

*Петровський А.А.*

незалежний дослідник

## СЕГМЕНТАЦІЯ СУПУТНИКОВИХ ЗНІМКІВ ЗА ДОПОМОГОЮ БІНАРНОГО ДЕРЕВОПОДІБНОГО НАЇВНОГО БАЄСА

*Данна стаття містить покращений алгоритм сегментації супутникових знімків, які були отримані за допомогою супутників місії Sentinel-2. Для створення рішення по сегментації зображень було проаналізовано актуальні методи сегментації. Як результат, було запропоновано використати метод, який базується на основі класифікатора Наївного Баєса.*

*Перевагою цього метода є те, що він не потребує значних обчислюваних потужностей та може використовуватися в режимі реального часу, що дозволяє його використовувати з відеопотоками. Було проаналізовано мультикласовий класифікатор, в результаті якого точність розпізнавання становить для 89%. Для покращення точності мультикласового класифікатора було вирішено використати бінарний деревоподібний класифікатор для збільшення точності сегментації, який поділяє мультикласовий класифікатор на послідовність бінарних класифікаторів. Автором було візуально зображено гістограми ймовірностей приналежностей для кожного з класів для обох класифікаторів та графік модуля абсолютної різниці між реальною кількістю пікселів та отриманою сегментатором для кожного з класів. Такий підхід дозволяє ефективніше розподіляти класи і точніше виділяти межі між різними об'єктами.*

*У результаті було отримано збільшення точності сегментації з 89% до 94%, що свідчить про надійність та ефективність запропонованого методу для конкретних застосувань у моніторингу природних ресурсів. Саме дослідження базувалося на таких категоріях: ліс, поле, вода, місто. У роботі також автор показав візуальне приклад візуального представлення результату розпізнавання для мультикласового та бінарного деревоподібного наївного Баєса поруч з реальним супутниковим знімком адаптованим до RGB. Основним недоліком методу є велика кількість ітерацій, необхідних для остаточного визначення приналежності до кожної категорії, а також скорочення даних для навчання на кожному наступному етапі ітерації. Вирішення цих проблем може ще краще покращити точність розпізнавання. В подальших дослідженнях планується вирішити цю проблему.*

**Ключові слова:** сегментація, машинне навчання, Наївний Байєс, Sentinel-2, класифікація, супутникові знімки, бінарний класифікатор.

**Постановка проблеми.** Сегментація зображень відіграє ключову роль в розумінні та інтерпретації візуальних даних та може використовуватися у різних сферах. Із швидким розвитком супутникової техніки з'явилася можливість отримувати зображення високої якості планети в режимі реального часу, що робить сегментацію супутникових знімків однією з найбільш актуальних задач сучасності.

Супутникові знімки, особливо отримані від супутника Sentinel-2, надають неймовірну можливість аналізу земних поверхонь завдяки їх високій частоті оновлення та високій просторовій роздільній здатності. На відміну від звичайних оптичних зображень, Sentinel-2 забезпечує дані в різних спектральних діапазонах, що розширює можливість для детектування та класифікації різних об'єктів на поверхні Землі. Даний метод сегментації може використовуватися для таких цілей як: виявлення повеней та пожеж, моніторинг полів та врожайності і т.д. [1].

### **Аналіз останніх досліджень і публікацій.**

Сучасні методи дослідження базуються в основному на згорткових нейронних мережах таких як: U-Net, SegNet та DeepLab. У роботі розглядається сегментація за допомогою нейронної мережі на базі U-Net для визначення сегментації сільськогосподарських угідь. У статті пропонується метод картографування рисових полів, який об'єднує сегментацію супутникових зображень високої роздільної здатності для визначення меж сільськогосподарських полів з класифікацією по пікселях на основі даних Sentinel-1. Точність даної моделі становить 95% [2].

Інший варіант використання архітектури семантичної сегментації, побудована з використанням механізму уваги (attention mechanism), яка спрямована на покращення точності та деталізації картографування сільськогосподарських культур на знімках Sentinel-2.

