

Застосування згорткових
нейронних мереж
для розпізнавання образів
в обраній предметній
області

Виконав: Матійчик Т. Я.

Науковий керівник: Олецький О. В.

Постановка задачі

- Сучасні проблеми та рішення із застосування згорткових нейронних мереж (ЗНМ) у сільському господарстві
- Ефективність тонкого налаштування, встановлення різних оптимізаторів на повнозв'язаний шар та опорну частину із використанням переднавченої ЗНМ EfficientNet V3
- Порівняння з моделлю, побудованою з нуля
- Вплив аугментації даних на успішність моделей

Вступ

- Згорткові нейронні мережі застосовуються в розпізнаванні медичних зображень, мікроскопічних знімків, обличь, моніторингу дорожнього руху, задачах із детекціїї смуг руху тощо
- У агропромисловості поширені проблеми великих затрат часу при детекціїї людьми, необізнаність працівників у визначенні стану рослини, складні умови середовища, фінансові збитки
- У роботі досліджено застосування ЗНМ в аграрній сфері, зокрема, класифікаціїї хвороб пшениці та соняшнику, як одних із основних світових вирощуваних культур, зокрема в Україні

Проблематика а та сучасні рішення обраної ТЕМИ

4 публікації:

- <https://doi.org/10.3390/agriculture12081192>
- <https://doi.org/10.3389/fpls.2016.01419>
- <https://doi.org/10.1038/s41598-023-29230-7>
- <https://doi.org/10.3390/agriculture11080707>

Основні проблеми:

- Незбалансованість навчальних вибірок
- Слабка репрезентативність зразків у датасетах
- Проблема багатшаблонної (multilabel) класифікації

Проблематика а та сучасні рішення обраної теми

4 публікації:

- <https://doi.org/10.3390/app13095801>
- <https://doi.org/10.3390/agriengineering6030117>
- <https://doi.org/10.3390/agriculture13081479>
- <https://ieeexplore.ieee.org/document/10521470>

Основні рішення:

- Залишкові зв'язки (Residuals) – ResNet
- Inception
- Уважні механізми (SE, CBAM, ECA)
- Методи аугментації даних (CycleGAN, ADASYN, SMOTE)

Будова згорткових нейронних мереж

Більшість ЗНМ мають наступні основні складові:

- Шари згортки (convolutional layers)
- Шари об'єднання (pooling layers)
- Шар згладжування (flatten)
- Повнозв'язаний шар (fully-connected)

Дані для дослідження

- Датасет містить 7162 зображення
- Розподіл на тренувальну, валідаційну та тестову підвибірки зі співвідношенням 8-1-1
- Пакетна нормалізація зі ImageNet-значеннями середнього та стандартного відхилення
- Зміна розмірів зображень до 300x300
- Аугментація тренувальної вибірки з фільтрами `RandomRotation(30)`, `RandomHorizontalFlip()`



