

В. Б. Мокін<sup>1</sup>  
Д. М. Грузман<sup>2</sup>  
С. О. Довгополюк<sup>1</sup>  
А. О. Лотоцький<sup>1</sup>

## СИСТЕМНИЙ АНАЛІЗ РОЗМІРІВ ФРАГМЕНТА ЗОБРАЖЕНЬ АЕРОФОТОЗЙОМКИ СІЛЬСЬКОГОСПОДАРСЬКИХ УГІДЬ ДЛЯ ПОШУКУ АНОМАЛІЙ У НИХ МЕТОДАМИ МАШИННОГО НАВЧАННЯ

<sup>1</sup>Вінницький національний технічний університет, Україна;

<sup>2</sup>Компанія «Nestlogic», м. Тель-Авів, Ізраїль

Великими проблемами для сільськогосподарських угідь (СГУ) є захворювання рослин, дія шкідників, бур'яни та інші аномалії. Швидке розповсюдження подібних проблемних місць спричиняє значну шкоду, якщо їх вчасно не виявити, локалізувати та нейтралізувати. Через великі площі та, часто, важкодоступність до окремих ділянок поля, для усунення таких проблем застосовується аерофотозйомка з дронів з подальшим її обробленням методами штучного інтелекту, машинного навчання, передусім — глибинного навчання. Кожне зображення розбивається на дрібніші фрагменти та аналізується, але результат аналізу суттєво залежить від вибору розміру таких фрагментів. Мета дослідження — розробити комплексний системний підхід до аналізу та обчислення оптимального за багатьма критеріями розміру найменшого фрагмента зображень аерофотозйомки СГУ для пошуку аномалій у них методами машинного глибинного навчання. Проведено огляд відомих підходів до розв'язання задачі пошуку таких аномалій та запропоновано які саме інформаційні технології потрібно використовувати на етапах передоброблення, машинного глибинного навчання та які типові проблеми слід усувати під час цього, з урахуванням специфіки предметної області. Виділено основні критерії, які необхідно враховувати для розв'язання поставленої задачі: тривалість обчислення, точність (мінімальна похибка) навчання моделі, наближеність середньої площі кластерів до заданої, за умови виконання ряду обмежень. Запропоновано вираз інтегрального критерію для врахування цих критеріїв та підходи щодо вибору їх ваг. Розроблено алгоритм застосування запропонованих підходів та прийомів щодо застосування відомих методів машинного глибинного навчання та кластеризації. Наведено реальний приклад застосування цього алгоритму та продемонстровано його ефективність для випадків, коли найвагомішими (з вагою 0,5) критеріями є тривалість обчислень або наближеність середньої площі кластерів до заданої. Запропонований комплекс підходів та прийомів для системного аналізу розмірів фрагмента зображень аерофотозйомки СГУ дозволить підвищити точність та швидкість пошуку аномалій у них методами машинного глибинного навчання та, в цілому, дозволить ефективніше та вчасно виявляти різні захворювання рослин, бур'яни, шкідників тощо.

**Ключові слова:** аерофотозйомка, аналіз зображень, автоенкодер, глибинне навчання, машинне навчання, сільськогосподарське угіддя, виявлення аномалій, кластеризація.

### Вступ

Великими проблемами для сільськогосподарських угідь (СГУ) є захворювання рослин, дія шкідників, бур'яни. Швидке наростання подібних проблемних місць спричиняє значну шкоду в сільськогосподарському, економічному та екологічному сенсі, якщо їх вчасно не виявити, локалізувати та нейтралізувати. При цьому, для СГУ характерними є велика площа, важкодоступність (наприклад, на полях соняшника) тощо. Для усунення таких проблем в наш час активно запроваджують інформаційні технології, зокрема, аерофотозйомку з дронів з подальшим її обробленням методами штучного інтелекту, машинного навчання, передусім — глибинного навчання. Але тоді впливають інші проблеми: складний рельєф, зашумленість даних, різна ширина рядків з посад-

ками, різний кут рядків, зумовлений елементами рельєфу, метеоумови (більшість моделей дронів не рекомендує їх використовувати, коли вітер більше 10 м/с, коли дощ, туман та ін.) тощо.

Головною метою такої технології є стабільне виявлення та сегментація і локалізація в GPS-координатах аномалій певного типу на різній аерофотозйомці одного і того ж поля, що, з часом, дозволяє здійснювати пошук серед них певних негативних для сільського господарства аномалій (захворювання рослин, шкідники, бур'яни, підтоплення тощо), порівняння з раніше виявленими для аналізу і прогнозування динаміки тощо. В основі цієї технології лежить нарізання результатів аерофотозйомки на фрагменти певного розміру, формування з них датасетів та їх подальше оброблення. Саме вдалий вибір розміру цих фрагментів і забезпечує досягнення мети. І навпаки, невдалий вибір розміру практично не гарантує її досягнення.

Аналіз сучасних досліджень та власний досвід авторів доводить, що оптимальними методами у цій сфері є методи машинного, передусім глибинного, навчання.

*Мета дослідження* — розробити комплексний підхід до системного аналізу та обчислення оптимального за багатьма критеріями розміру найменшого фрагмента зображень аерофотозйомки сільськогосподарських угідь для пошуку аномалій у них методами машинного глибинного навчання.

