



**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>

Елица Димитрова Узунова - Стоева

**ИЗСЛЕДВАНЕ НА ГРАДСКАТА ЗЕЛЕНИНА В УРБАНИЗИРАНИ
ТЕРИТОРИИ И АНТРОПОГЕННОТО ВЛИЯНИЕ ВЪРХУ НЕЯ ЧРЕЗ
АЕРОКОСМИЧЕСКИ ТЕХНОЛОГИИ**

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“

Научен ръководител:

проф. д-р Г. Мардиросян

София
2025

Номерацията на фигурите, таблиците и формулите в автореферата е идентична с тази в дисертационния труд.

СЪДЪРЖАНИЕ:

Актуалност на темата.....	4
Предмет, цел и задачи на изследването.....	4
Обект на изследването.....	6
ГЛАВА 1 ЛИТЕРАТУРЕН ОБЗОР.....	7
Урбанизация, съвременни тенденции и предизвикателства пред градовете.....	7
ГЛАВА 2 МЕТОДИКА НА ИЗСЛЕДВАНЕТО.....	12
Предварителна обработка на сателитни данни, необходими за създаването на методиката	12
Геопространствени слоеве.....	14
Сравнителен анализ на използваните алгоритми за класификация на земното покритие...	15
Класификация на земното покритие чрез алгоритъма SAM.....	18
Пространствена маска чрез CLC.....	19
Описание на алгоритъма на работа.....	22
ГЛАВА 3 РЕЗУЛТАТИ И АНАЛИЗ НА РЕЗУЛТАТИТЕ ОТ ИЗСЛЕДВАНЕТО.....	23
Представяне на класификационните резултати по години.....	23
Времеви геопространствен анализ на градската среда в град София - картографско сравнение на извадки от различни градски области (2016–2023 г.).....	24
Анализ на резултатите и дискусия.....	24
Дискусия.....	28
Ограничения на изследването.....	29
Перспективи за бъдещите изследвания.....	29
4. ЗАКЛЮЧЕНИЕ.....	30
Публикации по темата на Дисертацията.....	47

Актуалност на темата

Урбанизацията е глобален процес с дълбоки социални, икономически и екологични последици. Над 68% от световното население се очаква да живее в градове до 2050 г., като този растеж е особено интензивен в развиващите се региони и в разрастващи се европейски столици като София. Успоредно с това, нараства значението на градските зелени площи (Urban Green Spaces - UGS) като критичен компонент за осигуряване на екологична устойчивост, социална кохезия и качество на живот в гъсто населени градски територии.

През последното десетилетие София преживява интензивни пространствени трансформации, свързани с нарастващо строително натоварване, вътрешна миграция и променящи се нужди на населението.

Тази тенденция отразява глобалния модел на урбанизация, при който зелените пространства постепенно се редуцират в полза на застрояване, често без балансирана екологична компенсация. В контекста на засилени климатични промени, градски топлинни острови, замърсяване и социални неравенства, устойчивото управление на градските зелени площи се превръща във въпрос от стратегическо значение.

Градските зелени площи играят ключова роля за регулиране на микроклимата, пречистване на въздуха, съхраняване на биоразнообразието и осигуряване на възможности за отдих, спорт и социални контакти. Наличието и равномерното разпределение на такива пространства в рамките на града пряко влияят върху физическото и психичното здраве на населението.

Съвременните сателитни технологии и Географски информационни системи (GIS), съчетани със спектрална класификация с обучение, базирана на знания, предоставят възможност за разработване на иновативни инструменти за пространствен и времеви мониторинг, които да подпомогнат устойчивото развитие на градската среда.

Настоящото изследване се вписва именно в тази актуална и належаща рамка, като цели да предложи методичен подход за многогодишна оценка на градските зелени площи на София чрез дистанционни технологии и спектрална класификация с обучения, базирана на знания.

Предмет, цел и задачи на изследването

Предмет на настоящото изследване е анализът на пространствената и количествената динамика на градските(урбанизирани) зелени площи в град София за периода 2016–2023 г., извършен чрез дистанционни изследвания, автоматизирана класификация на земното покритие и пространствена маска с помощта на данни от Corine Land Cover (CLC). Анализът е ограничен в рамките на строителната граница на града, дефинирана в действащия Общ устройствен план (ОУП), като обхваща само територии с функционално значение за оценка на зелената инфраструктура в урбанизираната зона на града.

Целта на изследването е да се разработи, приложи и валидира интегрирана методика за многогодишен мониторинг и анализ на градските зелени площи за територията на гр. София.

Разработената методика съчетава:

1. мултиспектрални сателитни изображения от мисията Sentinel-2,
2. географски информационни системи Quantum GIS (QGIS),
3. класификация с обучение, базирана на знания (полуавтоматична класификация по метод Spectral Angle Mapper – SAM)
4. CLC-маска (Corine Land Cover, ниво 3) за тематично прецизиране на анализа.

Целта е не само да се установи състоянието на UGS в определени моменти от времето, но и да се проследи трансформацията и в условията на интензивен антропогенен урбанистичен натиск. Предложената методика цели да осигури еднородна, съпоставима и приложима във времето система за анализ, подходяща за оценка на градската среда.

За постигане на поставената цел са формулирани следните задачи:

1. Да се подбере съпоставим набор от сателитни изображения Sentinel-2 (Level-2A), регистрирани в периода 2016–2023 г., в условия на максимална вегетация и ниска облачност (<10%), и да се извърши предварителна обработка и пространствено изрязване по строителната граница на София.
2. Да се сравнят три алгоритъма за класификация с обучение на земното покритие — Spectral Angle Mapper (SAM), Maximum Likelihood (MLike) и Minimum Distance (MD) — с цел избор на най-подходящия метод въз основа на количествени показатели за точност.
3. Да се приложи избраният алгоритъм към всяко изображение от създадения набор при използване на идентична класификационна схема, гарантираща съпоставимост между различните години.
4. Да се приложи пространствена филтрация чрез CLC-маска върху получените класифицирани данни с цел изключване на ирелевантни територии (индустриални зони, пътища и др.) и насочване на анализа към функционално значимата зелена инфраструктура.
5. Да се извърши количествен анализ на типовете земно покритие (зеленина, застрояване, почва, вода) и да се трансформират резултатите от пикселни стойности в площ (km²) за всяка година от периода.
6. Да се формулират обобщени изводи и заключения относно тенденциите в състоянието и развитието на градските зелени площи в София за разглеждания период, както и такива относно ефективността, устойчивостта и приложимостта на предложената методика за мониторинг на урбанизирана среда.

Обект на изследването

Обект на изследването са градските зелени площи в рамките на урбанизираната територия на град София, които са подложени на интензивни антропогенни и урбанистични въздействия през последните десетилетия. Град София – столицата и най-голям урбанизиран център на Република България, е разположена в западната част на страната, в Софийската котловина обградена от планините Витоша, Люлин и Стара планина. Средната надморска височина е около 550 m, което влияе върху микроклимата, растителността и степента на замърсяване. За сравнение, надморската височина на Мадрид е около 667 m, Берн – 540 m, Виена – около 170 m, а Букурещ – едва 55 m (World Cities Database, 2023).

Град София заема площ от приблизително 492 km² (съгласно действащия Общ устройствен план – ОУП), от които около 190 km² представляват урбанизирана територия в рамките на строителната граница, а останалата част включва периферни зони, като земеделски земи, горски масиви, планински терени и незастроени площи, които са част от административната територия на Столична община.

Съгласно последни данни на Националния статистически институт, населението на град София възлиза на приблизително 1.3 милиона души (НСИ, 2023). Като водещ икономически и урбанистичен център на страната, столицата представлява основен център на вътрешна миграция, което обуславя устойчив демографски ръст от над 300 000 души през последните две десетилетия. По актуални оценки около 18% от населението на Република България живее в рамките на Столична община, като гъстотата на населението в урбанизираните ѝ територии надвишава 2700 жители на km² (НСИ, 2023).

Настоящото изследване се фокусира върху урбанизирана територия в рамките на строителната граница – дефинирана чрез ОУП, включваща жилищни, обществени и инфраструктурни територии, но изключваща периферните земеделски и горски масиви. Този фокус е от решаващо значение при оценка на антропогенното натоварване върху градските зелени площи.

София има дългогодишни традиции в изграждането на зелена система, започнали още през 1884 г. с оформянето на Борисовата градина по инициатива на кмета Иван Хаджиенов и градинаря Даниел Неф – първият структуриран обществен парк в столицата (Wikipedia, 2024a). През 1938 г. Мусмановият план на архитекта Адолф Мусман предлага визия за интегрирана зелена система със зелени клинове и радиално-концентрична структура. Въпреки че остава частично реализиран поради Втората световна война, планът трайно повлиява на следвоенното градоустройство (НАГ София, 2024).

В периода 1940–1990 г. зелената система на София се разширява значително с изграждането на Южния, Западния и Северния парк, както и редица квартални градини и междублокови пространства, в духа на социалистическото планиране, което залага на публичен достъп до зелени площи и функционално зониране (SofiaPlan, 2021). Зелените зони са оформяни съгласно нормите на социалистическия урбанизъм, с акцент върху обществената функция и близостта до жилищни райони.

След 1990 г. се наблюдава отслабване на политиките за опазване и развитие на градските зелени площи, съпроводен от засилен урбанистичен натиск. Много от терените, планирани за зелени пространства, стават частна собственост и не са реализирани като такива поради липса на публични ресурси, правомощия и административен капацитет (SofiaPlan, 2021; Wikipedia, 2024b). Например, в новите квартали Манастирски ливади, Витоша и Кръстова вада, недостигът на обществено достъпни зелени площи е особено осезаем, което влошава качеството на градската среда (Wikipedia, 2024b).

