

Цибуля Сергій Анатолійович (кандидат технічних наук, старший дослідник)¹
Ратушний Сергій Анатолійович¹
Цибуля Надія Сергіївна²

¹ Національний університет оборони України, Київ, Україна

² Львівський національний університет імені Івана Франка, Львів, Україна

СТВОРЕННЯ МАСКУВАЛЬНИХ МАЛЮНКІВ ЗА ДОПОМОГОЮ МАШИННОГО НАВЧАННЯ

Стрімкий розвиток технологій штучного інтелекту відкриває значні перспективи використання нейронних мереж як методу машинного навчання для розроблення засобів маскування. Метою статті є висвітлення результатів використання алгоритмів машинного навчання, зокрема, згорткового варіаційного автоенкодера, для аналізу текстурних особливостей різних типів місцевостей, генерування текстурних паттернів та створення маскувального малюнку засобів маскування. На основі отриманих результатів були створені маскувальні малюнки засобів маскування, характерні для конкретних типів місцевості, зображення яких слугували вхідними даними. Під час роботи використані наступні методи досліджень: кількісний аналіз для оцінки якості відтворення зображень порівняно з оригіналами, якісний аналіз для перевірки візуальної якості згенерованих та відтворених зображень, а також структурний аналіз архітектури нейронної мережі та її впливу на результати моделювання. Всі ці методи є складовими частинами процесу застосування згорткових варіаційних автоенкодерів, які є одним із видів нейронних мереж та належать до класу генеративних моделей. Отримані результати розрахунків середнього значення латентного простору й відтворені, на їх основі, узагальнення зображення місцевості, свідчать про високий рівень ефективності розглянутих методів. Це є новим підходом до розв'язання проблеми створення маскувальних малюнків та розширює відомі способи розроблення засобів маскування. Визначено, що у контексті створення маскувальних малюнків варіаційні автоенкодери, завдяки своїй архітектурі та принципу роботи, мають декілька переваг перед іншими алгоритмами машинного навчання: вони здатні кодувати зображення у низькорозмірні простори та декодувати/відтворювати їх, можуть автоматично виділяти текстурні особливості місцевості та генерувати нові зразки на основі навчених розподілів. Інтеграція методів машинного навчання у наукове обґрунтування підвищення ефективності виконання інженерних заходів маскування військ та об'єктів становить наукову новизну цього дослідження. Результати використання нейронної мережі, під час розроблення засобів маскування, свідчать, що сучасні методи машинного навчання дають змогу створювати більш реалістичні та ефективні маскувальні малюнки порівняно з традиційними підходами. Практичне впровадження результатів досліджень у вітчизняний військово-промисловий комплекс може сприяти розробленню більш ефективних засобів маскування, що підвищують безпеку особового складу та військової техніки на полі бою.

Ключові слова: машинне навчання, згорткова нейронна мережа, варіаційний автоенкодер, маскувальний малюнок, маскувальний візерунок, засіб маскування, текстурні особливості місцевості, зображення місцевості, текстурний паттерн, текстура, маскування, приховування.

Вступ

Виконання інженерних заходів маскування військ і об'єктів у сучасних військових операціях відіграє важливу роль у забезпеченні безпеки особового складу, озброєння, військової техніки та інших важливих військових об'єктів. Застосування засобів маскування забезпечує зменшення можливостей противника по розвідці та виявленню об'єктів, що своєю чергою зменшує ймовірність їх знищення або виведення з ладу.

Однією з ключових властивостей засобу маскування є його здатність візуально відповідати навколишньому ландшафту. Для забезпечення високого рівня візуальної непомітності на

маскувальному малюнку (далі – ММ) засобу маскування відтворюються текстура та колірна палітра місцевості. Тому дослідження текстурних особливостей місцевості є важливим етапом у процесі розроблення нових засобів маскування.

Зазвичай для створення ММ залучалися професійні художники та дизайнери, але зі збільшенням обчислювальних потужностей комп'ютерної техніки та розвитком технологій машинного навчання, широко почали впроваджуватися методи їх автоматичного генерування. Не зважаючи на значні технологічні досягнення в цій області складність дослідження текстурних особливостей місцевості залишається високою.

Розроблення засобів маскування для Збройних Сил України потребує дослідження місцевості нашої країни, текстурні особливості якої залежать від типу ландшафту. Проведення таких досліджень дає змогу проаналізувати характеристики місцевості усіх природних зон території України, та на основі отриманих даних розробити комплексний методичний апарат, спрямований на ефективне проєктування та створення ММ.

Постановка проблеми. Важливим аспектом ефективності процесу маскування є точне відтворення текстур місцевості на маскувальних матеріалах. Проте чинні методики визначення текстур місцевості не завжди відповідають вимогам військової галузі, в наслідок залежності від ручного контролю та експертних оцінок.

