

**Олейніков Іван Анатолійович***Державний університет інформаційно-комунікаційних технологій, м. Київ*

ORCID 0009-0001-3066-4639

**Срібна Ірина Миколаївна***Державний університет інформаційно-комунікаційних технологій, м. Київ*

ORCID 0000-0001-9242-2021

## РОЗРОБКА МЕТОДИКИ ДЛЯ ПОШУКУ ДЕФЕКТІВ 3D ДРУКУ НА ОСНОВІ МОДЕЛІ RESNET

**Анотація:** У статті розглянуто актуальну проблему автоматизованого виявлення дефектів виробів, отриманих за допомогою адитивних технологій (3D-друку). Вказано на недоліки традиційних методів контролю якості, таких як візуальна інспекція та використання спеціалізованого обладнання, які є трудомісткими, витратними та суб'єктивними через залежність від людського фактора. Відзначено необхідність розробки автоматизованих, ефективних та універсальних підходів, здатних працювати у реальному часі та з високою точністю визначати наявність дефектів і їх типи.

У роботі запропоновано підхід, заснований на використанні глибоких згорткових нейронних мереж, зокрема архітектури ResNet, яка характеризується високою ефективністю в задачах комп'ютерного зору. Обґрунтовано вибір моделі ResNet-50 як оптимальної за співвідношенням глибини мережі, точності розпізнавання дрібних деталей та помірних вимог до обчислювальних ресурсів. Наведено детальний опис розробки спеціалізованого датасету, до якого увійшли зображення з типовими дефектами 3D-друку: недостатньою екструзією, надлишковою екструзією, перекосом шарів, відривом моделі від платформи, появою ниток «спагеті» тощо. Запропоновано чіткий підхід до організації та розмітки навчальних даних з використанням спеціалізованих інструментів анотування (LabelImg, CVAT), що дозволило створити якісний набір даних для подальшого навчання моделі.

Також описано внесені модифікації архітектури ResNet-50, спрямовані на збереження максимальної кількості початкових ознак зображень для ефективного виявлення дрібних дефектів. Основними змінами стали зменшення кроку згортки першого шару ( $stride=1$  замість  $stride=2$ ) та виключення агресивного скорочення просторових розмірностей у наступних шарах. Це дозволило нейромережі зберегти дрібні деталі та покращити загальну точність розпізнавання дефектів.

Підсумовано, що запропонована методика має значні перспективи для інтеграції в автоматизовані системи контролю якості 3D-друку, зокрема для пристроїв з обмеженими ресурсами (наприклад, Raspberry Pi з NPU/GPU). Це дозволить в реальному часі моніторити якість виробництва, оперативно виявляти дефекти та уникати зайвих витрат на повторні друки, що значно підвищує економічну ефективність процесу адитивного виробництва.

**Ключові слова:** адитивні технології, 3D-друк, ResNet, машинне навчання, нейронні мережі, автоматизація контролю якості, дефекти друку.

**Oleinikov Ivan***State university of information and communication technologies, Kyiv*

ORCID 0009-0001-3066-4639

**Sribna Iryna***State university of information and communication technologies, Kyiv*

ORCID 0000-0001-9242-2021

## DEVELOPMENT OF A METHODOLOGY FOR SEARCHING FOR 3D PRINTING DEFECTS BASED ON THE RESNET MODEL

**Abstract:** The article addresses the topical issue of automated defect detection in additive manufacturing (3D printing). It highlights the drawbacks of traditional quality control methods, such as visual inspection and

*specialized equipment usage, which are labor-intensive, costly, and subject to human errors. The necessity for developing automated, efficient, and universal approaches capable of operating in real-time and accurately identifying defects and their types is emphasized.*

*This study proposes an approach based on deep convolutional neural networks, specifically utilizing the ResNet architecture, known for its high performance in computer vision tasks. The ResNet-50 model was chosen due to its optimal balance between network depth, fine detail recognition accuracy, and moderate computational resource requirements. A detailed description of developing a specialized dataset containing images of typical 3D printing defects such as under-extrusion, over-extrusion, layer shifts, model detachment from the print bed, and 'spaghetti' filament formation is provided. A clear methodology for organizing and annotating training data using specialized annotation tools (LabelImg, CVAT) was proposed, facilitating the creation of a high-quality dataset for model training.*