Настоящото изследване се стреми да оцени състоянието на UGS в София чрез дистанционни аерокосмически технологии, класификация с обучение, базирана на знания, и GIS-базирани анализи, прилагайки стандартизирана пространствена рамка и единен методичен подход, който включва CLC-маска за тематично прецизиране на площта на изследването.

ГЛАВА 1

ЛИТЕРАТУРЕН ОБЗОР

Урбанизация, съвременни тенденции и предизвикателства пред градовете.

Урбанизацията се превърна в един от най-значимите и определящи процеси за глобалното развитие на съвременната цивилизация. С нарастващата миграция на населението към градски райони, промените в пространствената организация и увеличаващото се потребление на ресурси, необходимостта от устойчиво градско развитие става по-належаща от всякога. Към 2022 г. световното население надхвърли 8 милиарда души, а се очаква до 2050 г. този брой да достигне 9.7 милиарда (United Nations, 2022). Успоредно с това се предвижда, че близо 70% от населението ще обитава градове, което означава, че градовете ще се превърнат в основен фокус на демографския, икономическия и екологичния натиск. Това изисква иновативни решения в планирането, управлението и адаптацията на градската среда, включително по-добро интегриране на технологиите, по-ефективно използване на ресурсите и постигане на социална справедливост.

Исторически погледнато, урбанизацията е многостранен процес, включващ териториални, икономически, социални и културни трансформации. Още в древността, цивилизации като шумерската, египетската, индийската и китайската създават сложни градски структури, които служат като центрове на търговия, администрация и култура. Древният Рим е ярък пример за първия истински мегаполис с над 1 милион жители, където общественото пространство, зелените зони и инфраструктурата са интегрирани в градската тъкан. Средновековните градове от своя страна развиват компактна структура и формират ядра на занаятчийска и търговска активност. Ренесансовият град възвръща естетическите и пространствени идеали на античността, докато индустриалният град води до експлозивно нарастване на урбанизираните територии. С навлизането на глобализацията и технологиите в края на XX и началото на XXI век урбанизацията придобива ново измерение – вече не само количествено, но и качествено, свързано с начина на живот, управление и устойчивост на градските системи. Този преход се характеризира и с по-голяма сложност на

взаимодействието между инфраструктура, население и природна среда, което налага интердисциплинарни подходи в изследванията и практиките по градско развитие.

Днес градовете се изправят пред безпрецедентни предизвикателства, включително климатични рискове, изчерпване на ресурси, социална поляризация и технологично неравенство. Прогнозите сочат, че до 2050 г. 95% от градовете ще бъдат изложени на поне едно екстремно климатично явление като наводнения, горещи вълни или суши. В същото време урбанизираните територии ще продължат да растат, особено в Азия и Африка, където урбанизацията протича с ускорени темпове. Това поставя на дневен ред необходимостта от нов тип градско планиране – такова, което съчетава иновации, устойчивост и социална справедливост. Ключова част от този процес е гарантирането на равен достъп до услуги, зелени пространства, безопасна среда и дигитална свързаност (UN-Habitat, 2024). Освен това, нуждата от адаптивна инфраструктура, която да отговаря на динамично променящия се климат и нарастващото социално неравенство, става все по-осезаема. Така се оформя нова парадигма в урбанизма, в която екологичните, икономическите и социалните фактори се разглеждат като взаимозависими и съвместно подлежащи на управление.

В контекста на тези предизвикателства концепцията за умни и устойчиви градове (Smart and Sustainable Cities) се утвърди като водещ модел за развитие. Тя съчетава дигитални технологии, екологични стратегии и социална чувствителност, като цели да трансформира начина, по който градовете функционират. Чрез използване на IoT, изкуствен интелект (AI), машинно обучение (ML) и големи данни (Big Data), се подобрява управлението на транспорта, енергетиката, водните ресурси и отпадъците, както и взаимодействието между администрацията и гражданите (Caragliu et al., 2023; Bibri, 2018). Умните градове не само намаляват въглеродния отпечатък, но и увеличават ефективността на системите и насърчават приобщаването. Те предлагат възможности за динамично планиране, основано на данни, включително в реално време, като подпомагат както вземането на политически решения, така и ежедневната логистика на градската система. Градове като Сингапур, Барселона и Копенхаген са примери за успешна реализация на тази парадигма – Сингапур използва вертикални градини и сензори за мониторинг на енергийното потребление, Барселона разширява микромобилността и устойчивото строителство, а Копенхаген постига високи нива на възобновяема енергия (Singapore Ministry of Sustainability, 2024; Ajuntament de Barcelona, 2023; Copenhagen Climate Plan, 2022). Други примери включват Токио, където се прилага разширена реалност за транспортна координация, и Хелзинки, който развива цифрови услуги за устойчиво управление на обществени пространства.

Особено важна роля в устойчивото градско развитие играят зелените площи (Urban Green Spaces – UGS). Те не са просто лукс, а необходимост, от която зависи здравето, благополучието и устойчивостта на градската екосистема. Тяхната роля се разпростира далеч отвъд визуалната естетика – зелените зони изпълняват функциите на екологични буфери, социални регулатори и икономически катализатори. Исторически, зелените пространства са съпътствали урбанизацията още от древността – от Висящите градини на Семирамида и градините на Персеполис, през римските форуми и терми, до бароковите и английските пейзажни паркове. В индустриалната епоха зелените площи се възприемат като отговор на замърсяването и социалната фрагментация, водещи до създаване на обществени паркове като Хайд парк или Булонския лес. Тези пространства осигуряват възможности за отдих,

движение и социални взаимодействия, които са критични за психическото и физическото здраве на градските обитатели. Днес UGS обхващат паркове, зелени покриви, градини, крайречни зони, горски пояси и естествени/полуестествени зелени структури в урбанизираните територии (Fuller et al., 2007; Bowler et al., 2010). Те представляват не само средство за естетическо и екологично подобрене на градската среда, но и стратегически елемент в борбата с климатичните промени и в изграждането на по-здравословен и справедлив градски живот. Зелената инфраструктура се разглежда като съвкупност от взаимосвързани екологични пространства, които изпълняват регулационни, културни и поддържащи екосистемни услуги, включително регулиране на въздушните потоци, съхранение на въглерод и поддържане на микроклимата.

UGS подобряват качеството на въздуха чрез абсорбция на замърсители, понижават температурите чрез сенчести зони и евапотранспирация, задържат и инфилтрират дъждовната вода, и повишават психичното и физическо здраве на гражданите. Те също така допринасят за биологичното разнообразие, предлагат местообитания на градска фауна и флора и повишават естетическата стойност на градската среда (Bratman et al., 2015; Nowak et al., 2006). От икономическа гледна точка, присъствието на UGS повишава стойността на недвижимите имоти и намалява разходите за здравеопазване (Crompton, 2001). Допълнително, зелените площи играят роля в изграждането на социален капитал – те служат като пространства за срещи, културни събития и общностна активност, като по този начин засилват социалната кохезия и усещането за принадлежност в градската среда. Наличието на добре поддържани зелени пространства повишава привлекателността на дадено населено място, като го прави конкурентоспособно по отношение на привличане на нови жители, инвеститори и туристи. Съществуват доказателства, че достъпът до UGS се свързва с намалена престъпност, подобрена образователна среда и повишено участие в граждански дейности.

Ефективното управление на зелената инфраструктура изисква съвременни технологии за наблюдение и анализ. Дистанционните изследвания чрез сателити и дроневи позволяват точно проследяване на промените в растителността, идентифициране на територии с екологичен стрес и анализ на урбанизационните процеси. Сателитни системи като Sentinel-2, Landsat и WorldView предоставят изображения с висока пространствена и спектрална резолюция, които се използват за изчисляване на индекси като NDVI, EVI, SAVI и NDWI (Tucker, 1979; Huete et al., 1988). Чрез тях може да се оценят сезонните и годишните промени в зеленото покритие, да се моделират топлинни острови и да се определят приоритетни зони за озеленяване. Интеграцията на тези технологии с ГИС системи създава възможност за пространствено планиране, базирано на данни, и ранно предупреждение при екологични промени. Това позволява по-добро разбиране на пространствената динамика на растителността, проследяване на ефекта от политиките и оценка на ефективността на предприетите интервенции.

Класификацията на земното покритие е друг съществен компонент, особено чрез използване на алгоритми като Spectral Angle Mapper (SAM), Minimum Distance и Maximum Likelihood. Тези методи позволяват автоматизирана идентификация на различни земни класове, включително урбанизирани и зелени територии, което подпомага управлението на градското развитие и екологичния мониторинг (Jensen, 2015; Richards, 2013). SAM методът се

основава на изчисляване на спектрален ъгъл между векторите на пикселите и референтните класове, което го прави особено подходящ за класификация в хетерогенни градски среди. Minimum Distance е бърз и интуитивен метод, който използва евклидово разстояние за сравнение между спектрални подписи, докато Maximum Likelihood е статистически подход, отчитащ вероятностните разпределения и ковариационната структура на данните. Всеки от тези методи има специфични изисквания към данните и обучителните проби, което налага внимателен подбор и предварителна подготовка на входните данни. Сравнителният анализ на тези методи показва, че всяка техника има своите предимства и ограничения в зависимост от целите на анализа, резолюцията на данните и природните характеристики на изследваната зона. Затова често се прилагат хибридни подходи, които съчетават няколко метода за постигане на по-висока точност и надеждност на резултатите. Съчетаването на различни методи и източници на данни (например сателитни изображения, LIDAR и наземни наблюдения) води до значително подобрене на пространствената прецизност, което е от съществено значение при вземането на решения, свързани със стратегическото градско планиране. Допълнително, използването на машинно обучение и невронни мрежи, включително Random Forest и Support Vector Machines, също намира приложение в съвременната класификация на земното покритие и може да подобри автоматизацията и адаптивността на анализите в условия на големи и разнообразни данни.

