. 4.11.)

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

|      |
|------|
| Лист |
| 50   |






Рисунок 4.11 — Тренування на валідаційному наборі зображень

Цифрами від 1 до 6 позначено номери класів компонентів. Всі зображення датасету приведено до розміру 416x416. Ресайз зображень необхідний для створення екземплярів, що мають однакове значення висоти та ширини (висока роздільна здатність показує кращі результати навчання нейронної мережі). Проте для швидкого тренування нейронної мережі необхідно мати якомога більш стиснуті зображення. Тому навчання на електронних модулях, що на відміну від окремих компонентів мають дуже високу роздільну здатність є досить проблематичною. Прийнято рішення ділити друковану плату на декілька частин для того, щоб на одній ділянці навіть після стиснення зображення чітко видно навіть найдрібніші компоненти.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

51




Рисунок 4.12 — Зображення частини плати, де детальніше видно дрібні компоненти

Тому в даному датасеті одна ДП може складатись одразу з декількох частин для кращої деталізації компонентів.

### Висновки до четвертого розділу

Проведено підготовку даних перед подальшим навчанням нейронної мережі. З існуючого датасету взято 440 зображень, що містять 6 класів компонентів та 5 друкованих плат. Зображення завантажені в середовище RoboFlow для створення анотацій для кожного компоненту окремо та одразу для багатьох компонентів, що містяться на друкованій платі. ДП ділиться одразу на декілька частин для створення більш якісних зображень. До даного датасету в середовищі додано ще 220 зображень для штучного збільшення даних — ці зображення, на відміну від наявних, містять дефекти (неправильно розташовані зображення, різні шуми та видалені ділянки

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

52

зображень). Це зроблено для того щоб ЗНМ не завчила дані та точніше вчилася аналізувати зображення. Зображення поділені на 3 групи: навчальні, валідні та тестові з співвідношенням 70%, 20% та 10% відповідно.

Код написано в середовищі Google Colaboratory. Використано існуючу бібліотеку PyTorch та архітектуру YOLOv5. Після проведення навчання ЗНМ показала середнє значення точності 83%.

|     |      |          |        |      |                    |      |
|-----|------|----------|--------|------|--------------------|------|
|     |      |          |        |      | PI71.426469.001 ПЗ | Лист |
| Зм. | Лист | № докум. | Підпис | Дата |                    | 53   |

## ВИСНОВКИ

За результатами виконання дипломної роботи можна зробити наступні висновки:

1. Проведено аналіз основних типів дефектів плати та встановлених на них електронних компонентів та наведено основні методи перевірки наявності таких дефектів. Порівнюючи методи визначено, що одним із найефективніших способів для масового виробництва є автоматичний візуальний контроль.

2. За результатами розгляду різновидів штучних нейронних мереж прийнято рішення, що найбільш підходящою для знаходження дефектів електронного модуля являється ЗНМ. Це можна пояснити тим, що в якості вхідних та вихідних даних в мережі виступає зображення.

3. Проаналізовано три загальнодоступних датасети, що містять дані для задач знаходження компонентів на друкованій платі. В якості даних для нейронної мережі обрано датасет, що містить одразу 31 друковану плату з різних пристроїв. Обраний датасет містить зображення, що були зроблені з двох інструментів: дзеркальної камери та цифрового мікроскопу.

4. Проведено порівняння двох архітектур згорткових нейронних мереж: YOLOv5, що використовує фреймворк Pytorch та YOLOv3 на Darknet. Обрано більш нову архітектуру YOLOv5.

5. Проведено підготовку даних перед подальшим навчанням нейронної мережі. З існуючого датасету взято 440 зображень, що містять 6 класів компонентів та 5 друкованих плат. Зображення поділені на 3 групи: навчальні, валідні та тестові з співвідношеннями 70%, 20% та 10% відповідно.

6. Розроблено згорткову нейронну мережу в середовищі Google Colaboratory. Використано існуючу бібліотеку PyTorch та архітектуру YOLOv5. Після проведення навчання ЗНМ показала середнє значення точності 83%.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

54

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ

1. Платы печатные. Классификация дефектов [Электронный ресурс] — Режим доступа до ресурсу: <https://www.rts-tender.ru/poisk/gost/r-56251-2014>.

2. Контроль качества печатных плат [Электронный ресурс] — Режим доступа до ресурсу: [https://zctc.ru/sections/kontrol\\_kachestwa\\_pechatnih\\_plat](https://zctc.ru/sections/kontrol_kachestwa_pechatnih_plat).

3. Перевірка дефектів компонентів [Електронний ресурс] — Режим доступу до ресурсу: [https://kivra.kpi.ua/wp-content/uploads/file/work/2020/Polikhovych/Polikhovych\\_bakalavr.pdf](https://kivra.kpi.ua/wp-content/uploads/file/work/2020/Polikhovych/Polikhovych_bakalavr.pdf).

