



БЪЛГАРСКА АКАДЕМИЯ НА НАУКИТЕ
ИНСТИТУТ ЗА КОСМИЧЕСКИ ИЗСЛЕДВАНИЯ И ТЕХНОЛОГИИ

София 1113, ул. "Акад. Г. Бончев", бл. 1; тел./ факс: +359 2 988 35 03; e-mail: office@space.bas.bg,
<http://www.space.bas.bg>

Иван Иванов Стоев

ИЗПОЛЗВАНЕ НА МЕТОДИ НА МАШИННОТО САМООБУЧЕНИЕ ЗА АНАЛИЗ НА ОТДЕЛНИ ХАРАКТЕРИСТИКИ НА СРЕДАТА С ИЗПОЛЗВАНЕ НА АЕРОКОСМИЧЕСКИ ИЗОБРАЖЕНИЯ

АВТОРЕФЕРАТ

за придобиване на образователната и научна степен

ДОКТОР

в област на висше образование

4. „Природни науки, математика и информатика“

професионално направление 4.4. „Науки за Земята“

научна специалност „Дистанционни изследвания на Земята и планетите“

Научени ръководители:

проф. д-р Христо Николов

проф. д-р Мария Димитрова

София

2026

Съдържание

Списък на приетите съкращения.....	2
Въведение.....	3
Цел на изследването.....	4
Предмет на изследването.....	5
Обект на изследването.....	5
1. Съвременно състояние на проблема.....	7
1.1. Преглед на методите за обработка на изображения.....	7
1.2. Модели на невронни мрежи, използвани при обработка на изображения.....	9
1.3. Теорема за универсална апроксимация.....	9
1.4. Обучителни съвкупности.....	10
1.5. Обобщение на методите за обработка и анализ на изображения.....	10
2. МЕТОДОЛОГИЯ.....	11
2.1. Обща методологична рамка.....	11
2.2. Експериментална обосновка на избрания подход.....	12
2.3. Метод 1: Класификация на подобласти и оценка чрез NDVI.....	17
2.4. Метод 2: Усъвършенстване чрез градиентно-базирана значимост.....	23
2.4.1 Мотивация за усъвършенстване на ниво пиксел.....	23
3. РЕЗУЛТАТИ.....	25
3.1. Общ преглед на резултатите.....	25
3.2. Резултати от Метод 1: класификация на подобласти и оценка чрез NDVI.....	25
3.3. Резултати от Метод 2: усъвършенстване чрез градиентно-базирана карта на значимост.....	29
3.4. Сравнение между Метод 1 и Метод 2.....	32
3.6. Обобщение на резултатите.....	35
ЗАКЛЮЧЕНИЕ.....	36
Приноси на дисертационния труд.....	38
Публикации по темата на Дисертацията.....	39
Литература:.....	40

Съкращение	Наименование	Пояснение
Accuracy	Accuracy	Точност; дял на правилно класифицираните примери
B4	Band 4	Червена лента на Sentinel-2
B8	Band 8	Близка инфрачервена лента на Sentinel-2
CNN	Convolutional Neural Network	Конволюционна невронна мрежа
DL	Deep Learning	Дълбоко обучение
EuroSAT	EuroSAT Dataset	Набор от Sentinel-2 изображения за класификация на земно покритие
F1-score	F1-score	F1-мярка; хармонично средно между прецизност и пълнота
NDVI	Normalized Difference Vegetation Index	Нормализиран разликов индекс за растителност
OBIA	Object-Based Image Analysis	Обектно-базиран анализ на изображения
RS / ДИ	Remote Sensing / Дистанционни изследвания	Наблюдение и анализ на земната повърхност чрез сензори
Sentinel-2 / S2	Sentinel-2 satellite mission	Сателитна мисия за мултиспектрално наблюдение на Земята
UTM	Universal Transverse Mercator	Проекционна координатна система
WGS 84	World Geodetic System 1984	Геодезическа координатна система
XAI	Explainable Artificial Intelligence	Обясним изкуствен интелект

Въведение

В последните години машинното зрение, като клон на изкуствения интелект, бележи значителен напредък и става все по-централен елемент в различни индустриални постижения, като автоматизацията на качествения контрол в производството, автономното управление на автомобили и научни изследвания, като анализ на медицински изображения за диагностика на заболявания (Szeliski, 2022; Goodfellow et al., 2016). Технологиите за машинно зрение се основават на способността на компютърните системи да извличат, интерпретират и анализират информация от визуални данни по начин, сходен с човешкото възприятие. Развитието на методите за дълбоко обучение (Deep Learning, DL) и невронните мрежи (Neural Networks, NN) доведе до съществени постижения в разпознаването на образи, анализа на видеоданни и триизмерното моделиране (Goodfellow et al., 2016).

Тези модели намират приложения в широк спектър от области като медицина, автомобилна индустрия, сигурност и роботика. Те позволяват автоматично разпознаване на обекти, класифициране на тематични зони, проследяване на настъпили промени, както и предсказване на бъдещи тенденции. В този контекст, настоящата дисертация разглежда прилагането на модели разработени в сферата на компютърното зрение към геореферирани многоканални спектрални изображения получени от дистанционни изследвания (ДИ) на Земята с цел изследване на околната среда и в частност обекти от градската среда. В ИКИТ-БАН има натрупан опит в областта с защитени две дисертации по тематиката за използване на методите за самообучение (Николов, 2019)

Изследванията на околната средата и по-конкретно градската среда стават все по-важни във връзка с променящия се климат и нарастващото население в градовете. Аерокосмическите изображения предоставят голяма по обем информация, която е полезна за анализ на специфични характеристики на средата, като например земното покритие, зони на замърсяване на въздуха, степен на урбанизация и други.

Настоящата дисертация е насочена към разработване, прилагане и оценка на автоматизирана методология за количествена оценка на растителното покритие в жилищни градски територии чрез анализ на аерокосмически изображения. В изследването се използват геореферирани мултиспектрални и мултитемпорални сателитни изображения Sentinel-2, които позволяват едновременно класификация на земното покритие и изчисляване на спектрални индекси, свързани с растителността.

Методологията съчетава модели на машинното обучение и изкуствени невронни мрежи, в частност конволюционни невронни мрежи и трансферно обучение, със спектралния индекс NDVI. Чрез този подход първо се идентифицират жилищните територии, а след това в техните граници се изчислява съотношението между растителни и нерастителни повърхности. Полученият количествен показател се разглежда като индикатор за степента на озеленяване и качеството на жилищната градска среда.

За реализиране на изследването се използват подходящи обучителни съвкупности, провеждат се експерименти за избор и оценка на моделите, а приложените методи се анализират по отношение на тяхната точност, повторяемост и практическа приложимост при обработка на сателитни изображения.

Цел на изследването

Целта на настоящото изследване е да се разработи, приложи и оцени автоматизирана методология за количествена оценка на растителното покритие в жилищни градски територии чрез анализ на геореферирани мултиспектрални и мултитемпорални сателитни изображения Sentinel-2. Получената количествена оценка се разглежда като индикатор за степента на озеленяване и качеството на жилищната градска среда.