### Огляд інформаційних технологій для пошуку аномалій методами машинного навчання на зображеннях аерофотозйомки СГУ

Огляд робіт вчених світу у сфері оброблення даних дистанційного зондування рослин (ДЗЗ) (або простіше — аерофотозйомки) дозволив виділити найпоширеніші типові параметри та технології, які використовуються для розв'язання цієї задачі (табл. 1) [1]—[4].

Таблиця 1

Параметри інформаційних технологій для пошуку аномалій методами машинного глибинного навчання на зображеннях аерофотозйомки СГУ

Назва статті	Збір інформації	Розмір $M$ використаних фрагментів зображень	Технології передоброблення	Тип нейронної мережі
DroNet: Efficient Convolutional Neural Network Detector for Real-Time UAV Applications [1]	БПЛА, кадрування супутникових зображень	352×352, 386×386, 416×416, 544×544, 608×608	—	12-шарова згортова нейронна мережа
CNN Features off-the-shelf: an Astounding Baseline for Recognition [2]	Використання датасетів Pascal VOC та MIT-67 та ін.	221×221	—	5-шарова згортова нейронна мережа
Drone Agriculture Imagery System for Radish Wilt Disease Identification via Efficient Convolutional Neural Network [3]	БПЛА (Phantom 4, DJI co., Ltd.)	64×64, 128×128, 256×256	Використання LBP (Local binary pattern), AutoEncoder, кластеризація методом $k$ -середніх	13-шарова згортова нейронна мережа
Pest Detection on UAV Imagery using a Deep Convolutional Neural Network [4]	БПЛА (DJI Phantom 3)	24×24, 50×50, 100×100, 150×150, 200×200, 250×250, 500×500	—	8-шарова згортова нейронна мережа

Традиційно використовуються такі інформаційні технології, методи та підходи [1]—[4]:

– вибрати параметри аерофотозйомки (найпоширенішим у популярних моделях дронів є отримання кольорових знімків 4000×3000, dpi =72 на висоті 32 м):

- висота зйомки, яку як правило, вибирають такою, щоб був нескладний коефіцієнт масштабування  $m$  між пікселями і квадратними метрами (наприклад  $m = 0,01$ , тоді  $M = 100$  пікселів — це 1 м або 1 піксель = 1 см<sup>2</sup>);

- роздільна здатність (dpi),

- розмір кадру тощо;

– отримати фото з перекриттям, зшити (пакети програм ArcGIS, Pix4Dfields чи ін.);

– вибрати спосіб кодування і кількість каналів  $K$  кольору:  $K = 1$  канал (градації сірого) або  $K = 3$  канали для кодування кольорів RGB або HSV;

- нарізати датасет з фрагментів певного розміру  $[M_1 \times M_2 \times K]$  — найчастіше вибирають квадратні фрагменти  $M = M_1 = M_2$  (пікселів), що спрощує їх оброблення  $[M \times M \times K]$ ;
- передоброблення датасету:
  - нарізання їх на партії (batch) певного розміру;
  - лінійне бінарне шаблонування (LBP) для усунення шумів та зменшення кількості ознак;
  - кластеризація ознак за методом k-середніх, опорних векторів (SVM — support vector machines), DBSCAN або ін.;
- застосування нейромережевого згорткового автоенкодера (англ. CAE) для виділення серед зображень унікальних шаблонів («паттернів») та зменшення розмірності цих даних у найвужчій частині — так званому «гирлі» CAE;
- кластеризація даних з гирла CAE та пошук серед них аномалій, порівняння з раніше виявленими для аналізу динаміки тощо.

Багаторічний досвід авторів застосування цих технологій показав, що однією з ключових засад досягнення успіху, тобто стабільного виявлення та локалізації аномалій певного типу у зображеннях аерофотозйомки, є вдалий вибір розміру  $M$  фрагмента, на які здійснюється поділ зображень аерофотозйомки.

### Визначення критеріїв, які слід враховувати під час вибору розміру фрагмента зображень аерофотозйомки СГУ

Аналіз усіх етапів технології машинного навчання для виявлення пошуку аномалій у зображеннях СГУ показав, що вибір розміру найменшого фрагмента, на які розбивається зображення, впливає на такі аспекти, які можна трансформувати у відповідні критерії:

#### 1. Відповідність регулярності зображення.

Особливістю більшості СГУ є їх смугастість, регулярність, тобто наявність рядків (рядок, рядів кущів, дерев тощо). І важливо фіксувати прояви аномалій саме в цих рядках, тому необхідно, щоб крок зображень це враховував. Отже, варто визначити діапазон зміни ширини рядка СГУ  $[M_{\min r}, M_{\max r}]$  і саме в цьому діапазоні чи кратному йому в подальшому шукати оптимальне значення  $M$ .

#### 2. Забезпечення можливості зберігання інформації про аномалію.

Як зазначено вище, метою технології є пошук аномалій, отже, важливо, щоб на фрагментах, які будуть зіставлятись, було видно (рис. 1):

- 1) зіставні елементи аномалій;
- 2) унікальні шаблони аномалій, наприклад, якщо аномалією є слід трактора, тоді у мінімальний фрагмент зображення повинно поміщатись достатньо ліній, щоб алгоритм «зрозумів» («навчився»), що це є саме регулярні лінії трака, а не природний чи інший об'єкт.