Водночас технології машинного та глибокого навчання пропонують автоматизовані рішення для визначення текстурних особливостей місцевості, дають змогу враховувати широкий спектр факторів, що впливають на текстуру, скоротити час аналізу великих об'ємів даних, до яких відносяться набори різних зображень (dataset), удосконалюючи якість генерування ММ. Основна ідея полягає в навчанні нейронних мереж на великих наборах зображень місцевості для генерування нових синтетичних зображень, що відобразатимуть середні характеристики вхідного набору та будуть частково схожими на основну частку таких зображень.

Оскільки створення ідеального ММ для всіх природних середовищ є важко досяжним, то основним завданням є проєктування дизайну ММ, що буде максимально ефективним в різних умовах застосування. Усе це робить важливим і актуальним проведення досліджень з визначення текстурних особливостей місцевості, а також формування нових способів їх генерування. Отримані результати можуть сприяти підвищенню ефективності маскування військових об'єктів у різних географічних умовах і оперативній обстановці.

Аналіз останніх досліджень і публікацій. Визначення текстурних особливостей місцевості широко застосовується у галузях, пов'язаних із зондуванням Землі, щодо аналізу аеро- та супутникових знімків [1]. Сьогодні відомо більше десятка різних методів виділення текстурних ознак, проте універсального методу, що дає змогу описати всю різноманітність текстур, не існує [2]. Наявні методи аналізу та генерації текстур можна розділити так:

1. Статистичні методи базуються на аналізі властивостей зображення, виходячи з припущення про певну узгодженість або регулярність цих властивостей відносно до визначених текстур та зосереджуються на визначенні текстурних властивостей за допомогою статистичних параметрів. Ці методи є ефективними для простих текстур, але можуть бути неефективними для складних текстур або в умовах змінного освітлення [3].

2. Параметричні методи ґрунтуються на використанні наявних параметрів для опису структури та особливостей текстур, що дає змогу ефективно відтворювати текстурні особливості відомих типів місцевості [4].

3. Методи, що базуються на локальних особливостях зображення, призначені для виявлення, опису та зіставлення особливостей або ключових точок на зображеннях. Основна ідея цих методів полягає у знаходженні таких точок на зображенні, які будуть надійно виявлені в різних умовах спостереження та зміни масштабу, орієнтації, освітлення тощо [5].

4. Методи, що засновані на машинному навчанні для аналізу та генерації текстур, зокрема згорткові нейронні мережі (англ. convolutional neural network (CNN)). Завдяки своїй спроможності виявляти ієрархічні залежності на зображеннях, CNN можуть ефективно визначати та відтворювати складні текстурні особливості [6].

Кожен з наведених методів має свої переваги та недоліки. Наприклад, методи машинного навчання можуть забезпечити високу якість генерації, але вони вимагають великої кількості початкових даних для навчання і є ресурсо- та часовитратними. Статистичні методи та методи, засновані на локальних особливостях, не можуть забезпечити високу точність і мають слабку здатність адаптації до нових текстурних випадків. Параметричні методи обмежені у здатності генерації нових типів текстур.

Останніми десятиліттями проводилася низка досліджень щодо використання машинного та, зокрема, глибокого навчання спрямованих на визначення і класифікацію текстур місцевості та подальшу їх генерацію. Новий підхід до створення деформаційного ММ, що ґрунтується на глибокому аналізі фонові текстури місцевості, запропоновано в роботі [7]. Для виявлення ключових особливостей фонові текстури місцевості використовується CNN. Після визначення основних особливостей текстури, застосовується алгоритм комбінації точкових контурів текстури та аналізу середнього кольору обраної площі. Це дає змогу формувати ММ який може мати дизайн у вигляді композиції з нерегулярних плям або піксельний малюнок.

Використання генеративно-змагальної мережі (англ. generative adversarial network (GAN)) для деталізованої генерації плям на маскувальних малюнках було висвітлено у науковій роботі [8]. За допомогою безпілотних літальних апаратів, було зібрано і систематизовано два значних набори даних, що являють собою зображення луків та лісових масивів. Застосуванням алгоритму кластеризації AFK-MC2 (наближений k-середній ланцюг Маркова на основі методу Монте-Карло (approximate k-means Markov chain Monte-Carlo)) було виділено специфічні форми плям на фоновій поверхні отриманих зображень місцевості. Після класифікації зображення плям вони були оброблені GAN. У результаті навчання мережі отримано модель, яка ефективно генерує ММ для відповідних

ділянок місцевості.

Аналіз і обробка зображення місцевості попередньо навченою нейронною мережею VGG-19, яка є частиною сімейства мереж Very Deep Convolutional Networks (дуже глибокі згорткові мережі), було використано у роботі [9]. Завдяки своїм згортковим прошаркам, ця мережа ефективно виділяє ключові особливості на зображеннях, що характерні для текстур місцевості.