Альтернаріоз



Здоровий
соняшник



Іржа
соняшника



Здорова
пшениця



Ризопусна
гниль



Мозаїка



Альтернаріоз



Борошниста
роса



Пероноспороз



Борошниста
роса
соняшника



Альтернаріоз



Септоріоз



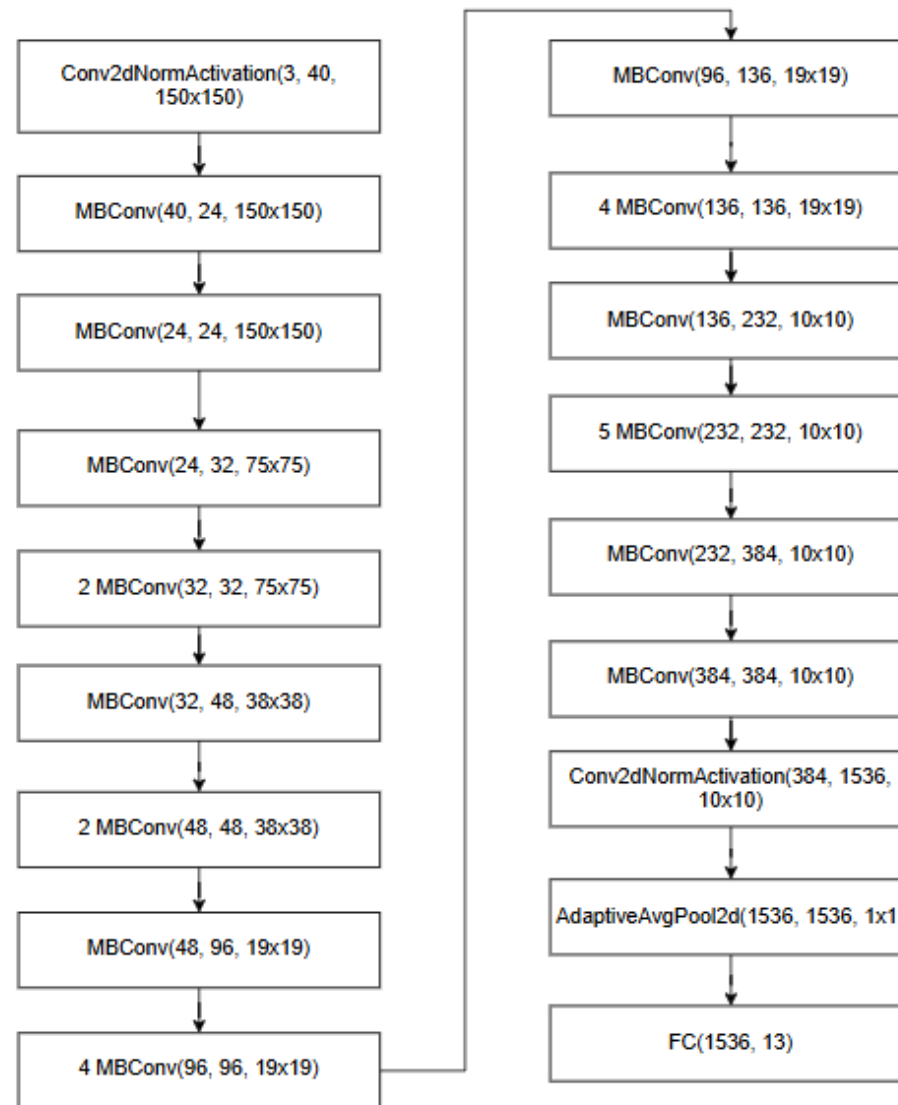
Іржа
пшениці



Склеротиніоз

Модель	Обсяг моделі (МВ)	GFLOPs	К-сть ваг	Точність	Час тренування (с)
B0	188.99	0.41	4 024 201	92.02%	490.6
B1	310.52	0.66	6 529 837	92.44%	504.6
B2	392.78	0.7	7 719 311	92.99%	510.9
B3	666.56	1.02	10 716 213	93.84%	548.9
B4	1 373.61	1.58	17 571 925	95.66%	747.1
B5	2 739.47	2.46	28 367 421	83.05%	1105.6
B6	4 616.92	3.49	40 765 668	89.91%	1574.5
B7	8 000.18	5.24	63 820 668	83.23%	2810.6

Порівняння моделей сімейства EfficientNet, 5 епох, всі шари тренувані, learning rate = 0.001, weight decay = 0.0001



Архитектура EfficientNet

B3

```
7 usages  Tymofii Matichyk
class MBCConv(nn.Module):
    Tymofii Matichyk
    def __init__(self, in_channels, out_channels, expand_ratio, kernel_size, stride):
        super().__init__()
        hidden_dim = in_channels * expand_ratio
        self.use_residual = in_channels == out_channels and stride == 1

        self.conv = nn.Sequential(
            nn.Conv2d(in_channels, hidden_dim, kernel_size=1, bias=False),
            nn.BatchNorm2d(hidden_dim),
            nn.SiLU(),
            nn.Conv2d(hidden_dim, hidden_dim, kernel_size, stride, kernel_size // 2, groups=hidden_dim, bias=False),
            nn.BatchNorm2d(hidden_dim),
            nn.SiLU(),
            nn.Conv2d(hidden_dim, out_channels, kernel_size=1, bias=False),
            nn.BatchNorm2d(out_channels)
        )

    Tymofii Matichyk
    def forward(self, x):
        if self.use_residual:
            return x + self.conv(x)
        else:
            return self.conv(x)
```

```
2 usages  Tymofii Matichyk
class ScratchCNN(nn.Module):
    Tymofii Matichyk
    def __init__(self, num_classes=13):
        super().__init__()
        self.stem = nn.Sequential(
            nn.Conv2d(in_channels=3, out_channels=40, kernel_size=3, stride=2, padding=1, bias=False),
            nn.BatchNorm2d(40),
            nn.SiLU()
        )

        self.blocks = nn.Sequential(
            MBCConv(in_channels=40, out_channels=24, expand_ratio=1, kernel_size=3, stride=1),
            MBCConv(in_channels=24, out_channels=32, expand_ratio=6, kernel_size=3, stride=2),
            MBCConv(in_channels=32, out_channels=48, expand_ratio=6, kernel_size=5, stride=2),
            MBCConv(in_channels=48, out_channels=96, expand_ratio=6, kernel_size=3, stride=2),
            MBCConv(in_channels=96, out_channels=136, expand_ratio=6, kernel_size=3, stride=1),
            MBCConv(in_channels=136, out_channels=232, expand_ratio=6, kernel_size=5, stride=2),
            MBCConv(in_channels=232, out_channels=384, expand_ratio=6, kernel_size=3, stride=1)
        )

        self.head = nn.Sequential(
            nn.Conv2d(in_channels=384, out_channels=1536, kernel_size=1, bias=False),
            nn.BatchNorm2d(1536),
            nn.SiLU(),
            nn.AdaptiveAvgPool2d(1),
            nn.Flatten(),
            nn.Dropout(0.3),
            nn.Linear(in_features=1536, num_classes)
        )

    Tymofii Matichyk
    def forward(self, x):
        x = self.stem(x)
        x = self.blocks(x)
        x = self.head(x)
        return x
```