Рис. 1. Приклад фрагментів 48×48 пікселів, на які розрізано фото з квадрокоптера, отримане авторами з висоти 32 м в результаті аерофотозйомки СГУ

З іншого боку, якщо метою є виявлення природних об'єктів на кшталт «захворювання рослин», «бур'яни», «підтоплення» тощо, які супроводжуються лише специфічною зміною кольору, тоді цей критерій не варто враховувати взагалі. Якщо ж його враховувати варто, тоді доцільно визначити рекомендовані інтервали  $[M_{min}, M_{max}]$  розміру фрагмента на основі вивчення прикладів вже відомих аномалій, перетворених відповідно до коефіцієнта масштабування  $m$ .

### 3. Забезпечення роботи САЕ.

Особливість автоенкодера в тому, що розмірність вхідного зображення поетапно зменшується з використанням згорток до найменшого (так зване «гирло» автоенкодера), а потім з нього відтворюється у первинне тією ж послідовністю згорток та перетворень моделі, але у зворотному («дзеркальному») порядку. Налаштування параметрів моделі здійснюється таким чином, щоб вихідне зображення якомога менше відрізнялось від вхідного [3], [5]. Найбільша цінність такої технології в тому, що це — так зване машинне навчання «без вчителя» («Unsupervised Machine Learning»), тобто не потрібні ніякі попередні вхідні дані про об'єкт дослідження [5].

На прикладі бібліотеки Keras модель САЕ може реалізуватись таким чином: MaxPooling2D(2,2), тобто зменшення у 4 рази (удвічі по ширині та довжині) — як правило застосовується в парі зі згорткою Conv2D в режимі (purpose = “same”) (без зміни розміру), а потім після «гирла» САЕ дзеркально відтворюється у вхідний розмір з використанням згорток UpSampling2D(2,2) та Conv2DTranspose (purpose = “same”), відповідно [6]. Як вищезазначено, головним принципом роботи САЕ є відтворення вихідного зображення, яке якнайменше відрізняється від вхідного. Але це відтворення буде неможливим чи некоректним, якщо під час згорток не вдасться відновити вхідний розмір зображення. Наприклад, використання архітектури кодера із 4 згорток Conv2D в парі з 4-ма послідовними MaxPooling2D(2,2), які зменшують розмір  $M$  зображення щоразу у 2 рази, зменшує розмір  $M$  вхідного зображення у  $12 = 4 \cdot 2$  разів з округленням на кожному етапі до меншого. А тоді, якщо воно було розміром  $M = 100$  пікселів, тоді на виході кожної з 4-х пар згорток буде відповідно:  $100/2 = 50$ ,  $50/2 = 25$ ,  $25/2 = 12$ ,  $12/2 = 6 = M_{CAE}$  пікселів, тобто вхідне зображення  $100 \times 100 = 10000$  пікселів зменшується до  $6 \times 6 = 36$  пікселів, тобто у  $D_{total} = 278$  разів. До речі, кольорове зображення у  $6 \times 6 \times 3$  у «гирлі» САЕ є дуже бажаним, оскільки кластеризація  $6 \times 6 \times 3 = 108$ -вимірного простору набагато простіша і швидша, аніж вхідного  $100 \times 100 \times 3 = 30\,000$ -вимірного. Для цього можна використати відомі методи зменшення розмірності PCA чи t-SNE, наприклад за допомогою безкоштовного відомого веб-сервісу projector.tensorflow (<https://projector.tensorflow.org/>).

Але спроба відтворити вхідне зображення з  $M_0 = 100$  пікселів із зображення  $M_{CAE} = 6$  пікселів декодером із дзеркальною для кодера архітектурою з 4-ма стискаючими розмір згортками буде неуспішною, оскільки:  $6 \cdot 2 = 12$ ,  $12 \cdot 2 = 24$ ,  $24 \cdot 2 = 48$ ,  $48 \cdot 2 = 96 \neq 100$  пікселів.

Вибір розміру  $M$  має бути таким, щоб гарантувати його відтворення в САЕ, наприклад, 24, 48, 64, 72, 96, 120, 144, 256 та ін., хоча це суттєво залежить від архітектури САЕ та вектора коефіцієнтів масштабування  $D = [D_1, D_2, \dots, D]$ , який він забезпечує на кожній згортці.

На рис. 2 наведено приклад програмного коду на Python з використанням бібліотек keras та tensorflow для реалізації 7-шарового згорткового САЕ (з 4-ма стискаючими розмір згортками: 3-ма MaxPooling2D і однією Conv2D з параметром strides = (2,2), що забезпечує і згортання, і масштабування одночасно), розроблений авторами для цієї статті для прикладу вхідного зображення розміру  $96 \times 96 \times 3$ , який здійснює стиснення його зображення у  $96 \cdot 96 \cdot 3 / (6 \cdot 6 \cdot 2) = 384$  рази і добре себе зарекомендував під час випробувань на реальних даних і за швидкістю, і за точністю. Для інших розмірів слід відповідно адаптувати значення розмірності у «гирлі».

