

УДК 616.5-006.81 + 004.8

КЛАСИФІКАЦІЯ УРАЖЕНЬ ШКІРИ НА ОСНОВІ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ

Климчук М.І., магістр
klymchuk.mariya@gmail.com
Сердаковський В.С., ст. викл.
v.serdakovskiy@kpi.ua

Національний технічний університет України «Київський
політехнічний інститут імені Ігоря Сікорського»
Київ, Україна

Реферат – *Проблематика.* Незважаючи на таку величезну кількість сучасних винаходів в області медицини та інформаційних технологій, боротьба з таким захворюванням як рак, все ще продовжується. Найпоширенішим видом раку залишається рак шкіри. Хоча рівень захворюваності на меланому становить лише близько одного відсотка випадку раку шкіри, але дана форма являється найбільш небезпечною, і може призвести до летальних наслідків. Завдяки численним дослідженням, які були проведені за останній час, лікарі запевняють, що при виявленні ознак захворювання меланоми на ранніх стадіях у 90% випадків призводить до позитивних результатів.

Тому на сьогодні, задача ранньої діагностики раку шкіри є досить актуальною. Традиційно лікарі дерматологи застосовують мікроскоп, та взяття біопсії у пацієнтів, для того щоб проаналізувати стан родимки. Однак, такий процес діагностики є досить непростим та потребує висококваліфікованих спеціалістів. Тому, постає задача полегшити процес діагностики, та підвищити точність її результатів. Для цього, широко застосовуються методи штучного інтелекту, а саме: проводять діагностику медичних зображень шкіри на наявність меланоми, застосовуючи глибинне навчання.

Мета. Метою роботи є побудова моделей, та аналіз отриманих експериментів.

Методика реалізації. Відповідно до поставленої мети, було побудовано згорткові нейронні мережі: з використанням методики трансферного навчання.

Для навчання моделі, було використано 33 126 унікальних доброякісних та злоякісних дерматоскопічних зображень шкіри. Даний набір даних було створено Міжнародною колаборацією з візуалізації шкіри (ISIC), зображення були взяті з наступних джерел: Університет Квінсленда, Віденський медичний університет, Медична школа Афіньського університету, клінічна лікарня Барселони, Меморіальний онкологічний центр Слоуна Кеттерінга та Австралійський інститут меланоми [9].

Результати дослідження. Загальна вибірка була розбита у співвідношенні 80% на навчання, 10% на тест та 10% на валідацію. Для дослідження були використані такі архітектури згорткових нейронних мереж: Xception, ResNet50, ResNet101, InceptionV3, VGG16. Були отримані результати експериментів, які показали, що Модель Xception на тестовій вибірці має такі значення: AUC та Precision 86%, Recall: 96%, F1-score: 88%. Модель InceptionV3 на тестовій вибірці має такі значення: AUC: 88%, Precision 84%, Recall: 96%, F1-score: 87%. Модель ResNet50 на тестовій вибірці має такі значення: AUC: 87% та Precision 82%, Recall: 91%, F1-score: 86%. Модель ResNet101 на тестовій вибірці має такі значення: AUC: 77% та Precision 72%, Recall: 76%, F1-score: 73%. Модель VGG16 на тестовій вибірці має такі значення: AUC: 83% та Precision 71%, Recall: 74%, F1-score: 72%.

Висновки. В результаті були побудовані досить якісні моделі класифікації, які можна застосовувати у програмних застосунках по діагностиці стану шкіри.

Ключові слова – *Машинне навчання, згорткові нейронні мережі, меланома, рак шкіри, діагн*

I. ВСТУП

Ми живемо в епоху найстрімкішого розвитку інформаційних технологій, медицини, фармацевтики, телемедицини. В минулому такі захворювання як грип, пневмонія, астма, зубний чи головний біль, гастрит, серцеві захворювання вважалися складними у лікуванні, через нестачу ліків та технологій, і тому могли привести до смертельних наслідків. Незважаючи на стрімкий розвиток

інноваційних технологій, питання лікування та діагностики раку все ще залишається актуальним. Рак шкіри вважається найпоширенішим серед інших видів раку. За даними міжнародного агентства з дослідження раку, за 2020 рік від меланоми загинуло 57 043 людини [1].

Безконтрольний поділ та мутації клітин меланоцитів призводять до появи меланоми. Меланоми можуть виникати на будь-якій

ділянці шкіри. За даними статистичних досліджень, у чоловіків найчастіше меланоми уражують спину та груди, у жінок – область ніг. Чоловіки частіше хворіють на меланому, порівняно з жінками. Але незалежно від статті, в зоні ризику знаходяться люди у віці від 70 до 90 років. Так як меланоцити у людей з темним кольором шкіри виробляють більше меланіну, вплив ультрафіолетового випромінювання зменшується, тому ризик появи захворювання меланоми у людей зі світлою шкірою є вищим [2]. Меланому дуже складно розпізнати на початкових стадіях. Перші ознаки є візуальними: новоутворення на шкірі, які змінюють розмір, колір чи форму. Попереджувальні ознаки виявлення меланоми називають аббревіатурою «ABCDE» [3]. За допомогою даної шкали з п'яти характеристик можливо провести аналіз на наявність або відсутність ознак меланоми. Існують різні методи діагностики меланом. Серед них, інвазійні методи, такі як гістопатологічне дослідження біопсії шкіри, та неінвазійні методи, такі як дерматоскопія. Однак кожен з них має свої недоліки. Перший метод носить болісний характер, і необхідність повторних проб є одним з основних обмежень для біопсії шкіри. Основні проблеми з якими стикається другий метод – це вартість, доступність та компетентність лікарів. Тому, у зв'язку з обмеженою кількістю висококваліфікованих спеціалістів, наявність точних інструментів має велике значення для лікарів дерматологів, що дозволяє отримувати досить хороші діагностичні результати, покращити процес лікування та зменшити кількість взяття біопсії у пацієнтів.