Нейронна мережа VGG-19 також була застосована в іншій роботі, щодо генерації ММ [10]. Автори дослідження зосередили увагу на попередній обробці зображень місцевості. За допомогою алгоритму кластеризації K-means, зображення були оброблені та поділені на групи за схожістю кольорів. Такий підхід дав змогу виділити характерні кольори та акцентувати на контрастних елементах пейзажу, що сприяло створенню ММ, які гармонійно відповідають колірній палітрі місцевості.

Усі розглянуті дослідження вказують на потенціал машинного навчання у сфері аналізу місцевості, визначення її текстур та генерування на їх основі ММ. Проте, більшість з них стикається з проблемами масштабування та адаптивності до змінних умов. Тому, не зважаючи на значний прогрес в цій галузі, існує актуальна потреба в розробленні більш ефективних методів роботи з текстурами, що сприятиме вдосконаленню процесу генерування ММ при розробленні засобів маскування.

Метою статті є висвітлення результатів використання алгоритмів машинного навчання, зокрема згорткового варіаційного автоенкодера, для аналізу текстурних особливостей різних типів місцевостей, генерування текстурних паттернів (англ. pattern – зразок, шаблон) та створення маскувального малюнку засобів маскування.

Виклад основного матеріалу дослідження

Важливим завданням при проектуванні засобу маскування є визначення текстурних особливостей місцевості та генерування на їх основі текстурованого зображення ММ. Визначення текстурних особливостей місцевості є складним завданням через його високу варіабельність, залежність від пори року, погодних умов, що впливають на освітлення та від перспективи спостереження або фотографування місцевості.

Генеративні моделі на основі глибокого навчання за останні роки демонструють значний прогрес та демонструють разючі результати. Завдяки використанню великих наборів вхідних даних (dataset), оптимізованих архітектур мереж та ефективних методів навчання, такі моделі дають змогу генерувати високоякісний контент, зокрема зображення. У контексті генеративних моделей особливо цікавими є два напрями розвитку нейронних мереж: генеративно-змагальні мережі та варіаційні автоенкодери (англ. variational

autoencoder (VAE)).

Генеративно-змагальні мережі являють собою технологію в області глибокого навчання, що швидко прогресує. Ці мережі здатні до вивчення основних особливостей та закономірностей, притаманних вхідному набору даних. На підставі такого аналізу можна створювати нові зображення, яким притаманні характеристики вхідних даних.

Варіаційні автоенкодери є одним із видів архітектури нейронних мереж, зі сфери прикладного машинного навчання з підкріпленням, та є потужним інструментом, що використовується для генерації та відновлення даних [11]. VAE є генеративними моделями, які здатні визначати складні розподіли даних на основі вхідних зразків, та можуть не тільки відновлювати дані, але і генерувати нові дані, що базуються на навчанні по зразках. За допомогою VAE можна вивчати текстурні особливості зображень, виявляти ключові властивості та групувати зображення зі схожими текстурними рисами. Така здатність робить VAE одним з ефективних алгоритмів аналізу текстур.

Варіаційні автоенкодери мають декілька важливих особливостей:

1. Однією з основних властивостей VAE є здатність втілювати високорозмірні дані, такі як зображення, в низькорозмірний латентний (скритий) простір, зберігаючи при цьому важливі характеристики даних. Це є важливим в області обробки зображень місцевості, оскільки кожен піксель несе візуальну інформацію, і зменшення розмірності може призвести до втрати ключового змісту зображення.

2. Алгоритм VAE забезпечує нормальний розподіл у латентному просторі, що сприяє плавним переходам між точками в цьому просторі. Це означає, що для створення усередненого зображення можна взяти усереднене значення латентних векторів відповідних зображень, і це середнє значення буде відповідати реалістичному зображенню.

3. Оскільки VAE використовує регуляційну компоненту у своїй функції втрат, модель генерує зображення, які лежать близько до вхідних даних.

4. Навчання VAE, у порівнянні з GAN, є більш стабільним та прогнозованим, особливо коли йдеться про відтворення вхідних даних.

Хоча GAN можуть виглядати привабливим вибором для генерування текстур, їх застосування є доволі складним і потребує додаткової регуляризації та контролю над латентним простором параметрів, а результати не завжди відповідають очікуванім.

Ураховуючи наведені вище фактори, для відтворення усередненого зображення набору даних, VAE було вибрано як основний інструмент визначення текстурних особливостей місцевості та генерування текстурних паттернів ММ засобів маскування.

Структурно проектування ММ за допомогою VAE складається з таких етапів:

підготовки та попереднє оброблення вхідних зображень місцевості;

визначення глобальних параметрів VAE (кількість та розміри прошарків мережі, функція втрат, оптимізатор, алгоритм оцінки відновлених даних тощо);

навчання VAE на зображеннях;

генерування текстурного паттерну (розрахунок та отримання усередненого зображення місцевості);

створення ММ (постоброблення отриманого зображення, розпламування та його розфарбування у характерні кольори місцевості).