### 4. Визначення критеріїв успішності машинного навчання.

Серед типових критеріїв успішності машинного навчання є такі [5], [6]:

1. Сумарна тривалість навчання (у годинах чи хвиликах) — час, за який алгоритм налаштування параметрів заданої моделі або досягне оптимального значення, або наперед заданої кількості епох (ітерацій), якщо оптимум буде недосяжним. Часто замість цього параметра використовується не сумарна тривалість, а середня тривалість  $T$  (в секундах) епохи (ітерації) цього навчання.
2. Мінімальне значення похибки val\_loss\_min навчання — оптимальне значення точності val\_loss за певним критерієм (наприклад, RMSE — з англ. «root-mean-square error» — «середньоквадратична похибка»), яке досяг алгоритм на окремо заданому наборі даних (так званому «validation dataset»).

```

def create_deep_cae():
    input_img = Input(shape=(96, 96, 3))

    # Encoder
    x = Conv2D(128, (7, 7), activation='relu', padding='same')(input_img)
    x = MaxPooling2D((2, 2), padding='same')(x)
    x = Conv2D(64, (5, 5), activation='relu', strides=(1, 1), padding='same')(x)
    x = MaxPooling2D((2, 2), padding='same')(x)
    x = Conv2D(32, (3, 3), activation='relu', strides=(1, 1), padding='same')(x)
    x = MaxPooling2D((2, 2), padding='same')(x)
    encoded = Conv2D(2, (2, 2), activation='relu', strides=(2, 2), padding='same')(x)

    # Decoder
    input_encoded = Input(shape=(6, 6, 2))
    x = Conv2DTranspose(32, (3, 3), activation='relu', strides=(2, 2), padding='same')(input_encoded)
    x = UpSampling2D((2, 2))(x)
    x = Conv2DTranspose(64, (5, 5), activation='relu', strides=(1, 1), padding='same')(x)
    x = UpSampling2D((2, 2))(x)
    x = Conv2DTranspose(128, (7, 7), activation='relu', strides=(1, 1), padding='same')(x)
    x = UpSampling2D((2, 2))(x)
    decoded = Conv2D(3, (2, 2), activation='relu', padding='same')(x)

    # Models
    encoder = Model(input_img, encoded, name="encoder")
    decoder = Model(input_encoded, decoded, name="decoder")
    autoencoder = Model(input_img, decoder(encoder(input_img)), name="autoencoder")
    return encoder, decoder, autoencoder

```

Рис. 2. Приклад програмного коду на Python (з використанням бібліотек Keras та Tensorflow) для реалізації 7-шарового згорткового CAE зі зменшенням вхідної розмірності у 384 рази (Python 3, Jupyter Notebook, Anaconda)

У документації бібліотеки Keras [6] є ще багато інших критеріїв, але для поставленої задачі вважаємо найголовнішими саме ці два. Адже, чим швидше навчиться модель, тим менше пройде часу між визначенням і класифікацією аномалій (проблемних місць) та їх картуванням, а отже, й швидше надійде допомога. При цьому, для того, щоб вибрати який саме розмір мінімального фрагмента варто використати, важлива й максимальна точність (мінімальна похибка `val_loss_min`) навчання.

Отже, пропонуємо враховувати ці два критерії і шукати слід їх мінімум.

##### 5. Визначення критерію успішності виявлення аномалій СГУ.




Рис. 3. Результат кластеризації результатів пошуку аномальних зон на СГУ методом DBSCAN

Враховуючи специфіку задачі, важливим вважаємо ще один критерій — середня площа  $S$  (в метрах) кластера, тобто виявлених аномалій, за певним методом, однаковим для усіх видів моделей, наприклад DBSCAN (англ. «density-based spatial clustering of applications with noise» — основана на щільності просторова кластеризація для зашумлених даних) (рис. 3).

Досвід показує, що, за малих розмірів фрагмента можливі випадки, коли буде виявлена величезна кількість дуже дрібних кластерів, що не є цінним, адже серед таких аномалій експерту важко буде вирізнити дійсно аномальні ділянки. Це можуть бути і неаномальні ділянки, але з високою варіативністю звичайних ознак. Тому важливим є намагання отримання цих ділянок не надто дрі-

бних розмірів. З іншого боку, завеликі за площею ділянки, як на рис. 6 (наприклад, більше 50 % від площі усього поля чи площі зйомки), теж є малоцінними. Пропонуємо задавати певний найбажаніший і водночас максимально допустимий поріг для середнього розміру площі кластера  $S_{lim}$  і ті, моделі, які його перевищують, відкидати. А серед інших найкращими вважати ті, в яких величина  $(S_{lim} - S)$  є мінімальною.

Враховуючи вимоги до оптимального варіанта розв'язання поставленої задачі, введено інтегральний критерій  $J$ , за яким і можна буде вибрати оптимальне значення розміру  $M_{opt}$ . Пропонуємо його визначати за такою формулою:

$$J = w_1 k_1 T + w_2 k_2 val\_loss\_min + w_3 k_3 (S_{lim} - S), \quad (1)$$

де  $w_{1,2,3}$  — вагові коефіцієнти критеріїв, сума яких дорівнює 1,  $k_{1,2,3}$  — масштабуючі коефіцієнти критеріїв, які забезпечують їх значення в діапазоні  $[0, 1]$ .