В ході роботи, була розглянута роль методів штучного інтелекту, які можуть допомогти виявляти хворобу на ранніх стадіях, тим самим збільшити ефективність діагностики та лікування. Штучний інтелект допомагає вирішувати різні проблеми, з якими ми стикаємось сьогодні, і задачі, які постають у сфері охорони здоров'я не є виключенням. До методів штучного інтелекту відносяться машинне та глибинне навчання. Одним із класів глибинних нейронних мереж є згорткові нейронні мережі [4]. Вони широко застосовуються для аналізу зображень, включаючи і медичні зображення. Одним з прикладів є діагностика зображень шкіри на

наявність меланом, які розглядаються в даній статті. Таким чином, використання згорткових нейронних мереж, може забезпечити якісні та точні результати діагностики раку шкіри. Завдяки стрімкому розвитку машинного навчання, на сьогодні, існує чимала кількість веб-сервісів та мобільних додатків, за допомогою яких можна самостійно проводити діагностику шкіри, не виходячи з дому. Це дозволяє людям на ранніх стадіях виявляти злоякісну родимку та вчасно звертатися до лікарів.

II. ПОСТАНОВКА ЗАДАЧІ

Метою даної роботи є побудова моделей класифікації уражень шкіри на основі згорткових нейронних мереж, та аналіз отриманих результатів експериментів.

III. ОПИС КЛІНІЧНИХ ДАНИХ

Для вирішення поставленої задачі, були використані данні Міжнародної колаборації з візуалізації шкіри (ISIC) [9]. Для дослідження було використано 33 126 унікальних доброякісних та злоякісних дерматоскопічних зображень шкіри у форматі «JPEG».

На рис. 1. продемонстровано приклад зображень доброякісних родимок.




Рис. 1. Зображення доброякісних родимок

На рис. 2. продемонстровано приклад зображень злоякісних родимок.




Рис. 2. Зображення злоякісних родимок

Набір даних, складається з таких ознак:

- image_name: унікальний ідентифікатор зображення
- patient_id: унікальний ідентифікатор пацієнта
- sex: стать пацієнта
- age_approx: вік пацієнта
- anatom_site_general_challenge: місцезнаходження зображення (torso – тулуб, lower extremity – нижня кінцівка, upper extremity – верхня кінцівка, head\neck – голова\шия, palms\soles – долоні\підшви)
- diagnosis – інформація про діагностику
- benign_malignant – показник доброякісного та злоякісного ураження
- target – цільова змінна

Таким чином, формулюючи завдання побудови бінарного класифікатора, першим класом є «benign» доброякісна родимка, а другим класом є «malignant» злоякісна родимка. Відношення цих двох класів є нерівномірним, це буде враховано при подальшому дослідженні.

Для навчання моделі було виділено 26 529 зображень, для тестової вибірки – 3286 зображень, та для валідаційної вибірки – 3311 зображень.

На рис. 3. продемонстровано перші п'ять рядків навчального набору даних.

	image_name	patient_id	sex	age_approx	anatom_site_general_challenge	diagnosis	benign_malignant	target
0	ISIC_2637011	IP_7279968	male	45.0	head/neck	unknown	benign	0
1	ISIC_0015719	IP_3075186	female	45.0	upper extremity	unknown	benign	0
2	ISIC_0052212	IP_2842074	female	50.0	lower extremity	nevus	benign	0
3	ISIC_0068279	IP_6890425	female	45.0	head/neck	unknown	benign	0
4	ISIC_0074268	IP_8723313	female	55.0	upper extremity	unknown	benign	0

Рис. 3. Початковий набір даних

На рис. 4. продемонстровано перші п'ять рядків тестового набору даних.

	image_name	patient_id	sex	age_approx	anatom_site_general_challenge
0	ISIC_0052060	IP_3579794	male	70.0	NaN
1	ISIC_0052349	IP_7782715	male	40.0	lower extremity
2	ISIC_0058510	IP_7960270	female	55.0	torso
3	ISIC_0073313	IP_6375035	female	50.0	torso
4	ISIC_0073502	IP_0589375	female	45.0	lower extremity

Рис. 4. Тестовий набір даних

На рис. 5. продемонстровано розподіл за ознакою «benign-malignant», де кількість доброякісних зображень переважає кількість злоякісних.

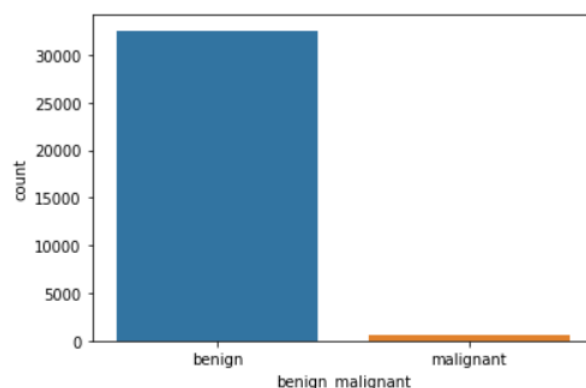


Рис. 5. Розподіл за ознакою «benign-malignant»

На рис. 6. продемонстровано розподіл за ознакою «sex», де кількість чоловіків ненабагато переважає кількість жінок у наборі даних.