Базується архітектура на моделі, подібній до U-Net, з додаванням модулів уваги, які фокусу-

ються на важливих ділянках зображення, полегшуючи виділення дрібних деталей. Застосування модулів уваги дозволяє нейронній мережі акцентувати увагу на більш актуальних пікселях, що робить сегментацію більш точною [3].

**Метою статті** є розробка алгоритму сегментації на основі деревоподібного Наївного Баєса, що буде забезпечувати такі характеристики:

- Відносно висока швидкість навчання
- Покращена точність сегментації порівняно з стандартною мультикласовою сегментацією

**Виклад основного матеріалу дослідження.**

У таблиці 1 наведено канали, з яких складаються знімки для Sentinel-2 та їх основні характеристики [4].

Таблиця 1  
Основні шари супутникового знімку Sentinel-2

Канал	Діапазон (нм)	Розмір пікселя (м)	Основне застосування
B1	0.443	60	Аерозольні умови
B2	0.490	10	Синій
B3	0.560	10	Зелений
B4	0.665	10	Червоний
B5	0.705	20	Червоний край
B6	0.740	20	Червоний край
B7	0.783	20	Червоний край
B8	0.842	10	Ближній інфрачервоний
B8A	0.865	20	Червоний край
B9	0.945	60	Водяний пар
B10	1.375	60	Водяний пар
B11	1.610	20	Середній інфрачервоний
B12	2.190	20	Середній інфрачервоний

Дане дослідження базується на завданні сегментації, яка буде розділяти супутниковий знімок на чотири основні категорії: ліси, міста, поля, вода. Як зазначено в таблиці вище – кожне зображення в датасеті має 12 каналів, що відображають різноманітні спектральні характеристики земної поверхні. Завдяки тому, що для кожного пікселя міститься 12 каналів, в порівнянні зі звичними 3 для RGB зображень є можливість отримати більш деталізовану інформацію про кожну конкретну ділянку земної поверхні.

Наївний Байєс є моделлю умовної ймовірності, яка визначає ймовірності  $p(C_k|x_1, \dots, x_n)$  для кожного з  $K$  можливих результатів або класів  $C_k$  даної проблеми, яка має бути класифікована, представленій вектором  $x = (x_1, \dots, x_n)$ , що включає декілька  $n$  ознак, як незалежні змінні. Застосовуючи теорему Байєса, умовну ймовірність можна представити як:

$$p(C_k | x) = \frac{p(C_k) p(x | C_k)}{p(x)}$$

Формула 1. Формула умовної ймовірності

де

$p(C_k)$  – це ймовірність спостереження набору ознак  $x$  за умови, що об’єкт належить до класу  $C_k$ ,  $p(x | C_k)$  – апіорна ймовірність класу  $C_k$ , тобто ймовірність того, що довільно вибраний об’єкт належить до класу  $C_k$ , до того, як було враховано ознаки об’єкта,

$p(x)$  – ймовірність спостереження набору ознак  $x$  незалежно від класу [5].

На практиці, нас цікавить лише чисельник цього дробу, оскільки знаменник не залежить від  $C$  та значення ознак  $x_i$  є заданими, тому знаменник є фактично сталим. Чисельник еквівалентний спільній ймовірнісній моделі  $p(C_k, x_1, \dots, x_n)$ , яка може бути переписана наступним чином, використовуючи правило ланцюга для повторного застосування визначення умовної ймовірності:

$$p(C_k, x_1, \dots, x_n) = p(x_1, \dots, x_n, C_k) = p(x_1|x_2, \dots, x_n, C_k) p(x_2, \dots, x_n, C_k) = \\ = p(x_1|x_2, \dots, x_n, C_k) p(x_2|x_3, \dots, x_n, C_k) p(x_3, \dots, x_n, C_k) = \\ = p(x_1|x_2, \dots, x_n, C_k) p(x_2|x_3, \dots, x_n, C_k) \dots p(x_{n-1}|x_n, C_k) p(x_n|C_k) p(C_k)$$

Формула 2. Чисельник умовної ймовірності

Враховуючи, що в наївному Баєсі всі ознаки є взаємно незалежними, то можна записати:  $p(x_i|x_{i+1}, \dots, x_n, C_k) = p(x_i|C_k)$

Тоді, загальну ймовірнісну модель можна написати:

$$p(C_k|x_1, \dots, x_n) \propto p(C_k, x_1, \dots, x_n) = p(C_k) p(x_1, \dots, x_n) = \\ = p(C_k) p(x_1|C_k) p(x_2|C_k) p(x_3|C_k) \dots \\ = p(C_k) \prod_{i=1}^n p(x_i|C_k)$$

Формула 3. Загальна ймовірнісна модель

де  $\propto$  означає пропорційність, оскільки знаменник  $p(x)$  опущений.