Зауважимо, що перед застосуванням формули (1) бажано здійснювати масштабування усіх критеріїв не тільки за максимальним значенням (максимальне значення дорівнює 1, інші — відсоток від нього, що забезпечують коефіцієнти  $k_{1,2,3}$ ), а й за мінімальним шляхом віднімання цього мінімального значення від усіх значень, що забезпечить для мінімального значення 0, інші будуть більшими.

Ключовими в інтегральному критерії (1) є ваги  $w_{1,2,3}$ , наприклад, 0,25, 0,25, 0,5 — в цьому випадку експерти повинні визначити, який саме критерій є важливішим за інші два і саме його коефіцієнт зробити таким, що дорівнює 0,5.

### Алгоритм застосування технології

Таким чином, вибір розміру  $M$  пропонується здійснювати за таким алгоритмом:

1. Визначити вхідні передумови:
  - 1) рекомендований діапазон ширини рядка (рядки, ряду кущів тощо):  $[M_{min\ r}, M_{max\ r}]$  — ці параметри можуть бути суттєво різними у різних частинах поля, якщо там є різні елементи рельєфу та інші аномалії, тоді треба задавати різні інтервали та координати зон, де вони мають місце, та обробляти їх окремо;
  - 2) рекомендований діапазон для виявлення найменших елементів усіх  $n$  аномалій, за якими експерту їх можна розпізнати:  $[M_{min\ a1}, M_{max\ a1}], [M_{min\ a2}, M_{max\ a2}], \dots [M_{min\ an}, M_{max\ an}]$ ;
  - 3) вектор коефіцієнтів масштабування  $D = [D_1, D_2, \dots, D]$  САЕ.
2. Вибрати ряд розмірів  $M$  найменших фрагментів зображення, який буде досліджуватись, наприклад 48, 96, 128, 512 або 50, 100, 150, 200, 250, 500 чи ін., які задовольнятимуть усім вимогам, визначеним у п.1.
3. Здійснити передоброблення даних.
4. Вибрати структуру моделі САЕ, яка забезпечує коректне відтворення розмірності вихідного зображення по вхідному (подібну показаної на рис. 2).
5. Провести навчання моделі та визначити середню тривалість  $T$  (в секундах) кожної епохи (ітерації) та найкращу точність  $val\_loss\_min$ .
6. Задати максимально допустимий поріг для середньої площі з розміром кластера  $S_{lim}$ .
7. Здійснити кластеризацію аномальних зон та визначити середню площу виявлених кластерів  $S$  і величину  $(S_{lim} - S)$  для кожного варіанта моделей, які не приводять до перевищення значення  $S_{lim}$ . Ті розміри  $M$  і моделі, які приводять до перевищення  $S_{lim}$ , відкинути.
8. Здійснити мінімаксне масштабування (з визначенням коефіцієнтів  $k_{1,2,3}$ ) критеріїв  $T$ ,  $val\_loss\_min$ ,  $(S_{lim} - S)$  для всіх варіантів моделей, визначених у пп. 5—7.
9. Задати ваги  $w_{1,2,3}$  критеріїв у формулі (1).
10. Обчислити значення інтегрального критерію за формулою (1) та вибрати розмір зображення  $M_{opt}$ , який забезпечує мінімум цього критерію, тобто дозволяє найшвидше і найточніше кластеризувати аномалії, середня площа є найближчою до заданої.

Проілюструємо застосування цього алгоритму на практиці.

## Приклад застосування технології

Розглянемо приклад застосування підходу до системного аналізу фрагмента зображень аерофотозйомки сільськогосподарських угідь для пошуку аномалій у них методами машинного глибинного навчання та вибору оптимального розміру цих фрагментів.

Здійснена аерофотозйомка СГУ з буряком на території Вінницької області за допомогою квадрокоптера «Dji Mavic Pro», висота аерофотозйомки була 32 м (цьому відповідає: 1 піксель зображення = 1 см<sup>2</sup> поля), тобто коефіцієнт масштабування  $m = 0,01$ .

Відповідно до пп. 1, 2 запропонованого алгоритму був сформований такий ряд розмірів  $M$  фрагментів, на які розбивається зображення: 48, 96, 128, 512 пікселів. Враховуючи коефіцієнт масштабування  $m = 0,01$ , 512 пікселів це — відрізок довжиною 5,12 м.

Передоброблення даних не здійснювалось (п. 3), оскільки зйомка здійснювалась на порівняно невеликій ділянці за однакових метеоумов.

За п. 4 алгоритму використано модель зі структури, показаної на рис. 2, яка забезпечує коректне відтворення розмірності вихідного зображення по вхідному для всього ряду розмірів  $M$  фрагментів, вибраного у п. 2.

Згідно з п. 5 здійснено навчання моделі. На рис. 4—6 подано приклади фрагментів зображень різного розміру  $M$ : ліві два зображення — це їх вигляд до застосування САЕ, а праві — після застосування САЕ. По темних плямах видно, що відтворення відбувається коректно, але, при цьому, дрібні деталі («шум») суттєво фільтруються, що потім спрощує кластеризацію, причому кластеризуються не вихідні зображення, а значення у «гирлі» САЕ, де розмірність є значно меншою.



