

АГРАРЕН УНИВЕРСИТЕТ - ПЛОВДИВ

АГРОНОМИЧЕСКИ ФАКУЛТЕТ

КАТЕДРА РАСТЕНИЕВЪДСТВО

ИВЕЛИН ДИМИТРОВ МАРКОВ

**ПРОУЧВАНЕ ВЛИЯНИЕТО НА РАЗЛИЧНИ ПРАКТИКИ ЗА
УСТОЙЧИВО УПРАВЛЕНИЕ НА ТРЕВНАТА СИСТЕМА ВЪРХУ
СЕКВЕСТИРАНЕТО НА С В ПОЧВАТА ПРИ ИНТЕНЗИВНО
ПОДДЪРЖАНЕ НА ПЪТИНГ ГРИЙНОВЕ НА ПЯСЪЧНА ОСНОВА И
ВЪРХУ ГОДИШНИЯ ВЪГЛЕРОДЕН БЮДЖЕТ.**

АВТОРЕФЕРАТ

На дисертация за присъждане на образователната и научна степен

“ Доктор ”

Научна специалност „Фуражно производство и ливадарство“

Научен ръководител:

Доц. д-р Атанас Севов

ПЛОВДИВ

2026

Изследванията са проведени през периода 2019 – 2025 година на две голф игрища в България и Китай.

Дисертацията е с обем 243 страници и съдържа 43 таблици и 94 фигури. Цитираната литература включва 456 източника на латиница.

Дисертационния труд е обсъден на разширен катедрен съвет на катедра „Растениевъдство“ при Агрономическия факултет на Аграрния Университет – Пловдив.

Защитата на дисертацията ще се състои на . .2026 г. от часа в заседателната зала на АУ – Пловдив пред Специализирано научно жури, утвърдено със Заповед на Ректора РД- от . .2026 г.

Рецензии от :

Становища от:

Материалите по защитата са на разположение на интересуващите се в библиотеката на Аграрния университет – Пловдив, бул. „Менделеев“ № 12.

Моля отзивите и бележките да се изпращат на адрес:

Ivomarkov2003@yahoo.com

1 Увод

Тревните системи заемат значителен дял от глобалната земна повърхност, като тревните площи покриват приблизително 31 до 43% от общата суша. Наред с естествените тревни съобщества, бързо нарастващ дял от тази покривка вече се формира от управляван тревен чим в градска и извън градска среда. Нарастващата урбанизация заменя гори и земеделски земи с поддържани зелени площи като ливади, паркове, спортни терени и голф игрища. В Съединените щати интензивно поддържаните градски тревни системи се оценяват на около 163 800 km², приблизително 2% от континенталната територия на страната, и площ приблизително три пъти по-голяма от тази, използвана за напоявана царевица.

В рамките на тази зелена инфраструктура спортните терени и голф игрищата представляват високопрофилен и управляем интензивен компонент. Само в САЩ има приблизително 700 000 спортни терена и 16 750 голф игрища, при глобален общ брой 38 886 игрища. Съществено е, че 78% от голф игрищата в света са концентрирани само в 10 държави, което подчертава както географската концентрация, така и потенциалния екологичен отпечатък на интензивно управляваните тревни системи.

Голф игрищата, и по-специално пътинг грийновете, илюстрират напрежението между изискванията за игрови характеристики и екологичната отговорност. Игрите очакват гладки, бързи и визуално равномерни пътинг повърхности. Постигането на тези очаквания обикновено изисква интензивни практики като често косене при много ниска височина, прецизно торене и планирано напояване. Тези операции могат да бъдат ресурсоемки, увеличавайки потреблението на вода, енергия и хранителни елементи, като едновременно повишават риска от нежелани последствия, например отмиване на хранителни вещества, когато нормите не са съобразени с потребностите на растенията и капацитета на задържане на почвата.

В същото време мениджърите на голф игрища са под нарастващ натиск от регулаторни рамки и обществени очаквания да намаляват химичните привнесания, да пестят вода и да демонстрират отговорно управление. Това двойно изискване, максимални ниво на игрово качество плюс устойчивост, създава силна необходимост от подходи, които са едновременно физиологично обосновани и оперативно приложими, така че решенията да се адаптират към променящите се метеорологични и стресови условия, вместо да се разчита на статични графици.

Почвите са централен компонент на глобалния въглероден цикъл, като съхраняват повече въглерод от атмосферата и наземната растителност взети заедно. Управляваните тревни системи могат да допринесат за улавяне на въглерод чрез продукцията на коренова биомаса и натрупване на органична материя на повърхността и в коренообитаемия слой. Нетната климатична полза от тревните системи обаче зависи от това как управлението влияе както върху въглеродните входове (биомаса, натрупване на органична материя), така и върху въглеродните разходи

(енергопотребление при интензивна поддръжка, емисии, свързани с торове, и ускорен кръговрат на хранителните елементи).

Голф игрищата са хетерогенни системи, при които интензивно управляваните грийнове и тий комплекси обикновено съставляват едва около 5% от поддържаната тревна площ, докато феъруите и ръфовете представляват съответно приблизително 25 до 35% и 60%. По-големите площи с по-ниски входове могат да действат като въглеродно отлагащи депа при консервативно управление, докато интензивните входове и честите механични операции увеличават емисиите на парникови газове и обръщат въглеродните печалби. Следователно основното предизвикателство не е просто дали тревните системи могат да съхраняват въглерод, а как управлението може да измести годишния въглероден бюджет към нетно улавяне, без да се компрометира функционалното представяне на игровата повърхност.

Нарастващата загриженост относно климатичните промени, недостига на вода и оттока на хранителни вещества налага прилагането на Precision Turfgrass Management (PTM). Макар прецизните инструменти да са широко разпространени в земеделието, тяхното внедряване в тревните системи остава сравнително ограничено. Интегрирането на сензори в реално време за почва и метеорологични условия, вегетативни индекси (VIs) от UAV или сателитни изображения и AI-базираните аналитични подходи създава възможност за повишаване на ефективността на напояването и торенето, намаляване на загубите на хранителни вещества и по-ранно и по-прецизно пространствено откриване на стрес в тревния чим в сравнение единствено с визуалното наблюдение. Тези възможности подпомагат преход от реактивно управление към предиктивно, основано на доказателства планиране.

Съвременните високоефективни голф грийнове обичайно се изграждат по спецификации на USGA или California, използвайки пясъчни коренообитаеми профили (обикновено най-малко 90% пясък) с добавки за подобряване на водо- и хранително-задържащите свойства. Пясъчните профили осигуряват бързо дрениране, твърди игрови повърхности и по-нисък риск от уплътняване, което е съществено при постоянен трафик и механичен стрес.

Тези предимства по отношение на игровите характеристики създават и присъщи управленски ограничения. Пясъкът има нисък катионообменен капацитет и ограничена водозадържаща способност; следователно водните и хранителните привнасяния могат бързо да се измиват или изчерпват, ако не се прилагат прецизно. В условия на горещини или суша влагодефицит може да се развие за кратко време. В резултат пясъчно-базираните грийнове изискват внимателно планиране и дозиране на напояването и торенето, за да се предотвратят както сушов стрес, така и прекомерно отмиване.

За да се постигнат постоянно и контролирано движение на топката по повърхността и визуална естетика, грийновете обикновено се косят ежедневно (а понякога два пъти дневно при турнирни условия) при височина от порядъка на 1,8 до 3 mm. Това ниско косене намалява листната площ, ограничава фотосинтезата и може да ограничи развитието на кореновата система, докато повтарящото се механично натоварване допринася за микроуплътняване. Тези стресове често водят до по-голяма зависимост от входове, които трябва да се управляват внимателно, за да се избегнат несъвместимости с целите за устойчивост.

Азотното торене е ключов фактор за качеството и функционалността на тревния чим, но често е източник на неефективност, когато не е съобразено с физиологичните потребности на отглеждания култивар. Излишъкът на азот може да увеличи растежа на надземната маса, натрупването на thatch и натиска от болести, докато недостигът на азот първо се отразява на цвета, гъстотата и възстановителния потенциал. В пясъчни системи, където задържането на хранителни елементи е ограничено, допустимата грешка е малка. Управлението на напояването е също толкова критично: поддържането на подходящо почвено обемно водно съдържание (VWC) изисква избягване както на сушов стрес, така и на пренапояване, като прецизното напояване все по-често се подпомага от почвени влагомери и съобразяване с Евапотранспирацията (ET). Грийновете подлежат и на аерация, вертикутиране, топдресинг и периодична скарификация за контрол на уплътняването и thatch. Тези интервенции са необходими, но ресурсоемки и могат временно да нарушат играта, което допълнително подчертава значението на оптимизирането на времето и интензивността им.

Пясъчно-базираните пътинг грийнове представляват управленски парадокс. Многогодишния тревен чим може да улавя въглерод чрез корени и натрупване на органична материя. В същото време високата интензивност на входовете и честите операции за овладяването му увеличават енергопотреблението и емисиите и ускоряват обмяната на хранителни елементи, което потенциално намалява нетните въглеродни ползи. Освен това прекомерното натрупване на органична материя може да компрометира игровите характеристики и функцията на коренообитаемия слой, дори ако увеличава въглеродното съхранение. Следователно научната и практическата цел е да се дефинират поддържащи режими, които запазват елитно качество на тревния чим, като едновременно подобряват нетния почвен въглероден баланс и намаляват ненужното използване на ресурси.

2 Материали и методи

Дисертационният труд е организиран в пет взаимосвързани части, които в съвкупност разглеждат устойчивото управление на интензивно поддържани пясъчно-базирани пътинг грийнове и предоставят входни данни за интегрирана SMART система за подпомагане на вземането на решения (DSS).

Част 1: Оптимизиране на азотното торене. Потребността от азот се моделира чрез температурно-базиран *growth potential* (GP), лагирани VI, и стрес-съотнесени променливи на средата, с цел подкрепа на адаптивно планиране в дневен до седмичен мащаб, с изводи, подходящи за оперативна интеграция в DSS.

Част 2: Оптимизиране на напояването. Напояване по фиксиран график се сравнява с подходи, базирани на ET, с фокус върху *distribution uniformity* (DU), VWC, реакцията на тревния чим и *water-use efficiency* (WUE). Резултатите дефинират прагове и параметри за планиране за интеграция в DSS.

Част 3: Развитие на кореновата система. Моделите на коренов растеж се определят количествено и се свързват с фактори на средата и управлението, включително контрастиращи стратегии за напояване. Целта е да се идентифицират параметри, които могат да информират прогнозно моделиране на кореновия растеж и да се свържат механистично с решенията за торене и напояване.

Част 4: Vegetation indices и дистанционни изследвания. Множество VIs се оценяват по чувствителност към напояване, торене и развитие на корените и се свързват с *in-situ* измервания (почвена влага, *clipping volume*, торене). Специално се разработва и обучава компютърно-зрителен UNet модел за класификация на елементи на голф игрището и предоставяне на пространствено детайлни управленски индикатори за DSS.

Част 5: AI-базирана байесова система за подпомагане на вземането на решения (BN-DSS). Изходите от Части 1 до 4 се интегрират в модулна Bayesian DSS, подпомогната от машинно обучение и *explainable AI* (SHAP), за предоставяне на специфични за обекта препоръки, които балансират качеството на тревния чим, съхранението на ресурси и целите за почвено улавяне на въглерод.

Методологичният работен процес е обобщен схематично на Фигура 3 (*Methodological workflow*), която свързва основната цел (почвено улавяне на въглерод и годишен въглероден бюджет при интензивно управлявани пясъчно-базирани пътинг грийнове) с четири второстепенни цели (оптимизиране на N торене, оптимизиране на норма на напояване, проследяване на развитие на корените и дистанционни изследвания/VIs) и с крайния резултат: AI-базирана SMART система за подпомагане на вземането на решения (DSS), изградена върху основа на Bayesian Network (BN).

Изследването прилага наблюдателен (нерепликиран) дизайн, вместо контролируем, репликиран полеви експеримент. Всяка локация представлява различен агроекологичен и управленски контекст, който отразява реалните ограничения при вземане на решения в поддръжката на голф игрища. Този дизайн ограничава строгото приписване на причина-следствие, но улавя реалистична хетерогенност и подобрява преносимостта на резултатите към оперативното управление на тревния чим. Сравненията между обектите се използват за разграничаване на стратегии с широко

приложима ефективност от такива, които изискват локално адаптиране. Грийновете са подбрани така, че да представят вариации в почвените характеристики, релефа (високи, средни и ниски нива) и управленската история.

Golf Course A (GCA) се намира при 43.41°N, 28.22°E, на около 1 km от Черно море, на 175 m надморска височина, с умерено-континентален климат, повлиян от близостта до морето (средногодишна T ~12°C; летни максимуми ~32°C; зимни минимуми ~-2°C; годишни валежи ~550 mm, концентрирани през пролетта/есента, с чести летни засушавания). Преобладаващите северо-североизточни ветрове в края на лятото увеличават ET и допринасят за влагов стрес. Вегетационните сезони 2023–2024 (1.03–30.10) бяха сухи (335 mm и 480 mm валежи), с по-топли условия през юли–август и повишен сезонен ET (910 mm и 955 mm).

Грийновете са изградени по спецификации на USGA (приблизително 95% пясък и 5% зеолит). След приблизително 12 години субоптимална поддръжка, повърхностната OM се натрупа до 6–8% в горните 5 cm, което намалява инфилтрацията и газообмена, стимулира плитко вкореняване и повишава риска от хидрофобност. Използвания култивар е *Agrostis Stolonifera*. Повърхностите са 16 годишни.