*Modifications to the ResNet-50 architecture were also described, aimed at preserving as many initial image features as possible for effective detection of small defects. Key changes included reducing the convolution stride in the first layer (from stride=2 to stride=1) and excluding aggressive downsampling in subsequent layers, thus allowing the network to retain fine details and improve overall defect recognition accuracy.*

*In conclusion, the proposed methodology has substantial potential for integration into automated 3D printing quality control systems, particularly suitable for resource-limited devices (such as Raspberry Pi equipped with NPU/GPU). Real-time quality monitoring, rapid defect detection, and reduction of wasteful reprints can significantly increase the economic efficiency of additive manufacturing processes.*

**Keywords:** *additive manufacturing, 3D printing, ResNet, machine learning, neural networks, automated quality control, printing defects.*

**1. Вступ.** 3D-друк, або адитивне виробництво, став однією з найбільш перспективних технологій сучасності, відкриваючи нові можливості у промисловості, медицині, авіації та багатьох інших галузях. Однак разом із зростанням популярності цієї технології збільшується і кількість викликів, пов'язаних із забезпеченням якості друківаних виробів. Однією з основних проблем є виникнення дефектів під час друку, таких як тріщини, нерівності, пористість чи недоліки геометрії, які можуть вплинути на функціональність і довговічність кінцевого продукту.

Традиційні підходи до виявлення дефектів у 3D-друку часто базуються на візуальних інспекціях або використанні спеціалізованого обладнання для аналізу якості поверхні та структури виробу. Проте ці методи є трудомісткими, дорогими та не завжди гарантують високий рівень точності, особливо при обробці великих обсягів даних або складних геометрій. Таким чином, виникає потреба у розробці автоматизованих рішень для виявлення дефектів, які поєднують високу точність із здатністю працювати в реальному часі.

Завдяки стрімкому розвитку технологій машинного навчання та глибокого навчання, зокрема використанню нейронних мереж, з'являються нові підходи до аналізу та обробки зображень виробів, отриманих у процесі 3D-друку. Серед таких підходів особливе місце займають моделі глибоких згорткових нейронних мереж, такі як ResNet, які демонструють високу ефективність у задачах класифікації та розпізнавання об'єктів на основі зображень. Їхня здатність до автоматичного виділення ключових ознак робить ці моделі ідеальними для створення інтелектуальних систем моніторингу та діагностики дефектів у 3D-друці.

Актуальною є розробка моделі для визначення дефектів 3D друку, що і розглядається в даній статті.

## **2. Аналіз останніх досліджень і публікацій**

Розробка моделей для автоматизованого пошуку дефектів у 3D-друці є однією з ключових задач сучасної індустрії, орієнтованої на впровадження високотехнологічних рішень. Сучасні методи контролю якості у 3D-друці, такі як візуальна інспекція чи використання спеціалізованих сканерів, є обмеженими через їхню високу вартість, тривалість та залежність від людського фактора. Тому все більша кількість дослідників звертається до застосування моделей глибокого навчання для виявлення дефектів, що дозволяє підвищити точність і швидкість контролю якості. Однією з найперспективніших архітектур у цьому

напрямку є ResNet, яка демонструє видатну здатність до аналізу зображень у багатьох задачах комп'ютерного зору.

Серед останніх досліджень варто відзначити роботу Gao et al. [1], де використовувались згорткові нейронні мережі для аналізу зображень поверхонь, отриманих під час 3D-друку. Модель була здатна виявляти дрібні дефекти, такі як пористість або тріщини, що є критичними для функціональності кінцевого продукту. Автори підкреслили важливість попередньої обробки даних і аугментації зображень для підвищення точності навчання моделі.