Методологията съчетава класически спектрални индекси, като нормализирания разликов индекс за растителност — NDVI, и модели на машинното обучение, в частност конволюционни невронни мрежи, прилагани за класификация на земното покритие. Чрез този подход първо се идентифицират жилищните територии, а след това в техните граници се изчислява съотношението между растителни и нерастителни повърхности. Това съотношение се използва като количествен показател за оценка на осигуреността на жилищната среда с градска зеленина.

За постигането на тази цел се поставят следните задачи:

1. Да се анализират съществуващи подходи за обработка, класификация и интерпретация на аерокосмически изображения, използвани при изследване на градска среда и растително покритие.
2. Да се проучат възможностите за използване на мултиспектрални изображения Sentinel-2 при идентифициране на жилищни територии и количествено оценяване на растителността в тях.
3. Да се избере и адаптира публично достъпен обучителен набор от данни, подходящ за класификация на земно покритие от Sentinel-2 изображения, като основа за обучение и проверка на избрания модел.
4. Да се избере и адаптира подходящ модел на конволюционна невронна мрежа за класификация на земното покритие чрез трансферно обучение.
5. Да се разработи метод за автоматизирано разделяне на сателитните изображения на квадратни пространствени подобласти и за класификация на тези подобласти по класове земно покритие.
6. Да се разработи метод за отделяне на жилищните територии и за изчисляване на растителното покритие в тях чрез NDVI и прагово определяне.
7. Да се разработи и приложи допълнителен метод за пространствено уточняване на жилищната маска чрез градиентно-базирана карта на значимост.
8. Да се приложат предложените методи върху мултитемпорални Sentinel-2 изображения за територията на град София и да се изчислят количествени показатели за растителността в жилищните територии.
9. Да се оцени приложимостта на разработения подход чрез сравнение между резултатите от двата метода, анализ на времевите изменения и разглеждане на основните ограничения и източници на несигурност.


Предмет на изследването

Предмет на настоящото изследване са методите за автоматизирана обработка, класификация и количествен анализ на геореферирани мултиспектрални сателитни изображения чрез съчетаване на спектрални индекси и модели на изкуствен интелект.

В по-конкретен план изследването разглежда възможността чрез конволюционни невронни мрежи и трансферно обучение да се идентифицират жилищни градски територии, а чрез NDVI да се определи делът на растителността в тях. По този начин предметът на изследването обхваща прехода от класификация на земното покритие към извличане на количествен показател, който може да се използва за оценка на озеленеността на жилищната среда.

Обект на изследването

Обект на настоящото изследване е градската среда на град София, България, представена чрез мултитемпорална серия от сателитни изображения Sentinel-2 за периода 2016–2023 г. Основен фокус на анализа са жилищните градски територии и растителното покритие в техните граници.




Фигура А. Обект на изследването – пълна област на изследването от 13.07.2016 г..

Изследваната област е дефинирана чрез полигон, обхващащ територията на град София и прилежащи градски зони (Фигура А). Координатите на върховете на полигона са представени в десетични градуси в геодезичната координатна референтна система WGS 84 (EPSG:4326), като първата стойност съответства на географската дължина, а втората – на географската ширина.

В рамките на изследването анализът се извършва в два пространствени обхвата: цялата област на проучването и строителната граница на град София (Фигура Б). Това позволява да се сравни растителното покритие както в по-широкия градски и крайградски контекст, така и в по-компактната урбанизирана структура.

В изследването са използвани изображения Sentinel-2, като анализът е базиран на спектралните канали с пространствена разделителна способност 10 m. Данните са приложени за извършване на класификация на земното покритие и за изчисляване на нормализирания диференциален вегетационен индекс (NDVI), който служи като количествен показател за оценка на растителното покритие. За целите на пространствените изчисления и изчисляването на площите данните се препроектират в координатна система UTM зона 34N, което позволява резултатите да бъдат представени в метрични единици по система SI.



Фигура Б. Сателитно изображение на изследваната територия, ограничена от строителните граници на град София съгласно Общия устройствен план (27.07.2023 г.)

ГЛАВА 1

1. Съвременно състояние на проблема


В настоящата глава е направен кратък преглед на основни методи, използвани в областта на компютърното зрение и обработката на изображения. Акцентът е поставен върху подходите, които имат отношение към анализа на геореферирани мултиспектрални изображения от дистанционни изследвания и които могат да бъдат използвани при оценка на характеристики на градската среда.

Компютърното зрение обхваща широк набор от задачи и методи, свързани с автоматизираното извличане, обработване и интерпретиране на визуална информация. В контекста на настоящото изследване интерес представляват както класическите методи за обработка на изображения, така и съвременните подходи, базирани на машинно обучение и изкуствени невронни мрежи. Най-общо методите за обработка на изображения могат да бъдат разгледани чрез няколко основни групи: филтриране, трансформации, сегментация, откриване на ръбове и контури, морфологични операции и класификация на изображения.

1.1. Преглед на методите за обработка на изображения

1.1.1. Класически методи за обработка на изображения


Откриването на ръбове и контури има за цел да идентифицира области в изображението, в които се наблюдава рязка промяна в яркостта, цвета или текстурата. Такива промени обикновено съответстват на граници между различни обекти или региони. Сред най-широко използваните методи са операторите на Собел, Лапласианът и алгоритъмът на Канни. Алгоритъмът на Канни е един от класическите подходи за откриване на ръбове, тъй като съчетава изглаждане, изчисляване на градиент, потискане на немаксималните стойности и хистерезисно прагово отделяне (Canny, 1986). Подобни методи се използват за извличане на структурна информация от изображенията и за подпомагане на последващи задачи като сегментация, класификация и разпознаване на обекти (Parker, 2011).




Фиг. 1. Изкуствена невронна мрежа.




Фиг. 2. Блок схема – функция на загубите.




Фиг. 3. Изкуствен неврон.



Фиг. 4 Активационни функции и примери.



Фиг. 5. Схема на невронна мрежа със скрити слоеве .



Фиг. 6 Пример за Конволюция


При задачи, свързани с обработка на изображения, напълно свързаните слоеве позволяват на модела да вземе крайно решение въз основа на характеристиките, извлечени от предходните конволюционни и pooling слоеве.

1.2. Модели на невронни мрежи, използвани при обработка на изображения

Vision Transformer — ViT — прилага принципите на трансформър архитектурата към изображения. При този подход изображението се разделя на малки подобласти (*patches*), които се третират като последователност от входни елементи. Всеки фрагмент се кодира и обработва чрез трансформър слоеве. ViT показва високи резултати при класификация на изображения, особено при обучение върху големи набори от данни (Dosovitskiy et al., 2021).

1.3. Теорема за универсална апроксимация

Теоремата за универсална апроксимация е една от основните теоретични постановки, които обясняват защо изкуствените невронни мрежи могат да моделират сложни зависимости между входни и изходни данни.



Фиг. 7. Стъпкова функция .