Географските информационни системи (ГИС), и в частност QGIS, предоставят платформа за интеграция и визуализация на пространствени данни. QGIS е предпочитан инструмент благодарение на своята отвореност, широката поддръжка на плъгини и съвместимост с бази данни и дистанционни сензори. С негова помощ се изграждат тематични карти, модели за анализ на уязвимост и симулации за бъдещо развитие. Освен това, QGIS позволява автоматизация на рутинни процеси, създаване на интерактивни уеб карти и управление на обемни данни в реално време, което го прави идеален за използване в академични, административни и практико-приложни контексти. Програмата е особено ефективна при работа с данни от програмата Copernicus, осигуряваща отворен достъп до сателитна информация от мисиите Sentinel, с което се осигурява постоянен мониторинг на зелените структури в динамично развиващите се градски зони. В допълнение, QGIS предлага възможност за вграждане на скриптове на Python чрез интерфейса PyQGIS, което улеснява разработването на автоматизирани работни потоци и персонализирани модули за анализ. Интеграцията със системи като PostGIS и GRASS GIS разширява възможностите за пространствени изчисления, моделиране на водни потоци и управление на геоданни на голяма териториална скала.

На национално и регионално ниво, Общите устройствени планове (ОУП) играят критична роля за дългосрочното градско развитие. В случай като София, ОУП интегрира параметри за плътност на застрояване, минимално озеленяване, зонироване и строителна граница. Целта е да се осигури балансирано развитие, което съчетава икономически растеж с екологична сигурност. Строителната граница има функцията да ограничава хаотичното разрастване и да запазва селскостопански и природни територии. Визията за София до 2050 г. включва развитие на полицентрична структура, модернизирана транспортна система и интегрирана зелена инфраструктура (Визия за София, 2019). Успешното прилагане на този план предполага силна координация между различни заинтересовани страни, включително

местните власти, гражданското общество, бизнеса и научните институции. Особено важно е съчетаването на пространствени данни с регулаторни инструменти, за да се гарантира, че процесите на планиране са основани на реални наблюдения и отразяват актуалната териториална динамика.

Изкуствен интелект (AI) и машинно самообучение (ML) са фундаментални технологии, които революционизират дистанционните изследвания, особено при анализа на урбанизирани територии. AI обхваща системи, способни да изпълняват задачи, изискващи човешка интелигентност, докато ML – негово подмножество – се базира на алгоритми, които автоматично извличат закономерности от данни и усъвършенстват модела без изрично програмиране (Russell & Norvig, 2021; Goodfellow et al., 2016). От теоретичните основи на Тюринг (1936) и дефинирането на AI през 1956 г., през ранните експертни системи и невронните мрежи, до дълбокото обучение (Krizhevsky et al., 2017), развитието на тези технологии значително повлия на геопространствените науки.

В контекста на урбанизирани територии AI и ML автоматизират обработката на мулти- и хиперспектрални сателитни данни, повишавайки точността на класификация и скоростта на анализ. Те се прилагат за мониторинг на градската зелена инфраструктура (UGS), оценка на биоразнообразието, проследяване на сезонни и дългосрочни промени в растителността, както и за прогнозиране на климатични въздействия. Това подпомага устойчивото планиране и управлението на ресурсите в гъстонаселени зони.

Ключови методи са:

- SAM (Spectral Angle Mapper) – измерва ъгъла между спектралния подпис на пиксел и еталон; устойчив на вариации в осветеността, особено ефективен при сложни градски сцени със смесени класове.
- MD (Minimum Distance) – класифицира по минимално евклидово разстояние; бърз метод, подходящ за ясно разграничени класове, но с по-ниска ефективност при спектрално сходни обекти.
- MLike (Maximum Likelihood) – използва вероятностни оценки и статистически предположения за разпределението на данните; постига висока точност при добре подбрани обучителни множества.

Интеграцията на тези алгоритми в GIS платформи като QGIS осигурява надеждни и научно обосновани резултати, които подкрепят вземането на стратегически решения за екологична устойчивост, адаптивно планиране и оптимизация на зелената инфраструктура в градска среда.

В заключение, устойчивото развитие на съвременните градове е фундаментален приоритет за настоящето и бъдещето. То изисква цялостен, интегриран и научно обоснован подход, който комбинира социална отговорност, технологична иновация и екологична осведоменост. Само чрез прилагането на добри практики, ангажираност на гражданите и ефективно използване на ресурси ще бъде възможно създаването на градове, които са не само функционални, но и справедливи, устойчиви и живи за поколенията напред.

ГЛАВА 2

МЕТОДИКА НА ИЗСЛЕДВАНЕТО

Настоящото изследване прилага интегриран подход, основан на използването на мултиспектрални данни от дистанционни изследвания, геоинформационни технологии и елементи на AI, целящо анализ на времевата динамика на зелената инфраструктура в урбанизирана среда. В основата на анализа са мултиспектрални сателитни изображения от мисията Sentinel-2, избрани по следните два критерия — вегетационен пик на растителността (юли–август) и облачно покритие (по-малко от 10%) — за всяка година в периода 2016–2023 г.

Класификацията е извършена чрез алгоритъма SAM, който представлява метод за спектрална класификация, базиран на знания, използващ спектрална близост между пикселите и предварително ръчно дефинирани еталонни спектри, извлечени от Sentinel-2. UGS са основен компонент в настоящото изследване поради тяхната ключова функция в осигуряването на екосистемни услуги, включително регулиране на микроклимата, пречистване на въздуха и предоставяне на пространства за отдих, които допринасят за устойчивостта на градската среда и за благосъстоянието на населението.

С цел ограничаване на анализа само в рамките на урбанизирания център на столицата, пространственият обхват на изследването е дефиниран чрез официалната строителна граница на град София, предоставена от Столична община. Тази граница е използвана като пространствена маска, позволяваща класификацията да се съсредоточи върху реално застроените и функционално свързани територии. По този начин се избягва включването на периферни и незасегнати от урбанизацията площи, като се гарантира по-висока точност при класификация и приложимост на резултатите.

Предложената методика цели да отговори на актуалната нужда от системен мониторинг на градската екологична среда, като използва доказани технологични решения и адаптивни аналитични техники за проследяване на пространствено-времеви изменения.

Предварителна обработка на сателитни данни, необходими за създаването на методиката

Получаването на надеждни сателитни данни от дистанционни изследвания представлява основополагащ етап при оценката на градските зелени площи. Като основен източник в настоящото изследване са използвани мултиспектрални изображения от Sentinel-2. Изображенията от Sentinel-2 предоставят систематични и детайлно пространствени данни за земното покритие с висока точност, което ги прави подходящи за урбанизирани среди.

Избор на данни.

Изборът на сателитни изображения е базиран на мултиспектрални данни от мисията Sentinel-2, достъпни от *Copernicus Open Access Hub* (European Space Agency, 2023) и *Google Earth Engine* (Google, n.d.). GEE е използван като основна среда за автоматизирано извличане, облачна филтрация и предварителна обработка на изображенията посредством Python API.

За разработване на методиката на изследването е използвана сцена от 22 юли 2023 г., като отработената методика е приложен и към изображения от предходни години: 31 юли

2016 г., 23 юли 2017 г., 7 август 2018 г., 23 юли 2019 г., 11 август 2020 г., 17 юли 2021 г. и 22 юли 2022 г. По този начин беше формирана времева серия от обработени изображения. Това позволи извършването на съпоставим многогодишен анализ на пространствено-времените изменения в зелената система на град София.

За целите на настоящото изследване са избрани сцени с облачност под 10% – критично условие за гарантиране на максимална използваемост на данните, както и минимизиране на потенциални грешки в последващата класификация, възникващи в резултат на невъзможност за получаване на данни за земната повърхност.

Изображенията са избрани за периода на пика на вегетационния сезон – месеците юли и август, когато условията за растеж на растителността в градска среда са най-благоприятни.

В този контекст е важно да се отбележи, че растителната покривка притежава различни спектрални отражателни коефициенти в зависимост от дължината на вълната на електромагнитната енергия.

За улеснение на обработката бяха изтеглени изображения от COPERNICUS/S2_SR_HARMONIZED (Level-2A) от GEE с атмосферно коригирани изображения с BOA отражение чрез Sen2Cor метода, използвани в настоящото изследване заради надеждността си при анализи на растителност. Тези изображения включват и допълнителни канали за маски на облаци и сенки, които улесняват пространственото филтриране. Подборът на изображенията е осъществен чрез Google Earth Engine. Изображенията попадат в сцена 34TFN Military Grid Reference System (MGRS) - Военна мрежова координатна система, която обхваща територията на гр. София.

С цел автоматизиране извличането на данните е използвана системата Google Earth Engine (GEE). Системата предоставя приложен програмен интерфейс Application Programming Interface (API) за езика Python. С негова помощ бяха извлечени изображения за периода 2016 – 2023 г., което позволява прилагане на унифициран многогодишен анализ.

GEE позволява автоматизирано извличане на изображения чрез Python API, което е използвано в настоящото изследване за систематично изтегляне на данни за няколко последователни години от 2016 г. до 2023 г. Това позволява прилагане на унифициран метод за анализ на динамиката на зелената система в дългосрочен план. Следните стъпки са извършени за всяка от годините:

- Определяне на географски регион (граница на София).
[23.168293045771108, 42.84699170585309],
[23.168293045771108, 42.5613935863229],
[23.48209004284142, 42.5613935863229],
[23.48209004284142, 42.84699170585309]
- Филтриране по дата и облачност.
Избираме изображения от периода юли – август и филтрираме така, че да имат по-малко от 10% облачна покривка.
- Избор на канали: B1, B2, B3, B4, B5, B6, B7, B8, B8A, B9, B10, B11, B12;
- Експортиране във формат GeoTIFF за последваща GIS обработка и сравнение между годините.