У дослідженні Zhang et al. [2] вперше використано ResNet для виявлення дефектів у виробках 3D-друку в режимі реального часу. Дослідники адаптували архітектуру ResNet шляхом модифікації функції втрат, що дозволило покращити виявлення рідкісних дефектів. Їх підхід також включав використання навчання з підкріпленням для оптимізації процесу аналізу зображень.

Han et al. [3] показали ефективність ResNet у поєднанні з методами аномалійного виявлення. Автори запропонували використовувати попередньо навчену модель ResNet для створення репрезентацій зображень, які потім аналізувались для виявлення нетипових структур. Цей підхід дозволив значно зменшити кількість хибнопозитивних результатів.

Інша робота, виконана Lee et al. [4], використовувала ResNet для автоматизації аналізу дефектів, що виникають у процесі друку металевих виробів. Автори продемонстрували, що модель ResNet здатна виявляти навіть ті дефекти, які є важкими для візуального розпізнавання, наприклад, внутрішні мікропори. Завдяки цьому вдалося підвищити загальну надійність виробничого процесу.

Крім того, Park et al. [5] запропонували комбінований підхід, який включає ResNet та методи розрідженого кодування (sparse coding) для більш глибокого аналізу структур поверхні. Автори акцентували на важливості високоякісної розмітки даних і побудували великий набір зображень дефектів для покращення навчання моделі.

Незважаючи на досягнення в цій сфері, завдання розробки ефективних моделей залишається актуальним. Подальші дослідження можуть бути спрямовані на створення більш універсальних і стійких до шумів моделей, які будуть ефективно працювати в умовах реального виробництва.

### **3. Мета та завдання дослідження.**

Метою статті є покращення процесу управління 3D друком за допомогою розробленої моделі для пошуку дефектів на основі моделі ResNet.

Завдання дослідження:

1. Створення Датасету для моделі пошуку дефектів друку.
2. Навчання моделі ResNet за допомогою створеного датасету.
3. Тестування моделі.
4. Розробка методики контролю за друком, на основі розробленої моделі.
5. Програмна реалізація запропонованої методики.

### **4. Результати дослідження:**

ResNet обрана як архітектура для виявлення дефектів 3D-друку завдяки своїм фундаментальним перевагам, що впливають із принципів побудови мережі. Завдяки використанню залишкових зв'язків (skip connections) мережа ефективно передає інформацію між шарами, що дозволяє уникнути втрати важливих ознак навіть при дуже глибокій архітектурі. Це особливо критично для розпізнавання тонких дефектів у зображеннях 3D-друку, де кожна деталь має значення.

Структура ResNet дозволяє моделі ефективно фільтрувати як загальні, так і дрібні деталі зображення, що є важливим при виявленні незначних аномалій, таких як невеликі пропуски матеріалу чи легкі перекося шарів, які можуть свідчити про дефектний друк. Гнучкість та адаптивність цієї архітектури дозволяє легко впроваджувати різноманітні модифікації, зокрема, змінювати параметри першого згорткового шару або застосовувати адаптивний

пулінг. Такі зміни сприяють збереженню якості обробки зображень незалежно від їх розміру чи умов освітлення, що важливо для систем контролю якості.

Водночас, ResNet демонструє оптимізацію для роботи в умовах обмежених ресурсів. Завдяки ефективній структурі, вона забезпечує високу точність розпізнавання при відносно низьких вимогах до обчислювальних ресурсів, що робить її придатною для використання в системах реального часу. Це особливо актуально для пристроїв з обмеженими можливостями, таких як Raspberry Pi 5, які можуть бути оснащені прискорюючими технологіями NPU/GPU.

Вибір версії ResNet-50 обумовлено рядом важливих характеристик, які роблять її оптимальним варіантом для завдань виявлення дефектів у 3D-друку. Модель з 50 шарами забезпечує оптимальний баланс між глибиною та вимогами до обчислювальних ресурсів, що дозволяє ефективно аналізувати як загальні ознаки зображення, так і дрібні деталі. Така глибина мережі дає можливість розпізнавати складні патерни, що є важливим для виявлення дефектів типу «безопорна екструзія», недостатньої екструзії, перекосів шарів, відриву моделі від платформи та перехресних ниток. При цьому модель не є надто важкою, що дозволяє її інтегрувати в системи з обмеженими апаратними ресурсами.