Архітектура мережі,
побудованої з нуля



Тонке налаштування

Конфігурації ЗНМ для порівняння:



- Повністю уточнена мережа (всі шари треновані)
- Частково уточнена – тренованими є останні 2 шари MBConv, AdaptiveAvgPool2d у backbone-частині та FC.
- Мережа, побудована з нуля, без перенесеного навчання

Тип моделі	GFLOPs	Обсяг моделі (МВ)	Треновані параметри
Full fine-tuned EffNet B3	1.93	666.56	10 716 213
Partial fine-tuned EffNet B3	1.93	666.56	3 897 095
From scratch CNN	0.59	254.67	2 035 741




Обсяг, GFLOPs та кількість параметрів для уточнених мереж



Графіки тренувальної та валідаційної точностей, матриці конфузій для мережі, побудованої з нуля



Графіки тренувальної та валідаційної точностей,
матриці конфузій для повністю розмороженої
EfficientNet B3



Графіки тренувальної та валідаційної точностей, матриці конфузій для частково розмороженої EfficientNet V3

Тип	Тренувальна точність (%)	Валідаційна точність (%)	Трен. похибка	Валід. похибка	Час виконання (с)
Full fine-tuned	95.26	94.26	0.14	0.20	1340.01
Partial fine-tuned	95.55	93.97	0.13	0.18	1030.6
From scratch	73.17	74.93	0.82	0.78	1079.74
Full fine-tuned	0.93	0.93	0.93	0.93	0.93
Partial fine-tuned	0.94	0.94	0.94	0.94	0.94
From scratch	0.76	0.76	0.76	0.75	0.75

Таблиці успішності уточнених мереж




Різні
гіперпараметри для
backbone-
частини та
повнозв'язаного (FC)
шару

Конфігурації ЗНМ для порівняння:




- **Single Adam** - єдиний оптимізатор на всю модель
- **FC Adam + Backbone Adam (1)**
- **FC Adam + Backbone Adam (2)**

Backbone - частина будови ЗНМ перед повнозв'язаним шаром

Тип оптимізатора	Рейтинг навчання	Затримка ваг
Single Adam	$1e^{-3}$	$1e^{-4}$
FC Adam	$1e^{-3}$	$1e^{-4}$
Backbone Adam (1)	$1e^{-5}$	$1e^{-6}$
Backbone Adam (2)	$1e^{-4}$	$1e^{-5}$



Графіки тренувальної та валідаційної точностей, матриці конфузій для EfficientNet V3 із Backbone Adam (1)



Графіки тренувальної та валідаційної точностей, матриці конфузій для EfficientNet V3 із Backbone Adam (2)

Тип	Тренувальна точність (%)	Валідаційна точність (%)	Трен. похибка	Валід. похибка	Час виконання (с)
Один оптимізатор (full fine-tuned)	95.26	94.26	0.14	0.20	1340.01
Різні оптимізатори (1)	94.51	93.98	0.17	0.18	1345.98
Різні оптимізатори (2)	98.98	95.79	0.02	0.14	1352.61

