

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет Інформаційно-аналітичних технологій та менеджменту  
(повна назва)

Кафедра Інформатики  
(повна назва)

**КВАЛІФІКАЦІЙНА РОБОТА**  
**Пояснювальна записка**

рівень вищої освіти другий (магістерський)

**ДОСЛІДЖЕННЯ МЕТОДІВ КЛАСИФІКАЦІЇ**  
**МИСЛИВСЬКИХ ПОРІД СОБАК НА ЗОБРАЖЕННЯХ**  
(тема)

Виконав:  
студент 2 курсу, групи ІНФМ-23-2

Корякіна С.М.  
(прізвище, ініціали)

Спеціальності 122 Комп'ютерні науки  
(код і повна назва спеціальності)

Тип програми освітньо-професійна

Освітня програма Інформатика  
(повна назва освітньої програми)

Керівник доц. Творошенко І.С.  
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри \_\_\_\_\_  
(підпис)

Кобилін О.А.  
(прізвище, ініціали)

2025 р.

## Харківський національний університет радіоелектроніки

Факультет Інформаційно-аналітичних технологій та менеджменту  
(повна назва)Кафедра Інформатики  
(повна назва)Рівень вищої освіти другий (магістерський)Спеціальність 122 Комп'ютерні науки  
(код і повна назва)Тип програми освітньо-професійнаОсвітня програма Інформатика  
(повна назва освітньої програми)

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

«\_\_\_\_» \_\_\_\_\_ 2025 р.

**ЗАВДАННЯ**  
НА КВАЛІФІКАЦІЙНУ РОБОТУстудентові Корякіній Софії Михайлівні  
(прізвище, ім'я, по батькові)1. Тема роботи Дослідження методів класифікації мисливських порід собак на зображеннях

затверджена наказом по університету від 25 листопада 2024 року № 1246Ст

2. Термін подання студентом роботи до екзаменаційної комісії 27 грудня 2024 р.3. Вихідні дані до роботи методи класифікації зображень, літературні джерела щодо застосування методів класифікації, програмні засоби для реалізації вибраних методів класифікації та десктоп-застосунку, зображення мисливських порід собак для тренування та тестування моделей.

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

1. Аналіз сучасних методів класифікації об'єктів на зображеннях.2. Аналіз літературних джерел щодо апробації методів класифікації об'єктів на зображеннях.3. Формування покрокового алгоритму для кожного із вибраних методів класифікації.4. Візуалізація сформованих покрокових алгоритмів.5. Розробка програмного застосунку, що надасть змогу класифікувати мисливські породи собак на зображеннях кожним із вибраних методів.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (п.5 включається до завдання за рішенням випускової кафедри) актуальність проблеми класифікації об'єктів на зображеннях, об'єкт та мета дослідження, постановка задачі, блок-схеми алгоритмів вибраних методів класифікації, приклад еталонних зображень для класу сформованого набору даних, ілюстрація головного екрану розробленого застосунку із контекстним меню вибору методу класифікації, ілюстрація результатів класифікації кожним із вибраних методів, висновки, перспективи та апробація роботи.

6. Консультанти розділів роботи (п.6 включається до завдання за наявності консультантів згідно з наказом, зазначеним у п.1)

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

### КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	25.11.2024	
2	Аналіз завдання, підбір літератури	25.11.24-30.11.24	
3	Аналіз літератури з досліджуваної проблеми	01.12.24-05.12.24	
4	Аналіз технічних засобів	05.11.24-07.11.24	
5	Формування покрокового алгоритму для кожного з методів	08.12.24-10.12.24	
6	Програмна реалізація	10.12.24-19.12.24	
7	Оформлення пояснювальної записки	19.12.24-21.12.24	
8	Перевірка на плагіат	23.12.2024	
9	Рецензування	24.12.2024	
10	Підготовка презентації та доповіді	26.12.2024	
11	Занесення роботи в електронний архів	27.12.2024	
12	Попередній захист кваліфікаційної роботи	07.01.2025	

Дата видачі завдання 25 листопада 2024 р.

Студент \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_ доц. Творошенко І. С.  
(підпис) (посада, прізвище, ініціали)

## РЕФЕРАТ/ABSTRACT

Пояснювальна записка до кваліфікаційної роботи: 90 с., 1 табл., 53 рис., 42 джерела.

PROTOTYPICAL NETWORK, TRANSFER LEARNING, VGG16, SIAMESE NETWORKS, FEW-SHOT LEARNING, КЛАСИФІКАЦІЯ ЗОБРАЖЕНЬ, МИСЛИВСЬКІ ПОРОДИ СОБАК, ДЕСКТОП-ЗАСТОСУНОК, БЛОК-СХЕМА, БІБЛІОТЕКА TENSORFLOW, БІБЛІОТЕКА PYTORCH.

Об'єктом дослідження є зображення мисливських порід собак.

Метою дослідження є порівняння методів розпізнавання зображень шляхом розробки застосунку, що класифікує мисливські породи собак на зображеннях із точністю у відсотковому значенні.

Використано методи Prototypical Network, Transfer Learning з Pretrained CNN та Siamese Networks для класифікації мисливських порід собак на зображеннях. Проведено аналіз сучасних методів класифікації об'єктів на зображеннях та відповідних літературних джерел. Сформовано та візуалізовано алгоритми методів блок-схемами.

У результаті дослідження розроблено десктоп-застосунок класифікації мисливських порід собак на зображеннях із точністю у відсотковому значенні.

PROTOTYPICAL NETWORK, TRANSFER LEARNING, VGG16, SIAMESE NETWORKS, FEW-SHOT LEARNING, IMAGE CLASSIFICATION, HUNTING DOG BREEDS, DESKTOP APPLICATION, FLOWCHART, TENSORFLOW LIBRARY, PYTORCH LIBRARY.

The object of the research is images with hunting dog breeds.

The aim of the research is to compare image recognition methods by developing an application that classifies hunting dog breeds in images with percentage accuracy.

The Prototypical Network, Transfer Learning with Pretrained CNN and Siamese Networks methods were used to classify hunting dog breeds on images. The analysis of modern methods of object classification on images and relevant literature is carried out. The algorithms of the methods are formed and visualized by flowcharts.

As a result of the research, a desktop application for classifying hunting dog breeds on images with a percentage accuracy was developed.

## ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів .....	7
Вступ.....	8
1 Аналіз методів класифікації об’єктів на зображеннях.....	10
1.1 Аналіз сучасних методів класифікації об’єктів на зображеннях...	10
1.1.1 Метод Prototypical Network для Few-Shot Learning.....	11
1.1.2 Метод Transfer Learning з Pretrained CNN.....	13
1.1.3 Метод Siamese Networks для Few-Shot Learning.....	14
1.1.4 Обґрунтування вибору методів для дослідження.....	15
1.2 Аналіз літературних джерел щодо апробації результатів застосування методів класифікації об’єктів на зображеннях, зокрема, тварин .....	17
1.3 Постановка задачі дослідження.....	30
2 Особливості вибраних методів класифікації об’єктів на зображеннях.....	31
2.1 Аналіз методу Prototypical Network для навчання з малою кількістю прикладів .....	31
2.1.1 Основна ідея методу Prototypical Network .....	31
2.1.2 Алгоритм методу Prototypical Network.....	32
2.2 Аналіз методу Transfer Learning з Pretrained CNN .....	38
2.2.1 Основна ідея методу Transfer Learning з Pretrained CNN .....	38
2.2.2 Алгоритм методу Transfer Learning з Pretrained CNN.....	39
2.3 Аналіз методу Siamese Networks для навчання з малою кількістю прикладів.....	44
2.3.1 Основна ідея методу Siamese Networks .....	44
2.3.2 Алгоритм методу Siamese Networks.....	45
3 Дослідження та порівняння методів класифікації мисливських порід собак на зображеннях.....	49

3.1	Вибір інструментальних засобів для реалізації вибраних методів.....	49
3.2	Етапи програмної реалізації вибраних методів класифікації мисливських порід собак на зображеннях.....	52
3.2.1	Структура реалізації методу Prototypical Network.....	55
3.2.2	Структура реалізації методу Transfer Learning з Pretrained CNN (VGG16).....	56
3.2.3	Структура реалізації методу Siamese Networks .....	57
3.3	Інструкція користувача .....	57
3.4	Дослідження методів класифікації мисливських порід собак на зображеннях.....	58
3.5	Критеріальний порівняльний аналіз досліджених методів класифікації мисливських порід собак на зображеннях .....	80
3.6	Перспективи подальшої роботи .....	82
	Висновки .....	84
	Перелік джерел посилання .....	86

## **ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ**

Prototypical Network for Few-Shot Learning (прототипна мережа для навчання з малою кількістю прикладів)

Transfer Learning with Pretrained CNNs (трансферне навчання з попередньо навченими згортковими неймережами)

Siamese Networks for Few-Shot Learning (сіамські мережі для навчання з малою кількістю прикладів)

YOLO – You Only Look Once (ви дивитеся лише раз)

HOG – Histogram of Oriented Gradients (гістограма напрямлених градієнтів)

SVM – Support Vector Machine (метод опорних векторів)

NLP – Natural Language Processing (обробка природної мови)

DNN – Deep Neural Network (глибока нейронна мережа)

WOA – Whale Optimization Algorithm (алгоритм оптимізації китів)

Loss Function – функція втрат

Cross-Entropy Loss – крос-ентропія

Fine-Tuning – «донавчання»

IDE – Integrated Development Environment (інтегроване середовище розробки)

GPU – Graphics Processing Unit (графічний процесор)

API – Application Programming Interface (прикладний програмний інтерфейс)

VGG – Visual Geometry Group (група візуальної геометрії)

ResNet – Residual Network («залишкова мережа»)

PIL – Python Imaging Library (бібліотека зображень Python)

GUI – Graphical User Interface (графічний інтерфейс користувача)

JPEG – Joint Photographic Experts Group (об'єднана група експертів із фотографії)

## ВСТУП

Сучасні технології комп'ютерного зору відіграють критичну роль у багатьох галузях, починаючи від медицини та закінчуючи автомобільною промисловістю. Застосування методів класифікації об'єктів на зображеннях дозволяє автоматизувати процеси, які раніше потребували значних людських ресурсів. Це сприяє підвищенню ефективності, зменшенню помилок та покращенню якості прийнятих рішень [1]. Комп'ютерний зір, використовуючи сучасні алгоритми машинного навчання та глибинного навчання, здатен виконувати завдання, які раніше здавались нереальними.

Методи комп'ютерного зору знаходять застосування в багатьох сферах життя. В медицині вони використовуються для аналізу зображень, що дозволяє діагностувати захворювання на ранніх стадіях. В автомобільній промисловості методи розпізнавання об'єктів застосовуються для розробки систем автономного водіння, які покращують безпеку на дорогах. Відеоспостереження, система розпізнавання облич, пошук зниклих людей, контроль доступу [2] – всі ці задачі вирішуються завдяки технологіям комп'ютерного зору.

Серед багатьох напрямків застосування комп'ютерного зору, класифікація порід собак на зображеннях є особливо важливим для зоології, ветеринарії та кінології. Це дозволяє автоматизувати процес ідентифікації порід, що має велике значення для ветеринарних клінік, кінологічних клубів та любителів собак. Класифікація порід допомагає швидко і точно ідентифікувати тварин, що зменшує ймовірність помилок, покращує обслуговування та підвищує ефективність роботи фахівців.

Актуальність теми дослідження методів класифікації мисливських порід собак на зображеннях обумовлена потребою в розробці та впровадженні ефективних алгоритмів, які здатні забезпечити високу точність ідентифікації порід. Це важливо не лише для кінологів і ветеринарів, але й

для розробників спеціалізованих застосунків та систем, що орієнтовані на класифікації тварин.

Задачею цього дослідження є порівняння та аналіз сучасних методів класифікації об'єктів на зображеннях, зокрема, для визначення найефективніших підходів до класифікації мисливських порід собак. У роботі буде досліджено три методи класифікації об'єктів, їх ефективність та точність. Вибрані методи будуть програмно реалізовані на мові програмування Python та протестовані на прикладній задачі класифікації мисливських порід собак. На основі результатів тестування буде проведено порівняльний аналіз, який дозволить виділити переваги та недоліки кожного з методів.

Таким чином, дослідження методів класифікації мисливських порід собак на зображеннях є актуальним і важливим завданням, яке сприяє подальшому розвитку технологій комп'ютерного зору та їх застосуванню в різних галузях.

# 1 АНАЛІЗ МЕТОДІВ КЛАСИФІКАЦІЇ ОБ'ЄКТІВ НА ЗОБРАЖЕННЯХ

## 1.1 Аналіз сучасних методів класифікації об'єктів на зображеннях

Сучасні методи класифікації об'єктів на зображеннях використовують різноманітні алгоритми та підходи для досягнення високої точності та ефективності. Ці методи знаходять застосування у багатьох галузях, включаючи безпеку, автомобільну промисловість, медицину, роздрібну торгівлю та інші. У цьому розділі буде розглянуто декілька сучасних методів класифікації об'єктів, таких як Transfer Learning з Pretrained CNN, Prototypical Network та Siamese Networks для навчання з малою кількістю прикладів, їх застосування, переваги та недоліки, а також обґрунтовано вибір цих методів для класифікації мисливських порід собак на зображеннях.

Сучасні методи класифікації об'єктів постійно розвиваються завдяки прогресу в галузі комп'ютерного зору та машинного навчання. Однією з основних цілей є створення алгоритмів, які можуть забезпечити високу точність при мінімальних затратах обчислювальних ресурсів. Важливим аспектом є здатність алгоритмів адаптуватися до різноманітних умов [3], таких як зміни освітлення, положення об'єктів, їх форма та розміри. Відтак, класифікації об'єктів стало важливим інструментом у багатьох сферах життя, що дозволяє автоматизувати процеси та підвищити їх ефективність.

Методи класифікації об'єктів на основі глибокого навчання [4] дозволяють автоматично виділяти ознаки та проводити класифікацію з високою точністю. Проте, однією з ключових проблем глибокого навчання є потреба у великих наборах даних для навчання. У випадку задачі класифікації мисливських порід собак обмежено кількість зображень для кожного класу, що потребує використання методів, здатних ефективно працювати з малою кількістю даних.

Prototypical Network для Few-Shot Learning – це метод, який використовує підхід класифікації на основі прототипів, де кожен клас представлений центроїдом (прототипом) у просторі ознак. Цей метод виявляється ефективним у ситуаціях, коли доступно лише кілька прикладів для кожного класу. У даному випадку, цей метод дозволяє класифікувати породи собак, навіть якщо для навчання доступні лише поодинокі зображення, що робить його чудовим вибором для задачі з малими наборами даних.

Transfer Learning з Pretrained CNN полягає у використанні попередньо навченої глибокої нейронної мережі для нових задач класифікації. Вже натреновані моделі на великих наборах даних можуть бути адаптовані для класифікації нових об'єктів шляхом донавчання на меншій вибірці. Це дозволяє значно зменшити потребу у великих обсягах даних та обчислювальних ресурсах, зберігаючи при цьому високу точність класифікації. Такий підхід добре підходить для задачі класифікації порід собак, де є лише кілька прикладів для кожної породи.

Siamese Networks для One-Shot або Few-Shot Learning працюють за принципом навчання порівнянням. Архітектура використовує пару однакових нейронних мереж, які вчаться вимірювати подібність між двома зображеннями. Такий підхід дозволяє класифікувати об'єкти навіть за наявності лише одного або кількох прикладів кожного класу. У задачі класифікації порід собак це особливо корисно, оскільки система може ідентифікувати нові породи, маючи мінімум даних для навчання.

### 1.1.1 Метод Prototypical Network для Few-Shot Learning

Метод Prototypical Network для Few-Shot Learning є ефективним підходом для класифікації об'єктів, коли для навчання доступна обмежена кількість даних. Основною особливістю цього методу є те, що він

використовує так звані прототипи – центроїди класів у просторі ознак. Для кожного класу створюється прототип на основі доступних зразків, а нові зображення класифікуються за відстанню до цих прототипів.

Цей підхід відрізняється від традиційних методів тим, що не потребує великих обсягів даних для навчання. Prototypical Networks можуть ефективно працювати з кількома прикладами кожного класу, що робить їх особливо корисними для задач з обмеженими даними, таких як класифікації порід собак на малих вибірках. Система швидко адаптується до нових класів, дозволяючи класифікувати породи навіть при наявності лише кількох зображень для кожної породи.

Метод Prototypical Network знайшов застосування в різних сферах, де обмежені дані є проблемою. Це, наприклад, медична діагностика, розпізнавання облич або об'єктів, де отримати велику кількість навчальних зразків складно або неможливо. Його переваги включають високу ефективність при обмежених обсягах даних, простоту в реалізації та можливість швидкого навчання нових класів.

Недоліками цього методу є те, що точність класифікації може знижуватися, якщо зображення мають сильні варіації або недостатньо точно представляють відповідний клас. Однак у задачах, де важлива швидка адаптація до нових класів і де доступ до великих наборів даних обмежений, цей метод є одним з найефективніших.

У випадку класифікації мисливських порід собак, метод Prototypical Network дозволяє точно ідентифікувати породи навіть при наявності лише кількох еталонних зображень для кожної породи. Це робить його придатним для задач, де доступна кількість даних є мінімальною, але необхідна висока точність класифікації.

Візуалізоване навчання з малою кількістю прикладів та навчання з нуля зображено на рисунку 1.1 [5].




Рисунок 1.1 – Візуалізація навчання з малою кількістю прикладів та навчання з нуля

### 1.1.2 Метод Transfer Learning з Pretrained CNN

Метод Transfer Learning з Pretrained CNN є одним із сучасних підходів до класифікації зображень, що дозволяє використовувати вже натреновані моделі для вирішення нових задач. Основною ідеєю цього методу є те, що попередньо навчені моделі на великих наборах даних можуть бути адаптовані для нових класів об'єктів шляхом донавчання на меншому наборі спеціалізованих зображень. Це дозволяє ефективно використовувати вже наявні знання, зекономити обчислювальні ресурси та час на навчання.

Трансферне навчання широко застосовується у таких сферах, як медична діагностика, розпізнавання облич, класифікація зображень у природничих науках та промисловості, а також у задачах розпізнавання об'єктів у відеоспостереженні та автономних системах.

Основні переваги цього підходу включають можливість досягнення високої точності навіть при малих обсягах навчальних даних, зниження потреби в обчислювальних ресурсах і зменшення часу на навчання моделі. Крім того, трансферне навчання дозволяє ефективно використовувати інформацію, що була отримана моделлю під час тренування на великих, різноманітних наборах зображень.

Серед недоліків методу можна виділити те, що попередньо навчені моделі можуть бути не оптимальними для специфічних задач, їх доведеться донавчати для досягнення бажаних результатів.

Також іноді складність моделі може бути надмірною для простих задач, що може вимагати додаткової оптимізації.

Архітектуру згорткової нейронної мережі зображено на рисунку 1.2 [6].

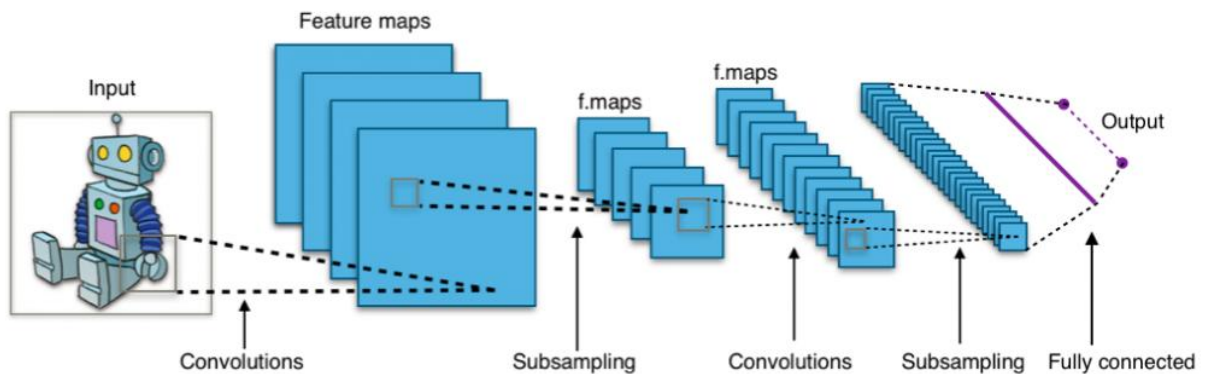


Рисунок 1.2 – Архітектура згорткової нейронної мережі

### 1.1.3 Метод Siamese Networks для Few-Shot Learning

Метод Siamese Networks для навчання з малої кількості прикладів є потужним підходом для задач класифікації, особливо коли доступні лише обмежені дані для тренування.

Основною особливістю Siamese Networks є те, що вони використовують дві (або більше) ідентичні нейронні мережі з однаковими вагами для обробки пар зображень. Метою такого підходу є навчитися порівнювати зображення і визначати, чи належать вони до одного класу.

Siamese Networks широко застосовуються у задачах, де необхідно працювати з обмеженими обсягами даних, таких як розпізнавання облич, ідентифікація почерку, біометричні системи та медична діагностика. Основною перевагою методу є його здатність ефективно класифікувати нові об'єкти, навіть якщо для навчання було використано лише кілька прикладів.

Це досягається завдяки тому, що Siamese Network навчається порівнювати відстань між зображеннями у просторі ознак, а не просто класифікувати їх на основі попередньо визначених класів.

До переваг Siamese Networks належать висока ефективність при обмежених обсягах даних, можливість розпізнавати нові класи без необхідності повного перенавчання моделі, а також здатність працювати у задачах з малою кількістю прикладів.

Проте, серед недоліків можна відзначити складність налаштування та оптимізації моделі, а також більші вимоги до обчислювальних ресурсів порівняно з класичними методами класифікації.

Архітектуру сіамської нейронної мережі зображено на рисунку 1.3 [7].

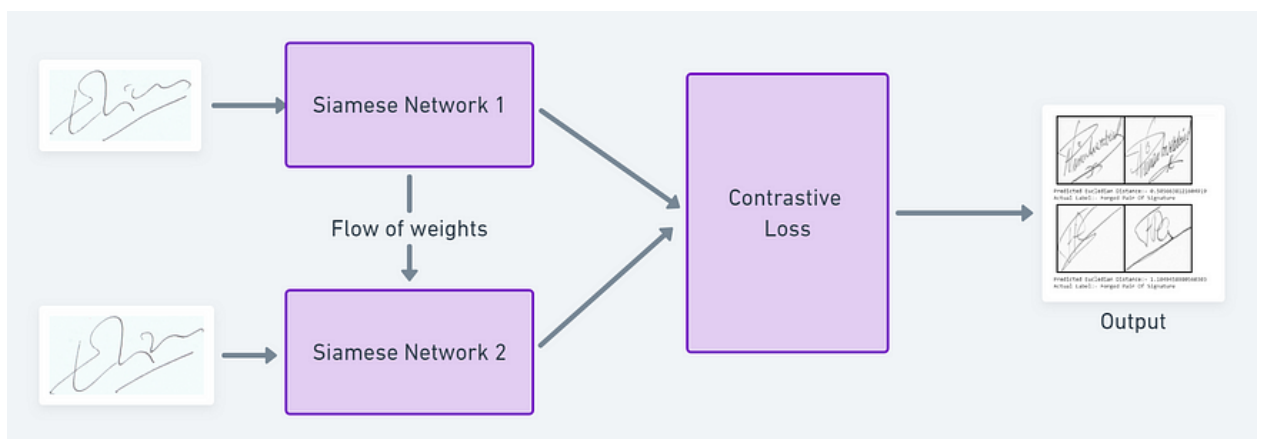


Рисунок 1.3 – Архітектура сіамської нейронної мережі

#### 1.1.4 Обґрунтування вибору методів для дослідження

Вибір методів Transfer Learning з Pretrained CNN, Prototypical Network та Siamese Networks для дослідження класифікації мисливських порід собак на зображеннях обґрунтований їх здатністю працювати з обмеженими наборами даних та ефективністю у задачах класифікації. Кожен з цих методів має свої особливості, що робить їх привабливими для порівняння та аналізу.

Перевага методу Transfer Learning з Pretrained CNN: можливість використовувати попередньо натреновані моделі дозволяє зекономити час на навчання та підвищити точність класифікації, оскільки моделі вже мають знання про загальні ознаки зображень. Це особливо корисно для задач класифікації порід собак, де доступ до великої кількості даних може бути обмежений.

Перевага Prototypical Network: цей метод дозволяє навчати моделі класифікації на основі обчислення відстаней між векторами ознак, що робить його ефективним для задач з малою кількістю прикладів. Зокрема, він допомагає правильно класифікувати нові зображення, порівнюючи їх з прототипами, що є важливим для класифікації мисливських порід собак, коли кожна порода може бути представлена лише кількома зображеннями.

Перевага Siamese Networks: використання сіамських мереж для навчання з одного або з малої кількості прикладів дозволяє порівнювати зображення та визначати їхню схожість, що є корисним для ідентифікації собак за обмеженими даними. Цей підхід дозволяє моделі навчатися розрізняти породи на основі наявних зображень, що робить його особливо ефективним для класифікації мисливських порід.

Порівняння результатів, отриманих за допомогою кожного з методів, дозволить зробити висновки щодо їх переваг та недоліків, а також виявити найефективніший підхід для цієї задачі.

Статистичні дані щодо застосування методів класифікації об'єктів на зображенні для навчання із малою кількістю еталонних прикладів зображено на рисунку 1.4.



Рисунок 1.4 – Статистичні дані щодо застосування методів класифікації зображень для малої кількості прикладів

1.2 Аналіз літературних джерел щодо апробації результатів застосування методів класифікації об'єктів на зображеннях, зокрема, тварин

Для кращого рівня обізнаності даної теми було проведено дослідження наукового матеріалу. У цьому підрозділі наведено результати дослідження літературних джерел, що стосуються методів розпізнавання об'єктів на зображеннях, зокрема, тварин.

У статті [8] представлено спробу створення класифікатора порід собак на основі сучасних підходів машинного навчання. Автори використовували різні методи, щоб підвищити точність класифікації, приділяючи особливу увагу архітектурі нейронних мереж та підходам до попередньої обробки даних. Ключовим аспектом роботи є акцент на ефективності й точності класифікації, що досягається за рахунок оптимізації моделей.

Однак, незважаючи на ці переваги, робота має декілька значних недоліків. Один із головних – це обмеження в можливостях моделі щодо роботи з великими обсягами даних та різноманітними породами. Незважаючи на використання потужних алгоритмів, автори не змогли належним чином адаптувати свою систему до класифікації менш

розповсюджених або рідкісних порід собак, що обмежує практичну цінність розробленого класифікатора. Це є важливим недоліком, оскільки реальне застосування системи вимагатиме вміння працювати з усіма породами собак, включаючи ті, що нечасто зустрічаються.