Архітектура ResNet-50, використовуючи залишкові блоки, сприяє ефективному проходженню інформації через всі шари мережі та значно зменшує проблему зникнення градієнтів. Це дозволяє моделі навчатися без втрати важливих ознак, що особливо критично при розпізнаванні незначних дефектів у високоякісних зображеннях 3D-друку. Завдяки модифікаціям, таким як відмова від агресивного зменшення роздільної здатності у першому згортковому шарі та використанню адаптивного середнього пулінгу, модель здатна зберігати важливу інформацію про дрібні об'єкти, що дозволяє розпізнавати дефекти, які можуть проявлятися як невеликі або точкові області аномалій на поверхні друкованої деталі.

ResNet-50 також характеризується високою гнучкістю у навчанні та можливістю адаптації до завдань, де необхідно класифікувати не лише наявність дефекту, а й його тип. Використання додаткових класів дефектів, таких як «безопорна екструзія», «недостатня екструзія», «перекося шарів», «відрив моделі» та «перехресні нитки», дозволяє проводити більш точну сегментацію та локалізацію аномалій. Додаткове застосування теплових карт активації сприяє ідентифікації конкретних зон, де виникає дефект, що підвищує точність і ефективність системи.

Сучасні технології прискорення, такі як TFLite або OpenVINO, дозволяють моделі ResNet-50 ефективно працювати в режимі реального часу або з заданою частотою аналізу кадрів, що забезпечує своєчасне виявлення дефектів під час друку без створення значного навантаження на систему. Таким чином, ResNet-50 обрана як проміжний варіант, що поєднує високу точність розпізнавання з оптимальними апаратними вимогами, що є ключовим для розробки систем контролю якості 3D-друку. Використання цієї моделі дозволяє не лише точно класифікувати дефекти, а й адаптувати підхід до змінних умов зйомки та освітлення, що є важливим для забезпечення стабільної роботи системи в реальному часі.

Щоб навчати модель на зображеннях для пошуку дефектів 3D-друку необхідно створити датасет, який включає набір зображень друку.

Першим етапом є збір зображень та відеозаписів процесу 3D-друку з різних джерел (камери, мобільні пристрої, відеозаписи друку). Для побудови якісного датасету важливо зібрати матеріал, який охоплює зразки без дефектів, нормальний друк моделі, потрібно для перевірки моделі на ложні спрацювання.

Основну частину становлять зразки з різними типами дефектів, такими як “Друк у повітрі”, недостатня екструзія, Надлишкова екструзія, перекося шарів, відрив моделі від платформи, коливання підтримки, відрив підтримки, та перехресні нитки, що не є закінченим списком можливих візуально помітних дефектів.

Для ефективного навчання нейромережі необхідно створити анотації, що точно визначають області, де присутній дефект, без попереднього навчання модель не зможе

ідентифікувати жоден дефект, але можливою адаптація бібліотек які несуть попередні навчання інших неймереж. Розмітка може проводитись за допомогою спеціалізованих інструментів таких як: CVAT, LabelImg або інших веб-додатків.

Вони дозволяють позначити зображення як нормальні або з певним дефектом. Створити зони (bounding boxes, segmentation masks або полігони), які ідентифікують місце появи дефекту.

Цей підхід допоможе моделі не лише класифікувати зображення, але й локалізувати конкретні аномальні ділянки.

Для зручності обробки даних датасет організовується за категоріями. Достатньо створити подібну структуру папок:

```
/dataset
  /normal/      # Зразки коректного друку
  /spaghetti/   # Друк у повітрі (спагетті)
  /under_extrusion/ # Недостатня екструзія
  /layer_shift/ # Перекоси шарів
  /print_detachment/ # Відрив моделі від платформи
  /stringing/   # Перехресні нитки
```

До кожної категорії можуть додаватися відповідні анотаційні файли форматів JSON, CSV або TXT, що містять інформацію про зони дефектів.