Підготовки вхідних даних є важливим кроком в будь-якому проєкті машинного навчання, що може значно підвищити ефективність і надійність навчання моделі, та складається з:

приведення розміру вхідних зображень до однакових значень і пропорцій;

аугментація зображень (від лат. *augmentum* – прирощення) для збільшення розміру та різноманітності dataset;

змінування масштабу зображень до розмірів, що відповідають потужності електронно-обчислювальних машин, об'єму його оперативної пам'яті та пам'яті відеокarti;

оброблення зображень фільтрами для виділення характерних особливостей текстури місцевості, видалення шуму та незначних елементів, які не впливають на загальне сприйняття пейзажу;

нормалізація значення пікселів у діапазоні $[0;1]$, для оптимізації роботи алгоритму машинного навчання.

Для відокремлення текстурних характеристик місцевості, було використано фільтр Canny, який використовується для розпізнавання контурів на зображеннях, виокремлюючи області з високим градієнтом інтенсивності, які відповідають краям [12]. Підсилення цих властивостей полегшує роботу алгоритмів машинного навчання у розпізнаванні та аналізі текстур. У результаті застосування фільтра Canny вихідне зображення є чорно-білим (рис. 1).




Рисунок 1 – Фотознімок місцевості України з мережі Internet (верхній рядок зліва на право: діброва, сосновий бір, різнотравний степ), результати оброблення фільтром Canny (середній рядок) та зображення, що відновлені VAE (нижній рядок)

Архітектура VAE складається з енкодера (encoder), декодера (decoder) та латентного простору. Структура VAE, гіперпараметри, кількість прошарків та розміри скритого простору тощо визначаються емпірично через серію дослідів. Ураховуючи те що, вхідними даними є зображення, для їх обробки основним типом прошарків вибрано згорткові *SeparableConv2D* з бібліотеки *Keras* фреймворку для машинного навчання *TensorFlow*, що розроблений компанією *Google* [13].

Завдання енкодера полягає в перетворенні вхідних зображень місцевості на параметри ймовірнісного розподілу $q(z|X)$ в латентному просторі. Розподіл, який базується на спостереженнях вхідних даних та передбаченнях моделі стосовно латентного простору, називається

апостеріорним [11]. Такий розподіл є розподілом ймовірностей невідомого параметра чи набору параметрів, що базується на спостережених даних згідно з теоремою Баєса. У контексті моделей, таких як VAE, енкодер намагається знайти розподіл латентних змінних z , що найкраще описує вхідні дані X . Латентні змінні z допомагають стиснути вхідні дані до їх сутності в латентному просторі та потім реконструювати їх в оригінальному просторі даних за допомогою декодера.

Використовуючи згорткову нейронну мережу, енкодер перетворює вхідне зображення X у два вектори: середніх значень (математичне сподівання) μ та дисперсію σ^2 розподілу. Через стохастичний процес вибірки з цього розподілу вибираються випадкові значення латентних

змінних z , що подаються на вхід декодера для генерації та відновлення зображення \hat{X} . З метою полегшення процесу навчання та стабілізації процесу оптимізації в алгоритмі VAE замість дисперсії використовується її логарифм. Це дає змогу моделі передбачати значення в необмеженому діапазоні, яке потім може бути перетворено в позитивний діапазон для дисперсії за допомогою експоненціальної функції.

Процес кодування формалізується виразом:

$$Encoder(X) = q(z|X) = \mathcal{N}(z; \mu, \sigma^2 I), \quad (1)$$

де $q(z|X)$ – апостеріорний розподіл латентних змінних z для вхідних даних X ;

\mathcal{N} – позначення нормального розподілу;

$\sigma^2 I$ – діагональна коваріаційна матриця;

I – одинична матриця.

Множення кожного елементу одиничної матриці на σ^2 дає діагональну матрицю, де всі діагональні елементи дорівнюють σ^2 . Це відображає припущення, що всі латентні змінні незалежні одна від одної, тобто вони не корелюють, і мають однакову дисперсію σ^2 . Тому використання $\sigma^2 I$ встановлює, що всі позадіагональні (недіагональні) елементи коваріаційної матриці дорівнюють нулю, що вказує на відсутність кореляції між латентними змінними та забезпечує однакову дисперсію σ^2 для кожної латентної змінної. У контексті VAE це припущення спрощує модель та обчислення.

Зразок z з латентного простору генерується за допомогою виразу:

$$z = \mu + \sigma \odot \varepsilon, \quad (2)$$

де ε – випадковий вектор, що відповідає стандартному нормальному розподілу $\mathcal{N}(0,1)$;

σ – стандартне відхилення;

\odot – поелементне множення.