Це означає, що за вищезазначеними припущеннями незалежності, умовний розподіл за класовою змінною  $C$  є таким:

$$p(C_k|x_1, \dots, x_n) = \frac{1}{Z} p(C_k) \prod_{i=1}^n p(x_i | C_k)$$

Формула 4. Умовний розподіл за класом  $C$

де  $Z = p(x) = \sum_k p(C_k) p(x|C_k)$  є масштабуючим коефіцієнтом, що залежить лише від  $x_1, \dots, x_n$ , тобто є константою, якщо значення змінних ознак відомі [6].

Те що наведено вище і є наївною баєсівською ймовірнісною моделлю. Для створення класифікатора необхідно цю модель поєднати з правилом прийняття рішень. Одне з поширених правил – вибрати гіпотезу, яка найбільш імовірна, щоб мінімізувати ймовірність помилкової класифікації.

фікації; це відомо як правило прийняття рішення за максимумом апостеріорної ймовірності або MAP-правило. Відповідний класифікатор, баєсівський класифікатор, – це функція, яка присвоює мітку класу  $\hat{y} = C_k$  для деякого  $k$  наступним чином:

$$\hat{y} = \operatorname{argmax}_{k \in \{1, \dots, K\}} p(C_k) \prod_{i=1}^n p(x_i | C_k)$$

Формула 5. Баєсівський класифікатор для  $k$  класів

Апріорна ймовірність класу може бути обрахована шляхом припущення про рівні ймовірності класів,  $p(C_k) = \frac{1}{K}$ , або шляхом розрахунку оцінки ймовірності класу з навчального набору:

$$\text{апріорна ймовірність} = \frac{\text{кількість зразків у класі}}{\text{загальна кількість}}$$

Формула 6. Апріорна ймовірність

При роботі з неперервними даними зазвичай припускають, що вони є пов'язані з кожним класом та розподілені відповідно до нормального (або гаусівського) розподілу. Наприклад, припустимо, що навчальні дані містять неперервний атрибут  $x$ . Дані спочатку сегментуються за класами, а потім для кожного класу обчислюються середнє значення  $x$  та його дисперсія. Нехай  $\mu_k$  буде середнім значенням  $x$ , асоційованим з класом  $C_k$ , а  $\sigma_k^2$  буде дисперсією, скоригованою за Бесселем, для значень  $x$ , що асоціюються з класом  $C_k$  [7]. Припустимо, що було зібрано деяке спостережуване значення  $v$ . Тоді щільність ймовірності  $v$ , за умови належності до класу  $C_k$  тобто  $p(x = v | C_k)$ , може бути обчислена шляхом підстановки  $v$  у формулу нормального розподілу, параметризовану середнім  $\mu_k$  та дисперсією  $\sigma_k^2$ . Формально, це виражається як:

$$P(x = v | C_k) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(v-\mu)^2}{2\sigma^2}}$$

Формула 7. Формула Гаусівського розподілу

Підставивши формулу 5 у формулу 7, отримаємо:

$$\hat{y} = \operatorname{argmax}_{k \in \{1, \dots, K\}} p(C_k) \prod_{i=1}^n p(x_i | C_k) = \operatorname{argmax}_{k \in \{1, \dots, K\}} p(C_k) \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}}$$

Формула 8. Загальна формула модель гаусівського наївного баєсівського класифікатора

Дана формула показує математичну модель гаусівського наївного баєсівського класифікатора [8].

У результаті проведеного дослідження з вказаним вище датасетом модель показала загальну точність 89%.

Нижче можна побачити гістограму ймовірностей приналежності до класів та графік модуля різниці між очікуваним та отриманим значеннями.