1.4. Обучителни съвкупности

"Обучителната съвкупност" (или training dataset) е основен елемент в машинното обучение и невронните мрежи. Тя включва набор от примери, чрез които моделът се обучава да открива зависимости между входните данни и очаквания изход. При задачи за класификация обучителната съвкупност обикновено съдържа входни изображения или извадки от изображения и съответстващи етикети, които определят принадлежността им към даден клас (Bishop, 2006; Goodfellow et al., 2016). Значението на големите и добре анотирани обучителни съвкупности е особено ясно демонстрирано при дълбоките конволюционни невронни мрежи, като например модела AlexNet, обучен върху ImageNet за класификация на изображения (Krizhevsky et al., 2012).

В контекста на настоящото изследване предварително обучените модели са важни, тъй като позволяват използване на вече научени визуални представяния при анализ на сателитни изображения. Въпреки че изображенията от ImageNet и мултиспектралните сателитни изображения имат различен произход и структура, началните слоеве на конволюционните мрежи често извличат общи признаци, които могат да бъдат полезни при адаптиране на модела към задачи за класификация на земно покритие и градска среда.

1.5. Обобщение на методите за обработка и анализ на изображения

Разгледаните методи показват развитието на обработката и анализа на изображения от класически подходи към съвременни модели на машинното и дълбокото обучение. Класическите методи, като филтриране, трансформации, сегментация, откриване на ръбове и морфологични операции, остават важна основа за предварителна обработка, подобряване на качеството на изображенията и извличане на пространствена информация (Gonzalez & Woods, 2018; Szeliski, 2022).

ГЛАВА 2

2. МЕТОДОЛОГИЯ

2.1. Обща методологична рамка

Настоящата глава представя методологията за извличане и количествена оценка на растителното покритие в жилищни градски територии чрез използване на мултиспектрални сателитни изображения Sentinel-2, конволюционни невронни мрежи и спектрални индекси. Основната цел на разработената методология е да се създаде последователен, повторям и изчислително приложим работен процес, чрез който първичните сателитни данни да бъдат преобразувани в количествени показатели за наличие и относителен дял на растителността в градска жилищна среда.

Градската растителност се характеризира с разнообразни форми, размери и типове растително покритие, включително паркове, жилищни градини, междублокови пространства, зелени ивици, площади, улична растителност и кръгови кръстовища. Тази хетерогенност затруднява нейното точно картографиране и количествено оценяване, особено в плътно застроена градска среда, където растителността често е фрагментирана и смесена със сгради, пътна инфраструктура, сенки и други повърхности.

Традиционните методи за получаване на полигони на градската зеленина обикновено включват теренни обследвания, ръчна дигитализация или експертна интерпретация на изображения. Тези подходи са трудоемки, времеемки и скъпи, особено когато трябва да бъдат приложени върху големи градски територии или върху изображения от различни години и сезони. Поради това въздушните и сателитните изображения се превръщат във важен източник на данни за мониторинг на градската растителност и за оценка на растителното покритие в жилищните райони.

С увеличаването на обема на свободно достъпните сателитни данни и инструменти за обработка на изображения възниква възможност за разработване на метод, който използва дистанционно наблюдение, машинно обучение и спектрални индекси за автоматизирана оценка на градската зеленина. В настоящото изследване се цели създаването на метод, който използва публично достъпни сателитни изображения, софтуер с отворен код и библиотеки за машинно обучение, като същевременно остава приложим без задължителна необходимост от високопроизводителна изчислителна инфраструктура.

Методологията се основава на комбиниране на два типа анализ. Първият е семантичен анализ на земното покритие, реализиран чрез конволюционна невронна мрежа и трансферно обучение. Неговата задача е да разграничи жилищните градски територии от останалите класове земно покритие. Вторият е спектрален анализ, базиран на нормализирания разликов индекс за растителност — NDVI, чрез който в рамките на вече избраните жилищни територии се определят пикселите, съответстващи на растителност (Stoev et al., 2023; Rouse et al., 1974; Tucker, 1979).

Предложената методология има няколко основни предимства. На първо място, тя използва публично достъпни сателитни данни и обучителни съвкупности, което я прави

възпроизводима и приложима за различни градски територии. На второ място, съчетава интерпретируем спектрален индекс с модел на дълбоко обучение, което позволява едновременно използване на физически обоснована спектрална информация и автоматично извлечени пространствени признаци. На трето място, методът е изчислително приложим, тъй като работи на ниво подобласти и може да бъде реализиран без необходимост от специализирана високопроизводителна инфраструктура.

2.2. Експериментална обосновка на избрания подход

Преди формулирането на окончателната методологична процедура е необходимо да се провери дали избраният подход — класификация на сателитни изображения на ниво подобласти чрез конволюционна невронна мрежа и последващо изчисляване на растителността чрез спектрален индекс — е приложим за задачите на настоящото изследване. Поради тази причина в началния етап е проведен експеримент, чиято основна цел е да установи дали чрез налични свободно достъпни обучителни данни и предварително обучени модели може надеждно да се разпознават жилищни градски територии в изображения Sentinel-2.

Тази постановка позволява да се оцени ролята на трансферното обучение при класификацията на сателитни изображения. Сравнението между двете конфигурации е важно, тъй като показва дали предварително научените визуални признаци могат да подобрят представянето на модела спрямо обучение от нулата върху наличния набор от данни.

Вид параметри	Брой
Общ брой параметри	117 762 538
Обучаеми параметри	117 249 962
Необучаеми параметри	512 576

Измерената точност на класификацията върху, извършена с модел без предварително зададени тегла.

Метрика	Стойност
Accuracy	0.6408
F1-score	0.6300

Измерена точност на сематичната класификация с използването на предварително зададени тегла за начално инициализиране на коефициентите на мрежата.

Метрика	Стойност
Accuracy	0.9700
F1-score	0.9695

Клас	Брой подобласти
Гора	292
Растителност	233
Магистрала	200
Индустриални зони	185
Пасища	300
Постоянни култури	47
Жилищни зони	367
Река	67
Езеро	350
Общо	2041

$$\hat{y}_i = \arg \max_k p_{i,k}, \quad (1)$$

където $p_{i,k}$ е вероятността подобластта i да принадлежи към клас k , а

$\hat{y}_i$ е прогнозираният клас за съответната подобласт.

Този подход е подходящ, когато целта е всяка подобласт да бъде отнесена към един единствен клас. В настоящото изследване обаче задачата е по-специфична. Не е необходимо да се анализират всички класове земно покритие, а да се изберат само онези подобласти, които с достатъчно висока увереност принадлежат към класа „Жилищни зони“. Причината е, че последващото изчисляване на растителността чрез NDVI се извършва само в рамките на избраните жилищни подобласти.

Поради това вместо да се използва единствено най-вероятният клас, се прилага праг върху вероятността за жилищния клас. Избират се само подобластите, за които вероятността да принадлежат към класа „Жилищни зони“ е по-висока от 75%:

$$p_{i,residential} > 0.75.$$

Този праг има ролята на критерий за надеждност на класификацията. Чрез него се цели да се намали рискът от включване на несигурни или гранични подобласти в последващия анализ на растителността. Това е особено важно в градска среда, където една подобласт с размер 64×64 пиксела може да съдържа едновременно сгради, пътища, дървета, тревни площи, сенки и други елементи. В такива случаи изборът само на най-вероятния клас може да бъде недостатъчен, ако вероятностите между няколко класа са близки.