Исторически планирането на напояването не е тясно обвързано с измерване на почвена влага („deep and infrequent“ подход), сезонните приложения на N-P-K не съответстват напълно на физиологичната потребност на растенията, а културните практики се недостатъчни за ограничаване на натрупването на thatch. Височината на косене през вегетацията е 3.0–3.2 mm; валира се рядко, при събития.

Golf Course B (GCB) се намира при 39.16°N, 116.99°E, на около 10 m надморска височина и приблизително 70 km навътре от Бохайско море, с влажен континентален климат и силно мусонно влияние (горещи влажни лета до 35°C; годишни валежи ~590 mm; сумарни валежи за юли–август ~600 mm както през 2023, така и през 2024; студени сухи зими до -12°C).

Грийновете също са по USGA-базиран стандарт, с коренообитаем слой със състав 94% пясък, 4% нанос, 2% глина; pH 6.3–6.8; OM се поддържа около ~2.0%, което подпомага висока инфилтрация и стабилна водозадържаща способност. Управлението е силно структурирано: мониторинг на VWC (цел 18–22%), торене - основано на данни и съгласувано с почвени/тъканни анализи, месечна аерация/вертикутиране/леко топд्रेसиране (с увеличение на обема пясък през мусонните периоди), косене на 3 mm и валиране през ден. Използвания култивар е *Agrostis Stolonifera*. Повърхностите са 20 годишни.

Метеорологични и ET данни - Автоматизирани метеорологични станции на всеки обект регистрираха температура на въздуха, относителна влажност, слънчева радиация, скорост на вятъра и валежи на 15-мин интервали, като генерираха агрегирани почасови и дневни обобщения. Тези данни подпомогнаха: (i) GP, изчислен

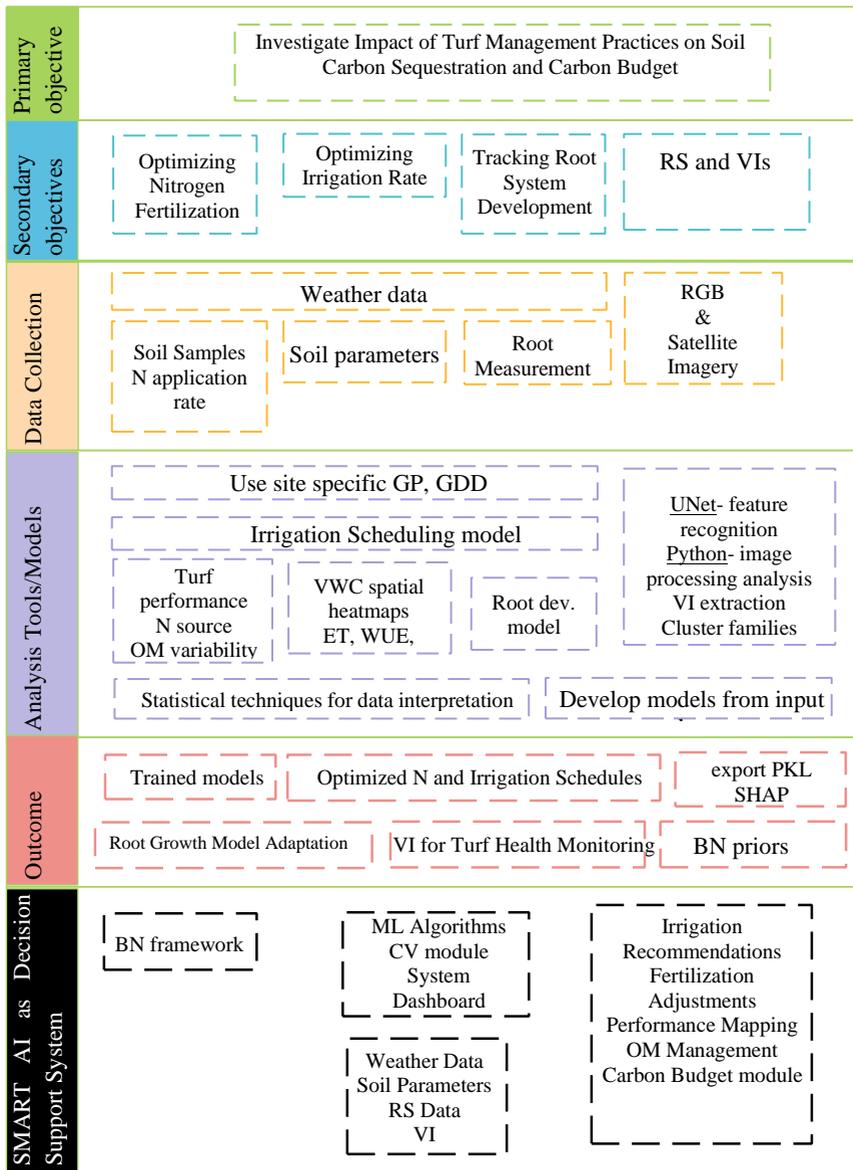


Figure 1. Methodological workflow

от температурата на въздуха за метаболитната активност на cool-season тревни видове и моделиране на потребността от N; (ii) ET_0 , оценен чрез уравнението на Penman–Monteith; и (iii) K_s стойности, извлечени от литературата за cool-season тревни видове

и сезонно коригирани, като за анализите на напояването се използваше $ET_c = ET_0 \times K_c$. Метеорологичните и ET изходи се обединени с ежедневно отчетени обем откос, почвена влага, VI и управленски дневници в времево съгласувани набори от данни, използвани във всичко моделиране.

Почвени и коренообитаеми измервания - Почвени проби бяха взети и на двете локации на дълбочини 0–25 mm, 25–50 mm и 50–75 mm, използвайки стандартен почвен екстрактор. Пробите бяха анализирани за pH, общ N, P, K, разпределение на OM по дълбочина и общ въглерод, следвайки стандартни протоколи (Kjeldahl за N; Mehlich-3 за P и K). Пробонабирането беше насочено към периоди на пикова растежна активност и преходни фази (пролетно позеленяване; есенно забавяне), за да се улови сезонната динамика на хранителните елементи и да се подпомогнат оценките на почвения C запас и връзките му с практиките на управление.

VWC - Ръчни TDR сензори измерваха VWC на стандартизирана дълбочина (150 mm), с периодични проверки спрямо автоматизирани сонди. При GCA VWC се измерва на фиксирани точки ежеседмично (по-често при стресови периоди). При GCB TDR мрежа улавя пространствените модели поне ежеседмично; VWC карти се генерират чрез ordinary kriging, което позволи анализ на равномерността на напояването и взаимодействията влага–стрес.

Измервания на тревния чим и корените – обем на откоса се измерва при GCA след всяко косене (градуирани съдове) като прокси за растеж/продуктивност. Данните се събират от грийнове, получаващи N норми GP, +25% GP и -25% GP, разпределени по режими на напояване (D и WD AOIs). Дебелината на thatch се измерва периодично - вземат се плъгове, прилага се тежест 1 kg; записва се компресираната дълбочина на thatch (mm) за намаляване на вариабилността. Измерванията на корените се извеждат от почвени плъгове, взети от фиксирани пробоотборни точки; плъговете се промиват и кореновата дължина се измерва ежеседмично (1.04–16.09 през 2023; 6.04–28.09 през 2024). Позициите на пиновете се ротират, за да се улови пространствената вариабилност без многократно пробонабиране от едно и също място. Локациите за пробонабиране са избрани далеч от ръбовете и зоните с висок трафик (равни централни участъци, ≥ 1.5 m от периметъра). Стандартен hole cutter (112 mm диаметър) извличаше плъгове до 240 mm дълбочина; пробите се етикетират по дата и идентификатор на грийна (AOI).

Част 1: Оптимизиране на азотното торене

Азотните стратегии са насочвани от GP. При GCA базовата норма 100% GP е $3.5 \text{ g N m}^{-2} \text{ month}^{-1}$ ($0.9 \text{ g N m}^{-2} \text{ week}^{-1}$), с варианти +25% GP ($1.125 \text{ g N m}^{-2} \text{ week}^{-1}$) и -25% GP ($0.675 \text{ g N m}^{-2} \text{ week}^{-1}$). Седмични корекции се извършва в отговор на климатичните условия. Периодът на изследване за GCA е отчетен като 01 March 2021 до 31 October 2023, като останалите практики по поддръжката са запазени постоянни. При GCB е приложена сходна рамка, базирана на GP, с 100% GP = $40 \text{ g N m}^{-2} \text{ month}^{-1}$ ($1 \text{ g N m}^{-2} \text{ week}^{-1}$), коригирана седмично така, че да отразява регионалните климатични условия.

Апликацията на гранулирана тор се извършват с калибрирана ръчна разпръсквачка тип „walk-behind“; листни пръскания (с повърхностноактивни вещества) се използваха при пикова потребност или във фази на възстановяване, чрез калибрирана шангова пръскачка с определен дебит на дюзите и работна скорост. Моделирането на N използва обединени дневни набори от данни, включващи записи за торене (N и кумулативна асс_N_rate), VIs, променливи на средата (Tmax, Tmin, ET, precipitation, RH, wind, GP, PAR) и производни индикатори за стрес. Етикетите за торене на ниво AOI се запазваха за контролни проверки, но предсказването на N се извършваше на времева резолюция за целия грийн. SHAP анализ беше приложен към HistGradientBoosting модели, обучени върху съгласувани набори от предиктори, за интерпретация на приноса на отделните променливи.

Част 2: Прогнозиране на почвената влага и оптимизиране на норма на напояване

Оптимизирането на напояването интегрира измервания на VWC, оценка на ET и (при GCB) пространствено картографиране на VWC. Ефективността на напоителната система се оценява чрез DU и CV, като DU се изчислява от „catch-can“ одити (средна стойност на най-ниския квантил, разделена на общата средна стойност). Показателите за водна продуктивност включваха WUE (обем откос/общ воден вход), IWUE (обем откос /обем на напояване) и HUE (обем откос /натрупани топлинни единици, GDD).

При GCA напояването следва предварително зададен график от ~35 mm/week, включително валежите (D), докато дефицитното напояване (WD) възстановява ~80% от полевата влагемост, използвайки ET оценки и in situ VWC. Напоителната система подаваше 5.2 mm m⁻² за 10 min при DU ~72%.

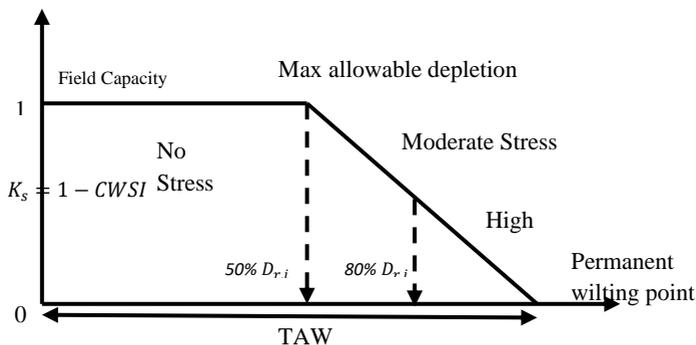


Figure 2. Schematic representation of water stress in the rootzone

При GCB напояването е ET-базирано с ~80% възстановяване, мониторинг на VWC на 15 cm дълбочина и подаване 6.8 mm m⁻² за 10 min при DU ~81% (стойности на DU по AOI са отчетени за S_3, S_4, W_9). Пространственото картографиране при GCB

използва 5 m TDR мрежа и kriging; периметрите на АОИ и мрежите се управляват чрез KML/JSON структури и се визуализират като heatmaps с изчислен CV. За изчисляване на дефицита и компонентите на ET се използва подход soil water balance (SWB) и FAO-56 single Kc рамка, като категориите стрес са илюстрирани схематично (Figure 20).

Част 3: Проследяване на развитието на кореновата система

Развитието на кореновата система е квантифицирано чрез седмичните коренови измервания от почвени монолити и съгласувано с VWC, индикатори за thatch/OM, норми на торене (GP, $\pm 25\%$) и режими на напояване (D, WD). Анализите включват корелационни и регресионни тестове на влиянието на влагоналичността, практиките за управление на OM (аерация/топд्रेसиране), режима на торене върху метрики за дължина на корените и времеви сравнения (сезонни модели). Многофакторни експлораторни анализи (PCA/PLS) се използват за идентифициране на променливите, които най-силно обясняват вариацията в кореновото развитие, като изходите са подготвени като входни данни за подпомагане на решенията в AI рамката.

Част 4: Дистанционни изследвания и vegetative indices (VIs)

Наземни RGB изображения са заснети ежеседмично на височина ~ 1.5 m с фиксирани настройки на камерата, съгласувани с локациите за почвено/кореново пробонабиране. UAV изображения (FIMI S2) се събираха при стандартизирана височина на полета и припокриване (70% по посока на полета, 60% странично), при ясни метеорологични условия, с геореферирание чрез GCPs или GPS. Мултиспектрални сателитни данни са свалени от PlanetScope (8 спектрални канала: Coastal Blue до NIR; Table 14), като изображенията са подбирани като безоблачни и събирани в многогодишни сезонни прозорци (Table 15).

Table 1. PlanetScope multispectral images bands

Band Nr.		Wave length
1	Coastal Blue	431 - 452 nm
2	Blue	465 - 515 nm
3	Green I	513 - 549 nm
4	Green II	547 - 583 nm
5	Yellow	600 - 620 nm
6	Red	650 - 680 nm
7	Red-Edge	697 - 713 nm
8	NIR	845 - 885 nm
-	RGB	-

Предварителната обработка на изображенията включва ортокорекция, визуална обработка (корекция на слънчев ъгъл, изостряне, цетова крива) и обработка до повърхностно отражение. UNet модел е специално обучен върху анотирани UAV изображения, генерира АОИ маски на ниво пиксел за грийнове/феъруси; VIs се изчисляват само в рамките на маските. Извлечен е набор от индекси (Table 17),

интегриран с почвени/коренови/екологични набори от данни и анализиран чрез time-series, регресионни и ML подходи. Работен процес за клъстеризация през множество сезони (средна стойност, вариация, тренд по пиксел; k-means k=10) генерира карти на състоянието на повърхността и подпомогна групиране по сходство между VI семейства чрез йерархична клъстеризация (Ward linkage).