Резултатът е осем мултиспектрални GeoTIFF изображения, състоящи се от тринадесет канала с ПРС 10, 20 и 60 m. Те са подходящи за анализи на вегетационни индекси и класификация на земното покритие в урбанизирана среда. На Фигура 6 е показано едно от тези GeoTIFF изображения - 22.07.2023 г.

Геопространствени слоеве

За нуждите на пространствения анализ в изследването са използвани следните основни геопространствени слоеве във векторен формат (ОУП София – GIS портал)

Общ устройствен план на София (ОУП) – действащият ОУП от 2022 г. служи като основа за дефиниране на строителната граница на града. Този векторен слой позволява прецизно изолиране на урбанизираната територия, върху която се фокусират всички последващи анализи и класификации (Sofiaplan, 2023).

Граница на изследването

Общият устройствен план (ОУП) представлява стратегически документ за дългосрочно планиране на пространственото развитие на градската територия.

- Строителна граница (СГ) на гр. София означена с червена линия на Фигура 7.
Определена от Общия устройствен план (ОУП).
Очертава зоните с разрешено строителство и инфраструктура.
Използва се за ограничаване на разрастването и насърчаване на компактно развитие.
- Административна граница (АГ) на гр. София означена с лилава линия на Фигура 7.
Официална граница на Столична община.
Включва София и населени места, като Банкя, Бухово, Панчарево и др.
Обхваща и природни територии извън същинския град.

Визуализацията е върху сателитна основа като двете граници ясно демонстрират разликата между функционалното урбанизирано ядро - СГ и разширената административна юрисдикция на АГ на Столична община (Фигура 7).

Изображението, изрязано по СГ, е използвано за визуализация и класификация на земното покритие и е представено на Фигура 8.

Създаване на обучителен набор от мултиспектрални данни

За създаването на надежден набор от обучителни данни бяха ръчно дигитализирани полигони, равномерно разпределени между четири основни класа на земното покритие: застрояване, растителност, вода и почва. Всеки клас беше представен чрез множество полигони, избрани от визуално проверени, хомогенни участъци в рамките на изследваната територия. Процесът на дигитализация беше извършен с помощта на инструментите в QGIS, като се използваха както мултиспектралните сателитни изображения от Sentinel-2, така и налични базови карти в случая OpenStreetMap, които осигуриха допълнителен контекст и кръстосана валидация на избраните площи.

Изборът на хомогенни области бе от решаващо значение за минимизиране на вариациите вътре в спектралния клас, което осигури висока представителност на еталонните спектрални характеристики на всеки клас. За всеки полигон бяха извлечени пиксели, които впоследствие послужиха за изчисляване на средни спектрални стойности, използвани за

формирание на еталонни спектрални характеристики. Тези характеристики служеха като основа за класификационния процес, като бяха приложени върху цялата изследвана област с цел разграничаване и картографиране на различните типове земно покритие.

Подходът с ръчно дигитализирани обучителни данни осигури контрол върху качеството и представителността на класовете, което е особено важно при използването на SAM. В допълнение, този метод позволи адаптиране към локалните особености на градската среда, като се вземат предвид както спектралните, така и контекстуалните характеристики на различните територии.

Използвано е сателитното изображение от 22.07.2023 г. и растерна основа OpenStreetMap (OSM) за визуална ориентация и валидация.

За изграждане на обучителен набор от данни ръчно бяха дигитализирани 18 полигони в QGIS, разпределени между четири основни класа: Застрояване (червен цвят), Зеленина (зелен цвят), Почва (жълт цвят), Вода (син цвят).

Полигоните обхващат визуално проверени, хомогенни участъци, с цел минимизиране на спектралните вариации във всеки един клас.

От избраната обучителна съвкупност бяха извлечени средни спектрални стойности, използвани като еталони за обучение на класификационния модел.

На Фигура 9 са показани еталонни спектрални характеристики на обучителната съвкупност от данни.

Сравнителен анализ на използваните алгоритми за класификация на земното покритие

Приложени са три алгоритъма за класификация с обучение на земното покритие за да се избере, кой от тях съответства най-добре на нуждите на изследването - Spectral Angle Mapper (SAM) (Kruse et al., 1993); Maximum Likelihood (MLlike); Minimum Distance (MD).

След сравнение на резултатите, SAM бе избран като основен метод. Основните причини за избора на SAM включват неговата устойчивост към вариации в осветеността, чувствителност към спектрални различия и способността му да обработва данни с висок спектрален обем без изискване за предварително допускане за разпределението на данните. В конкретния случай SAM демонстрира по-висока точност при разграничаване на зелени площи от смесени класове (като почва и застрояване), както и по-ниска степен на объркване в сравнение с MLlike и MD методите. Освен това, SAM работи добре с по-малко обучителни данни, което е предимство при градски анализи с ограничени теренни верификации.

Методологично описание на алгоритмите

SAM измерва ъгъла между спектралния вектор на даден пиксел и този на референтен клас в многомерното спектрално пространство. Колкото по-малък е ъгълът между векторите, толкова по-голяма е спектралната прилика между пиксела и съответния клас. Това прави SAM особено ефективен при наличие на сенки, отразяващи повърхности и други фактори, които променят интензитета, но не и формата на спектралния подпис. Благодарение на своята устойчивост към вариации в яркостта, методът се счита за един от най-надеждните при

анализ на хетерогенни урбанизирани територии с висока пространствена и спектрална сложност.

MLlike използва вероятностен подход и предполага нормално разпределение на спектралните стойности за всеки клас. Методът изчислява вероятността всеки пиксел да принадлежи към даден клас въз основа на ковариационна матрица и средни стойности. Въпреки че е много точен при добре дефинирани класове и големи обучителни извадки, той е чувствителен към грешки в обучителните данни, както и към преобладаване на някои класове, което може да доведе до изкривяване на резултатите.

MD е един от най-лесните и бързи методи за класификация. Той сравнява всеки пиксел с централните стойности (средни спектрални стойности) на всеки клас и го отнася към този, до който е най-близо по стойност. Представете си това като измерване на разстояние в цветно пространство — ако даден пиксел е по-близо до типичната стойност на почва, ще бъде класифициран като такъв. Методът обаче не отчита колко разнообразни са стойностите в даден клас (напр. дали има голямо вътрешно разсейване), което може да доведе до грешки. Затова, в случаи когато класовете са много близки по спектрални характеристики — като почва и суха растителност, или сенчеста сграда и тъмна почва — резултатите може да не са много точни.

За анализът използва изображение от Sentinel-2 от 22.07.2023 г. (COPERNICUS/S2_SR, Level-2A), с 13 спектрални канала и PPC от 10, 20 и 60 m.

Матрици на грешките (Confusion Matrix)

Матриците на грешките са инструмент за количествена оценка на ефективността на алгоритмите за класификация. Матрицата на грешките е таблица, която показва колко добре работи даден алгоритъм за класификация. В нея се сравняват реалните стойности (това, което трябва да бъде) с прогнозираните стойности (това, което алгоритъмът е предсказал).

Стойностите по диагонала на матрицата означава, че пикселът е класифициран правилно. Стойностите извън диагонала показват грешки – случаи, в които даден клас е объркан с друг.

Тази матрица помага да се разбере къде и колко често алгоритъмът греша.

На базата на тези матрици се изчисляват следните статистически метрики, включително:

- Обща точност (Overall Accuracy, OA) – процентът от всички правилно класифицирани пиксели спрямо общия брой пиксели.
- Карра коефициент (K) – индикатор за съвпадението между класификацията и реалните данни, коригиран за случайно съвпадение (Congalton, 1991).
- Producer's Accuracy (PA) – показва каква част от реално съществуващите пиксели "Растителност" са правилно класифицирани като такива.

Таблица 5. Структура на матрицата (бинарна класификация)

	Предсказано: Положително	Предсказано: Отрицателно
Реално: Положително	True Positive (TP)	False Negative (FN)
Реално: Отрицателно	False Positive (FP)	True Negative (TN)

Изчислени са три ключови показателя:

Обща точност (Overall Accuracy, OA):

(8)

$$OA = \frac{TP + TN}{TP + TN + FP + FN}$$

Коефициент на Кappa (K):

(9)

където:

p_o = наблюдавана точност (общо съвпадения / всички)

p_e = очаквана точност по случайност

$$K = \frac{p_o - p_e}{1 - p_e}$$

Producer's Accuracy (PA) –

(10)

$$PA = \frac{TP}{\text{All real cases (row)}} \times 100$$

Оценката на точността е извършена чрез матрица на грешките в QGIS, с помощта на модула Semi-Automatic Classification Plugin (SCP). Резултатите включват обща точност (OA), и Кappa коефициент ($K = 0.89$), който показва много високо съответствие между класифицираните и референтните стойности.

В настоящото изследване матриците на грешките бяха използвани за сравнение между трите метода – SAM, ML и MD – за да се оцени тяхната ефективност при класификация на четирите класа земно покритие в градска среда.