Вероятностното филтриране позволява последващият анализ да бъде ограничен до подобласти, за които моделът има достатъчно висока увереност, че принадлежат към жилищна територия. По този начин CNN моделът изпълнява ролята на семантичен филтър, който отделя жилищните части на сцената от останалите типове земно покритие.

Тази стъпка е важна, защото грешките при избора на жилищни подобласти пряко влияят върху крайната оценка на растителността. Ако в анализа бъдат включени горски, земеделски, индустриални или водни територии, полученото съотношение няма да отразява реално растителността в жилищна среда. Обратно, ако част от действителните жилищни подобласти бъдат пропуснати, ще се получи непълна оценка на изследваната територия. Затова вероятностното филтриране служи като междинна контролна стъпка между класификацията на земното покритие и последващото изчисляване на NDVI.

В резултат на този етап се получава подмножество от подобласти, които са класифицирани като жилищни с достатъчно висока вероятност. Именно върху тези подобласти се прилага следващият етап от експерименталната процедура — изчисляване на растителното покритие чрез NDVI.

2.2.8. Първоначално изчисляване на растителността чрез NDVI

След определяне на подобластите, класифицирани като жилищни, следващата стъпка в експерименталната проверка е да се оцени наличието и относителният дял на растителността в тях. Това е съществен момент в логиката на изследването, тъй като крайната цел не е единствено да се разпознаят различни класове земно покритие, а да се изчисли количествен показател за растителното покритие в жилищна градска среда.

В този етап класификацията чрез конволюционната невронна мрежа изпълнява ролята на пространствен филтър. Първо се определят онези подобласти, които с висока вероятност принадлежат към класа „Жилищни зони“, а след това анализът на растителността се ограничава само до тях. По този начин не се изчислява общата растителност в цялото сателитно изображение, а растителността именно в жилищните части на изследваната територия.

За оценка на растителността могат да бъдат използвани различни подходи. Един възможен подход е анализът на изображения, базиран на обекти — Object-Based Image Analysis (OBIA), при който изображението първо се сегментира на пространствени обекти въз основа на спектрални, пространствени и контекстуални характеристики. След това тези обекти могат да бъдат класифицирани като растителност или нерастителни повърхности според техните спектрални свойства, форма и текстура. В рамките на първоначалния експеримент обаче е избран по-лек и директен подход, основан на спектрален индекс, тъй като целта е да се провери дали комбинирането на CNN класификация и NDVI анализ може да даде приложим количествен резултат.


За тази цел се използва нормализираният разликов индекс за растителност — Normalized Difference Vegetation Index (NDVI).

При изображенията Sentinel-2 червения спектрален канал съответства на B4, а канала за близката инфрачервена радиация — на B8. Следователно за използваните Sentinel-2 изображения формулата приема вида:


$$NDVI = \frac{B8 - B4}{B8 + B4} \quad (2)$$

$$NDVI(x,y) > 0.3 \quad (3)$$

След изчисляването на NDVI върху подобластите, класифицирани като жилищни, се получава индексно изображение, което показва пространственото разпределение на стойностите на растителния индекс в тези райони.



Фиг. 8. Индекс NDVI, изчислен върху подобласти от изображения, класифицирани като жилищни.



Фиг. 9. Карта на растителното покритие, получена чрез NDVI с праг 0.3.

След получаване на бинарната маска се преброява броят на пикселите, класифицирани като растителност в рамките на избраните жилищни подобласти. Това позволява да се изчисли относителният дял на растителността спрямо цялата площ на жилищните подобласти.

Формално съотношението на растителността в жилищните зони може да бъде представено като:

$$V = \frac{\sum_{n=1}^N v_n}{N * 4096} \quad (4)$$

V - Съотношение на растителността в жилищните зони.

v_n - Брой пиксели в n^{th} с индекс NDVI, по-голям от прага (0,3).

N - Общият брой пиксели в жилищните подобласти.

Получената стойност V представлява количествен показател за дела на растителността в жилищните територии. Този показател е безразмерен и приема стойности в интервала от 0 до 1. Стойност, близка до 0, показва нисък дял на растителност в избраните жилищни подобласти, докато по-висока стойност показва по-голямо наличие на растително покритие.

Този етап има важно значение за цялостната методология, защото показва, че след класификацията на жилищните зони може да се извърши последващ спектрален анализ и да се получи количествен показател за растителното покритие. По този начин първоначалният експеримент доказва приложимостта на комбинирания подход: CNN моделът определя пространствената област на интерес, а NDVI се използва за количествено измерване на растителността в тази област.

Именно този показател V е основата, която по-късно се формализира в Метод 1. В последващата методологична част процедурата се развива по-строго: описват се входните данни, разделянето на сцената на подобласти, класификацията, филтрирането на жилищните територии, изчисляването на NDVI, праговото определяне, генерирането на бинарна маска и изчисляването на площните показатели. Тук обаче ролята на изчислението е експериментална — да покаже, че избраният подход може реално да доведе до измерим и интерпретируем резултат за градската растителност

2.2.9. Резултати и изводи от експерименталната обосновка

Резултатите от проведените експерименти показват ясно различие между обучението на модела без предварително обучени тегла и използването на трансферно обучение чрез предварително обучен EfficientNetV2L модел. Обобщените резултати от класификацията са представени в Таблица 5.

Таблица 5. Резултати от класификацията

Използван модел	Accuracy	F1-score
EfficientNetV2L без предварително обучени тегла	0.6408	0.6300
EfficientNetV2L с предварително обучени тегла, тестван върху валидационни данни	0.9700	0.9695
EfficientNetV2L с предварително обучени тегла, тестван върху реални данни	0.9520	0.9500

Дата на изображението	Съотношение на растителността	Брой жилищни подобласти	NDVI праг
04.04.2016	0.4524	280	0.4
28.07.2019	0.3396	367	0.3
02.06.2022	0.3259	411	0.4



Фигура 8. Блок схема на методологията.

2.3. Метод 1: Класификация на подобласти и оценка чрез NDVI

Предложеният Метод 1 представлява последователен работен процес за обработка и анализ на мултиспектрални изображения Sentinel-2 с цел количествена оценка на растителното покритие в жилищни градски територии. Методът комбинира подходи от дистанционните изследвания, дълбокото обучение, спектралния анализ и пространствената статистика.

В експерименталната част е използван пълният набор от класове на EuroSAT, който съдържа 10 категории земно покритие. При формализирането на Метод 1 класификационното пространство е адаптирано към целта на изследването чрез изключване на класа, свързан с транспортна инфраструктура. Това решение е мотивирано от факта, че в градска среда транспортната инфраструктура често е пространствено свързана с жилищните територии и може да отдели части от реалната жилищна структура в самостоятелен клас. Поради тази причина в Метод 1 се използва редуцирано множество от 9 класа, което позволява по-добро пространствено обхващане на жилищните територии като основна област на интерес.