Рис. 6. Розподіл за ознакою «sex»

На рис. 7. продемонстровано розподіл за ознакою «age_approx». З графіку можна побачити, що вік відповідає нормальному розподілу, а також, що найбільша ймовірність виникнення меланоми у віці від 20 до 70 років.




Рис. 7. Розподіл за ознакою «age_approx»

На рис. 8. представлена матриця кореляцій. Можна бачити, що кореляція між змінними є слабкою або середньою, тому дані можна використовувати для подальшого аналізу.

sex	1	0.13	0.024	-0.039	0.028
age_approx	0.13	1	-0.034	-0.076	0.085
anatom_site_general_challenge	0.024	-0.034	1	-0.0012	-0.0096
diagnosis	-0.039	-0.076	-0.0012	1	-0.38
target	0.028	0.085	-0.0096	-0.38	1
	sex	age_approx	anatom_site_general_challenge	diagnosis	target

Рис. 8. Матриця кореляції між змінними

IV. МАТЕРІАЛИ ТА МЕТОДИ ДОСЛІДЖЕННЯ

Було обрано п'ять архітектур моделей глибинного навчання, для того, щоб дослідити відмінності в їх продуктивності та визначити найбільш ефективну модель глибинного навчання для задачі класифікації. Глибинне навчання являється експериментальною наукою, тому потрібно проводити досить велику кількість експериментів з архітектурами та гіперпараметрами нейронних мереж.

При навчанні глибоких мереж розв'язання задачі класифікації з нуля має низку складнощів. По-перше, необхідно створювати великий навчальний набір розмічених зображень, наприклад, як ImageNet. По-друге, з технічного боку складність полягає у підключенні великих обчислюваних ресурсів, щоб завершити процес навчання у прийнятний час. Описані вище проблеми дозволяє вирішувати техніка трансферного навчання. Даний метод, дозволяє використовувати попередньо навчені моделі, навіть на інших наборах даних для побудови класифікатора зображень меланом. Трансферне навчання дозволяє повторно натренувати останній шар мережі, з використанням власного набору зображень, не змінюючи ваги інших шарів та, при цьому, досягати необхідної точності моделі.

ResNet або Residual Network є одним з типів згорткових нейронних мереж. Основним

елементом ResNet є залишковий блок зі швидким з'єднанням. Res-блок представляє собою декілька згорткових шарів з активаціями, які перетворюють вхідний сигнал x в $F(x)$.

На рис. 9. представлена схема з'єднання швидкого доступу [10, 11].




Рис. 9. Приклад з'єднання швидкого доступу

ResNet50 – це 50-шарова згорткова нейронна мережа, яка складається з 48 згорткових шарів, одного max-pooling шару та одного повнозв'язного шару для класифікації.

ResNet101 – працює за тим самим принципом, що і ResNet50. Дана мережа складається з 101 шару, тому він може апроксимувати більш складні залежності між вхідними та вихідними даними, у порівнянні з ResNet50.

У таблиці 1. продемонстровано архітектури ResNet50 та ResNet101 [10, 11].

Таблиця 1. Архітектури згорткових нейронних мереж ResNet50 та ResNet101.

Layer Name	Output Shape	50-Layers	101-Layers
conv1	112x112	7x7, 64, stride 2	7x7, 64, stride 2
conv2_x	56x56	3x3 max pool, stride 2	3x3 max pool, stride 2
		$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28x28	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
conv4_x	14x14	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$
conv5_x	7x7	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1x1	3x3 average pool, 1000-d fc	3x3 average pool, 1000-d fc

VGG16 – базується на 16-рівневій архітектурі VGG. Він складається з 5 блоків згортки та кількох повнозв'язаних шарів. Перші 2 блоки згортки мають по 2 шари, а інші 3 блоки згортки – по 3 шари. Операція згортки

використовує ядро розміром 3x3. Ці шари згортки автоматично вилучають характерні ознаки із зображень. Після кожного шару згортки «ReLU» використовується як функція активації. Після кожного блоку згортки є шар «max-pooling», загалом 5 таких шарів. Кожна операція «pooling» виконується ядром розміром 2x2 із кроком 2 і без доповнення. Наприкінці є три повнозв'язні шари. Перші два з них мають по 4096 каналів кожен, а останній шар має 1000 каналів.

У таблиці 2. продемонстровано архітектуру VGG16 [11].

Таблиця 2. Архітектура згорткової нейронної мережі VGG16.