Крім того, підхід, використаний авторами, значно залежить від якості даних, що вводяться в систему, і цей аспект не було належним чином враховано в дослідженні. У роботі відсутній детальний аналіз того, як система реагує на шумові дані або дані з низькою якістю, що є важливим для реальних умов використання. Це може призвести до того, що класифікатор демонструватиме низьку точність у ситуаціях, де ідеальні умови не забезпечені.

Ще одним аспектом, який варто зазначити, є те, що автори не зосередилися на забезпеченні масштабованості своєї системи. Класифікатор, розроблений у межах дослідження, може мати труднощі з адаптацією до нових порід або з інтеграцією нових функцій [9] без значної модифікації архітектури моделі. Це робить систему менш гнучкою і придатною для розширення в майбутньому.

Нарешті, автори не надали достатньо уваги питанню оптимізації продуктивності свого класифікатора на різних апаратних платформах. У роботі не було розглянуто, як система поводить себе на пристроях із обмеженими ресурсами, що є важливим для її широкого впровадження. Ця відсутність уваги до питань оптимізації може обмежити можливість використання класифікатора на мобільних пристроях або інших середовищах з низькою продуктивністю.

Загалом, хоча робота робить значний внесок у галузь класифікації порід собак, її недоліки, зокрема обмежені можливості щодо рідкісних порід, недостатня увага до якості даних та проблеми з масштабованістю і продуктивністю, значно знижують її практичну цінність і вимагають подальших досліджень та вдосконалень.

У роботі [5] було представлено концепцію, що стосується навчання з малими наборами даних методом Prototypical Network, з акцентом на реалізацію нового підходу до класифікації з використанням прототипів. Основна мета дослідження полягала в розробці ефективного методу для роботи з невеликою кількістю прикладів на клас, зокрема в умовах, коли традиційні методи навчання не можуть бути застосовані через брак даних [10].

Автори провели експерименти на декількох популярних наборах даних, таких як Omniglot і MiniImageNet, щоб продемонструвати ефективність своєї методики. Результати показали, що Prototypical Networks досягають високої точності у класифікації, перевершуючи ряд інших сучасних методів на момент публікації. Це свідчить про потенціал використання їхнього підходу в реальних сценаріях, де отримання великої кількості мічених даних є складним завданням.

Prototypical Networks, як зазначається в дослідженні [11], вже зарекомендували себе як потужний інструмент у задачах із навчанням на малій кількості прикладів завдяки своїй здатності формувати прототипи класів на основі обмежених даних. Упровадження самонавчальних методів у SSL-ProtoNet відкриває нові можливості для подальшого розвитку цієї архітектури, зокрема в контексті генерації більш гнучких і стійких до шуму представлень.

Автори продемонстрували, як застосування самонавчальних технік може забезпечити більш ефективне представлення ознак, що в свою чергу підвищує точність класифікації в умовах обмежених даних. Дослідження показало, що метод SSL-ProtoNet здатний генерувати більш репрезентативні прототипи для кожного класу, що веде до покращення загальної продуктивності в задачах класифікації.

Експерименти, проведені на різних наборах даних, таких як MiniImageNet, підтвердили ефективність Prototypical Network, виявивши, що він перевершує традиційні прототипічні мережі за різними метриками.

Авторами було відзначено, що їхній підхід дозволяє досягти вищих показників точності навіть у випадках, коли навчальні дані є значно обмеженими.

У роботі [12] досліджується застосування глибоких моделей навчання для системи розпізнавання порід собак. Основна мета дослідження полягала у створенні високоефективної системи, яка б могла точно ідентифікувати породи собак на основі зображень, використовуючи сучасні алгоритми глибокого навчання. Автори обрали саме цей підхід через його потенціал у розв'язанні складних завдань розпізнавання зображень, які важко вирішити традиційними методами комп'ютерного зору.

У роботі детально розглядаються різні архітектури згорткових нейронних мереж [13], які використовувалися для навчання системи. Зокрема, автори експериментували з кількома варіантами CNN, оптимізуючи їх для досягнення найвищої точності розпізнавання. Результати дослідження показали, що глибокі моделі навчання можуть досягати високих показників точності в задачах класифікації порід собак, особливо коли системи навчаються на великих наборах даних.

Перевагами цієї роботи є використання сучасних методів глибокого навчання, які забезпечують високу точність і здатність до обробки складних і різноманітних зображень. Автори також підкреслюють важливість підбору та попередньої обробки даних, що значно впливає на ефективність системи.

Однак робота також має ряд обмежень. По-перше, глибокі моделі навчання вимагають значних обчислювальних ресурсів, що може бути проблемою при їхньому використанні на менш потужному обладнанні. Крім того, процес навчання таких моделей є тривалим і складним, що вимагає наявності великого обсягу високоякісних даних. Ще однією важливою проблемою є схильність до перенавчання, особливо якщо модель навчалася на обмеженому наборі даних, що може призвести до погіршення результатів на нових, невідомих зображеннях.

Можливість розпізнавання порід собак з використанням сучасних моделей глибокого навчання, зокрема YOLO та CNN розглянуто у дослідженні [14]. Автори прагнули створити ефективну систему, здатну ідентифікувати породи собак з високою точністю і швидкістю, комбінуючи потужність YOLO для швидкого виявлення об'єктів із додатковими можливостями оптимізації через алгоритм Whale Optimization Algorithm (WOA) у рамках згорткової нейронної мережі.

Однією з основних переваг роботи є інтеграція методів, що дозволяють підвищити точність розпізнавання, особливо на складних зображеннях із низькою якістю або частковою видимістю об'єктів.

Проте робота має суттєві недоліки. Одним із найбільших викликів є складність у налаштуванні й оптимізації моделей. Комбінація YOLO з WOA-CNN може потребувати значних обчислювальних ресурсів, що обмежує її застосування на менш потужних платформах. Крім того, інтеграція таких методів може призвести до складності в налаштуванні параметрів моделі, що, в свою чергу, підвищує ризик перенавчання або, навпаки, недонавчання моделі.

Ще одним недоліком є залежність від якості даних, на яких навчалася модель. У роботі не було належним чином висвітлено питання щодо збалансованості та різноманітності використаних наборів даних. Це може призвести до того, що модель погано працюватиме з новими зображеннями, особливо якщо вони сильно відрізняються від тих, на яких модель була навчена. Відсутність аналізу щодо потенційних проблем з генералізацією результатів на інші породи або умови зйомки також є слабким місцем цього дослідження.

Таким чином, хоча робота демонструє потенціал для підвищення точності та швидкості класифікації порід собак за допомогою сучасних моделей глибокого навчання, її недоліки, такі як складність оптимізації, високі вимоги до ресурсів та проблеми з генералізацією, значно обмежують її практичне застосування.

Дослідники роботи [15] розглянули підхід до класифікації порід собак, який поєднує аналіз зображень із метаданими, використовуючи методи машинного навчання. Основна мета роботи полягала в тому, щоб створити точну та ефективну систему класифікації порід собак, яка б поєднувала візуальні характеристики з іншими типами даних, такими як вік, вага та інші атрибути тварин.

Однією з переваг роботи є застосування мультифункціонального підходу, що включає не лише аналіз зображень, але й використання додаткової інформації для покращення результатів класифікації. Це дозволило дослідникам досягти високої точності у визначенні порід собак, особливо в тих випадках, коли одних лише візуальних характеристик було недостатньо для точної класифікації.

Проте, робота має низку обмежень. По-перше, використані методи машинного навчання, хоч і продемонстрували добрі результати, все ще не оптимізовані для реального часу і можуть вимагати значних обчислювальних ресурсів. Крім того, дослідження не повною мірою враховує можливість зміни якості зображень через різні фактори, такі як освітлення чи кут зйомки, що може негативно впливати на точність класифікації.

Щодо методів комп'ютерного зору, у дослідженні було використано кілька базових алгоритмів для обробки зображень. Відсутність глибокого навчання та складних моделей нейронних мереж, таких як згорткові нейронні мережі, обмежує можливості роботи з великими та складними наборами даних.

Узагальнюючи, робота демонструє перспективний підхід до класифікації порід собак, однак має ряд технічних недоліків, які можна було б усунути за допомогою більш сучасних методів класифікації зображень. Це підкреслює необхідність використання більш спеціалізованих методів, які могли б забезпечити високу точність класифікації.

У роботі [16] досліджують застосування штучного інтелекту для передбачення типів особистості у собак. Основна мета дослідження полягала

в розробці моделі, здатної аналізувати різноманітні аспекти поведінки собак та класифікувати їхні особистісні типи на основі даних, зібраних через різні сенсори та поведінкові параметри.

Дослідження використовує передові методи машинного навчання для обробки та аналізу даних [17]. Основною технікою є застосування глибоких нейронних мереж (DNN), які дозволяють моделі вчитися на великій кількості даних та визначати складні закономірності, які не завжди очевидні при традиційному аналізі. Автори також застосовують методи обробки природної мови (NLP) для аналізу текстових описів поведінки собак, що дозволяє створити комплексну картину особистісних характеристик.

Однією з основних переваг роботи є її інноваційний підхід до аналізу особистості собак за допомогою штучного інтелекту. Включення великих наборів даних та використання глибоких нейронних мереж дозволяє досягти високого рівня точності у прогнозуванні особистісних типів.

Проте робота має і певні недоліки. По-перше, застосування глибоких нейронних мереж та обробки природної мови вимагало великої кількості даних для навчання моделі. Це може бути проблемою, якщо якість або кількість доступних даних є недостатньою або ненадійною. Відсутність достатньо репрезентативних даних може призвести до того, що модель буде недостатньо узагальненою і менш точна при класифікації нових, невідомих даних.

Крім того, висока складність нейронних мереж часто пов'язана з необхідністю значних обчислювальних ресурсів. Це може стати перешкодою для розгортання системи на менш потужних пристроях або в умовах обмежених ресурсів. Також, незважаючи на те що модель показує добрі результати, її застосування в реальних умовах може бути ускладнене через потребу у великій кількості обчислень і часу на навчання.

У дослідженні [18] автори розглядають підходи до класифікації емоцій домашніх собак на основі комп'ютерного зору. Використані методи аналізують як обличчя, так і тіло тварини для визначення емоційного стану.

Однією з основних переваг є те, що дослідження використовує комплексний підхід, який дозволяє враховувати різні аспекти зовнішності собак. Це може підвищити точність розпізнавання емоцій у порівнянні з методами, що фокусуються лише на одній частині тіла. Однак, робота має суттєві недоліки. По-перше, обробка даних, що стосуються обличчя та тіла, може бути обчислювально витратною, що ускладнює використання системи на менш потужних пристроях. По-друге, дослідження не приділяє достатньо уваги проблемам загальної адаптації системи до різних порід і розмірів собак, що може обмежити її універсальність у реальних умовах. Ці аспекти підкреслюють необхідність подальших удосконалень у методах класифікації емоцій домашніх собак.

Автори роботи [19] розробили систему розпізнавання порід котів та визначення їхніх емоцій на основі аналізу зображень. У дослідженні застосовано сучасні методи комп'ютерного зору, включаючи YOLO, згорткові нейронні мережі (CNN) та алгоритм Sanny для виявлення країв, що забезпечує комплексний підхід до вирішення завдань класифікації порід та аналізу емоційного стану котів.

Основна перевага роботи полягає у поєднанні декількох методів для досягнення високої точності розпізнавання та класифікації. Використання YOLO дозволяє здійснювати швидке та ефективно виявлення об'єктів на зображеннях у реальному часі, що робить систему придатною для використання в умовах, де потрібна оперативність. CNN, у свою чергу, забезпечує глибоке навчання, дозволяючи моделі краще розпізнавати складні візуальні патерни, які є характерними для різних порід котів. Алгоритм Sanny для виявлення країв додає системі точності, дозволяючи краще виділяти контури об'єктів, що покращує якість класифікації та аналізу емоційного стану.

Однак, робота має і ряд недоліків. По-перше, хоча поєднання методів, використаних у дослідженні, є ефективним, воно може призводити до збільшення обчислювальної складності системи. Використання YOLO в

поєднанні з CNN вимагає значних обчислювальних ресурсів, особливо якщо система працює з великою кількістю даних або в умовах реального часу. Це може стати перешкодою для застосування системи на менш потужних пристроях або в умовах обмежених ресурсів.

Крім того, алгоритм Sanny, хоча і добре підходить для виявлення країв, має свої обмеження. Він чутливий до шуму та якості зображень, що може впливати на точність роботи системи у випадках, коли зображення мають низьку роздільну здатність або містять артефакти. Це може призвести до помилок у класифікації порід та визначенні емоцій, особливо коли мова йде про схожі породи.

У роботі [20] представлено новий підхід до виявлення і локалізації зниклих видів тварин з використанням моделі YOLO. Автори зосереджені на розробці системи, яка здатна ефективно і точно виявляти загрозливі види диких тварин у складних екологічних умовах.

Основною перевагою є вдосконалення точності [21] і швидкості локалізації об'єктів, що критично важливо для охорони природи. Однак, система орієнтована на специфічні умови і не враховує широкий спектр можливих варіантів освітлення і фону, що може обмежити її застосовність у різних середовищах. Крім того, робота не приділяє достатньої уваги можливості масштабування та адаптації моделі для інших типів об'єктів, що є важливим для її використання у більш широких екологічних дослідженнях.

Одним із ключових аспектів роботи [22] є використання згорткових нейронних мереж (CNN) для класифікації тварин. Хоча цей підхід забезпечує високу точність та дозволяє ефективно ідентифікувати різні види тварин, зокрема собак, у системи є певні недоліки, що обмежують її універсальність та ефективність у практичних умовах.

По-перше, розроблений мобільний застосунок орієнтований на загальне розпізнавання загублених тварин, а не на розпізнавання конкретних порід собак. Це знижує його ефективність у ситуаціях, коли необхідно

відрізнити одну породу від іншої, особливо якщо йдеться про схожі між собою породи.

По-друге, робота, незважаючи на використання сучасних методів комп'ютерного зору, зосереджена виключно на мобільних пристроях. Хоча мобільні застосунки є зручними та доступними для широкого кола користувачів, вони мають обмежені обчислювальні ресурси порівняно з десктопними системами. Це може негативно вплинути на швидкість та точність роботи застосунку.

Крім того, ще одним важливим аспектом, який не отримав достатньої уваги у роботі, є питання адаптації розробленої системи до різних умов експлуатації. Наприклад, зміни освітлення, різні кути зйомки, часткове перекриття об'єктів – усе це може впливати на якість класифікації, особливо у випадку з подібними породами собак.

Робота [23] спрямована на розробку та впровадження методів розпізнавання порід котів у програмній системі обліку домашніх тварин, що є важливим кроком у автоматизації процесу ідентифікації тварин. Використання методів комп'ютерного зору, таких як HOG для виділення ключових ознак зображень і SVM для класифікації порід, дозволило створити систему, яка здатна точно розпізнавати різні породи котів.

Однією з головних переваг роботи є інтеграція розроблених методів у програмну систему, що дозволяє зручно використовувати їх у реальних умовах, наприклад, у ветеринарних клініках або притулках для тварин. Це значно полегшує процес обліку та ідентифікації домашніх тварин, роблячи його більш ефективним та менш залежним від людського фактору.

Застосування методу HOG для виділення ознак зображень є ефективним рішенням, оскільки він дозволяє виділити ключові деталі, які є характерними для різних порід котів. Це, в свою чергу, підвищує точність класифікації та зменшує ймовірність помилок, що є важливим фактором у контексті системи, призначеної для обліку тварин.

Метод SVM, використаний для класифікації порід, також демонструє високу ефективність у вирішенні задачі класифікації. Цей підхід дозволяє точно відрізнити різні породи, навіть коли межі між ними є тонкими. Використання SVM у роботі забезпечує високу точність класифікації, що є особливо важливим для ідентифікації рідкісних або схожих порід котів.

Крім того, розробка системи, що інтегрує ці методи, забезпечує її зручність у використанні, що робить її привабливим рішенням для широкого кола користувачів. Це позитивно впливає на швидкість та ефективність роботи з даними [24], знижує ймовірність людських помилок та підвищує загальну продуктивність системи.

Таким чином, робота робить важливий внесок у розвиток технологій розпізнавання тварин, демонструючи, що методи HOG та SVM є ефективним підходами до розв'язання задачі класифікації тварин. Ця робота підкреслює можливість застосування розроблених методів у реальних умовах, що робить її актуальною та корисною для подальших досліджень і розробок у цій галузі.

У дослідженні [25] основну увагу приділено оцінці емоційних виразів собак і людей. Із технічної точки зору, автори використали методи комп'ютерного зору для аналізу зображень собак і людей, що демонструють різні емоційні стани. Основна мета дослідження полягала в тому, щоб зрозуміти, як досвід і вік впливають на здатність розпізнавати ці стани.

Однією з ключових переваг роботи є застосування автоматизованого аналізу зображень, що дозволило дослідникам ефективно обробляти та аналізувати великі обсяги даних. Проте використані методи розпізнавання мали обмежену складність, що не дозволяло повною мірою врахувати всі можливі варіації у зображеннях, особливо при роботі зі складними і неоднозначними емоційними виразами.

Крім того, у роботі не було приділено достатньої уваги оптимізації процесу обробки зображень для забезпечення максимальної точності розпізнавання. Методологія дослідження могла б бути значно покращена за

рахунок використання сучасних методів глибокого навчання, таких як CNN [26]. Це дозволило б підвищити ефективність і точність аналізу.

Використання лише статичних зображень також обмежило можливості роботи, оскільки реальні сценарії можуть вимагати врахування динамічних факторів, таких як рухи або зміни в освітленні.

Таким чином, хоча робота надає цінний внесок у розуміння того, як діти та дорослі сприймають емоції, з інформативної точки зору, дослідження має ряд обмежень, які можна було б усунути за допомогою більш передових методів комп'ютерного зору.

Робота [27] присвячена розробці та дослідженню методу ідентифікації порід котів за їх зображеннями, що є важливим кроком у розвитку технологій комп'ютерного зору та машинного навчання. Одним із головних досягнень дослідження є використання багат шарових нейронних мереж для класифікації зображень, що дозволило досягти досить високої точності розпізнавання різних порід котів. Проте, незважаючи на певні переваги, робота має ряд обмежень, які слід враховувати при розробці подібних систем.

Варто зазначити, що дослідження орієнтоване на класифікацію порід котів, що, безумовно, є специфічною задачею, але не охоплює ширшого спектра задач розпізнавання інших тварин, таких як собаки, зокрема мисливські породи, де розрізнення може бути складнішим через схожість між різними породами. Використання багат шарових нейронних мереж є ефективним інструментом для класифікації зображень [28], однак даний підхід має певні обмеження, особливо коли йдеться про розпізнавання менш поширених або специфічних порід тварин. Ця проблема стає особливо помітною, коли мова йде про ідентифікацію тварин у різних умовах, наприклад, при поганому освітленні, з частковим перекриттям об'єктів або при наявності подібних візуальних характеристик у різних порід.

Значний акцент зроблено на використанні великої кількості даних для тренування моделі, що, безумовно, є позитивним аспектом. Проте,

залишається відкритим питання, наскільки ефективною буде система в умовах обмеженого доступу до великої кількості високоякісних даних. Це особливо важливо в реальних умовах, де може бути складно зібрати достатню кількість зображень для тренування моделей, особливо для рідкісних порід котів або собак. Таким чином, робота не враховує можливість використання меншого обсягу даних або застосування методів, які могли б забезпечити ефективну роботу в таких умовах.

У статті [29] автори детально аналізують методіку Siamese Networks у контексті навчання з малими наборами даних. Дослідження зосереджене на поясненні механізмів, що лежать в основі цієї архітектури, та її застосуванні в задачах, де обмежена кількість навчальних зразків представляє значні труднощі для традиційних підходів до класифікації [30].

Метод Siamese Networks базується на структурі, що складається з двох ідентичних підмереж, які беруть на вхід пари зразків. Основна мета полягає в тому, щоб навчити модель розрізняти, чи належать обидва зразки до одного класу чи ні, шляхом мінімізації відстані між їхніми векторами ознак.

Автори роботи [31] досліджують, як використання ансамблів, у поєднанні з Siamese Networks, може покращити здатність моделі до узагальнення та адаптації, особливо в задачах, де доступні лише кілька прикладів для кожного класу. У роботі аналізуються різні підходи до ансамблювання, такі як поєднання кількох Siamese Networks або створення варіацій однієї мережі з різними налаштуваннями. Мета цих підходів полягає у тому, щоб покращити стабільність і точність класифікації [32], використовуючи сильні сторони кожної з окремих моделей в ансамблі.

Крім того, увага приділена навчанню ознак – процесу побудови більш ефективних і стійких представлень ознак зображень, щоб забезпечити точнішу класифікацію на основі декількох зразків. Автори досліджують різні способи оптимізації цього процесу в межах Siamese Networks, що дозволяє моделі краще визначати подібності та відмінності між класами з невеликою кількістю даних.

Отже, досліджено низку літературних джерел за темою класифікації об'єктів на зображеннях, підтверджено необхідність подальших досліджень у цій галузі з використанням сучасних технологій і методів комп'ютерного зору для досягнення більш точних і надійних результатів класифікації об'єктів на зображеннях.

### 1.3 Постановка задачі дослідження

Таким чином, класифікація мисливських порід собак на зображеннях є актуальним завданням. Прийнято рішення щодо розробки програмного застосунку класифікації мисливських порід собак на зображенні трьома методами, а саме із застосуванням Prototypical Network, Transfer Learning з Pretrained CNN та Siamese Networks.

Об'єктом дослідження є зображення мисливських порід собак.

Метою дослідження є порівняння методів розпізнавання зображень шляхом розробки застосунку, що класифікує мисливські породи собак на зображеннях із точністю у відсотковому значенні.

Для досягнення мети необхідно вирішити такі завдання:

- провести аналіз сучасних методів класифікації об'єктів на зображеннях;
- провести аналіз літературних джерел щодо апробації методів класифікації об'єктів на зображеннях;
- сформулювати покроковий алгоритм для кожного із вибраних методів класифікації об'єктів на зображеннях;
- візуалізувати покроковий алгоритм кожного із вибраних методів блок-схемою;
- розробити програмний застосунок, що надасть змогу класифікувати мисливські породи собак на зображеннях кожним із вибраних методів.

## 2 ОСОБЛИВОСТІ ВИБРАНИХ МЕТОДІВ КЛАСИФІКАЦІЇ ОБ'ЄКТІВ НА ЗОБРАЖЕННЯХ

2.1 Аналіз методу Prototypical Network для навчання з малою кількістю прикладів

### 2.1.1 Основна ідея методу Prototypical Network

Prototypical Networks є одним із сучасних підходів до розв'язання задачі класифікації в умовах обмежених даних, зокрема, в задачах, де доступно лише кілька навчальних прикладів для кожного класу. Цей метод базується на ідеї, що для кожного класу може бути створений прототип, який представляє собою «середнє» зображення всіх об'єктів цього класу.

Основна концепція прототипічних мереж полягає у тому, що замість того, щоб безпосередньо класифікувати об'єкти, мережа навчається створювати прототипи класів на основі представлених зразків. Прототипи є векторами виявлення ознак, що знаходяться в багатовимірному просторі ознак. Коли новий об'єкт потрібно класифікувати, його представлення також перетворюється в вектор ознак, після чого обчислюється відстань між цим вектором і прототипами всіх класів. Клас, прототип якого найближчий до вектора ознак об'єкта, буде визначено як прогнозований клас.

Однією з ключових особливостей прототипічних мереж є використання метрики відстані, наприклад, евклідової або косинусної відстані, для оцінки близькості між векторами ознак. Зазвичай, прототипи обчислюються шляхом взяття середнього значення векторів ознак всіх навчальних прикладів класу, що дозволяє згладити вплив випадкових помилок або аномалій в даних. Це робить прототипи більш стабільними і надійними для класифікації.

### 2.1.2 Алгоритм методу Prototypical Network

Алгоритм Prototypical Network для навчання з малою кількістю прикладів є потужним інструментом для класифікації зображень. Цей метод дозволяє класифікувати об'єкти, опираючись на обмежену кількість навчальних зразків для кожного класу. У цьому підпункті покроково описано алгоритм Prototypical Network:

#### Крок 1. Формування навчальних наборів.

Спочатку потрібно сформувати навчальні набори. У контексті навчання із малою кількістю даних, зазвичай, доступні два типи наборів: тренувальний набір і тестовий набір. Тренувальний набір містить  $N$  класів, кожен з яких представлений  $K$  зразками, тоді як тестовий набір включає один або кілька зразків з  $C$  класів, для яких потрібно зробити класифікацію.

Кількість класів та зразків розраховується як

$$N \cdot K, \quad (2.1)$$

де  $N$  – кількість класів;

$K$  – кількість зразків для кожного класу.

#### Крок 2. Формування навчальних наборів.

На другому кроці виконується попередня обробка зображень та витягнення ознак. Для цього використовується згортова нейронна мережа [33], яка перетворює вхідні зображення на вектори ознак.

Нехай  $f(x)$  – це функція, що відображає зображення  $x$  в простір ознак  $R^d$ , де  $d$  – кількість ознак.

Витягнення ознак відбувається за допомогою

$$z_i = f(x_i), \quad (2.2)$$

де  $z_i$  – вектор ознак для  $i$ -го зразка.

Крок 3. Обчислення прототипів класів.

Після витягнення ознак для кожного класу потрібно обчислити прототип. Прототип класу є середнім вектором ознак для всіх зразків цього класу. Нехай  $z_{ij}$  – це вектор ознак  $j$ -го зразка з класу  $i$ . Прототип  $p_i$  для класу  $i$  обчислюється як

$$p_i = \frac{1}{K} \sum_{j=1}^K z_{i,j}, \quad (2.3)$$

де  $K$  – кількість зразків у класі  $i$ .

Крок 4. Визначення відстаней.

На цьому етапі для кожного тестового зразка  $z_t$  потрібно обчислити відстань між вектором ознак тестового зразка і прототипами всіх класів. Зазвичай використовують евклідову відстань, яка визначається як

$$d(p_i, z_t) = \sqrt{\sum_{k=1}^d (p_{i,k} - z_{t,k})^2}, \quad (2.4)$$

де  $d$  – розмірність вектора ознак;

$p_{i,k}$  –  $k$ -та компонента прототипу класу  $i$ ;

$z_{t,k}$  –  $k$ -та компонента вектора ознак тестового зразка.

Крок 5. Класифікація.

На основі обчислених відстаней алгоритм визначає клас для тестового зразка. Клас обирається відповідно до прототипа, з яким тестовий зразок має найменшу відстань.

Класифікація визначається як

$$\hat{y} = \arg \min_i d(p_i, z_t), \quad (2.5)$$

де  $\hat{y}$  – прогнозований клас для тестового зразка.

Крок 6. Навчання моделі.

Під час навчання Prototypical Network використовує функцію втрат, що базується на крос-ентропії. Функція втрат враховує правильність класифікації тестових зразків.