Рис. 4. Приклади фрагментів зображень: а — до; б — після застосування САЕ для зображень розміром  $M = 48$



Рис. 5. Приклади фрагментів зображень: а — до; б — після застосування САЕ для зображень розміром  $M = 96$




Рис. 6. Приклади фрагментів зображень: а — до; б — після застосування САЕ для зображень розміром  $M = 128$

Результати обчислень параметрів  $T$  та  $\text{val\_loss\_min}$  для кожного  $M$  подано у табл. 2.

Таблиця 2

Результати обчислення параметрів  $T$ ,  $\text{val\_loss\_min}$  та  $(S_{lim} - S)$  для кожного розміру  $M$

Розмір $M$ , пікселів	Тривалість обчислень $T$ , с	Найкраща точність $\text{val\_loss\_min}$	Середня площа кластерів $S$ , м	Різниця $S_{lim} - S$ , м
48	7876	0,2883614	0,2343750	3,7656250
96	1056	0,2594737	0,9375000	3,0625000
128	1080	0,2109954	1,1520000	2,8480000
512	1116	0,3008534	2,5000000	1,5000000

Згідно з п. 6 алгоритму задано максимально допустимий поріг для середньої площі з розміром кластера  $S_{lim} = 4 \text{ м}^2$ . У табл. 2 наведено відповідні значення  $(S_{lim} - S)$ , розраховані за методом DBSCAN.

Здійснено мінімаксне масштабування критеріїв, результат подано у табл. 3.

Таблиця 3

Масштабовані значення параметрів  $T$ ,  $\text{val\_loss\_min}$  та  $(S_{lim} - S)$  для кожного розміру  $M$

Розмір $M$ , пікселів	Тривалість обчислень $T$ , с	Найкраща точність $\text{val\_loss\_min}$	Різниця площ $S_{lim} - S$ , м	$J_1$	$J_2$
48	1	0,860980992	1	1	1
96	0	0,539498987	0,689655	0,192434	0,319058
128	0,003519062	0	0,594979	0	0,06475
512	0,008797654	1	0	0,127518	0

Перейдемо до пунктів 9, 10 алгоритму. Розглянемо 2 варіанти вибору:

- 1)  $J_1$ : головним критерієм є тривалість, тобто  $w_1 = 0,5$ ,  $w_2 = 0,25$ ,  $w_3 = 0,25$ ;
- 2)  $J_2$ : головним критерієм є середній розмір кластера, тобто  $w_1 = 0,25$ ;  $w_2 = 0,25$ ;  $w_3 = 0,5$ .

У табл. 3 та на рис. 7 подано відповідні результати обчислень (для подання значень інтегрального критерію також застосовано мінімаксне масштабування), з яких видно, що у першому випадку  $M_{opt} = 128$  пікселів (таким самим буде й результат, коли головним критерієм є точність  $\text{val\_loss\_min}$ ), а у другому —  $M_{opt} = 512$  пікселів. Задача розв'язана.

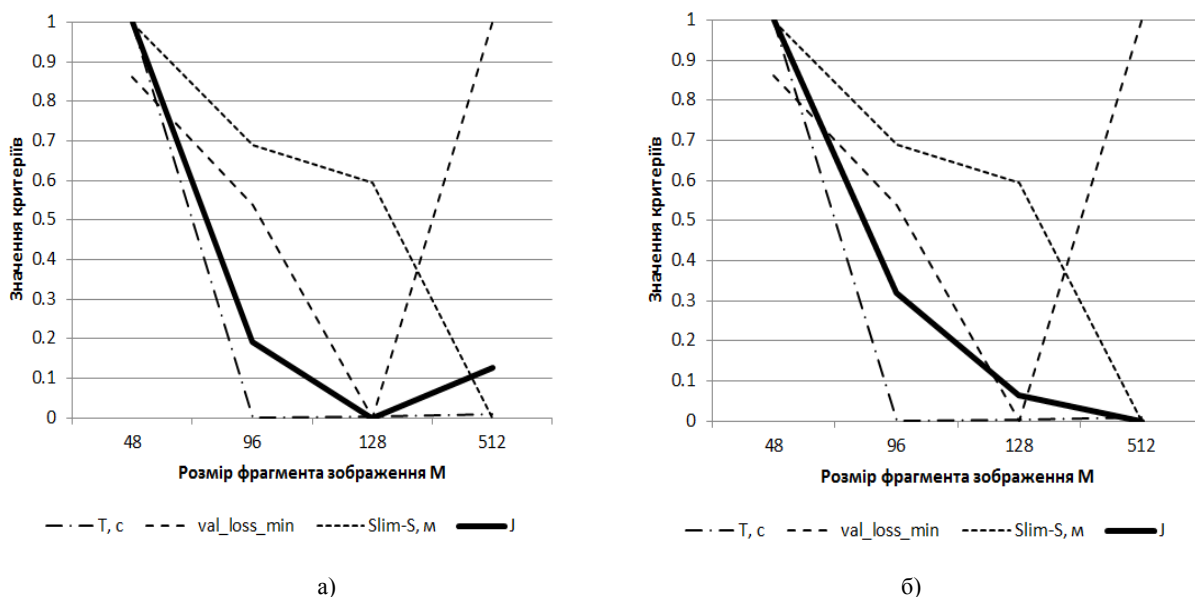


Рис. 7. Критерії тривалості обчислень  $T$ , точності  $\text{val\_loss\_min}$ , наближення середньої площі кластера до заданої  $S_{lim} - S$ , а також інтегральні критерії  $J$  для різних розмірів фрагмента  $M$ , на які розбивається зображення для аналізу, за умови, коли найвагомішим (з вагою 0,5) критерієм є: а — тривалість обчислень; б — наближеність середньої площі кластерів до заданої



## Висновки

Розглянуті питання автоматизації процесу аналізу аерофотозйомки з дронів сільськогосподарських угідь (СГУ) для пошуку аномалій на зображеннях, які відповідають місцям захворювання рослин, дії шкідників, бур'янам та ін. Зазначено, що, зазвичай, кожне зображення розбивається на дрібніші фрагменти та аналізується, але результат аналізу суттєво залежить від вибору розміру таких фрагментів.

