

Българска академия на науките
Институт по математика и информатика

АВТОРЕФЕРАТ

на дисертационен труд
за присъждане на
образователната и научна степен "доктор"

в област на висше образование 4. Природни науки, математика и информатика
професионално направление 4.6. Информатика
докторска програма "Информатика"

**Адаптивна невронна мрежа
за обработка на сателитни данни
с различни пространствени и
спектрални характеристики**

Автор:

Венцислав Полименов

Научен ръководител:

доц. д-р Красимира Иванова

30 април 2026 г.

Венцислав Полименов

Адаптивна невронна мрежа за обработка на сателитни данни с различни пространствени и спектрални характеристики

Научен ръководител: доц. д-р Красимира Иванова

Област на висше образование 4. Природни науки, математика и информатика

Професионално направление 4.6. Информатика

Докторска програма "Информатика"

Дисертационният труд се състои от 138 страници, включващи 20 страници предварителни материали, увод и пет глави (стр. 1–108) и библиография (стр. 109–118). Предварителната част съдържа заглавна страница, благодарности, резюме, съдържание, списък на фигурите, списък на таблиците и списък на съкращенията. Текстът на дисертацията включва 25 таблици и 26 фигури. Списъкът с използвани литературни източници съдържа 127 заглавия.

Дисертационният труд беше обсъден и допуснат до защита по време на разширено заседание на секция "Софтуерни технологии и информационни системи" в Института по математика и информатика при Българска академия на науките, проведено на 24 април 2026 г.

Глава 1. Увод

1.1 Описание на проблема

Индексът на листната маса (Leaf Area Index – LAI), дефиниран като едностранната зелена листна площ на единица повърхност, е основен биофизичен параметър за количествено определяне на структурата, здравословното състояние и продуктивността на растителността [11]. Точната оценка на LAI е от решаващо значение за прецизното земеделие, като позволява наблюдение на развитието на културите, оптимизиране на напояването и торенето, откриване на растителен стрес и прогнозиране на добивите. Традиционните полеви измервания са трудоемки и пространствено ограничени [22], докато съществуващите сателитни подходи имат собствени предизвикателства: емпиричните вегетационни индекси (Vegetation Indices – VIs) се насищат при умерени до високи стойности на LAI, физически базираната инверсия на моделите за пренос на излъчване е изчислително натоварваща и изисква специфична за обекта калибрация [40], а най-критичното е, че текущите методи обработват всеки сензор поотделно, без да използват допълващата информация между платформите.

Съвременното наблюдение на Земята предоставя множество свободно достъпни източници на данни, от които се фокусираме върху Sentinel-2 (10 m, 10 канала, 5-дневен повторен цикъл на заснемане) и Landsat 8/9 (30 m, 6 канала, 8-дневен повторен цикъл), които заедно предлагат ефективен повторен цикъл от 2-3 дни. Интегрирането на тези сензори в единна рамка обаче поражда значителни технически усложнения: несъответствие на разделителната способност, различни спектрални конфигурации, неравен брой отрязъци, който може да причини *mode collapse* по време на обучение и осигуряване на последователни оценки на LAI независимо от входния сензор. Допълнително предизвикателство, често пренебрегвано в изследванията с дълбоко самообучение, е пространственото изтичане на данни при валидацията – земеделските ландшафти показват силна пространствена автокорелация и случайните разделения на обучаващ и тестов набор завишават оценките на производителността, поставяйки корелирани пиксели и в двата набора [18]. Дълбокото самообучение предлага потенциален пробив, тъй като конволюционните невронни мрежи могат да научат сложни спектрално-пространствени зависимости на LAI директно от данните, но това въвежда фундаменталното предизвикателство за получаване на пространствено плътни етикети за обучение, тъй като полево измерен LAI не е наличен в необходимия мащаб..

Настоящата дисертация адресира тези предизвикателства чрез разработване на мулти-сензорна рамка за дълбоко самообучение за оперативна оценка на LAI. Подходът комбинира U-Net архитектура с Conditional Batch Normalisation и Atrous Spatial Pyramid Pooling (ASPP), заедно с нови стратегии за обучение – включително

балансиране на обучителните партии и VI-ensemble псевдо-етикети – за преодоляване на липсата на полево измерени референтни данни, постигане на устойчиво обобщаване между сензори и демонстриране на висока точност при картографиране на LAI в земеделието чрез изображения от Sentinel-2 и Landsat 8/9.

1.2 Цели и задачи

Основната цел е да се разработи и оцени адаптивна невронна мрежа, способна да обработва сателитни изображения от множество източници с различни пространствени и спектрални разделителни способности. Основното приложение е оценката на Leaf Area Index, с потенциално разширяване към други биофизични свойства.

За постигането на тази цел трябва да се решат следните задачи:

1. **Предварителна обработка на данните:** Събиране и предварителна обработка на изображения от Sentinel-2 и Landsat 8/9 от предварително коригирани продукти за повърхностна отразителност, с последователно разделяне на отрязъци между сензорите за провеждане на систематични сравнителни експерименти.
2. **Проектиране на архитектурата:** Реализиране на мулти-сензорна CNN, която обработва мултиспектрални данни с различна разделителна способност в единна рамка, включваща Conditional Batch Normalisation за специфична за сензора адаптация на признаците, като същевременно поддържа споделени растителни представяния.
3. **Генериране на псевдо-етикети:** Обучение на модела с използване на пространствено плътни LAI етикети, генерирани чрез ансамблов подход на вегетационни индекси, за намаляване на индивидуалните отклонения при запазване на последователност, независима от сензора.
4. **Балансиране на обучителните партии:** Изследване и разрешаване на дисбаланса в експозицията на сензорите на ниво епоха (съотношение близо 4:1 между отрязъците на Landsat 8/9 и Sentinel-2) чрез диференцирана аугментация при семплирането за предотвратяване на mode collapse.
5. **Пространствена валидация:** Прилагане на пространствена блокова кръстосана валидация с използване на 4×4 географска мрежа за налагане на строго разделение между обучаващ и тестов набор, предотвратяващо пространствено изтичане на данни.
6. **Тестване на обобщаването:** Валидиране на трансфер между региони (от Пловдив до Бургас, 200 km) и времева стабилност (8-месечен интервал, септември 2023 до май 2024) без повторно обучение.
7. **Сравнителен анализ:** Количествено определяне на добавената стойност на CNN спрямо съставните вегетационни индекси и сравнение с ESA SNAP Biophysical Processor.

8. **Възпроизводимост:** Документиране на пълния работен процес, архитектурата и методологията за оценка с цел осигуряване на прозрачност и възпроизводимост.

1.3 Хипотези

Три основни хипотези ръководят експерименталния дизайн:

1. Спектрално осведомена CNN може да обобщава между сензори поне толкова ефективно, колкото специфични за сензора модели, което предполага, че научаването на инвариантни спрямо сензора LAI признаци може да подобри производителността в сравнение със специфични за сензора представяния.
2. Пространствената разделителна способност влияе нелинейно върху точността на прогнозиране на LAI, като зависимостта се определя от пространствения мащаб на земеделските обекти и силата на ландшафтната автокорелация.
3. Модел, обучен в един земеделски регион, може да обобщава към географски и времево различни региони без повторно обучение, при условие че прогнозите са изразени в абсолютни физически единици – влошаването при трансфер между региони произтича предимно от кодирането на разпределителните статистики на обучаващия регион в изходното представяне, а не от архитектурни ограничения.

1.4 Структура на дисертацията

Глава 2: Изследователски контекст прави преглед на сателитното дистанционно наблюдение за оценка на LAI, от традиционните вегетационни индекси през моделите за пренос на излъчване до дълбокото самообучение, позиционирайки настоящата работа в контекста на мулти-сензорния синтез на данни и извличането на биофизични параметри.

Глава 3: Методология описва подробно пълния работен процес за мулти-сензорна оценка на LAI: генериране на референтни данни чрез VI-ensemble, зареждане и разделяне на данните на отрязъци в оригинална разделителна способност, филтриране по качество, пространствено блоково разделяне, аугментация и нормализация, архитектурата Multi-Sensor U-Net с ASPP и Conditional Batch Normalisation, стратегия за обучение с балансиране на обучителните партии, метрики за оценка и петстепенна рамка за валидация.

Глава 4: Експерименти и резултати представя пространствено строга валидация на базови модели за единичен сензор и мулти-сензорна интеграция, трансфер между региони към Бургас, времева валидация за 8-месечен интервал, сравнение с ESA SNAP и 77% подобрене на RMSE спрямо най-добрия индивидуален VI.

Глава 5: Заключение и бъдещи насоки синтезира приносите, обсъжда прозрачното ограничението на кръговите референтни данни и предлага направления за бъдещи изследвания, включително валидиране с наземни данни, разширяване на PROSAIL

до Landsat и фина настройка за сцени от WorldView-3.

Глава 2. Изследователски контекст

2.1 Литературен обзор

Централен практически фокус на настоящото изследване е Leaf Area Index (LAI), ключов биофизичен параметър, характеризиращ структурата на растителната покривка и свързан с фотосинтезата, дишането и транспирацията [1]. LAI традиционно се оценява чрез трудоемко полево семплиране или чрез вегетационни индекси като NDVI и EVI, които предлагат емпирични корелации с характеристиките на покривката, но страдат от насищане при умерени до високи стойности на LAI и изискват специфична за сензора калибрация [16]. Нарастващата достъпност на високорезолюционни мултиспектрални изображения от сателити, в комбинация с техники за машинно самообучение, е позволила по-машабируема и точна оценка на LAI, която преодолява тези ограничения [15, 42]. Настоящата работа надгражда тези разработки чрез реализиране на мулти-сензорен модел на невронна мрежа за оценка на LAI от изображения на Sentinel-2 и Landsat 8/9, допринасяйки към по-широкото усилие за разработване на надеждни, недеструктивни методи за мониторинг на растителността и прецизно земеделие.

2.2 Сателитни изображения и тяхното приложение за наблюдение на Земята

Мисиите за дистанционно наблюдение предоставят мултиспектрални изображения, улавящи спектрални сигнатури, които представят различни характеристики на земното покритие в електромагнитния спектър. Нарастването на мисиите с отворен достъп значително разшири достъпността на сателитните изображения за наблюдение на Земята. Тази секция представя сензорните платформи, спектралните свойства и биофизичните променливи, релевантни за настоящата дисертация.

Типове изображения и резолюция

Сателитните изображения попадат в три основни категории [45]: 1) Панхроматични (PAN) изображения записват един широк канал с висока пространствена резолюция. 2) Мултиспектрални (MS) изображения записват множество дискретни канали – типично в областта на видимия спектър, NIR и SWIR – използвайки отличителни спектрални сигнатури за мониторинг на растителността и класификация на земното покритие. 3) Хиперспектрални (HS) изображения улавят стотици непрекъснати тесни канали, предоставяйки детайлни спектрални сигнатури за сметка на големи обеми данни. Ефективността на сателитните данни зависи и от пространствената резолюция (площ на земната повърхност на пиксел), спектралната резолюция (ширина на улавяните сигнали) и радиометричната резолюция (битова дълбочина за разграничаване на

енергийни нива).

Сензорен ландшафт

Разнообразието в пространствените, времевите и спектралните характеристики между платформите (Таблица 2.1) усложнява приложението на дълбокото самообучение в дистанционните изследвания, изисквайки модели, способни да обработват хетерогенни резолюции и качество на данните [44].

Таблица 2.1: Пространствена и времева резолюция и спектрални разлики между сателитните платформи.

Сателит	Простр. рез. PAN (m)	Простр. рез. MS (m)	Спектр. каналы (#)	Времева рез. (дни)	Радиом. рез. (бита)	Ширина обхват (km)	Дълж. вълна (nm)
GeoEye-1	0.41	1.65	4	1-3	11	15.2	450-800
IKONOS	0.82	3.2	4	1-3	11	11.3	445-853
KOMPSAT-3	0.7	2.8	5	1	14	15	450-900
Landsat 8	15	30	11	16	16	185	433-12500
Pleiades 1A, 1B	0.5	2	5	1-2	12	20	430-950
QuickBird	0.65	2.62	4	1-3.5	11	16.5	450-900
Sentinel-2	10	20	13	5	12	290	442-2186
WorldView-2	0.46	1.84	8	1.1	11	16.4	400-1040
WorldView-3	0.31	1.24	28	1	11	13.1	397-2373

(източник: [34, 45])

Въпреки че рамката, разработена в настоящата дисертация, не е ограничена до конкретна двойка сензори, тази работа се фокусира върху Sentinel-2 и Landsat 8/9 като двете основни свободно достъпни мисии със средна резолюция, глобално покритие и оперативна непрекъснатост.


Sentinel-2

Sentinel-2, част от програмата Copernicus, събира мултиспектрални изображения в 13 канала – четири при 10 m (видим спектър и NIR), шест при 20 m (red-edge, SWIR и допълнителен NIR) и три при 60 m (аерозоли, водни пари и цируси). Каналите в red-edge областта при 20 m осигуряват повишена чувствителност към съдържанието на хлорофил и структурата на растителността. Констелацията от Sentinel-2A (2015) и Sentinel-2B (2017) постига комбиниран петдневен повторен цикъл.

Landsat 8/9

Landsat 8, оперативен от 2013 г., е оборудван със сензорите OLI и TIRS с 11 канала при 30 m (VNIR/SWIR) и 15 m (панхроматичен), 16-битова радиометрична резолюция и 185 km обхват в 16-дневна слънчево-синхронна орбита [31]. Landsat 9 (2021) има подобрени сензори OLI-2 и TIRS-2. Заедно двата сателита намаляват повторния цикъл до 8 дни [32].

Както е показано на Фигура 2.1, спектралните канали на Sentinel-2 и Landsat 8/9 се припокриват значително в областите на видимото, NIR и SWIR, докато Sentinel-2 предоставя допълнително покритие в red-edge областта. Тази комплементарност мотивира мулти-сензорния подход за синтез, възприет в настоящата дисертация.



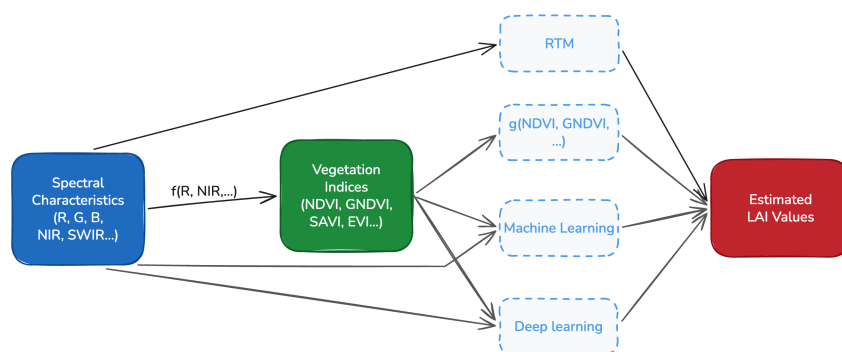
Фигура 2.1: Сравнение на спектралния отклик на Sentinel-2 и Landsat 8/9.