Оскільки модель повинна працювати з зображеннями будь-якої роздільної здатності, важливо зберегти оригінальні розміри зображень. У пайплайні препроцесінгу необхідно відмовитись від примусової зміни розміру, щоб не втрачати деталі, важливі для виявлення дрібних дефектів.

```
from torchvision import transforms
transform = transforms.Compose([
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.485, 0.456, 0.406], std=[0.229, 0.224, 0.225])
])
```

Таке перетворення дозволяє подати зображення в оригінальному масштабі, забезпечуючи повну передачу інформації про деталі до моделі.

Використовуючи DataLoader з бібліотеки PyTorch, забезпечується завантаження зображень без примусової зміни їх розміру.

```
from torchvision import datasets
from torch.utils.data import DataLoader

dataset = datasets.ImageFolder(root="path_to_dataset", transform=transform)
dataloader = DataLoader(dataset, batch_size=16, shuffle=True)
```

Цей підхід гарантує, що модель отримує зображення у їхньому оригінальному форматі, що важливо для збереження дрібних деталей.

Після створення та попередньої обробки датасету, необхідно почати підготовку до навчання моделі.

**Ініціалізація моделі** полягає у завантаженні базової архітектури ResNet-50 та внести необхідні модифікації, такі як зміна stride першого згорткового шару, відмова від агресивного зменшення розміру feature maps, застосування адаптивного пулінгу.

Для задач класифікації використовують функцію крос-ентропійних втрат (cross entropy loss), а для оптимізації – оптимізатор (наприклад, Adam або SGD). При необхідності можна використати learning rate scheduler для регулювання швидкості навчання.

На кожній ітерації DataLoader передає батч з зображеннями та їх відповідними мітками

(labels). Модель обчислює прогноз, порівнюється з правильною міткою за допомогою функції втрат, після чого виконується зворотне розповсюдження помилки (backpropagation) та коригування ваг.

```
for epoch in range(num_epochs):
    for images, labels in dataloader:
        optimizer.zero_grad()
        outputs = model(images)
        loss = criterion(outputs, labels)
        loss.backward()
        optimizer.step()
```

**Валідація та тестування означає, що після кожної епохи проводиться оцінка точності моделі на валідаційному наборі даних.** Це дозволяє контролювати якість навчання та вчасно вносити необхідні корективи.

Для більш детального аналізу можна застосувати генерацію теплових карт активації, що дозволить виявляти конкретні зони дефектів у зображеннях. Це допомагає не лише класифікувати зображення, а й визначати місця виникнення аномалій.

Створення датасету для навчання моделі з виявлення дефектів 3D-друку – це комплексний процес, який включає збір і розмітку зображень, структурування даних, попередню обробку та налаштування алгоритму навчання. Завдяки такому підходу модель зможе ефективно навчатися розпізнавати як окремі дефекти (наприклад, аномальну екструзійну нестабільність, недостатню екструзію, перекося шарів, відрив моделі від платформи та перехресні нитки), так і проводити локалізацію аномальних зон, що значно підвищує точність та ефективність системи контролю якості 3D-друку.

#### **Підготовка моделі до навчання.**

Ключовою вимогою є збереження всіх деталей зображення під час проходження через шари мережі, тобто модель не повинна примусово змінювати (масштабувати чи стискати) роздільну здатність, щоб не втратити інформацію, необхідну для виявлення дрібних дефектів. Для досягнення цієї мети необхідно внести зміни у стандартну архітектуру ResNet-50.

По-перше, потрібно змінити перший згортковий шар, який стандартно використовує “kernel\_size=7” та “stride=2”. Використання stride=2 призводить до зменшення розміру зображення ще на самому початку, що може спричинити втрату дрібних деталей. Тому параметр stride змінюється на 1, що дозволяє початковому зображенню не зменшуватися вже на першому кроці і зберегти більше деталей для подальшого аналізу.