Проведено огляд відомих підходів до розв'язання задачі пошуку таких аномалій та запропоновано які саме інформаційні технології варто використовувати на етапах передоброблення, машинного глибинного навчання та які типові проблеми слід усувати під час цього, з урахуванням специфіки предметної області, у т.ч. врахування регулярності окремих елементів зображення (грядок, рядів кущів, дерев тощо).

Як основні критерії, які варто враховувати для розв'язання поставленої задачі запропоновано враховувати такі: тривалість обчислення, точність (мінімальна похибка) навчання моделі, наближеність середньої площі кластерів до заданої, за умови виконання низки обмежень. Запропоновано вираз інтегрального критерію для врахування цих критеріїв та підходи щодо вибору їх ваг. Розроблено алгоритм застосування запропонованих підходів та прийомів щодо застосування відомих методів машинного глибинного навчання та кластеризації. Наведено реальний приклад застосування цього алгоритму та продемонстровано його ефективність. Показано, що в залежності від того, який критерій вважається найвагомим (тривалість обчислень чи наближеність середньої площі кластерів до заданої), змінюється і результат.

Запропонований комплекс підходів та прийомів для системного аналізу розмірів фрагмента зображень аерофотозйомки СГУ дозволить підвищити точність та швидкість пошуку аномалій у них методами машинного глибинного навчання та, в цілому, дозволить ефективніше та вчасно виявляти різні захворювання рослин, бур'яни, шкідників тощо.

## СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] C. Kyrkou, G. Plastiras, T. Theocharides, S. I. Venieris, and C. S. Bouganis, "DroNet: Efficient Convolutional Neural Network Detector for Real-Time UAV Applications," in *Design, Automation Test in Europe Conference Exhibition*, 2018, pp. 967-972.
- [2] A. Sharif Razavian, H. Azizpour, J. Sullivan, and S. Carlsson, "Cnn features off-the-shelf: an astounding baseline for recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2014, pp. 806-813.
- [3] L. M. Dang, et al., "Drone Agriculture Imagery System for Radish Wilt Disease Identification via Efficient Convolutional Neural Network," *Sustainable Computing: Informatics and Systems*, 2018. [Online]. Available: <https://doi.org/10.1016/j.suscom.2018.05.010>. Accessed on: June 13, 2019.
- [4] Y. Bouroubi, et al., "Pest Detection on UAV Imagery using a Deep Convolutional Neural Network," in *Proceedings of the 14th International Conference on Precision Agriculture*, Montreal, Quebec, Canada, 2018.
- [5] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, 2016. [Electronic resource]. Available: <https://www.deeplearningbook.org/>.
- [6] Keras: The Python Deep Learning library, 2019/ [Electronic resource]. Available: <https://keras.io/>.

Рекомендована кафедрою системного аналізу, комп'ютерного моніторингу та комп'ютерної графіки ВНТУ

Стаття надійшла до редакції 20.06.2019

**Мокін Віталій Борисович** — д-р техн. наук, професор, завідувач кафедри системного аналізу, комп'ютерного моніторингу та комп'ютерної графіки, e-mail: [vbmokin@gmail.com](mailto:vbmokin@gmail.com) ;

**Довгополюк Сергій Олександрович** — аспірант кафедри системного аналізу, комп'ютерного моніторингу та інженерної графіки, e-mail: [isergeyq@gmail.com](mailto:isergeyq@gmail.com) ;

**Лотоцький Андрій Олександрович** — студент факультету комп'ютерних систем та автоматики.

Вінницький національний технічний університет, Вінниця, Україна;

**Грузман Давид Михайлович** — директор компанії.

Компанія «Nestlogic», Тель-Авів, Ізраїль

V. B. Mokin<sup>1</sup>  
D. M. Groozman<sup>2</sup>  
S. O. Dovhopoliuk<sup>1</sup>  
A. O. Lototskyi<sup>1</sup>

## System Analysis of the Sizes of the Fragment of Images of Aerial Photography of Agricultural Lands for the Search of Anomalies in these by Machine Learning Methods

<sup>1</sup>Vinnitsia National Technical University, Ukraine;