Вегетационни индекси

Вегетационните индекси (VI) комбинират данни от множество канали в единични стойности, които подчертават контраста между растителността и другите повърхности [12, 30]. За оценка на LAI индексите, включващи NIR и red-edge канали, улавят структурата на покривката по-точно от индексите, базирани само на видимата област. В тази работа са използвани три индекса, избрани заради тяхната сензорна агностичност (изчислени от канали, общи за Sentinel-2 и Landsat 8/9) и допълваща чувствителност: **NDVI** [30] улавя общата жизненост на растителността чрез контраста между NIR и червената отражателност ($NDVI = (\rho_{NIR} - \rho_{Red}) / (\rho_{NIR} + \rho_{Red})$), но се насища при $LAI \approx 3-4$. **GNDVI** [14] заменя червения канал със зеления, осигурявайки по-голяма чувствителност към концентрацията на хлорофил с по-късна точка на насищане ($LAI \approx 4-5$). **SAVI** [17] въвежда корекционен фактор за яркостта на почвата L , смекчаващ влиянието на почвения фон при редки покривки ($SAVI = (\rho_{NIR} - \rho_{Red})(1 + L) / (\rho_{NIR} + \rho_{Red} + L)$, $L = 0.5$).

2.3 Дистанционни изследвания за оценка на LAI – еволюция на методите

Оценката на LAI от сателитни изображения е преминала през няколко методологични поколения (Фигура 2.2), като всяко адресира ограниченията на предшественика си.



Фигура 2.2: Схематичен преглед на методите за извличане на Leaf Area Index (LAI) от спектрални измервания на отразителност.

Физически базирана инверсия на радиативен трансфер

Радиативните трансферни модели (RTM) като PROSAIL симулират отразителността на покривката като права функция на биофизичните параметри и геометрията на наблюдение [21]. Оценката на LAI тогава става обратна задача, а именно намиране на набора от параметри, който минимизира разминаването между моделираната и наблюдаваната отразителност [40]. Тази обратна задача обаче е зле поставена, тъй като множество комбинации от параметри могат да произведат почти идентични спектри. Това налага използването на силни предварителни ограничения или методи за ансамблово семплиране, които са изчислително непрактични за оперативна обработка. Точността допълнително зависи от правилното определяне на параметрите за структурата на покривката, които варират пространствено и рядко са известни *a priori*.

Вегетационни индекси

Вместо да инвертират пълен физически модел, вегетационните индекси (VI) използват известния спектрален отклик на зелената растителност чрез алгебрични комбинации на каналите за отразителност.

VI изпълняват двойна роля. Първо, като биофизични заместители, калибрирани трансферни функции (типично експоненциални, основани на закона на Beer–Lambert) преобразуват стойностите на индекса директно в оценки на LAI, напр. $LAI = -\frac{1}{k} \ln(1 - f(VI))$ [6]. Второ, като конструирани признаци за последващи статистически модели и модели за машинно самообучение. Въпреки полезността си, всички емпирични индекси споделят фундаментални ограничения: насищане при умерени до високи стойности на LAI, изисквания за специфична за сензора калибрация и невъзможност да представят сложни нелинейни спектрално-LAI зависимости в разнообразни ландшафти [18].

Статистическа регресия и регресия чрез машинно самообучение

Методите за машинно самообучение заобикалят експлицитното физическо моделиране, научавайки емпирични съответствия от спектрални признаци към LAI чрез

обучение с надзор [41]. Модели като Random Forests, Support Vector Regression и Gaussian процеси подобряват калибрацията с единичен индекс, комбинирайки информация от множество индекси и спектрални канали едновременно, частично преодолявайки индивидуалните ограничения на насищане. Тези методи обаче все още разчитат на ръчно конструирани признаци и обработват всеки пиксел независимо, без да използват пространствената структура, присъща в мултиспектралните изображения.

Дълбоко самообучение – пълно спектрално-пространствено картографиране

Дълбоките конволюционни невронни мрежи представляват фундаментална промяна – вместо да разчитат на ръчно конструирани вегетационни индекси, CNN-мрежите научават йерархични представяния на признаците директно от суровите спектрални канали чрез оптимизация [23, 47]. За оценка на LAI CNN предлагат научаване на сложни нелинейни спектрално-пространствени зависимости без насищане, използване на пространствен контекст в множество мащаби, оптимизация от край до край без междинно конструиране на признаци и потенциал за трансферно обучение между сензори и региони [43]. Критичната точка е изискването за пространствено плътни обучителни етикети, което настоящата дисертация адресира чрез ансамблов подход на вегетационни индекси, генериращ псевдо-етикети за обучение с надзор (Секция 3.1).

2.4 Архитектури за дълбоко самообучение за плътна оценка на LAI

Плътната оценка на биофизични параметри от сателитни изображения представлява задача за семантична сегментация – присвояване на непрекъсната LAI стойност на всеки пиксел. Тази секция прави преглед на архитектурните компоненти, използвани в настоящата дисертация.

U-Net: Encoder-Decoder архитектура

Архитектурата U-Net [35] използва encoder, който прогресивно намалява резолюцията чрез конволюционни слоеве и pooling, улавяйки все по-абстрактни признаци, както и симетричен decoder, който възстановява пространствената резолюция чрез транспонирани конволюции. Иновацията при тази архитектура са skip connections – директно конкатениране на признаците от encoder и decoder при съвпадащи резолюции, което повторно въвежда фините пространствени детайли, загубени при намаляване на резолюцията, предоставя алтернативни пътища за градиента, смекчаващи изчезващите градиенти и синтезира груба семантична информация с фини пространствени детайли на всяко ниво на резолюция.

Тези свойства се съгласуват добре с оценката на LAI от сателитни данни. Земеделският LAI проявява структура в множество мащаби, от редове на културите през зони на ниво поле до ландшафтни градиенти; encoder-ът улавя тази йерархия, докато skip connections запазват фините детайли. Напълно конволюционният дизайн обработва

изображения с произволен размер, позволявайки обучение върху малки отрязъци с извеждане върху пълни сцени [24]. Варианти на U-Net са широко възприети в дистанционните изследвания – разпознаване на пътища [46], детекция на сгради [19], класификация на култури [36], детекция на промени [7], моделиране на височината на покривката [24] и оценка на биомаса [37]. Специално за LAI, U-Net е демонстрирал 30-50% подобрения на RMSE спрямо VI базови линии [33, 43], въпреки че повечето предишни работи се фокусират върху сценарии с единичен сензор.

Разширени конволюции и ASPP

Разширяването на рецептивното поле е от решаващо значение за улавяне на контекст в голям мащаб. Разширените (dilated/atrous) конволюции [5] вмъкват $(r-1)$ нули между теглата на ядрото:

$$y[i] = \sum_k w[k] \cdot x[i + r \cdot k] \quad (2.1)$$

Ядро 3×3 с коефициент на разширяване $r=2$ покрива област 5×5 само с 9 параметъра, запазвайки пространствената резолюция, докато ефективно разширява контекста. Atrous Spatial Pyramid Pooling (ASPP) [5] прилага множество разширени конволюции паралелно с различни коефициенти (напр. $r \in \{1, 6, 12, 18\}$), конкатенира изходите и ги синтезира чрез 1×1 конволюция, опционално включвайки global average pooling за контекст на ниво изображение. Интегриран в bottleneck-a на U-Net, ASPP позволява едновременно разсъждение в мащаби на субполе, поле и ландшафт [9].

Batch Normalisation

Batch Normalisation (BN) [20] нормализира активациите на слоевете до нулева средна стойност и единична дисперсия в рамките на всяка мини-партида:

$$\text{BN}(x) = \gamma \frac{x - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \quad (2.2)$$

където γ, β са обучаеми параметри за мащаб и отместване. BN предотвратява експлозията на градиента, позволява по-високи нива на обучение и осигурява имплицитна регуляризация [20].

Conditional Batch Normalisation за мулти-сензорно обучение

При мулти-сензорни настройки стандартният BN изчислява статистики по всички проби, налагайки компромисно представяне, което осреднява специфичните за сензора разпределителни разлики [10]. Conditional BN [8, 10] адресира това чрез извличане по сензорна идентичност, научавайки специфични за сензора параметри $(\gamma^{(s)}, \beta^{(s)})$:

$$\text{CondBN}(x, s) = \gamma^{(s)} \frac{x - \mu_{B_s}}{\sqrt{\sigma_{B_s}^2 + \epsilon}} + \beta^{(s)} \quad (2.3)$$

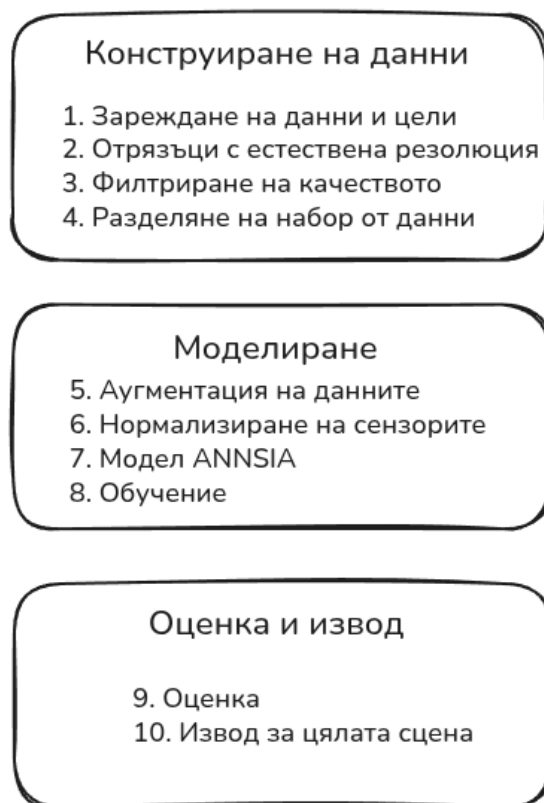
където $s \in \{S2, L8\}$ и статистиките на партидата се изчисляват само от пробите на сензор s . Това поддържа специфична за сензора нормализация, докато споделя всички конволюционни тегла, добавяйки под 1% към общите параметри. Основната идея – афинните параметри кодират домейн-специфични статистики, докато конволюционните тегла кодират споделено семантично съдържание – произхожда от *neural style transfer* [10] и се прилага директно към мулти-сензорния синтез, където “стилът” става специфичната за сензора радиометрична характеристика, а “съдържанието” е основният LAI модел. Conditional BN изисква партии от единичен сензор за валидно изчисляване на статистиките.

Базови модели за наблюдение на Земята

Масщабните базови модели, предварително обучени върху масивни сателитни архиви, представляват зараждаща се парадигма. Prithvi-EO-2.0 [38], разработен от IBM и NASA, е Vision Transformer с masked autoencoder предварително обучен върху 4.2 милиона HLS секвенции от изображения, достъпен в конфигурации до 600M параметъра. Въпреки демонстрираната силна производителност при задачи за сегментация, Prithvi не е оценяван за извличане на LAI. Двата подхода са допълващи се: предварителното обучение на базов модел може да осигури подобрени представяния на признаците, докато нашата стратегия за мулти-сензорно обучение и методология за пространствена валидация остават съществени за оперативно извличане на LAI. Нашият специализиран U-Net с conditional BN постига забележителни резултати само с 28.7M параметъра.

Глава 3. Методология

Тази глава описва подробно пълната методология за мулти-сензорна оценка на LAI, структурирана като десететапен работен процес (Фигура 3.1). Етапите обхващат пълния работен цикъл от генериране на псевдо-референтни данни и мулти-сензорна интеграция на данни, през предварителна обработка, аугментация и нормализация, до дизайн на модела, обучение и валидация. Модулната организация осигурява възпроизводимост и прозрачност, като позволява индивидуалните компоненти да бъдат адаптирани или разширени за други задачи за мониторинг на растителността.



Фигура 3.1: Преглед на работния процес за мулти-сензорна оценка на LAI, показващ последователността от генериране на псевдо-етикети до обучение и валидация на модела.

3.1 Генериране на LAI референтни данни

Обучението с надзор чрез дълбоко самообучение за оценка на LAI изисква големи обеми етикетирани обучителни данни, но полевите LAI измервания са деструктивни, трудоемки и пространствено оскъдни – такива не са били налични за района на Пловдив по време на вегетационния сезон 2023 г. Съществуващите оперативни продукти представят собствени ограничения: Biophysical Processor на ESA SNAP е склонен към екстраполиране отвъд границите на насищане на VI при гъсти покривки, докато Copernicus Global Land Service (CGLS) работи при резолюция от 300 m. В настоящата работа вместо това се възприемат **псевдо-етикети базирани на ансамбъл от вегетационни индекси** като заместващи обучителни цели, позиционирани като физически обосновани, възпроизводими заместители, които позволяват научаване на пространствени модели, като същевременно запазват прозрачност относно ограниченията.

Избор на вегетационни индекси

На базата на сензорна агностичност (изчислими от канали, общи за Sentinel-2 и Landsat 8/9), допълваща чувствителност и установена емпирична валидация [25, 29] са избрани три представителя на вегетационните индекси: NDVI улавя общата жизненост

на растителността и плътността на покривката, GNDVI повишава чувствителността към концентрацията на хлорофил с по-късна точка на насищане, а SAVI смекчава ефектите на почвения фон при редки покривки. Таблица 3.1 обобщава формулите и съответствията на каналите.

Таблица 3.1: Формули на вегетационните индекси и специфични за сензора съответствия на каналите.

Индекс	Формула	Аргументи	S2 канали	L8/9 канали	Насищане LAI
NDVI	$\frac{\rho_{\text{NIR}} - \rho_{\text{Red}}}{\rho_{\text{NIR}} + \rho_{\text{Red}}}$	NIR, Red	B08, B04	B5, B4	~3–4
GNDVI	$\frac{\rho_{\text{NIR}} - \rho_{\text{Green}}}{\rho_{\text{NIR}} + \rho_{\text{Green}}}$	NIR, Green	B08, B03	B5, B3	~4–5
SAVI	$\frac{(\rho_{\text{NIR}} - \rho_{\text{Red}})(1 + L)}{\rho_{\text{NIR}} + \rho_{\text{Red}} + L}$	NIR, Red	B08, B04	B5, B4	~3–4

Трансферни функции от VI към LAI

И трите индекса използват експоненциалната (Beer-Lambert) трансферна функция, която моделира LAI като оптичната дебелина, необходима за затихване на падащото излъчване:

$$\text{LAI} = -\frac{1}{k} \ln(1 - \text{VI}) \quad (3.1)$$

където VI е ограничен до $[0, 0.95]$ и $k = 0.60$ е емпиричният коефициент на затихване, възприет от установени земеделски калибрации [6, 13]. Формулировката на Beer-Lambert има солидна теоретична обосновка в теорията на радиативния трансфер, тъй като затихването през растителната покривка следва експоненциално намаляване, пропорционално на кумулативната листна площ. Въпреки че е опростена (предполага случайно разпределение на листата, игнорира многократното разсейване), тя предоставя физически интерпретируема връзка между спектралната отразителност и структурата на покривката.