Рис. 1.1. Гістограма ймовірностей мультикласового класифікатора

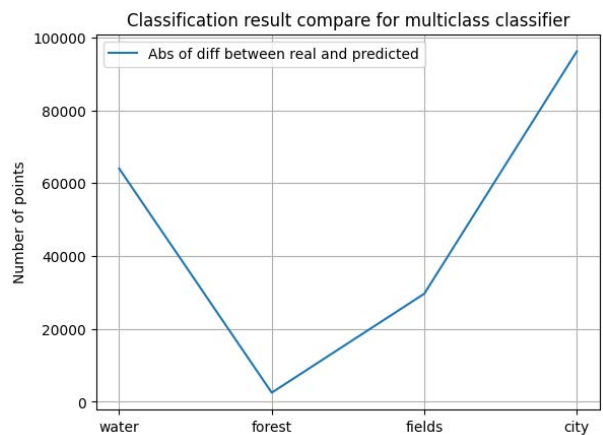


Рис. 1.2. Модуль різниці мультикласового класифікатора між очікуваним та реальним

Проаналізувавши ці дані, можна побачити, що вода, ліс та пісок розпізнаються найкраще. Найбільше проблем є саме з полем та містом. Для вирішення цієї проблеми було запропоновано використати замість мультикласової класифікації метод ієрархічної деревоподібного Баєса.

Такий підхід передбачає послідовне відсіювання категорій на кожному етапі, що дозволяє ефективно використовувати інформацію з попередніх етапів класифікації для уточнення рішення на наступних етапах.

Центральною ідеєю такого підходу є те, що прийняття рішення про належність до певної категорії відбувається на основі ряду послідовних тестів. Якщо на початковому етапі даний об'єкт не проходить перевірку на належність до певної загальної категорії, він помічається як, наприклад, «не вода» і помічається на те, щоб пройти на наступну ітерацію. В іншому випадку, даний об'єкт записується як «вода» і більше не враховується в наступних ітераціях. Нижче на рисунку можна побачити схематичне зображення вигляду цього алгоритму.




Рис. 2. Схематичне зображення деревоподібного бінарного класифікатора

Якщо говорити про математичне обґрунтування, то для математичного обрахунку потрібно буде використати рекурентний підхід, оскільки кожна наступна ітерація буде залежати від попередньої:

Тоді загальну ймовірність приналежності до класу можна описати:

$$p(C_{k,m}|x_1, \dots, x_{n_m}) \propto p(C_{k,m}) \prod_{i=1}^{n_m} p(x_i | C_{k,m}) \tilde{p}(C_{k,m-1}|x_1, \dots, x_{n_{m-1}})$$

Формула 9. Рекурентна формула обчислення ймовірності

Отже, загальна формула класифікатора матиме вигляд:

$$\hat{y}_m = \operatorname{argmax}_{k \in \{1, \dots, K\}} p(C_{k,m}) \prod_{i=1}^{n_m} p(x_i | C_{k,m}) = \operatorname{argmax}_{k \in \{1, \dots, K\}} \prod_{i=1}^{n_m} \frac{1}{\sqrt{2\pi\sigma_m^2}} e^{-\frac{(x_i - \mu_m)^2}{2\sigma_m^2}} y_{m-1}$$

Формула 10. Загальна формула бінарного деревоподібного класифікатора

Як видно з формули, що кожна наступна ітерація залежить від попередньої та буде враховувати ймовірність не приналежності до батьківського класу. Важливим аспектом цього підходу є те, що ймовірності на одному рівні дерева залежать від результатів попереднього рівня. Тобто, для отримання ймовірності належності даних до певної категорії на третьому рівні, наприклад, потрібно спершу визначити ймовірності на другому та першому рівнях. І загальна ймовірність приналежності до певної категорії буде добуток всіх ймовірностей по цьому дереву.

Графічно така модель може бути представлена у вигляді дерева, де корінь символізує початковий етап розпізнавання, а гілки – подальші ітерації. На кожному рівні дерева можливе розділення на два піддерева, що відображають рішення моделі про категорію даних.