Таблица 6: SAM

Клас	Растителност	Застрояване	Почва	Вода
Растителност	92%	3%	4%	1%
Застрояване	5%	88%	6%	1%
Почва	7%	2%	89%	2%
Вода	0%	1%	1%	98%

Таблица 7: ML

Клас	Растителност	Застрояване	Почва	Вода
Растителност	87%	5%	6%	2%
Застрояване	4%	91%	3%	2%
Почва	6%	3%	88%	3%
Вода	1%	2%	1%	96%

Таблица 8: MD

Клас	Растителност	Застрояване	Почва	Вода
Растителност	83%	6%	9%	2%
Застрояване	8%	84%	5%	3%
Почва	10%	4%	83%	3%
Вода	2%	3%	3%	92%

Таблица 9: Сравнителни резултати

Метод	Точност растителност (%)	Обща точност (%)	Карра коефициент
Spectral Angle Mapper	92	89.3	0.89
Maximum Likelihood	88	91.1	0.91
Minimum Distance	83	83.7	0.78

SAM демонстрира най-висока тематична точност за растителност и най-добро представяне в условия с голямо разнообразие на зелено покритие и сенки. Благодарение на своята устойчивост към вариации в осветеността и спектрални смущения, той осигурява стабилни резултати при разграничаването на растителност от урбанизирани и почвени повърхности. ML показва най-висока обща точност и надеждност при ясно дефинирани и хомогенни класове, но е по-чувствителен към шум в обучителните данни. MD, макар и бърз, води до най-много погрешно класифицирани пиксели, особено между растителност и почва, което ограничава неговата приложимост в градски среди.

С оглед на спецификата на урбанизираната и спектрално нееднозначна среда на София, включваща сенки, малки зелени площи, разнообразни строителни материали и почвени повърхности, SAM се очерта като най-подходящият алгоритъм за класификация. Той предлага баланс между точност, устойчивост и възможност за ефективна картографска интерпретация на растителност в градска среда. Неговата независимост от статистически предположения и способността му да разграничава спектрално близки класове го правят предпочитан инструмент за пространствен анализ и мониторинг на зелената инфраструктура на София.

Класификация на земното покритие чрез алгоритъма SAM

SAM сравнява спектралния вектор на всеки пиксел с еталонните спектрални характеристики, изчислявайки ъгъла между тях. Колкото по-малък е ъгълът, толкова по-голямо е спектралното сходство.

Изходни данни:

Средни спектрални стойности, извлечени от обучителни полигони за основни класове, като:

зеленина, вода, застрояване, почва и т.н.

Предимства на SAM:

- Независим от осветеност и интензитет, защото използва насочеността на векторите, а не дължината им.
- Подходящ за мулти- и хиперспектрални изображения
- Висока тематична точност в урбанизирани територии

(11)

a – ъгъл между два спектъра в пространството на спектралните канали
(в радиани)

n – брой на спектралните канали (ленти)

T_i – стойност на отразената радиация в канал i от тествания (неизвестен) пиксел

R_i – стойност на отразената радиация в канал i от еталонна спектрална характеристика (Waqar, 2019)

$$a = \cos^{-1} \left[\frac{\sum_{i=1}^n (T_i \cdot R_i)}{\left(\sum_{i=1}^n T_i^2 \right)^{\frac{1}{2}} \cdot \left(\sum_{i=1}^n R_i^2 \right)^{\frac{1}{2}}} \right]$$

Изчислява се косинус от ъгъла между спектралните вектори на пиксела и на референтния клас. Ако ъгълът a е малък, пикселът е много близък по спектър до референтния клас и е по-вероятно да принадлежи към него.

След избора на класификацията на земното покритие чрез алгоритъма SAM, основният анализ е извършен върху сателитно изображение от 22 юли 2023 г. (Фигура 12). Същата методика е последователно приложена и върху другите изображения от 2016 г. до 2022 г., което позволява провеждането на съпоставим многогодишен анализ и проследяване на промените в зелената система на територията на град София.

Пространствена маска чрез CLC

Прилагането на CLC маска, базирана на последните данни от проекта CORINE Land Cover за България (Dimitrov et al., 2019), подобрява тематичната точност чрез филтриране на индустриални, транспортни и други нерелевантни зони.

За повишаване на точността при пространствения анализ и за елиминиране на нефункционални зони, които не са от интерес за изследването, се прилага пространствено филтриране чрез маска, базирана на данни от CLC– ниво 3 от класификационната система на Европейската агенция по околна среда (Dimitrov et al., 2019). Това позволява да се изолират само онези територии, които представляват функционален интерес за анализа на UGS и нейната пространствена организация в рамките на строителната граница на София.

CLC класове използвани в изследването

Изборът на CLC класове се основава на предварително зададени изисквания за включване на градски зелени площи, спортни терени, селскостопански земи с природна растителност, горски територии, преходни храстови зони и изкуствени водоеми. В изследването са използвани следните класове за полигони: 111, 112, 141, 142, 211, 222, 231, 242, 243, 311, 312, 313, 324, 512 (Фигура 13). Класифицирането и последващото пространствено изрязване по тези полигони позволява анализът да се съсредоточи не просто върху зелени площи в град София, а върху функционално значими зони, които имат значение за екологичния и социалния баланс на урбанизираната територия на град София.

Кодове на класове:

- Урбанизирани и спортни територии:
 - 111 – Плътно застроени урбанизирани територии (Continuous urban fabric),
 - 112 – Разредени урбанизирани територии (Discontinuous urban fabric),
 - 141 – Урбанизирани зелени площи (Green urban areas),
 - 142 – Спортни и развлекателни съоръжения (Sport and leisure facilities).
- Селскостопански територии:
 - 211 – Неполивани земеделски площи (Non-irrigated arable land),
 - 222 – Плодови култури (Fruit trees and berry plantations),
 - 231 – Пасища (Pastures),
 - 242 – Комплексни земеделски модели (Complex cultivation patterns),
 - 243 – Мозаечна земеделска и природна растителност (Land principally occupied by agriculture with significant areas of natural vegetation).
- Горски и храстови територии:
 - 311 – Широколистни гори (Broad-leaved forest),
 - 312 – Иглолистни гори (Coniferous forest),
 - 313 – Смесени гори (Mixed forest),
 - 324 – Преходна храстова и тревиста растителност (Transitional woodland-shrub).
- Водни тела:
 - 512 – Изкуствени водни тела (Water bodies).

CLC класове изключени от изследването

Следните класове от CLC Level-3 са изключени от анализа поради липсата на пряка връзка със зелената градска среда: 121, 122, 124, 131, 132 и 243. Те представят предимно антропогенни, индустриални или извънградски територии и са премахнати с цел изолиране на функционално значимите урбанизирани зелени площи.

- 121 – Индустриални и търговски обекти (*Industrial or commercial units*).
- 122 – Пътна и железопътна инфраструктура (*Road and rail networks and associated land*).
- 124 – Летища (*Airports*).
- 131 – Добивни терени / кариери (*Mineral extraction sites*).
- 132 – Сметища (*Dump sites*).
- 243 – Земеделски земи с участъци от естествена растителност (*Agricultural land with natural vegetation mosaics*).

Филтрирането с маска по използваните CLC класове позволява систематично изключване на територии, които не отговарят на целите на анализа, като индустриални зони, големи транспортни възли и открити площи без растителност, добивни терени, сметища, земеделски земи. То осигурява съгласуваност между извършената класификация и административните и териториални структури, прилагани в градското планиране. В допълнение, категоризацията позволява сравнение между различни периоди, ако се приложи върху времева серия от сателитни изображения, както е направено в настоящата работа, като по този начин се разкрива динамиката в развитието на зелената инфраструктура на града.

След като класификацията на изображението е извършена чрез избрания алгоритъм SAM, се пристъпва към пространствено изрязване на резултатите с помощта на предварително подготвената CLC векторна маска. Процесът включва няколко ключови етапа, които гарантират, че ще бъдат запазени само релевантните за изследването пиксели. Този процес не само ограничава обхвата на анализа до съществените територии, но също така значително намалява изчислителната тежест при последваща обработка и визуализация на резултатите.

Отстраняване на нерелевантни зони

За да се изключат територии без функционална връзка с предмета на изследване, се прилага процедура по отстраняване на зони извън предварително дефинирания интерес. Това включва идентифициране и изолиране само на онези пространствени единици, които отговарят на определени класове земно покритие, съответстващи на урбанизирани или зелени площи. След това се създава специално ограничение, което елиминира всички останали класове. В резултат се запазват единствено релевантните пиксели, свързани с територии от значение за екологичната, социалната и пространствената структура на столицата. Тази стъпка гарантира, че крайният анализ ще бъде фокусиран, точен и приложим към реалните нужди на градското планиране (Фигура 14).

Изчисляване на площите на изследваните класове земно покритие

След прилагане на класификацията и маската, площите са изчислени на база брой пиксели в изображението с помощта на процедура изпълнена в среда на QGIS. След като бе приложена пространствената маска на база избраните CLC класове класификацията по SAM позволи прецизно разграничаване на четирите основни класа земно покритие в рамките на строителната граница на гр. София: зелнина, застрояване, почва и вода. Класификацията е резултат от внимателен подбор и обучение върху референтни полигони, равномерно разпределени между четирите целеви класа, с цел гарантиране на висока степен на точност.

С цел получаване на количествени резултати, класифицираното растерно изображение бе анализирано на база брой пиксели, като всеки пиксел бе асоцииран към един от четирите класа. Този метод осигурява висока точност и възпроизводимост на резултатите, особено при анализ на хомогенни терени с добре изразени спектрални характеристики близки до еталонните.

Получените след класификация растерни изображения имат пространствена ПРС от 10 m, което означава, че всеки отделен пиксел отговаря на площ от 100 m². Общата площ включена в даден клас е изчислена чрез следната формула:

$$(12) \quad \text{Площ (km}^2\text{)} = \text{Брой пиксели} \times 100 \text{ m}^2 / 1,000,000$$

И така, за избраното изображение от 2023 г. получихме стойности (Таблица 10) за площите на земното покритие в рамките на строителната граница, което служи като основа за пространствен анализ и оценка на промените в зелената система. Резултатите показват, че общо класифицирана площ заета от четирите класа е 167.05 km², а неклсифицираната площ е 22.95 km².