Основната идея е първо да се идентифицират жилищните райони чрез класификация на изображението на ниво квадратни пространствени подобласти, наричани още patches, а след това в рамките на тези райони да се изчисли растителното покритие чрез NDVI. Така CNN класификацията изпълнява ролята на семантичен филтър, който ограничава анализа до жилищните територии, докато NDVI осигурява количествена оценка на растителността на ниво пиксел.

Този подход е подходящ за настоящото изследване, тъй като крайната цел не е изчисляване на общата растителност в цялата сателитна сцена, а оценка на растителността именно в жилищните градски територии. Така се избягва смесване на резултатите с големи

зелени площи извън жилищната структура, като гори, земеделски територии, пасища или паркови зони, които не отразяват пряко състоянието на жилищната среда.



Фигура 9. Реазделяне на многоканално изображение от Sentinel-2 на еднакви подобласти с размер 64x64

Сложността на извършената операция е:


$$O(M \cdot C_{CNN}) \quad (5)$$

където C_{CNN}

а M е броя подобласти

е цената на еднократно преминаване напред.

Групирането позволява GPU паралелизъм, намалява I/O натоварването и спомага за ефективното използване на паметта.



Фигура 10. Класификация на патчове с помощта на изкуствена нервонна мрежа.

Точността на сегментацията определяме като:

$$\text{Accuracy} = \frac{\text{Correct predictions}}{\text{Total samples}} \quad (6)$$



Фигура 11. Подобласти филтрирани по семантичен клас „Жилищен“

Метриките които използваме за оценка на работата на класификатора са:

Прецизност(Precision) показва каква част от всички обекти, определени от модела като принадлежащи към класа *res*, действително принадлежат към него.


Пълнотата (Recall) показва каква част от всички реални обекти от класа *res* са били успешно открити от модела.

$$\begin{aligned} \text{Precision}_{res} &= \frac{TP}{TP + FP} \\ \text{Recall}_{res} &= \frac{TP}{TP + FN} \end{aligned} \quad (7)$$


TP (True Positives) – брой правилно класифицирани обекти от класа *res*;

FP (False Positives) – брой обекти, погрешно класифицирани като принадлежащи към класа *res*


FN (False Negatives) – брой обекти от класа *res*, които моделът не е разпознал и е отнесъл към друг клас.



Фигура 12. Филтрирани жилищни зони, изчисляване на NDVI и намиране на праг по метода Оцу



Фигура 13. Бинарна маска на растителността.



Фигура 14. Резултати.

В обобщение, този етап преобразува сегментацията на растителността на ниво пиксел в физически интерпретируеми, геопространствено референцирани показатели за площ, което

позволява количествена оценка на растителното покритие в жилищни среди в съответствие с установената методология за дистанционно наблюдение.

2.3.9 Разпространение на статистическата грешка по веригата

Нека истинският пространствен обхват на жилищния клас се обозначи с $\Omega_{\text{res}}^{\text{истинска}}$ и прогнозираният пространствен обхват с $\Omega_{\text{res}}^{\text{прогнозна}}$. Етапът на класификация (раздел 5.2) въвежда грешки в класификацията, характеризиращи се с точност и възстановяване, специфични за класа. Нека E_{FP} и E_{FN} обозначават процента на фалшивите положителни и фалшивите отрицателни резултати за класа „Жилищна“. Прогнозираната жилищна област може да се изрази като

В обобщение, разпространението на грешките в предложеният работен процес е йерархично и кумулативно. Семантичната грешка в класификацията променя пространствената подкрепа, праговете определят точността на бинарната сегментация, а пространствената автокорелация влияе върху вариацията на агрегирането. Разпознаването и количествено измерване на тези зависимости укрепва интерпретируемостта на крайния показател за растителното покритие и привежда методологията в съответствие с установените принципи на статистическата inferенция в анализа на пространствени данни.


2.4. Метод 2: Усъвършенстване чрез градиентно-базирана значимост

2.4.1 Мотивация за усъвършенстване на ниво пиксел

Етапът на класифициране на земното покритие, описан в раздел 2.3, извършва извод на ниво подобласт, където всяка пространствена единица с размер 64×64 пиксела получава един етикет за категория. Макар че тази формулировка е статистически съвместима с набора от данни EuroSAT, тя въвежда ефект на пространствена квантизация в получената маска на земното покритие.

$$A(i, j) = \sum_{c=1}^3 \left| x(i, j, c) \frac{\partial s}{\partial x(i, j, c)} \right| \quad (8)$$


$$A \in \mathbb{R}^{64 \times 64}$$



Фигура 15. Карта на вниманието. $\theta_{atn} = 0.3$

$$A_{norm} = \frac{A - \min(A)}{\max(A) - \min(A)} \quad (9)$$

$$\theta_{attn} \in [0.2, 0.5]$$



Фигура 16. Връзка между двата предложени метода.

Такива обяснения, базирани на градиенти, предоставят локални приближения на поведението на невронната мрежа и са се превърнали в широко използван подход в изследванията в областта на обяснимата изкуствена интелигентност (XAI). Подобни техники са били успешно приложени и в приложения за дистанционно наблюдение за интерпретиране на модели за дълбоко обучение, работещи върху сателитни изображения.

ГЛАВА 3

3. РЕЗУЛТАТИ

3.1. Общ преглед на резултатите

В настоящата глава са представени резултатите от прилагането на разработената методология за оценка на растителното покритие в жилищни градски територии. Анализът е извършен върху мултиспектрални изображения Sentinel-2 за периода 2016–2023 г., като са разгледани два пространствени обхвата: цялата област на проучването и областта, ограничена до строителната граница на град София.

Резултатите са получени чрез прилагане на двата разработени метода. Метод 1 използва класификация на сателитното изображение на ниво квадратни подобласти чрез CNN модел, последвано от изчисляване на NDVI и статистическо определяне на праг за отделяне на растителност от нерастителни повърхности. Метод 2 надгражда този подход чрез използване на градиентно-базирана карта на значимост, която има за цел да уточни пространствената опора на жилищните райони преди изчисляването на растителното покритие.

За всяка анализирана сцена са изчислени основни количествени показатели, включително брой подобласти, класифицирани като жилищни, използван праг на NDVI, площ на растителността и относително съотношение между растителност и нерастителни повърхности в рамките на жилищните територии. Получените стойности позволяват сравнение както между отделните години, така и между двата предложени метода.

Полученото съотношение между растителност и нерастителни повърхности в жилищните територии се интерпретира като количествен показател за степента на озеленяване на жилищната среда. То не представлява само резултат от класификация на земното покритие, а индикатор за осигуреността на жилищните области с градска зеленина. По този начин комбинирането на NDVI и методи на изкуствен интелект позволява преминаване от пикселна и регионална класификация към по-високо ниво на интерпретация, свързано с качеството на средата за обитаване.