Table 2. GCA and GCB satellite image collection

GCA			GCB	
Images	Season	Year	Season	Images
43	14.06-01.10	2019		
66	06.04-26.11	2020		
94	04.03-25.11	2021	21.03-01.12	52
94	15.03-26.11	2022	1.03-30.11	100
92	08.03-30.11	2023	1.03-30.11	64
103	05.03-28.11	2024	1.03-29.11	77
88	05.03-24.11	2025	4.03-25.11	94

Table 3. Collection of extracted VIs from satellite imagery

NDVI	MGVRI	GLI	MPRI	EXG	VARI	GNDVI	IRPVI	GRNDVI
GBNDVI	SAVI	MSAVI	GOSAVI	RVI	IPVI	DVI	MSR	NLI

Част 5: Разработване на AI-базирана SMART/DS рамка

DSS следва четиристъпков процес, който интегрира знание, извлечено от литературата, със специфични за обекта данни.

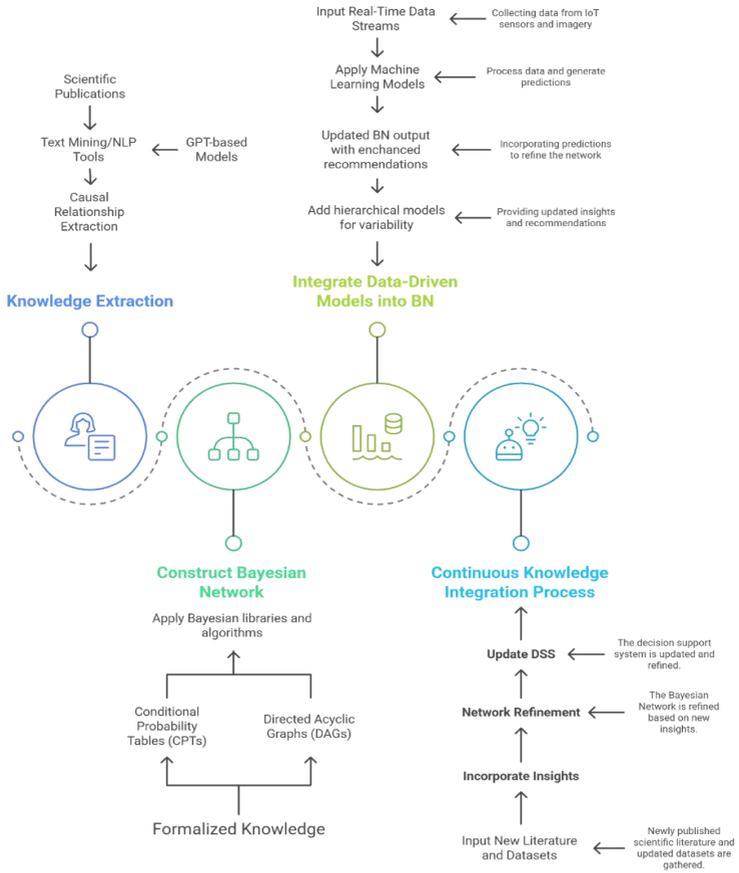
Стъпка 1 извлича причинно-следствени начални условия (priors) от литературата чрез NLP работни потоци;

Стъпка 2 кодира тези priors в начален BN с дискретизирани състояния на възлите (предоставени са примери за състояния на NDVI, норма на напояване и N-rate) и оценява предсказанията на BN чрез accuracy/balanced accuracy, confusion matrices и калибрация чрез reliability curves и Expected Calibration Error (ECE).

Стъпка 3 актуализира извлечените от литературата CPTs с локални набори от данни, като изходите от ML и SHAP моделите добавят информация за likelihood за Bayesian обновяване, а йерархично Bayesian моделиране се използва за отчитане на варибилността, когато е приложимо.

Стъпка 4 предлага Continuous Knowledge Integration Process (CKIP) за обновяване на BN с нова литература и потоци от данни в реално време. Интеграцията между модулите (N, напояване, корени, VIs) калибрира BN към поведението на конкретния обект и подпомага оперативни изводи (напр. обем на напояване, норма на азот, детекция на стрес) с пренос на неопределеността.

Framework Development Process



3 Резултати

3.1 Част 1. Оптимизиране на азотното торене и динамика на SOM

1) Вегетативни индекси, оптимални лагове и композитни сигнали (N и acc_N_rate)

Пълен лаг-скан (2–14 дни) идентифицира най-силните асоциации на отделни VI с азотните променливи. За приложената норма на торене (N) DVI при лаг 2 дни е най-висока корелация ($r = 0.270$, $p < 0.001$). За кумулативната азотна норма (acc_N_rate) най-силен това е GOSAVI при лаг 5 дни ($r = 0.252$, $p = 0.003$). Тези лаг-прозорци вероятно отразяват времето, необходимо на характеристиките на тревната повърхност (плътност, хлорофилен сигнал, зелен-кафяв контраст) да се променят след торене и растежни импулси.

Table 4. Highest Pearson correlations between VIs at lag windows (2–14 days) and the two nitrogen-related response variables: the fertilization rate (N) and accumulated nitrogen (acc_N_rate).

Top correlations with (N)			Top correlations with acc_N_rate		
Lag	VI	Correlation with (N)	Lag	VI	Correlation with acc_N_rate
2	DVI	0.270026	5	GOSAVI	0.251954
2	MSR	0.236140	4	GOSAVI	0.242078
4	MSR	0.204282	4	SAVI	0.235005
2	SAVI	0.170501	4	MSAVI	0.233556
10	MPRI	0.165335	7	GOSAVI	0.228355
14	MPRI	0.153311	2	DVI	0.227865
2	GOSAVI	0.132502	5	MSAVI	0.225554
8	MSR	0.121539	2	SAVI	0.224635
8	DVI	0.121521	5	SAVI	0.223829
7	GOSAVI	0.117007	6	MSAVI	0.220579

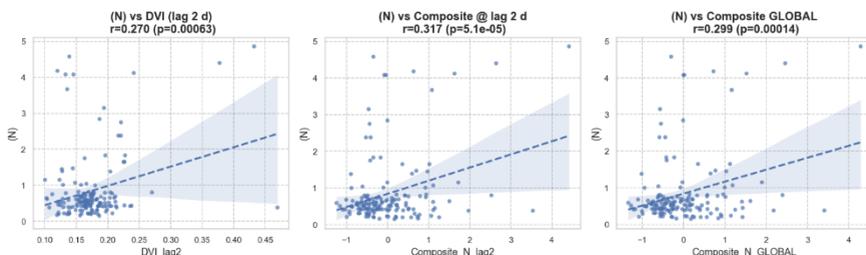


Figure 3. Relationships between fertilization rate (N) and (a) the best-performing single VI at its optimal lag (DVI_lag2), (b) the lag-specific composite index, and (c) the global composite index. Composites show higher correlation coefficients ($r \approx 0.30$ – 0.32) than the single VI, indicating that combining spectral information improves representation of management-driven canopy responses.

При комбиниране на множество VI в композити сигналът се усилва. За (N) както лаг-специфичният, така и GLOBAL композитът показват малко по-високи корелации ($r \approx 0.30$ – 0.32) спрямо най-добрия единичен VI. За acc_N_rate GLOBAL композитът

последователно превъзхожда единичните VI ($r = 0.342$, $p < 0.001$), което показва, че интегрирането на множество канали по-добре представя кумулативния растеж и отнемането на азот.

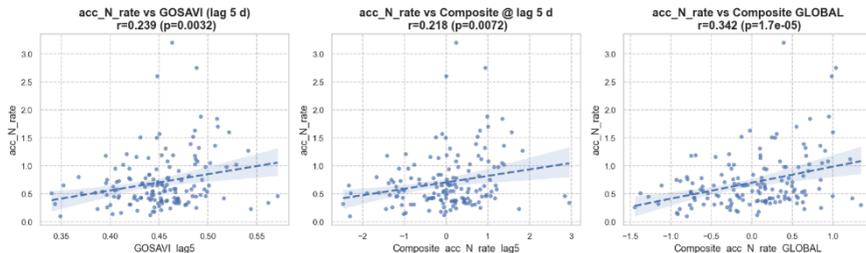


Figure 4. Relationships between accumulated nitrogen removal (acc_N_rate) and (a) the strongest VI ($GOSAVI_lag5$), (b) the lag-specific composite, and (c) the global composite. The global composite produces the highest correlation ($r = 0.342$, $p < 0.001$), reflecting the advantage of integrating multiple canopy signals to represent cumulative growth.

2) Базова supervised prediction само с VI признаци (обучение 2023 → тест 2024)

Моделите, базирани само на VIs, улавят сезонните модели, но имат тенденция да изглаждат прекомерно резките преходи. За (N) най-добрият модел само с VIs се показва Gradient Boosting с $RMSE = 0.321$ и $R^2 = 0.369$, което означава, че само VIs обясняват ~37% от вариацията в приложената от мениджъра норма на торене. За acc_N_rate HistGradientBoosting се представя най-добре с $RMSE = 0.300$ и $R^2 = 0.396$, което показва, че състоянието на тревната повърхност съдържа значителна информация за кумулативното отнемане на N, свързано с окосения обем.

Оценките по времеви ред за 2024 г. показват, че моделите само с VIs като цяло следват сезонната траектория, но пропускат внезапни промени (раннопролетни пикове; къснолетни спадове), което мотивира включването на предиктори за стрес от средата.

Table 5. Predictive performance of models trained on 2023 VI features and tested on 2024. Gradient Boosting was most effective for (N).

(N) models (train 2023 → test 2024)			
Model	Test RMSE	Test R ²	Notes
Gradient Boosting	0.321	0.369	Best performer
Ridge	0.331	0.328	Stable linear baseline
HistGB	0.396	0.039	Underfits non-linearities
Random Forest	0.398	0.027	Over-smoothing
CatBoost	0.437	-0.17	Overfits train season

Table 6. Predictive performance of models trained on 2023 VI features and tested on 2024 HistGradientBoosting performed best for acc_N_rate.

acc_N_rate models (train 2023 → test 2024)			
Model	Test RMSE	Test R ²	Notes
HistGradientBoosting	0.300	0.396	Best performer
Ridge	0.331	0.265	Smooth linear baseline
CatBoost	0.336	0.243	Reasonable fit
Random Forest	0.337	0.242	Similar to CatBoost
Gradient Boosting	0.386	0.003	Essentially no predictive power

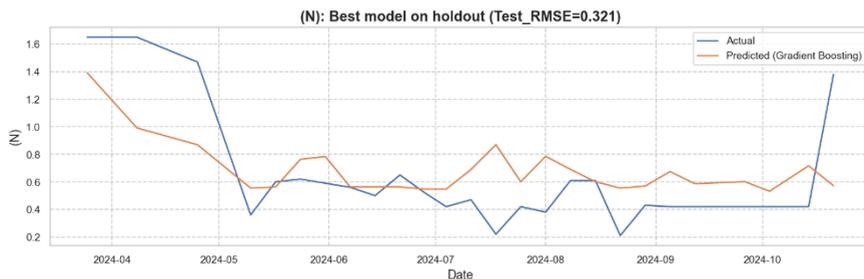


Figure 5. (N) Seasonal predictions for 2024 using VI-only models. Panels show that VI features capture the overall seasonal trajectories but miss abrupt transitions, especially early-season peaks and late-season declines. These limitations justify the inclusion of environmental stress predictors.

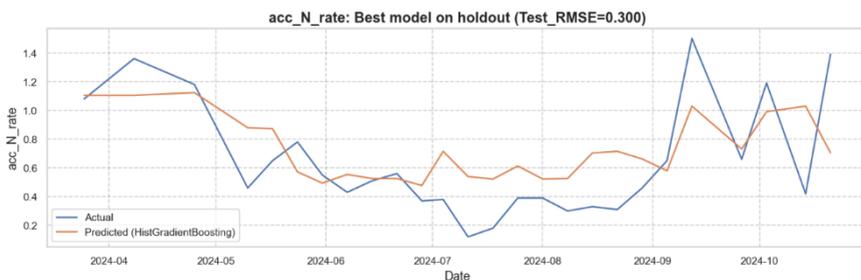


Figure 6. Acc_N_rate Seasonal predictions for 2024 using VI-only models. Panels show that VI features capture the overall seasonal trajectories but miss abrupt transitions, especially early-season peaks and late-season declines. These limitations justify the inclusion of environmental stress predictors.

3) Сигналите на стрес-вълни се изразяват във VIs (стрес → реакция на тревната повърхност)

За да се определи количествено ефектът на екологичния стрес върху динамиката на състоянието на тревната повърхност, променливи за суша/топлина са извлечени от дългосрочни метеорологични записи и тествани в различни лаг-комбинации. Сред ~12 000 тествани комбинации най-силната единична връзка е DVI спрямо deficit3 при лаг 2 дни ($r = 0.258$, $p = 0.001$), което показва, че краткотрайните дефицити валежи–ЕТ потискат индексите за „зеленина“/контраст в рамките на ~1–3 дни. Подобни резултати се наблюдават и при структурно чувствителни VIs като SAVI.

При обобщаване по VI най-добрите дескриптори на стрес се различават между индексите (DVI най-добре се съгласува с deficit3 при лаг 2; EXG се съгласува с heat_flag при лаг 1; хлорофил-чувствителните индекси се съгласуват с по-голяма продължителност на топлинната вълна при лаг 14), което потвърждава, че информацията за стрес се открива в спектралните сигнали в физиологично съгласувана посока.