Функція втрат розраховується як

$$L = - \sum_{t=1}^T \log \left( \frac{e^{-\alpha d(p_{y_t, z_t})}}{\sum_{j=1}^N e^{-\alpha d(p_{j, z_t})}} \right), \quad (2.6)$$

де  $T$  – кількість тестових зразків;

$y_t$  – правильний клас для  $t$ -го тестового зразка;

$\alpha$  – масштабуючий параметр, що контролює вплив відстані.

Крок 7. Оптимізація.

На цьому етапі алгоритму Prototypical Network відбувається процес налаштування ваг мережі для досягнення кращих результатів класифікації. Цей процес реалізується за допомогою алгоритму градієнтного спуску.

У першу чергу необхідно визначити, наскільки правильним було передбачення моделі. Для цього використовується функція втрат, яка обчислює різницю між передбаченими відстанями до прототипів класів і фактичними. В алгоритмі Prototypical Networks зазвичай використовується функція втрат на основі крос-ентропії, яка добре підходить для задач класифікації.

Формально, функція втрат для одного елемента тестового набору може бути записана як

$$L(\theta) = -\log \frac{\exp(-d(f_{\theta}(x_q), c_{y_q}))}{\sum_k \exp(-d(f_{\theta}(x_q), c_k))}, \quad (2.7)$$

де  $f_{\theta}(x_q)$  – це ознаки тестового зразка  $x_q$ , витягнуті за допомогою моделі з параметрами  $\theta$ ;

$c_{y_q}$  – це прототип класу, до якого належить зразок;

$d(f_{\theta}(x_q), c_{y_q})$  – це відстань між ознаками тестового зразка та прототипом;

$c_k$  – прототип класу  $k$ .

Граденти функції втрат обчислюються по відношенню до параметрів мережі (ваг). Для цього використовується метод зворотного поширення похибки (backpropagation), який дозволяє знайти похідні функції втрат по кожному параметру моделі. Ці граденти показують, у якому напрямку потрібно змінювати параметри мережі, щоб зменшити похибку.

Для кожної ваги мережі  $\theta_i$ , часткова похідна функції втрат визначається як

$$\frac{\partial L}{\partial \theta_i}. \quad (2.8)$$

Ці похідні вказують, як змінювати кожен параметр, щоб функція втрат зменшувалася найшвидше.

Після обчислення градієнтів параметри мережі оновлюються у напрямку, що зменшує функцію втрат. Це робиться за допомогою правила градієнтного спуску. Оновлення ваг відбувається таким чином

$$\theta_{i+1} = \theta_i - \alpha \frac{\partial L}{\partial \theta_i}, \quad (2.9)$$

де  $\theta_i$  – це параметри мережі на поточній ітерації;

$\alpha$  – це швидкість навчання, яка визначає, наскільки великими будуть кроки в напрямку градієнта.

Оптимізація відбувається ітеративно. На кожній ітерації обчислюються градієнти і оновлюються параметри мережі. Цей процес повторюється до тих пір, поки функція втрат не досягне мінімуму або інший критерій зупинки (наприклад, кількість ітерацій або зміна втрат між ітераціями) не буде виконаний.

Важливі моменти при оптимізації:

- швидкість навчання (якщо швидкість навчання занадто велика, модель може перестрибнути мінімум і не знайти оптимальні параметри. Якщо вона занадто мала, оптимізація буде дуже повільною);

- регуляризація (щоб уникнути перенавчання (overfitting), можуть використовуватися методи регуляризації, такі як L2-регуляризація або «відключення нейронів», які додають додаткові штрафи до функції втрат для складних моделей);

- адаптивні методи оптимізації (крім стандартного градієнтного спуску, можуть використовуватися адаптивні методи, такі як Adam, RMSprop, які динамічно змінюють швидкість навчання для кожного параметра в залежності від величини градієнта).

Оптимізація в Prototypical Network – це ключовий етап, що дозволяє мережі вивчити представлення класів, яке буде ефективним для класифікації нових зразків навіть при малій кількості тренувальних прикладів.

Покроковий алгоритм методу Prototypical Network продемонстровано на рисунку 2.1.

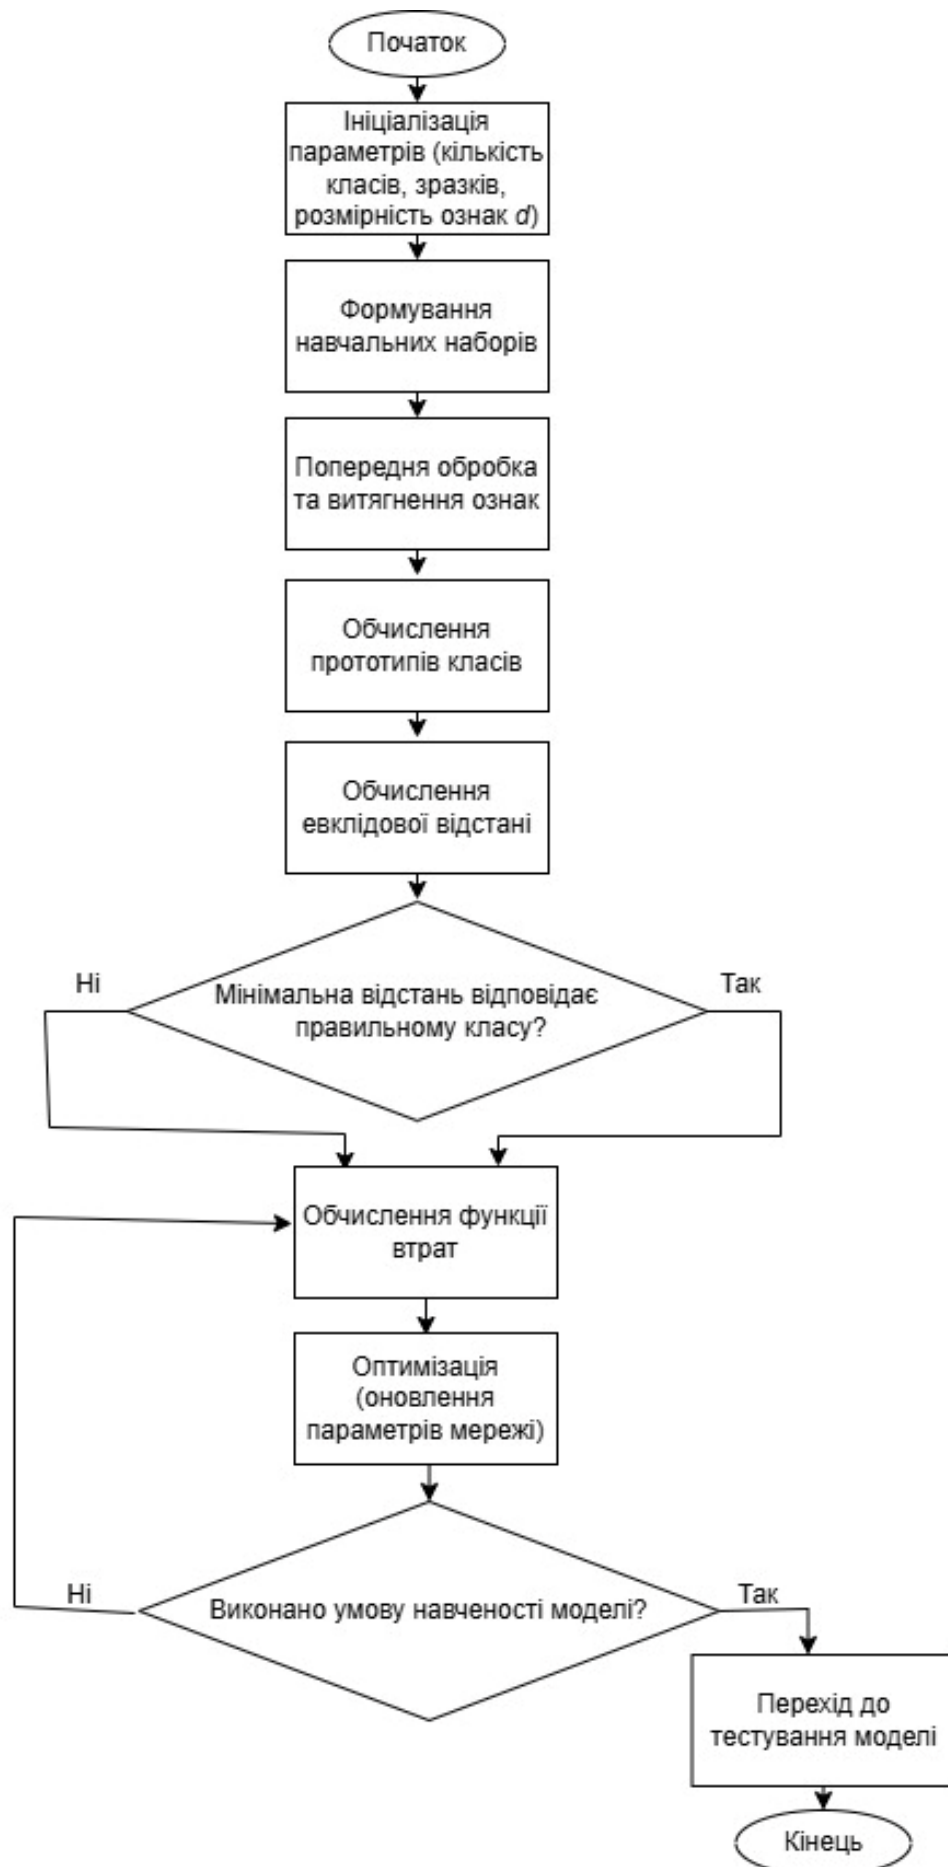


Рисунок 2.1 – Покроковий алгоритм методу Prototypical Network

## 2.2 Аналіз методу Transfer Learning з Pretrained CNN

### 2.2.1 Основна ідея методу Transfer Learning з Pretrained CNN

Основна концепція методу Transfer Learning з Pretrained CNN полягає в тому, що CNN (згорткова нейронна мережа), яка була попередньо навчена на великому наборі даних, уже здатна ефективно витягати загальні ознаки зображень, які є корисними для багатьох задач класифікації. При Transfer Learning переносяться якомога більше знань з попередньої задачі, на якій навчалася модель, на нову задачу, що стоїть перед нею (рис. 2.2) [34]. Ці знання можуть бути в різних формах, залежно від задачі та даних.

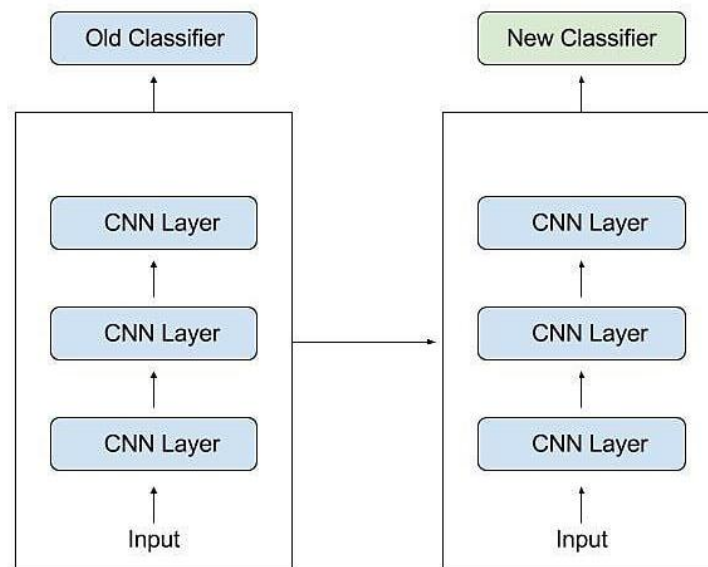


Рисунок 2.2 – Архітектура Transfer Learning з використанням попередньо навченої CNN

Наприклад, перші шари CNN вивчають низькорівневі ознаки зображень, такі як краї, текстури та контури, які є універсальними для багатьох типів об'єктів. Більш глибокі шари вивчають більш складні структури, такі як частини об'єктів або навіть цілі об'єкти. Завдяки цьому підходу можна використовувати попередньо навчені CNN як основу для розв'язання нових задач, таких як класифікація зображень мисливських порід собак, і донавчати останні шари моделі для конкретної задачі.

## 2.2.2 Алгоритм методу Transfer Learning з Pretrained CNN

Нижче наведено покроковий опис алгоритму трансферного навчання із використанням попередньо навченої CNN:

Крок 1. Вибір попередньо навченої моделі.

На першому етапі необхідно обрати модель CNN, яка вже була попередньо навчена на великому наборі даних, такому як ImageNet. ImageNet містить мільйони зображень і більше тисячі класів, що дозволяє моделям вивчати загальні ознаки об'єктів, такі як краї, контури, текстури.

Популярні моделі для трансферного навчання:

- VGG16/VGG19 – глибокі згорткові мережі, які відомі своєю простотою і хорошою продуктивністю на задачах класифікації;
- ResNet – мережа з пропускними зв'язками, яка дозволяє ефективніше тренувати глибокі моделі;
- Inception – мережа, яка використовує кілька різних розмірів фільтрів одночасно, що дозволяє краще захоплювати різні масштаби ознак на зображеннях.

Крок 2. Підготовка даних.

Перед тим, як модель можна буде використовувати, дані повинні бути підготовлені. Основні етапи підготовки включають:

- зміну розміру зображень. Всі зображення повинні бути перетворені до єдиного розміру, що відповідає входу моделі (наприклад, 224×224 пікселів для моделей ResNet або VGG);
- нормалізацію. Піксельні значення зазвичай масштабуються в діапазон від 0 до 1 або стандартизуються відповідно до середнього і стандартного відхилення набору даних, на якому була навчена модель.

Нормалізації піксельних значень визначається наступним чином

$$x_{norm} = \frac{x - \mu}{\sigma}, \quad (2.10)$$

де  $x$  – піксельне значення;

$\mu$  – середнє значення пікселів у тренувальному наборі;

$\sigma$  – стандартне відхилення.

Крок 3. Використання попередньо навчених ваг.

У трансферному навчанні попередньо навчені ваги використовуються як початкові параметри моделі. Оскільки мережі вже були навчені на великих наборах даних, вони здатні витягувати потужні ознаки навіть з нових зображень, які відрізняються від оригінальних.

Ці попередньо навчені ваги можна:

- заморозити (не змінювати під час навчання), що зменшує час тренування і обчислювальні витрати [35];
- розморозити певні шари або всі шари для донавчання на нових даних.

Крок 4. Додавання нового вихідного шару.

Оскільки вихідний шар попередньо навчених моделей призначений для певної кількості класів (наприклад, 1000 класів для ImageNet), його необхідно замінити на новий вихідний шар, відповідний до кількості класів у новій задачі.

Приклад заміни вихідного шару: якщо задача класифікації мисливських порід собак включає 10 різних порід, вихідний шар з 1000 класів замінюється на шар з 10 нейронами, кожен з яких відповідає одній з порід.

Нова активація вихідного шару розраховується як

$$a_i = \frac{\exp(z_i)}{\sum_{j=1}^{10} \exp(z_j)}, \quad (2.11)$$

де  $z_i$  – лінійне поєднання ознак для класу  $i$ ;

$a_i$  – ймовірність того, що зображення належить до класу  $i$  (softmax-функція).

Крок 5. Процес повного донавчання.

Після додавання нового вихідного шару виконується навчання моделі.

Є два підходи до навчання:

– навчання лише вихідного шару: усі попередні шари CNN залишаються замороженими, і лише новий вихідний шар тренується на нових даних. Цей підхід швидкий і підходить, коли нові дані схожі на ті, на яких навчалася оригінальна модель;

– повне донавчання: розморожуються певні шари або всі шари моделі, і вся модель тренується на нових даних. Цей підхід є більш складним і вимагає більше ресурсів, але дозволяє моделі краще адаптуватися до нової задачі.

Крок 6. Функція втрат.

Для класифікації зазвичай використовується функція втрат на основі крос-ентропії. Вона обчислює різницю між передбаченими ймовірностями та фактичними класами.

Функції втрат для одного зразка визначається як

$$L = - \sum_{i=1}^N y_i \log(\hat{y}_i), \quad (2.12)$$

де  $y_i$  – це реальний клас зразка;

$\hat{y}_i$  – передбачена ймовірність для цього класу.

Крок 7. Оптимізація.

Оптимізація виконується з використанням методів градієнтного спуску або його варіацій, таких як Adam або SGD. У процесі оптимізації мінімізується функція втрат, а ваги моделі коригуються для покращення точності класифікації.

Оновлення ваг у градієнтному спуску виглядає як

$$\theta_{t+1} = \theta_t - \alpha \nabla_{\theta} L, \quad (2.13)$$

де  $\theta_t$  – поточні параметри моделі;

$\alpha$  – швидкість навчання;

$\nabla_{\theta}L$  – градієнт функції втрат по відношенню до параметрів.

Крок 8. Оцінка моделі.

Після тренування модель перевіряється на тестових даних для оцінки її ефективності. Зазвичай використовуються такі метрики, як точність (accuracy), повнота (recall), точність (precision) і F1-міра для оцінки якості класифікації.

Точність визначається як

$$Accuracy = \frac{\text{Кількість правильних передбачень}}{\text{Загальна кількість зразків}}. \quad (2.14)$$

Отже, алгоритм Transfer Learning з Pretrained CNN дозволяє використовувати вже існуючі моделі для вирішення нових задач з меншою кількістю даних. Цей підхід особливо ефективний у випадках, коли збір великого набору даних є складним завданням, а також дозволяє значно скоротити час і ресурси, необхідні для навчання моделі з нуля.

Покроковий алгоритм методу Transfer Learning з Pretrained CNN продемонстровано на рисунку 2.3.

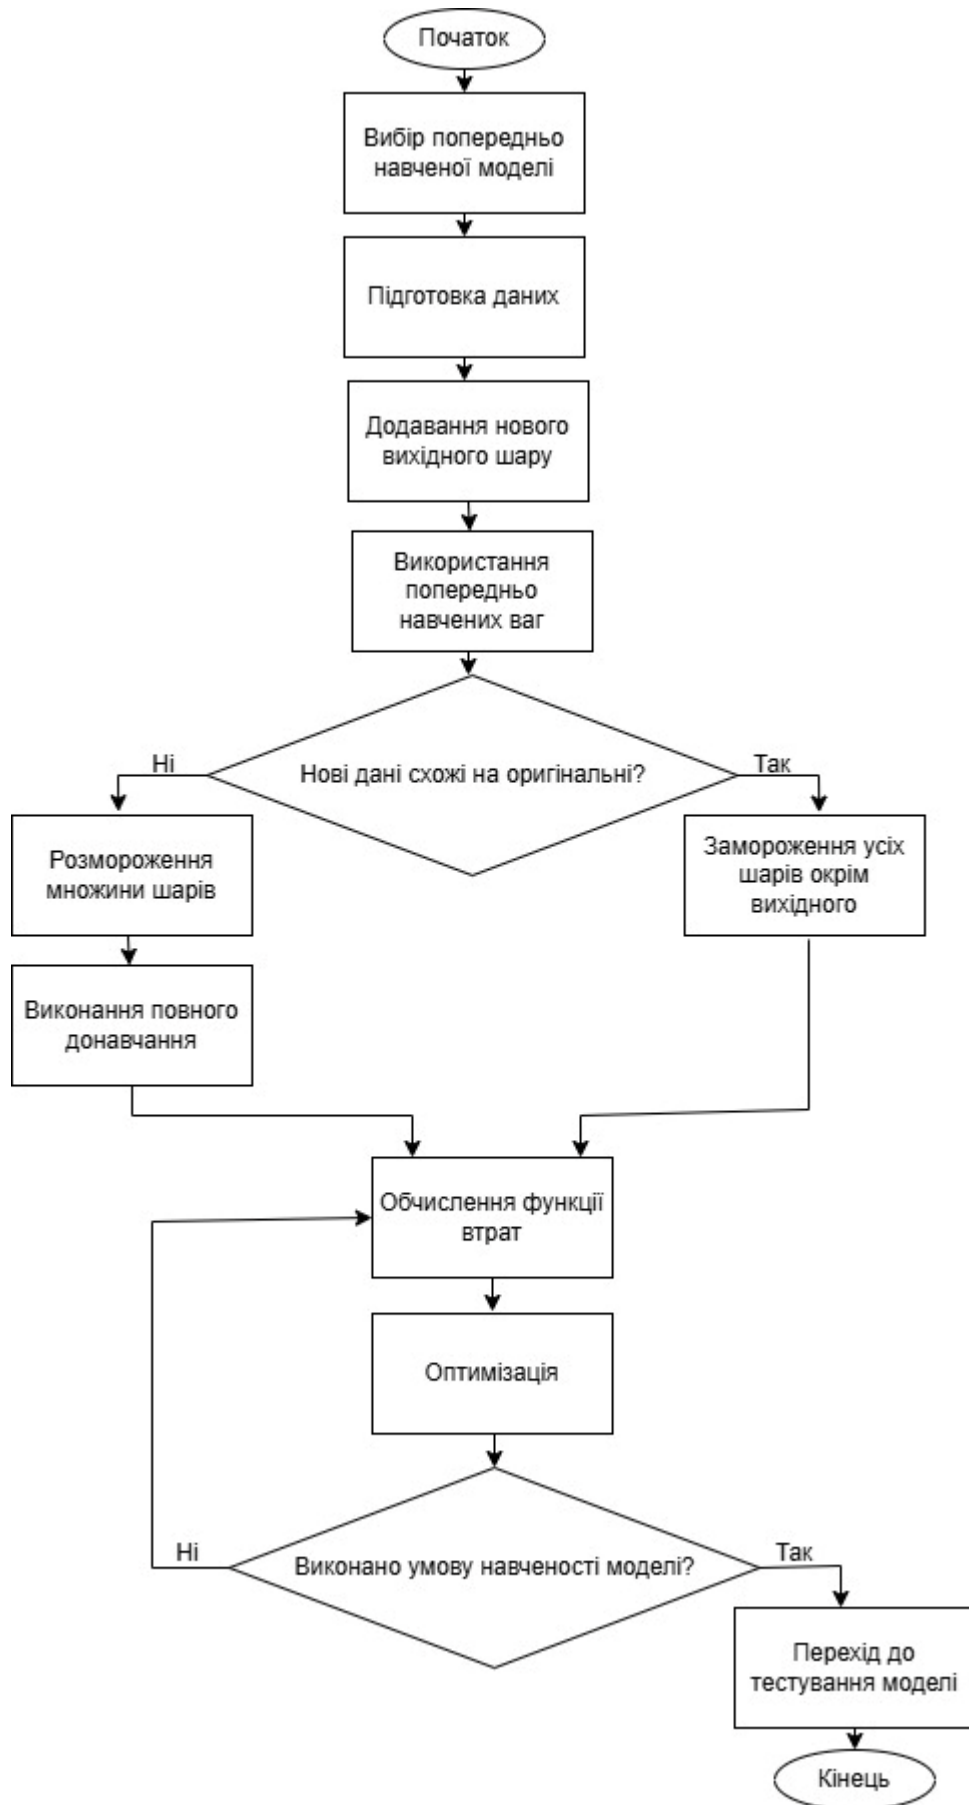


Рисунок 2.3 – Алгоритм методу Transfer Learning з Pretrained CNN

## 2.3 Аналіз методу Siamese Networks для навчання з малою кількістю прикладів

### 2.3.1 Основна ідея методу Siamese Networks

Метод Siamese Networks є ефективним підходом для розв'язання задачі навчання моделей у випадках, коли наявна мала кількість прикладів для кожного класу, що типово для задач навчання із малою кількістю прикладів. Основна ідея алгоритму полягає у тому, щоб навчити модель порівнювати дві вхідні одиниці даних (зображення, текст тощо) і визначати, чи належать вони до однієї категорії, чи до різних. Siamese Networks використовуються для обчислення подібності між двома об'єктами, замість класичної класифікації об'єктів в одну з декількох категорій.

На відміну від звичайних нейронних мереж, які навчаються класифікувати об'єкти в заздалегідь визначені категорії, Siamese Networks мають архітектуру з двома паралельними підмережами, що працюють з двома різними вхідними даними одночасно. Обидві підмережі мають однакову архітектуру та спільні ваги, що дозволяє їм генерувати однакові векторні уявлення для об'єктів з однієї категорії. Завдяки цьому мережа навчається порівнювати дві вхідні одиниці даних і оцінювати їх схожість, що дозволяє їй виконувати задачі порівняння навіть при наявності малої кількості тренувальних прикладів.

Основною функцією Siamese Networks є здатність вивчати функцію подібності між двома об'єктами. Це означає, що замість того, щоб прямо класифікувати об'єкти, мережа обчислює відстань між двома векторами ознак, отриманих з двох вхідних даних, і використовує цю відстань для визначення подібності між ними. Якщо відстань між векторами ознак двох зображень невелика, об'єкти вважаються подібними (належать до однієї категорії), і навпаки.

### 2.3.2 Алгоритм методу Siamese Networks

Детальний покроковий опис алгоритму Siamese Networks для навчання з малою кількістю прикладів:

Крок 1. Ініціалізація.

Мережа складається з двох ідентичних підмереж, які мають спільні ваги. Кожна з підмереж обробляє одне з двох зображень, поданих на вхід, і витягує з них ознаки. Це означає, що підмережі мають однакову архітектуру та спільні параметри. Нехай  $f(x)$  – це функція, що представляє виведення ознак для зображення  $x$ .

Крок 2. Підготовка пари зображень.

Для навчання моделі формується набір пар зображень. Кожна пара складається або з двох зображень однієї категорії (позитивна пара), або зображень різних категорій (негативна пара). Позначимо перше зображення як  $x_1$ , а друге як  $x_2$ . Відповідно, пара  $(x_1, x_2)$  може бути або позитивною, або негативною.

Крок 3. Витягнення ознак.

Кожне зображення подається до підмережі. Підмережі виконують екстракцію ознак для кожного зображення. Виведення ознак для зображення  $x_1$  позначається як  $f(x_1)$ , а для зображення  $x_2$  як  $f(x_2)$

$$f(x_1) = CNN(x_1), \quad (2.15)$$

$$f(x_2) = CNN(x_2). \quad (2.16)$$

Крок 4. Обчислення евклідової відстані.

Для порівняння зображень використовується відстань між векторами ознак  $f(x_1)$  та  $f(x_2)$ . Найчастіше застосовується евклідова відстань для обчислення різниці між двома векторами. Евклідова відстань визначається як

$$d(f(x_1), f(x_2)) = \sqrt{\sum_{i=1}^n (f_i(x_1) - f_i(x_2))^2}, \quad (2.17)$$

де  $f_i(x_1)$  і  $f_i(x_2)$  – це компоненти векторів ознак для зображень  $x_1$  і  $x_2$ ;

$n$  – розмірність векторів ознак.

Крок 5. Функція втрат.

Мета полягає у тому, щоб навчити мережу правильно визначати, чи належать два зображення до однієї категорії на основі відстані між ними. Для цього використовується спеціальна функція втрат – контрастивна функція втрат. Вона спрямована на те, щоб мінімізувати відстань між векторами ознак позитивних пар і максимізувати відстань для негативних пар.