Декодер являє собою зворотню згорткову нейронну мережу, де звичайні згортки замінюються на транспоновані згортки Conv2DTranspose. На вхід декодер отримує випадковий зразок z з латентного простору та відтворює вихідне зображення \hat{X} :

$$Decoder(z) = p(X|z) = \mathcal{N}(X; g(z), \Sigma) \rightarrow \hat{X}, \quad (3)$$

де $g(z)$ – функція, яка визначає середнє значення розподілу відновленого зображення;

Σ – коваріаційна матриця, що вказує на структуру шуму в розподілі відтворення;

\hat{X} – відновлене зображення;

z – випадковий зразок з розподілу $q(z|X)$.

$p(X|z)$ – умовний розподіл ймовірностей вихідних даних X при заданому значенні латентної змінної z . В контексті варіаційних автоенкодерів розподіл $p(X|z)$ вважається «генеративною моделлю».

В основі VAE лежить ідея оптимізації обмеженого ймовірнісного розподілу, тобто намагання зробити апостеріорний розподіл $q(z|X)$ якомога ближчим до апіорного розподілу $p(z)$, що зазвичай є стандартним нормальним розподілом. Основна мета роботи алгоритму VAE – мінімізувати різницю між вхідними даними та їх відтворенням, а також регуляризувати латентний

простір. Важливим елементом цього алгоритму є функція втрат. Функція втрат для VAE складається з двох частин: перша частина відповідає за відновлення даних, і вона мотивує декодер відновлювати вхідні дані якомога точніше; друга частина є регуляризаційною, яка вимагає, щоб латентний розподіл був близьким до стандартного нормального розподілу, що сприяє загальній узагальнювальній здатності моделі.

Функція втрат VAE виглядає так:

$$L(X, \hat{X}, z) = -E_{q(z|X)}[\log p(X|z)] + KL(q(z|X)||p(z)), \quad (4)$$

де E – математичне сподівання втрат від відновлення (reconstruction loss);

KL – розходження Кульбака-Лейблера (divergence Kullback-Leibler) між апіорним розподілом $p(z)$ та апостеріорним розподілом $q(z|x)$.

Втрати при відновленні вимірюють різницю між початковим зображенням X і зображенням, створеним декодером \hat{X} . Порівняння чорно-білих зображень доцільно виконувати за допомогою бінарної перехресної ентропії (англ. Binary Cross-Entropy (BCE)), яка описується виразом:

$$Loss_{BCE} = -\frac{1}{M} \sum_{m=1}^M [x_m \log \hat{x}_m + (1 - x_m) \log(1 - \hat{x}_m)], \quad (5)$$

де M – загальна кількість пікселів у зображенні;

x – значення пікселя m ;

\hat{x} – відновлене значення пікселя m .

Завдання VAE полягає у відтворенні вхідних даних та створенні ефективного та структурованого представлення даних у латентному просторі для генерації нових зразків. Для досягнення цього, в алгоритм VAE вводиться регуляризаційна складова, що починає впливати на модель у випадку відхилення латентних змінних від нормального розподілу. Математично ця регуляризаційна складова вимірює відмінність між розподілом, з якого було взято z , та стандартним нормальним розподілом:

$$KL(q(z|X)||p(z)) = 0,5(\sigma_q^2 + \mu_q^2 - 1 - \log(\sigma_q^2)), \quad (6)$$

де $q(z|X)$ – розподіл з параметрами μ_q і σ_q^2 , що вивчаються моделлю і представляють відповідно середнє значення та дисперсію латентного розподілу q для конкретного вхідного з даних X ;

$p(z)$ – стандартний нормальний розподіл з параметрами $\mu_p = 0$ і $\sigma_p^2 = 1$.

У наслідок не ідентичності вхідного та відновленого зображення, значення показника оцінки відновлення даних може суттєво перевищувати значення KL, що призводить до нівелювання впливу на загальну похибку значень KL. Для урівноваження значень цих показників вводиться гіперпараметр β [14]. Тоді вираз (4) буде мати такий вигляд:

$$L(X, \hat{X}, z) = -E_{q(z|X)}[\log p(X|z)] + \beta KL(q(z|X)||p(z)). \quad (7)$$

Адаптивний розрахунок гіперпараметра β дає змогу динамічно балансувати між двома частинами функції втрат – відтворенням вхідних даних і регуляризацією.

Навчання варіаційного автоенкодера та аналіз отриманих результатів.

Навчання VAE проводилось на 3 окремих dataset: сосновий бір з початковою кількістю зображень 3850 шт.; діброва – 2807 шт., степ різотравний – 5785 шт.

Під час навчання виконувався моніторинг значень показника відновлення вхідних даних (рис. 2) та значень регуляризації латентного простору KL (рис. 3) з метою контролю за процесом навчання та корегування гіперпараметрів моделі.