Ансамблово агрегиране

За да се използват допълващите силни страни и да се намалят специфичните за метода отклонения, се прилага ансамблово осредняване:

$$\text{LAI}_{\text{ensemble}} = \frac{1}{N} \sum_{i=1}^N \text{LAI}_{\text{method}_i} \quad (3.2)$$

където $N = 3$. Междуметодната вариабилност осигурява пикселна неопределеност:

$$\sigma_{\text{LAI}} = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (\text{LAI}_{\text{method}_i} - \text{LAI}_{\text{ensemble}})^2} \quad (3.3)$$

Висока стойност на стандартното отклонение ($\sigma > 0.5 \text{ m}^2/\text{m}^2$) индикира начало на насищане, почвено или атмосферно замърсяване, или смесени пиксели. Метриката за неопределеност се съхранява заедно с ансамбловата средна стойност и се използва за филтриране по качество на обучителните проби (изключване на отрязъци с $\sigma > 1.0 \text{ m}^2/\text{m}^2$) и за идентифициране на пространствени региони, където оценките са по-малко надеждни. Ансамбловото осредняване частично компенсира случайни грешки, разширява ефективния динамичен обхват чрез различни прагове на насищане и намалява чувствителността към откази на единичен метод. CNN, обучена върху ансамблови цели, може впоследствие да превъзхожда индивидуалните индекси чрез научаване на пространствени модели отвъд пикселните спектрални зависимости, както е демонстрирано в Секция 4.2.

Обосновка и ограничения

Обучението на CNN върху VI-производни етикети въвежда фундаментална кръговост, при която моделът се научава да интерполира и изглажда VI-ensemble LAI, вместо да извлича абсолютен LAI независимо. Настоящата работа не претендира за абсолютни LAI стойности; тя е позиционирана като **оперативна оценка на LAI с използване на VI-ensemble псевдо-етикети**. Няколко фактора подкрепят този подход: ансамбълът агрегира три независими формулировки с десетилетия емпирична валидация [13, 39]; функцията на Beer–Lambert е основана на теорията на радиативния трансфер; валидационните доклади на ESA показват $\text{RMSE} < 1.0 \text{ m}^2/\text{m}^2$ за VI-базирани подходи в земеделски системи [3]; етикетите са генерирани независимо от SNAP, запазвайки го като ортогонална валидационна референция (Секция 4.4).

Основните ограничения са три. Първо, кръговата референтна стойност означава, че задачата на CNN е пространствена интерполация на VI-ensemble LAI; това се адресира чрез допълнителни оценки, включително сравнение със SNAP, анализ на пространствената кохерентност и експерименти за обобщаване между региони (Глава 4). Второ, насищането на VI при LAI 3–5 m^2/m^2 неизбежно се наследява от CNN, въпреки че това се смекчава чрез фокусиране върху земеделски ландшафти, където LAI типично остава под 5 m^2/m^2 . Трето, обучителните данни произлизат от единичен сезон (септември 2023), въпреки че времевото обобщаване и обобщаването между региони се тестват с данни от май 2024 г. от Бургас (Секция 4.3).

3.2 Обработка на данни, обучение и извеждане

Тази секция описва цялостния работен процес – от приемане на сателитни данни, през обучение на модела, до пълноценно прогнозиране на LAI.

Зареждане на данни и сензорна конфигурация

Методологията използва Level-2 атмосферно коригирани продукти за повърхностна отразителност: Sentinel-2 Level-2 от Copernicus Data Space и Landsat 8/9 Collection 2 Level-2 от USGS Earth Explorer. За Sentinel-2 се запазват всички канали с резолюция

20 m или по-добра (10 канала общо), изключвайки каналите при 60 m за крайбрежно, аерозолно и пересто облачно покритие (B01, B09, B10). За Landsat 8/9 се използват всички шест 30 m VNIR-SWIR канала (B2-B7). Шест общи спектрални региона (Blue, Green, Red, NIR, SWIR1, SWIR2) формират сензорно-агностично подмножество, докато четирите red-edge канала на Sentinel-2 предоставят допълнителни спектрални детайли. Таблица 3.2 обобщава съответствието на каналите. Суровите цифрови стойности се преобразуват във физически стойности на отразителност (деление на 10 000 за Sentinel-2; прилагане на USGS gain/offset за Landsat) и се съхраняват като float16 за ефективно съхранение.

Таблица 3.2: Избор на спектрални канали за Sentinel-2 и Landsat 8/9.

Спектрален регион	S2 канал	S2 λ (nm)	L8/9 канал	L8/9 λ (nm)
Blue	B02	490	B2	482
Green	B03	560	B3	561
Red	B04	665	B4	655
Red-Edge 1	B05	705	–	–
Red-Edge 2	B06	740	–	–
Red-Edge 3	B07	783	–	–
NIR	B08	842	B5	865
NIR Narrow	B8A	865	–	–
SWIR 1	B11	1610	B6	1609
SWIR 2	B12	2190	B7	2201
Общо канали	10 канала		6 канала	

Разделяне на отрязъци при оригинална резолюция

За разлика от конвенционалните подходи, които ресемплират всички входове към обща мрежа, работният процес запазва оригиналната сензорна резолюция навсякъде. Всеки сензор се разделя на отрязъци при своя оригинален пикселен размер, като размерите на отрязъците се настройват за покриване на приблизително една и съща географска област (Таблица 3.3). Това избягва артефакти от ресемплиране, които влошават финомасщабната пространствена информация. Архитектурата на CNN поема различните резолюции чрез специфични за сензора пътища (Секция 3.2). Пълните сцени се разделят на неприпокриващи се отрязъци; частичните отрязъци на границите на сцената се отхвърлят, ако са под 90% от номиналните размери. Всеки отрязък запазва своята координатна референтна система и метаданни за геотрансформация.

Филтриране по качество и маскиране

И двата сензора предоставят пикселни слоеве за качество за маскиране на облаци и артефакти. За Sentinel-2 се използва Sen2Cor Scene Classification Layer (SCL)

Таблица 3.3: Конфигурация на размерите на отрязъците за обработка при оригинална резолюция.

Сензор	Резолюция	Размер отрязък	Покритие (km)	Покритие (km ²)	Пиксели
Sentinel-2	10 m	158×158	1.58 × 1.58	2.50	24,964
Landsat 8/9	30 m	53×53	1.59 × 1.59	2.53	2,809

за маскиране на облаци, облачни сенки, перести облаци, сняг, наситени/дефектни пиксели и пиксели без данни [28]. За Landsat 8/9 се прилага консервативно маскиране чрез битово кодирани QA_PIXEL флагове за високо достоверни облаци, сенки, перести облаци, наситени и запълващи пиксели. След пикселното маскиране отрязъците се запазват само ако отговарят на три критерия: валиден дял ≥ 0.95 , средна стойност на $\text{LAI ensemble} \in [0, 10] \text{ m}^2/\text{m}^2$ и стандартно отклонение на $\text{LAI ensemble} < 1.5 \text{ m}^2/\text{m}^2$. Маскираните пиксели в запазените отрязъци се задават като NaN и се изключват от изчисляването на функцията за загуба.

Генериране на набор от данни и пространствено разделяне

Обработените отрязъци се сериализират като .npy файлове, съдържащи масиви с отражателност (10 канала за Sentinel-2, 6 за Landsat), средна стойност на LAI ensemble и неговата неопределеност, всички във float16. Финалните експерименти (Exp X1-X4, Глава 4.1) реализират географска разединеност чрез разделяне с 4×4 пространствена мрежа (Фигури 4.1 и 4.2). Блоковете се присвояват случайно към обучаващо, валидационно и тестово разделение с фиксиран seed в съотношение 70/15/15. За двете пловдивски сцени това дава 22 пълни блока (15 обучаващи, 3 валидационни, 4 тестови). Това присвояване на ниво блок гарантира, че всички отрязъци в един и същи географски регион остават в едно и също разделение, предотвратявайки пространственото изтичане на данни.

Аугментация на данни

Обучителните данни се аугментират в реално време с осем геометрични трансформации: идентичност, три 90° ротации и четири комбинации от обръщане/ротация. Използват се само 90° стъпки и осово симетрични обръщания, запазвайки спектралните стойности точно, без интерполация. Спектрални аугментации умишлено не са включени, за да се запази физическата цялост на спектрално-LAI зависимостите. За мулти-сензорните експерименти отрязъците от Sentinel-2 се семплират с четирикратно по-висока честота на аугментация, за да се компенсира дисбалансът от $\sim 4:1$ в броя отрязъци на Landsat, изравнявайки сензорната експозиция на ниво епоха.

Нормализация

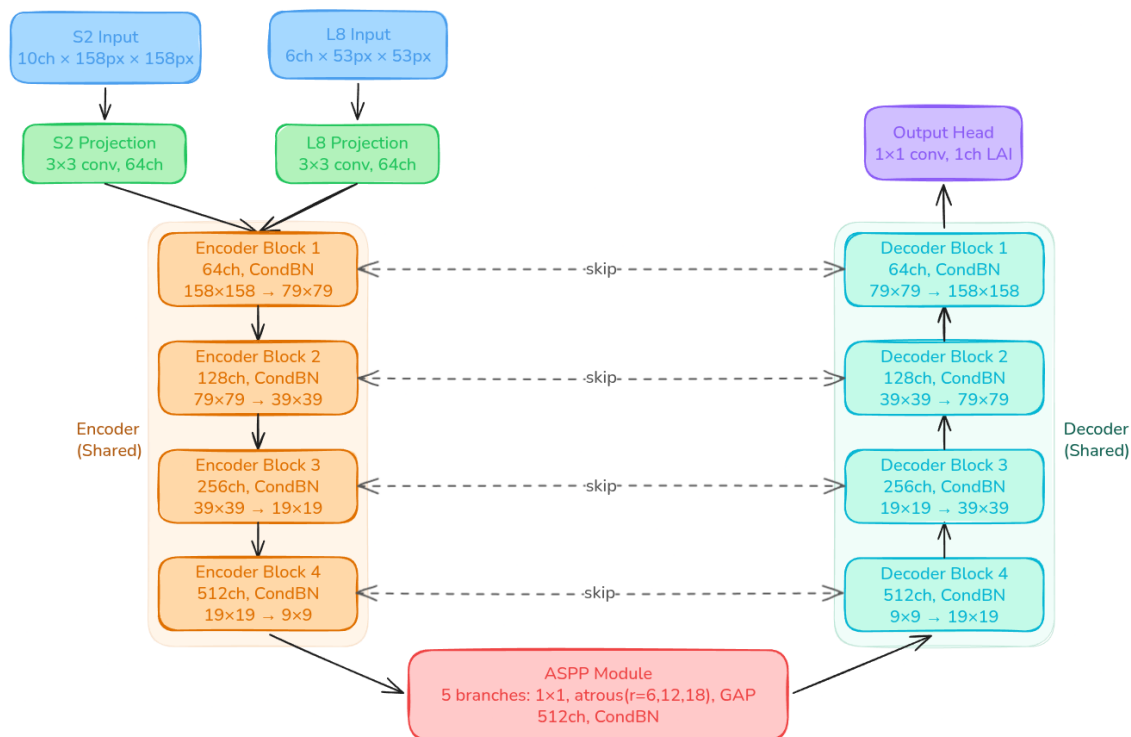
Прилага се специфична за сензора Z-score нормализация за картографиране на разпределението на отражателността на всеки сензор към обща стандартизирана скала:

$$x_{\text{norm}}^{(s,b)} = \frac{x_{\text{raw}}^{(s,b)} - \mu^{(s,b)}}{\sigma^{(s,b)}} \quad (3.4)$$

където $\mu^{(s,b)}$ и $\sigma^{(s,b)}$ са средната стойност и стандартното отклонение за сензор s и канал b , изчислени само от обучаващото разделение и приложени последователно към валидационните и тестовите набори. Тази линейна трансформация запазва относителните спектрални контрасти, критични за изчисляването на вегетационните индекси, като същевременно улеснява научаването на споделени представяния, въпреки междусензорните разлики.

Архитектура на модела

Основната архитектура е ANNSIA – мулти-сензорен U-Net с Conditional Batch Normalisation и Atrous Spatial Pyramid Pooling (ASPP), илюстриран на Фигура 3.2.



Фигура 3.2: Архитектурата на ANNSIA.

U-Net архитектура със специфични за сензора входни проекции, споделен encoder-decoder, ASPP модул в bottleneck-a и Conditional Batch Normalisation навсякъде. Skip connections (пунктирани стрелки) конкатенират признаците от encoder с признаците от decoder при съвпадащи пространствени резолюции.

Специфични за сензора 3×3 входни проекции картографират различния брой канали (10 за Sentinel-2, 6 за Landsat) към общо 64-канално представяне. Споделеният encoder се състои от четири блока за намаляване на резолюцията (канали: $64 \rightarrow 128 \rightarrow 256 \rightarrow 512$), всеки включващ две 3×3 конволюции с ReLU активация,

Conditional Batch Normalisation и 2×2 max pooling. В bottleneck-а модулът ASPP [5] агрегира многомащабен контекст чрез пет паралелни клона: 1×1 конволюция, три 3×3 atrous конволюции с rate-ове 6, 12 и 18 и global average pooling, улавяйки контекст на субполе (~ 200 m), поле (~ 400 m) и мултиполе (~ 600 m) съответно. Симетричният decoder възстановява пространствената резолюция чрез четири блока с транспонирани конволюции и skip connections. Финална 1×1 конволюция с ReLU активация произвежда едноканалния LAI изход. Мрежата съдържа приблизително 28.7 милиона обучаеми параметъра.

Conditional Batch Normalisation

Въпреки че входовете са Z-score нормализирани, Sentinel-2 и Landsat 8/9 проявяват различни вътрешни разпределения на признаците поради различаващите се входни резолюции, спектрално съдържание и характеристики на пространствените честоти. Conditional Batch Normalisation адресира това чрез поддържане на специфични за сензора афинни параметри ($\gamma^{(s)}, \beta^{(s)}$) и текущи статистики на всеки нормализационен слой, като споделя всички конволюционни тегла. По време на обучение всяка партида съдържа проби от единичен сензор; по време на извеждане идентификаторът на сензора избира подходящите параметри. Това позволява сензорно-инвариантни конволюционни филтри със специфично за сензора мащабиране на признаците.

Стратегия за обучение

Обучението използва оптимизатора AdamW [27] с learning rate $\eta = 10^{-3}$, weight decay $\lambda = 10^{-5}$ и cosine annealing с топли рестартове [26]:

$$\eta_t = \eta_{\min} + \frac{1}{2}(\eta_{\max} - \eta_{\min}) \left(1 + \cos \left(\frac{T_{\text{cur}}}{T_i} \pi \right) \right) \quad (3.5)$$

където $\eta_{\max} = 10^{-3}$, $\eta_{\min} = 10^{-6}$ и T_i е периодът на рестартиране. Функцията на загуба е NaN-осведомена пикселна MSE по валидните пиксели:

$$\mathcal{L}_{\text{MSE}} = \frac{1}{|\mathcal{V}|} \sum_{(i,j) \in \mathcal{V}} (\hat{y}_{i,j} - y_{i,j})^2 \quad (3.6)$$

където \mathcal{V} е множеството от не-NaN пиксели след облачно маскиране. Използва се размер на партидата от 64 за всеки сензор на NVIDIA A100 40 GB GPU (Секция 4.5), с партии от единичен сензор, редуващи се между Sentinel-2 и Landsat 8/9, за осигуряване на правилното функциониране на Conditional Batch Normalisation.