4. Контроль печатных плат по признакам внешнего вида [Электронный ресурс] – Режим доступа до ресурсу: [https://tech-e.ru/2005\\_3\\_34.php](https://tech-e.ru/2005_3_34.php).

5. Виды контроля печатных плат [Электронный ресурс] — Режим доступа до ресурсу: <https://www.mettatron.ru/stati/payalnye-materialy/vidy-kontrolya-pechatnykh-plat>.

6. Qualification of Manual Visual Inspection [Электронный ресурс] — Режим доступа до ресурсу: <https://www.pda.org/pda-letter-portal/home/full-article/qualification-of-manual-visual-inspection-still-critical>.

7. PCB inspection and testing techniques [Электронный ресурс] — Режим доступа до ресурсу: <https://medium.com/supplyframe-hardware/pcb-inspection-and-testing-techniques-30631a885109>. —

8. Test Nixie Tube Driver PCBs on Bed of Nails [Электронный ресурс] — Режим доступа до ресурсу: <https://medium.com/@CabeFSAtwell/test-nixie-tube-driver-pcb-on-a-bed-of-nails-c4721f9164f1>.

9. ICT Testing vs Flying Probe Testing [Электронный ресурс] — Режим доступа до ресурсу: <https://blog.matric.com/ict-testing-vs-flying-probe-testing>.

10. X-Ray inspection to Reveal hidden PCB Assembly Defects [Электронный ресурс] — Режим доступа до ресурсу: <https://www.tempoautomation.com/blog/x-ray-inspection-reveals-hidden-pcba-defects/>.

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 55   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |

11. Functional Test: A Final Manufacturing Step [Электронный ресурс] — Режим доступа до ресурсу: <https://www.nexlogic.com/pcb-testing/functional-testing/>.

12. Классификация данных при помощи нейронных сетей [Электронный ресурс] — Режим доступа до ресурсу: <https://loginom.ru/blog/neural-classification>.

13. ICT Testing vs Flying Probe Testing [Электронный ресурс] — Режим доступа до ресурсу: <https://blog.matric.com/ict-testing-vs-flying-probe-testing>.

14. Применение нейронных сетей для решения задач прогнозирования [Электронный ресурс] — Режим доступа до ресурсу: <http://elibrary.lt/resursai/Uzsienio%20leidiniai/MFTI/2006/136.pdf>.

15. Наглядное введение в нейросети на примере распознавания цифр [Электронный ресурс] — Режим доступа до ресурсу: <https://proglib.io/p/neural-network-course>.

16. Нейронные сети — распознавание образов и изображений с помощью ИИ [Электронный ресурс] — Режим доступа до ресурсу: <https://center2m.ru/ai-recognition>.

17. Классификация нейронных сетей [Электронный ресурс] — Режим доступа до ресурсу: <https://aisimple.ru/12-klassifikacija-nejronnyh-setej.html>.

18. Типы нейронных сетей [Электронный ресурс] — Режим доступа до ресурсу: <https://otus.ru/nest/post/1263/>.

19. Нейронные сети, перцептрон [Электронный ресурс] — Режим доступа до ресурсу: [https://neerc.ifmo.ru/wiki/index.php?title=%D0%9D%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D1%8B%D0%B5\\_%D1%81%D0%B5%D1%82%D0%B8\\_%D0%BF%D0%B5%D1%80%D1%86%D0%B5%D0%BF%D1%82%D1%80%D0%BE%D0%BD](https://neerc.ifmo.ru/wiki/index.php?title=%D0%9D%D0%B5%D0%B9%D1%80%D0%BE%D0%BD%D0%BD%D1%8B%D0%B5_%D1%81%D0%B5%D1%82%D0%B8_%D0%BF%D0%B5%D1%80%D1%86%D0%B5%D0%BF%D1%82%D1%80%D0%BE%D0%BD).

20. Введение в RBF сети [Электронный ресурс] — Режим доступа до ресурсу: <https://basegroup.ru/community/articles/rbf>.

|     |     |          |        |      |                    |      |
|-----|-----|----------|--------|------|--------------------|------|
|     |     |          |        |      | PI71.426469.001 ПЗ | Лист |
|     |     |          |        |      |                    | 56   |
| Зм. | Лис | № докум. | Підпис | Дата |                    |      |



21. A Dataset for Computer-Vision-Based PCB Analysis [Электронный ресурс] — Режим доступа до ресурсу: <http://www.mva.org.jp/Proceedings/2015USB/papers/10-38.pdf>.

22. PCB DSLR Dataset [Электронный ресурс] — Режим доступа до ресурсу: <https://zenodo.org/record/3886553#.YMEyMn6wnIU>.

23. A dataset for computer vision based PCB analysis, IEEE Conference [Электронный ресурс] — Режим доступа до ресурсу: <https://ieeexplore.ieee.org/abstract/document/7153209>.