3.2. Резултати от Метод 1: класификация на подобласти и оценка чрез NDVI


В този раздел се представят резултатите, получени чрез Метод 1. При този подход сателитното изображение първо се разделя на квадратни пространствени подобласти с размер 64×64 пиксела. Всяка подобласт се класифицира чрез CNN модел, след което анализът се ограничава само до подобластите, класифицирани като жилищни. В рамките на избраните жилищни подобласти се изчислява нормализираният разликов индекс за растителност — NDVI, чрез който се отделят пикселите, съдържащи растителност, от нерастителните повърхности.

Метод 1 може да се разглежда като базов подход в настоящото изследване, тъй като използва директно резултата от класификацията на ниво подобласт. След като дадена

подобласт бъде класифицирана като жилищна, цялата ѝ площ се включва в пространствената маска на жилищните територии. Това позволява сравнително проста и изчислително ефективна оценка на растителността, но същевременно въвежда известна пространствена генерализация, тъй като една подобласт може да съдържа различни типове земно покритие.


За всяка анализирана сцена са изчислени следните показатели: използван NDVI праг, обща жилищна площ, растителна площ, нерастителна площ и процентно съотношение на растителността в рамките на класифицираните жилищни територии. Съотношението на растителността се изчислява като дял на растителната площ спрямо общата жилищна площ.

Дата	NDVI праг	Жилищна площ (ха)	Растителна площ (ха)	Нерастителна площ (ха)	Съотношение на растителността (%)
13.07.2016 г.	0,40	16 384,00	8 443,17	7 940,83	51,53
23.07.2017 г.	0,39	15 482,88	8 123,24	7 359,64	52,47
07.08.2018 г.	0,42	16 056,32	8 842,74	7 213,58	55,07
03.07.2019 г.	0,00*	15 892,48	8 534,18	7 358,30	53,70
02.07.2020 г.	0,00*	15 851,52	8 242,62	7 608,90	52,00
27.07.2021 г.	0,37	14 540,80	7 237,24	7 303,56	49,77
22.07.2022 г.	0,41	16 670,72	8 914,56	7 756,16	53,47



Фигура 17. Маска на зеленината изчислена по Метод 1 за цялата област

Дата	NDVI праг	Жилищна площ (ха)	Растителна площ (ха)	Нерастителна площ (ха)	Съотношение на растителността (%)
13.07.2016 г.	0,38	11 172,97	5 396,35	5 776,62	48,30
23.07.2017 г.	0,37	10 777,88	5 256,65	5 521,23	48,77
07.08.2018 г.	0,40	11 134,77	5 633,60	5 501,17	50,59
23.07.2019 г.	0,00*	11 097,89	5 483,80	5 614,09	49,41
11.08.2020 г.	0,38	11 176,18	5 777,85	5 398,33	51,70
17.07.2021 г.	0,00*	10 742,35	4 909,63	5 832,72	45,70
22.07.2022 г.	0,39	11 107,15	5 429,65	5 677,50	48,88
22.07.2023 г.	0,37	10 621,36	5 144,46	5 476,90	48,44




Фигура 18. Маска на зеленината изчислена по Метод 1 за строителната граница на град София.



Фигура 19. Тренд на намаляване на растителното покритие 2016 г. - 2023 г..



Фигура 20. Метод 1 Времева динамика.



Фигура 20а. Метод 1 Времева динамика.

3.3. Резултати от Метод 2: усъвършенстване чрез градиентно-базирана карта на значимост

В този раздел са представени резултатите, получени чрез Метод 2. За разлика от Метод 1, при който цялата подобласт с размер 64×64 пиксела се приема за принадлежаща към класа, предсказан от CNN модела, Метод 2 въвежда допълнително пространствено усъвършенстване. Това усъвършенстване се основава на градиентно-базирана карта на значимостта, която показва кои пиксели в рамките на дадена подобласт имат най-голям принос към решението на модела за класа „жилищни зони“.

Този подход е особено важен при градски територии, тъй като една подобласт често съдържа смес от различни обекти — сгради, улици, паркинги, тревни площи, дървета, сенки и открити почви. Следователно твърдото присвояване на цялата подобласт към един клас може да доведе до пространствено обобщаване и включване на пиксели, които не са пряко свързани с жилищната структура. Чрез Метод 2 се запазват само онези пиксели, които имат достатъчно висока градиентна значимост за решението на CNN модела.

Важно е да се подчертае, че градиентно-базираната карта на значимост не представлява самостоятелна семантична сегментация. Тя не доказва директно, че даден пиксел е жилищен, а показва кои части от входното изображение са били най-влиятелни за решението на класификатора. В този смисъл Метод 2 се разглежда като постпроцесинг за пространствено уточняване на жилищната маска, а не като напълно отделен модел за пикселна класификация.

След получаване на усъвършенстваната жилищна маска, последващите стъпки остават аналогични на Метод 1: в рамките на избраните пиксели се изчислява NDVI, прилага се праг за разграничаване на растителност и нерастителни повърхности, след което се изчисляват

площите и съотношението на растителността. За всяка сцена са представени: NDVI праг, праг на значимост, жилищна площ, растителна площ, нерастителна площ и процентно съотношение на растителността

3.3.1. Резултати за границите строителната граница

В Таблица 3.3 са представени резултатите от Метод 2 при ограничаване на анализа до строителната граница на града. Този пространствен обхват е най-подходящ за оценка на растителността в плътно урбанизираната жилищна среда, тъй като изключва част от периферните и крайградски територии, които могат да имат различна структура на земното покритие.

Таблица 3.3. Резултати от Метод 2 за строителната граница на град София

Дата	NDVI I праг	Праг на значимост	Жилищна площ (ха)	Растителна площ (ха)	Нерастителна площ (ха)	Съотношение на растителността (%)
13.07.2016 г.	0,35	0,30	386,47	120,80	265,67	31,26
23.07.2017 г.	0,35	0,30	422,71	154,64	268,07	36,58
07.08.2018 г.	0,38	0,30	414,89	149,98	264,91	36,15
23.07.2019 г.	0,36	0,30	414,47	143,49	270,98	34,62
11.08.2020 г.	0,36	0,30	400,79	145,28	255,51	36,25
17.07.2021 г.	0,34	0,30	409,04	122,65	286,39	29,98
22.07.2022 г.	0,36	0,30	401,30	120,17	281,13	29,95
22.07.2023 г.	0,36	0,30	386,61	124,33	262,28	32,16




Фигура 21. Метод 2 Времева динамика, строителната граница на град София .



Фигура 22. Метод 2 Времева динамика, строителната граница на град София.

Дата	NDV I праг	Праг на значимост	Жилищна площ (ха)	Растителна площ (ха)	Нерастителна площ (ха)	Съотношение на растителността (%)
04.04.2016 г.	0,28	0,30	775,41	348,26	427,15	44,91
13.07.2016 г.	0,37	0,30	584,74	242,88	341,86	41,54
23.07.2017 г.	0,36	0,30	602,21	268,31	333,90	44,55
28.07.2019 г.	0,00*	0,20	1 560,58	736,26	824,32	47,18
02.07.2020 г.	0,38	0,30	605,79	273,63	332,16	45,17
27.07.2021 г.	0,36	0,30	632,23	259,69	372,54	41,08
02.06.2022 г.	0,42	0,20	1 482,84	682,77	800,07	46,04



Фигура 22. Метод 2 Времева динамика, цялата област.