Метрики за оценка

Производителността на модела се определя качествено чрез RMSE, MAE, R^2 , Bias и Variance Ratio. Във всички уравнения \hat{y}_i означава прогнозирания LAI, y_i – референтния LAI, а N – броя на валидните пиксели:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (3.7)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (3.8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (3.9)$$

$$\text{Bias} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i) \quad \text{Variance Ratio} = \frac{\sigma_{\hat{y}}}{\sigma_y} \quad (3.10)$$

Метриците се изчисляват за всеки сензор, стратифицирани по LAI интервали (0-0.5, 0.5-1, 1-2, 2-3, 3-5, 5-10 m²/m²) и за всяка сцена. Важността на каналите се оценява чрез пермутация – разбъркване на канал b и измерване на увеличението на RMSE спрямо базовата линия.

Извеждане (Inference)

За оперативно LAI картографиране обучените модели се прилагат върху пълни сцени с плъзгащ се прозорец с $\sim 25\%$ припокриване (40 пиксела за Sentinel-2, 13 за Landsat). В зоните на припокриване прогнозите се смесват чрез линейно-рампово претегляне:

$$\hat{y}_{i,j} = \frac{\sum_k w_k(i,j) \hat{y}_k(i,j)}{\sum_k w_k(i,j)} \quad (3.11)$$

където w_k нараства линейно от 0 до 1 за $O/2$ пиксела на всеки край на отрязъка, елиминирайки гранични прекъсвания. Изходните LAI карти се експортират като компресирани GeoTIFF растери с оригиналната координатна референтна система. Пълносценното извеждане за една Sentinel-2 сцена (~ 120 милиона пиксела) завършва за по-малко от две минути на единичен A100 GPU.

3.3 Методология за валидиране

Използването на оценки на ансамбъл от вегетационни индекси като обучителни цели въвежда фундаментална кръговост, при която CNN се научава да прогнозира LAI от отразителност, използвайки етикети, които самите са производни на вегетационни индекси, базирани на отразителност. Въпреки че това ограничение не може да бъде напълно преодоляно без деструктивни полеви измервания, многостепенна стратегия за валидация осигурява триангулация чрез независими източници на доказателства. В тази работа се използва петстепенна рамка за валидация, описана по-долу. Нито едно ниво от тази рамка не преодолява самостоятелно ограничението на кръговата референтна стойност, но конвергенцията по множество независими оси повишава

увереността в устойчивостта на методологията.

Ниво 1: Вътрешна Machine Learning валидация

Пространствената блокова кръстосана валидация (Секция 3.2) гарантира географска разединеност между обучаващите и тестовите набори. Производителността на модела се оценява чрез RMSE, MAE, R^2 , bias и variance ratio (Секция 3.2), стратифицирани в четири LAI бина – нисък (0-2), среден (2-4), висок (4-6) и много висок ($>6 \text{ m}^2/\text{m}^2$) – за диагностициране на ефекти на насищане и LAI-зависими отклонения.

Ниво 2: Оперативни LAI продукти

SNAP Biophysical Processor реализира невронна мрежова емуляция на PROSAIL [21], обучена върху 50,000 симулирани конфигурации на покривката. Той предоставя пикселни LAI оценки, основани на теория на радиативния трансфер, а не на емпирични индекси и не се използва като обучителни данни на нито един етап, запазвайки независимостта му. Съгласие между CNN прогнозите и SNAP индикира съгласуваност с физически базирани оценки; несъгласие подчертава разминаване между VI-ensemble псевдо-етикетите и RTM подходите.

Ниво 3: Валидация с радиативен трансферен модел

Моделът PROSAIL [21] свързва модела PROSPECT за оптичните свойства на листата с модела SAIL за отразителност на покривката. За тестване на съгласуваността с теорията на радиативния трансфер PROSAIL се изпълнява за избрани полета с известни типове култури, използвайки литературно базирани диапазони на параметрите и измерена слънчева геометрия. Симулираните спектри на отразителност се подават на обучената CNN и получените прогнози се сравняват с LAI стойностите от forward симулацията. Съгласуваност (RMSE под $0.5 \text{ m}^2/\text{m}^2$) индикира, че научената спектрално-LAI зависимост е в съответствие с физически базираната теория. Това ниво е ограничено от неопределеността на параметрите на PROSAIL и трябва да се интерпретира като физически базирана проверка, независима от емпиричните VI.

Ниво 4: Междурегионална и времева съгласуваност

Моделът, обучен върху пловдивските сцени от септември 2023, се оценява на независим обект – районът на Бургас, приблизително 200 km на изток – в два сезона. Географският трансфер се оценява чрез zero-shot приложение към есенни сцени от Бургас за 2023, изолирайки географското изместване, докато се контролира за фенология. Времевият трансфер се оценява чрез zero-shot приложение към пролетни сцени от Бургас за 2024, въвеждайки 8-месечен сезонен интервал, обхващащ цял фенологичен цикъл. Мулти-сензорното обучение допълнително позволява вътрешни проверки за съгласуваност: CNN прогнозите от Sentinel-2 и Landsat 8 за пространствено припокриващи се области трябва да съвпадат в рамките на $\pm 0.5 \text{ m}^2/\text{m}^2$.

Ниво 5: Сравнителен анализ с емпирични вегетационни индекси

Най-директната мярка за добавената стойност на CNN е сравнението с индивидуалните VI методи (NDVI-exp, GNDVI-exp, SAVI-exp) и тяхната ансамблова средна стойност, използвани за генериране на обучителните етикети. Ако CNN просто запазва пикселните VI-LAI зависимости, тя не би трябвало да се представя по-добре от най-добрия индивидуален VI; превъзходна производителност индикира пространствено обучение отвъд пикселните спектрални индекси. За всеки валидационен отрязък LAI оценките от трите VI метода, ансамбловата средна стойност и CNN се сравняват по RMSE, MAE и R^2 .

Обосновка и ограничения

Конвергентните доказателства по пет независими оси осигуряват увереност въпреки ограничението на кръговата референтна стойност. Ниво 1 потвърждава обобщаването извън извадката, Ниво 2 контекстуализира прогнозите в рамките на оперативни продукти, Ниво 3 верифицира съгласуваността с теорията на радиативния трансфер, Ниво 4 демонстрира географска и времева преносимост, а Ниво 5 количествено определя добавената стойност отвъд пикселните индекси. Тази рамка не претендира за валидиране на абсолютната точност на LAI спрямо полеви измервания; работата е позиционирана като оперативна оценка на LAI с демонстрирано пространствено обучение, мулти-сензорен синтез и капацитет за обобщаване. Бъдещо шесто ниво, включващо полеви LAI измервания, би позволило оценка на абсолютната точност и специфична за културата калибрация.

Глава 4. Експерименти и резултати

4.1 Експериментална конфигурация

Тази секция описва набора от данни, стратегията за пространствено разделяне и вариантите на модела, оценени в настоящата дисертация.

Регион на изследване и събиране на данни

Основният набор от данни включва сателитни изображения, събрани над **района на Пловдив, България** (42.15°N, 24.75°E), предимно земеделски ландшафт, характеризиращ се с отглеждане на зърнени култури (пшеница, царевица), индустриални култури (слънчоглед) и лозарство, с равнинен до слабо хълмист терен (100-300 m надморска височина). Всички обучителни данни са събрани през септември 2023 г., съответстващо на есенна фенология, която осигурява разнообразен LAI обхват (0-6 m²/m²), като избягва екстремни условия на насищане. Обобщаването се оценява с помощта на независими сцени от района на Бургас, приблизително 200 km на изток. Таблица 4.1 обобщава използваните сателитни сцени.

Сателитните проби за обучение от Sentinel-2 и Landsat 9 са разделени само от

Таблица 4.1: Сателитни сцени, използвани за обучение, валидация и тестване на обобщаването.

Регион	ID на сцена	Сензор	Дата	Облачност	Отрязъци
<i>Обучение и пространствена валидация (Пловдив, септември 2023)</i>					
Пловдив	T34TGM	Sentinel-2B	10 сеп 2023	< 5%	2,543
Пловдив	T35TLG	Sentinel-2B	10 сеп 2023	< 5%	831
Пловдив	Path 183/031	Landsat 9	9 сеп 2023	< 1%	14,145
<i>Междурегионално обобщаване (Бургас, септември 2023)</i>					
Бургас	T35TNH	Sentinel-2B	7 сеп 2023	< 5%	–
Бургас	Path 181/030	Landsat 8	3 сеп 2023	–	–
<i>Времево обобщаване (Бургас, май 2024)</i>					
Бургас	T35TNH	Sentinel-2A	6 май 2024	< 1%	–
Бургас	Path 182/031	Landsat 8	7 май 2024	–	–

Забележка: Отрязъците за Пловдив са след филтриране по качество и преди пространственото блоково разделяне (S2: 158×158 px, L8/9: 53×53 px). Сцените от Бургас тестват географски (200 km) и времеви (8 мес.) трансфер. Моделът не е обучаван с данни от Бургас.

един ден, минимизирайки фенологичната промяна и позволявайки последователно генериране на VI-ensemble референтни данни. Районът на Бургас осигурява напълно независим тест с различен земеделски състав, почвени характеристики и крайбрежно влияние, тествайки едновременно географски трансфер (200 km) и времеви трансфер (8-месечен интервал).

Брой отрязъци и разпределение на данните

След разделяне на отрязъци, филтриране по качество и пространствено блоково разделяне наборът от данни включва 17,519 отрязъка. Отрязъците от Landsat 9 надвишават тези от Sentinel-2 приблизително 4:1 поради по-грубата резолюция, произвеждаща повече отрязъци на сцена, мотивирайки стратегията за балансиране на обучителните партии (Секция 3.2).

Статистики за нормализация

Таблица 4.2 представя средна стойност и стандартно отклонение за всеки канал за шестте спектрални региона, общи за двата сензора. Отражателностите на Landsat 9 са систематично по-ниски в каналите от видимата област, отразявайки разлики в спектралните функции за отклик и атмосферната корекция, докато NIR и SWIR показват по-близко съгласие. Тези специфични за сензора статистики се прилагат чрез Z-score нормализация (Уравнение (3.4)) и се съхраняват с контролната точка на модела за последователно използване по време на валидация и извеждане.

Таблица 4.2: Статистики за нормализация за всеки канал на обучителния набор от данни за Пловдив.

Канал	S2 Mean	S2 Std	L9 Mean	L9 Std
Blue (S2 B02 / L9 B2)	0.1611	0.0653	0.0354	0.0249
Green (S2 B03 / L9 B3)	0.1763	0.0652	0.0584	0.0325
Red (S2 B04 / L9 B4)	0.1758	0.0746	0.0601	0.0480
NIR (S2 B08 / L9 B5)	0.3534	0.1027	0.2588	0.0832
SWIR1 (S2 B11 / L9 B6)	0.3115	0.1094	0.1912	0.0909
SWIR2 (S2 B12 / L9 B7)	0.2413	0.1023	0.1119	0.0726

Статистики на LAI референтните данни

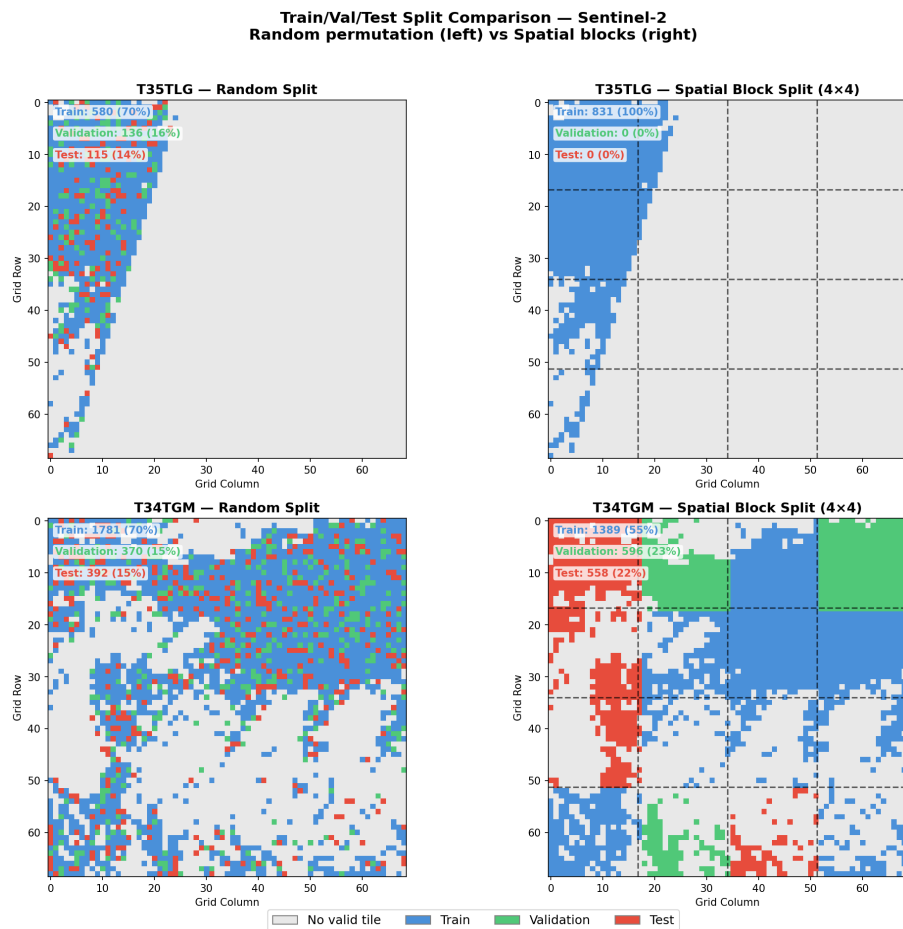
Разпределението на VI-ensemble LAI (Таблица 4.3) има средна стойност $1.82 \text{ m}^2/\text{m}^2$ и е дясно асиметрично, отразявайки преобладаването на ниски до умерени LAI стойности с отделни полета с висок LAI. Обучаващите, валидационните и тестовите набори проявяват почти идентични статистики (средни стойности в рамките на $0.03 \text{ m}^2/\text{m}^2$), потвърждавайки, че пространственото блоково разделяне запазва LAI разнообразието. Максималната наблюдавана стойност на LAI от $5.92 \text{ m}^2/\text{m}^2$ остава под екстремния праг на насищане. Средното между VI стандартно отклонение е $0.34 \text{ m}^2/\text{m}^2$ ($CV = 19\%$), индикирайки разумен консенсус между трите метода за оценка.

Таблица 4.3: Статистики на LAI ensemble по разделения (m^2/m^2).