Layer Name	Output Shape	16 Weight Layers
block1_convx	224x224	conv3-64
		conv3-64
block1_pool	112x112	maxpool
block2_convx	112x112	conv3-128
		conv3-128
block2_pool	56x56	maxpool

Продовж. табл. 2

block3_convx	56x56	conv3-256
		conv3-256
		conv3-256
		-
block3_pool	28x28	maxpool
block4_convx	28x28	conv3-512
		conv3-512
		conv3-512
		-
block4_pool	14x14	maxpool
block5_convx	14x14	conv3-512
		conv3-512
		conv3-512
		-
block5_pool	7x7	maxpool
		FC-4096
		FC-4096
		FC-1000
		soft-max

InceptionV3 – відрізняється від архітектури мережі VGG тим, що містить ключовий компонент, який називається початковим модулем. Цей модуль використовує різні розміри рецептивних ядер. Вихідний розмір операції згортки підтримується узгодженим за допомогою нульового доповнення. Остаточні карти об'єктів отримуються шляхом об'єднання фільтрів. Початкова операція допомагає отримати більш складні функції з

вхідного зображення. На рис. 10. продемонстровано структуру початкового модуля [12].

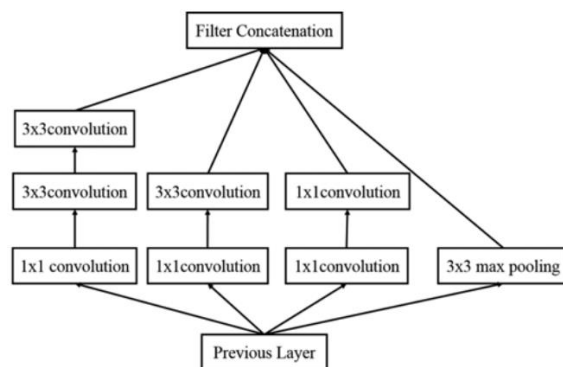


Рис. 10. Приклад початкового модуля

У таблиці 3. продемонстровано архітектуру InceptionV3 [12].

Таблиця 3. Архітектура згорткової нейронної мережі InceptionV3.

Type	Kernel size/stride	Input size
Convolution	3x3/2	299x299x3
Convolution	3x3/1	149x149x32

Продовж. табл. 3

Convolution	3x3/1	147x147x64
Pooling	3x3/2	147x147x64
Convolution	3x3/1	73x73x64
Convolution	3x3/2	71x71x80
Convolution	3x3/1	35x35x192
Inception module	Three modules	35x35x288
Inception module	Five modules	17x17x768
Inception module	Two modules	8x8x1280
Pooling	8x8	8x8x2048
Linear	Logits	1x1x2048
Softmax	Output	1x1x1000

Xception – це архітектура глибокої згорткової нейронної мережі, яка включає згортки, що розділяються по глибині, за якими слідує повністю пов'язані шари для класифікації. Дані спочатку проходять через вхідний потік (entry flow), потім через середній потік (middle flow), який повторюється вісім разів, і, нарешті, через вихідний потік (exit flow). Після всіх шарів згортки та роздільної згортки виконується пакетна нормалізація. Архітектура Xception перевершує VGG-16, ResNet і InceptionV3 у більшості класичних завдань класифікації.

На рис. 11. продемонстровано архітектуру Xception [13, 14].

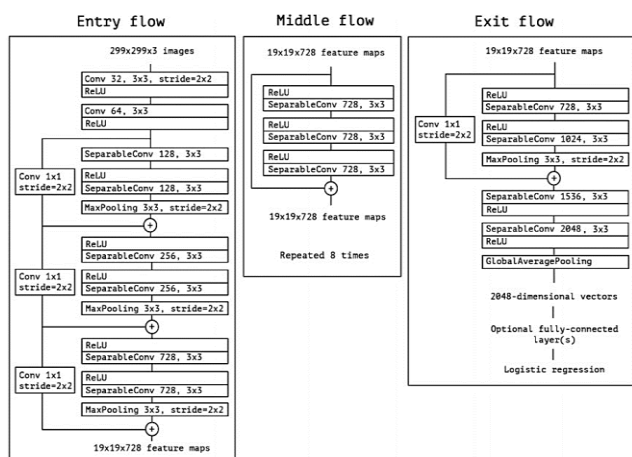


Рис. 11. Архітектура згорткової нейронної мережі Xception

Для задачі побудови бінарного класифікатора були використані попередньо навчені моделі, згідно трансферного навчання, в якості базової конфігурації моделі. На рис. 12. продемонстровано обчислюваний підхід глибокого навчання для розрізнення зображень родимок від меланом.




Рис. 12. Обчислювальна структура глибокого навчання для розрізнення зображень родимок від меланом

Дані було розділено на навчальну, валідаційну та тестову вибірки у співвідношенні: 80\10\10. Перший набір даних використовується для навчання мережі, другий набір використовується для моніторингу та покращення продуктивності моделі під час процесу навчання, а третій – для тестування навченої моделі (рис. 13).



Рис. 13. Розподіл набору даних на навчання, валідацію та тестування.

Експерименти проводилися з використанням ресурсів Kaggle GPU на мові програмування Python, включаючи такі бібліотеки: numpy, pandas, seaborn, tensorflow, matplotlib.

Згідно з метою роботи одна з задач полягала у виділенні загальних характеристик зображення та прогнозування його належності до цільової категорії. Даний підхід отримує ознаки з зображення та перетворює їх у нове зображення, при цьому зменшуючи його розміри, яке є більш ефективним для класифікації. На початку дані зчитувалися з файлу набору даних, потім розмір зображень було перетворено до 299x299 пікселів для вилучення ознак.

Для вирішення проблеми локального зберігання великого масиву даних використовувалась технологія «ImageDataGenerator». Вона дала можливість застосувати аугментацію до вхідних зображень – це процес генерації нових зображень з вхідних, шляхом зміни їх розміру, положення, дзеркального відображення. Даний процес дозволив збільшити об'єм вхідних даних, що неодмінно допомогло зробити моделі більш робастними.