Контрастивна функція втрат виглядає наступним чином

$$L(Y, d) = Y \cdot \frac{1}{2} d^2 + (1 - Y) \cdot \frac{1}{2} \max(0, m - d)^2, \quad (2.18)$$

де  $Y$  – це мітка, що позначає, чи є пара позитивною ( $Y=1$ ) або негативною ( $Y=0$ );

$d$  – евклідова відстань між векторами ознак;

$m$  – це маржа (порогове значення), що визначає мінімальну відстань для негативних пар.

Контрастивна функція втрат намагається зменшити відстань для позитивних пар і гарантувати, що відстань для негативних пар не менша за значення маржі  $m$ .

Крок 6. Оновлення параметрів мережі.

Після обчислення втрат модель оновлює свої параметри (ваги підмереж) за допомогою алгоритму градієнтного спуску або одного з його варіантів, таких як Adam чи RMSprop. Обчислюються похідні функції втрат за кожним із параметрів моделі, і ваги оновлюються відповідно

$$W_{new} = W_{old} - \alpha \cdot \frac{\partial L}{\partial w}, \quad (2.19)$$

де  $w$  – ваги моделі;

$\alpha$  – це швидкість навчання;

$L$  – функція втрат.

Крок 7. Оцінка подібності та класифікація.

На етапі класифікації мережа отримує нову пару зображень і використовує навчені параметри для обчислення відстані між ними. Якщо відстань  $d$  менша за деякий поріг, зображення вважаються такими, що належать до однієї категорії. У іншому випадку вони належать до різних категорій.

Крок 8. Навчання на малій кількості еталонних прикладів.

Коли у розпорядженні є дуже мала кількість прикладів для навчання (наприклад, лише один або кілька прикладів для нової категорії), модель використовує вже навчену на попередніх парах функцію для порівняння з новими прикладами. Модель оцінює подібність нових зображень до вже наявних категорій шляхом обчислення відстані між векторами ознак.

Алгоритм Siamese Networks є одним із ключових методів для розв'язання задач, де мало тренувальних даних, і особливо добре підходить для класифікації нових категорій об'єктів, таких як мисливські породи собак, маючи лише декілька прикладів кожної породи.

Покроковий алгоритм методу Siamese Networks продемонстровано на рисунку 2.4.

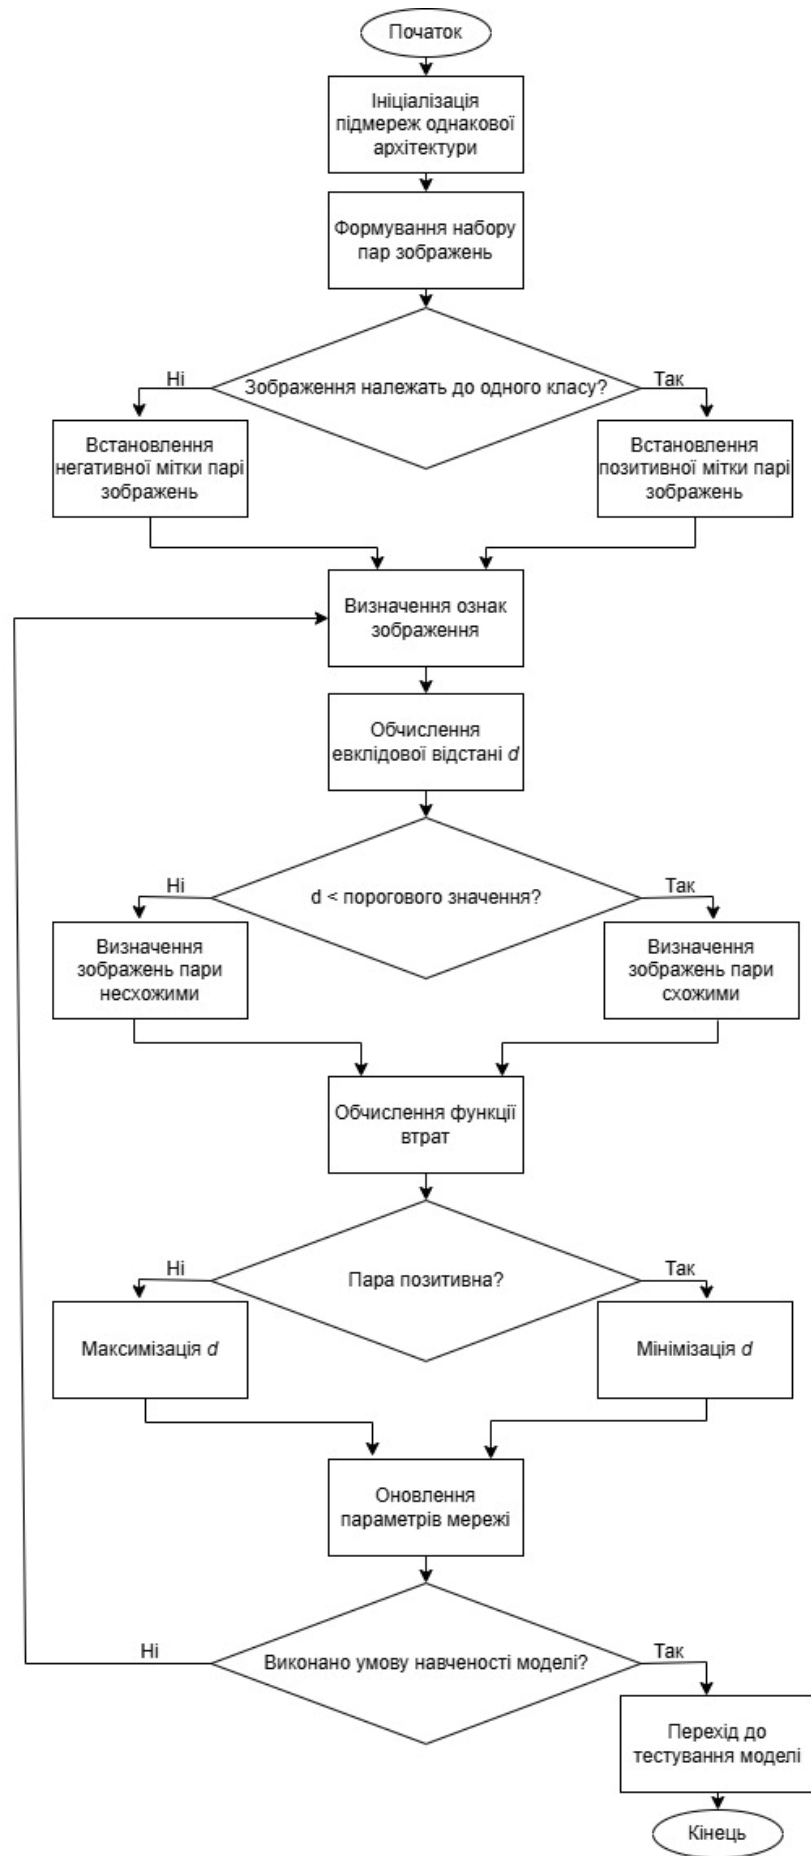


Рисунок 2.4 – Алгоритм методу Siamese Networks

### 3 ДОСЛІДЖЕННЯ ТА ПОРІВНЯННЯ МЕТОДІВ КЛАСИФІКАЦІЇ МИСЛИВСЬКИХ ПОРІД СОБАК НА ЗОБРАЖЕННЯХ

#### 3.1 Вибір інструментальних засобів для реалізації вибраних методів

Для задачі класифікації мисливських порід собак на зображеннях було обрано три методи – Prototypical Network, Transfer Learning з використанням попередньо навчених CNN, та Siamese Networks.

Усі три методи реалізовано мовою Python 3.12.4, яка є одною із найпопулярніших мов програмування для роботи з машинним навчанням завдяки широкому спектру бібліотек.

У якості IDE (інтегрованого середовища розробки) було обрано Spyder. Spyder підходить для прикладних задач, пов'язаних з аналізом візуальної інформації, обробкою зображень та використанням методів машинного навчання в комп'ютерному зорі. Функціонал середовища орієнтований на наукову роботу та роботу з Python, що робить його ефективним вибором для завдань, подібних до класифікації мисливських порід собак на зображеннях.

Основні переваги IDE Spyder:

- зручна інтеграція з бібліотеками для аналізу зображень;
- робота з великими обсягами даних;
- відладка коду (Spyder має потужний налагоджувач, який дозволяє крок за кроком виконувати алгоритм і виявляти помилки);
- гнучка візуалізація результатів (можливість виводити оброблені зображення з накладеними рамками виявлених об'єктів, підписами порід, а також будувати графіки, наприклад, графік залежності точності від кількості навчальних прикладів);
- простота інтеграції з іншими інструментами (Spyder дозволяє легко використовувати попередньо натреновані моделі, наприклад, із TensorFlow

або PyTorch, для розпізнавання об'єктів, оцінювати результати та вдосконалювати їх).

Бібліотека PyTorch [36, 37] використовується для реалізації методу Prototypical Network завдяки простоті у створенні кастомних архітектур нейронних мереж. PyTorch дозволяє ефективно обчислювати тензори, працювати з GPU та забезпечує необхідний функціонал для навчання та виводу прототипових мереж.

Бібліотека TensorFlow/Keras [38, 39] застосовується для реалізації методів Transfer Learning та Siamese Networks. Keras надає зручний API для роботи з попередньо навченими моделями, такими як VGG16 або ResNet, що значно спрощує процес навчання з перенесенням. TensorFlow також використовується для обчислення функції контрастивної втрати та побудови архітектури сіамської мережі.

У методі Prototypical Network використовується модель бібліотеки PyTorch ResNet18 як «кістяк» для витягування ознак зображень.

VGG16 – попередньо навчена модель із бібліотеки TensorFlow/Keras. Дана модель дозволяє використовувати вже набутий досвід для класифікації зображень. VGG16 задіяна для реалізації методу Transfer Learning.

Для роботи із зображеннями були застосовано наступні бібліотеки:

- PIL (бібліотека зображень Python) (для зміни розміру зображення або обрізання до квадратної форми);
- torchvision.transforms (для нормалізації та перетворення зображень у формат, придатний для нейронних мереж);
- TensorFlow ImageDataGenerator: (для завантаження та підготовки набору даних під час навчання Transfer Learning).

Зокрема для взаємодії з користувачем створено графічний інтерфейс за допомогою бібліотеки Tkinter, що дозволяє завантажувати зображення для класифікації та візуалізувати результати класифікації.

Для ефективного навчання моделей використовується обчислювальна потужність GPU. Бібліотеки PyTorch і TensorFlow автоматично забезпечують підтримку обчислень на графічних процесорах.

Таким чином, вибір зазначених інструментальних засобів забезпечує гнучкість та ефективність реалізації методів класифікації, а також спрощує інтеграцію кількох підходів у межах однієї програмної системи.

Головну сторінку розробленого графічного інтерфейсу користувача продемонстровано на рисунку 3.1.

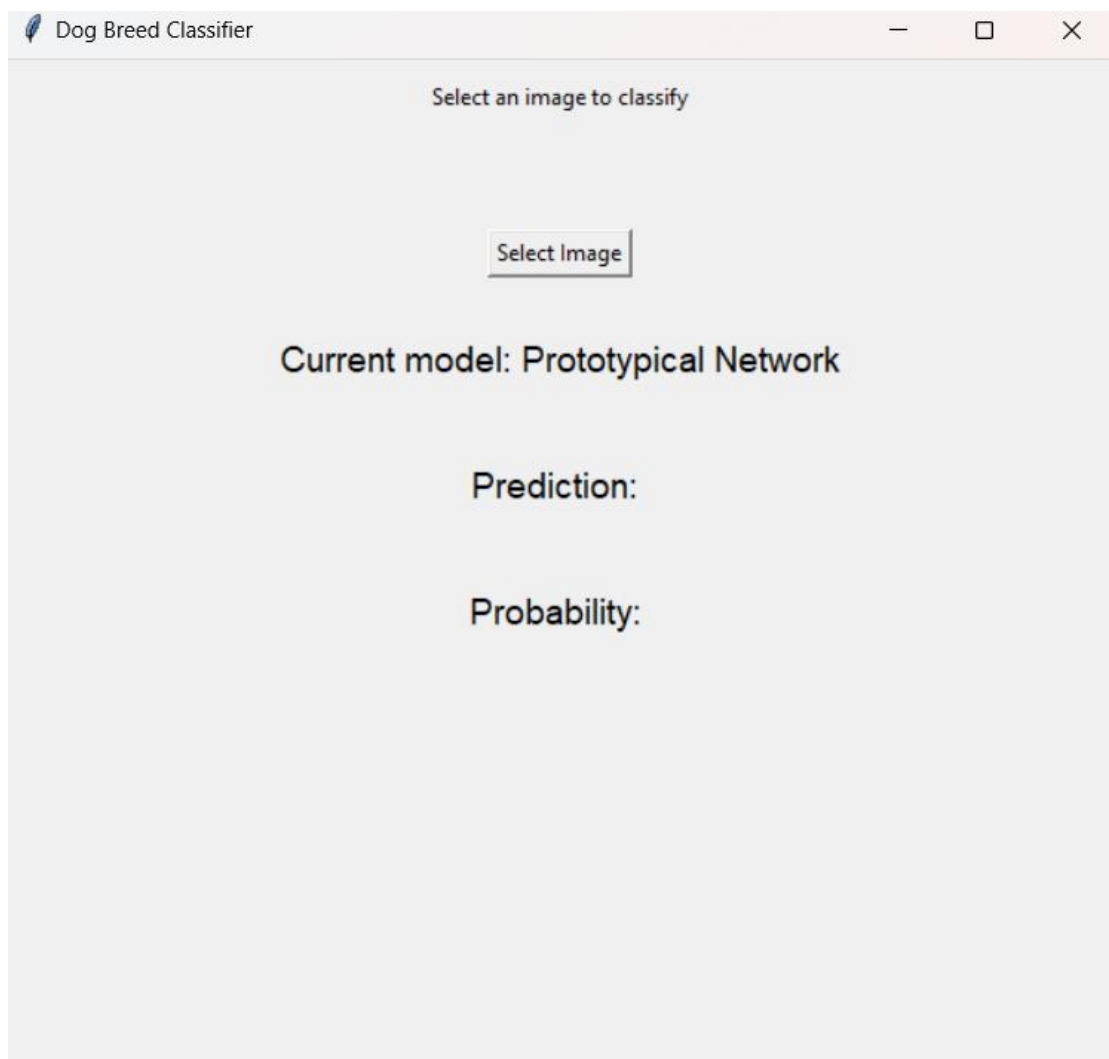


Рисунок 3.1 – Головна сторінка розробленого графічного інтерфейсу користувача

### 3.2 Етапи програмної реалізації вибраних методів класифікації мисливських порід собак на зображеннях

Для забезпечення високої якості виконання завдання класифікації мисливських порід собак було створено власноручний унікальний набір даних. Набір даних включає 52 класи, кожен із яких відповідає окремій породі собаки [40, 41]. Для кожного класу відібрано по 15 еталонних зображень, що дозволяє створити збалансований набір даних для навчання та тестування методів класифікації. Вибрана кількість еталонних прикладів обумовлена успішним вирішенням подібних задач у літературі, де використовують лише 10-20 прикладів на клас.

Збір даних здійснювався з особливою увагою до якості зображень. Вибрані фото відображають собак у різних ракурсах, позах і за умов, максимально наближених до реальних сценаріїв використання. Перевага надавалася якісним зображенням (у діапазоні від  $640 \times 640$  до  $1024 \times 1024$  пікселів формату JPEG), де собаки добре відокремлені від фону, що дозволяє мінімізувати вплив сторонніх об'єктів на результати класифікації. Усі зображення проходили попередню обробку, зокрема масштабування до єдиного розміру, що забезпечує однорідність вхідних даних.

З метою ілюстрації структури набору даних наведено приклад п'яти еталонних зображень для одного з класів (рис. 3.2).

Підібрані еталонні зображення демонструють репрезентативність вибору, вони охоплюють основні характеристики породи, включаючи форму тіла, забарвлення, структуру шерсті та вираз морди. Такий підхід дозволяє впевнено використовувати набір даних для подальшого навчання моделей та їх оцінки.

Загалом сформований набір даних відповідає сучасним вимогам до підготовки даних у задачах комп'ютерного зору і слугує міцною основою для проведення експериментів класифікації мисливських порід собак.

Програма складається з наступних основних компонентів:

- графічний інтерфейс користувача, який забезпечує вибір зображення, моделі класифікації та відображення результатів;
- модулі для кожного методу класифікації (прототипна нейромережа, модель на основі transfer learning (VGG16) та сіамська нейромережа);
- завантаження та попередня обробка даних (обробка зображень перед подачею в модель).



Рисунок 3.2 – Приклад п'яти еталонних зображень для класу мисливської породи собаки Akita-inu

Графічний інтерфейс реалізовано за допомогою бібліотеки Tkinter. Основні елементи включають:

- меню для вибору методу класифікації;
- кнопку завантаження зображення;
- поля для відображення результатів (порода та точність класифікації у відсотковому значенні).

Лістинг 3.1 Реалізація графічного інтерфейсу:

```

self.menu = Menu(self.root, tearoff=0)
self.menu.add_command(label="Prototypical Network",
command=self.select_prototypical_model)
self.menu.add_command(label="Transfer Learning (VGG16)",
command=self.select_transfer_learning_model)
self.menu.add_command(label="Siamese Network",
command=self.select_siamese_model)
self.select_button = tk.Button(self.root, text="Select Image",
command=self.load_image)
self.select_button.pack(pady=10)

```

DogBreedClassifierApp – головний клас, що має такі основні функції:

- load\_prototypical\_model – функція, що завантажує модель Prototypical Network;
- load\_transfer\_learning\_model – функція, що завантажує модель Transfer Learning;
- load\_siamese\_model – функція, що завантажує Siamese Network;
- load\_support\_set – функція, що завантажує набір даних для few-shot навчання;
- load\_image – функція, що викликає діалогове вікно для вибору зображення;
- display\_image – функція, що відповідає за відображення, обрізку, зміну розміру, конвертацію, оновлення зображення у вікні;
- predict\_breed – функція, що викликає відповідну модель для передбачення породи;
- display\_prediction – функція, що відображає прогноз.

Лістинг 3.2 Головний блок програми:

```
if __name__ == "__main__":
    root = tk.Tk()
    app = DogBreedClassifierApp(root)
    root.mainloop()
```

### 3.2.1 Структура реалізації методу Prototypical Network

Основні класи реалізованого методу Prototypical Network:

- CenterCropToSquare – клас підготовки зображень (обрізає зображення до квадрату та масштабує його до заданого розміру, центрує обрізку, забезпечуючи збереження головної частини зображення);
- PrototypicalNetwork – головний клас для створення моделі Prototypical Network на основі ResNet-18 (пропускає вхідні дані через ResNet-18 і повертає вектор ознак зображення).

Основні функції реалізованого методу Prototypical Network:

- preprocess\_image – функція попередньої обробки зображень (обрізає, масштабує, перетворює зображення на тензор і нормалізує його, використовується перед подачею зображення в модель);
- compute\_prototypes – функція обчислення прототипів для кожного класу на основі середнього значення векторів ознак;
- pairwise\_distance – функція обчислення попарних евклідових відстаней між векторами ознак;
- predict\_class – функція передбачення класу на основі мінімальної відстані до прототипів (знаходить найближчий прототип для вхідного вектору ознак);
- predict\_breed\_prototypical – головна функція для класифікації зображення.

### 3.2.2 Структура реалізації методу Transfer Learning з Pretrained CNN (VGG16)

Для вирішення задачі класифікації зображень було використано попередньо натреновану модель VGG16.

Лістинг 3.3 Завантаження попередньо навченої моделі VGG16:

```
def load_transfer_learning_model(self):
    model =
        load_model('dog_breeds_transfer_learning_with_pretrained_cnn.h5')
    return model
```

У цій функції виконується завантаження файлу із збереженою моделлю (dog\_breeds\_transfer\_learning\_with\_pretrained\_cnn.h5). Модель попередньо була донавчена на спеціалізованому наборі даних, який містить зображення порід собак.

Лістинг 3.4 Обробка зображення та прогнозування класу зображення методом Transfer Learning з Pretrained CNN (VGG16):

```
def predict_breed_transfer_learning(model, image_path, train_generator):
    img = image.load_img(image_path, target_size=(224, 224))
    img_array = image.img_to_array(img) / 255.0
    img_array = np.expand_dims(img_array, axis=0)

    prediction = model.predict(img_array)
    predicted_class = np.argmax(prediction, axis=1)
    predicted_probability = prediction[0][predicted_class[0]] * 100
    class_labels = list(train_generator.class_indices.keys())
    predicted_breed = class_labels[predicted_class[0]]
    return predicted_breed, predicted_probability
```

### 3.2.3 Структура реалізації методу Siamese Networks

Основні функції реалізованого методу Siamese Networks:

- `euclidean_distance` – функція обчислення евклідової відстані;
- `contrastive_loss` – обчислення функції втрат;
- `load_reference_embeddings` – функція завантаження довідкових векторів ознак (для кожної породи обчислюється середній вектор ознак, зображення нормалізуються та подаються на базову модель сіамської мережі);
- `predict_breed_siamese` – функція прогнозування породи (порівнює вектор ознак вхідного зображення із довідковими векторами ознак, найближча відстань визначає прогнозовану породу).

### 3.3 Інструкція користувача

Основний сценарій користування реалізованим десктоп-застосунком:

- користувач вибирає модель класифікації через контекстне меню за допомогою правої кнопки миші, доступні моделі: Prototypical Network, Transfer Learning (VGG16), Siamese Network (рис. 3.3);
- після вибору моделі відбувається завантаження відповідної моделі для класифікації;
- користувач завантажує зображення через кнопку, після чого воно відображається у вікні програми;
- після класифікації на екрані відображається назва породи та ймовірність.

Кожного разу при зміні моделі на іншу користувачеві необхідно вибрати зображення із провідника кнопкою «Select Image».

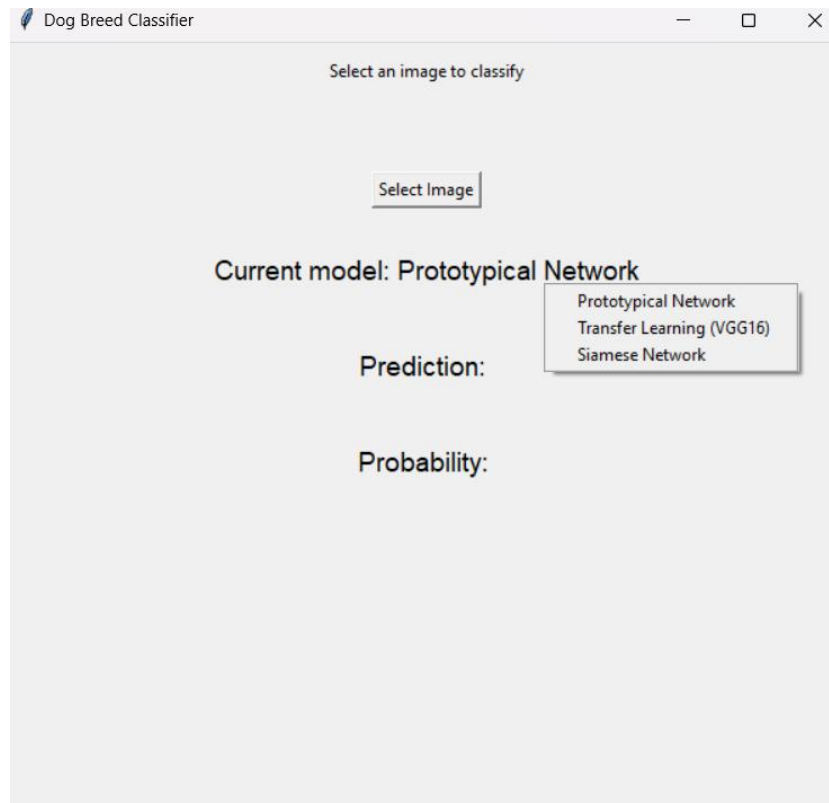


Рисунок 3.3 – Контекстне меню вибору моделі для класифікації мисливської породи собаки на зображенні

#### 3.4 Дослідження методів класифікації мисливських порід собак на зображеннях

У даному розділі представлено результати класифікації зображень мисливських порід собак за допомогою трьох методів – Prototypical Network, Transfer Learning (VGG16) та Siamese Network. Для перевірки якості роботи застосунку було використано зображення собак, кожне з яких оброблялося трьома методами.

На рисунках 3.4 – 3.45 породи класифіковано правильно, тобто очікуваний результат відповідає актуальному. Програма надає точність класифікації у відсотковому значенні для кожного проведеного тестового кейсу.