<sup>2</sup>Company “Nestlogic”, Tel Aviv, Israel

*Big problems for agricultural lands (ACL) are plant diseases, pests, weeds and other anomalies. The rapid growth of such problem areas is of great harm if they are not found in time, localized and neutralized. With a large area and, often, inaccessibility to individual areas of the field, aerial photography from drones with its subsequent processing by artificial intelligence methods, machine learning, first of all — deep learning, is used to eliminate such problems. Each image is divided into small fragments and analyzed, but the result of the analysis essentially depends on the choice of the size of such fragments. The purpose of the study is to develop an integrated systems approach to analyzing and calculating the smallest fragment of aerial photography of an ACL, which is optimal for many criteria, to search for anomalies in them by the methods of machine deep learning. There has been carried out a review of known approaches to solving the problem of finding such anomalies and the information technologies have been proposed which should be used at the preprocessing, machine deep learning stages and the typical problems which should be eliminated during this, taking into account the specifics of the subject area. The main criteria that should be taken into account to solve the problem are highlighted: the duration of the calculations, the accuracy (minimum error) of the model training, the proximity of the average area of clusters to the given one, subject to a number of restrictions. An expression of the integral criterion for taking into account these criteria and approaches to the choice of their weights are proposed. An algorithm has been developed for applying the proposed approaches and techniques for applying the known methods of machine depth learning and clustering. A real example of the application of this algorithm is given and its efficiency is demonstrated for cases where the most significant (with weighing 0,5) criterion is the duration of the calculations and when the proximity of the average area of clusters to the given one. The proposed set of approaches and techniques for systematic analysis of the size of a fragment of an aerial photography image of the ACL will improve the accuracy and speed of searching for anomalies in them by machine deep learning methods and, in general, will allow for more efficient and timely detection of various plant diseases, weeds, pests, and the like.*

**Keywords:** aerial photography, image analysis, autoencoder, deep training, machine learning, agricultural land, detection of anomalies, clusterization.

**Mokin Vitalii B.** — Dr. Sc. (Eng.), Professor, Head of the Chair of Systems Analysis, Computer Monitoring and Engineering Graphics, e-mail: vbmokin@gmail.com ;

**Groozman Davyd M.** — Director of the Company;

**Dovhopoliuk Serhii O.** — Post-Graduate Student of the Chair of Systems Analysis, Computer Monitoring and Engineering Graphics, e-mail: isergeyq@gmail.com ;

**Lototskyi Andrii O.** — Student of the Department of Computer Systems and Automation

**В. Б. Мокин<sup>1</sup>**  
**Д. М. Грузман<sup>2</sup>**  
**С. А. Довгополук<sup>1</sup>**  
**А. А. Лотоцкий<sup>1</sup>**

## **Системный анализ размеров фрагмента изображений аэрофотосъемки сельскохозяйственных угодий для поиска аномалий в них методами машинного обучения**

<sup>1</sup>Вінницький національний технічний університет, Україна;

<sup>2</sup>Компания «Nestlogic», Тель-Авив, Израиль

*Большими проблемами для сельскохозяйственных угодий (СХУ) являются заболевания растений, действие вредителей, сорняки и другие аномалии. Быстрое нарастание подобных проблемных мест несет большой вред, если их вовремя не найти, локализовать и нейтрализовать. При большой площади и, часто, труднодоступности к отдельным участкам поля, для устранения таких проблем применяется аэрофотосъемка с беспилотников с последующей ее обработкой методами искусственного интеллекта, машинного обучения, прежде всего — глубинного обучения. Каждое изображение разбивается на мелкие фрагменты и анализируется, но результат анализа существенно зависит от выбора размера таких фрагментов. Цель исследования — разработать комплексный системный подход к анализу и вычислению оптимального по многим критериям размера наименьшего фрагмента изображения аэрофотосъемки СХУ для поиска аномалий в них методами машинного глубинного обучения. Проведен обзор известных подходов к решению задачи поиска таких аномалий и предложены информационные технологии, которые следует использовать на этапах предобработки, машинного глубинного обучения и какие типовые проблемы следует устранять во время этого, с учетом специфики предметной области. Выделены основные критерии, которые следует учитывать для решения поставленной задачи: длительность расчетов, точность (минимальная ошибка) обучения модели, близость средней площади кластеров к заданной, при условии выполнения ряда ограничений. Предложено выражение интегрального критерия для учета этих критериев и подходы к выбору их весов. Разработан алгоритм применения предложенных подходов и приемов по применению известных методов машинного глубинного обучения и кластеризации. Приведен реальный пример применения этого алгоритма и продемонстрирована его эффективность для случаев, когда наиболее весомыми (с весом 0,5) критериями являются длительность расчетов и близость средней площади кластеров к заданной. Предложенный комплекс подходов и приемов для системного анализа размеров фрагмента изображения аэрофотосъемки СХУ позволит повысить точность и скорость поиска аномалий в них методами машинного глубинного обучения и, в целом, позволит более эффективно и своевременно выявлять различные заболевания растений, сорняки, вредителей и тому подобное.*

**Ключевые слова:** аэрофотосъемка, анализ изображений, автоэнкодер, глубинное обучение, машинное обучение, сельскохозяйственное угодье, выявление аномалий, кластеризация.

**Мокин Виталий Борисович** — д-р техн. наук, профессор, заведующий кафедрой системного анализа, компьютерного мониторинга и инженерной графики, e-mail: vbmokin@gmail.com ;

**Грузман Давид Михайлович** — директор компании «Nestlogic»;

**Довгополук Сергей Александрович** — аспирант кафедры системного анализа, компьютерного мониторинга и инженерной графики, e-mail: isergeyq@gmail.com ;

**Лотоцкий Андрей Александрович** — студент факультета компьютерных систем и автоматизации