Окрім цього була застосована технологія адаптивної зміни параметру швидкості навчання мережі. Ця технологія дозволяє прискорити збіжність алгоритму оптимізації. В якості алгоритму оптимізації було обрано «Adam», а в якості функції помилки – «BinaryCrossEntropy». Дані гіперпараметри є досить поширеними для вирішення подібних задач класифікації.

Для оцінки якості моделей класифікації зображень були використані такі метрики: матриця помилок, precision, recall, AUC-ROC, F1-score.

V. РЕЗУЛЬТАТИ ДОСЛІДЖЕНЬ

Розглянемо результати проведених експериментів, для кожної з моделей. У таблиці 4, представлені метрики AUC на тестовій, навчальній та валідаційній вибірках для кожної з архітектур.

Таблиця 4. Значення метрики AUC на тестовій, валідаційній та навчальній вибірках по кожній з архітектур.

Архітектура	AUC train	AUC validate	AUC test
Xception	0.92	0.83	0.86
InceptionV3	0.89	0.84	0.88
ResNet50	0.86	0.81	0.87
ResNet101	0.73	0.76	0.77
VGG16	0.82	0.80	0.83

На рис. 14 представлені графіки ROC-кривої на валідаційному наборі для кожної з архітектур.

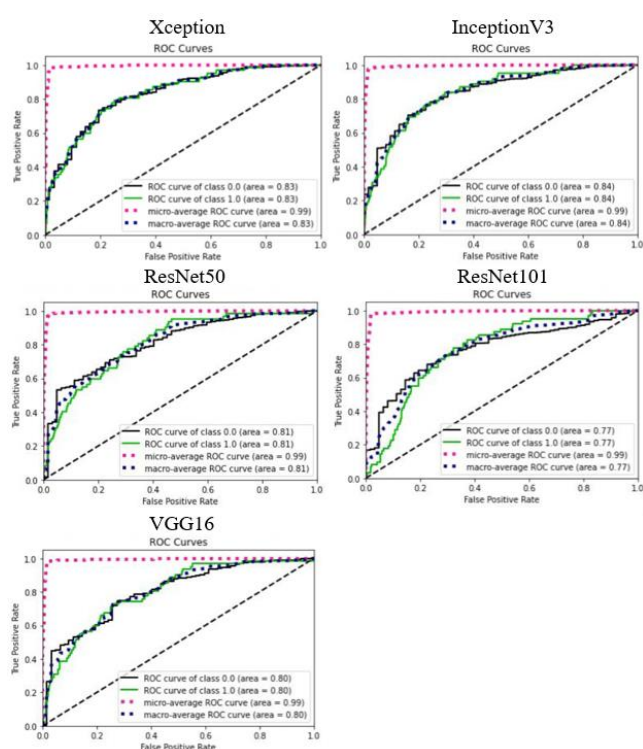


Рис. 14. Графіки ROC-кривої на валідаційному наборі даних по кожній моделі

Матриця помилок застосовується для вимірювання загальної ефективності класифікації.

TP – означає, що модель класифікації правильно передбачила позитивний результат. Тобто зображення доброякісної родимки, були вірно розпізнані як доброякісна родимка.

TN – означає, що модель класифікації правильно передбачила негативний результат. Тобто зображення меланоми, були вірно розпізнані як меланома.

FP – означає, що модель класифікації передбачила позитивний результат, хоча

насправді він є негативним. Тобто доброякісні родимки, були хибно передбачені як меланома.

FN – означає, що модель класифікації передбачила помилковий результат, хоча насправді він є позитивним. Тобто, зображення меланоми були хибно передбачені як зображення доброякісної родимки.

Правильно передбачені результати дорівнюють: TP+TN. Не правильно класифіковані результати дорівнюють: FP+FN.

У моделі Xception: правильно передбачені результати склали: 2939, а не правильно класифікованих - 15.

У моделі InceptionV3: правильно передбачені результати склали: 3033, а не правильно класифікованих - 17.

У моделі ResNet50: правильно передбачені результати склали: 3039, а не правильно класифікованих - 19.

У моделі ResNet101: правильно передбачені результати склали: 2555, а не правильно класифікованих - 36.

У моделі VGG16: правильно передбачені результати склали: 2446, а не правильно класифікованих - 37.

У таблиці 5, продемонстровані метрики матриці помилок на тестовій вибірці.

Таблиця 5. Значення метрики матриці помилок на тестовій вибірці по кожній з архітектур.

Архітектура	TP	FP	FN	TN
Xception	2877	10	5	62
InceptionV3	2971	12	5	62
ResNet50	2978	13	6	61
ResNet101	2504	20	16	51
VGG16	2396	20	17	50

У таблиці 6, продемонстровано результати метрик F1-score, precision та recall для всіх архітектур на тестовій вибірці.

Таблиця 6. Значення метрик F1-score, precision та recall на тестовій вибірці по кожній з архітектур.

Архітектура	Precision	Recall	F1-score
Xception	0.86	0.92	0.88
InceptionV3	0.84	0.92	0.87
ResNet50	0.82	0.91	0.86
ResNet101	0.72	0.76	0.73
VGG16	0.71	0.74	0.72

На рис. 15 – 16 представлені графіки залежності функції помилки та метрики AUC від кількості ітерацій на навчальному та валідаційному наборі.