Разделение	Средна	Ст. откл.	Медиана	Мин.	Макс.
Обучение	1.82	1.15	1.54	0.02	5.87
Валидация	1.79	1.12	1.51	0.01	5.92
Тест	1.85	1.18	1.58	0.03	5.79
Общо	1.82	1.15	1.55	0.01	5.92

Пространствено блоково разделяне

Всички експерименти използват пространствена блокова кръстосана валидация. Всяка сцена се разделя на 4×4 мрежа от равни географски блокове, случайно присвоени към обучаващо, валидационно и тестово разделение с фиксиран seed в съотношение 70/15/15. За двете пловдивски сцени това дава 22 непразни блока (15 обучаващи, 3 валидационни, 4 тестови). Присвояването на ниво блок гарантира, че всички отрязъци в един и същи географски регион остават в едно и също разделение, предотвратявайки пространственото изтичане на данни от съседни отрязъци, попадащи в различни разделения (Фигури 4.1 и 4.2).



Фигура 4.1: Случайно разделяне спрямо пространствено блоково разделяне за Sentinel-2 изображения T35TLG и T34TGM.



Фигура 4.2: Случайно разделяне спрямо пространствено блоково разделяне за Landsat 9 изображение LC09_183031.

Варианти на модела

Четири експериментални конфигурации изолират приносите на мулти-сензорната интеграция, формулирането на референтните данни и нормализацията. **X1** (само Sentinel-2) и **X2** (само Landsat 8/9), установяват едносензорни базови линии. **X3** (мулти-сензорен, VI-ensemble цели, $4 \times$ batch balancing) е **най-добре представящият се модел** и референция за всички експерименти за обобщаване. **X4** (идентичен на X3, но с хибридни VI+PROSAIL цели в съотношение 50:50) проверява дали физически базираните RTM ограничения подобряват обобщаването. Таблица 4.4 предоставя обобщение на експериментите и ключовите резултати по рамката за валидация.

Таблица 4.4: Обобщение на експериментите и ключови резултати по рамката за валидация.

#	Ниво	Експеримент	Фокус	Основни метрики	Ключови резултати
<i>Едносензорни базови линии (Секция 4.2)</i>					
X1	T1	Само Sentinel-2	Референция при 10 m, 10 канала	Test RMSE, R^2	RMSE = 0.059, R^2 = 0.958
X2	T1	Само Landsat 8/9	Референция при 30 m, 6 канала	Test RMSE, R^2	RMSE = 0.071, R^2 = 0.990
<i>Мулти-сензорна интеграция (Секция 4.2)</i>					
X3	T1	Мулти-сензорен, без LAI норм. (най-добър)	Съвместен S2 + L8/9	Test RMSE, R^2	Общо: RMSE = 0.017, R^2 = 0.999. S2: 0.012; L8: 0.026. 80%/64% намаление на RMSE спрямо X1/X2
X4	T1, T3	Мулти-сензорен, хибриден VI+PROSAIL	RTM цели спрямо само VI	Δ RMSE спрямо X3	+35% влошаване на RMSE
<i>Обобщаване (Секция 4.3)</i>					
G1	T4	Между региони (Бургас, 200 km)	Zero-shot географски трансфер	RMSE	И двата сензора: RMSE = 0.051
G2	T4	Времеви трансфер (8-месечен интервал)	Фенологична съгласуваност	LAI съотношение	S2: $2.9 \times$; L8: $1.7 \times$ увеличение
G3	T5	CNN срещу вегетационни индекси	Добавена стойност спрямо VI	RMSE спрямо VI-ensemble	CNN: 0.010 (77% по-нисък от най-добрия VI)
<i>Оперативна валидация (Секция 4.4)</i>					
O1	T1, T4	Пълноценно извеждане	Съгласуваност в мащаб на внедряване	RMSE, VR	S2: 0.004, VR = 0.999; L8: 0.010, VR = 0.998
O2	T2	Сравнение с ESA SNAP	Оперативен RTM продукт	RMSE, R^2	SNAP спрямо VI-ens.: RMSE = 1.987, R^2 = 0.312

Забележка: Всички стойности на RMSE са в m^2/m^2 . Нива на валидация: T1 = Вътрешна ML, T2 = Оперативни продукти, T3 = RTM, T4 = Между сензори/времево, T5 = VI сравнителен анализ. VR = Variance Ratio.

4.2 Пространствено строга валидация

Тази секция представя основната оценка на производителността на всички варианти на модела в рамките на пространствената блокова валидация (Секция 4.1). Всички метрики отразяват истинска точност на прогнозиране извън региона, със строга географска разединеност между обучаващите и тестовите набори.

Едносензорни базови линии

Едносензорните U-Net модели са обучени при идентични ограничения на пространствената валидация, за да се изолира приносът на мулти-сензорния синтез. И двата използват същата encoder-decoder архитектура, адаптирана за специфичните за сензора входни размерности (10 канала за Sentinel-2, 6 за Landsat 8/9). Таблица 4.5 обобщава производителността на тестовия набор.

Таблица 4.5: Производителност на едносензорните базови линии при пространствена блокова валидация (тестов набор).

Експ.	Сензор	RMSE (m^2/m^2)	MAE (m^2/m^2)	R^2	Bias (m^2/m^2)
X1	Sentinel-2	0.0593	0.0415	0.9581	-0.0023
X2	Landsat 8/9	0.0707	0.0469	0.9899	+0.0030

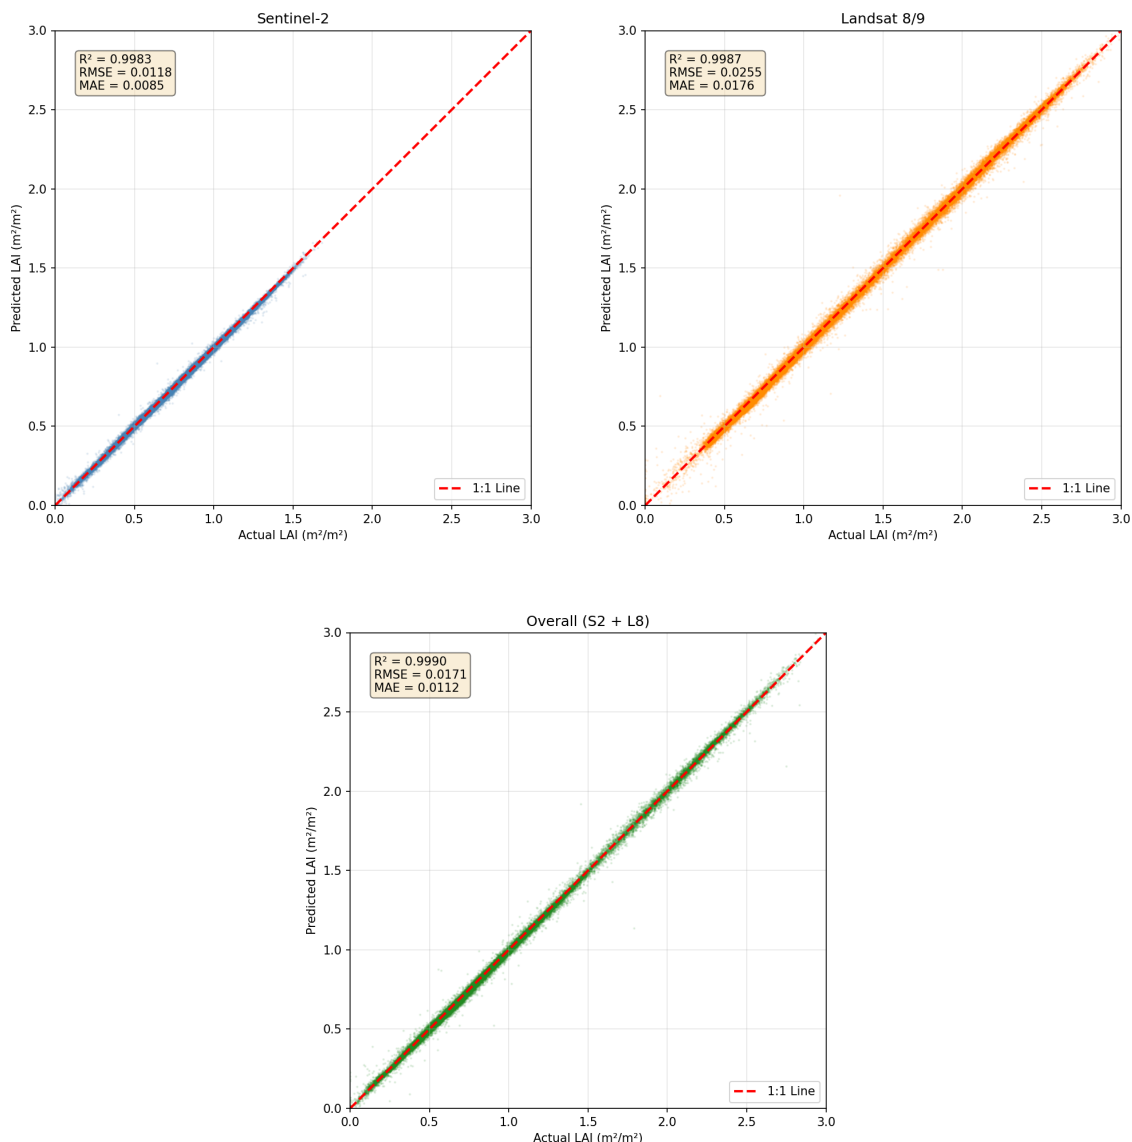
Sentinel-2 постига по-нисък RMSE (0.059 спрямо 0.071 m^2/m^2) благодарение на по-фината пространствена резолюция и red-edge каналите (705, 740, 783 nm), които осигуряват директна чувствителност към съдържанието на хлорофил. Въпреки по-грубата резолюция и липсата на red-edge канали, Landsat постига отличен $R^2 = 0.990$. По-високият R^2 въпреки по-високия RMSE отразява ефект, зависим от резолюцията: 30 m пикселите по природа изглаждат вътрешнополевата вариационност, намалявайки разсейването около регресионната линия. И двата модела проявяват незначително отклонение ($<0.003 \text{ m}^2/\text{m}^2$), потвърждавайки, че научените спектрално-LAI зависимости не са артефакти на пространствено запаметяване.

Експеримент X3: Най-добро представяне на модела

Мулти-сензорният модел комбинира Sentinel-2 и Landsat 8/9 чрез Conditional Batch Normalisation с VI-ensemble псевдо-етикети и $4 \times$ Sentinel-2 batch balancing. Таблица 4.6 и Фигура 4.3 представят резултатите от тестовия набор.

Таблица 4.6: Производителност на тестовия набор за Експеримент X3: мулти-сензорен модел без LAI нормализация.

Сензор	RMSE (m^2/m^2)	MAE (m^2/m^2)	R^2	Тестови пиксели
Sentinel-2	0.0118	0.0085	0.9983	13,929,912
Landsat 8/9	0.0255	0.0176	0.9987	6,027,817
Общо	0.0171	0.0112	0.9990	19,957,729



Фигура 4.3: Scatter диаграми на прогнозиран спрямо псевдо-референтен LAI за Експеримент X3.

Моделът постига общ $R^2 = 0.999$ и $\text{RMSE} = 0.017 \text{ m}^2/\text{m}^2$, като и двата сензора независимо надвишават $R^2 > 0.998$. Моделът конвергира за 45 епохи (35 минути на единичен A100 GPU), като кривите на обучителната и валидационната загуба следват отблизо една друга без разминаване.

Експеримент X4: Хибридни VI+PROSAIL цели

Експеримент X4 заменя чистите VI-ensemble референтни данни със смес 50:50 от VI-ensemble и PROSAIL-инвертиран LAI. Хибридните цели влошават общия RMSE с 35% (Таблица 4.7). Производителността за Sentinel-2 остава сравнима (+2%), но Landsat страда от 33% увеличение на RMSE поради специфично за сензора несъответствие на целите: отрязъците от Sentinel-2 получават хибридни етикети, докато отрязъците от Landsat получават само VI-ensemble етикети. Това потвърждава, че **съгласуваността**

на референтните данни между сензорите е по-важна от сложността на референтните данни.

Таблица 4.7: Експеримент X4: мулти-сензорен с хибридни VI+PROSAIL цели (валидационен набор).

Сензор	RMSE (m^2/m^2)	R^2	спрямо X3 RMSE	Оценка
Sentinel-2	0.012	0.9989	+2%	Сравнимо
Landsat 8/9	0.034	0.9972	+33%	Влошено
Общо	0.023	0.9980	+35%	Влошено

Мулти-сензорна синергия

Таблица 4.8 представя оценка на подобрението, постигнато чрез мулти-сензорна интеграция. Мулти-сензорният модел намалява RMSE на Sentinel-2 с 80% ($0.059 \rightarrow 0.012$) и RMSE на Landsat с 64% ($0.071 \rightarrow 0.026$). Това демонстрира истинска мулти-сензорна синергия: прогнозите за всеки сензор се подобряват отвъд това, което сензорът постига самостоятелно. Мулти-сензорното обучение принуждава споделения encoder да научи сензорно-инвариантни LAI признаци; Sentinel-2 предоставя финомасщабни пространствени детайли и чувствителност в red-edge областта, докато Landsat допринася устойчиви широколентови сигнатури. Conditional Batch Normalisation позволява специфично за сензора нормализиране на признаците, запазвайки споделените семантични представяния.


Таблица 4.8: Мулти-сензорен (X3) спрямо едносензорна (X1, X2) производителност (тестов набор).

Модел	Сензор	RMSE (m^2/m^2)	R^2	ΔRMSE
X1 (само S2)	Sentinel-2	0.059	0.9581	Базова линия
X2 (само L8)	Landsat 8/9	0.071	0.9899	Базова линия
X3 (Мулти-сензорен)	Sentinel-2	0.012	0.9983	−80%
	Landsat 8/9	0.026	0.9987	−64%

Анализ на важността на спектралните ленти

Пермутационната важност на признаците (Фигура 4.4) разкрива сензорно-адаптивни спектрални стратегии, които възникват автоматично чрез мулти-сензорното обучение. Sentinel-2 разчита основно на NIR (39.4%) и Red (23.4%), съгласувано с биофизичната основа на вегетационните индекси, като трите red-edge канала заедно допринасят 8.9%. Landsat, без red-edge канали, възприема различна стратегия: Red (25.5%) и NIR (24.9%) допринасят почти еднакво, със съществено повече значимост, разпределена

на SWIR каналите (28.2% общо спрямо 7.6% за Sentinel-2) и Green (18.2% спрямо 11.5%), компенсирайки липсващата red-edge информация чрез чувствителност към водното съдържание на покривката и структурата на листата.



Фигура 4.4: Пермутационна важност на каналите за Експеримент X3.

Обобщение

Мулти-сензорната интеграция осигурява съответно 80% и 64% намаление на RMSE за Sentinel-2 и Landsat. Сензорно-агностичните референтни данни (чист VI-ensemble) превъзхождат хибридните VI+PROSAIL цели, поддържайки междусензорна съгласуваност. Моделът научава сензорно-адаптивни спектрални стратегии чрез споделения encoder-decoder с Conditional Batch Normalisation. Тези резултати, валидирани върху почти 20 милиона географски разединени тестови пиксела, установяват капацитета на модела за точно извличане на LAI в рамките на обучаващия домейн.