24. PCB METAL Dataset [Электронный ресурс] — Режим доступа до ресурсу: <https://pan.baidu.com/s/1RjEnSu3719tPzpEOqEYWsw#list/path=%2FPCB-dataset>.

25. FICS-PCB A Multi-Modal Image Dataset for Automated Printed Circuit Board Visual Inspection [Электронный ресурс] — Режим доступа до ресурсу: <https://www.semanticscholar.org/paper/FICS-PCB%3A-A-Multi-Modal-Image-Dataset-for-Automated-Lu-Mehta/de274e9ba67a09e80816b98818dcd2debe10350d>.

26. FICS-PCB: A multi modal image dataset for automated printed circuit board visual inspection [Электронный ресурс] — Режим доступа до ресурсу: <https://www.trust-hub.org/#/data/fics-pcb>.

27. Распознавание объектов в режиме реального времени на iOS с помощью YOLOv3 [Электронный ресурс] — Режим доступа до ресурсу: <https://habr.com/ru/post/460869/>.

28. R-CNN — Neural Network for Object Detection [Электронный ресурс] — Режим доступа до ресурсу: <https://neurohive.io/en/popular-networks/r-cnn/>.
29. What's new in YOLOv3? [Электронный ресурс] — Режим доступа до ресурсу: <https://towardsdatascience.com/yolo-v3-object-detection-53fb7d3bfe6b>.
30. Training a YOLOv3 Object Detection Model with a Custom Dataset [Электронный ресурс] — Режим доступа до ресурсу: <https://blog.roboflow.com/training-a-yolov3-object-detection-model-with-a-custom-dataset/>.
31. YOLOv3 Explained [Электронный ресурс] — Режим доступа до ресурсу: <https://towardsdatascience.com/yolo-v3-explained-ff5b850390f>.
32. What is YOLO [Электронный ресурс] — Режим доступа до ресурсу: <http://datahacker.rs/tensorflow2-0-yolov3/>.
33. YOLOv5 New Version [Электронный ресурс] — Режим доступа до ресурсу: <https://blog.roboflow.com/yolov5-improvements-and-evaluation/>.
34. Data Augmentation in YOLOv4 [Электронный ресурс] — Режим доступа до ресурсу: <https://blog.roboflow.com/yolov4-data-augmentation/>.
35. PCB Component Detection Dataset [Электронный ресурс] — Режим доступа до ресурсу: <https://app.roboflow.com/project/pcb-component-detection/1>.
36. Метрики в методах машинного обучения [Электронный ресурс] — Режим доступа до ресурсу: <https://habr.com/ru/company/ods/blog/328372/>.
37. Метрики качества и функции потерь в задачах 3D ML [Электронный ресурс] — Режим доступа до ресурсу: <https://medium.com/phygitalism/3d-ml-metrics-loss-functions-9708ff0476e2>.
38. mAP (mean Average Precision) might confuse you [Электронный ресурс] — Режим доступа до ресурсу: <https://towardsdatascience.com/map-mean-average-precision-might-confuse-you-5956f1bfa9e2>.
39. What does the mAP [.5:.95] [Электронный ресурс] — Режим доступа до ресурсу: <https://datascience.stackexchange.com/questions/16797/what-does-the-notation-map-5-95-mean>.

|     |     |          |        |      |
|-----|-----|----------|--------|------|
|     |     |          |        |      |
| Зм. | Лис | № докум. | Підпис | Дата |