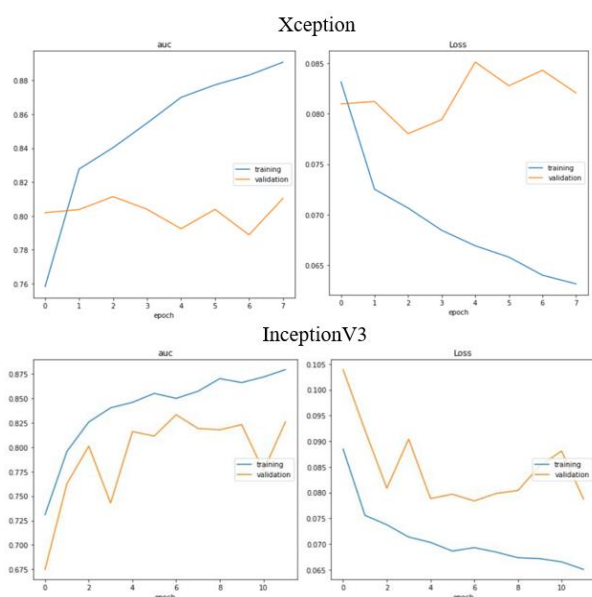


Рис. 15. Графіки залежності метрики AUC та функції помилки від кількості ітерацій для навчального та валідаційного набору даних для моделей Xception та InceptionV3

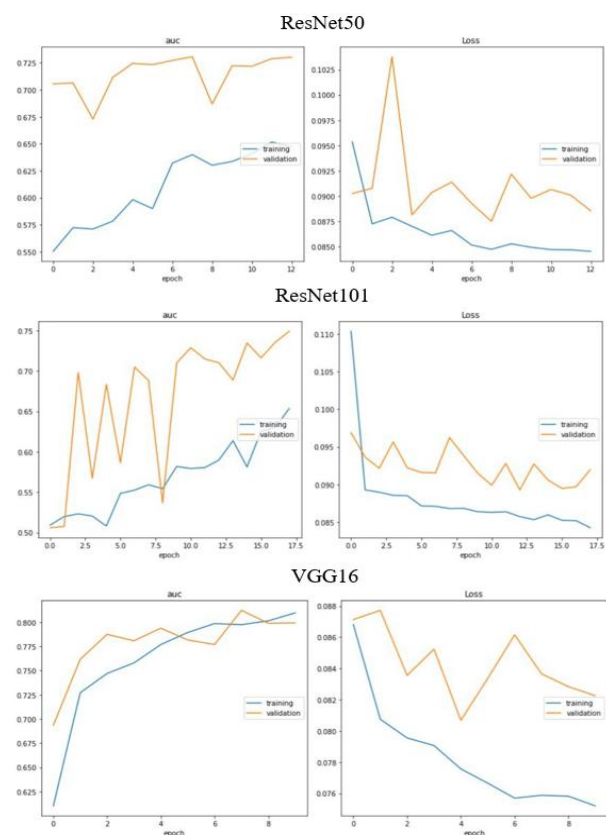


Рис. 16. Графіки залежності метрики AUC та функції помилки від кількості ітерацій для навчального та валідаційного набору даних для моделей ResNet50, ResNet101 та VGG16

VI. ВИСНОВКИ

В даній роботі було побудовано бінарний класифікатор для діагностики захворювань шкіри на основі згорткових нейронних мереж. Аналізуючи отримані результати в табл. 1 – 3 можна стверджувати, що за сукупністю метрик моделі є адекватними.

Модель Xception на тестовій вибірці має такі значення: AUC та Precision 86%, Recall: 96%, F1-score: 88%

Модель InceptionV3 на тестовій вибірці має такі значення: AUC: 88%, Precision 84%, Recall: 96%, F1-score: 87%.

Модель ResNet50 на тестовій вибірці має такі значення: AUC: 87% та Precision 82%, Recall: 91%, F1-score: 86%

Модель ResNet101 на тестовій вибірці має такі значення: AUC: 77% та Precision 72%, Recall: 76%, F1-score: 73%

Модель VGG16 на тестовій вибірці має такі значення: AUC: 83% та Precision 71%, Recall: 74%, F1-score: 72%.

За результатами метрик, найкращою є модель Xception, гірші результати мають моделі VGG16 та ResNet101.

ПЕРЕЛІК ПОСИЛАНЬ

[1] Internatioanl Agency for Research on Cancer. World Health Organization. Melanoma of skin. Source: Globocan 2020. December, 2020. URL: <https://gco.iarc.fr/today/data/factsheets/cancers/16-Melanoma-of-skin-fact-sheet.pdf>. (Last accessed: 09.09.2022).

[2] What to know about melanoma. Medical news today. November, 2019. URL: <https://www.medicalnewstoday.com/articles/154322#outlook> (Last accessed: 09.09.2022).

[3] Melanoma sights and symptoms. Moffitt cancer center. 2022. URL: <https://moffitt.org/cancers/melanoma/signs-symptoms/> (Last accessed: 09.09.2022). (Last accessed: 09.09.2022).

[4] Chen, X.; Weng, J.; Lu, W.; Xu, J.; Weng, J. Deep manifold learning combined with convolutional neural networks for action recognition. IEEE Trans. Neural Netw. Learn. Syst. 2017, 29, 3938–3952. URL: <https://ieeexplore.ieee.org/document/8038860> (Last accessed: 09.09.2022).