Table 7. Strongest correlations between environmental stress descriptors and VIs across lag windows

Best stress feature per VI				
VI	Lag	Stress feature	r	Interpretation
DVI	2	deficit3	0.258	Canopy contrast drops after short-term water imbalance
EXG	1	heat_flag	0.169	Heat reduces green dominance
GBNDVI	14	heat_wave_len	0.213	Long heat waves increase drying/necrosis signal
GNDVI	14	heat_wave_len	0.226	Heat influences chlorophyll-sensitive indices

4) Цялостни модели с лаг-съгласувани предиктори за стрес (VI + stress) и интерпретируеми драйвери

Стрес метриците са съгласувани с оптималните VI лагове (стрес при $t-L$ предсказва VI_lagL и отговор при t). Включени са само топ- K стрес признаци ($K = 6$), подредени според асоциацията им с целевата променлива в обучаващия сезон. За (N) най-добрият модел е Ridge Regression с $RMSE = 0.272$ и $R^2 = 0.548$, което представлява съществено подобрене спрямо представянето само с VIs ($R^2 \approx 0.37$). Това показва, че решенията за торене са били по-тясно свързани с непосредствените условия на топлинен/влагов стрес, отколкото само с отражателната способност на тревната повърхност.

Стандартизираните коефициенти показват, че deficit3_aligned_lag2 е най-силният предиктор, следван от краткосрочното натрупване на топлина (heat_dd7_aligned_lag2; heat_dd3_aligned_lag2) и по-дълги периоди на сушова вълна (drought_sum14_aligned_lag2; deficit14_aligned_lag2). Спектралните предиктори (DVI_lag2 и Composite_N_lag2) остават с принос, но второстепенен спрямо стрес метриците.

За `acc_N_rate` най-добрият модел е `HistGradientBoosting` с $RMSE = 0.294$ и $R^2 = 0.422$, като резултатите са в общи линии съпоставими с моделите само с VIs ($R^2 \approx 0.40$), но с по-добра устойчивост в началото на сезона. Значимостта на признаците се различава от тази при (N): глобалният композит (`Composite_acc_N_rate_GLOBAL`) доминира, докато дефицитите за 7–14 дни (`deficit7/14`, съгласувани с лаг 5) и по-дълги периоди на суша модулират кумулативното усвояване, в съответствие с физиологичния контрол върху обема откос в средносрочни времеви прозорци.

Компактно обобщение на редукцията на грешката показва, че включването на съгласувани стрес признаци намаля тестовия $RMSE$ за 2024 от ~ 0.32 до ~ 0.27 – 0.29 за (N) и от ~ 0.30 до ~ 0.27 – 0.29 за `acc_N_rate`. Това подкрепя виждането, че моделите на торене се модулират силно от топлинен и сушов стрес, който VIs сами по себе си не могат да представят.

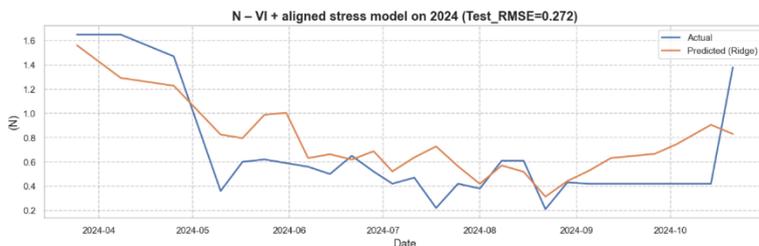


Figure 7. (N) Seasonal predictions for 2024 using VI + assigned stress models. Panels show that VI features has a substantial improvements ($R^2 = 0.548$) over VI-only models ($R^2 = 0.37$).

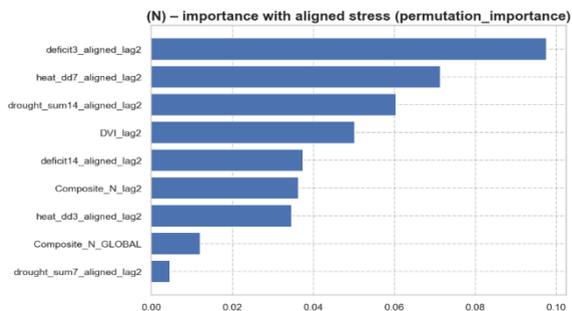


Figure 8. Standardized coefficients from the best-performing Ridge Regression model predicting fertilization rate (N). Short-term moisture deficits (`deficit3_aligned_lag2`) and heat accumulation (`heat_dd7_aligned_lag2`, `heat_dd3_aligned_lag2`) are the most influential predictors. Spectral variables contribute secondarily after stress metrics.

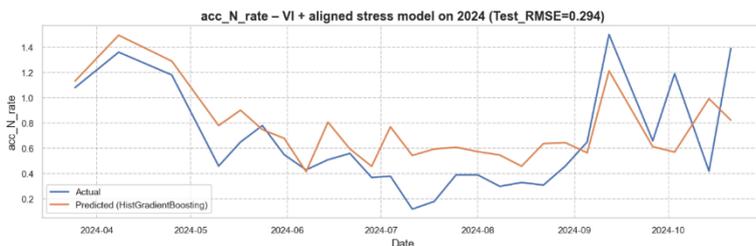


Figure 9. Predictions for 2024 using models that combine VIs with lag-aligned stress features. Incorporating heat and drought metrics improves responsiveness to early-season changes and reduces over-smoothing seen in VI-only models

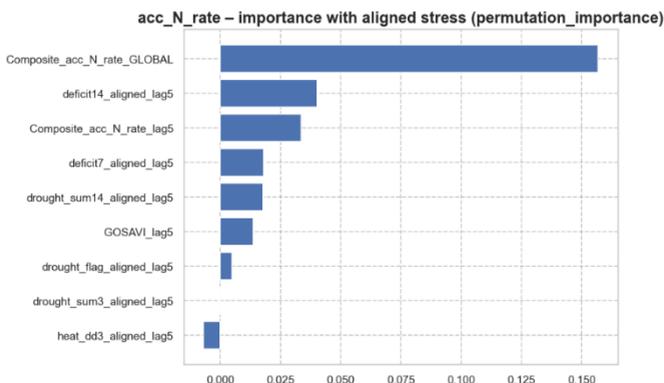


Figure 10. Feature importance from the HistGradientBoosting model predicting accumulated nitrogen removal (acc_N_rate). The global composite VI is the dominant predictor, while medium-term water deficits over 7–14 days strongly influence cumulative GP and clipping removal.

Table 8. VI only to VI+stress RMSE comparison

Target	VI-only RMSE	VI+Stress RMSE	Meaning
(N)	~0.32	~0.27–0.29	Better tracking of fertilization triggers
acc_N_rate	~0.30	~0.27–0.29	Better representation of cumulative response

5) SHAP потвърждение на причинно-следствената йерархия (fast-cycle stress control vs canopy state)

SHAP анализите подкрепят същата йерархия. За (N) най-силните приноси бяха от $deficit3_aligned_lag2$ и $heat_dd7_aligned_lag2$, последвани от по-дълги сушови сигнали. Спектралните признаци (DVI_lag2 и композитите) осигуряват стабилен, но второстепенен принос. За acc_N_rate доминиращият драйвер е $Composite_acc_N_rate_GLOBAL$, като също имат влияние средносрочни признаци за

воден дисбаланс (deficit и суми на drought за 7–14 дни); кратките остри стресови събития имат малък принос.

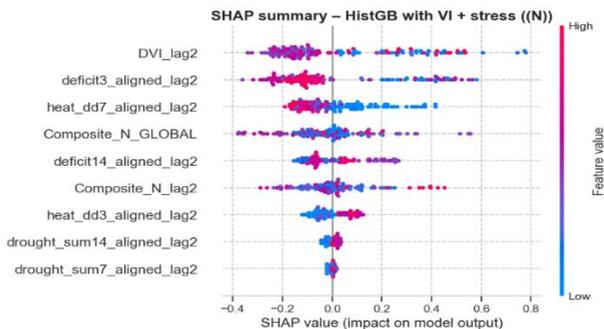


Figure 11. SHAP summary plot for the fertilization rate model (N) integrating VIs and lag-aligned environmental stress metrics

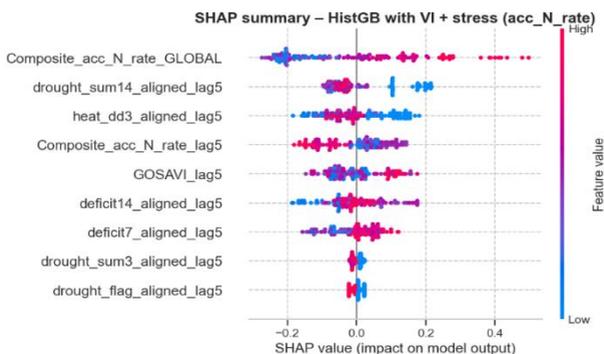


Figure 12. SHAP summary plot for the accumulated nitrogen removal model (acc_N_rate) using vegetation composites and aligned stress metrics

6) Динамика на SOM (2019–2024): дълбочинни тенденции, връзка с N и разделение по AOI

SOM се наблюдава ежегодно на три дълбочини (0–25, 25–50, 50–75 mm) в четири AOIs (p01, p10, pt1, pt2) в рамките на шест години. Между AOIs SOM като цяло намалява на всички дълбочини, с изключение на зоната с висок N pt2, като най-силният спад е в повърхностните слоеве. SOM₁ намалява от ~9–10% (2019) до ~4–6% (2024) (най-изразено в p01 и pt1), SOM₂ спада от ~7–8% до ~4–6%, а SOM₃ намалява по-бавно и се стабилизира около ~2.0–2.8%. Подредбата по AOI се запазва през дълбочините (pt2 >

p10 > p01 > p1), в съответствие с това, че устойчивото торене поддържа по-високи нива на OM при пясъчно-базирани грийнове.

Table 9. SOM belongs to carbon budget and is influenced by direct physical and indirect management drivers and represented by spectral signals.

Direct physical drivers	Indirect management drivers	Spectral signals
thatch accumulation clipping inputs root biomass soil moisture regime decomposition environment (temperature, moisture, oxygen)	irrigation strategy N plan clipping removal frequency topdressing stress-wave patterns (heat, deficit)	vegetation density NDVI/NDRE → biomass / canopy thickness DGCI/EXG/VARI → chlorophyll & color composite VIs → yield potential over time

Годишният общ вход на N показва силна положителна асоциация със SOM на всички дълбочини: $r \approx 0.70$ (SOM₁), $r \approx 0.79$ (SOM₂), $r \approx 0.80$ (SOM₃). Този модел е в съответствие с по-висока продуктивност, която подпомага входовете на OM чрез плътност на надземната маса, обем на окосената биомаса, оборот на корените и C отлагане в ризосферата.

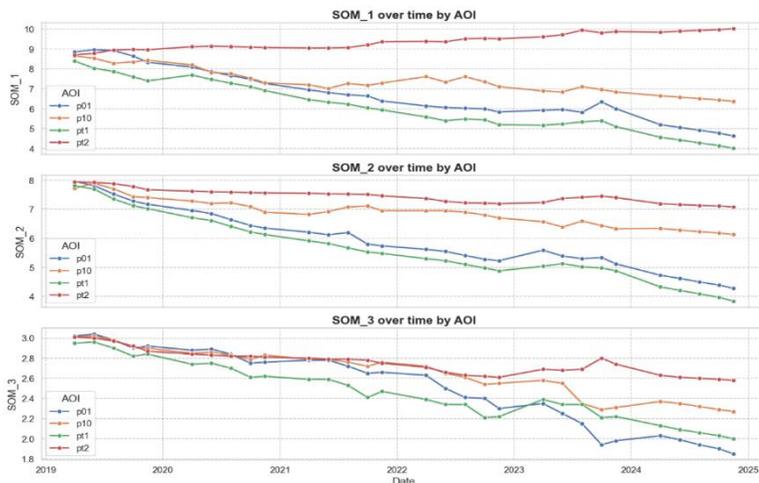


Figure 13. Temporal trends of soil organic matter (SOM) across three depths (0–25 mm, 25–50 mm, 50–75 mm) within four AOIs from 2019 to 2024. All areas except p2 show declining SOM across depths, reflecting long-term dilution and decomposition in sand-based putting greens.

SOM ко-варираше силно между дълбочините (SOM₁–SOM₂ $r = 0.93$; SOM₂–SOM₃ $r = 0.90$; SOM₁–SOM₃ $r = 0.78$), което предполага споделени дългосрочни контроли, свързани с отлагането на биомаса и режима на управление. Machine learning и SHAP не

са приложени към SOM поради ограничения размер на годишния набор от данни ($n = 24$, дълбочините и AOIs) и допълнителното редуциране при обединяване с метриците за корени/клипинг/thatch.

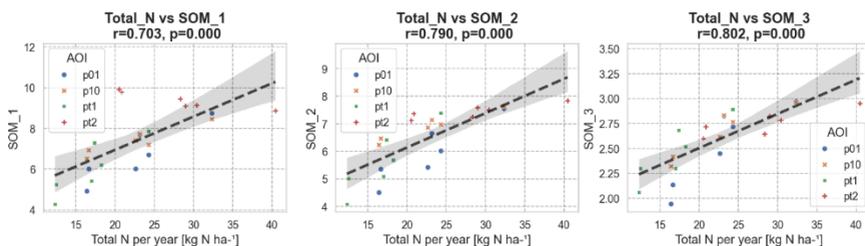


Figure 14. Relationships between annual nitrogen input and SOM at three depths. Strong positive correlations ($r = 0.70$ – 0.80) indicate that higher nitrogen fertilization supports SOM accumulation through increased shoot density, root turnover, and rhizosphere carbon deposition.