Ці обмеження ускладнюють інтерпретацію результатів та візуалізацію гістограм ймовірностей.

У результаті досліджень та експериментальних перевірок було виявлено, що впровадження ієрархічної моделі у вигляді бінарного дерева дозволяє значно підвищити ефективність класифікації. Порівняно з традиційним підходом, де точність склала 89%, ієрархічна модель продемонструвала покращення точності до 94%. Нижче показана гістограма ймовірностей класифікації за допомогою ієрархічного бінарного дерева.

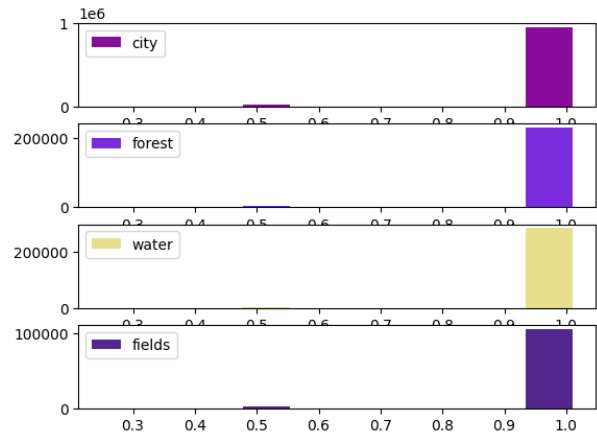


Рис. 3.1. Гістограма ймовірностей бінарного деревоподібного класифікатора

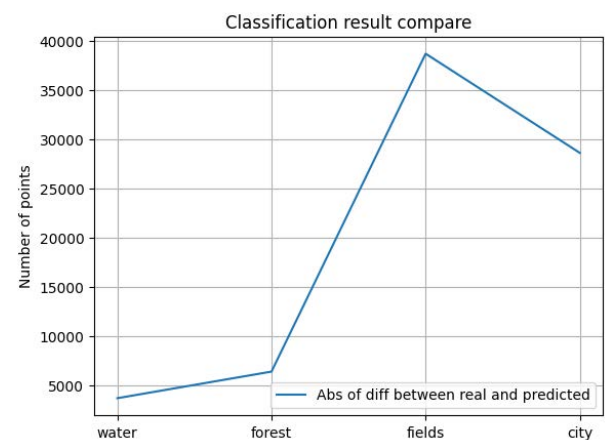


Рис. 3.2. Модуль різниці бінарного деревоподібного класифікатора між очікуваним та реальним

Порівнявши обидві гістограми, можна побачити, що для звичайного мультикласового класифікатора є певна кількість даних, ймовірність приналежності до класу в яких коливається в значеннях 20%–30%. В свою чергу, для бінарного – є певна кількість, ймовірність, яких є близько 50%, але їх кількість є набагато меншою. Це свідчить про те, що деревоподібний класифікатор є більш точним. Така різниця у 2.5 рази показує ефективність цього підходу.

Нижче також можна побачити розпізнавання супутникового знімка за допомогою багатокласового класифікатора, бінарного ієрархічного та зображенням адаптованим до RGB.

**Висновки.** Деревоподібний бінарний класифікатор показав себе ефективнішим за класичний підхід з багатокласовою класифікацією. Завдяки цій ієрархічній моделі точність класифікації зросла з 89% до 94%. Порівняння гістограм для обох підходів (класичний та деревоподібний) показало, що розподіл ймовірностей в деревоподібному класифікаторі




Рис. 4. Результат сегментації за допомогою бінарного деревоподібного класифікатора




Рис. 5. Результат сегментації за допомогою мультикласового класифікатора



Рис. 6. Оригінальне зображення

є більш визначеним. Тобто, замість розподілених ймовірностей між класами в класичному підході, деревоподібний підхід демонструє більшу точність у приналежності пікселів до конкретних категорій. Такий підхід може бути корисним не тільки для задач сегментації супутникових зображень, але й у інших областях, де важливо чітко розрізнити різні категорії на основі складних або характеристик, що можуть перекриватися між собою.