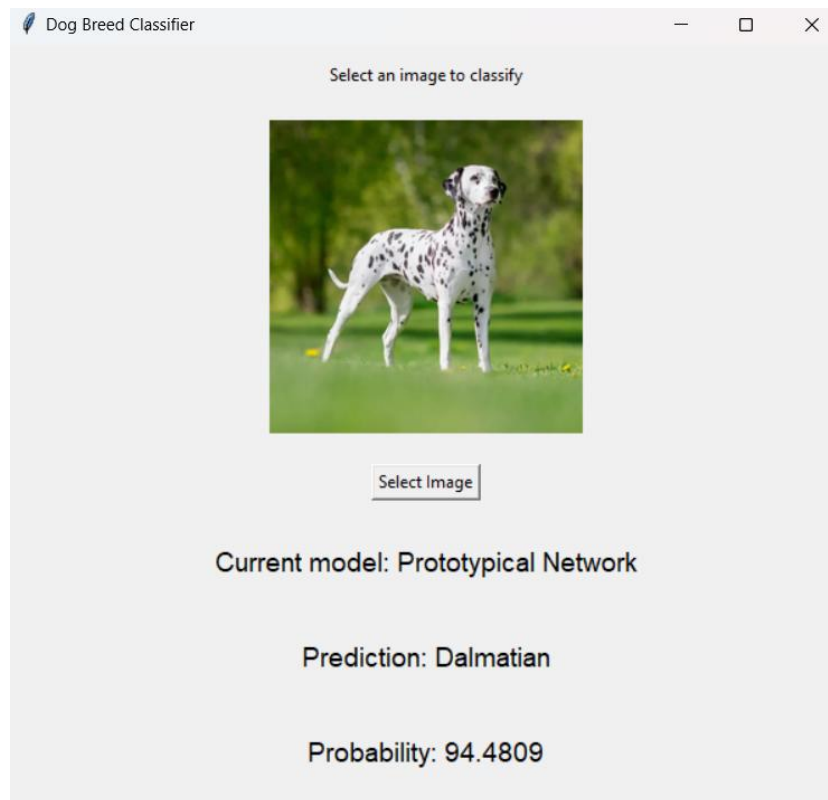


Рисунок 3.4 – Результат класифікації методом Prototypical Network для породи dalmatian

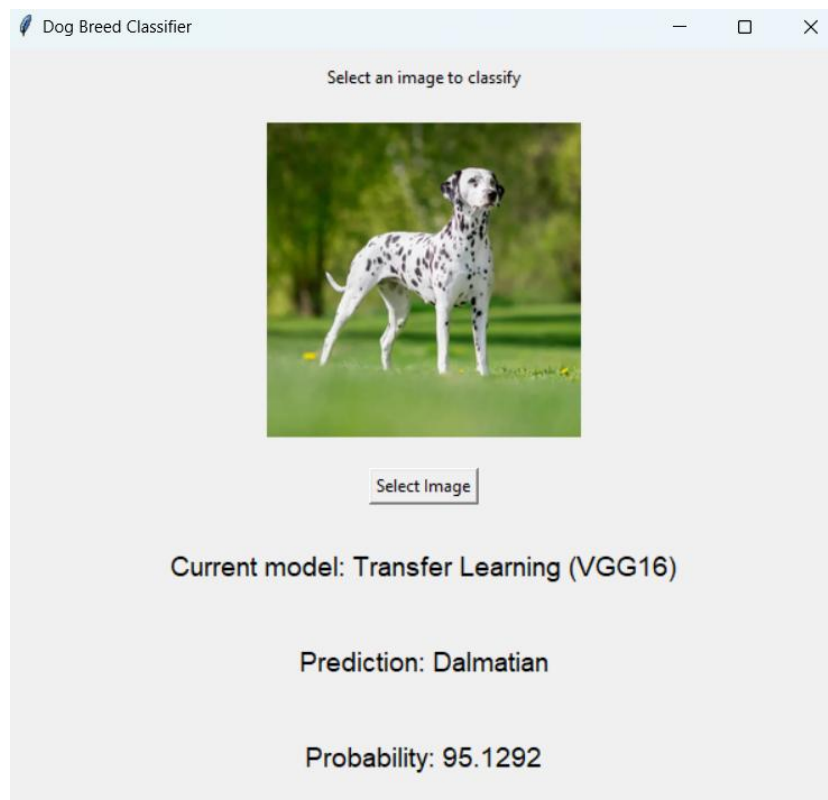


Рисунок 3.5 – Результат класифікації методом Transfer Learning (VGG16) для породи dalmatian

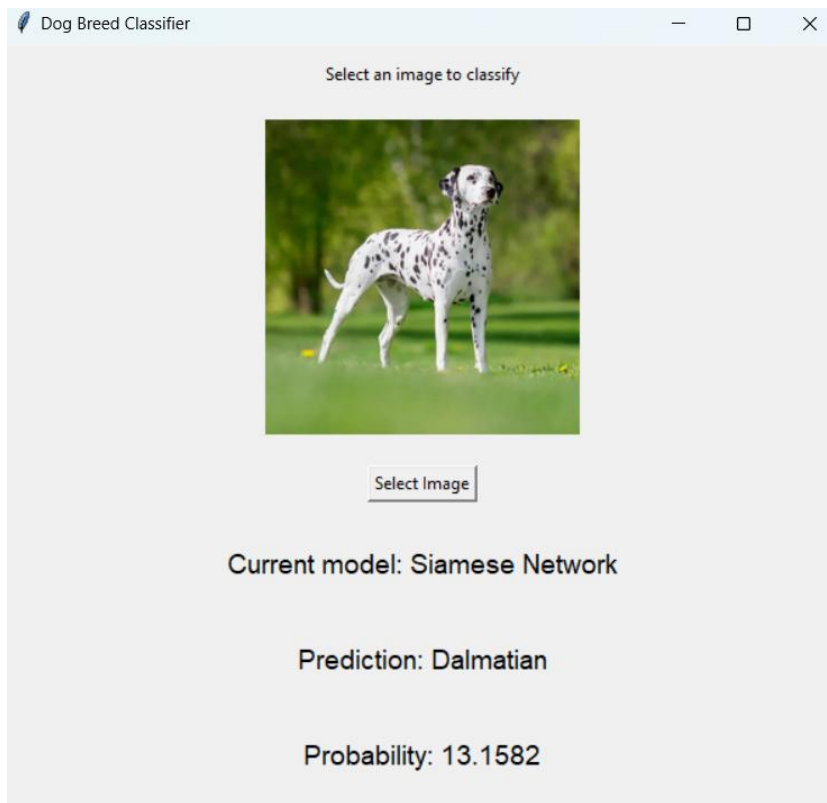


Рисунок 3.6 – Результат класифікації методом Siamese Networks для породи dalmatian

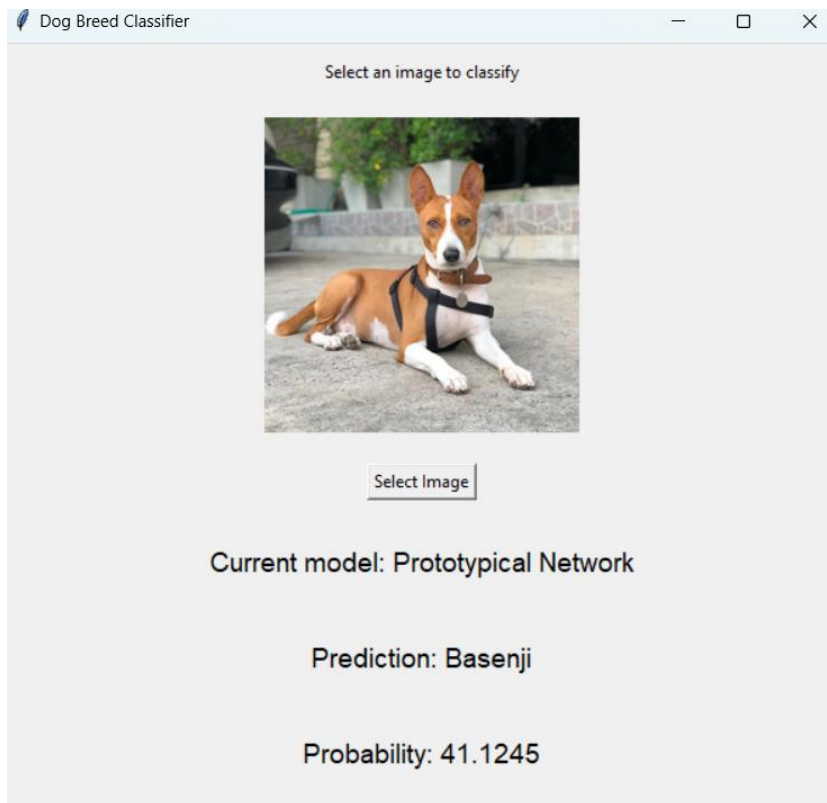


Рисунок 3.7 – Результат класифікації методом Prototypical Network для породи basenji

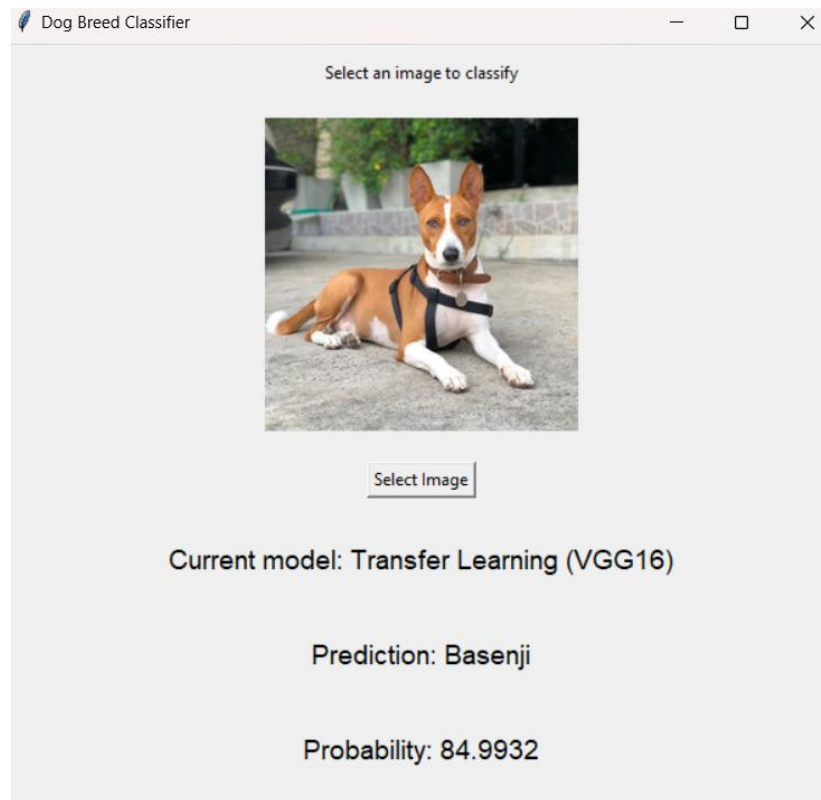


Рисунок 3.8 – Результат класифікації методом Transfer Learning (VGG16) для породи basenji

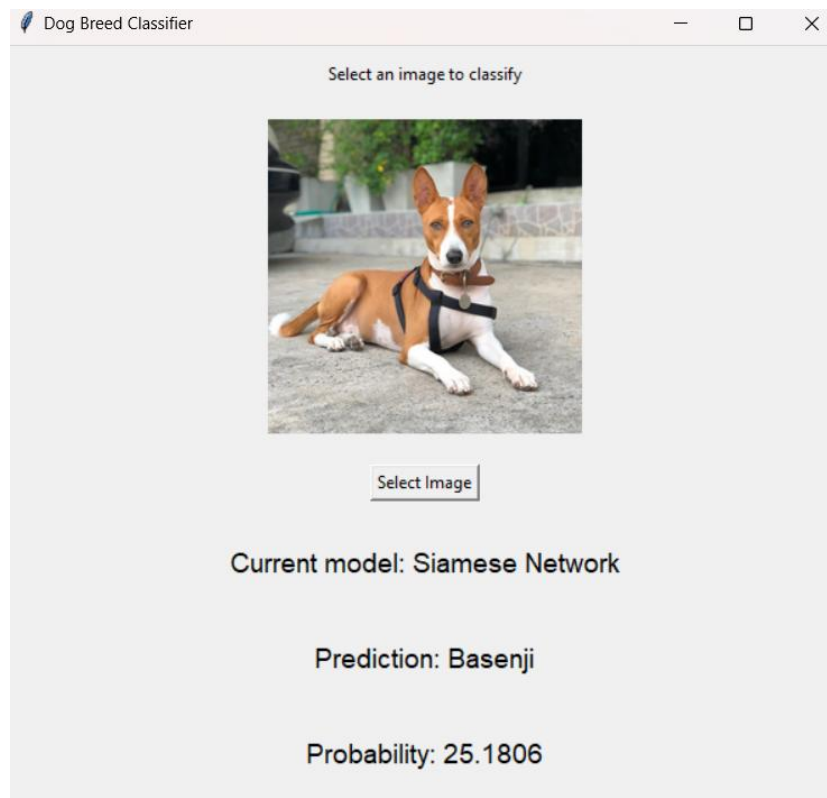


Рисунок 3.9 – Результат класифікації методом Siamese Networks для породи basenji

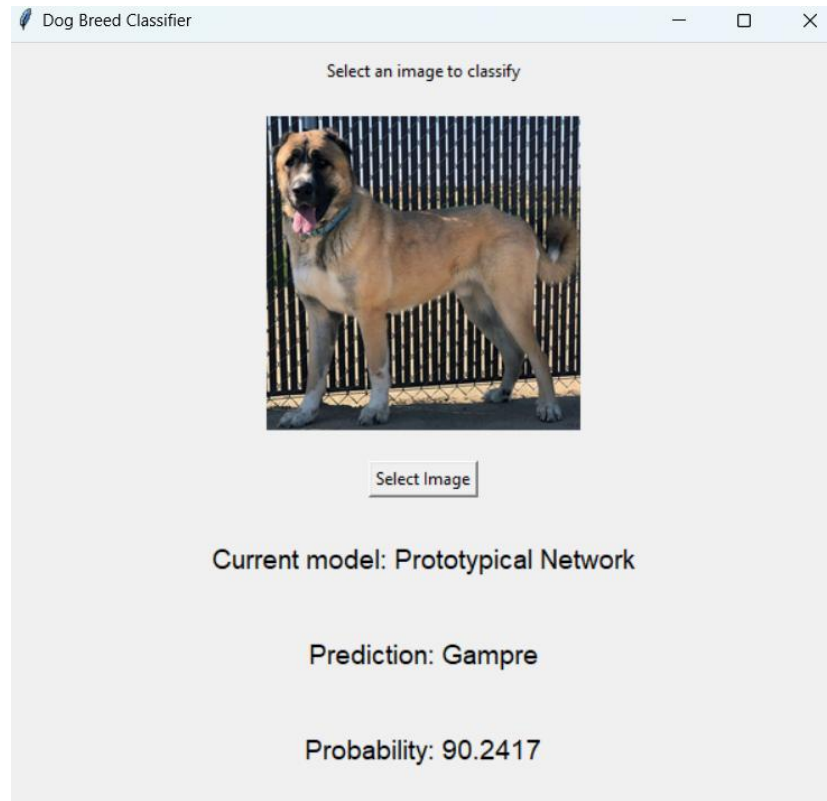


Рисунок 3.10 – Результат класифікації методом Prototypical Network для породи gampre

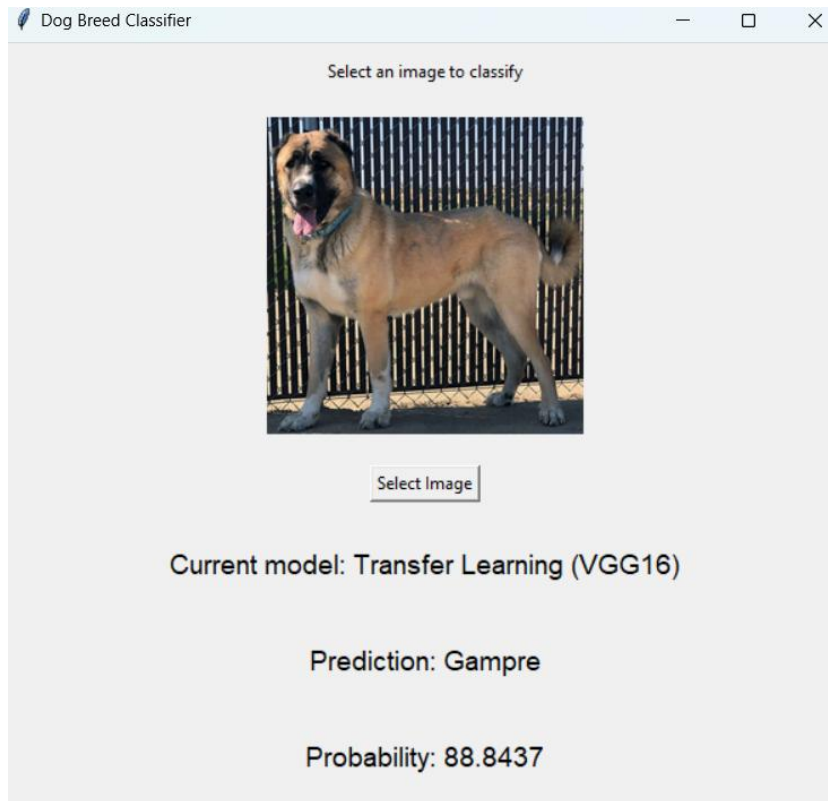


Рисунок 3.11 – Результат класифікації методом Transfer Learning (VGG16) для породи gampre

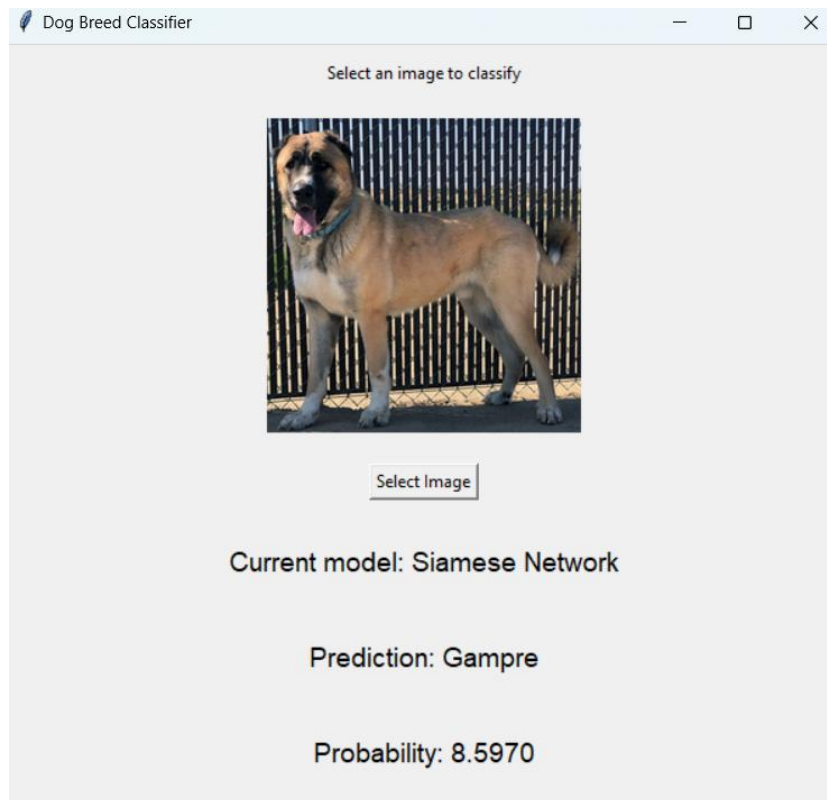


Рисунок 3.12 – Результат класифікації методом Siamese Networks для породи gampre

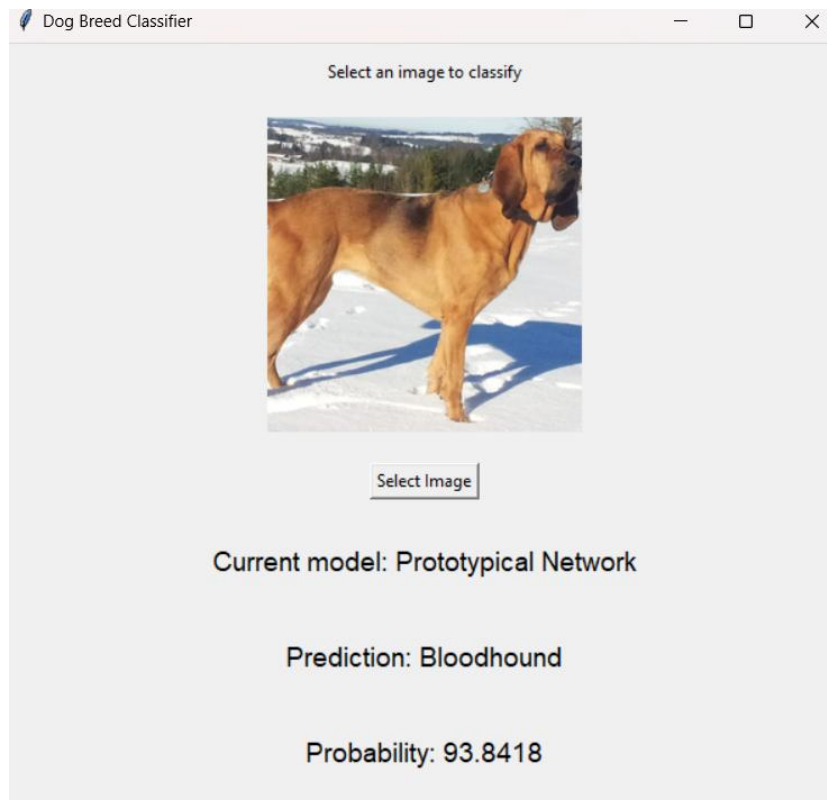


Рисунок 3.13 – Результат класифікації методом Prototypical Network для породи bloodhound

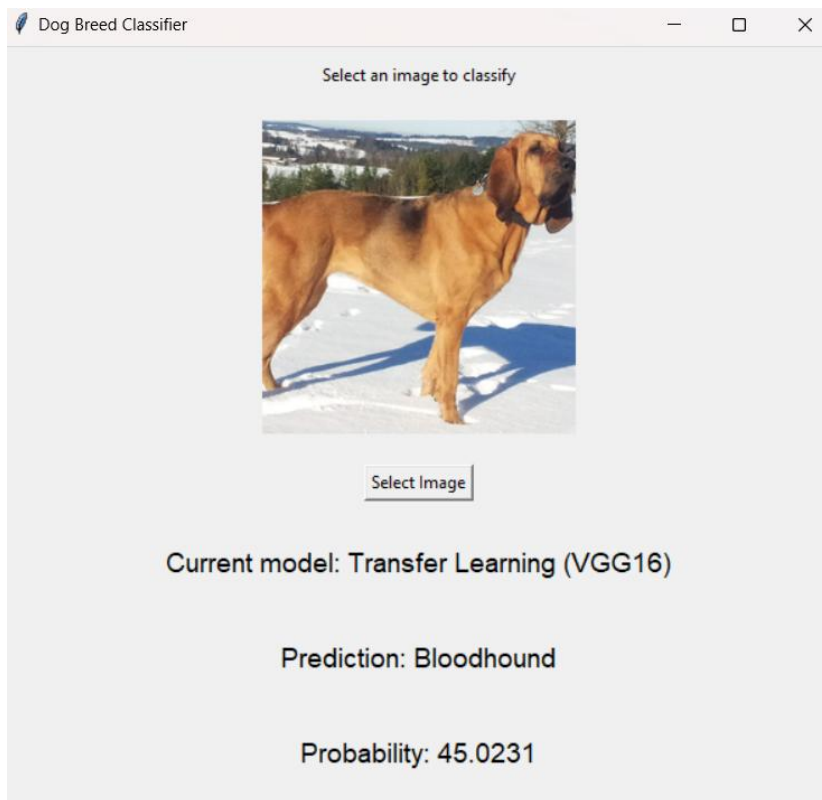


Рисунок 3.14 – Результат класифікації методом Transfer Learning (VGG16) для породи bloodhound

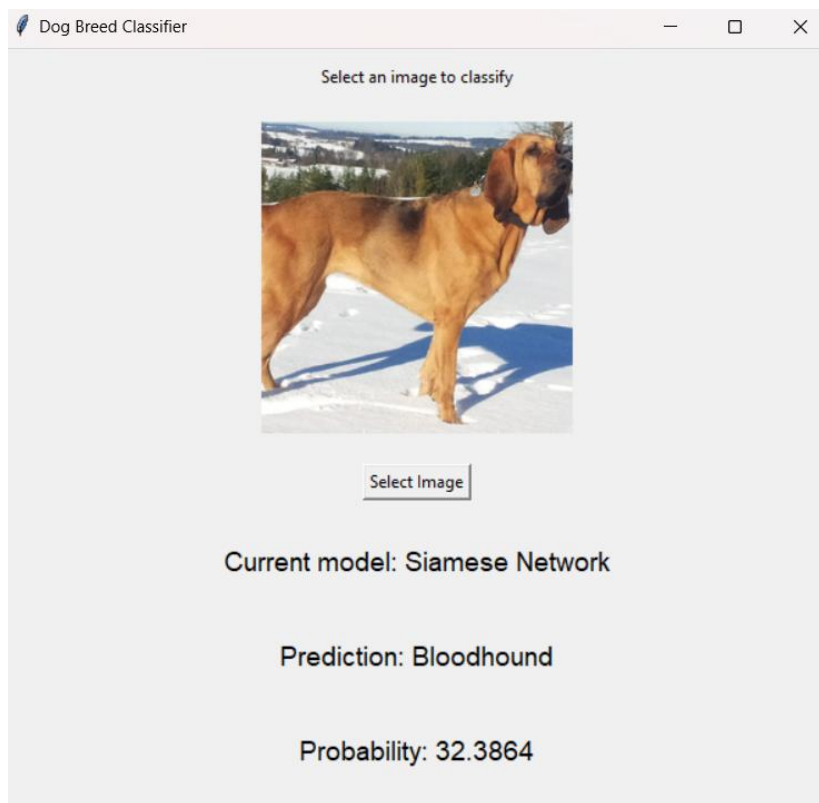


Рисунок 3.15 – Результат класифікації методом Siamese Networks для породи bloodhound

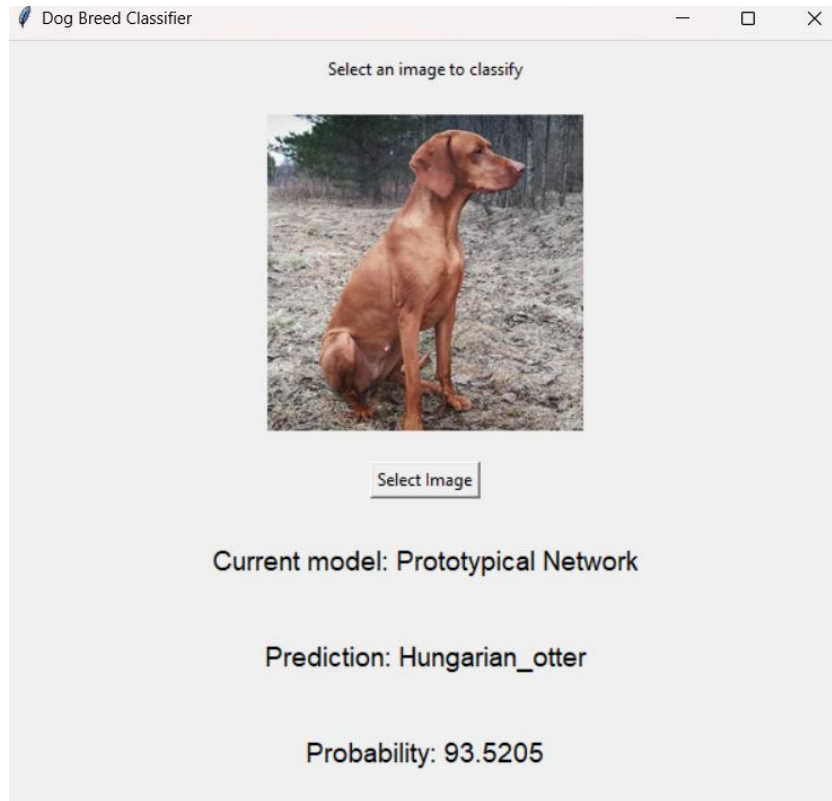


Рисунок 3.16 – Результат класифікації методом Prototypical Network для породи hungarian otter