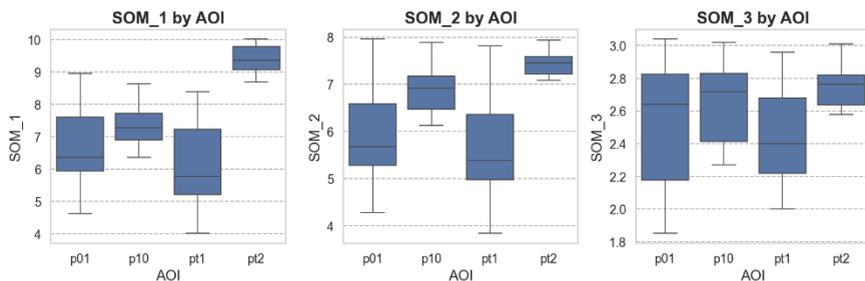


Figure 15. SOM distributions across AOIs at three depths. The +25% N treatment (pt2) consistently shows the highest SOM, while the –25% N treatment (pt1) maintains the lowest values, validating the expected treatment gradients

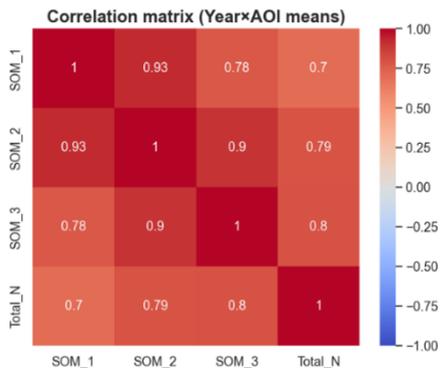


Figure 16. Correlation matrix showing co-variation of SOM across three depths.

Заедно моделирането на азота и резултатите за SOM дефинират ядрото на азотния модул на DSS: fast-cycle азотна динамика (N и acc_N_rate) се управлява от сигнал, при който състоянието на тревната повърхност улавя реализирания растеж, а лаг-съгласуваните стрес метрики предоставят липсващите екологични ограничения, които контролират краткосрочните решения и сезонните отклонения. SOM функционира като slow-cycle индикатор за устойчивост, интегриращ многогодишните последиствия от тези решения.

PHYSIOLOGICAL BASE
Temperature (Tmax/Tmin) → Growth Potential (GP) → MLSN limits
VEGETATION SIGNAL PROCESSING
Raw VIs (NDVI, DVI, SAVI, MSR, GOSAVI, ...) ↓ lag scan (2–14 d) Best VIs @ lag → Composite
ENVIRONMENTAL STRESS ENGINEERING
Heat flags, heat degree-days (DD3/DD7/DD14) Drought flags, 3–14 day deficit windows Stress time-alignment to VI lag
PREDICTIVE MODELLING
Ridge (for N) / HistGB (for acc_N_rate) Train: 2023 Test: 2024
MODEL INTERPRETATION
SHAP values → feature contributions Identify: canopy signals, heat/drought accumulation, composite
DSS INTEGRATION LAYER
Fast-cycle N demand (daily–weekly) + Slow-cycle SOM feedback (annual) → Adaptive nitrogen envelope & recommendations

Figure 17. The diagram illustrates the central nitrogen–carbon feedback mechanism identified in this study. Nitrogen fertilization drives canopy density and clipping production, which in turn influence root growth and OM deposition. These inputs accumulate slowly into SOM. SOM then feeds back into the DSS as a long-term sustainability indicator, modifying the recommended nitrogen envelope for subsequent seasons. This forms a closed loop connecting short-term N demand with long-term carbon storage.

3.2 Част 2. Оптимизиране на напояването

1) GCA (2019–2024): времева динамика на почвената влага и ефективност на напояване.

Многогодишна класификация на стреса (FAO56 SWB). Почвеният воден баланс е реконструиран за GCA (2019–2024) и показва силно стабилен сезонен модел: пътинг грийнът остава преобладаващо в умерен стрес през по-голямата част от вегетационния сезон, обикновено ~170–180 дни/година, докато условия без стрес се наблюдават за ~55–65 дни, в зависимост от разпределението на валежите. Дните с висок стрес са почти отсъстващи при текущата стратегия на напояване. Това показва управляван режим, който рутинно допуска частично изчерпване без навлизане в тежък стрес, но също така предполага чувствителност към кратки периоди на недостиг на напояване при пикове на ЕТс. (Figure 38)

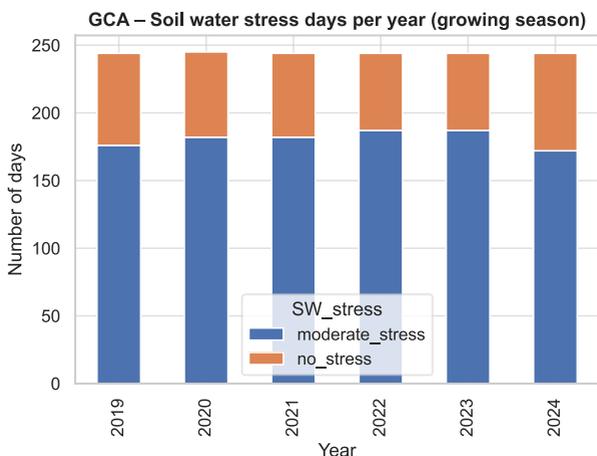


Figure 18. Soil water stress days per year (GCA, 2019–2024). Annual counts of days classified as no-stress, moderate-stress, and high-stress based on the FAO56 soil-water-balance reconstruction. Moderate stress consistently dominated the seasonal moisture regime (~170–180 days per year), while high-stress conditions were nearly absent.

Реакция на VWC към нетния дневен воден баланс ($P + I - ET_c$). През годините повечето наблюдения попадат в тесен диапазон на VWC от ~18–28%, в съответствие с ограничената водозадържаща способност на пясъчния профил и честото напояване с малки норми. Отрицателните стойности на ($P+I-ET_c$) се асоциират със спад на VWC, но реакцията е нелинейна поради честите напоителни събития и бързото дрениране. Положителният воден баланс не увеличава VWC пропорционално над ~28–30%, което предполага оперативен таван на полевата влагоемност, при който допълнителната вода се дренира под дълбочината на сензора и не е полезна за VWC на следващия ден. Тези

модели директно подкрепят прагове на влаговите състояния за DSS около <18% (склонно към изчерпване), 18–26% (оптимален диапазон) и ~28% (зона на дрениране/без полза).

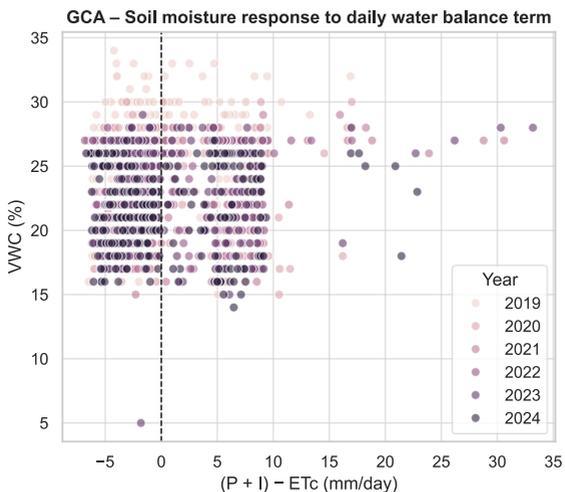


Figure 19. Soil moisture response to the daily water-balance term ($P + I - ET_c$). Relationship between TDR-measured VWC and net daily water balance. Negative balance values correspond to moisture decline, while positive values plateau near 28–30% VWC, indicating the practical field-capacity limit of the sand profile. The narrow VWC range reflects rapid drainage and the stabilizing effect of frequent low-volume irrigation.

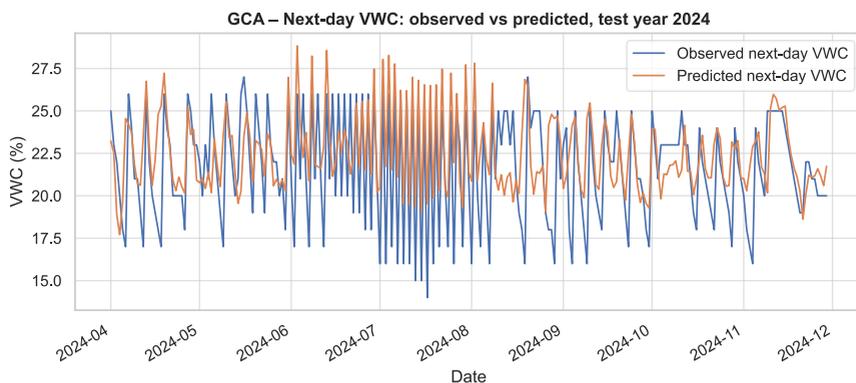


Figure 20. The time-series view for 2024 confirms that the model tracks the general drying/wetting cycles (daily oscillation patterns) even though individual peaks and troughs are not perfectly aligned. This is expected given the high-frequency noise and the sensitivity of sand-based greens.

Прогнозиране на VWC за следващия ден (ML). GradientBoostingRegressor е идентифициран като най-добре представящ се подход за прогнозиране на VWC за следващия ден. Прогнозната точност е описана като практически полезна за вземане на решения при пясъчен грийн, с RMSE в диапазона $\sim 2\text{--}3\%$ VWC и умерена, но стабилна генерализация към тестови условия. Времевите графики и тези за разсейване показват добро проследяване на цикли на овлажняване-изсъхване, с очаквани ограничения при екстрими: леко подценяване при много висока VWC и повишена вариабилност при ниска VWC ($<18\%$), отразяваща бързо изсъхване при висока ETc. (Figure 40)

SHAP йерархия на драйверите и прагово поведение. SHAP интерпретацията потвърждава физически съгласувана йерархия:

1. Текущата VWC е доминиращият предиктор (силна инерция на почвената влага).
2. ETc е вторият по влияние драйвер, с ясно прагово поведение: ETc $< \sim 2$ mm/day води до слабо изсъхване; ETc $\sim 3\text{--}5$ mm/day прогресивно намалява VWC за следващия ден; ETc $> \sim 5.5$ mm/day дава силни отрицателни приноси, съответстващи на пикове на бързо изсъхване.
3. DOY улавя сезонността.
4. **Precipitation and RH** имат стабилизиращи положителни ефекти.
5. Температурните условия действат основно чрез ETc/VPD, докато drought flags и depletion индекси добавят контекст, особено при средни до ниски влагови състояния. (Figure 41, 42a, 42b, 43, 44)

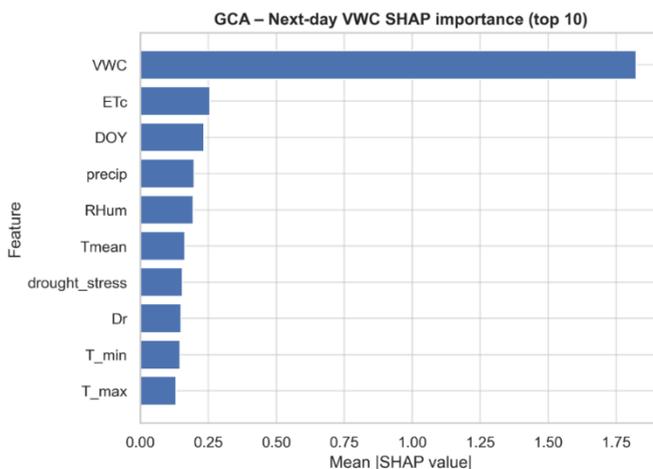


Figure 21. Top-10 SHAP feature importance for next-day VWC. showing the relative mean absolute SHAP contribution of each predictor. VWC overwhelmingly dominate prediction behavior, confirming the strong inertia and climatic dependence of moisture in a sand green

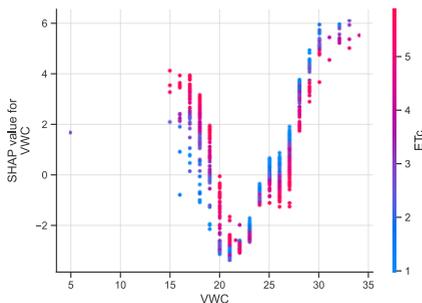


Figure 22a SHAP dependence for current VWC in the next-day VWC model (GCA), coloured by ETC. Contributions are most negative around ~20–22% VWC and become more positive at lower and higher VWC; higher ETC generally shifts values downward.

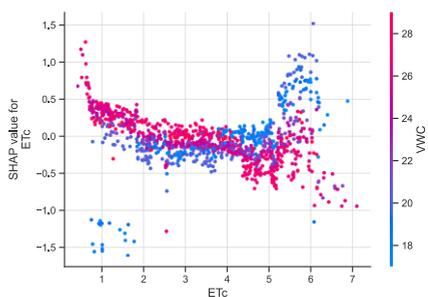


Figure 42b SHAP dependence for ETC in the next-day VWC model (GCA), coloured by current VWC. Increasing ETC tends to reduce next-day VWC, with stronger and more variable effects at ~5–6+ mm day⁻¹ depending on starting moisture.

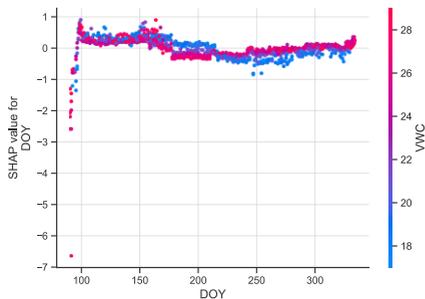


Figure 23 SHAP dependence for DOY (coloured by current VWC) in the next-day VWC model (GCA), showing seasonality: early DOY tends positive, mid-season (≈190–280) slightly negative, late season near-neutral to mildly positive.