Рисунок 2 – Графік значень показника відновлення вхідних даних (reconstruction loss)




Рисунок 3 – Графік значень регуляризації латентного простору Kullback-Leibler




Рисунок 4 – Гістограми розподілу значень математичного сподівання та дисперсії

Ріст значень KL та зниження показника відновлення свідчать про збалансованість навчання, під час якого VAE прагне знайти баланс між точністю відновлення вхідних даних та регуляризацією латентного простору. Збільшення KL вказує на те, що модель починає використовувати латентний простір більш активно для кодування інформації про дані. В наслідок чого

латентний простір стає більш інформативним та добре структурованим. Аналіз гістограм показує, що значення ваг мають нормальний розподіл, середні значення цих ваг зосереджено близько до нуля, що свідчить про те, що більшість ваг центровані навколо цього значення (рис. 4). Такі характеристики розподілу є позитивними для навченої моделі.

По завершенню процесу навчання виконується перевірка (валідація) роботи моделі VAE на окремому наборі даних для визначення здатності моделі відтворювати адекватні зображення (рис. 1).

Декодування середнього значення у латентному просторі та відтворення узагальненого зображення, що являє собою текстурний паттерн ММ.

Важливою частиною властивостей VAE є здатність моделі кодувати зображення у латентному просторі та надалі відтворювати ці зображення. Цей процес дає змогу отримати узагальнені або «середні» зображення набору вхідних даних.

Визначення середнього значення латентних векторів для обраного набору зображень, виконується за виразом:

$$z_{avg} = \frac{1}{M} \sum_{i=1}^M z_i, \quad (8)$$

де M – кількість зображень у наборі,

z_i – латентний вектор i -го зображення.

Надалі визначене середнє значення латентного вектора z_{avg} передається на вхід декодера для отримання узагальненого зображення місцевості:

$$\hat{X}_{avg} = \text{Decoder}(z_{avg}). \quad (9)$$

Результати роботи VAE щодо розрахунку середнього значення латентного вектора та на його основі генерації узагальненого зображення місцевості наведені у верхньому рядку рисунку 5.

Створення маскувального малюнку виконується шляхом розплямування отриманого зображення текстурного паттерну та розфарбування його у характерні для місцевості кольори, визначені у попередньому дослідженні [15] та представлені в таблиці 1. Для досягнення цієї мети використовується процес квантування зображень (англ. Quantization) [16] до фіксованої кількості кольорів. За результатами квантування отримані кластери (табл. 2), розміри яких відповідають частці характерних кольорів від загальної палітри (табл. 1), що підтверджує відповідність запропонованого методу генерації текстурних паттернів ММ. Надалі отримані кластери заповнюються відповідними кольорами з таблиці 1. Результати створення маскувальних малюнків наведено у нижньому рядку рисунку 5.

Таблиця 1

Колірна палітра місцевості [15]

Назва	Колір у форматі RGB, частка від загальної палітри, %							
Сосновий бір	[160, 169, 116]	26	[51, 51, 30]	30	[105, 115, 69]	29	[219, 228, 183]	15
Діброва	[38, 56, 29]	27	[136, 168, 128]	5	[79, 104, 67]	14	[10, 20, 6]	54
Степ	[92, 92, 36]	31	[121, 120, 59]	37	[149, 146, 89]	16	[52, 55, 14]	18

Назва	Відсоток кластерів на зображенні місцевості			
	Розмір кластеру на зображенні, %			
Сосновий бір	23.51	34.89	28.28	13.31
Діброва	30.59	6.09	14.11	49.21
Степ	31.13	35.97	13.86	19.03




Рисунок – 5 Згенеровані зображення місцевості (зліва на право: діброва, сосновий бір, степ)

Висновки й перспективи подальших досліджень

В статті висвітлено спосіб визначення текстурних особливостей місцевості та генерування текстурних паттернів ММ засобів маскуванню, що базується на використанні нейронної мережі – згорткового варіаційного автоенкодера, та його здатності відтворювати узагальнені зображення місцевості, шляхом декодування середнього значення у латентному просторі. Отримані результати свідчать, що VAE може виявляти текстурні особливості місцевості з високою точністю. Згенеровані текстурні паттерни та створенні на їхній основі ММ відповідають місцевості, зображення якої використовувалися як вхідні дані для їх розробки.

Практичне впровадження результатів проведених досліджень у вітчизняний військово-промисловий

комплекс відкриває значні перспективи для розроблення ефективних засобів маскуванню військових об'єктів, озброєння та військової техніки, особового складу тощо.

Напрямом подальших досліджень є проведення розрахунків проєкціонування отриманих ММ на маскувальні матеріали за типами застосування: індивідуальні засоби, маскувальні сітки для техніки та фарбувальні покриття на техніку та військові об'єкти тощо. Також потребує перевірки ефективності згенерованих текстурних паттернів та отриманих на їх основі ММ, шляхом оцінювання їхньої здатності зменшувати ймовірність виявлення об'єктів у різних умовах освітлення та фонів місцевості за допомогою комп'ютерного моделювання і практичних випробувань на місцевості, та здійснити порівняння отриманих результатів з іншими засобами маскуванню.