Однією з основних проблем запропонованого підходу є те, що складність моделі зростає пропорційно кількості класів. Це може призвести до значного збільшення обчислювальних ресурсів та часу навчання моделі, особливо при наявності великої кількості класів. Існує ризик, що деяка

важлива інформація може бути втрачена або ігнорована при відсіюванні даних на попередніх етапах розпізнавання. У подальшому дослідженні пропонується також розглянути підхід з використанням паралельного бінарного класифікатора, де для кожного класу розпізнавання буде виконуватися окремо, і потім обробляти ці результати, а також використання гібридного методу з увімкненням навчання з учителем.

Отже, бінарний деревоподібний класифікатор пропонує новий спосіб підходу до багатокласової класифікації, який може поліпшити точність сегментації, що дасть змогу використовувати даний метод замість тих, які потребують значних обчислювальних потужностей.

### Список літератури:

1. Sentinel-2: Satellite Imagery, Overview, And Characteristics. EOS Data Analytics. URL: <https://eos.com/find-satellite/sentinel-2/>. (дата звернення: 21.11.2024).
2. Agricultural Field Boundary Delineation with Satellite Image Segmentation for High-Resolution Crop Mapping: A Case Study of Rice Paddy / M. Wang та ін. *Agronomy*. 2022. Т. 12, № 10. С. 2342. URL: <https://doi.org/10.3390/agronomy12102342> (дата звернення: 18.11.2024).
3. Gao M., Lu T., Wang L. Crop Mapping Based on Sentinel-2 Images Using Semantic Segmentation Model of Attention Mechanism. *Sensors*. 2023. Vol. 23, no. 15. P. 7008. URL: <https://doi.org/10.3390/s23157008>.
4. Sentinel-2 Bands. URL: <https://custom-scripts.sentinel-hub.com/custom-scripts/sentinel-2/bands/> (дата звернення: 18.11.2024).
5. McCallum A., Nigam K. A comparison of event models for naive bayes text classification. *AAAI Conference on Artificial Intelligence*. 1998. URL: <https://api.semanticscholar.org/CorpusID:7311285>.
6. Murty M. N., Devi V. S. *Pattern Recognition: An Algorithmic Approach*. Springer, 2011.
7. Caruana R., Niculescu-Mizil A. An empirical comparison of supervised learning algorithms. *Proceedings of the 23rd International Conference on Machine Learning*. New York, NY, USA, 2006. С. 161–168. URL: <https://doi.org/10.1145/1143844.1143865>.
8. John G. H., Langley P. Estimating Continuous Distributions in Bayesian Classifiers. *CoRR*. 2013. Abs/1302.4964. URL: <http://arxiv.org/abs/1302.4964>.

### **Petrovskiy A.A. SEGMENTATION OF SATELLITE IMAGES USING A BINARY TREE-BASED NAIVE BAYES CLASSIFIER**

*This article presents an improved algorithm for satellite image segmentation using data obtained from the Sentinel-2 mission. To develop the segmentation solution, current segmentation methods were analyzed. As a result, a method based on the Naïve Bayes classifier was proposed.*

*The advantage of this method lies in its low computational requirements, allowing real-time usage, including processing video streams. A multiclass classifier was analyzed, achieving a recognition accuracy of 89%. To improve the accuracy of the multiclass classifier, a binary tree-based classifier was employed, dividing the multiclass problem into a sequence of binary classifications. The author visually represented histograms of class membership probabilities for each classifier and a graph of the absolute difference between the real pixel counts and those predicted by the segmenter for each class. This approach enables more effective class distribution and more precise delineation of boundaries between objects.*

*As a result, the segmentation accuracy increased from 89% to 94%, demonstrating the reliability and efficiency of the proposed method for specific applications in natural resource monitoring. The study focused on the following categories: forest, field, water, and city. Additionally, the author provided a visual representation of the recognition results for both the multiclass and binary tree-based Naïve Bayes classifiers, compared alongside the real satellite image adapted to RGB. The main drawback of the method is the high number of iterations required for final classification into all categories and the reduced training data for each subsequent iteration step. Addressing these issues could further improve recognition accuracy. Future research aims to resolve these challenges.*

**Key words:** *segmentation, machine learning, Naïve Bayes, Sentinel-2, classification, satellite images, binary classifier.*