Тип	Влучність	Повнота	F1-бал
Single optimizer	0.93	0.93	0.93
Different optimizers (1)	0.94	0.93	0.93
Different optimizers (2)	0.96	0.96	0.96

Таблиці успішності мереж з різними оптимізаторами

Тип мережі	З аугментацією			Без аугментації		
	Трен. точність	Валід. точність	Різниця (%)	Трен. точність	Валід. точність	Різниця (%)
Повністю уточнена	95.26	<u>94.26</u>	<u>1</u>	<u>96.99</u>	91.18	5.81
Частково уточнена	95.55	<u>93.97</u>	<u>1.58</u>	<u>98.13</u>	93.41	4.72
Модель з Backbone Adam (1)	94.51	93.98	<u>0.53</u>	<u>97.03</u>	<u>94.26</u>	2.77
Модель з Backbone Adam (2)	98.98	<u>95.79</u>	<u>3.19</u>	<u>99.23</u>	95.52	3.71
Побудована з нуля	73.17	<u>74.93</u>	<u>1.76</u>	<u>87.92</u>	71.84	16.08

Таблиці порівняння точностей мереж під час тренування із та без аугментації даних

Тип мережі	З аугментації			Без аугментації		
	Трен. похибка	Валід. похибка	Різниця	Трен. похибка	Валід. похибка	Різниця
Повністю уточнена	0.14	<u>0.20</u>	<u>0.06</u>	<u>0.09</u>	0.34	0.25
Частково уточнена	0.13	<u>0.18</u>	<u>0.05</u>	<u>0.06</u>	0.2	0.14
Модель з Backbone Adam (1)	0.17	<u>0.18</u>	<u>0.01</u>	<u>0.11</u>	<u>0.18</u>	0.07
Модель з Backbone Adam (2)	<u>0.02</u>	0.14	0.12	<u>0.02</u>	<u>0.11</u>	<u>0.09</u>
Побудована з нуля	0.82	0.78	0.04	0.37	1.06	0.69

Таблиця порівняння похибок мереж під час тренування із та без аугментації даних

Тип мережі	З аугментацією			Без аугментації		
	Влучність	Повнота	F1-бал	Влучність	Повнота	F1-бал
Повністю уточнена	<u>0.93</u>	<u>0.93</u>	<u>0.93</u>	<u>0.93</u>	<u>0.93</u>	<u>0.93</u>
Частково уточнена	<u>0.94</u>	<u>0.94</u>	<u>0.94</u>	<u>0.94</u>	0.93	0.93
Модель з Backbone Adam (1)	<u>0.94</u>	0.93	0.93	0.93	0.93	0.93
Модель з Backbone Adam (2)	<u>0.95</u>	<u>0.95</u>	<u>0.95</u>	<u>0.95</u>	<u>0.95</u>	<u>0.95</u>
Побудована з нуля	<u>0.76</u>	<u>0.76</u>	<u>0.75</u>	0.74	0.72	0.73

Таблиці порівняння тестових метрик мереж під час тренування із та без аугментації даних

Результати

- **Частково уточнена мережа** показала найкращі результати на метриках під час навчання та тестування серед моделей з тонким налаштуванням
- Серед моделей з різними оптимізаторами **найбільш стійкою до перенавчання** виявилась модель із оптимізатором **Backbone Adam (1)**. Проте **найкращою з точки зору показників** – модель із оптимізатором **Backbone Adam (2)**
- Без аугментації даних точність моделей на небачених даних падає, більше спостерігається перенавчання. Модель із оптимізатором **Backbone Adam (2)** здобула найвищу точність із та без аугментації

Подальші покращення та розвиток

- Підвищення точності класифікації (інтеграція кращих уважних механізмів як СВАН, генеративні техніки)
- Удосконалення навчальної вибірки (урізноманітнення та балансування класів у датасетах)
- Створення прикладної програми для застосування в реальних умовах

ВИСНОВКИ

- Представлено наявні проблеми та рішення із застосування ЗНМ в обраній предметній області
- Досліджено різні методи застосування згорткових нейронних мереж для розпізнавання образів в обраному домені – класифікації хвороб пшениці та соняшнику
- Серед імплементованих методик часткове тонке налаштування та інтеграція різних оптимізаторів виявились найбільш ефективними – такі моделі досягли **94-96%** валідаційної точності та **0.94-0.96** значення F1-балу
- Аугментація даних показала себе ефективною технікою підвищення якості навчання ЗНМ та розпізнавання образів

Дякую за увагу!