Список бібліографічних посилань

1. Пестунов И. А., Рылов С. А. Сегментация спутниковых изображений высокого разрешения по спектральным и текстурным признакам : материалы Междунар. науч. конгр. г. Новосибирск. 10-12 апреля. 2012 г. С. 96-102. 2. С.Н. Chen, L.F. Pau, P.S.P. Wang. The Handbook of Pattern Recognition and Computer Vision (2nd ed.). World Scientific Publishing Co. 1998. P. 207-248. 3. Yang P., Zhang F. L., Yang Z. J. Statistical image modeling based texture feature extraction in dual-tree complex wavelet transform domain. Control Decis. 2019. Vol. 34, №7. P. 1492-6. 4. Van D., Reisslein M., Karam L. J. Video texture and motion based modeling of rate variability-distortion (VD) curves. IEEE Trans Broadcast. 2007. Vol. 53, №3. P. 637-48. 5. Hong T. H., Dyer C. R., Rosenfeld A. Texture primitive extraction using an edge-based approach. IEEE Trans Syst Man Cybern. 2007. Vol. 10, №10. P. 659-75. 6. Gatys L. A., Ecker A. S., Bethge M. Texture Synthesis Using Convolutional Neural Networks. Advances in neural information processing systems 28. 2015. 9 p. DOI: 10.48550/arXiv.1505.07376. 7. Fennell J. G., Talas L., Baddeley R. J., Cuthill I. C., Scott-Samuel N. E. The Camouflage Machine: Optimizing protective

coloration using deep learning with genetic algorithms. Evolution. 2021. Volume 75, Issue 3. P. 614-624. DOI: 10.1111/evo.14162. 8. Yang X., Xu W.-d., Jia Q., Li L., Zhu W.-n., Tian J.-y., Xu H. Research on extraction and reproduction of deformation camouflage spot based on generative adversarial network model. Defence Technology. 2020. Volume 16, Issue 3. P. 555-563. DOI: 10.1016/j.dt.2019.06.021. 9. Wei X., Wang K., Li G., Kim H. An Automatic Design of Camouflage Patterns Based on CNNs. In Proceedings of the 2020 6th International Conference on Computing and Artificial Intelligence (ICCAI '20). Association for Computing Machinery. 2020. P. 257-260. DOI: 10.1145/3404555.3404637. 10. Wei X., Li G., Wang K. A Novel Method for Automatic Camouflage Pattern Synthesize. IEEE Access. 2021. Vol. 9. P. 67559-67568. DOI: 10.1109/ACCESS.2021.3077258. 11. Doersch C. Tutorial on variational autoencoders. 2016. DOI: 10.48550/arXiv.1606.05908. 12. Canny J. A Computational Approach to Edge Detection. in IEEE Transactions on Pattern Analysis and Machine Intelligence. Nov. 1986. Vol. PAMI-8, no. 6, P. 679-698. DOI: 10.1109/TPAMI.1986.4767851. 13. Keras Applications <https://keras.io/api/applications/>

(дата звернення: 04.10.2023). **14. Higgins I., Matthey L., Pal A., Burgess C., Glorot X., Botvinick M., Mohamed S., Lerchner A.** beta-VAE: Learning Basic Visual Concepts with a Constrained Variational Framework. International Conference on Learning Representations. 2017. 13 p. URL: <https://openreview.net/forum?id=Sy2fzU9gl> (дата звернення: 04.10.2023). **15. Цибуля С. А.** Визначення

характерних кольорів місцевості в процесі розроблення маскувальних засобів. Військово-технічний збірник. 2023. №28. С. 114-123. Львів: НАСВ. DOI: 10.33577/2312-4458.28.2023.114-123. **16. Frackiewicz M., Mandrella A., Palus H.** Fast Color Quantization by K-Means Clustering Combined with Image Sampling. Symmetry. 2019. Vol. 11, №8. DOI: 10.3390/sym11080963.

CREATING CAMOUFLAGE PATTERNS USING MACHINE LEARNING

Tsybulia Serhii (Candidate of Technical Sciences, Senior Researcher)¹

Ratushnyi Serhii¹

Tsybulia Nadia²

¹*The National Defence University of Ukraine, Kyiv, Ukraine*

²*Ivan Franko National University of Lviv, Lviv, Ukraine*

Formulation of the problem in general. The purpose of the article is to highlight the results of the research conducted on the possibility of using machine learning algorithms to create camouflage drawings. During the work, the following research methods were used: quantitative analysis to evaluate the quality of image reproduction and qualitative analysis to check the visual quality of the generated and reproduced images.

Analysis of recent research and publications indicates the potential of machine learning in the field of terrain analysis, the determination of its textures, and the generation of camouflage patterns based on them. However, most of them face problems with scaling and adaptability to changing conditions.