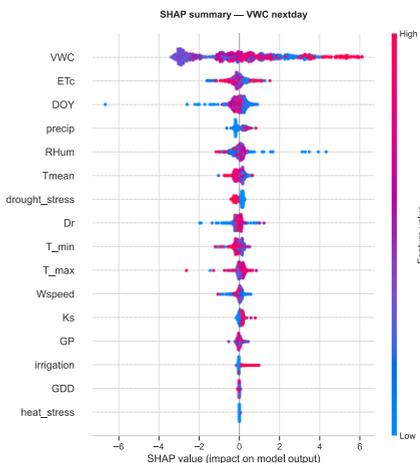


Figure 24 SHAP summary (beeswarm) for the next-day VWC model (GCA). VWC is the main driver, followed by ETC and DOY; precipitation and RH are secondary. Colour indicates low-to-high feature values

Оперативни прагове, извлечени от комбинираните анализи. Комбинираните описателни, прогнозни и SHAP анализи се обобщават в следните прагове за вземане на решения:

- **Оптимален диапазон на VWC: 18–26%** (стабилна динамика, неутрално SHAP поведение).
- **Долна граница: ~16–18%** (рязко отрицателен SHAP, бърз спад при $ET_c > \sim 4$ mm/day; практичен тригер „започни напояване“).
- **Горна граница: ~28–30%** (VWC достига плато; намаляваща възвръщаемост; избягване на ненужно напояване).
- **Прагова класификация на ET_c : < 2 , $3-5$, > 5.5 mm/day** (възли за ниско/средно/високо изпарително търсене).

Тези прагове са директно подходящи за дискретизация в състояния на BN възли за решения по напояване.

2) GCB (2024): пространствени модели на почвената влага в рамките на грийнове (S_3, S_4, W_9)

Сезонна динамика на пространствената равномерност. Седмичните VWC мрежи за 2024 г. са използвани за определяне на количественото разпределение на влагата в рамките на грийна и неговата времева стабилност. DU се подобрява от началото на май до средата на сезона и се стабилизира над общоприетия праг $DU = 0.75$. S_4 поддържа последователно високи стойности на DU ($\sim 0.85-0.92$ след средата на май), докато S_3 и W_9 показват по-силна ранносезонна вариабилност (при W_9 DU нараства бързо от ~ 0.65 до ~ 0.90 след първоначалните дати). (Figure 45)

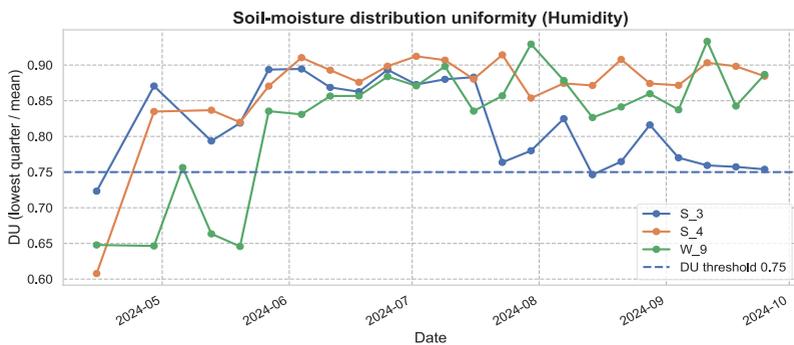


Figure 25. Seasonal trends in distribution uniformity (DU) for S_3, S_4, and W_9. DU increases from early spring toward mid-season across all greens, stabilizing above the acceptable threshold ($DU = 0.75$). S_4 maintains the highest DU throughout the season, while S_3 and W_9 show greater early-season variability.

Пространствена вариабилност (CV). Моделите на CV допълват DU, като описват интензивността на хетерогенността. S_4 остана най-стабилен ($\sim 8-12\%$), докато S_3 и

W_9 прояват изразена ранносезонна вариабилност (пикове около ~20–23%) и, за S_3, допълнителен пик в края на лятото (~22%), в съответствие със спад на DU. (Figure 46) (Figure 46)

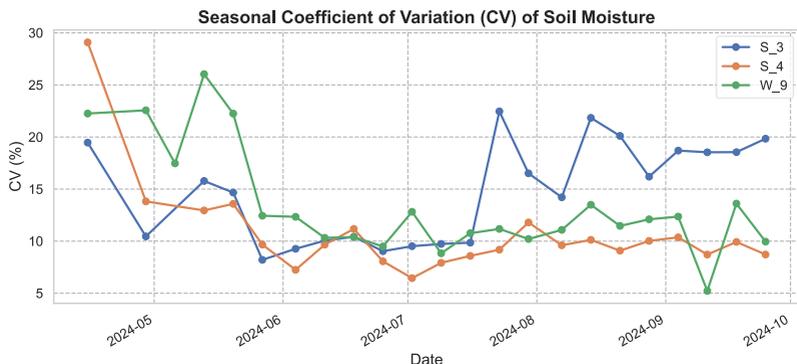


Figure 26. Seasonal coefficient of variation (CV) of VWC for S_3, S_4, and W_9. CV patterns reveal spatial heterogeneity and complement DU interpretation. S_4 exhibits consistently low CV (~8–12%), while S_3 and W_9 show substantial early-season variability and localized heterogeneity later in the season.

Дялове по влагови състояния (Dry/Optimal/Wet). Класифицирането на точките от мрежата в Dry, Optimal и Wet състояния показва, че Optimal условията доминират при всички грийнове, като Dry условия се появяват епизодично (в началото/края на сезона или при временни спадове на равномерността). Wet петната като цяло са ограничени и краткотрайни, с изключение на ранните периоди при W_9 и в определени периоди при S_3. (Figures 47–49)

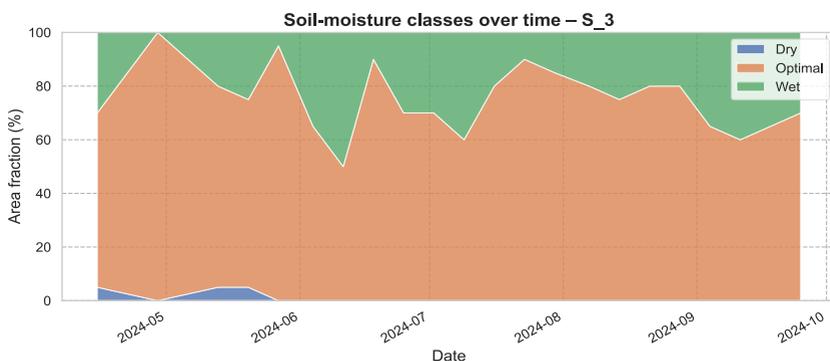


Figure 27. Proportion of Dry, Optimal, and Wet areas over the season for S_3.

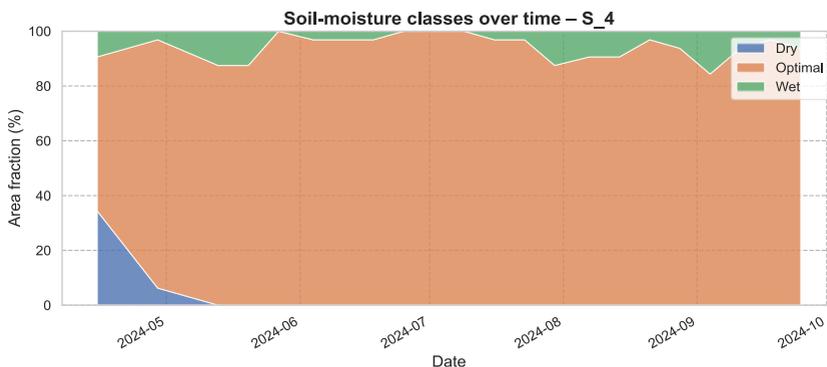


Figure 28. Proportion of Dry, Optimal, and Wet areas over the season for S_4.

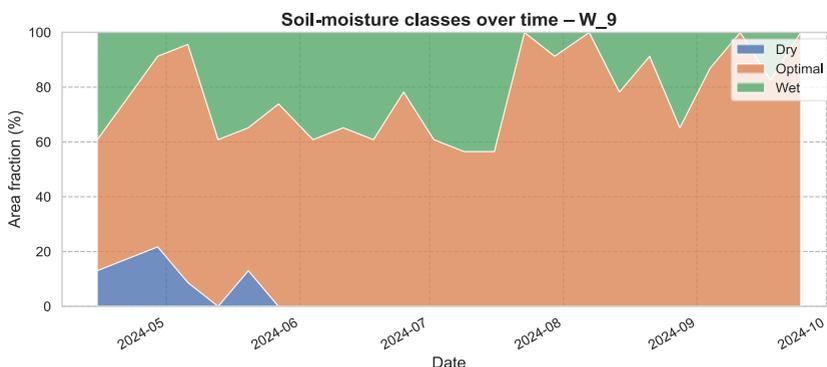


Figure 29. Proportion of Dry, Optimal, and Wet areas over the season for W_9.

Зони с устойчиво поведение, идентифицирани чрез времеви клъстерен анализ (k-means, k=3):

- Устойчиво сухи зони (потенциални хидрофобни петна, засенчване от разпръсквачи/ветрова експозиция).
- Транзиторни зони (нормална реакция на напояване/валежи)
- Устойчиво влажни зони (микродепресии, припокриване, дренажни ограничения, сянка/уплътняване)

S_3 показва отчетливи устойчиво сухи зони (вляво и в долната централна част), както и малки влажни петна близо до периферията, което съответства на късносезонния спад на DU. S_4 е предимно транзиторен/влажен с минимален брой устойчиво сухи точки, в съответствие с най-доброто представяне по DU/CV. W_9 има стабилни, но по-малки влажни и сухи петна при доминиращи транзиторни зони. (Figures 50–53)

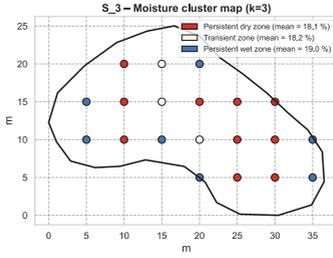


Figure 30. Moisture-cluster map for S_3 using k -means ($k = 3$).

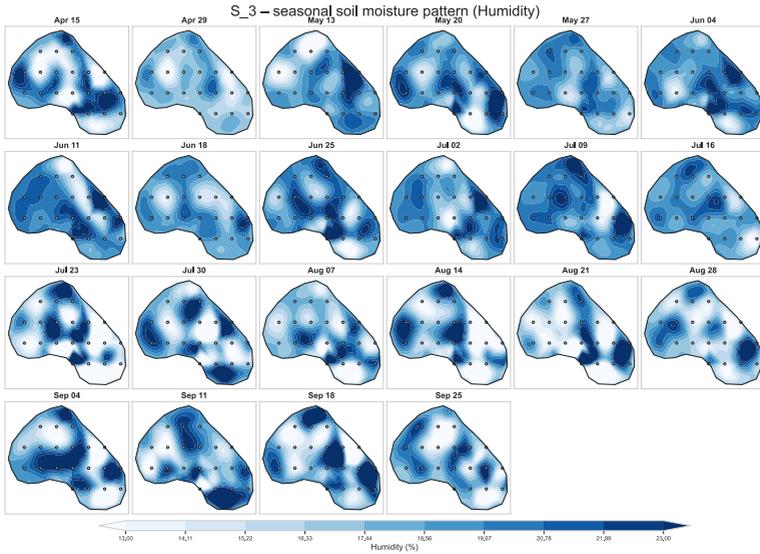


Figure 31. Example of seasonal moisture clustering for S_3

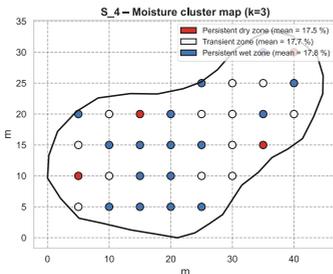


Figure 32. Moisture-cluster map for S_4 using k -means ($k = 3$)

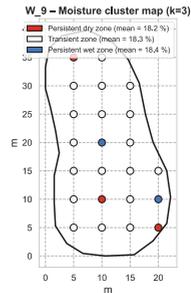


Figure 33. Moisture-cluster map for W_9 using k -means ($k = 3$).

3) Интеграция в напоителния модул на SMART-DSS (времеви + пространствен)

INTEGRATED IRRIGATION INTELLIGENCE FRAMEWORK (GCA + GCB)		
INPUT LAYER		
Weather Data PAR, Tmin, Tmax, RH Wind, solar radiation Rainfall, ET _o (PM)	Management Data Irrigation (D / WD) ET-based scheduling Fertilization Mowing / clipping	Soil & Spatial Data TDR VWC (GCA, daily) Weekly VWC grids (GCB) Green boundary polygons DU, CV, moisture classes
TEMPORAL - SPATIAL ANALYSIS LAYER		
GCA: TEMPORAL WATER BALANCE	GCB: SPATIAL MOISTURE PATTERNS	
$ET_c = ET_o \times K_c$ Daily water balance: Irrigation + Rain - ET _c Stress indicators: Soil Water Deficit (SWD), K _s , DS, stress classes Efficiency metrics: WUE, IWUE, HUE Seasonal patterns: VWC dynamics, ET demand	VWC heatmaps (interpolated surfaces) Spatial indices: DU, CV Moisture-class area fractions: Dry / Optimal / Wet Cluster analysis (k=3): Persistent dry zones Transient zones Persistent wet zones Spatial stability across season	
SYNTHESIS OF TEMPORAL + SPATIAL BEHAVIOR		
Rising ET _c deficit → temporal stress (GCA) Chronic dry pockets → spatial under-irrigation (GCB) High CV or low DU → uneven irrigation distribution	High wet-area fraction → potential over-irrigation / drainage issue Stable clusters → strong spatial priors Unstable clusters → higher DSS uncertainty weight	
SMART-DSS IRRIGATION MODULE (OUTPUT LAYER)		
Feature Engineering for BN		
Temporal Features (GCA):	Spatial Features (GCB):	
Rolling ET deficit Time since last effective rainfall Daily VWC stress state Predicted next-day VWC (ML model) Seasonal phase classification	DU class (High / Medium / Low) CV class (Stable / Variable / Highly variable) Cluster identity (Dry / Transient / Wet) Moisture-class area fractions Persistent zone flags (dry/wet) Spatial uncertainty factor	
BN / CPT Integration		
Convert thresholds → discrete BN nodes Populate CPTs using empirical seasonal behavior Combine temporal + spatial indicators	Output → risk-adjusted irrigation recommendation: Increase irrig: ET deficit+dry cluster+low DU Decrease irrigation: wet cluster+low ET Alert: persistent wet zones / low DU / unstable	

Figure 34. Integrated temporal-spatial irrigation framework for the SMART-DSS.