Фигура 23. Метод 2 Времева динамика, цялата област.

3.4. Сравнение между Метод 1 и Метод 2

В този раздел се извършва сравнителен анализ между резултатите, получени чрез Метод 1 и Метод 2. Двата метода използват една и съща обща логика — първо се определят жилищните територии, след което в тях се изчислява растителното покритие чрез NDVI. Разликата между тях е в начина, по който се дефинира пространствената опора на жилищния клас.

При Метод 1 цялата подобласт с размер 64×64 пиксела се приема като жилищна, ако CNN моделът я класифицира като такава. Това прави метода по-обхватен, но води до по-груба пространствена маска. При Метод 2 се използва градиентно-базирана карта на значимостта, чрез която се запазват само пикселите, които имат най-голям принос към

решението на модела за класа „жилищни зони“. Затова Метод 2 е по-селективен и дава значително по-малка жилищна площ.

Сравнението между двата метода не трябва да се разглежда като директно противопоставяне между „правилен“ и „неправилен“ резултат. Метод 1 представя по-широката жилищна структура, докато Метод 2 извлича по-строга пространствена опора, свързана с най-силно разпознатите жилищни пиксели. В този смисъл двата метода са допълващи се: Метод 1 осигурява цялостна оценка на жилищните подобласти, а Метод 2 позволява по-фина пространствена интерпретация.

3.4.1. Сравнение в границите на строителната граница на град София


Най-пряко сравнение между Метод 1 и Метод 2 може да се направи за строителната граница на града, тъй като и при двата метода са използвани едни и същи дати на изображенията. Това позволява да се проследи как промяната в начина на дефиниране на жилищната маска влияе върху площите и върху изчисленото съотношение на растителността.

Таблица 3.5. Сравнение между Метод 1 и Метод 2 в границите на строителната граница на град София

Дата	Жилищна площ Метод 1 (ха)	Жилищна площ Метод 2 (ха)	Дял на Метод 2 спрямо Метод 1 (%)	Растителност Метод 1 (%)	Растителност Метод 2 (%)	Разлика Метод 2 – Метод 1 (пр. п.)
13.07.2016 г.	11 172,97	386,47	3,46	48,30	31,26	-17,04
23.07.2017 г.	10 777,88	422,71	3,92	48,77	36,58	-12,19
07.08.2018 г.	11 134,77	414,89	3,73	50,59	36,15	-14,44
23.07.2019 г.	11 097,89	414,47	3,73	49,41	34,62	-14,79
11.08.2020 г.	11 176,18	400,79	3,59	51,70	36,25	-15,45
17.07.2021 г.	10 742,35	409,04	3,81	45,70	29,98	-15,72
22.07.2022 г.	11 107,15	401,30	3,61	48,88	29,95	-18,93
22.07.2023 г.	10 621,36	386,61	3,64	48,44	32,16	-16,28



Фигура 24. Сравнение между Метод 1 и Метод 2 в строителната граница на град София.



Фигура 24. Сравнение на NDVI праговете избрани от Метод 1 и Метод 2 в строителната граница на град София.

Дата	Жилищна площ Метод 1 (ха)	Жилищна площ Метод 2 (ха)	Дял на Метод 2 спрямо Метод 1 (%)	Растителност Метод 1 (%)	Растителност Метод 2 (%)	Разлика Метод 2 – Метод 1 (пр. п.)
13.07.2016 г.	16 384,00	584,74	3,57	51,53	41,54	-9,99
23.07.2017 г.	15 482,88	602,21	3,89	52,47	44,55	-7,92
02.07.2020 г.	15 851,52	605,79	3,82	52,00	45,17	-6,83
27.07.2021 г.	14 540,80	632,23	4,35	49,77	41,08	-8,69

В обобщение, Метод 1 и Метод 2 не трябва да се разглеждат като конкуриращи се, а като две равнища на анализ. Метод 1 дава базова количествена оценка на растителността в жилищните територии, а Метод 2 надгражда тази оценка чрез по-прецизно пространствено филтриране на жилищната маска. Това позволява по-задълбочена интерпретация на връзката между жилищната структура и наличието на градска растителност.

3.6. Обобщение на резултатите

В настоящата глава бяха представени резултатите от прилагането на разработената методология за оценка на растителното покритие в жилищни градски територии чрез използване на мултиспектрални изображения Sentinel-2, CNN класификация, NDVI и пространствено агрегиране на резултатите. Анализът беше извършен за различни години в периода 2016–2023 г. и в два пространствени обхвата: цялата област на проучването и границите на строителната граница на град София.

ГЛАВА 4

ЗАКЛЮЧЕНИЕ

В настоящата дисертация е разгледан проблемът за количествено определяне на растителното покритие в жилищни градски територии чрез използване на мултиспектрални сателитни изображения, методи на дълбокото обучение и спектрални индекси. Основната цел на изследването е да се разработи повторяем и изчислително приложим подход, който позволява оценка на растителността в градска среда чрез публично достъпни данни и софтуерни инструменти с отворен код.

В теоретичната част са разгледани основни понятия, свързани с изкуствените невронни мрежи, конволюционните невронни мрежи, трансферното обучение, спектралните индекси и особеностите на дистанционното наблюдение в градска среда. Специално внимание е отделено на възможността предварително обучени модели, разработени първоначално за задачи от компютърното зрение, да бъдат адаптирани към анализ на сателитни изображения. Това е важно, тъй като обучението на дълбоки невронни мрежи от нулата изисква значителни обеми данни и изчислителни ресурси.

В методологичната част е предложен работен процес, основан на разделяне на изображенията Sentinel-2 на квадратни подобласти, класификация на земното покритие чрез CNN модел и последващо изчисляване на растителността чрез NDVI. В рамките на Метод 1 жилищните територии се определят чрез класификация на ниво подобласт, след което в тях се изчислява растителното покритие. Метод 2 надгражда този подход чрез използване на градиентно-базирана карта на значимост, която позволява по-fino пространствено уточняване на жилищната маска.

Експерименталната обосновка показва, че използването на трансферно обучение значително подобрява резултатите спрямо обучение на модела без предварително обучени тегла. Получената висока точност върху реално изображение от територията на град София потвърждава, че класификацията на подобласти може да бъде използвана като надеждна основа за последващ анализ на растителността в жилищни райони.

Резултатите показват, че Метод 1 осигурява стабилна и по-обхватна оценка на растителното покритие в жилищните територии. Метод 2, от своя страна, дава по-селективна оценка, като запазва само пикселите с висока значимост за класа „жилищни зони“. Сравнението между двата метода показва, че те не са взаимно изключващи се, а предоставят две различни равнища на анализ. Метод 1 е подходящ за обща площна оценка, докато Метод 2 е полезен при необходимост от по-прецизно пространствено уточняване.