4.3 Валидация на обобщаването

Силната вътрешнодомейнна производителност при пространствена блокова валидация (Секция 4.2) е необходимо, но недостатъчно условие за оперативна увереност. Тази секция оценява най-добрия мулти-сензорен модел (X3) по три независими оси на обобщаване: географски трансфер към независим регион на 200 km разстояние, времеви трансфер за 8-месечен сезонен интервал и методологично сравнение с индивидуалните компоненти на вегетационните индекси.

Междурегионално географско обобщаване

Районът на Бургас (42.5°N, 27.5°E), приблизително 200 km на изток от Пловдив, служи като напълно независим валидационен обект с различен земеделски състав, по-висока почвена солениост и морско климатично влияние. Моделът е приложен без каквото и да е повторно обучение или калибрация – истински zero-shot географски трансфер. И двата сензора постигат идентичен $RMSE = 0.051 \text{ m}^2/\text{m}^2$ (Фигура 4.5), добре в рамките на границите на неопределеност на VI-ensemble ($\sim 0.34 \text{ m}^2/\text{m}^2$). Това сензорно равенство потвърждава, че мулти-сензорното обучение произвежда еднакво

преносими представяния за двата инструмента въпреки различните им спектрални конфигурации и пространствени резолюции.



Фигура 4.5: Резултати от междурегионалното обобщаване, демонстриращи географска преносимост и сензорно-агностично обобщаване на Експеримент X3.


Междусезонно времево обобщаване

Районът на Бургас е заснет и през есента (септември 2023), и през пролетта (май 2024), позволявайки контролирано сравнение, което изолира времевите ефекти. И двата сензора последователно прогнозируют по-висок LAI през пролетта (Sentinel-2: $2.9\times$, Landsat: $1.7\times$; Фигура 4.7), правилно улавяйки очаквания фенологичен модел: пролетните заснемания съответстват на активен вегетативен растеж ($\text{LAI } 0.6\text{--}1.7 \text{ m}^2/\text{m}^2$), докато есенните улавят стърнища след жътва и старееща растителност ($\text{LAI } 0.2\text{--}1.0 \text{ m}^2/\text{m}^2$). Разликата в сезонното съотношение отразява по-голямата чувствителност на Sentinel-2 към финомащабната структура на покривката при 10 m резолюция с red-edge канали. Не са наблюдавани систематично отклонение или дрейф, потвърждавайки, че научената спектрално-LAI зависимост улавя фундаментални биофизични връзки, а не специфични за сезона модели.

CNN срещу базова линия на вегетационните индекси

Тъй като CNN е обучена върху VI-ensemble псевдо-етикети, ключов въпрос е дали тя добавя стойност отвъд съставните вегетационни индекси. Фигура 4.6 сравнява всеки метод спрямо VI-ensemble референцията за пловдивската Sentinel-2 сцена (T34TGM). CNN постига $\text{RMSE} = 0.010 \text{ m}^2/\text{m}^2$, **77% подобрение** спрямо най-добрия индивидуален VI (GNDVI-expr, 0.044). Индивидуалните VI проявяват голямо междуметодно несъгласие ($\text{RMSE } 0.044\text{--}0.088$) и значителен bias (± 0.05), докато CNN възпроизвежда

ансамбловия консенсус с почти нулев bias. Това превъзходство произтича от интегрирането на пространствен контекст (U-Net обработва 158×158 фрагменти вместо индивидуални пиксели), научени нелинейни спектрални комбинации по всички 10 канала, потискане на шума чрез научена пространствено-спектрална регуляризация и имплицитна междусензорна съгласуваност, наложена от споделения encoder-decoder.

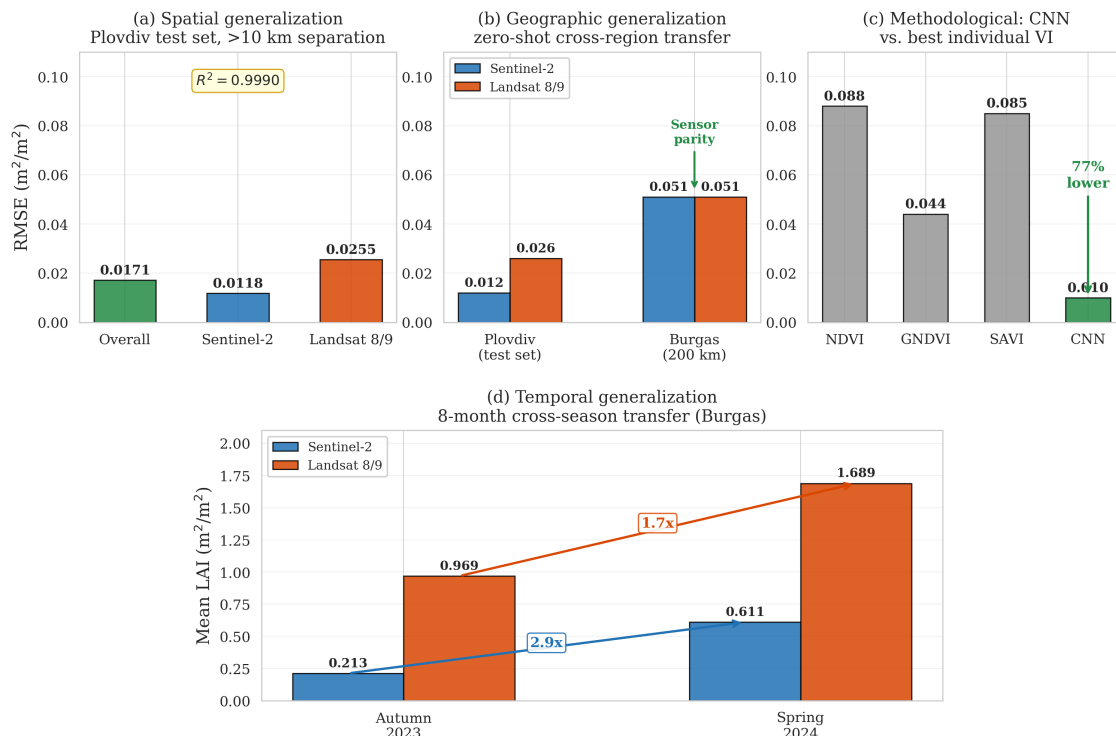


Фигура 4.6: Сравнение на CNN спрямо вегетационни индекси.

Обобщение на генерализацията

Фигура 4.7 консолидира производителността по всички измерения на оценка. Трите оси заедно установяват тройно постижение на обобщаването: пространствената блокова валидация потвърждава, че моделът не запаметява локални модели, 200 km междурегионалният трансфер потвърждава географската устойчивост, а 8-месечният междусезонен трансфер потвърждава времевата стабилност.

Няколко предупреждения съпътстват тези резултати. VI-ensemble референтните данни наследяват насищане при висок LAI ($>5 \text{ m}^2/\text{m}^2$) и чувствителност към ефекти на почвения фон. Географското обобщаване е валидирано в рамките на умерени земеделски региони в Югоизточна Европа; производителността в тропически, пустинни или горски ландшафти остава нетествана. Времевата валидация обхваща единичен 8-месечен интервал; многогодишната стабилност изисква оценка на по-дълги времеви серии.



Фигура 4.7: Обобщение на рамката за тройно обобщаване.

4.4 Оперативна валидация

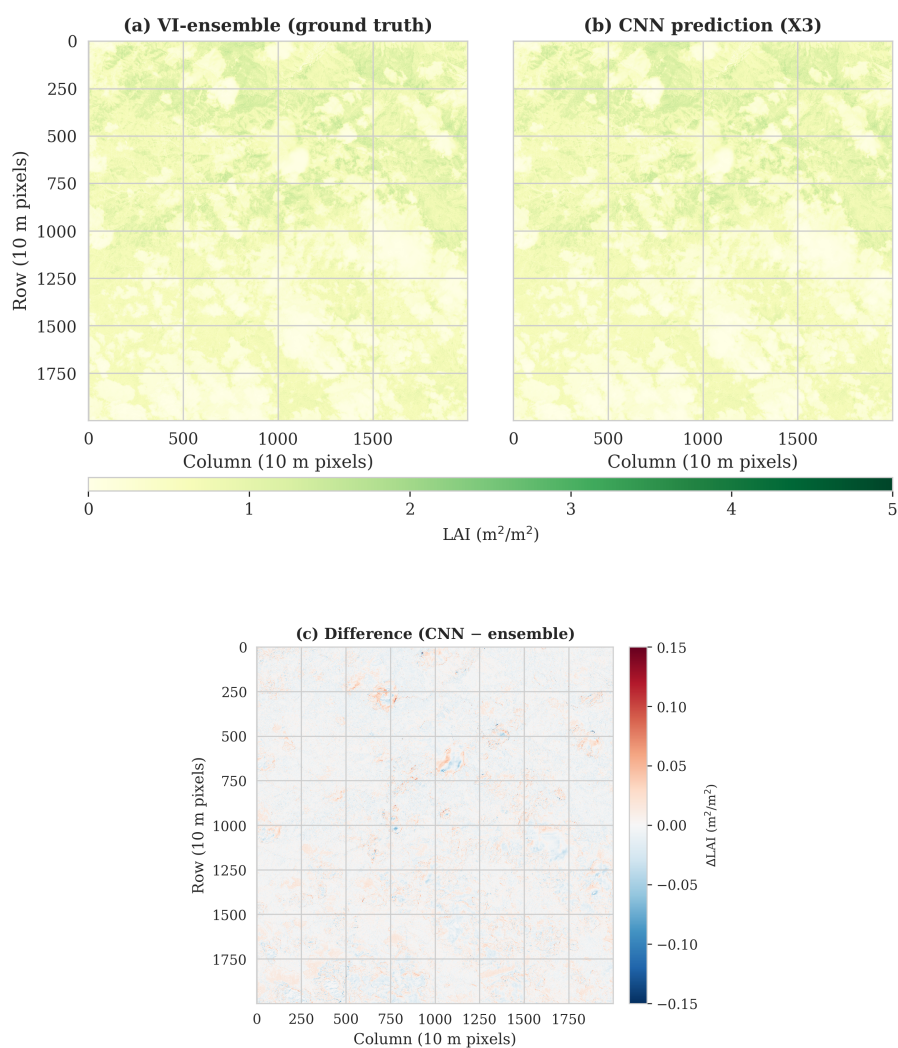
Оперативното внедряване изисква пълноценно извеждане при оригинална резолюция и интерпретируемо сравнение с установени LAI продукти. Тази секция валидира CNN в мащаб на сцена спрямо нейните VI-ensemble обучителни цели и сравнява прогнозите с ESA SNAP Biophysical Processor като независима референция.

Пълноценен CNN спрямо VI-Ensemble


Обученият модел (X3) е приложен към всички пловдивски сцени при пълна резолюция: Sentinel-2 сцени T34TGM и T35TLG (3,374 отрязъка) и Landsat 9 сцена LC09_183031 (14,145 отрязъка), общо 17,519 отрязъка. CNN постига почти перфектно възпроизвеждане на обучителните цели (Таблица 4.9), с $R^2 > 0.999$ за двата сензора, незначителен bias (<0.002 m²/m²) и variance ratio ≈ 1.0 , потвърждавайки, че пълният динамичен обхват на LAI е запазен без компресиране. Пълноценният RMSE (0.004-0.010 m²/m²) е значително под между-VI несъгласието (~ 0.036 m²/m²).

Таблица 4.9: Пълносценно сравнение на CNN спрямо VI-ensemble за всички пловдивски сцени (17,519 отрязъка).

Сензор	RMSE (m^2/m^2)	MAE (m^2/m^2)	R^2	Bias (m^2/m^2)	Var. Ratio
Sentinel-2	0.004	0.003	0.9998	-0.001	0.999
Landsat 8/9	0.010	0.007	0.9996	+0.002	0.998
Общо	0.007	0.005	0.9997	+0.001	0.999



Фигура 4.8: Представителен 20×20 km подрегион от пловдивската сцена T34TGM (120.6 милиона валидни пиксела). LAI карти, сравняващи VI-ensemble (горе-ляво), CNN прогноза (горе-дясно) и пикселна разлика (долу).

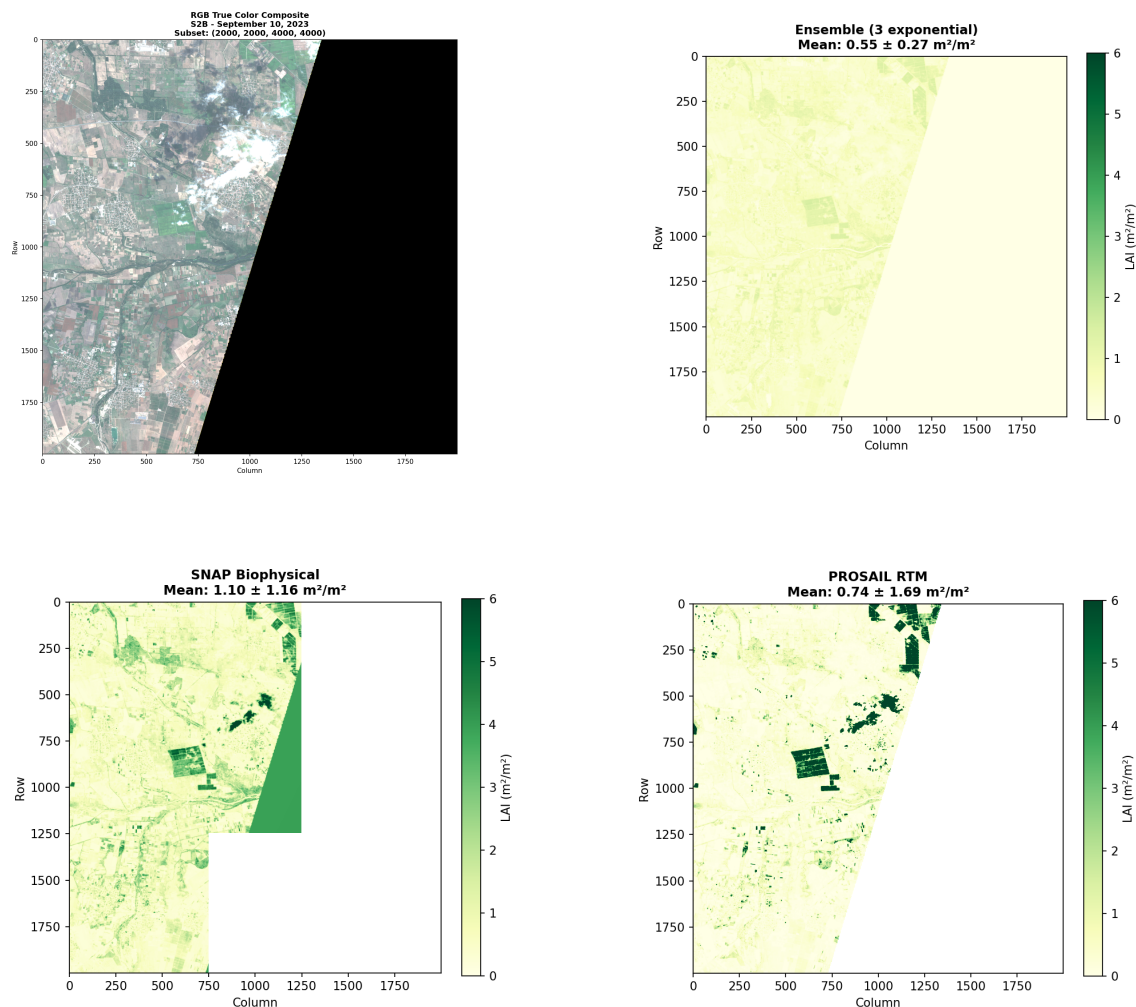


Фигура 4.9: Scatter диаграма с плътност на CNN прогнозите спрямо VI-ensemble целите за пловдивската сцена T34TGM.