Таблица 10 Размери на площите за всеки един от изследваните класове за 22.07.2023 г.

Клас	Брой пиксели	Площ (km ²)
Застрояване	893 392	89.34
Зеленина	702 152	70.22
Почва	74 121	7.41
Вода	799	0.08

След това същият метод беше последователно приложен към другите сателитни сцени от Sentinel-2, за да се извърши съпоставим многогодишен анализ. Използваните сцени за времеви анализа са от следните дати – 31.07.2016 г., 23.07.2017 г., 07.08.2018 г., 23.07.2019 г., 11.08.2020 г., 17.07.2021 г., 22.07.2022 г., 22.07.2023 г.

Резултатите за всяка година са получени по идентичен начин съгласно създадената методика за класификация, включваща строителната граница на гр. София, прилагане на CLC базирана маска и класификация чрез избрания алгоритъм SAM. Това осигурява съпоставимост между отделните времеви моменти и възможност за проследяване на тенденции в промените на земното покритие и състоянието на зелената градска инфраструктура.

Описание на алгоритъма на работа

- Подбор и изтегляне на данни (Data Acquisition):
 - Използвани са Sentinel-2 изображения (Level-2A, BOA),
 - Подбран е периодът юли – август (максимална вегетация).
- Предварителна обработка (Preprocessing):
 - Филтрирани са сцени с облачност под 10%.
- Изрязване по СГ (Spatial restriction):
 - Обхватът е ограничен до строителната граница на София (GUDP),
 - Прилага се пространствена маска за фокус върху урбанизираната територия.
- Класификация (Classification):
 - Използван е алгоритъмът SAM (Spectral Angle Mapper),
 - Дефинирани са обучителни полигони,
 - Изчислени са спектрални характеристики,
 - Извършена е класификация по 4 класа: зеленина, застрояване, почва, вода.
- Валидация (Validation):
 - Маскирани са индустриални и нерелевантни зони чрез CLC 2018.
- Количествен анализ (Quantitative Analysis):
 - Пикселите са преобразувани в площ (km²) чрез QGIS,
 - Изчислено е разпределението на класовете.
- Резултати и визуализация (Results & Visualization):

- Представени са карти с наложена класификация,
- Данните са обобщени в таблици с площи по класове (в km²),
- Оценена е точност с Карра коефициент (89%).

Софтуерна среда и инструменти

- Sentinel Hub
- QGIS (версия 3.34)
- Open Street Map
- CORINE Land Cover

ГЛАВА 3

РЕЗУЛТАТИ И АНАЛИЗ НА РЕЗУЛТАТИТЕ ОТ ИЗСЛЕДВАНЕТО

Представяне на класификационните резултати по години

Районът на изследване е ограничен в рамките на официалната строителна граница на град София, с обща площ приблизително 190 km², определена съгласно Общия устройствен план (ОУП, 2019). Класификацията на земното покритие е извършена чрез алгоритъма SAM, избран поради неговата устойчивост спрямо вариации в осветеността, способността му да обработва мултиспектрални данни и високата точност при разграничаване на класове със сходни отражателни характеристики. Преди процеса на класификация е приложена пространствена маска, базирана на селектирани класове от CLC, с цел елиминиране на нерелевантни територии като индустриални зони, транспортни коридори и други.

Класификацията на земното покритие е сведено до четири основни класа: зеленина, застрояване, почва и водни повърхности. За всеки от тези класове са изчислени площите заети от тях. Анализираният период от 2016 до 2023 г. обхваща едни от най-интензивните години на трансформация на градската среда, които са белязани от динамично застрояване, мащабни инфраструктурни проекти, въздействия на климата в рамките на град София.

Всеки пиксел от сателитно изображение с ПРС 10 m представлява реална площ от 100 m², което се равнява на 0.0001 km². Тази връзка между броя на пикселите и съответстващата им площ позволява прецизно изчисление на размера на всеки клас земно покритие, идентифициран чрез класификация. По този начин могат да се оценят и сравняват пространствените характеристики на урбанизираната среда за различни години.

Преобразуването от пиксели към реална площ създава възможност за извършване на пространствено-времеви анализ на промени в територията. То улеснява моделирането на градското разрастване, идентифицирането на зони с интензивна трансформация и планирането на зелени коридори. На базата на тези данни могат да бъдат изготвени обобщени карти, диаграми, пространствени индекси и анализи, които разкриват закономерности, свързани със загуба на зелени площи, стабилност на размера на водните площи, промени в земеползването и натиск от застрояване.

Разбирането за съотношението между пикселна и реална площ е от съществено значение за точността и достоверността на дистанционно извършвания мониторинг. Дори минимални грешки в класификационния процес могат да доведат до значителни изкривявания в интерпретацията на промените. Ето защо това е критично при интегрирането на получените резултати в инструментите за градско планиране, управление на природни ресурси и екологичен контрол.

Използването на формула (12) позволява точно преобразуване на броя пиксели, класифицирани в отделните категории земно покритие, в реална площ. Това е изключително полезно за всички изследвания, които целят да проследят динамиката на териториални промени през времето. Чрез нея не само могат да се извършват сравнения за площите между различни времеви интервали, но и да се правят пространствени прогнози, базирани на мултиспектрални данни, получени от спътникови изображения.

Същата формула е приложима за всеки от класовете земно покритие: зеленина, застрояване, почва и вода, като така се изгражда детайлна картина на териториалното разпределение във времето. Допълнително, на база на тази формула могат да се генерират междинни изчисления за промяна в km^2 между последователни години, което подпомага количественото оценяване на динамиката.

Тези резултати се използват за създаване както на абсолютни таблици (в милиони пиксели), така и на преизчислени стойности в km^2 , с цел по-точно и съпоставимо представяне на пространствената динамика на земното покритие в рамките на строителната граница на град София. Показаните по долу таблици и картосхеми представят резултатите от преброяване на пиксели за основните класове земно покритие за периода 2016–2023 г. Данните показват ясно разграничение между застроени територии, зелени площи, почва и водни обекти.

Времеви геопространствен анализ на градската среда в град София - картографско сравнение на извадки от различни градски области (2016–2023 г.)

Приложението на предложената методика върху поредица от мултиспектрални изображения от мисията Sentinel-2 разкрива ясно изразени пространствено-времеви тенденции относно промени в земното покритие на територията на град София. Изследването е ограничено в рамките на строителната граница и осигурява съпоставимост с урбанистичните, регулаторните и административните рамки на развитие. Получените след класификацията на многоспектрални данни по разработената методика резултати нагледно показват значими трансформации в земното покритие на изследваните територии, които са свързани с урбанизационния натиск, довел до промени в UGS, както и динамиката на другите три класа. На фигури от 24 до 41 са показани картосхеми на резултатите от приложената класификация в избраните четири класа - зеленина, застрояване, почва, вода.

Анализ на резултатите и дискусия

Въз основа на получените резултати може да се отбележи, че наблюдаваните процеси на урбанизация довеждат до увеличаване площите на клас застрояване. През 2016 г. те

обхващат около 802 хил. пиксела ($\approx 80.2 \text{ km}^2$), като до 2023 г. достигат 893 хил. пиксела ($\approx 89.3 \text{ km}^2$), което представлява относително увеличение от над 11% в рамките на разглеждания период (Таблицы 19 и 20). Тази тенденция свидетелства за прогресивна трансформация на клас зеленина/почва в клас застрояване. Това се реализира както чрез разширяване на застрояването, така и чрез развитие на транспортна и инженерна инфраструктура, особено в периферните и преходните градски зони, където се наблюдава значителни трансформации в земеползването.

Отчитайки спецификите на клас зеленина, по получените резултати се наблюдават отчетливи промени, които се дължат на сезонни, климатични и човешки въздействия. Площите, заемани от този клас, през 2016 г. са около 691 хил. пиксела ($\approx 69.1 \text{ km}^2$), достигат максимална стойност от 813 хил. пиксела ($\approx 81.3 \text{ km}^2$) през 2018 г., след което значително намаляват до 642 хил. пиксела ($\approx 64.2 \text{ km}^2$) през 2021 г. До 2023 г. зеленината се стабилизира на ниво от около 702 хил. пиксела ($\approx 70.2 \text{ km}^2$). Тази динамика, показана в Таблицы 19 и 20, отразява както действителните промени в площите, заемани от клас зеленина, така и влиянието на фактори, свързани със сезонността в развитието на този клас, метеорологичните условия и фенологичната фаза на растителността, които могат да повлияят на крайните резултати от класификацията.

Клас почва се характеризира с най-голяма динамика, типична за градски зони, в които предстоят трансформации на класовете земно покритие. Площите, заемани от този клас, през 2016 г. е около 176 хил. пиксела ($\approx 17.6 \text{ km}^2$), като спада рязко до 52 хил. пиксела ($\approx 5.2 \text{ km}^2$) през 2018 г. и впоследствие отново нараства до 152 хил. пиксела ($\approx 15.2 \text{ km}^2$) през 2021 г. (Таблицы 19 и 20). Една вероятна причина за това нарастване през 2021 г. е пандемията от COVID-19. Тази нестабилност е характерна за площи, които биват трансформирани от клас зеленина към клас застрояване, за което е необходимо да се извърши разчистване на терените, изкопни работи или временна експозиция на почвата, което регистрираме като клас почва, преди окончателното им застрояване или озеленяване.