Полученото съотношение между растителност и нерастителни повърхности в жилищните територии може да бъде разглеждано като количествен показател за степента на озеленяване на жилищната среда. Този показател има потенциално приложение при мониторинг на градската зеленина, сравнение между различни времеви периоди и подпомагане на пространственото планиране.

Основните ограничения на разработения подход са свързани с пространствената разделителна способност на Sentinel-2, наличието на смесени пиксели, влиянието на облаци

и сенки, сезонните различия между изображенията, избора на NDVI праг и чувствителността на Метод 2 към прага на градиентната значимост. Допълнително ограничение е зависимостта от обучителния набор EuroSAT и от неговата класификационна структура.

Въпреки тези ограничения, разработената методология показва, че чрез комбиниране на сателитни изображения, конволюционни невронни мрежи, трансферно обучение и спектрални индекси може да се изгради практически приложим подход за оценка на растителността в градска жилищна среда. Методът е повторяем, може да бъде приложен върху различни времеви периоди и използва достъпни данни и инструменти.

Бъдещото развитие на изследването може да бъде насочено към автоматизирано определяне на праговете, по-прецизно маскиране на облаци и сенки, използване на повече изображения за всяка година, прилагане на допълнителни спектрални индекси и валидация чрез независими геопространствени данни. Перспективно направление е и разработването на специализиран модел за семантична сегментация на растителността в жилищни райони, който да намали зависимостта от ръчно или полуавтоматично прагово определяне.

В заключение, настоящата дисертация предлага методологична рамка за количествено изследване на градската растителност чрез съчетаване на дистанционни изследвания и изкуствен интелект. Получените резултати показват, че подобен подход може да бъде използван като основа за мониторинг на зелената инфраструктура и за оценка на качеството на жилищната градска среда.

Приноси на дисертационния труд

1. Разработена е интегрирана методология за количествена оценка на растителното покритие в жилищни градски територии чрез многоканални сателитни изображения от Sentinel-2. Методологията комбинира класификация на земното покритие чрез CNN модел с трансферно обучение върху EfficientNetV2, семантично филтриране на жилищните зони, изчисляване на NDVI, статистическо определяне на праг и изчисляване на площни показатели за растителни и нерастителни повърхности.

2. Предложен е подход за насочване на анализа само към жилищните градски територии. Чрез класификация на изображението на ниво квадратни подобласти се отделят жилищните райони, а след това растителното покритие се изчислява само в техните граници. По този начин се избягва смесване на резултатите с гори, земеделски площи, пасища и други зелени територии, които не са пряко свързани с жилищната среда.

3. Разработен е втори метод за пространствено уточняване на жилищната маска чрез градиентно-базирана карта на значимост. Методът използва картите на значимост, получени чрез обратно разпространение на градиента през обучената CNN, за да се определят пикселите с най-голям принос към решението за класа „жилищни зони“. Това позволява намаляване на блоковия ефект от класификацията на цели подобласти и осигурява по-прецизна пространствена основа за последващия NDVI анализ.

4. Извършена е експериментална проверка и сравнителен анализ на предложените методи върху многовременни Sentinel-2 изображения за територията на град София. Методите са приложени върху изображения от различни години и върху два пространствени обхвата — цялата област на проучването и строителната граница на град София. Получените резултати позволяват сравнение на растителното покритие във времето, както и оценка на разликите между базовия подход и градиентно-базираното пространствено уточняване.

5. Разработен е специализиран софтуерен инструмент с графичен потребителски интерфейс за прилагане на предложената методология. Софтуерът реализира основните етапи на анализа — зареждане и обработка на данни, класификация, филтриране на жилищни територии, изчисляване на NDVI, генериране на маски и извеждане на пространствени и статистически резултати. Това улеснява практическото използване на методите от потребители без необходимост от директно програмиране.

Публикации по темата на Дисертацията

Гочев, Д., Узунова, Е., **Стоев, И.**, Проблеми в управлението на риска от екологични бедствия. Seventeenth Scientific Conference with International Participation “Space, Ecology, Safety – SES 2021”, 20-22 October 2021, Sofia, Bulgaria.
http://www.space.bas.bg/SES/archive/SES%202021_DOKLADI/4_Ecology/15_Gochev.pdf

Stoev, I., Uzunova, E., Knowledge transfer in artificial neural networks: state-of-the-art techniques for efficient learning and performance improvement. Nineteenth Scientific Conference with International Participation “Space, Ecology, Safety – SES 2023”, 24-26 October 2023, Sofia, Bulgaria.
http://www.space.bas.bg/SES/archive/SES%202023_DOKLADI/4_Ecology/5_Stoev.pdf

Узунова, Е., **Стоев, И.**, Мардиросян, Г., Изследване на зелените площи в градската среда с използване на методи на машинно самообучение и географски информационни системи. Twentieth Scientific Conference with International Participation “Space, Ecology, Safety – SES 2024”, 22-25 October 2024, Sofia, Bulgaria.
http://www.space.bas.bg/SES/archive/SES%202024_DOKLADI/4_Ecology/6_Uzunova.pdf

Стоев, И., Узунова, Е., Използване на изкуствени невронни мрежи за откриване, разпознаване и анализ на различни обекти от спътникови изображения. Годишна Университетска Научна Конференция, Национален военен университет „Васил Левски“, 30 юни – 1 юли 2022, Велико Търново, България.
Издателски комплекс на НВУ „Васил Левски“ ISSN 2367-7481 (във файла)

Стоев, И., Узунова, Е., И., Използване на аерокосмическата информация за изследване на урбанизацията. Годишна Университетска Научна Конференция, Национален военен университет „Васил Левски“, 30 юни – 1 юли 2022, Велико Търново, Българи
Издателски комплекс на НВУ „Васил Левски“ ISSN 2367-7481 (във файла)

Литература:

1. Bishop, C. M. (2006). Pattern Recognition and Machine Learning. In link.springer.com. Springer. <https://link.springer.com/book/9780387310732>
2. Canny, J. (1986). A Computational Approach to Edge Detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8(6), 679–698. <https://doi.org/10.1109/tpami.1986.4767851>
3. Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
4. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
5. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In Advances in Neural Information Processing Systems (pp. 1097-1105).
6. Parker, J. R. (2011). Algorithms for image processing and computer vision. Wiley.
7. Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. NASA.
8. Stoev, I., & Uzunova, E. (2023). Calculating the vegetation-to-building ratio in urban environment using remote sensing images and artificial neural network: A case study from Sofia, Bulgaria. In 2023 10th International Conference on Recent Advances in Air and Space Technologies (RAST) (pp. 1–5). IEEE. <https://doi.org/10.1109/RAST57548.2023.10197955>
9. Szeliski, R. (2022). *Computer vision: algorithms and applications* (2nd ed.). Springer. doi:10.1007/978-3-030-34372-9.
10. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. Remote Sensing of Environment, 8(2), 127–150.
11. Николов, Х. С. (2019). Приложение на нелинейни методи от теорията за разпознаване на образи в дистанционните изследвания на Земята [Докторска дисертация, Институт за космически изследвания и технологии, Българска академия на науките]. НАЦИД.