Визуалната инспекция (Фигури 4.8 и 4.9) разкрива подобрена пространствена кохерентност в CNN прогнозите в сравнение с пикселните VI-ensemble карти, които проявяват шум тип “сол и пипер” в хетерогенни области. Пространственото рецептивно поле на U-Net действа като научен филтър, потискащ некохерентните пикселни флуктуации, като запазва истинската вариабилност на ниво поле и резките гранични преходи.

Сравнение с ESA SNAP Biophysical Processor

SNAP Biophysical Processor (v2.1, SNAP 9.0) предоставя глобално калибриран LAI продукт, базиран на Multi Layer Perceptron (MLP), обучен върху PROSAIL симулации. Фигура 4.10 сравнява трите подхода за оценка над изследвания район. VI-ensemble произвежда най-консервативните оценки (среден LAI = $0.55 \text{ m}^2/\text{m}^2$, $\text{CV} = 0.49$), SNAP дава по-високи стойности ($\bar{x} = 1.10 \text{ m}^2/\text{m}^2$) с по-голяма пространствена дисперсия, а PROSAIL RTM инверсията проявява най-широкия динамичен обхват, но страда от нестабилност на инверсията. Въпреки разликите в абсолютните стойности, всички методи са съгласувани в относителното подреждане на пикселите по LAI, като най-силното съгласие е между VI-ensemble и SNAP ($r_s = 0.87$, $r_p = 0.77$, $p < 0.001$), т.е. съгласуват се къде растителността е по-гъста.



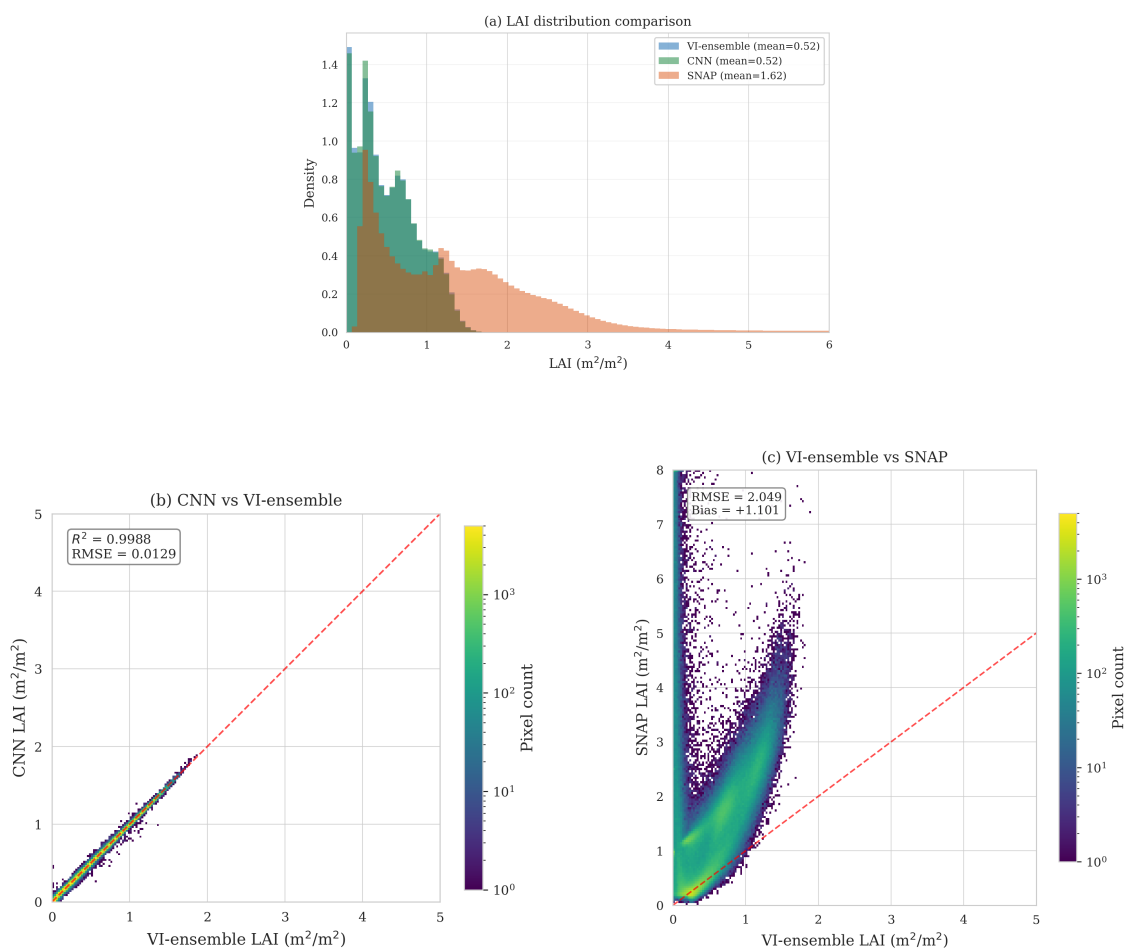
Фигура 4.10: Пространствено сравнение на методите за оценка на LAI за Sentinel-2B сцена T35TLG.

По отношение на абсолютните стойности обаче двата метода се разминават значително (Таблица 4.10, Фигура 4.11): $RMSE = 1.987 \text{ m}^2/\text{m}^2$, $R^2 = 0.312$, което е очаквано, а не индикативно за провал. SNAP прогнозира средно по-висок LAI ($\bar{x} = 1.10$ спрямо $0.55 \text{ m}^2/\text{m}^2$ за VI-ensemble), като разминаването е най-изразено при гъста растителност, където VI-ensemble се насища, докато SNAP продължава да нараства. Variance ratio = 0.421 индикира по-широк динамичен обхват на SNAP спрямо VI-ensemble. Това разминаване отразява четири фактора: (1) различни дефиниции на LAI – SNAP оценява ефективен LAI (включващ незелени растителни елементи), докато VI-ensemble оценява зелен LAI; (2) различни парадигми за калибрация – SNAP използва глобално калибрани PROSAIL симулации, VI-ensemble използва емпирични земеделски зависимости; (3) различни механизми на насищане; и (4) пикселната обработка на SNAP спрямо пространствената регуляризация на CNN, базирана на фрагменти.

Таблица 4.10: Тристранно сравнение: CNN, VI-ensemble и SNAP
Biophysical Processor (само Sentinel-2).

Сравнение	RMSE (m^2/m^2)	MAE (m^2/m^2)	R^2	Bias (m^2/m^2)	Var. Ratio
CNN спрямо VI-Ensemble	0.004	0.003	0.9998	-0.001	0.999
SNAP спрямо VI-Ensemble	1.987	1.542	0.312	-1.124	0.421
CNN спрямо SNAP	1.989	1.545	0.308	-1.125	0.418

Забележка: Разминаването на SNAP отразява различни дефиниции на LAI и парадигми за калибрация, а не провал на модела.



Фигура 4.11: Сравнение на оперативни продукти.

CNN точно възпроизвежда своята обучителна парадигма. Двата подхода служат за допълващи се цели: SNAP предоставя глобално съгласуван, физически обоснован продукт, който не изисква локална калибрация, докато CNN предлага локално оптимизирани, пространствено кохерентни прогнози, използващи мулти-сензорна синергия. Примиряването на тези парадигми би изисквало полево измерен LAI като независима референция.

4.5 Мащабируема високопроизводителна изчислителна рамка за пълноценно LAI картографиране

Цялостното обучение на модела, изводите и мащабната обработката на данни са проведени на суперкомпютъра **HEMUS**, което позволи ефективна обработка на мултиспектралните сателитни сцени с пълна резолюция. В тази работа е използван единичен GPU изчислителен възел със спецификациите в Таблица 4.11.

Таблица 4.11: Хардуерни спецификации на изчислителния възел на HEMUS.

Компонент	Спецификация
GPU	NVIDIA A100 (40 GB HBM2e)
GPU изчислителна способност	8.0 (архитектура Ampere)
GPU FP32 / TF32 / FP16	19.5 / 156 / 312 TFLOPS
CPU	128 ядра
Системна RAM	503 GB

Софтуерният стек включва PyTorch 2.1.2 (CUDA 12.1), Python 3.11.7 и поддържащи библиотеки (NumPy, Rasterio, GDAL, Scikit-learn), управлявани чрез Conda среда за възпроизводимост. ESA SNAP е използван за генериране на биофизични продукти.

Ефективност на обучението

Tensor ядрата на A100 поддържат аритметика със смесена точност (FP16 в FP32), позволявайки Automatic Mixed Precision обучение, което удвоява производителността без измерима числена нестабилност. Експеримент X3 (28.65M параметъра) завършва за 35.1 минути, конвергирайки на епоха 29 от 45 (early stopping с patience 15) при приблизително 1,500 отрязъка/секунда.

Мащабна обработка

Пълноценното извеждане за една Sentinel-2 сцена ($10,980 \times 10,980$ пиксела, ~ 120 милиона валидни пиксела) завършва за по-малко от две минути. Разделянето на отрязъци от четири сателитни сцени включва обработка на приблизително 40 GB растерни данни в $\sim 50,000$ геореферирани двойки. Системната RAM от 503 GB е критична за тези операции, тъй като зареждането на ко-регистрирани растери с пълна резолюция едновременно надвишава типичния капацитет на работна станция.

Ключов компонент на предложената изчислителна рамка за пълноценно извеждане, базирана на пачове, с реконструкция, отчитаща припокриването, която осигурява пространствена непрекъснатост и елиминира граничните артефакти.

Пълноценното извеждане за една Sentinel-2 сцена ($10,980 \times 10,980$ пиксела, 120 милиона валидни пиксела) завършва за по-малко от две минути. Разделянето на отрязъци от четири сателитни сцени включва обработка на около 40 GB растерни данни в 50,000 геореферирани двойки. Системната RAM от 503 GB е критична за

тези операции, тъй като едновременно зареждане на ко-регистрирани растери с пълна резолюция надвишава типичния капацитет на работна станция.

Изградената рамка предоставя мащабируема и физически консистентна изчислителна верига за оценка на LAI върху цяла сцена, позволявайки директен преход към оперативни продукти за наблюдение на Земята в голям мащаб.

Глава 5. Заключение

5.1 Основни приноси

В дисертационния труд са получени следните научни, научно-приложни и приложни приноси:

Научни приноси:

1. Разработен е мулти-сензорен модел за дълбоко самообучение, интегриращ U-Net, Conditional Batch Normalization и Atrous Spatial Pyramid Pooling в единна архитектура за сензорно-инвариантно обучение без предварително уеднаквяване на входните данни. Подходът е валидиран със Sentinel-2 и Landsat 8/9 при оценка на индекса на листна маса (LAI).
2. Предложен е метод за балансиране на обучението при мулти-сензорни данни чрез аугментация и изравняване на участието на отделните сензори в рамките на обучителните епохи. Идентифициран е режим на деградация при дисбаланс в броя обучителни примери, при който мажоритарният сензор доминира и ограничава междусензорната обобщаваща способност. Балансирането на участието на сензорите осигурява стабилна работа на Conditional Batch Normalization и сензорно-инвариантно обучение при неравномерно разпределени данни.
3. Разработена е методология за генериране на псевдо-еталонни LAI данни чрез ансамблов комбинирание на Beer-Lambert трансформирани вегетационни индекси (NDVI, GNDVI и SAVI). Избраните индекси осигуряват допълваща чувствителност към плътността на растителната покривка, съдържанието на хлорофил и почвения фон, като същевременно са сензорно-агностични спрямо Sentinel-2 и Landsat 8/9. Подходът позволява обучение на дълбоки невронни модели при липса на мащабни полеви измервания.
4. Предложена е многостепенна рамка за валидация на модели за оценка на LAI при кръговост в обучителните етикети, базирани на вегетационни индекси. Рамката интегрира пет нива: (1) пространствена блокова кръстосана валидация върху 4x4 географска мрежа, (2) сравнение с оперативни продукти (SNAP Biophysical Processor), (3) физически базирана проверка чрез PROSAIL, (4) анализ на географска и времева преносимост чрез zero-shot трансфер и междусензорна съгласуваност, (5) сравнителен анализ спрямо емпирични вегетационни индекси

и техния ансамбъл. Подходът осигурява възпроизводим протокол за валидация без пространствено изтичане на данни, оценяващ статистическата устойчивост, физическата съгласуваност и пространствено-времевата генерализация.

Научно-приложни приноси:

5. Реализирана е цялостна методология за оценка на индекса на листна маса (LAI) от мулти-сензорни сателитни данни върху земеделски райони в България, базирана на свободно достъпни изображения от Sentinel-2 и Landsat 8/9.
6. Експериментално е доказано, че предложеният мулти-сензорен модел превъзхожда едносензорните подходи и класическите вегетационни индекси, като при пространствено строга валидация са постигнати значителни подобрения на точността при оценката на LAI.
7. Демонстрирана е възможност за географска и времева генерализация на предложения модел чрез успешно прилагане върху независими региони и изображения, придобити в различни периоди без допълнително обучение.

Приложен принос:

8. Разработена е интегрирана изчислителна рамка за обработка на многоспектрални сателитни изображения, обучение на дълбоки невронни модели и генериране на пълноценни карти на LAI върху високопроизводителна инфраструктура. Извеждането на резултати от цели сцени се осъществява чрез плъзгащ се прозорец с безшевно сливане на припокриващи се фрагменти, което осигурява непрекъснати изходни карти за ландшафтен мониторинг.