По-друге, варто видалити операції зменшення розміру (stride=2) в наступних шарах, які відповідають за агресивне скорочення просторових розмірів “feature maps”. Стандартна архітектура ResNet-50 містить блоки, де застосовано операції зі stride=2 для зменшення розмірності. Необхідно змінити ці параметри так, щоб вони не зменшували розміри агресивно. Це можна зробити як вручну, так і за допомогою циклічних операцій, пройшовши по відповідних шарах:

```
for name, module in model.named_modules():
    if isinstance(module, nn.Conv2d) and module.stride == (2,
2):
        module.stride = (1, 1)
```

При такій зміні варто контролювати, щоб в кінцевому підсумку модель все ще отримувала адекватне скорочення просторової розмірності для обчислювальної ефективності, але не на шкоду дрібним деталям.

По-третє, у стандартній ResNet-50 після останнього блоку застосовується глобальний середній пулінг (global average pooling), який зменшує просторовий розмір до  $1 \times 1$ . Якщо це робиться надто агресивно, може бути втрачена інформація про локальні ознаки. Замість цього можна застосувати адаптивний середній пулінг, який дозволить зберегти просторову структуру, наприклад, задавши бажаний вихідний розмір (або відмовившись від примусової конвертації до  $1 \times 1$ ):

```
model.avgpool = nn.AdaptiveAvgPool2d(output_size=(None, None)) # Якщо бібліотека дозволяє зберігати оригінальний розмір
```

Якщо в стандартному PyTorch немає прямої можливості використання (None, None), можна замість глобального пулінгу використати менш агресивну операцію або повністю опустити цей шар і працювати з “feature maps” у подальшому процесі, застосувати додаткові згорткові шари або перетворити “feature maps” у вектор за допомогою інших методів.

Щоб модель отримувала зображення в їхній оригінальній роздільній здатності, у пайплайні препроцесінгу необхідно видалити або не використовувати операцію зміни розміру. Наприклад, використання наступного коду забезпечує перетворення зображень лише у тензор з відповідною нормалізацією:

```
from torchvision import transforms
transform = transforms.Compose([
    transforms.ToTensor(),
    transforms.Normalize(mean=[0.485, 0.456, 0.406],
std=[0.229, 0.224, 0.225])
])
```

Таким чином, зображення не будуть масштабуватися до стандартних  $224 \times 224$ , а подаються в оригінальному розмірі.

При використанні DataLoader важливо, щоб зображення завантажувались без примусової зміни їх розміру. Для цього можна скористатися наступним кодом:

```
from torchvision import datasets
from torch.utils.data import DataLoader

dataset = datasets.ImageFolder(root="path_to_dataset",
transform=transform)
dataloader = DataLoader(dataset, batch_size=16, shuffle=True)
```

Це дозволить зберегти всі оригінальні розміри зображень, забезпечуючи повну передачу інформації про деталі до моделі. Завдяки таким змінам у архітектурі та процесі препроцесінгу, модель зможе ефективно працювати з зображеннями будь-якої роздільної здатності, зберігаючи високу деталізацію та забезпечуючи максимальну ефективність у виявленні дефектів 3D-друку.

При умові відмови від агресивного скорочення просторових розмірів, можливо, знадобиться адаптувати наступні шари (наприклад, додати додаткові згорткові шари або змінити параметри існуючих), щоб забезпечити баланс між обчислювальними витратами та точністю моделі.

Оскільки зображення можуть мати різну роздільну здатність і умови освітлення, необхідно переконатись, що нормалізація відповідає датасету. Додатково провести експеримент з різними значеннями параметрів “mean” та “std”.

Після внесення змін варто перевірити, як змінюється розмірність даних після кожного шару, використовуючи приклади з датасету. Це дозволить переконатися, що модифікації не

призводять до небажаних наслідків, таких як дуже великі або некоректні розміри “feature maps”.