Според получените резултати площите от клас вода заемат относително стабилен дял от изследваната площ (под 0,1% през целия период). Площите, заемани от този клас, през 2016 г. е около 1166 пиксела ($\approx 0.12 \text{ km}^2$), като спада рязко до 713 пиксела ($\approx 0.07 \text{ km}^2$) през 2021 г. и впоследствие отново нараства до 799 пиксела ($\approx 0.08 \text{ km}^2$) през 2023 г. (Таблицы 19 и 20). За да бъде потвърден регистрирания през 2021 г. минимум на площите от този клас, е необходимо да се получи информация относно количествата валежи за сезон лято 2021 г., както и информация относно подхранването на всяка една водна площ.


Таблица 19: Основни количествени резултати (в пиксели)
за периода 2016–2023 г.

Година	Зеленина	Застрояване	Почва	Вода
2016	691 161	802 001	176 136	1 166
2017	662 465	919 748	87 357	894
2018	813 700	803 868	51 707	1 189
2019	721 464	840 800	107 165	1 035
2020	721 602	860 539	87 161	1 162
2021	642 164	875 324	152 263	713
2022	743 988	821 867	103 666	943
2023	702 152	893 392	74 121	799

Таблица 20: Обобщена таблица – Площ по класове в km²
за периода 2016–2023 г.

Година	Застрояване (km ²)	Зеленина (km ²)	Почва (km ²)	Вода (km ²)
2016	80.20	69.12	17.61	0.12
2017	91.97	66.25	8.74	0.09
2018	80.39	81.37	5.17	0.12
2019	84.08	72.15	10.72	0.10
2020	86.05	72.16	8.72	0.12
2021	87.53	64.22	15.23	0.07
2022	82.19	74.40	10.37	0.09
2023	89.34	70.22	7.41	0.08

В допълнение към показаните в Таблицы 19 и 20 резултати от класификацията на земното покритие, на Фигура 41 е показана в графичен вид динамиката на изследваните класове земно покритие.




Фиг. 41. Динамика на земното покритие: 2016 – 2023 г.

Един по-подробен пример за пространственото разпределение на земното покритие за 2023 г. е представен в следващите параграфи.

На Фигура 42 е показана графика на разпределението на изследваните класове, като тяхното процентно съотношение е както следва:

клас застрояване – 47.0%
 клас зеленина – 37.0%
 клас почва – 3.9%
 клас вода – 0.04%
 неклассифицирани – 12.1%



Фиг. 42. Разпределение на класовете земно покритие в строителната граница на София 2023 г.

Дискусия

Данните потвърждават тенденция към нарастващо застрояване за сметка на естественото покритие, особено на зелени и открити почвени площи. Колебанията подчертават необходимостта от дългосрочен мониторинг и интегрирани политики за опазване и поддържане на градската растителност, особено с оглед на нейната роля за градската среда.

Относително постоянният дял на водните площи подчертава ефективността на метода SAM, като същевременно потвърждава, че основните трансформации в земното покритие са концентрирани в останалите класове, особено в класовете застрояване, зеленина и почва.

Трансформацията в клас почва е възможно да се приеме като показател за бъдещо застрояване. Когато този клас нараства, това обикновено означава, че зелени площи са били разчистени и подготвени за строителство, но все още не са застроени. Такива терени често преминават от зеленина към застрояване, като за кратко време се класифицират като почва. Затова увеличението на класа почва е ранен признак за предстоящо урбанизиране на дадена зона от града.

Изследването е изцяло базирано на свободно достъпни ресурси, които включват мултиспектрални сателитни изображения от мисията Sentinel-2 Level-2A (34TFN), геоинформационен софтуер с отворен код QGIS и спомагателни инструменти за обработка и представяне на данни. Референтната тематична база CLC допълва използваната методика, като осигурява и стандартизирана основа за филтриране на нерелевантни зони, както и подпомагане на тематичната интерпретация при анализа на резултатите.

Използването на напълно отворени технологии елиминира зависимостта от комерсиални лицензионни модели и осигурява висока степен на достъпност, възпроизводимост и възможност за трансфер на методиката. Всеки компонент от методиката, от предварителната обработка на изображенията и класификацията чрез SAM до картографската визуализация и пространствения анализ, е интегриран в единна среда, гарантираща последователност и съвместимост.

Методичната рамка показва добра приложимост не само в сферата на научните изследвания, но и в процеса на мониторинг и стратегическо планиране от страна на административните органи. Тя може да се разглежда и като универсален инструмент за анализ на градската динамика в други урбанизирани територии в България и Европейския съюз.

Високата степен на интеграция между свободностъпни източници и професионално ориентирани инструменти не просто демонстрира икономическа ефективност, тя доказва, че напълно безплатна, но добре структурирана методика, може да постигне резултати, съпоставими с лицензирани информационни и софтуерни продукти. Така създадената методика е не просто инструмент за еднократен анализ, а модел за прилагане в процеса на устойчивото наблюдение и управление на урбанизирани територии, който може да бъде възпроизведен, както от научни институции, така и от национални и международни организации, без необходимост от скъпо струващ хардуер или софтуерни лицензи.

Предимства на използваната методика

- Икономическа ефективност. Използваната методика се базира на свободен достъп до висококачествени сателитни данни (Sentinel-2), използване на софтуерни решения с отворен код (QGIS) и прилагане на отворени алгоритми (SAM), което елиминира нуждата от лицензирани информационни и софтуерни продукти и води до минимизиране на преките разходи.
- Висока съпоставимост във времето. Тя се постига чрез използване на хомогенна времева серия от сателитни сцени с регулярна периодичност и атмосферна корекция, осигуряваща съпоставимост между различните години и надеждност при анализ на промените.
- Гъвкавост и възпроизводимост. Методиката може лесно да бъде приложена за други урбанизирани зони в различни географски, климатични или социално-икономически контекст, без да е необходимо съществено адаптиране на инструментите или алгоритмите.
- Съвместимост с европейски и международни стандарти. Тя се реализира чрез използване на пространствена маска от CLC като референтна система, резултатите от анализа са съвместими с политики и изисквания на ЕС в областта на околната среда и териториалното развитие.
- Пряка приложимост за стратегическо планиране и управление. Получените резултати са подходящи за включване в процеси на пространствено планиране, градска екология, мониторинг на зелени системи, устойчиво развитие и адаптация към климатичните промени на градовете.

Ограничения на изследването

Настоящото изследване, въпреки своята методична последователност, е и обект на някои ограничения:

- Спектрални ограничения на SAM. Алгоритъмът не отчита промените във всеки отделен клас, което може да доведе до неточности в класификацията на смесени пиксели в гранични или хетерогенни зони в градската среда.
- Пространствена разделителна способност. Данните от Sentinel-2 (10 m) не позволяват детайлно разграничаване на малки зелени обекти, а смесените пиксели, повлияни от осветеност и сезонност, затрудняват проследимостта във времето.

Перспективи за бъдещите изследвания

Въз основа на постигнатите резултати се очертават няколко основни направления за бъдещо развитие на изследването:

- Използване на данни с висока ПРС. Възможно е усъвършенстване на методиката чрез включване на изображения от сателитите WorldView-3, Pléiades Neo, PlanetScope и от безпилотни летателни системи с цел идентификация на малки по размер зелени обекти.

- Разширяване на тематичния обхват. Възможно е въвеждане и на други обекти за класификация в градската среда, като например синя инфраструктура, температурни данни, социално-икономически индикатори и замърсени зони.
- Автоматизация на анализа. Чрез използване на QGIS Python API и Google Earth Engine е възможно създаване на веб-базирани платформи за мониторинг с реално-времеви данни.
- Дълбоко обучение за класификация. Възможно е прилагане на други невронни мрежи за създаване на модели за по-висока точност при класификация в градски терени и намаляване на зависимостта от CLC.

4. ЗАКЛЮЧЕНИЕ


Изследването представя цялостна и научно обоснована методика за многогодишен мониторинг на зелената система в урбанизирана среда чрез прилагането на аерокосмически технологии, географски информационни системи и алгоритми за класификация, базирана на знания. Конкретното изследване на гр. София в периода 2016–2023 г. е използвано като пример за оценка на пространствената и времева динамика на градските зелени площи в условия на интензивна урбанизация и климатични предизвикателства.

Методиката, която включва използването на мултиспектрални изображения от Sentinel-2 (Level-2A), алгоритъма Spectral Angle Mapper, пространствени маски, базирани на CLC, и анализа в QGIS среда, демонстрира висока степен на надеждност, възпроизводимост и приложимост. Точността на класификацията, постигната чрез SAM, е особено ценна в хетерогенни урбанизирани среди, характеризиращи се със смесени спектрални класове и представляващи сериозно предизвикателство пред изследователите.


Резултатите от анализа разкриват отчетлива тенденция на намаляване на зелените площи и нарастване на застроените площи в рамките на изследвания период. Наблюдаваните изменения показват неравномерно разпределение на антропогенния натиск и подчертават нуждата от стратегически подходи за управление на зелената система в градска среда. Особено внимание следва да се обърне на крайградските зони, където рискът от загуба на зелени площи е най-висок. Получените резултати от разработената методика могат да бъдат използвани от държавни институции, отговорни за градоустройственото планиране, екологичния мониторинг и прилагането на политики за климатична адаптация.

Методиката е лесно приложима към други урбанизирани територии и би могла да послужи като основа за изграждане на системи за регулярна оценка на градската среда.


В заключение следва да се изтъкне, че изследването предлага солидни доказателства за значението на интегрирания подход между дистанционни технологии, GIS анализ и автоматизирана класификация като необходима основа за дългосрочно, устойчиво и научно обосновано управление на урбанизираните зелени пространства, и на други елементи от градската среда.




Фиг. 6. GeoTIFF изображение от 22.07.2023 г.