5.2 Бъдещи насоки

Няколко разширения биха укрепили и разширили настоящата работа. Включването на слънчева и наблюдателна геометрия като допълнителни входове на модела или прилагането на експлицитна BRDF корекция би могло да подобри устойчивостта при различни условия на осветяване, без да се изисква пълна ъглова нормализация [4, 40]. Съвременна безоблачна сцена от WorldView-3 (8 VNIR канала при 1.24 m, септември 2023) вече е налична за изследвания регион; фина настройка на Експеримент X3 с тези данни чрез добавяне на трета сензорна идентичност към рамката на Conditional Batch Normalisation би тествала дали спектрално-LAI представянията, научени при 10-30 m, се трансферират ефективно към субметрова разделителна способност, позволявайки ефективни приложения в прецизното земеделие. Най-критичната следваща стъпка е дообучение с полево измерени LAI референтни данни за количествено определяне на систематичните отклонения на VI-ensemble подхода и преход на рамката от оперативна оценка с псевдо-етикети към напълно калибрирано извличане на биофизични параметри. Накрая, разширяването на PROSAIL forward моделирането към Landsat 8/9 чрез конволюция на спектралния отклик на OLI [2, 21] би позволило сензорно-агностични, физически базирани етикети.

5.3 Публикации, свързани с дисертационния труд

- Polimenov, V.; Ivanova, Kr.: *Remote Sensing and Deep Learning Integration for Spatial Intelligence*. International Multidisciplinary Scientific GeoConference Surveying Geology and Mining Ecology Management (SGEM 2024), 24, 2.1, 2024, ISSN:1314-2704, pp. 275-282, <https://doi.org/10.5593/sgem2024/2.1/s10.33>
- Polimenov, V.; Ivanova, Kr.; Tsvetkova, M.; Anastasova, E.; Dimitrova, K.: *Calculating Leaf Area Index Using Neural Network and WorldView 3 Multispectral Imagery*. 59th International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST 2024), 2024, ISSN:2603-3267, pp. 1-4, <https://doi.org/10.1109/ICEST62335.2024.10639753>
- Tsvetkova, M.; Anastasova, E.; Polimenov, V.; Djamiykov, T.; Dimitrova, K.: *Remote Sensing for Smart Agriculture Monitoring Pepper Crops*. XXXIII International Scientific Conference Electronics (ET 2024), Sozopol, Bulgaria, 2024, ISBN: 979-835037644-9, pp. 1-4, <https://doi.org/10.1109/ET63133.2024.10721488>.

Последната публикация към края на април 2026 г. е цитирана от 2 публикации.

5.4 Докладване на елементи от дисертационното изследване

- Polimenov, V.: *Application of Artificial Intelligence Algorithms for Identification of Leaf Areas from Satellite Imagery*. 4th Interdisciplinary PhD forum with international participation, 16-19.05.2023, Sandanski, Bulgaria.
- Polimenov, V., Ivanova, Kr.: *Remote Sensing and Deep Learning Integration for Spatial Intelligence*. XXIV International Multidisciplinary Scientific GeoConference Surveying Geology and Mining Ecology Management (SGEM 2024), 29.06-08.07.2024, Albena, Bulgaria.
- Polimenov et al.: *Calculating Leaf Area Index Using Neural Network and WorldView 3 Multispectral Imagery*. 59th International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST 2024), 01-03.07.2024, Sozopol, Bulgaria.
- Polimenov, V., Ivanova, Kr.: *Deep Learning Techniques for Supporting Remote Sensing*. National Seminar of Coding Theory "Professor Stefan Dodunekov 21-24.11.2024, Arbanasi, Bulgaria.
- Polimenov, V.: *ANNSIA (Adaptive Neural Network for Satellite Image Analysis) – Methodology, Experiments and Main Contributions*. Annual Scientific Session of the Institute of Mathematics and Informatics, 02.12.2025 (SofTIS Dept.), Sofia, Bulgaria.

Благодарности

Бих искал да изразя искрената си благодарност към моя научен ръководител, Красимира Иванова, за нейните насоки, търпение и многобройните ползотворни разговори, които насочиха тази работа към успешното ѝ завършване. Нейната подкрепа през целия процес на докторантурата беше безценна.

Изключително съм благодарен на Камен Илиев и екипа на RST-TTO за първоначалния тласък, който постави началото на тази работа, за идеите, данните и възможностите, щедро споделяни по пътя, както и за постоянната интелектуална ангажираност, оформила голяма част от представеното тук.

Бих искал също да благодаря на Ивелин Иванов за полезните дискусии относно изграждането на целевите данни, както и за обясненията и предложенията, които съществено допринесоха за изграждането на методологията.

Изчислителните експерименти, представени в тази дисертация, бяха проведени върху високопроизводителния изчислителен клъстер HEMUS и съм благодарен за предоставения достъп и подкрепа.

Накрая, дължа дълбока благодарност на моето семейство, чиято безусловна подкрепа и доверие ми помогнаха да премина през най-предизвикателните етапи на това пътуване.

Библиография

1. Amato, M. T. & Giménez, D. Predicting monthly near-surface soil temperature from air temperature and the leaf area index. *Agricultural and Forest Meteorology* **345**. <https://doi.org/10.1016/j.agrformet.2023.109838> (2024).
2. Barsi, J. A., Lee, K., Kvaran, G., Markham, B. L. & Pedelty, J. A. The spectral response of the Landsat-8 operational land imager. *Remote Sensing* **6**, 10232—10251 (2014).
3. Brown, L. A., Dash, J., Lidón, A., Lopez-Baeza, E. & Dransfeld, S. Validation of Sentinel-2 LAI products with ground reference data collected across Europe. *Remote Sensing* **11**, 637. <https://doi.org/10.3390/rs11060637> (2019).
4. Camps-Valls, G., Tuia, D., Zhu, X. X. & Reichstein, M. Physics-aware machine learning. *Nature Reviews Earth & Environment* **2**, 736—752. <https://doi.org/10.1038/s43017-021-00202-5> (2021).
5. Chen, L.-C., Papandreou, G., Schroff, F. & Adam, H. Rethinking atrous convolution for semantic image segmentation. *arXiv preprint arXiv:1706.05587*. Published at CVPR 2018 (2017).
6. Clevers, J. G. P. W. The application of a weighted infrared-red vegetation index for estimating leaf area index by correcting for soil moisture. *Remote Sensing of Environment* **29**, 25—37. [https://doi.org/10.1016/0034-4257\(89\)90076-X](https://doi.org/10.1016/0034-4257(89)90076-X) (1988).
7. Daudt, R. C., Le Saux, B. & Boulch, A. Fully convolutional siamese networks for change detection. *IEEE International Conference on Image Processing (ICIP)*, 4063—4067. <https://doi.org/10.1109/ICIP.2018.8451652> (2018).
8. De Vries, H. *u dp*. Modulating early visual processing by language. *Advances in Neural Information Processing Systems (NeurIPS)*, 6594—6604 (2017).
9. Diakogiannis, F. I., Waldner, F., Caccetta, P. & Wu, C. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data. *ISPRS Journal of Photogrammetry and Remote Sensing* **162**, 94—114 (2020).
10. Dumoulin, V., Shlens, J. & Kudlur, M. A learned representation for artistic style. *International Conference on Learning Representations (ICLR)* (2017).
11. Fang, H., Baret, F., Plummer, S. & Schaepman-Strub, G. An overview of global leaf area index (LAI): Methods, products, validation, and applications. *Reviews of Geophysics* **57**, 739—799. <https://doi.org/10.1029/2018RG000608> (2019).
12. Galle, N. J. *u dp*. Correlation of WorldView-3 spectral vegetation indices and soil health indicators of individual urban trees with exceptions to topsoil disturbance. *City and Environment Interactions* **11**. <https://doi.org/10.1016/j.cacint.2021.100068> (2021).
13. Gitelson, A. A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. *Journal of Plant Physiology* **161**, 165—173. <https://doi.org/10.1078/0176-1617-01176> (2004).
14. Gitelson, A. A., Kaufman, Y. J. & Merzlyak, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment* **58**, 289 – 298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7) (1996).
15. Guo, A. *u dp*. Inversion of maize leaf area index from UAV hyperspectral and multispectral imagery. *Computers and Electronics in Agriculture* **212**, 108020. <https://doi.org/10.1016/j.compag.2023.108020> (2023).

16. Han, D. *u dp.* Combining Sentinel-1 and -3 imagery for retrievals of regional multitemporal biophysical parameters under a deep learning framework. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **15**, 6985 – 6998. <https://doi.org/10.1109/JSTARS.2022.3200735> (2022).
17. Huete, A. R. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* **25**, 295—309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X) (1988).
18. Huete, A. *u dp.* Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* **83**, 195—213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2) (2002).
19. Igllovikov, V. & Shvets, A. TerausNet: U-Net with VGG11 encoder pre-trained on ImageNet for image segmentation. *arXiv preprint arXiv:1801.05746* (2018).
20. Ioffe, S. & Szegedy, C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International Conference on Machine Learning (ICML)*, 448—456 (2015).
21. Jacquemoud, S. *u dp.* PROSPECT+SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment* **113**, S56—S66. <https://doi.org/10.1016/j.rse.2008.01.026> (2009).
22. Jonckheere, I. *u dp.* Review of methods for in situ leaf area index determination Part I. Theories, sensors and hemispherical photography. *Agricultural and Forest Meteorology* **121**, 19 – 35. <https://doi.org/10.1016/j.agrformet.2003.08.027> (2004).
23. Kamilaris, A. & Prenafeta-Boldú, F. X. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture* **147**, 70—90. <https://doi.org/10.1016/j.compag.2018.02.016> (2018).
24. Kattenborn, T., Leitloff, J., Schiefer, F. & Hinz, S. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* **173**, 24—49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010> (2021).
25. Liu, Y. *u dp.* The fusion of vegetation indices increases the accuracy of cotton leaf area prediction. *Frontiers in Plant Science* **15**, 1357193 (2024).
26. Loshchilov, I. & Hutter, F. SGDR: Stochastic gradient descent with warm restarts. *International Conference on Learning Representations (ICLR)*. arXiv:1608.03983 (2017).
27. Loshchilov, I. & Hutter, F. Decoupled weight decay regularization. *International Conference on Learning Representations (ICLR)*. arXiv:1711.05101 (2019).
28. Louis, J. *u dp.* Sentinel-2 Sen2Cor: L2A processor for users. *Proceedings of the Living Planet Symposium*, 1—8 (2016).
29. Lv, F., Sun, K., Li, W., Miao, S. & Hu, X. Estimation of Leaf Area Index across biomes and growth stages combining multiple vegetation indices. *Sensors* **24**, 6106 (2024).
30. Myneni, R. B., Hall, F. G., Sellers, P. J. & Marshak, A. L. Interpretation of spectral vegetation indexes. *IEEE Transactions on Geoscience and Remote Sensing* **33**, 481 – 486. <https://doi.org/10.1109/36.377948> (1995).
31. NASA. *Landsat 8* <https://science.nasa.gov/mission/landsat-8/>. Accessed 11.01.2026. 2013.
32. NASA. *Landsat 9* <https://science.nasa.gov/mission/landsat-9/>. Accessed 11.01.2026. 2021.

33. Peng, Y., Nguy-Robertson, A., Arkebauer, T. & Gitelson, A. A. Assessment of canopy chlorophyll content retrieval in maize and soybean: Implications of hysteresis on the development of generic algorithms. *Remote Sensing* **9**, 226. <https://doi.org/10.3390/rs9030226> (2017).
34. Radočaj, D., Obhodaš, J., Jurišić, M. & Gašparović, M. Global Open Data Remote Sensing Satellite Missions for Land Monitoring and Conservation: A Review. *Land* **9**. <https://doi.org/10.3390/land9110402> (2020).
35. Ronneberger, O., Fischer, P. & Brox, T. U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, 234—241. https://doi.org/10.1007/978-3-319-24574-4_28 (2015).
36. Rustowicz, R. *u dp*. Semantic segmentation of crop type in Africa: A novel dataset and analysis of deep learning methods. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, 75—82 (2019).
37. Shen, W., Li, M., Huang, C. & Wei, A. Quantifying live aboveground biomass and forest disturbance of mountainous natural and plantation forests in Northern Guangdong, China, based on multi-temporal Landsat, PALSAR and field plot data. *Remote Sensing* **8**, 595. <https://doi.org/10.3390/rs8070595> (2016).
38. Szwarcman, D. *u dp*. Prithvi-EO-2.0: A versatile multi-temporal foundation model for Earth observation applications. *arXiv preprint arXiv:2412.02732*. <https://arxiv.org/abs/2412.02732> (2024).
39. Tucker, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* **8**, 127—150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0) (1979).
40. Verrelst, J. *u dp*. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties – A review. *ISPRS Journal of Photogrammetry and Remote Sensing* **108**, 273—290. <https://doi.org/10.1016/j.isprsjprs.2015.05.005> (2015).
41. Verrelst, J. *u dp*. Quantifying vegetation biophysical variables from imaging spectroscopy data: A review on retrieval methods. *Surveys in Geophysics* **40**, 589—629. <https://doi.org/10.1007/s10712-018-9478-y> (2019).
42. Vlachopoulos, O. *u dp*. Evaluation of crop health status with UAS multispectral imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* **15**, 297 – 308. <https://doi.org/10.1109/JSTARS.2021.3132228> (2022).
43. Weiss, M., Jacob, F. & Duveiller, G. Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment* **236**, 111402. <https://doi.org/10.1016/j.rse.2019.111402> (2020).
44. Zhang, C., Marzougui, A. & Sankaran, S. High-resolution satellite imagery applications in crop phenotyping: An overview. *Computers and Electronics in Agriculture* **175**, 105584. <https://doi.org/10.1016/j.compag.2020.105584> (2020).
45. Zhang, K. *u dp*. Panchromatic and multispectral image fusion for remote sensing and earth observation: Concepts, taxonomy, literature review, evaluation methodologies and challenges ahead. *Information Fusion* **93**, 227 – 242. <https://doi.org/10.1016/j.inffus.2022.12.026> (2023).
46. Zhang, Z., Liu, Q. & Wang, Y. Road extraction by deep residual U-Net. *IEEE Geoscience and Remote Sensing Letters* **15**, 749—753. <https://doi.org/10.1109/LGRS.2018.2802944> (2018).
47. Zhu, X. X. *u dp*. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine* **5**, 8—36. <https://doi.org/10.1109/MGRS.2017.2762307> (2017).

Съдържание

1	Увод	3
1.1	Описание на проблема	3
1.2	Цели и задачи	4
1.3	Хипотези	5
1.4	Структура на дисертацията	5
2	Изследователски контекст	6
2.1	Литературен обзор	6
2.2	Сателитни изображения и тяхното приложение за наблюдение на Земята	6
2.3	Дистанционни изследвания за оценка на LAI – еволюция на методите	8
2.4	Архитектури за дълбоко самообучение за плътна оценка на LAI . . .	10
3	Методология	12
3.1	Генериране на LAI референтни данни	13
3.2	Обработка на данни, обучение и извеждане	15
3.3	Методология за валидиране	20
4	Експерименти и резултати	22
4.1	Експериментална конфигурация	22
4.2	Пространствено строга валидация	27
4.3	Валидация на обобщаването	30
4.4	Оперативна валидация	33
4.5	Масшабируема високопроизводителна изчислителна рамка за пълноценно LAI картографиране	38
5	Заключения	39
5.1	Основни приноси	39
5.2	Бъдещи насоки	40
5.3	Публикации, свързани с дисертационния труд	41
5.4	Докладване на елементи от дисертационното изследване	41
	Библиография	43