[5] Cooper S (1844). The first lines of the theory and practice of surgery: including the principle operations. S.S. and W.Wood.

[6] Ercal F, Chawla A, Stoecker WV, Lee HC, Moss RH. Neural network diagnosis of malignant melanoma from color images. IEEE Trans Biomed Eng. 1994;41(9):837–45 PMID: 7959811.

[7] Hekler, A.; Utikal, J.S.; Enk, A.H.; Berking, C.; Klode, J.; Schadendorf, D.; Jansen, P.; Franklin, C.; Holland-Letz, T.; Krahl, D.; et al.

Pathologist-level classification of histopathological melanoma images with deep neural networks. Eur. J. Cancer 2019, 115, 79–83. URL: [https://www.ejancer.com/article/S0959-8049\(19\)30275-8/fulltext](https://www.ejancer.com/article/S0959-8049(19)30275-8/fulltext) (Last accessed: 09.09.2022).

[8] Brinker TJ, Hekler A, Enk AH, Klode J, Hauschild A, Berking C, Schilling B, Haferkamp S, Schadendorf D, Fröhling S, Utikal JS, von Kalle C, Collaborators. A convolutional neural

network trained with dermoscopic images performed on par with 145 dermatologists in a clinical melanoma image classification task. *Eur J Cancer*. 2019;111:148–54. Epub 2019 Mar 8. PMID:30852421. URL: [https://www.ejancer.com/article/S0959-8049\(19\)30144-3/fulltext](https://www.ejancer.com/article/S0959-8049(19)30144-3/fulltext) Last accessed: 09.09.2022).

[9] The ISIC 2020 Challenge Dataset. Skin Lesion Analysis Towards Melanoma Detection. 2020. URL: <https://challenge2020.isic-archive.com/>. (Last accessed: 01.06.2020).

[10] Datagen. ResNet-50: The Basics and a Quick Tutorial. URL: <https://datagen.tech/guides/computer-vision/resnet-50/> (Last accessed: 11.10.2022).

[11] Awal Ahmed Fime, M.M.A Hashem. Estimation of Road Boundary for Intelligent Vehicles Based on DeepLabV3+ Architecture. *IEEE Access*. 2021. URL: https://www.researchgate.net/publication/354108791_Estimation_of_Road_Boundary_for_Intelligent_Vehicles_Based_on_DeepLabV3_Architecture (Last accessed: 08.10.2021).

[12] Chuncheng Feng, Hua Zhang, Shuang Wang, Yonglong Li, Haoran Wang and Fei Yan. Structural Damage Detection using Deep Convolutional Neural Network and Transfer Learning. *KSCE Journal of Civil Engineering*. March 26, 2019. URL: https://www.researchgate.net/publication/335442913_Structural_Damage_Detection_using_Deep_Convolutional_Neural_Network_and_Transfer_Learning (Last accessed: 15.08.2019).

[13] Maël Fabien. Xception Model and Depthwise Separable Convolutions. URL: <https://maelfabien.github.io/deeplearning/xception/#> (Last accessed: 20.03.2019).

[14] Francois Chollet. Xception: Deep Learning with Depthwise Separable Convolutions. Google, Inc. URL: https://openaccess.thecvf.com/content_cvpr_2017/papers/Chollet_Xception_Deep_Learning_CVPR_2017_paper.pdf (Last accessed: 15.12.2015).

REFERENCES

[1] International Agency for Research on Cancer. World Health Organization. Melanoma of skin. Source: Globocan 2020. December, 2020. URL: <https://gco.iarc.fr/today/data/factsheets/cancers/16-Melanoma-of-skin-fact-sheet.pdf>. (Last accessed: 09.09.2022).

[2] What to know about melanoma. Medical news today. November, 2019. URL: <https://www.medicalnewstoday.com/articles/154322#outlook> (Last accessed: 09.09.2022).

[3] Melanoma signs and symptoms. Moffitt cancer center. 2022. URL: <https://moffitt.org/cancers/melanoma/signs-symptoms/> (Last accessed: 09.09.2022). (Last accessed: 09.09.2022).

[4] Chen, X.; Weng, J.; Lu, W.; Xu, J.; Weng, J. Deep manifold learning combined with convolutional neural networks for action recognition. *IEEE Trans. Neural Netw. Learn. Syst.* 2017, 29,

3938–3952. URL: <https://ieeexplore.ieee.org/document/8038860> (Last accessed: 09.09.2022).

[5] Cooper S (1844). The first lines of the theory and practice of surgery: including the principle operations. S.S. and W.Wood.

[6] Ercal F, Chawla A, Stoecker WV, Lee HC, Moss RH. Neural network diagnosis of malignant melanoma from color images. *IEEE Trans Biomed Eng.* 1994;41(9):837–45 PMID: 7959811.

[7] Hekler, A.; Utikal, J.S.; Enk, A.H.; Berking, C.; Klode, J.; Schadendorf, D.; Jansen, P.; Franklin, C.; Holland-Letz, T.; Krahl, D.; et al.

Pathologist-level classification of histopathological melanoma images with deep neural networks. *Eur. J. Cancer* 2019, 115, 79–83. URL: [https://www.ejancer.com/article/S0959-8049\(19\)30275-8/fulltext](https://www.ejancer.com/article/S0959-8049(19)30275-8/fulltext) (Last accessed: 09.09.2022).