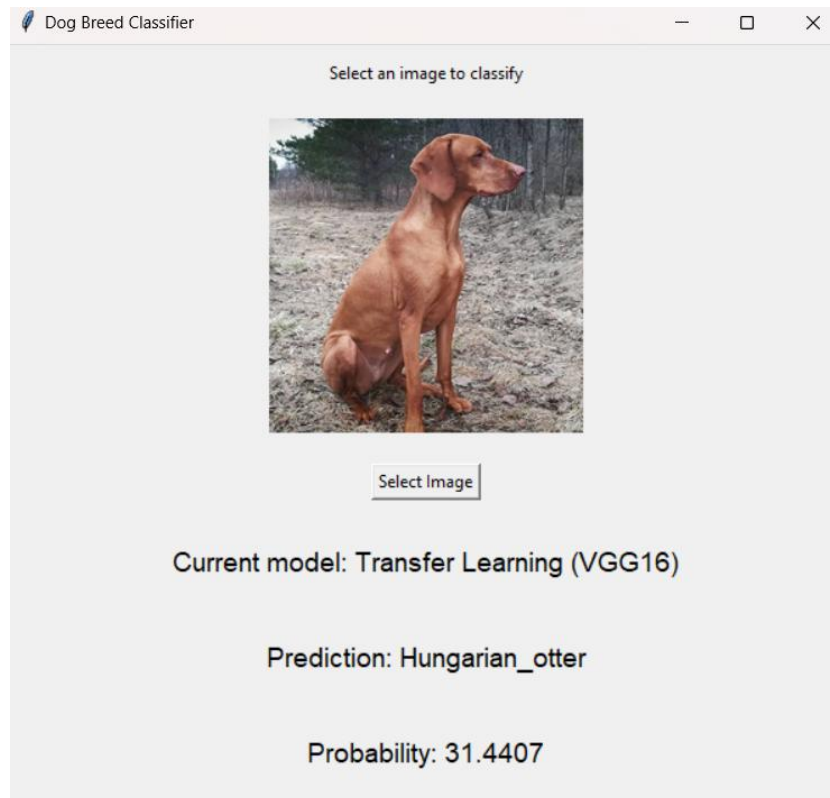


Рисунок 3.17 – Результат класифікації методом Transfer Learning (VGG16) для породи hungarian otter

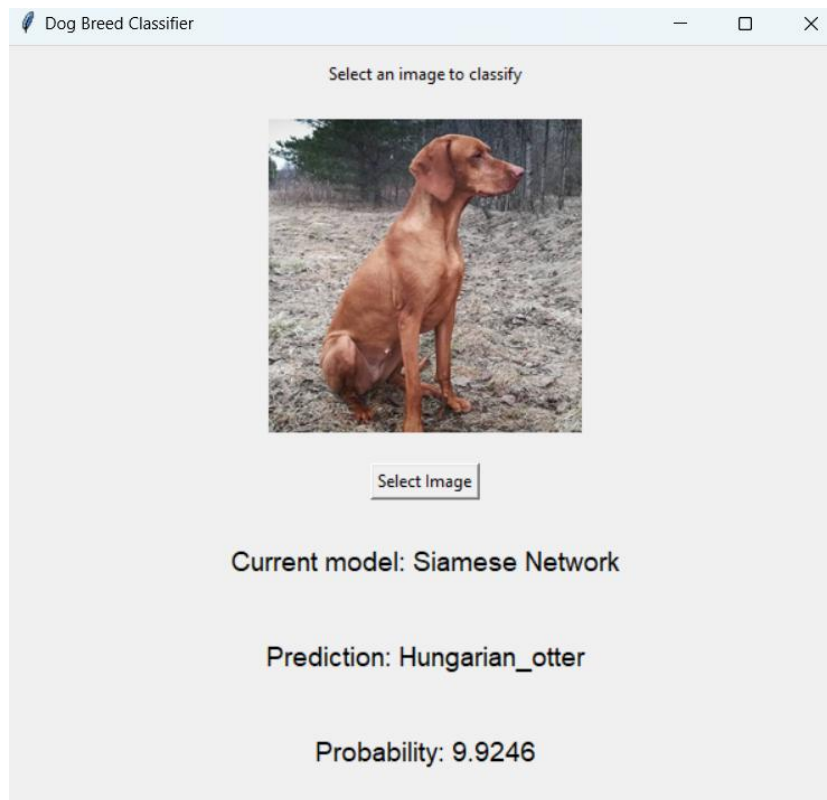


Рисунок 3.18 – Результат класифікації методом Siamese Networks для породи hungarian otter

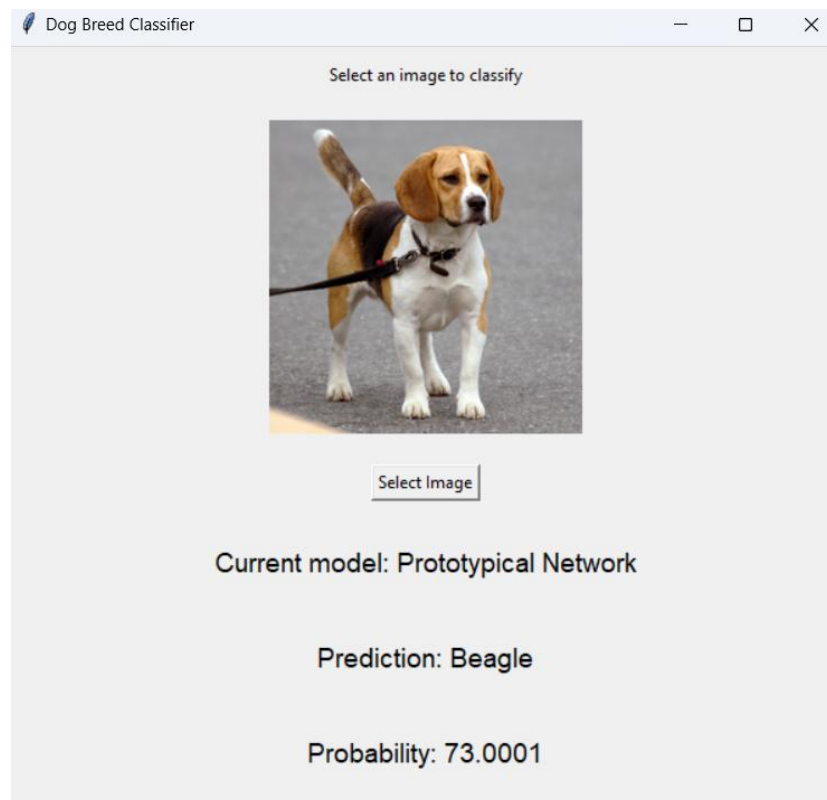


Рисунок 3.19 – Результат класифікації методом Prototypical Network для породи beagle

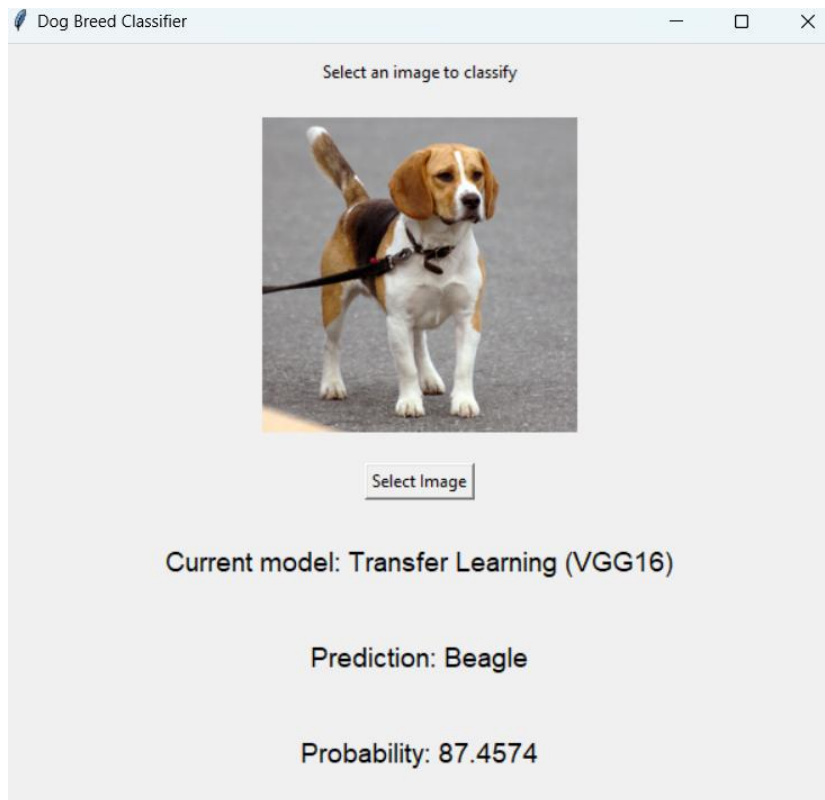


Рисунок 3.20 – Результат класифікації методом Transfer Learning (VGG16) для породи beagle

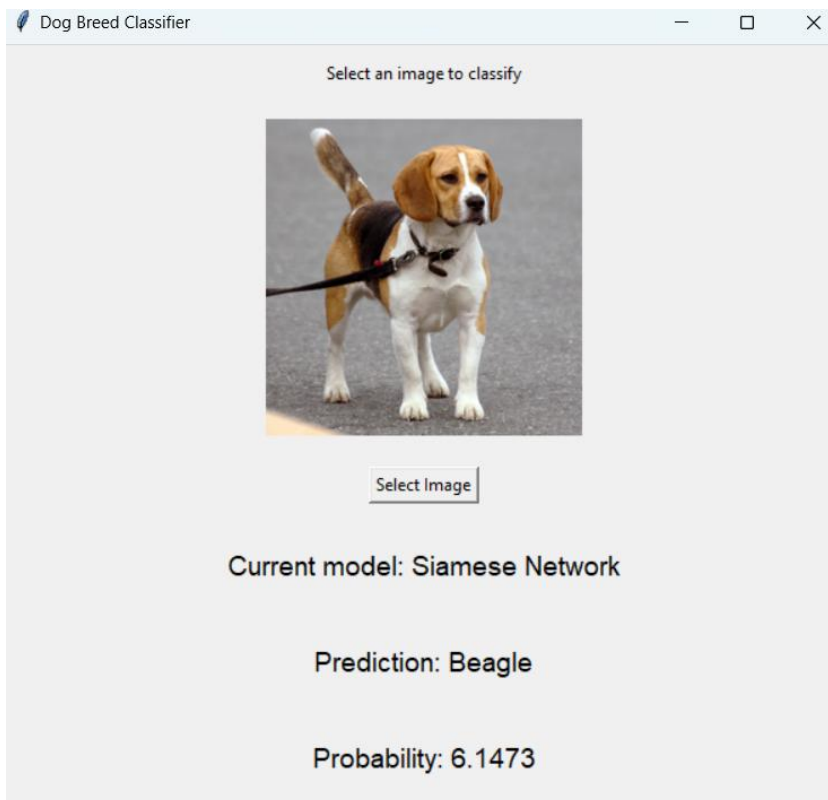


Рисунок 3.21 – Результат класифікації методом Siamese Networks для породи beagle

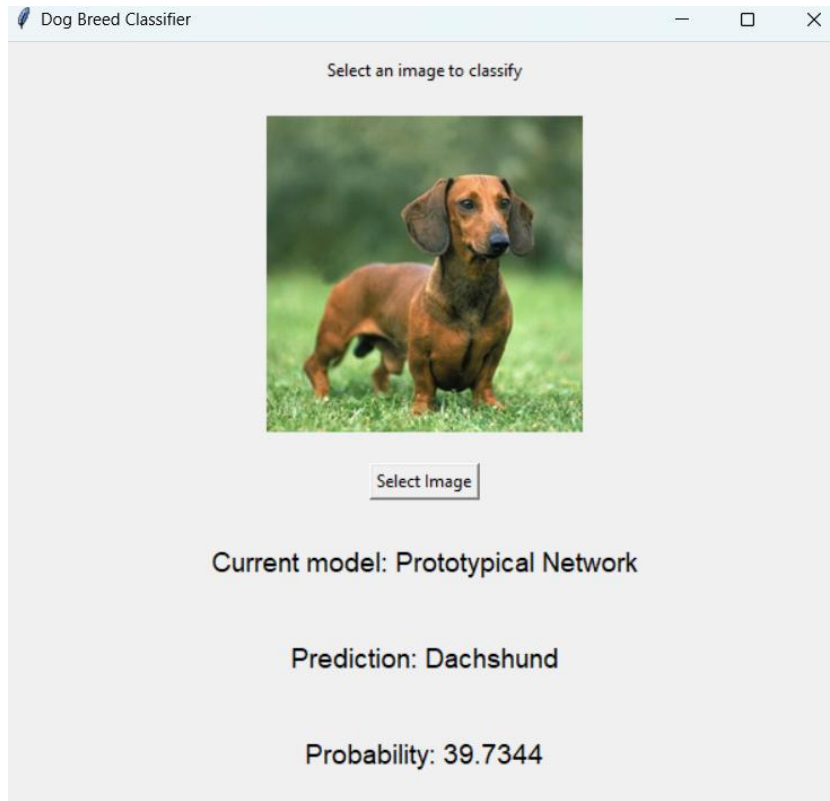


Рисунок 3.22 – Результат класифікації методом Prototypical Network для породи dachshund

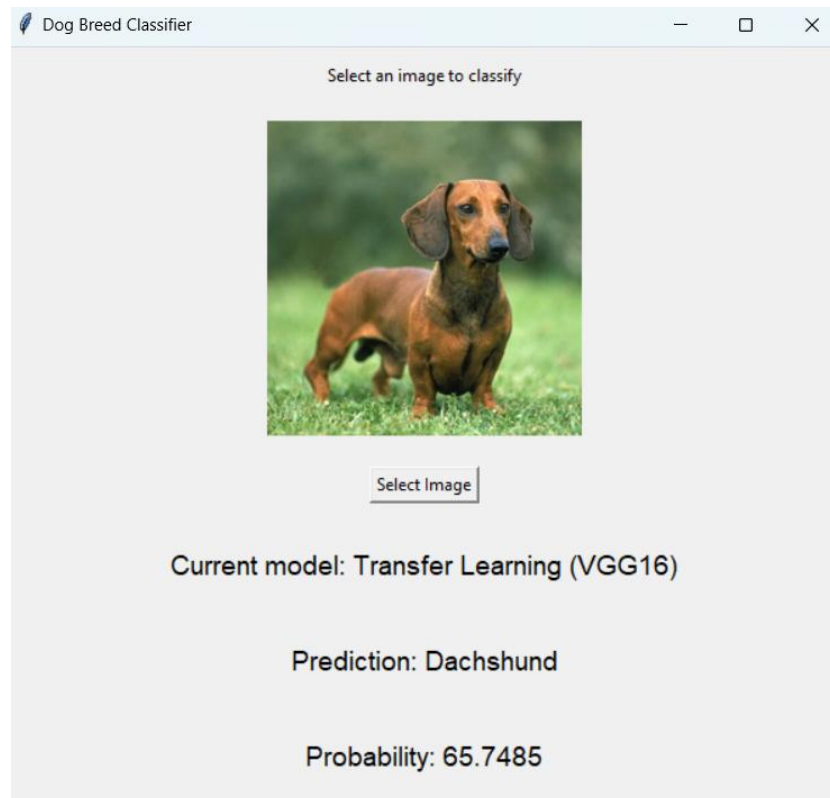


Рисунок 3.23 – Результат класифікації методом Transfer Learning (VGG16) для породи dachshund

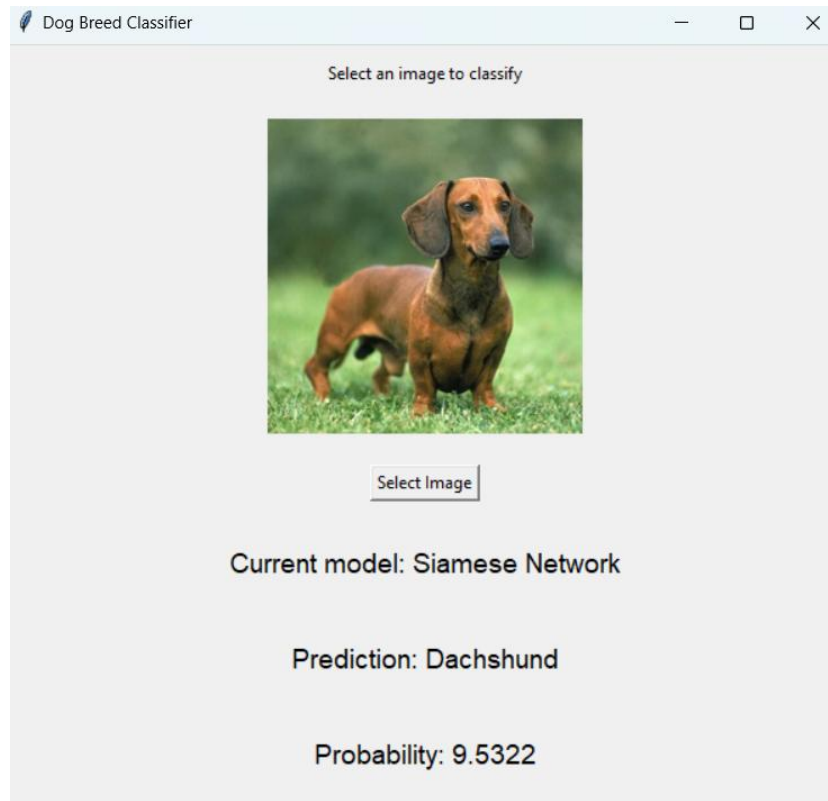


Рисунок 3.24 – Результат класифікації методом Siamese Networks для породи dachshund

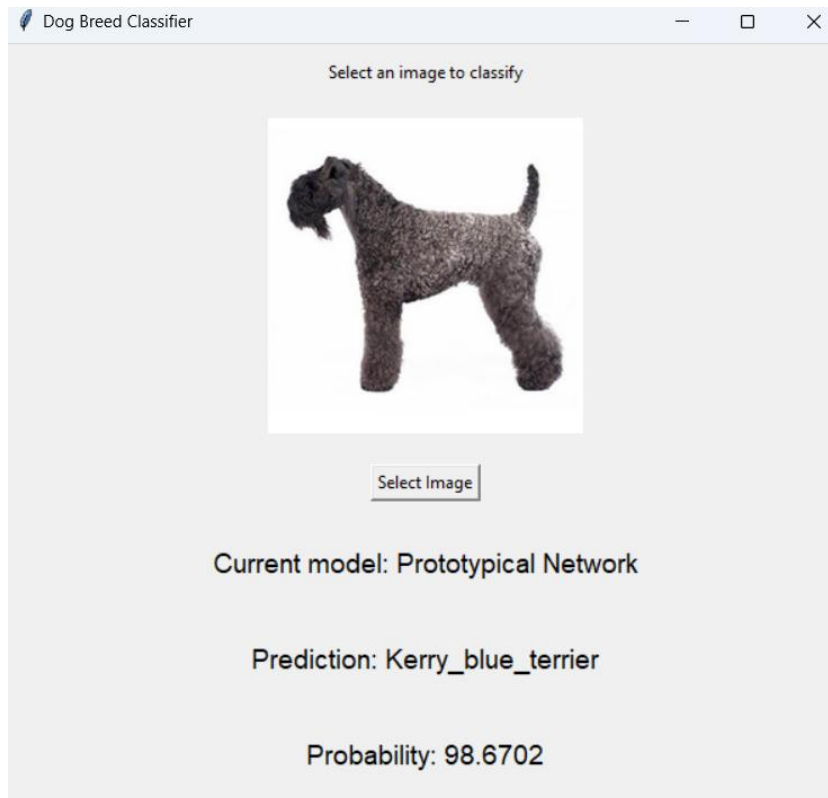


Рисунок 3.25 – Результат класифікації методом Prototypical Network для породи kerry blue terrier

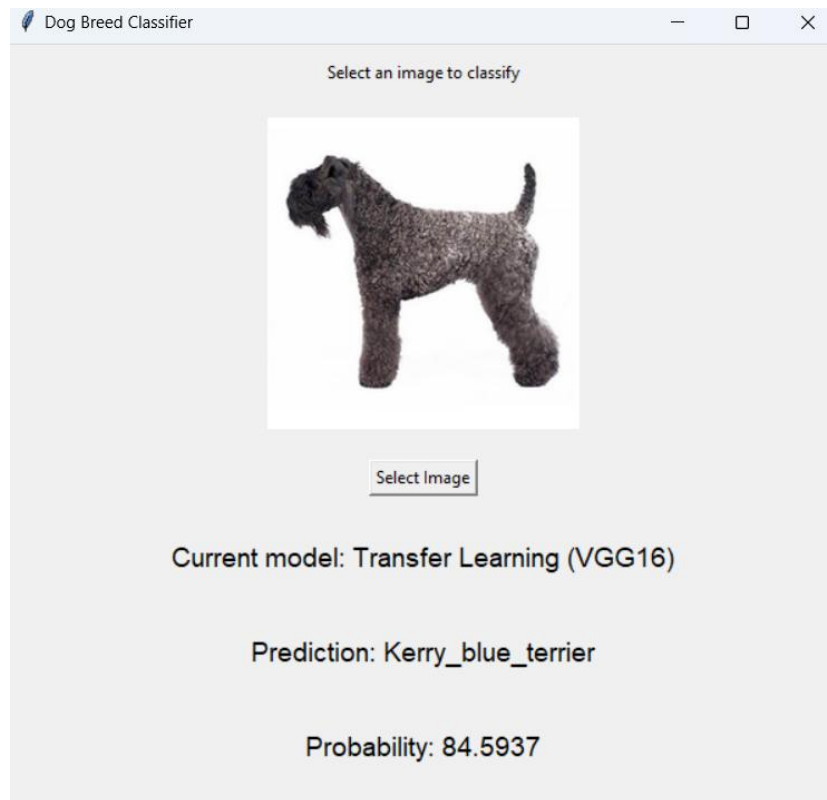


Рисунок 3.26 – Результат класифікації методом Transfer Learning (VGG16) для породи kerry blue terrier

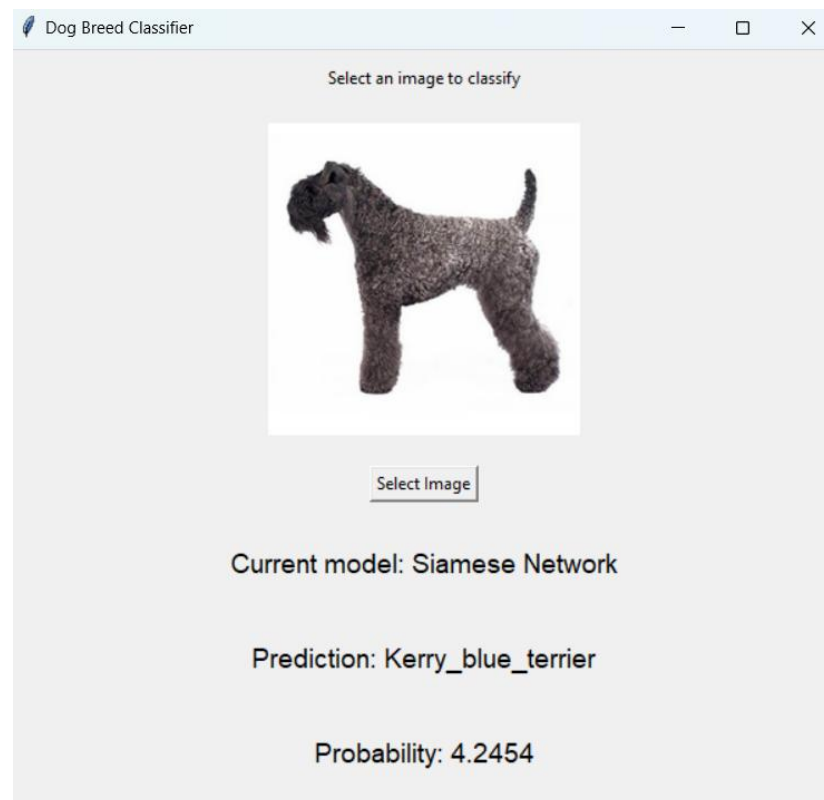


Рисунок 3.27 – Результат класифікації методом Siamese Networks для породи kerry blue terrier

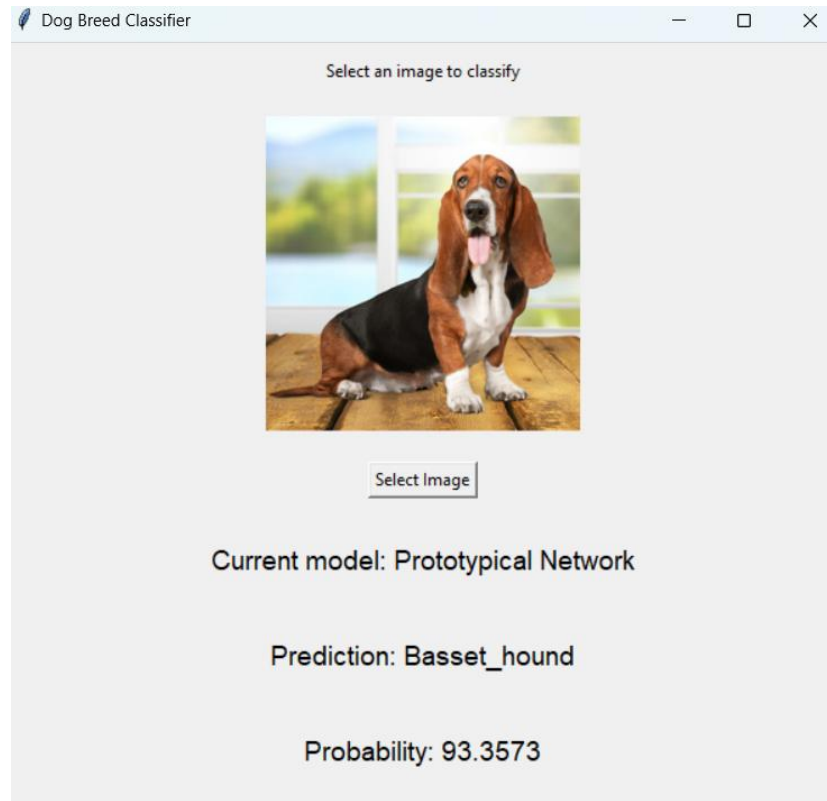


Рисунок 3.28 – Результат класифікації методом Prototypical Network для породи basset hound