Част 2 интегрира времеви набор от правила от GCA с пространствен диагностичен слой от GCB. GCA дефинира динамичния отговор: инерция на влагата (VWC_today), ETc-обусловена скорост на изчерпване и практичен влагов прозорец (18–26%), ограничен от зона, склонна към изчерпване, и зона без полза. GCB дефинира пространствени модификатори: DU, CV, площни дялове по влагови класове и устойчиви сухи/влажни клъстери, които обясняват защо стрес или пренасищане могат да възникват локално, дори когато средните стойности за целия грийн изглеждат приемливи. В DSS времевите възли (VWC_today, ETc_today, net balance, краткосрочно натрупване на суша, прогнозирана VWC за следващия ден) определят базовите решения за напояване, а пространствените възли (равномерност/хетерогенност/идентичност на зоните) коригират риска и надеждността и подпомагат целеви решения (настройка на дюзи, аерация, wetting agents, локални корекции на дренажето). (Figure 54).

3.3 Част 3. Развитие на кореновата система

След като в Част 1 беше установено, че растежът и азотната динамика се модулират силно от краткосрочен стрес, а в Част 2, че праговете на VWC и ETc контролират цикъла изчерпване–възстановяване при пясъчно-базирани грийнове, Част 3 се фокусира върху биологичния „приемник“ на тези решения: кореновата система. Резултатите по-долу определят количествено сезонните траектории на кореновата дължина при контрастиращи режими на напояване, след което ги разширяват към пространствени, управленски и дистанционни прокси показатели, които могат да бъдат интегрирани в SMART DSS.

1) Сезонна динамика на кореновата дължина при Daily (D) спрямо Water-Deficit (WD) напояване (2023–2024)

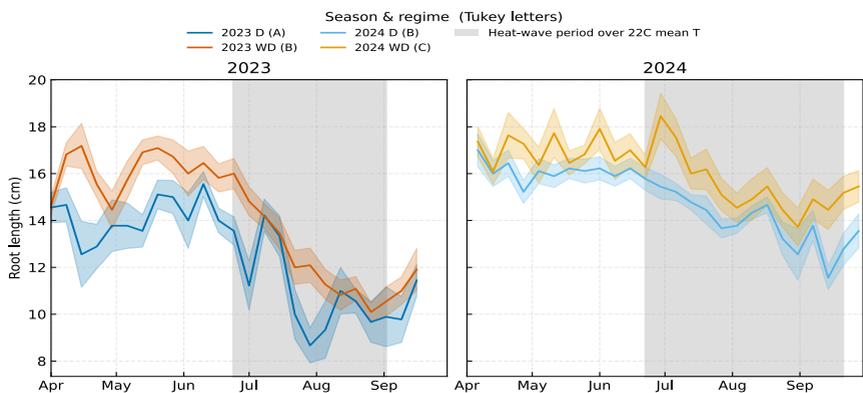


Figure 35. Seasonal root-length dynamics under daily (D) and water-deficit (WD) irrigation (2023–2024). ime-series of root length showing consistent spring increases to 15–18 cm, followed by summer decline.

И през двете години кореновата дължина следва последователна сезонна траектория: пролетно увеличение (април до юни) към пикове около 15–18 cm, последвано от прогресивен летен спад (юли до септември). WD последователно формира по-дълбоки корени от D, с по-ясно разграничение в началото на сезона и запазено предимство през периодите на стрес. Периодите на топлинни вълни (в сиво) съвпадат с началото на ускорения спад, като при D се наблюдава по-рязък среднолетен срив, особено през 2023 г., докато WD намалява темпа на спад и поддържа по-дълго функционални корени в прозореца на топлинните вълни. След пиковия стрес се наблюдава частично възстановяване, но без връщане към пролетните максимуми, което съответства на типичен сезонен модел на вкореняване при С3 при летен стрес. (Figure 55)

2) Йерархия на между режимите, потвърдена чрез модел със смесени ефекти

Смесеният модел потвърди, че корените през 2024 г. са значимо по-дълги от тези през 2023 г. (приблизително +2.40 cm, $p < 0.001$). Взаимодействието Season \times Irrigation не е значимо ($p = 0.29$), което показва, че предимството на WD е било стабилно между годините, а не зависимо от конкретната година. Tukey compact-letter display предоставя ясно за интерпретация разделяне на групите:

- **2023-D:** най-къси корени
- 2023-WD и 2024-D: средни резултати
- **2024-WD:** най-дълбоки

Това установява ясна управленска градация в набора от данни:

Daily напояване (най-плитки) \rightarrow Water deficit (по-дълбоки) \rightarrow Water deficit плюс по-благоприятен сезон (най-дълбоки).

Table 10. Mixed-effects model summary for root length across seasons and irrigation regimes. Fixed-effect estimates indicating that 2024 roots were significantly longer than 2023 roots, the irrigation main effect was modest when examined alone, and the Season \times Irrigation interaction was non-significant. The seasonal improvement and irrigation-driven differences are captured more clearly in group means than in raw coefficients, due to model centering.

Effect	Interpretation
Season (2024 > 2023)	2024 had significantly longer roots overall ($\sim +2.40$ cm, $p < 0.001$), consistent with cooler early-season conditions and slightly lower ET demand.
Irrigation main effect	The WD vs. D difference was detectable but not statistically large as a main effect—because the interaction captures most of the variation.
Season \times Irrigation interaction	Not statistically significant ($p = 0.29$), meaning the WD advantage was consistent across years , not dependent on season.

Table 11. Tukey compact-letter display (CLD) for treatment-based root-length groupings

Group	Treatment	Interpretation
-------	-----------	----------------

A	2023-D	Shortest roots
B	2023-WD, 2024-D	Intermediate depths
C	2024-WD	Deepest roots

3) Пространствена структура между AOIs, разделена по режим на напояване и торене (GP, GP+25%, GP-25%)

Разпределенията на кореновата дължина между AOIs показват силна пространствена структура на пътинг грийна. Еднофакторният ANOVA показва силно значим ефект на AOI ($F_{19,1000} = 10.0$, $p < 0.001$) и силно значим ефект на годината ($F_{1,1018} = 142.3$, $p < 0.001$), в съответствие с резултатите от сезонния модел. В представянето чрез violin и boxplot по AOI зоните с WD като цяло се изместват към по-дълбоки корени спрямо зоните с D, докато интензивността на торенето модифицира „обвивката“ на разпределенията на кореновата дължина. В този набор от данни pt1 (GP+25%) има тенденция към най-плитки разпределения, а pt2 (GP-25%) към най-дълбоки, докато повечето GP зони заемат междинен диапазон. Този пространствен изглед допълва времевите редове: разделението D спрямо WD се запазва в цялата пробоотборна област и не е само преходен сезонен феномен.

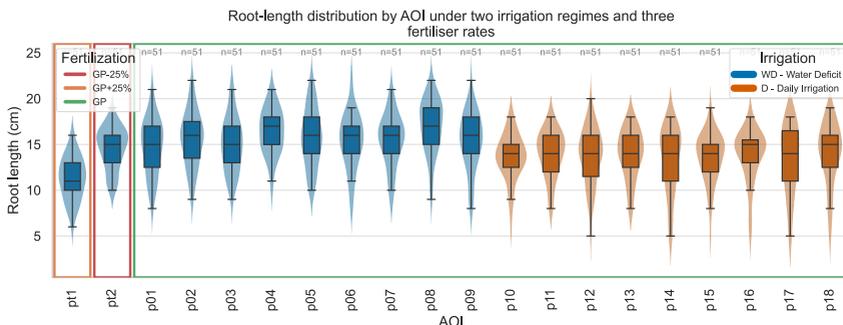


Figure 36. Spatial distribution of root length across AOIs, irrigation regimes, and fertilisation treatments. Violin + boxplots showing the full distribution of root lengths across the green. WD zones generally exhibit deeper roots than D zones, while fertilisation intensity (GP-25 %, GP, GP+25 %) modulates the lower and upper extremes.

4) Годишни реакции на режимите в зависимост от напояване × торене (разпределение на стойностите)

Когато данните се прегрупираат по година и ниво на торене (GP+25%, GP, GP-25%) и се разделят по режим на напояване, медианите нарастват в повечето панели от 2023 към 2024 г., което потвърждава, че ефектът на годината е устойчив във всички управленски режими. В рамките на всяко ниво на торене WD има тенденция да поддържа равна или по-голяма коренова дължина спрямо D, като предимството на WD

е най-видимо през 2024 г. При GP–25% WD поддържа относително дълбоки корени с по-тесен IQR, което предполага по-ограничена, но стабилна коренова система при комбинирани спестявания на N и вода. Заедно този блок подкрепя емпирично дефинирани „рамки на кореновата дължина“ за всяка управленска комбинация за нуждите на DSS.

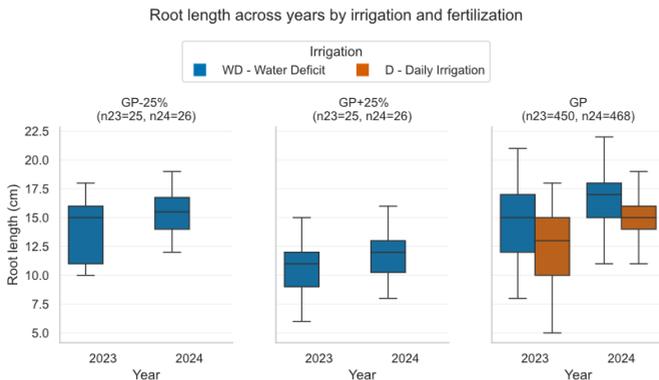


Figure 37. Year-by-year root-length responses by irrigation regime and fertilisation level. Faceted boxplots comparing 2023 and 2024, grouped by fertilisation strategy.

5) Прокси чрез дистанционни изследвания: единичен VI с лаг спрямо композит за проследяване на кореновата дължина (WD спрямо D)

Единичните VIs с лаг показват смислени асоциации с кореновата дължина и при двата режима на напояване, като връзките са разпределени между няколко индекса и лагове, вместо да се концентрират в един VI. Най-добрият единичен VI–лаг за всеки режим осигурява полезен базов спектрален прокси, потвърден визуално чрез регресионни scatterplot графики с confidence intervals.

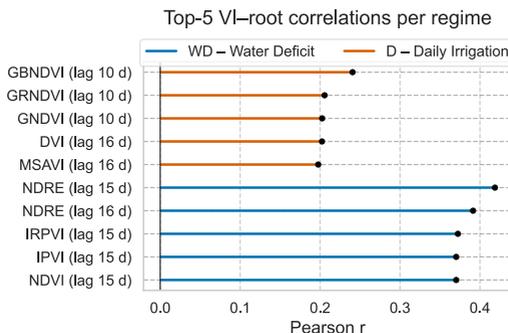


Figure 38. Ranked correlations of single lagged VIs with root length under WD and D irrigation regimes. Forest plot showing the strongest $|r|$ values for each irrigation regime. Multiple lagged VIs

exhibit meaningful associations with root length, confirming that belowground dynamics can be partly inferred from delayed canopy responses

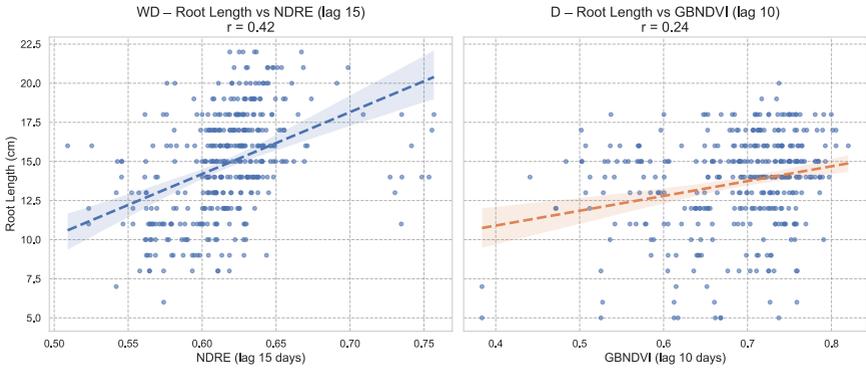


Figure 39. Scatterplots of root length versus the best single VI–lag combination for each irrigation regime. Regression plots (with 95% CIs) illustrating the strongest single spectral predictors of root length for WD and D. Both show clear monotonic relationships, with tighter clustering under D and greater variability under WD.