PI71.426469.001 ПЗ

Лист

58



## ДОДАТОК А

```
!git clone https://github.com/ultralytics/yolov5 # clone repo
```

```
%cd yolov5
```

```
!git reset --hard 886f1c03d839575afecb059accf74296fad395b6
```

```
!pip install -qr requirements.txt # install dependencies (ignore errors)
```

```
import torch
```

```
from IPython.display import Image, clear_output # to display images
```

```
from utils.google_utils import gdrive_download # to download  
models/datasets
```

```
print('Setup complete. Using torch %s %s' % (torch.__version__,  
torch.cuda.get_device_properties(0) if torch.cuda.is_available() else 'CPU'))
```

```
# Тут, після команди !curl, необхідно додати посилання на датасет
```

```
%cd /content
```

```
#!curl -L "https://app.roboflow.com/yourlinkhere" > roboflow.zip; unzip  
roboflow.zip; rm roboflow.zip
```

```
%cat data.yaml
```

```
import yaml
```

```
with open("data.yaml", 'r') as stream:
```

```
num_classes = str(yaml.safe_load(stream)['nc'])
```

```
%cat /content/yolov5/models/yolov5s.yaml
```

```
from IPython.core.magic import register_line_cell_magic
```

```
@register_line_cell_magic
```

```
def writetemplate(line, cell):
```

```
with open(line, 'w') as f:  
f.write(cell.format(**globals()))
```

```
%%writetemplate /content/yolov5/models/custom_yolov5s.yaml
```

```
# parameters
```

```
nc: {num_classes} # number of classes
```

```
depth_multiple: 0.33 # model depth multiple
```

```
width_multiple: 0.50 # layer channel multiple
```

```
# anchors
```

```
anchors:
```

```
- [10,13, 16,30, 33,23] # P3/8
```

```
- [30,61, 62,45, 59,119] # P4/16
```

```
- [116,90, 156,198, 373,326] # P5/32
```

```
# YOLOv5 backbone
```

```
backbone:
```

```
# [from, number, module, args]
```

```
[-1, 1, Focus, [64, 3]], # 0-P1/2
```

```
[-1, 1, Conv, [128, 3, 2]], # 1-P2/4
```

```
[-1, 3, BottleneckCSP, [128]],
```

```
[-1, 1, Conv, [256, 3, 2]], # 3-P3/8
```

```
[-1, 9, BottleneckCSP, [256]],
```

```
[-1, 1, Conv, [512, 3, 2]], # 5-P4/16
```

```
[-1, 9, BottleneckCSP, [512]],
```

```
[-1, 1, Conv, [1024, 3, 2]], # 7-P5/32
```

```
[-1, 1, SPP, [1024, [5, 9, 13]]],
```

```
[-1, 3, BottleneckCSP, [1024, False]], # 9
```

]

# YOLOv5 head

head:

[-1, 1, Conv, [512, 1, 1]],

[-1, 1, nn.Upsample, [None, 2, 'nearest']],

[-1, 6, 1, Concat, [1]], # cat backbone P4

[-1, 3, BottleneckCSP, [512, False]], # 13

[-1, 1, Conv, [256, 1, 1]],

[-1, 1, nn.Upsample, [None, 2, 'nearest']],

[-1, 4, 1, Concat, [1]], # cat backbone P3

[-1, 3, BottleneckCSP, [256, False]], # 17 (P3/8-small)

[-1, 1, Conv, [256, 3, 2]],

[-1, 14, 1, Concat, [1]], # cat head P4

[-1, 3, BottleneckCSP, [512, False]], # 20 (P4/16-medium)

[-1, 1, Conv, [512, 3, 2]],

[-1, 10, 1, Concat, [1]], # cat head P5

[-1, 3, BottleneckCSP, [1024, False]], # 23 (P5/32-large)

[[17, 20, 23], 1, Detect, [nc, anchors]], # Detect(P3, P4, P5)

]

%%time

%cd /content/yolov5/

!python train.py --img 416 --batch 16 --epochs 100 --data './data.yaml' --  
cfg ./models/custom\_yolov5s.yaml --weights " --name yolov5s\_results --cache

```
# Запуск tensorboard
%load_ext tensorboard
%tensorboard --logdir runs

from utils.plots import plot_results # plot results.txt as results.png
Image(filename='/content/yolov5/runs/train/yolov5s_results/results.png',
width=1000) # view results.png

# відображення правильних даних
print("GROUND TRUTH TRAINING DATA:")
Image(filename='/content/yolov5/runs/train/yolov5s_results/test_batch0_label
s.jpg', width=900)

# дані, що були штучно розширені
print("GROUND TRUTH AUGMENTED TRAINING DATA:")
Image(filename='/content/yolov5/runs/train/yolov5s_results/train_batch0.jpg',
width=900)

%ls runs/

%ls runs/train/yolov5s_results/weights

%cd /content/yolov5/
!python detect.py --weights runs/train/yolov5s_results/weights/best.pt --img
416 --conf 0.4 --source ../test/images


import glob
from IPython.display import Image, display
```

```
for imageName in glob.glob('/content/yolov5/runs/detect/exp/*.jpg'):
    #assuming JPG
    display(Image(filename=imageName))
    print("\n")
```

Классово Б.Ю.

# ВІДОМІСТЬ ДИПЛОМНОГО ПРОЄКТУ

[illegible]

|          |              |   |      |  |   |        |
|----------|--------------|---|------|--|---|--------|
|          |              |   |      | PI71.426469.001  |   |        |
|          | ПБ           | Підп.   | Дата | Виявлення дефектів<br>електронного модуля за<br>допомогою згорткової<br>нейронної мережі | Лист  | Листів |
| Розробн. | Клюско В.Ю.  |  |      |  | 1   | 1      |
| Керівн.  | Адаменко В.О |   |      |  | КПІ ім. Ігоря<br>Сікорського<br>Каф. КіВРА, Гр.<br>PI-п71 |        |
| Н/контр. |              |   |      |  |   |        |
| Зав.каф. | Нелін Є.А.   |   |      |  |   |        |