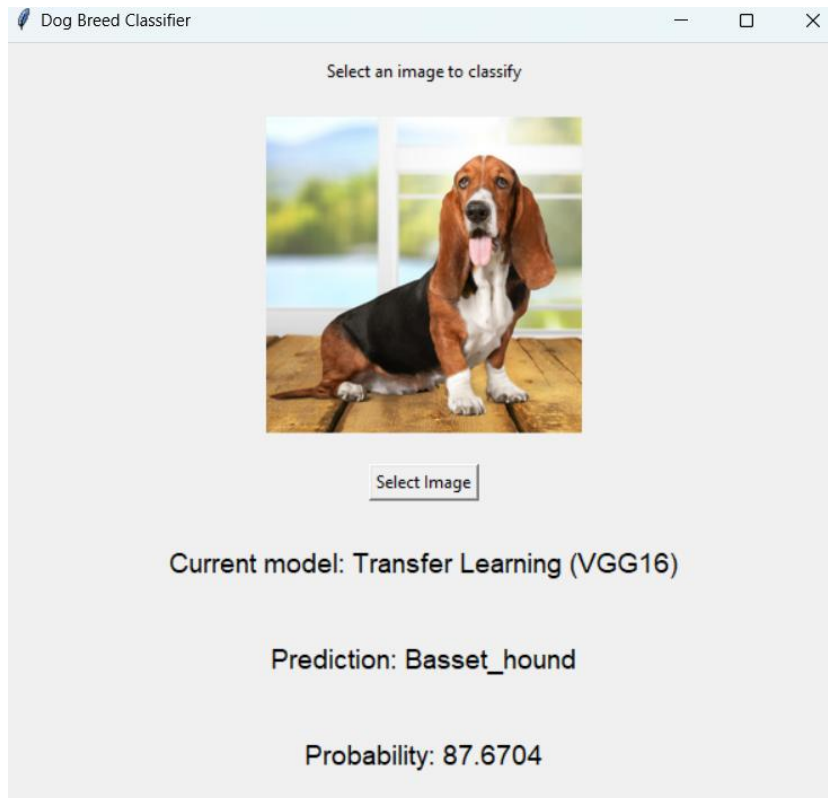


Рисунок 3.29 – Результат класифікації методом Transfer Learning (VGG16) для породи basset hound

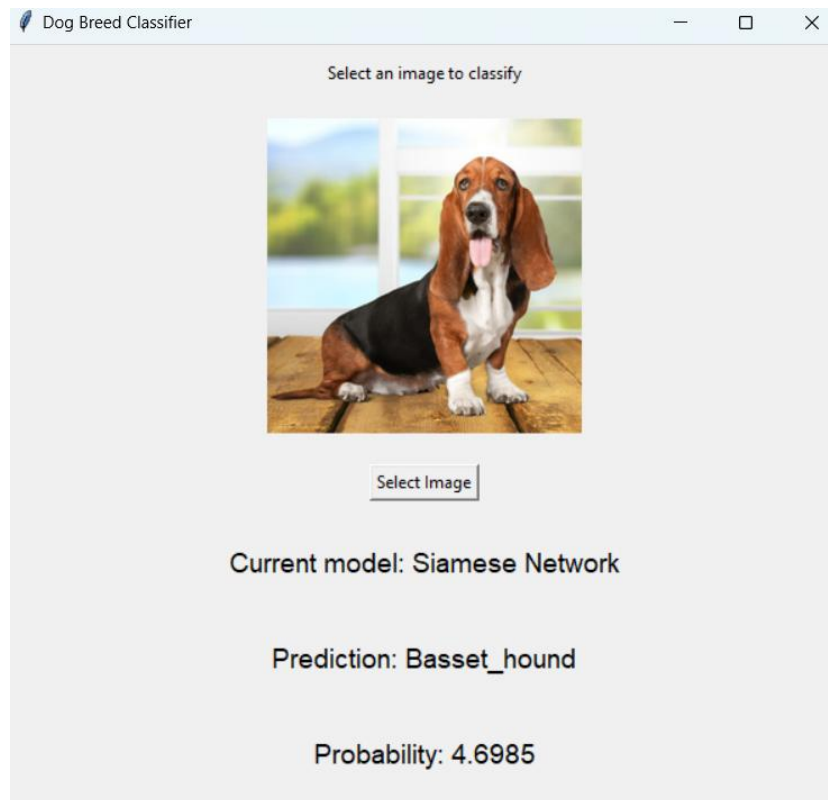


Рисунок 3.30 – Результат класифікації методом Siamese Networks для породи basset hound

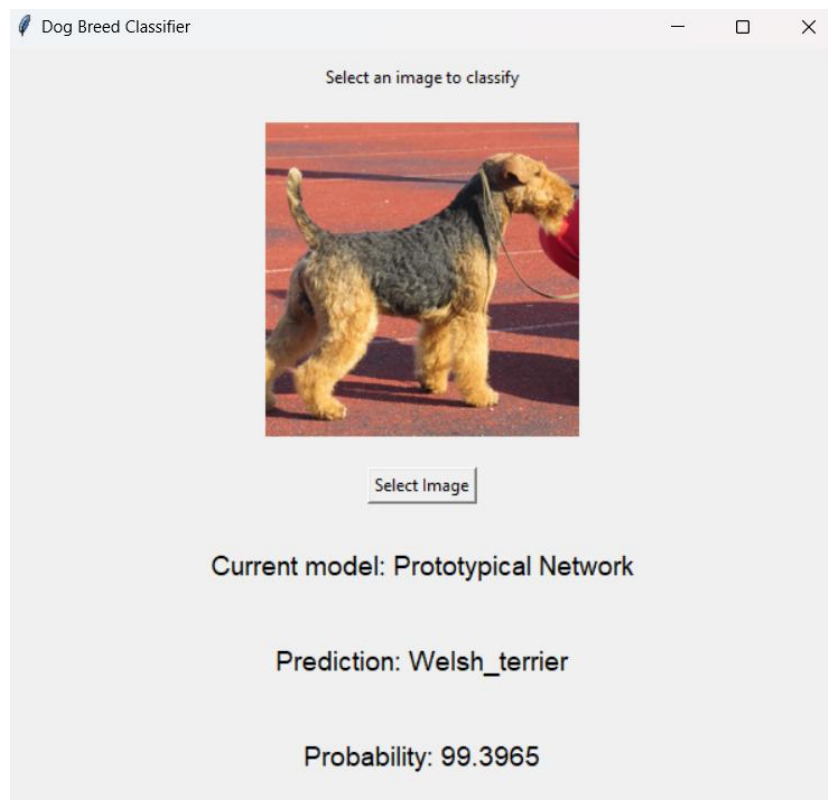


Рисунок 3.31 – Результат класифікації методом Prototypical Network для породи welsh terrier

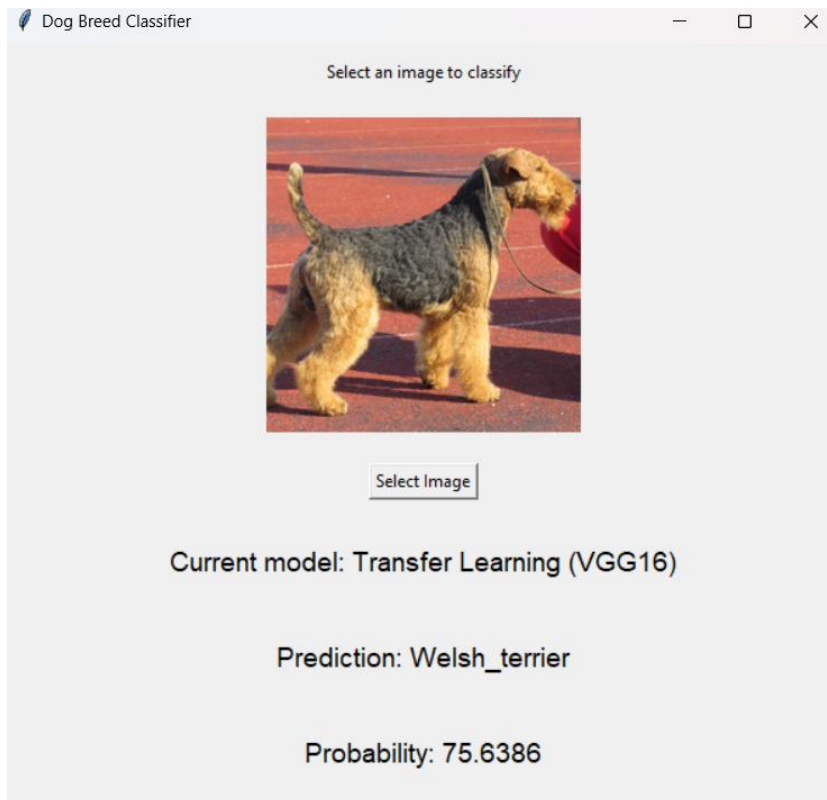


Рисунок 3.32 – Результат класифікації методом Transfer Learning (VGG16) для породи welsh terrier

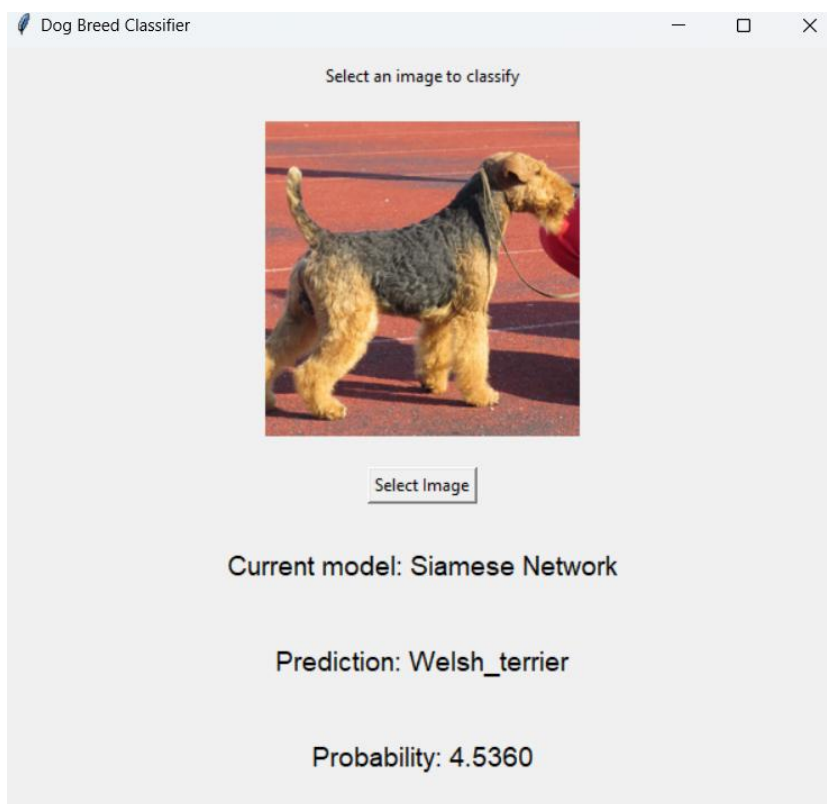


Рисунок 3.33 – Результат класифікації методом Siamese Networks для породи welsh terrier

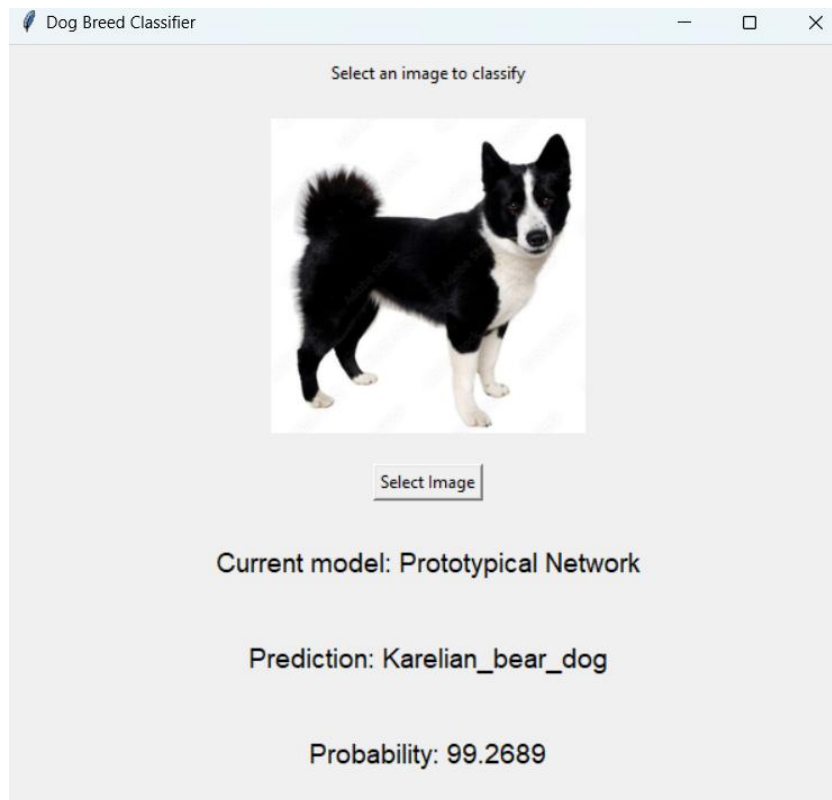


Рисунок 3.34 – Результат класифікації методом Prototypical Network для породи karelian bear dog

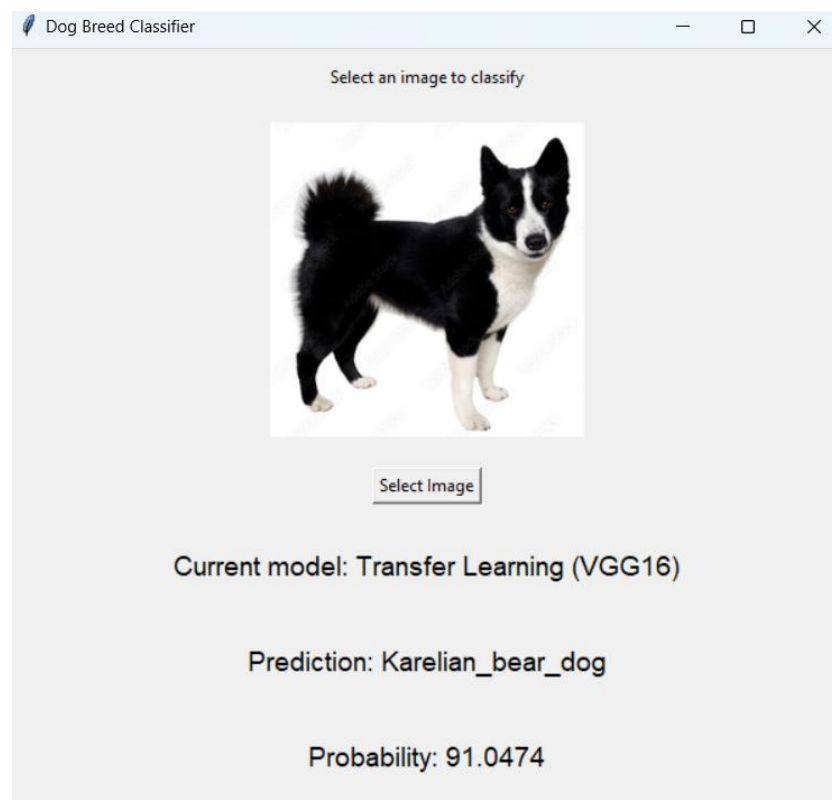


Рисунок 3.35 – Результат класифікації методом Transfer Learning (VGG16) для породи karelian bear dog

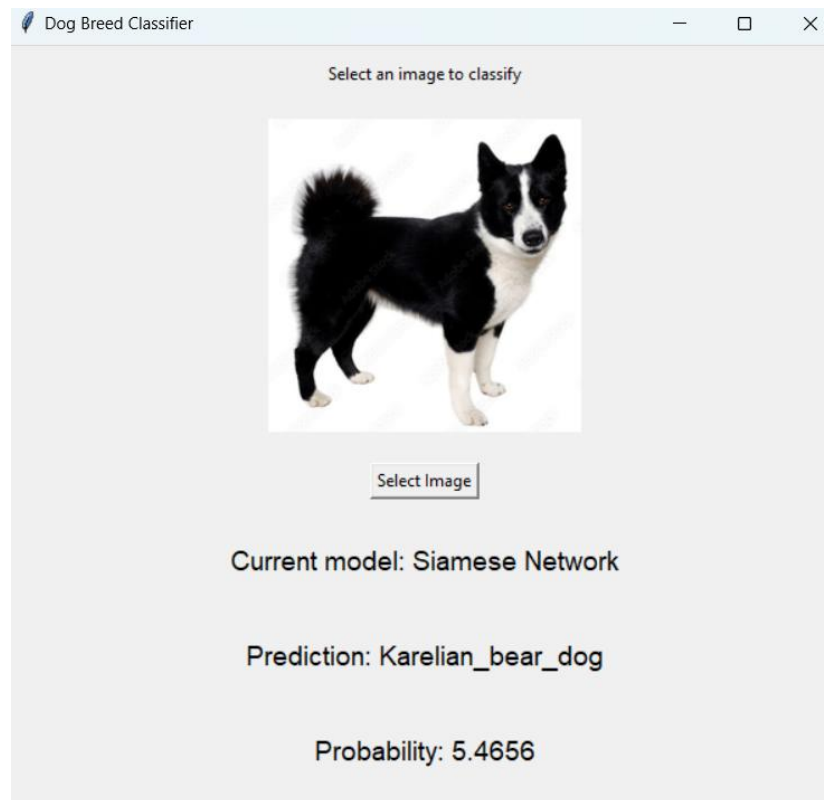


Рисунок 3.36 – Результат класифікації методом Siamese Networks для породи karelían bear dog

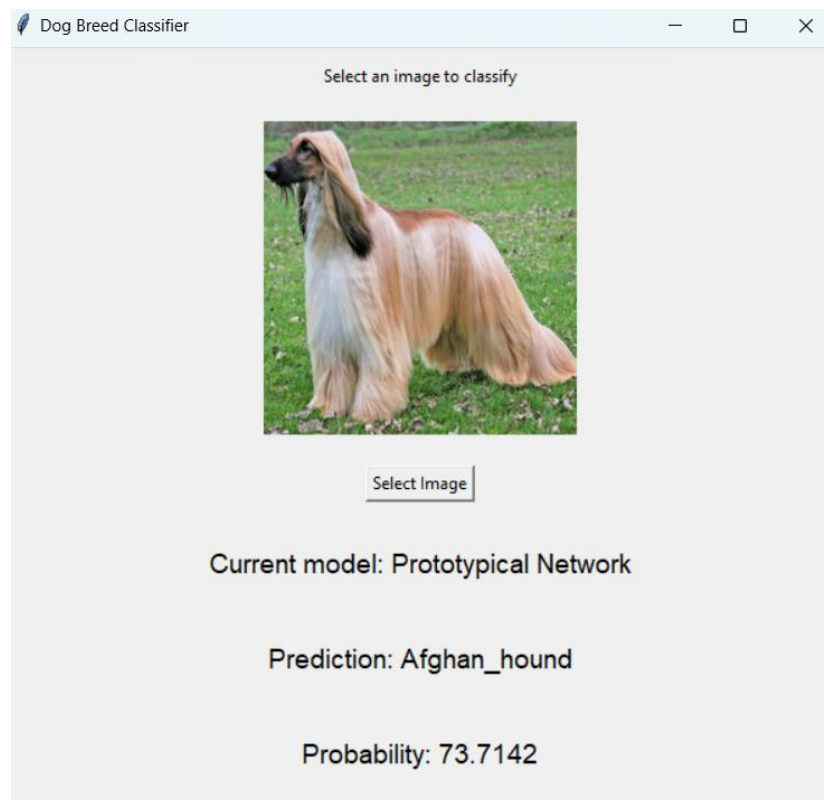


Рисунок 3.37 – Результат класифікації методом Prototypical Network для породи afghan hound

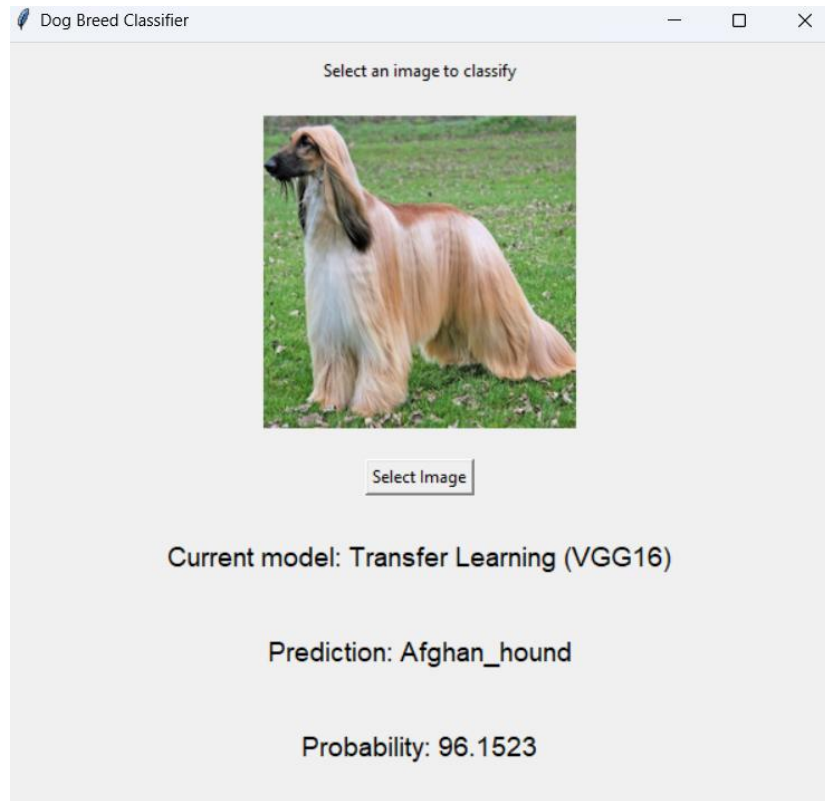


Рисунок 3.38 – Результат класифікації методом Transfer Learning (VGG16) для породи afghan hound

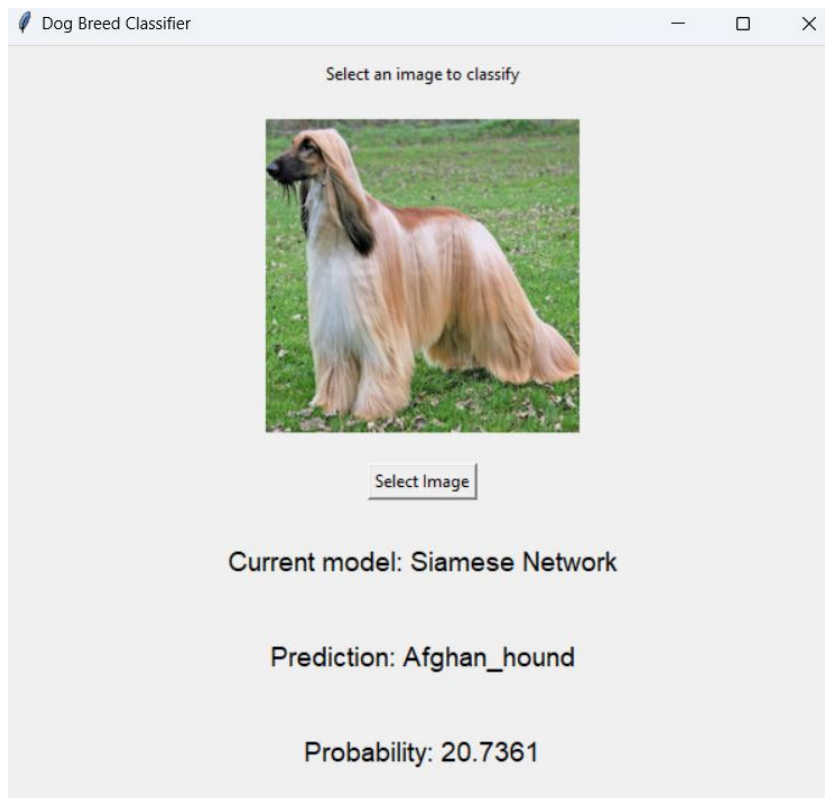


Рисунок 3.39 – Результат класифікації методом Transfer Learning (VGG16) для породи afghan hound

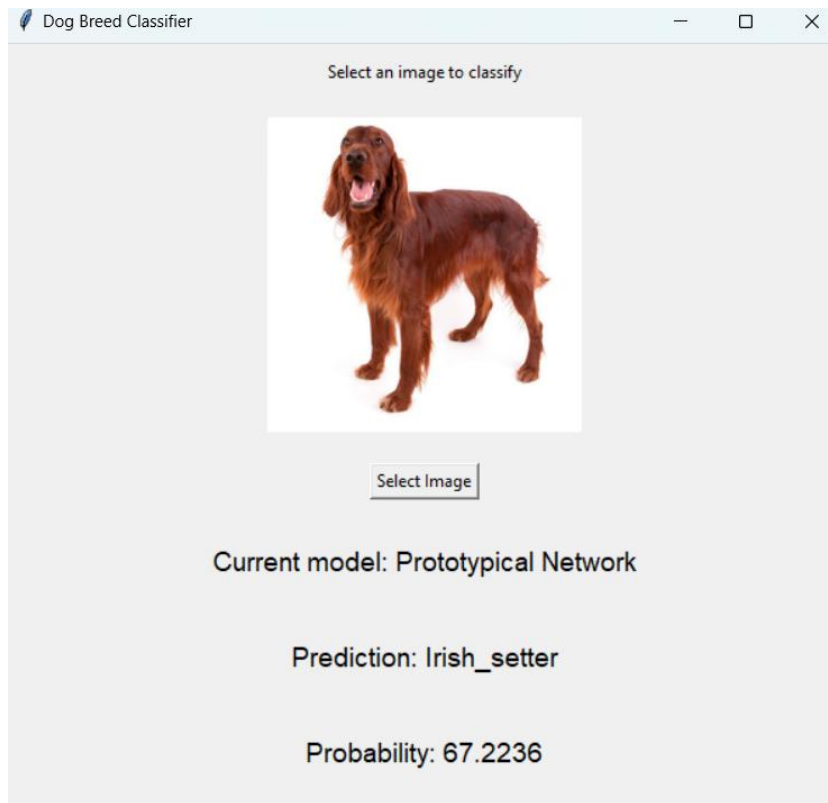


Рисунок 3.40 – Результат класифікації методом Prototypical Network для породи irish setter

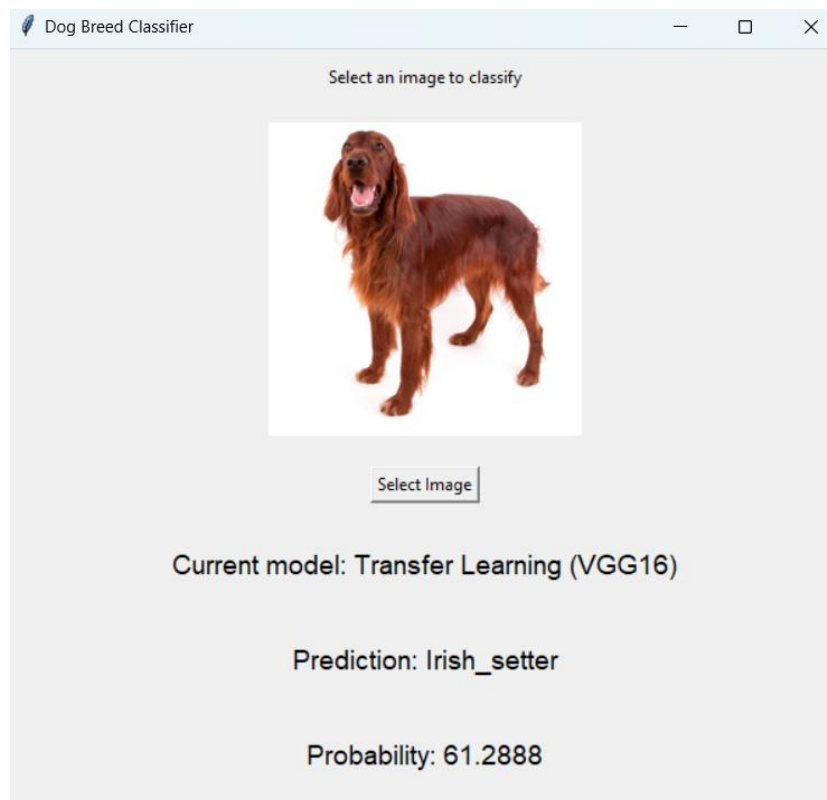


Рисунок 3.41 – Результат класифікації методом Transfer Learning (VGG16) для породи irish setter