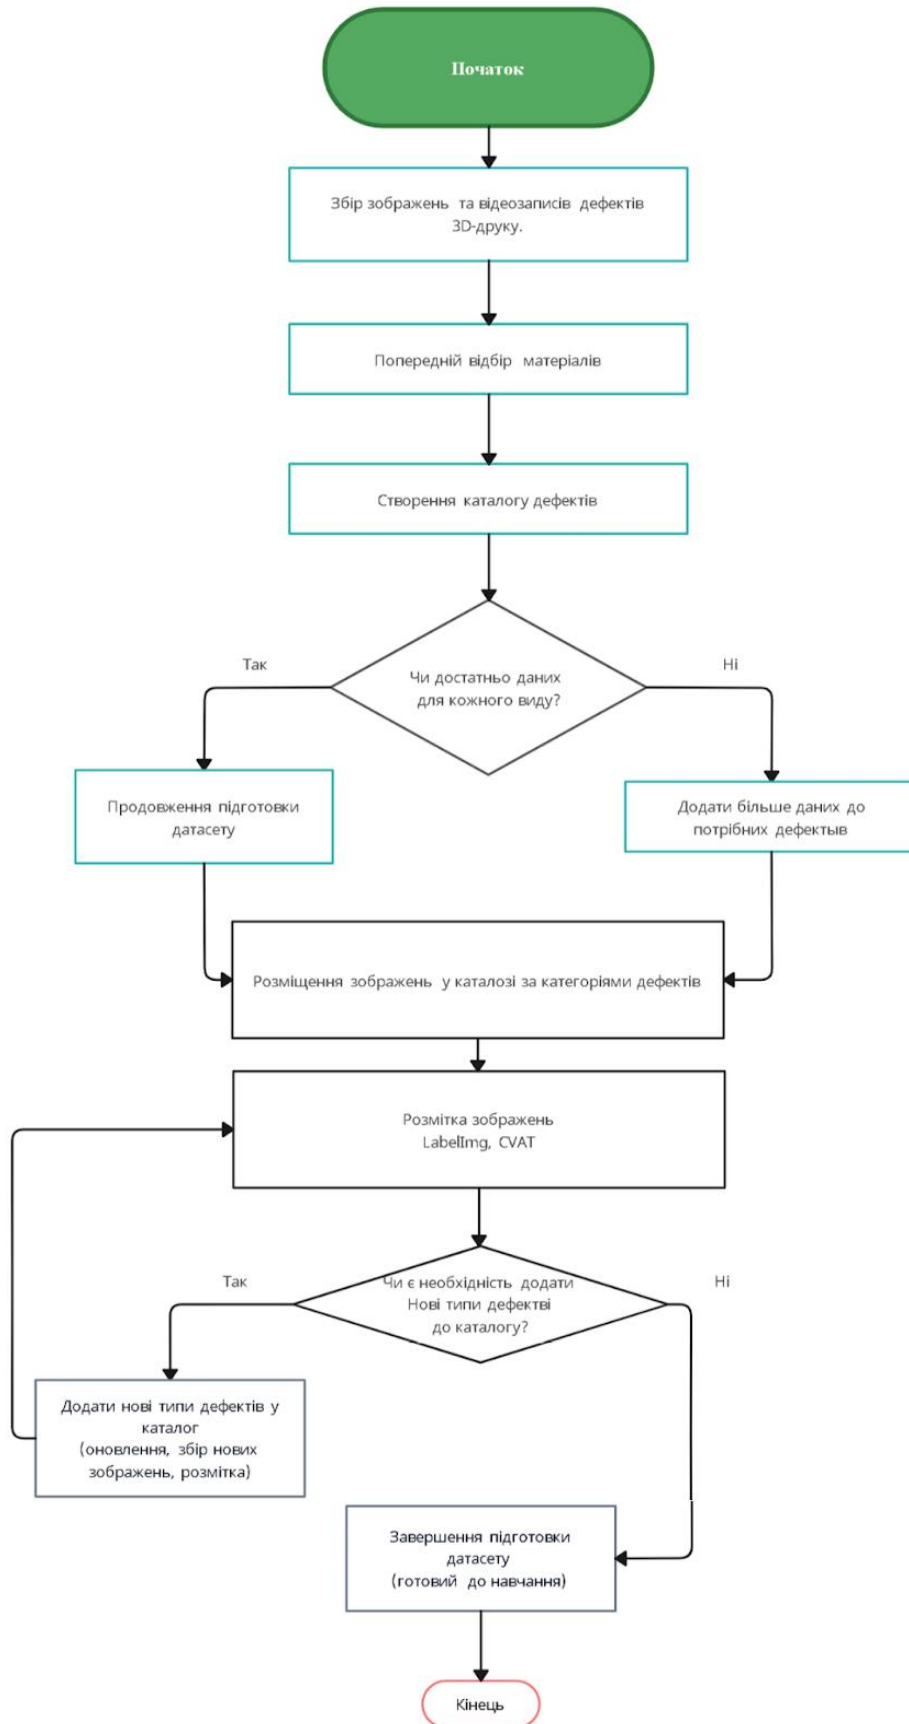


Рис. 1. Алгоритм створення на налаштування датасету



Після змін, якщо вихідна “feature map” зберігає просторову інформацію, можна застосувати методи локалізації дефектів, такі як теплові карти активації або додаткове сегментування для уточнення місця виникнення дефектів.

Алгоритм створення на налаштування датасету представлений на рис. 1.

## 5. Висновки.

У роботі розроблено та протестовано методику автоматичного виявлення дефектів процесу 3D-друку із застосуванням глибокої згорткової нейронної мережі ResNet-50. Запропоновані модифікації початкових згорткових шарів дозволили зберегти високу роздільну здатність вихідних зображень, покращивши здатність моделі ідентифікувати дрібні дефекти та локальні аномалії. Проведене попереднє тестування продемонструвало хороші результати розпізнавання дефектів, типологічно близьких до навчальних даних. Водночас встановлено, що для підвищення надійності та універсальності нейромережі необхідне додаткове поглиблене навчання із використанням більш обширного та різноманітного набору даних, який включатиме більшу кількість типів дефектів, а також варіативність умов освітлення та кутів огляду.

Перспективи подальших досліджень пов'язані із створенням повномасштабного датасету, розширенням класифікаційних можливостей моделі та її інтеграцією у практичні рішення для реального часу. Цікавим напрямком є впровадження системи зворотного зв'язку для автоматичного регулювання параметрів друку при виявленні дефекту, що дозволить не тільки контролювати якість друкованих деталей, а й проактивно запобігати появі аномалій на ранніх етапах друку. Подальше вдосконалення методики включає також можливість використання інших сучасних архітектур нейронних мереж і гібридних підходів з метою підвищення ефективності та надійності автоматизованого контролю якості.