Presenting the main material. The obtained results of calculations of the average value of the latent space and the reproduction of generalized terrain images based on them demonstrate a high level of effectiveness of the proposed technique, which presents a new approach to solving the problem of developing effective camouflage patterns and expands the known methods of creating camouflage. In the course of research, it was determined that in the context of the development of masking drawings, variational autoencoders, due to their architecture and principle of operation, have several advantages over other machine learning algorithms: they are able to encode images into low-dimensional spaces and decode and reproduce them, they can automatically highlight the textural features of the terrain, and they can generate new samples based on trained distributions.

Elements of scientific novelty in this study include the incorporation of machine learning methods into the scientific justification for enhancing the effectiveness of engineering measures used to camouflage troops and objects. The use of a neural network has shown that modern machine learning methods provide an opportunity to create realistic camouflage patterns.

Practical significance of the article in the domestic military-industrial complex can contribute to the development of more effective means of camouflage that increase the safety of personnel and military equipment on the battlefield.

Conclusion and the perspectives of future researches is to determine the effectiveness of the obtained texture patterns and camouflage patterns generated on their basis by evaluating their ability to reduce the probability of detecting objects in different lighting conditions and terrain backgrounds using computer simulations and practical field tests.

Keywords: machine learning, convolutional neural network, variational autoencoder, camouflage pattern, camouflage set, terrain texture features, terrain image, texture pattern, texture, camouflage, concealment.

References

1. Pestunov, I.A. and Rylov, S.A. (2012). Segmentatsiya sputnikovyh izobrazheniy vysokogo razresheniya po spektralnym i teksturnym priznakam. Interexpo Geo-Sibir 2012, (4). pp.96-102. **2. Chen, C.H., Pau, L.F. and Wang, P.S.P.** (1998). The Handbook of Pattern Recognition and Computer Vision. 2nd ed. World Scientific Publishing Co., pp.207-248. **3. Yang, P., Zhang, F.L. and Yang, Z.J.** (2019). Statistical image modeling based texture feature extraction in dual-tree complex wavelet transform domain. Control Decis, 34(7), pp.1492-6. **4. Van, D., Reisslein, M. and Karam, L.J.** (2007). Video texture and motion based modeling of rate variability-distortion (VD) curves. IEEE Trans Broadcast, 53(3), pp.637-48. **5. Hong, T.H., Dyer, C.R. and Rosenfeld, A.** (2007). Texture primitive extraction using an edge-based approach. IEEE Trans Syst Man Cybern, 10(10), pp.659-75. **6. Gatys, L.A., Ecker, A.S. and Bethge, M.** (2015). Texture Synthesis Using Convolutional Neural Networks. Advances in neural information processing systems, 28, 9 p. DOI: 10.48550/arXiv.1505.07376. **7. Fennell, J.G., Talas, L., Baddeley, R.J. et al.** (2021). The Camouflage Machine: Optimizing protective coloration using deep learning with genetic algorithms. Evolution, 75(3), pp. 614-624. DOI: 10.1111/evo.14162. **8. Yang, X., Xu, W.-d., et al.** (2020). Research on extraction and reproduction of deformation camouflage spot based on generative adversarial network model. Defence Technology, 16(3), pp.555-563. DOI: 10.1016/j.dt.2019.06.021. **9. Wei, X., Wang, K., Li, G.**

and Kim, H. (2020). An Automatic Design of Camouflage Patterns Based on CNNs. In Proceedings of the 2020 6th International Conference on Computing and Artificial Intelligence (ICCAI '20). Association for Computing Machinery, pp.257-260. DOI: 10.1145/3404555.3404637. **10. Wei, X., Li, G. and Wang, K.** (2021). A Novel Method for Automatic Camouflage Pattern Synthesize. IEEE Access, 9, pp.67559-67568. DOI: 10.1109/ACCESS.2021.3077258. **11. Doersch, C.** (2016). Tutorial on variational autoencoders. DOI: 10.48550/arXiv.1606.05908. **12. Canny, J.** (1986). A Computational Approach to Edge Detection. in IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8(6), pp.679-698. DOI: 10.1109/TPAMI.1986.4767851. **13.** Keras Applications <https://keras.io/api/applications/> [Accessed 4 Oct. 2023]. **14. Higgins, I., Matthey, L., Pal, A. et al.** (2017). beta-VAE: Learning Basic Visual Concepts with a Constrained Variational Framework. International Conference on Learning Representations, 13 p. <https://openreview.net/forum?id=Sy2fzU9gl> [Accessed 4 Oct. 2023]. **15. Tsybulia, S.A.** (2023). Determination of the characteristic colors of the terrain in the development of camouflage means. Viyskovo-tekhnichnyy zbirnyk, 28, pp.114-123. Lviv: NASV. DOI: 10.33577/2312-4458.28.2023.114-123. **16. Frackiewicz, M., Mandrella, A. and Palus, H.** (2019). Fast Color Quantization by K-Means Clustering Combined with Image Sampling. Symmetry, 11(8). DOI: 10.3390/sym11080963.