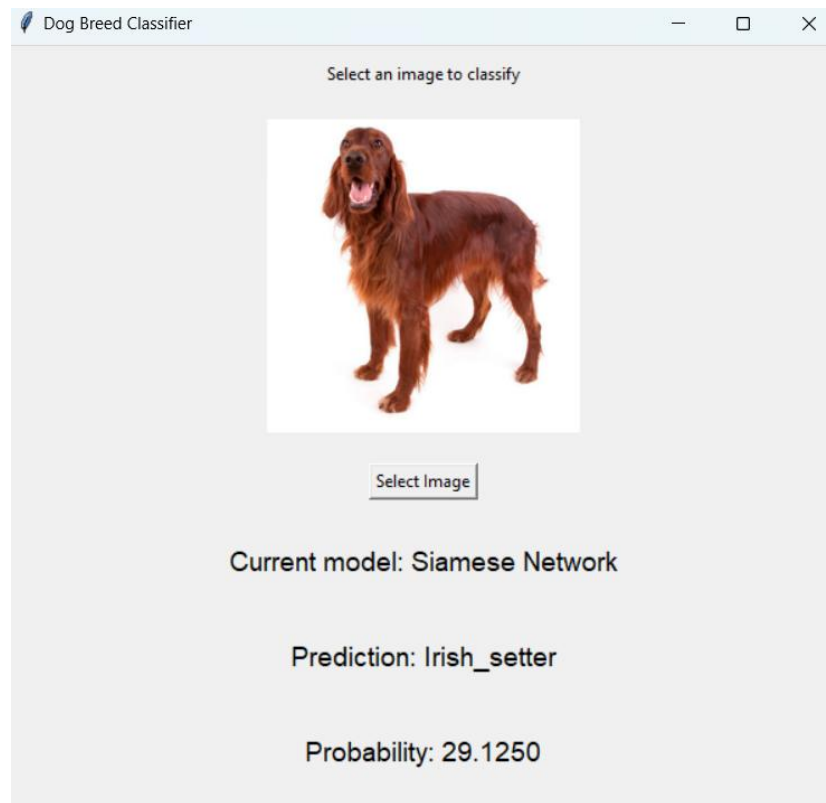


Рисунок 3.42 – Результат класифікації методом Siamese Networks для породи irish setter

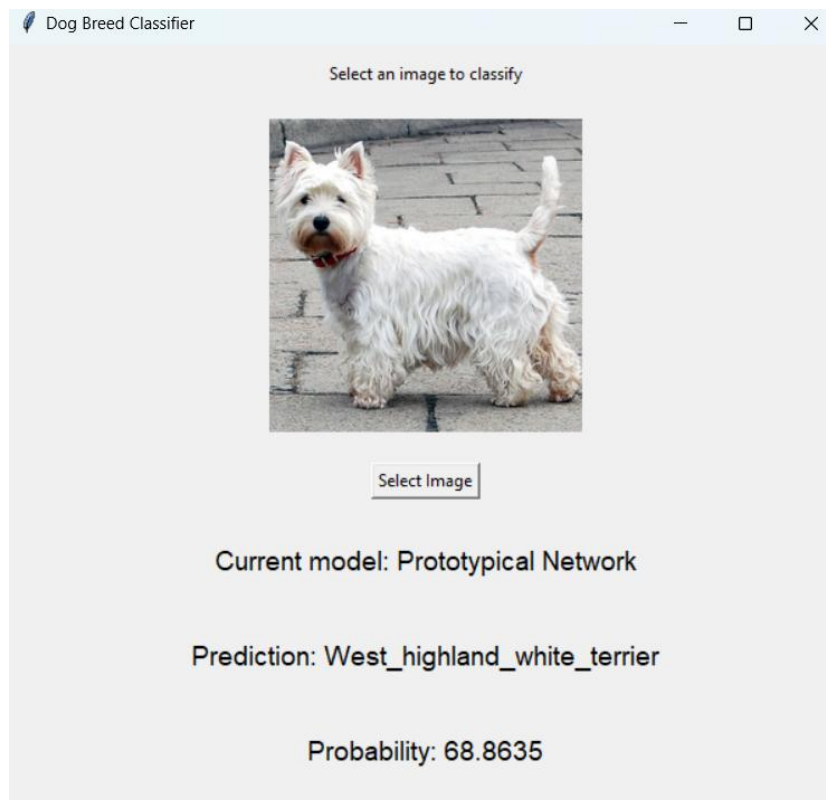


Рисунок 3.43 – Результат класифікації методом Prototypical Network для породи west highland white terrier

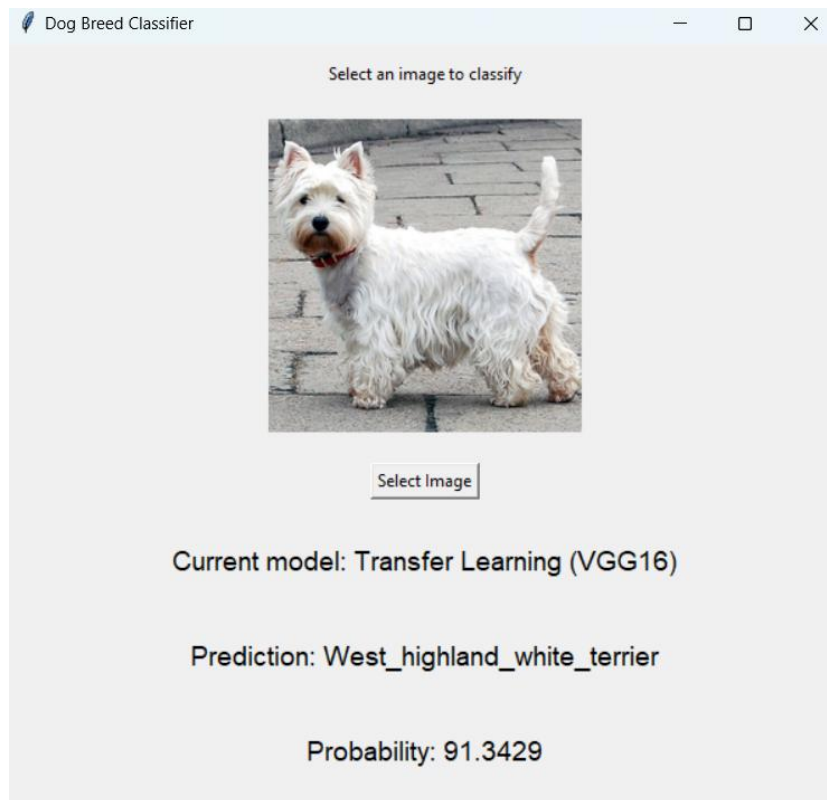


Рисунок 3.44 – Результат класифікації методом Transfer Learning (VGG16) для породи west highland white terrier

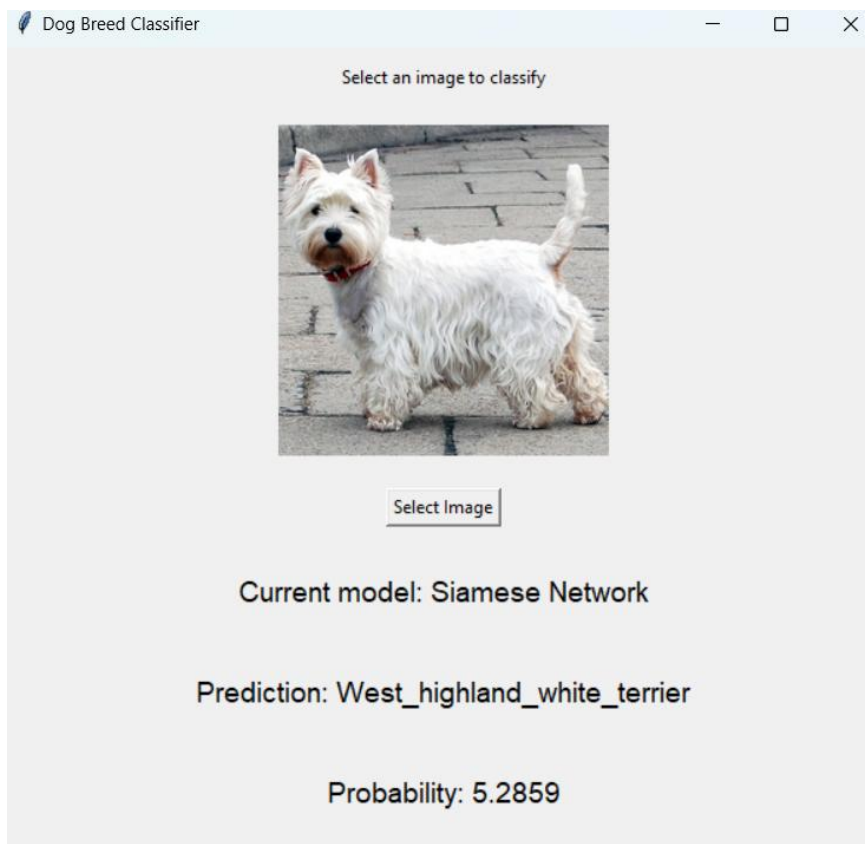


Рисунок 3.45 – Результат класифікації методом Siamese Networks для породи west highland white terrier

### 3.5 Критеріальний порівняльний аналіз досліджених методів класифікації мисливських порід собак на зображеннях

Таблиця 3.1 демонструє точність класифікації мисливських порід собаки у відсотковому значенні, усі перелічені породи було правильно класифіковано на зображеннях усіма трьома методами.

Таблиця 3.1 – Результати класифікації деяких порід із точністю у відсотковому значенні

Порода	Відсоток точності класифікації за методами, %		
	Prototypical Network	Transfer Learning (VGG16)	Siamese Networks
1	2	3	4
Dalmatian	94,5	95,1	13,2
Basenji	41,1	85	25,2
Gampre	90,2	88,8	8,6
Bloodhound	93,8	45	32,4
Hungarian otter	93,5	31,4	9,9
Beagle	73	87,5	6,1
Dachshund	39,7	65,7	9,5
Kerry blue terrier	98,7	84,6	4,2
Basset hound	93,4	87,7	4,7
Welsh terrier	99,4	75,6	4,5
Karelian bear dog	99,3	91	5,5
Afghan hound	73,7	96,2	20,7
Irish setter	67,2	61,3	29,1
West highland white terrier	68,9	91,3	5,3

Продовження таблиці 3.1

1	2	3	4
Jack russell terrier	62,9	81,4	9,8
Golden retriever	55	67,8	18,4
East siberian husky	58,3	50,5	16,1
English foxhound	61,8	69,9	21,9

Метод Prototypical Network демонструє в більшості стабільну якість класифікації. На основі аналізу результатів можна стверджувати, що метод більше орієнтується на форму об'єкта та частково на його колір. Проте, швидкість обробки зображень цим методом є найповільнішою серед розглянутих.

Метод Transfer Learning (VGG16) забезпечує найбільш високу швидкість роботи та високу якість класифікації, якщо кольори зображень відповідають характерним ознакам породи. Основна увага в процесі класифікації приділяється кольорам. Цей метод є перспективним для використання з великими наборами даних, але його ефективність також залежить від різноманітності еталонних зображень.

Метод Siamese Network працює повільніше за Transfer Learning і менш стабільно за Prototypical Network. Даний метод найменш «впевнено» класифікував породи собак. Класифікація часто орієнтується на пропорції та колір об'єкта. Покращення можливе за рахунок доопрацювання моделі й розширення еталонного набору.

Для всіх методів результативність класифікації залежить від якості та різноманітності навчального набору даних. Поліпшення роботи методів можливе за рахунок додавання більш різноманітних еталонних зображень у навчальний набір, що відображають різні ракурси й кольорові варіації мисливських порід. Розроблений десктоп-застосунок дозволяє тестувати методи класифікації та порівнювати їхні результати, надаючи користувачу зручний інструмент для експериментів.

Загалом середнє значення точності у відсотках для методу Prototypical Network дорівнює 75,8, для методу Transfer Learning – 75,3, для методу Siamese Networks – 13,6.

Найвищий відсоток точності класифікації був помічений під час користування методом Prototypical Network і сягав 99,4 %, але класифікація цим методом відбувалася набагато повільніше аніж двома іншими методами. Метод Transfer Learning (VGG16) відпрацьовував найшвидше та продемонстрував найстабільніші чудові результати. Результати випробування методу Siamese Networks виявилися найгіршими. Єдиною перевагою методу Siamese Networks над Prototypical Network є швидкість.

Отже, серед трьох методів класифікації мисливських порід собак на зображеннях Prototypical Network та Transfer Learning (VGG16) показали кращі результати за Siamese Networks. Можна зробити висновок, що при потребі швидкої класифікації слід використовувати метод Transfer Learning (VGG16). Метод Prototypical Network також дає досить точну відповідь, але набагато повільніше за Transfer Learning (VGG16).

### 3.6 Перспективи подальшої роботи

Розроблений десктоп-застосунок демонструє значний потенціал для автоматизації процесу класифікації мисливських порід собак. Водночас існує низка напрямків для вдосконалення та розширення функціоналу програми, що відкривають перспективи для подальших досліджень і практичного застосування.

Перспективи роботи:

– покращення точності класифікації. Незважаючи на задовільні результати роботи застосунку, рівень точності не завжди досягає бажаного значення (наприклад, 90% і більше). Досягнення стабільно високої точності класифікації можна забезпечити шляхом удосконалення навчального набору,

що включає додавання більш різноманітних еталонних зображень, які відображають різні ракурси, кольорові варіації, а також специфічні характеристики кожної породи;

- модернізація реалізованих методів. Удосконалення реалізованих методів передбачає поліпшення алгоритмів навчання, адаптацію параметрів моделей та використання новітніх технік оптимізації. Це дозволить підвищити продуктивність і зменшити похибки класифікації;

- додаткові перевірки для покращення універсальності програми. Реалізація перевірок для складних випадків, таких як наявність кількох собак на одному зображенні, присутність собак не представлених у наборі даних, або об'єктів, які не є собаками, підвищить надійність застосунку;

- розширення функціоналу застосунку. У перспективі можливим є впровадження класифікації інших категорій порід собак, (наприклад, декоративних, службових). Такий підхід зробить програму універсальним інструментом для кінологів, ветеринарів та любителів собак;

- збільшення кількості методів класифікації. Включення нових методів машинного навчання сприятиме підвищенню точності класифікації та дозволить порівнювати різні підходи з точки зору продуктивності та швидкодії. Це також надасть користувачам більше можливостей для вибору найефективнішого методу під конкретні задачі;

- просування застосунку серед користувачів. Маркетингові заходи, спрямовані на популяризацію програми серед кінологів, ветеринарів, власників собак та організацій, зацікавлених у автоматизованій ідентифікації порід, сприятимуть розширенню аудиторії. Впровадження застосунку в спеціалізовані виставки, кінологічні клуби або ветеринарні клініки може значно підвищити його практичну цінність.

Запропоновані напрями розвитку програми створюють основу для її масштабування, поліпшення користувацького досвіду та збільшення сфери застосування у різних галузях.

## ВИСНОВКИ

У рамках кваліфікаційної роботи було проведено дослідження методів Prototypical Network, Transfer Learning з Pretrained CNN (на основі VGG16) та Siamese Networks шляхом програмної реалізації десктоп-застосунку, що надає можливість класифікувати мисливські породи собак на зображеннях.

Зокрема проведено аналіз сучасних методів класифікації об'єктів на зображеннях за допомогою ознайомлення із літературними джерелами щодо апробації результатів застосування таких методів, прийнято рішення про актуальність та доцільність реалізації застосунку класифікації мисливських порід собак.

Досліджено методи Prototypical Network, Transfer Learning з Pretrained CNN та Siamese Networks, побудовано покроковий алгоритм для кожного з методів та візуалізовано алгоритми за допомогою блок-схем.

Створено власноручний унікальний набір даних, що включає 52 класи, кожен із яких відповідає окремій породі собак. Для кожного класу відібрано по 15 еталонних зображень, що дозволяє сформувати збалансований набір даних для навчання та тестування вибраних методів класифікації. Проведено тестування десктоп-застосунку та порівняння результатів класифікації порід кожним із трьох методів.

Розроблено зручний зрозумілий користувацький інтерфейс, за допомогою якого юзер має змогу обрати одну з трьох моделей та зображення із провіднику, після чого застосунок визначає породу собаки із точністю класифікації у відсотковому значенні.

Наукова новизна роботи полягає у порівнянні результатів спрацювання трьох методів щодо класифікації мисливських порід собак на зображенні, що дозволило зробити висновки стосовно їх ефективності в умовах реальних завдань. Такий підхід сприяє глибшому розумінню можливостей сучасних методів класифікації об'єктів та їхньому впровадженню в практичні застосунки.

Результати дослідження апробовано у вигляді тез доповіді під час XI Міжнародної науково-практичної конференції «MODERN GENERATION: CURRENT PROBLEMS, EXPERIENCE, DEVELOPMENT PROSPECTS» [42].

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Daradkeh Y.I., Gorokhovatskyi V., Tvoroshenko I., and Al-Dhaifallah M. (2022) Classification of Images Based on a System of Hierarchical Features, *Computers, Materials & Continua*, 72(1), pp. 1785-1797.
2. Yakovleva O., Matúšová S., Tvoroshenko I., and Isaiev Y. (2024) Visitor counting based on video stream analysis from surveillance cameras to solve various business problems, *Verejná správa a regionálny rozvoj ekonómia, manažment a marketing*, XX(1), pp. 67-87.
3. Gorokhovatskyi, V., Tvoroshenko, I., Kobylin, O., & Vlasenko, N. (2023). Search for visual objects by request in the form of a cluster representation for the structural image description, *Advances in Electrical and Electronic Engineering*, 21(1), pp. 19-27.
4. Tvoroshenko I., Gorokhovatskyi V., Kobylin O., and Tvoroshenko A. (2023) Application of deep learning methods for recognizing and classifying culinary dishes in images, *International Journal of Academic and Applied Research*, 7(9), pp. 57-70.
5. Snell, J., Swersky, K., & Zemel, R. (2017). Prototypical networks for few-shot learning. *Advances in neural information processing systems*, 30.
6. Як працює класифікація зображень? URL: <https://www.unite.ai/uk/%D1%8F%D0%BA-%D0%BF%D1%80%D0%B0%D1%86%D1%8E%D1%94-%D0%BA%D0%BB%D0%B0%D1%81%D0%B8%D1%84%D1%96%D0%BA%D0%B0%D1%86%D1%96%D1%8F-%D0%B7%D0%BE%D0%B1%D1%80%D0%B0%D0%B6%D0%B5%D0%BD%D1%8C/> (дата звернення 02.10.2024).
7. A friendly introduction to Siamese Networks. URL: <https://towardsdatascience.com/a-friendly-introduction-to-siamese-networks-85ab17522942> (дата звернення 03.10.2024).

8. Yadav, R. R., Mishra, M. A., Mahato, A. K., Chaudhary, N., & Sharma, S. (2024). Dog Breeds Classifier.
9. Гороховатський В., Передрій О., Творошенко І., Марков Т. (2023) Матриця відстаней для множини компонентів структурного опису як інструмент для створення класифікатора зображень, *Сучасні інформаційні системи*, 7(1), С. 5-13.
10. Gorokhovatskyi V., Tvoroshenko I., Yakovleva O., Hudáková M., and Gorokhovatskyi O. (2024) Application a committee of Kohonen neural networks to training of image classifier based on description of descriptors set, *IEEE Access*, vol. 12, pp. 73376-73385.
11. Lim, J. Y., Lim, K. M., Lee, C. P., & Tan, Y. X. (2024). SSL-ProtoNet: Self-supervised Learning Prototypical Networks for few-shot learning. *Expert Systems with Applications*, 238, 122173.
12. Kishore, P. Y. N. D., & Gohin, B. Deep Learning Models-Based Dog Breed Recognition System.
13. Pomazan V., Tvoroshenko I., and Gorokhovatskyi V. (2023) Handwritten character recognition models based on convolutional neural networks, *International Journal of Academic Engineering Research*, 7(9), pp. 64-72.
14. Singh, A., Kothari, R., & Arulalan, V. (2024, April). Dog Breed Detection using YOLOv7 and WOA-CNN. In *2024 10th International Conference on Communication and Signal Processing (ICCSP)* (pp. 1477-1482). IEEE.
15. Sarvakar, K., Salot, P., Pancholi, P., & Gondalia, A. Multi-View Dog Breed Classification: Integrating Image-Based and Metadata Approaches with Machine Learning.
16. Amirhosseini, M. H., Yadav, V., Serpell, J. A., Pettigrew, P., & Kain, P. (2024). An artificial intelligence approach to predicting personality types in dogs. *Scientific Reports*, 14(1), 2404.
17. Daradkeh Y.I., Gorokhovatskyi V., Tvoroshenko I., and Zeghid M. (2022) Cluster representation of the structural description of images for effective classification, *Computers, Materials & Continua*, 73(3), pp. 6069-6084.

18. Villaluz, A. C., De Goma, J. C., Besa, J. V. T., Ignacio, J. I. D., & Zaguirre, S. A. A. (2024, February). Emotion Classification in Domestic Dogs Using Computer Vision Based on the Dog's Body and Face. In *Proceedings of the 2024 9th International Conference on Intelligent Information Technology* (pp. 359-364).
19. VISHWAKARMA, M., JANGID, K., PAL, K., & RODRIGUES, L. (2024). Cat Breed & Emotion Detection Using Yolo, CNN & Canny Edge Detection.
20. Roy, A. M., Bhaduri, J., Kumar, T., & Raj, K. (2023). WilDect-YOLO: An efficient and robust computer vision-based accurate object localization model for automated endangered wildlife detection. *Ecological Informatics*, 75, 101919.
21. Tvoroshenko I., and Gorokhovatskyi V. (2022) The Application of Hybrid Intelligence Systems for Dynamic Data Analysis, *International Journal of Engineering and Information Systems*, 6(2), pp. 40-48.
22. Колесникова, М. В. (2023). *Дипломна кваліфікаційна робота магістра на тему «Мобільний застосунок для розпізнавання загублених тварин»* (Master's thesis, Національний університет «Запорізька політехніка»).
23. Соловей, І. В. (2023). Розпізнавання порід котів у програмній системі обліку домашніх тварин.
24. Daradkeh Y.I., Gorokhovatskyi V., Tvoroshenko I., and Zeghid M. (2024) Improving the effectiveness of image classification structural methods by compressing the description according to the information content criterion, *Computers, Materials & Continua*, vol. 80, no. 2, pp. 3085-3106.
25. Törnqvist, H., Höller, H., Vsetecka, K., Hoehl, S., & Kujala, M. V. (2023). Matters of development and experience: Evaluation of dog and human emotional expressions by children and adults. *PloS one*, 18(7), e0288137.

26. Pomazan, V., Tvoroshenko, I., & Gorokhovatskyi, V. (2023). Development of an application for recognizing emotions using convolutional neural networks, *International Journal of Academic Information Systems Research*, 7(7), pp. 25-36.
27. Мануйлова, Н. Я. (2019). Розробка та дослідження методу ідентифікації порід котів за їх зображенням.
28. Gorokhovatskyi V., Tvoroshenko I. (2023) Identification of visual objects by the search request. *International scientific symposium «INTELLIGENT SOLUTIONS-S». Computational intelligence (results, problems and perspectives). Decision making theory: proceedings of the international symposium, September 28, 2023, Kyiv-Uzhorod, Ukraine*, pp. 25-27.
29. Fedele, A., Guidotti, R., & Pedreschi, D. (2024). Explaining Siamese networks in few-shot learning. *Machine Learning*, 1-38.
30. Gorokhovatskyi V., Tvoroshenko I., and Yakovleva O. (2024) Transforming image descriptions as a set of descriptors to construct classification features, *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 33, no. 1, pp. 113-125.
31. Valero-Mas, J. J., Gallego, A. J., & Rico-Juan, J. R. (2024). An overview of ensemble and feature learning in few-shot image classification using siamese networks. *Multimedia Tools and Applications*, 83(7), 19929-19952.
32. Daradkeh Y.I., Gorokhovatskyi V., Tvoroshenko I., Gadetska S., and Al-Dhaifallah M. (2023) Statistical data analysis models for determining the relevance of structural image descriptions, *IEEE Access*, vol. 11, pp. 126938-126949.
33. Tvoroshenko I., Pomazan V., Gorokhovatskyi V., and Kobylin O. (2023) Application of video data classification models using convolutional neural networks, *International Journal of Academic and Applied Research*, 7(11), pp. 134-145.
34. What Is Transfer Learning? Exploring the Popular Deep Learning Approach. URL: <https://builtin.com/data-science/transfer-learning> (дата звернення 22.10.2024).

35. Гороховатський В.О., Творошенко І.С., Чмутов Ю.В. (2022) Застосування систем ортогональних функцій для формування простору ознак у методах класифікації зображень, *Сучасні інформаційні системи*, 6(3), С. 5-12.

36. PyTorch documentation. URL: <https://pytorch.org/docs/stable/index.html> (дата звернення 14.11.2024).

37. Welcome to PyTorch Tutorials. URL: <https://pytorch.org/tutorials/> (дата звернення 14.11.2024).

38. Module: tf.keras. URL: [https://www.tensorflow.org/api\\_docs/python/tf/keras](https://www.tensorflow.org/api_docs/python/tf/keras) (дата звернення 15.11.2024).

39. TensorFlow Core. URL: <https://www.tensorflow.org/tutorials> (дата звернення 15.11.2024).

40. Мисливські породи собак. URL: <https://home-animal.org.ua/mislivski-porodi-sobak/> (дата звернення 11.11.2024).

41. Мисливські Породи Собак: Повний Перелік та Огляд Найпопулярніших Представників. URL: <https://aboutdogs.com.ua/blog/myslyvski-porody-sobak> (дата звернення 11.11.2024).

42. Корякіна С., Творошенко І.С. (2024) Особливості методу SIAMESE NETWORKS щодо його застосування до задачі класифікації об'єктів на зображеннях, *Abstracts of XI International Scientific and Practical Conference «Modern generation: current problems, experience, development prospects»*, (November 12 – 15, 2024). Seville, Spain, pp. 386-390.