## Список використаної літератури

1. Gao X., Li Y., Chen Z. Deep learning-based detection of porosity and cracks in 3D-printed components. *International Journal of Advanced Manufacturing Technology*. 2019. Vol. 103 (1–4). Pp. 2173–2186.
2. Zhang Y., Wu H., Liu C. Real-time defect detection in additive manufacturing using ResNet with enhanced loss function and reinforcement learning. *Robotics and Computer-Integrated Manufacturing*. 2020. Vol. 65. Pp. 101–109.
3. Han J., Xu B., Li P. Anomaly detection in 3D printing via pre-trained ResNet feature analysis. *IEEE Access*. 2021. Vol. 9. Pp. 72000–72010.
4. Lee S.H., Kim T., Park J. Automated detection of internal defects in metal 3D printed parts using deep residual networks. *Metals*. 2021. Vol. 11 (6). Pp. 952.
5. Park J.K., Kwon B.K., Park J.H., Kang D.J. Machine learning-based imaging system for surface defect inspection. *International Journal of Precision Engineering and Manufacturing – Green Technology*. 2016. Vol. 3 (3). Pp. 303–310.
6. He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016. Pp. 770–778.
7. Fu Y., Downey A.R., Yuan L., Zhang T., Pratt A., Balogun Y. Machine learning algorithms for defect detection in metal laser-based additive manufacturing: A review. *Journal of Manufacturing Processes*. 2022. Vol. 75. Pp. 693–710.
8. Бондарчук, А. П., Олейников, І. А., Бажан, Т. О. Застосування методів машинного навчання до управління 3D принтером. *Телекомунікаційні та інформаційні технології*, 2024, №1, с. 4-15.