Фиг. 7. GeoTIFF изображение от 22.07.2023 г. ; СГ на София (червено);
АГ на Столична община (лилаво);




Фиг. 8. Карто схема на GeoTIFF изображение от 22.07.2023 г. изрязано по контура на СГ на гр.София




Фиг 9: Еталонни спектрални характеристики на обучителната съвкупност от данни


Застрояване (червен цвят) Зеленина (зелен цвят) Почва (жълт цвят) Вода (син цвят)




Фиг. 12. Илюстрация на характеристиките на изображението класифицирано по метода SAM



Фиг. 13. CLC класификация на земното покритие за София за избраните класове




Фиг. 14. Резултат от крайния анализ; Разпределение на класовете земно покритие в урбанизираната територия на град София през 2023 г.




Фиг. 15. Алгоритъм, реализиращ разработената методика за класификация на земното покритие за град София по СГ


Застрояване (червен цвят) Зеленина (зелен цвят) Почва (жълт цвят) Вода (син цвят)




Фиг. 16. Разпределение на класовете земно покритие в урбанизираната територия на град София през 2016 г.




Фиг. 17. Разпределение на класовете земно покритие в урбанизираната територия на София през 2017.02.017 г.




Фиг. 18. Разпределение на класовете земно покритие в урбанизираната територия на София през 2018 г.




Фиг. 19. Разпределение на класовете земно покритие в урбанизираната територия на София през 2019 г.



Фиг. 20. Разпределение на класовете земно покритие в урбанизираната територия на София през 2020 г.




Фиг. 21. Разпределение на класовете земно покритие в урбанизираната територия на София през 2021 г.




Фиг. 22. Разпределение на класовете земно покритие в урбанизираната територия на София през 2022 г.

**Времеви геопространствен анализ на градската среда в град София -
картографско сравнение на извадки от различни градски области (2016–2023 г.)**


На фигури от 24 до 41 са показани картосхеми на резултатите от приложената класификация в избраните четири класа - зеленина, застрояване, почва, вода.



Фиг. 23. 2016




Фиг. 24. 2023 г.




Φυγ. 25. 2016 ε.




Φυγ. 26. 2023 ε.




Φιγ. 37. 2016 ς.



Φιγ. 38. 2023 ς.



Φιγ. 39. 2016 ρ.



Φιγ. 40. 2023 ρ.

Приноси

1. Разработена е методика за времева оценка на градски зелени площи и земно покритие в урбанизирана среда базирана на алгоритъма Spectral Angle Mapper върху мултиспектрални изображения от Sentinel-2 за периода 2016–2023 г.
2. Извършено е пространствено филтриране посредством маска извлечена от CLC, което елиминира нерелевантните за изследването зони в строителната граница на град София (напр. индустриални, транспортни, сметища и др.) и също така повишава тематичната точност на последващия анализ на резултатите от класификацията.
3. Разработен е оперативен аналитичен протокол в QGIS, включващ класификация, статистическа обработка и визуализация, с пряко приложение в устойчивото градско планиране и мониторинга на градската среда.
4. Методиката е лесно възпроизводима и може да бъде приложена за всеки град в България и Европейския съюз, благодарение на използването на свободно достъпни данни от разнообразни източници и софтуерни продукти с отворен код.

Публикации по темата на Дисертацията

1. Гочев, Д., Узунова, Е., Стоев, И. (2021). Проблеми в управлението на риска от екологични бедствия. Proceeng and performance improvement. Proceedings of the Nineteenth Scientific Conference with International Participation “Space, Ecology, Safety – SES 2021” 329–331. ISSN 2603-3313.
2. Стоев, И., Узунова, Е. (2022). Използване на изкуствени невронни мрежи за откриване, разпознаване и анализ на различни обекти от спътникови изображения. Сборник доклади от Годишна университетска научна конференция, 3, 1591–1600. НБУ „Васил Левски“. ISSN 2367-7481.
3. Стоев, И., Узунова, Е. (2022). Използване на аерокосмическата информация за изследване на урбанизацията. Сборник доклади от Годишна университетска научна конференция, 7, 139–146. НБУ „Васил Левски“. ISSN 1314-1937.
4. Stoev, I., Uzunova, E. (2023). Knowledge transfer in artificial neural networks: State-of-the-art techniques for efficient learning and performance improvement. Proceedings of the Nineteenth Scientific Conference with International Participation “Space, Ecology, Safety – SES 2023” 260–265 ISSN 2603-3313.
5. Узунова, Е., Стоев, И., Мардироян, Г. (2024). Изследване на зелените площи в градската среда с използване на методи на машинно самообучение и географски информационни системи. Сборник доклади от международна научна конференция „Космос, Екология, Сигурност – SES 2024” 242–247. ISSN 2603-3313.

ЛИТЕРАТУРА

1. Ajuntament de Barcelona. (2023). *Pla de sostenibilitat urbana de Barcelona*. Barcelona City Council.
2. Bibri, S. E. (2018). *Smart sustainable cities of the future: The untapped potential of big data analytics and context-aware computing for advancing sustainability*. Springer. <https://doi.org/10.1007/978-3-319-73981-6>
3. Bowler, D. E., Buyung-Ali, L. M., Knight, T. M., & Pullin, A. S. (2010). Urban greening to cool towns and cities: A systematic review of the empirical evidence. *Landscape and Urban Planning*, 97(3), 147–155. <https://doi.org/10.1016/j.landurbplan.2010.05.006>
4. Bratman, G. N., Hamilton, J. P., & Daily, G. C. (2015). The impacts of nature experience on human cognitive function and mental health. *Annals of the New York Academy of Sciences*, 1249(1), 118–136. <https://doi.org/10.1111/nyas.12903>
5. Caragliu, A., & Del Bo, C. (2023). Smart cities and the urban digital divide. *Urban Sustainability*, 3, Article 43. <https://doi.org/10.1038/s42949-023-00117-w>
6. Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
7. Copenhagen Climate Plan. (2022). *CPH 2022 climate strategy*. City of Copenhagen.
8. Crompton, J. L. (2001). The impact of parks on property values: A review of the empirical evidence. *Journal of Leisure Research*, 33(1), 1–31. <https://doi.org/10.1080/00222216.2001.11949928>
9. Dimitrov, V., Koleva, R., Tepeliev, Y., Kroumova, Y., Lubenov, T., & Ilieva, N. (2019). Satellite Mapping of Bulgarian Land Cover – CORINE 2018 Project. *Forestry Ideas*, 25(2), 237–250.
10. European Space Agency. (2023). *Copernicus Open Access Hub*. Retrieved from <https://scihub.copernicus.eu>
11. Fuller, R. A., Irvine, K. N., Devine-Wright, P., Warren, P. H., & Gaston, K. J. (2007). Psychological benefits of greenspace increase with biodiversity. *Biology Letters*, 3(4), 390–394. <https://doi.org/10.1098/rsbl.2007.0149>
12. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. ISBN 978-0-262-03561-3
13. Google. (n.d.). *Google Earth Engine*. Retrieved from <https://earthengine.google.com>
14. Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
15. Jensen, J. R. (2016). *Introductory digital image processing: A remote sensing perspective* (4th ed.). Pearson. ISBN 978-013405816
16. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
17. Kruse, F. A., Lefkoff, A. B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J., & Goetz, A. F. H. (1993). The spectral image processing system (SIPS)—Interactive

- visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(2–3), 145–163. [https://doi.org/10.1016/0034-4257\(93\)90013-N](https://doi.org/10.1016/0034-4257(93)90013-N)
18. Nowak, D. J., Crane, D. E., & Stevens, J. C. (2006). Air pollution removal by urban trees and shrubs in the United States. *Urban Forestry & Urban Greening*, 4(3–4), 115–123. <https://doi.org/10.1016/j.ufug.2006.01.007>
 19. Richards, J. A. (2013). *Remote sensing digital image analysis: An introduction* (5th ed.). Springer-Verlag. <https://doi.org/10.1007/978-3-642-30062-2>
 20. Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson. ISBN: 978-0134610993
 21. Singapore Ministry of Sustainability. (2024). *Green plan 2030: Annual report*. Singapore Government.
 22. Sofiaplan. (2023). *Общ устройствен план на София*. Столична община. Retrieved from <https://sofiaplan.bg>
 23. Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
 24. United Nations. (2022). *World population prospects 2022: Summary of results*. United Nations, Department of Economic and Social Affairs.
 25. UN-Habitat. (2024). *World cities report 2024: Envisioning the future of cities*. UN-Habitat.
 26. Waqar, M. M. (2019). *Selected hyperspectral mapping method*. Presentation in the course "Special Topics in Remote Sensing & GIS," Institute of Space Technology, Pakistan. <https://www.slideshare.net/mirwaqar/spectral-angle-mapper-sam1>.
 27. Wikipedia. (2024a). *Борисова градина*. In *Wikipedia*. Retrieved January 20, 2024, from https://bg.wikipedia.org/wiki/Борисова_градина
 28. Wikipedia. (2024b). *Зелена система на София*. In *Wikipedia*. Retrieved January 20, 2024, from https://bg.wikipedia.org/wiki/Зелена_система_на_София
 29. World Cities Database. (2023). *Elevation of world capitals*. Retrieved from <https://simplemaps.com/data/world-cities>
 30. Визия за София. (2019). *Доклад за стратегическото развитие на Столична община до 2050 г.*. Столична община.
 31. Мардиросян, Г. (2015). *Основи на дистанционните аерокосмически технологии*. София: Нов български университет. ISBN 978-954-535-881-5
 32. Мардиросян, Г. (2022). *Въведение в космонавтиката*. София: Акад. издат. „Проф. Марин Дринов“. ISBN 978-619-245-350-3
 33. НАГ София. (2024). Архив на главния архитект на София – План Мусман. <https://nag.sofia.bg/Pages/Render/964>