[8] Brinker TJ, Hekler A, Enk AH, Klode J, Hauschild A, Berking C, Schilling B, Haferkamp S, Schadendorf D, Fröhling S, Utikal JS, von Kalle C, Collaborators. A convolutional neural network trained with dermoscopic images performed on par with 145 dermatologists in a clinical melanoma image classification task. *Eur J Cancer*. 2019;111:148–54. Epub 2019 Mar 8. PMID:30852421. URL: [https://www.ejancer.com/article/S0959-8049\(19\)30144-3/fulltext](https://www.ejancer.com/article/S0959-8049(19)30144-3/fulltext) Last accessed: 09.09.2022).

[9] The ISIC 2020 Challenge Dataset. Skin Lesion Analysis Towards Melanoma Detection. 2020. URL: <https://challenge2020.isic-archive.com/>. (Last accessed: 01.06.2020).

[10] Datagen. ResNet-50: The Basics and a Quick Tutorial. URL: <https://datagen.tech/guides/computer-vision/resnet-50/> (Last accessed: 11.10.2022).

[11] Awal Ahmed Fime, M.M.A Hashem. Estimation of Road Boundary for Intelligent Vehicles Based on DeepLabV3+ Architecture. *IEEE Access*. 2021. URL: https://www.researchgate.net/publication/354108791_Estimation_of_Road_Boundary_for_Intelligent_Vehicles_Based_on_DeepLabV3_Architecture (Last accessed: 08.10.2021).

[12] Chuncheng Feng, Hua Zhang, Shuang Wang, Yonglong Li, Haoran Wang and Fei Yan. Structural Damage Detection using Deep Convolutional Neural Network and Transfer Learning. *KSCE Journal of Civil Engineering*. March 26, 2019. URL: https://www.researchgate.net/publication/335442913_Structural_Damage_Detection_using_Deep_Convolutional_Neural_Network_and_Transfer_Learning (Last accessed: 15.08.2019).

[13] Maël Fabien. Xception Model and Depthwise Separable Convolutions. URL: <https://maelfabien.github.io/deeplearning/xception/#> (Last accessed: 20.03.2019).

[14] Francois Chollet. Xception: Deep Learning with Depthwise Separable Convolutions. Google, Inc. URL: https://openaccess.thecvf.com/content_cvpr_2017/papers/Chollet_Xception_Deep_Learning_CVPR_2017_paper.pdf (Last accessed: 15.12.2015).

UDC 616.5-006.81 + 004.8

CLASSIFICATION OF SKIN LESIONS BASED ON CONVOLUTIONAL NEURAL NETWORKS

Klymchuk M.I., master
klymchuk.mariya@gmail.com
Serdakovsky V.S., senior lecturer
v.serdakovskiy@kpi.ua
National Technical University of Ukraine
"Igor Sikorsky Kyiv Polytechnic
Institute" Kyiv, Ukraine

Abstract - Background. Despite such a huge number of modern inventions in the field of medicine and information technology, the fight against such a disease as cancer still continues. Skin cancer remains the most common type of cancer. Although the incidence rate of melanoma is only about one percent of skin cancer cases, this form is the most dangerous and can lead to fatal consequences. Thanks to numerous studies that have been conducted recently, doctors assure that detecting signs of melanoma in the early stages leads to positive results in 90% of cases.

Therefore, today, the task of early diagnosis of skin cancer is quite relevant. Traditionally, dermatologists use a microscope and take biopsies from patients in order to analyze the condition of the mole. However, such a diagnostic process is quite difficult and requires highly qualified specialists. Therefore, the task is to facilitate the diagnostic process and increase the accuracy of its results. For this purpose, artificial intelligence methods are widely used, namely: diagnosis of medical skin images for the presence of melanoma, using deep learning.

Objective. The aim of the work is to build models and analyze the obtained experiments.

Methods. In accordance with the set goal, convolutional neural networks were built: using the transfer learning technique, and building a neural network according to its own configuration.

To train the model, 33,126 unique benign and malignant dermatoscopic skin images were used. This dataset was created by the International Skin Imaging Collaboration (ISIC), images were taken from the following sources: University of Queensland, Vienna Medical University, University of Athens Medical School, Barcelona Clinical Hospital, Memorial Sloan Kettering Cancer Center and Australian Melanoma Institute [9].

Results. The total sample was split into 80% for training, 10% for testing, and 10% for validation. The following architectures of convolutional neural networks were used for the study: Xception, ResNet50, ResNet101, InceptionV3, VGG16. The results of the experiments were obtained, which showed that the Xception Model on the test sample has the following values: AUC and Precision 86%, Recall: 96%, F1-score: 88%. The InceptionV3 model on the test sample has the following values: AUC: 88%, Precision 84%, Recall: 96%, F1-score: 87%. The ResNet50 model on the test sample has the following values: AUC: 87% and Precision 82%, Recall: 91%, F1-score: 86%. The ResNet101 model on the test sample has the following values: AUC: 77% and Precision 72%, Recall: 76%, F1-score: 73%. The VGG16 model on the test sample has the following values: AUC: 83% and Precision 71%, Recall: 74%, F1-score: 72%.

Conclusions. As a result, fairly high-quality classification models were built, which can be used in software applications for diagnosing skin conditions.

Keywords - Machine learning, convolutional neural networks, melanoma, skin cancer, diagnosis.