Greedy композитна процедура, която комбинира множество VI–лаг двойки, увеличи $|r|$ най-силно при прехода от $k = 1$ към $k \approx 2-3$, след което подобренията се насищаха или намаляваха. Най-добрите композити постигат корелации, които са поне толкова силни и обикновено малко по-силни от най-добрия единичен VI. Профилите на теглата показват, че само малък поднабор от VI носи основното влияние във всеки композит, което подкрепя пестелив (парсимоничен) дизайн - малки композити са напълно достатъчни. Кривата на маргиналното подобрение ($\Delta|r_k|$) потвърждава намаляваща възвръщаемост след малък k , което е важно за възможната интерпретация на DSS.

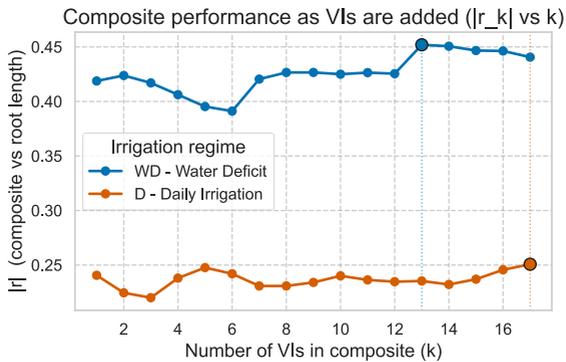


Figure 40. Correlation trajectories for greedy composite VI construction ($|r_k|$ vs k) under WD and D. Curves showing how composite–root correlations change as additional VIs are added. The strongest

improvements occur at $k = 1-3$, after which gains plateau or decline, demonstrating diminishing returns and supporting low-dimensional composite design

Анализите за устойчивост с времеви блокове и bootstrap confidence intervals показват, че знакът на корелацията остава стабилен, а получените bootstrap разпределения имат интервали, които не включват нулата.

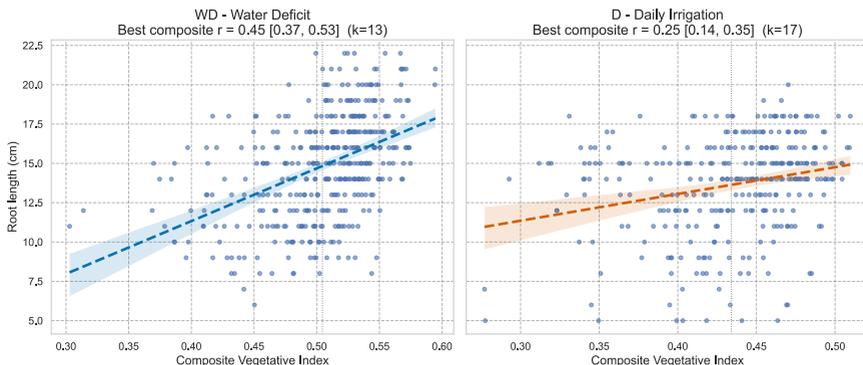


Figure 41. Scatterplots of root length versus the best composite VI for each irrigation regime. Plots showing that composite indices achieve equal or slightly stronger correlations than the best single VI, with stable regression lines and Fisher-transformed confidence intervals excluding zero. Composites smooth noise and better represent integrated canopy signals.

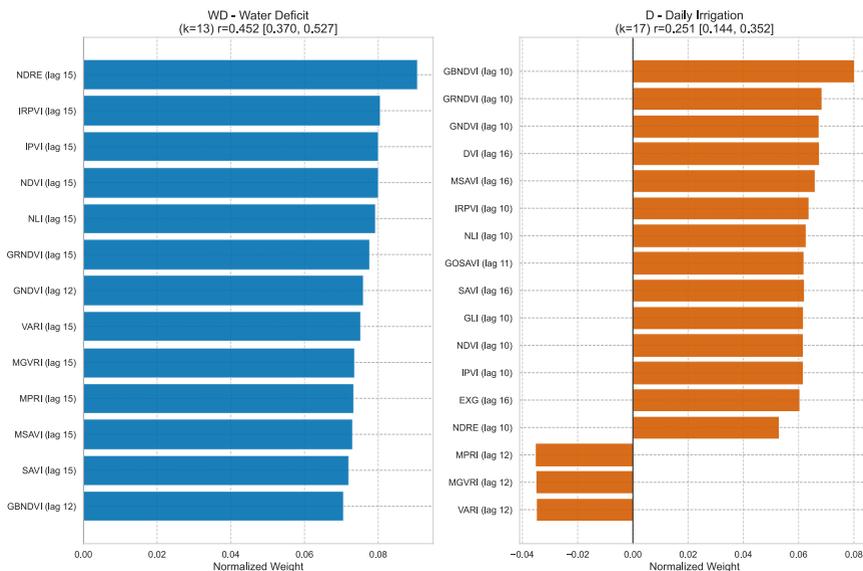


Figure 42. Normalised VI weight profiles for the best composite index under each irrigation regime. Weight distributions showing that only a few VIs carry strong influence in each composite, while most

contribute marginally. High-weight VIs correspond to those with strong individual correlations, indicating internal consistency in composite construction.

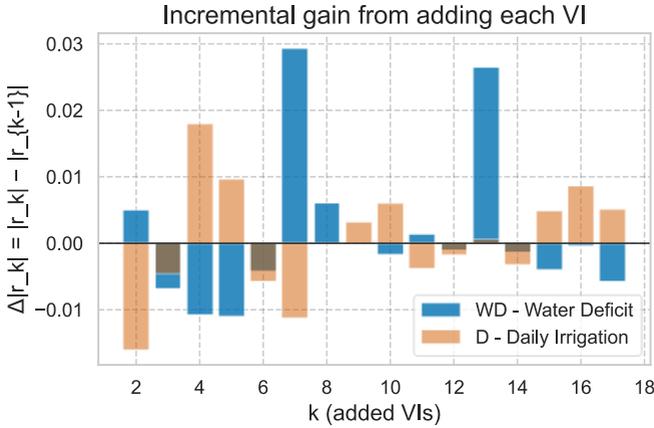


Figure 43. Change in composite-root correlation ($\Delta|r_k|$) as a function of composite size (k). $\Delta|r_k|$ plots illustrating that the largest improvements occur when moving from $k = 1$ to $k = 2-3$. Later additions yield negligible or negative changes, reinforcing the optimality of small composites for DSS use.

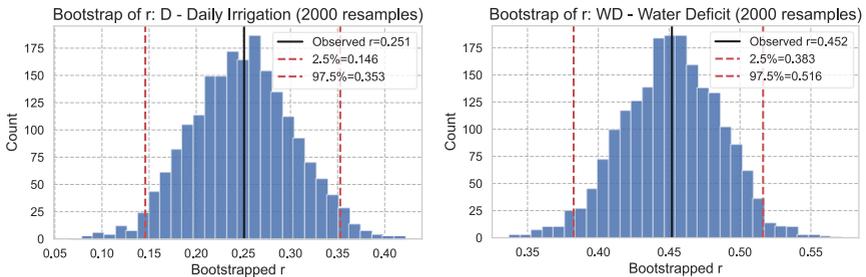


Figure 44 and Figure 45. Robustness checks for composite-root relationships: temporal block correlations and bootstrap confidence intervals. Panels showing stable correlation signs across temporal blocks and unimodal bootstrap distributions with 95% intervals not crossing zero. These results confirm that composite-root linkages are seasonally persistent and not driven by isolated events.

6) Прогностично моделиране на коренова дължина (ENV vs. ENV+VI/CVI; по режими)

И при двата режима прогнозните модели обясняват умерен дял от вариацията в тестовите набори. За D най-добрата конфигурация е Linear regression с ENV + най-добър единичен VI (FeatureSet B) с $R^2 \approx 0.47$ и $RMSE \approx 2.04$ cm, докато моделите само с ENV са по-слаби ($R^2 \approx 0.25$). За WD най-добрият модел е Random Forest с ENV +

единичен VI (FeatureSet B) с $R^2 \approx 0.43$ и $RMSE \approx 2.74$ cm, докато моделите само с ENV вече се представят силно ($R^2 \approx 0.42$). Добавянето на единичен VI и CVI едновременно не води до последователни подобрения, което подсказва наличие на излишност. Междугодишните тестове за трансфер (обучение 2023 → тестване 2024) дават отрицателни стойности на R^2 , което показва, че за оперативна употреба е необходима годишно специфична прекалибрация

Table 12. Predictive model performance for root-length forecasting under daily (D) and water-deficit (WD) irrigation. Test-set R^2 and RMSE for four learners (Linear, Gradient Boosting, LightGBM, Random Forest) using different feature sets (ENV only; ENV + single VI; ENV + CVI; ENV + both). ENV+single VI provides the most reliable gains, particularly under daily irrigation. Inter-year transfer models (2023→2024) perform poorly, confirming the need for annual recalibration.

Regime	Model	FeatureSet	R2	RMSE
D - Daily Irrigation	GBM_2023→2024	A_ENV	-2.97	NaN
	GradientBoosting	C_ENV+CVI	0.467	2.26
	LightGBM	C_ENV+CVI	0.456	2.28
	Linear	B_ENV+SINGLE	0.472	2.04
	RandomForest	C_ENV+CVI	0.419	2.36
WD - Water Deficit	GBM_2023→2024	B_ENV+SINGLE	-1.182	NaN
	GradientBoosting	A_ENV	0.423	2.31
	LightGBM	A_ENV	0.423	2.31
	Linear	D_ENV+SINGLE+CVI	0.403	2.81
	RandomForest	B_ENV+SINGLE	0.431	2.74

SHAP обобщенията за ENV+CVI моделите показват, че в двата режима доминират приносите на екологичните драйвери (влагоналичност и атмосферни променливи), като композитният VI действа като вторичен, физиологично съгласуван модификатор на състоянието на тревната повърхност.

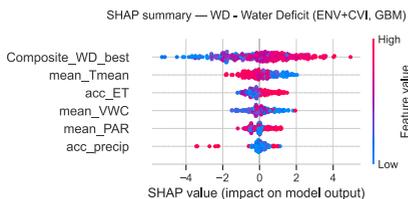


Figure 46. SHAP summary — D (ENV+CVI, GBM). Features ranked by mean absolute SHAP value for a gradient-boosting model fit within the D regime using environmental covariates plus the best CVI.

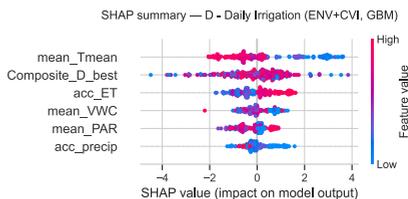


Figure 47. SHAP summary — WD (ENV+CVI, GBM). Composite_WD_best has the largest and most consistently positive impact, followed by air temperature and cumulative ET.

Част 3 предоставя два допълващи се коренови сигнала за DSS: (i) сезонна, чувствителна към стрес траектория, при която WD последователно стабилизира кореновата дължина в периодите на топлинни вълни, и (ii) оперативен прокси слой, при който малък брой Vis с лаг, за предпочитане като нискоразмерен композит, може да проследява и умерено да подобрява прогнозите за кореновата дължина, когато е комбиниран с екологични драйвери. Заедно тези резултати дават дискретизирани BN състояния за „root condition“ и позволяват кореновата дълбочина да действа като средносрочно ограничение както при избора на прагове за напояване, така и при азотните „safety margins“ при пясъчни условия.

Резултатите за корените показват, че стратегията на напояване формира предсказуема сезонна обвивка на вкореняването и че спектралните сигнали от тревната повърхност могат да служат като компактен прокси за подземния статус, когато са съгласувани с подходящи лагове. Това подготвя Част 4, където компонентът за дистанционни изследвания се разширява отвъд кореновите прокси към по-широк мониторинг на тревната повърхност, пространствената AOI хетерогенност и извличането на VIs, които могат непрекъснато да обновяват състоянията на стрес и представяне по цялата повърхност на грийна.

3.4 Част 4. Анализ на VIs и работен поток за дистанционни наблюдения

Части 1–3 установиха, че (i) сигналите за азотната динамика и обема откос, са ограничени от кратки стресови прозорци, (ii) праговете за напояване се определят от ETC-обусловено изчерпване на почвената влага и пространствена хетерогенност, и (iii) кореновото състояние реагира предсказуемо на режима на напояване и може да се представи чрез Vis с лаг. Част 4 надгражда това чрез изграждане на защитим работен процес за дистанционни наблюдения: първо се гарантира, че VI статистиките представят само тревните AOIs, след което многосезонните VI архиви се компресират в стабилни режими на състоянието на тревната повърхност и VI семейства, които могат да бъдат опростени до входни възли за BN/DSS.

1) U-Net сегментация на пътинг грийнове (computer-vision фронтенд)

Мотивация и смяна на модела. Надеждното дефиниране на AOI е предпоставка за смислени VI времеви редове. Имплементиран е U-Net модел за семантична сегментация, който генерира маски за цялото изображение на ниво пиксел, с геометрична непрекъснатост, подходящи за последващо извличане на VI.

Данни за обучение и настройка. UAV RGB кадри (2560×1440) бяха извлечени и ръчно анотирани за означаване на границите на пътинг грийновете. Кадрите бяха обединени от множество „jobs“ за анотиране и разделени 70/15/15 на train/val/test за всеки job. Изображенията бяха преоразмерени до 512×512, аугментирани (ротация, скалиране, обръщания) и нормализирани (ImageNet статистики). U-Net използваше RGB вход и

един изходен клас (green) с encoder–decoder структура (64/128 down-sampling етапи, 256 bottleneck), Adam (LR 1×10^{-4}), BCEWithLogits loss, StepLR scheduler и batch size 12, като се оценяваше чрез IoU и Dice на епоха.

Резултати при обучение. Загубата намаля бързо в рамките на ~ 20 – 30 епохи и остава ниска (< 0.02) в хода на обучението. Validation loss спада от ~ 0.25 – 0.30 в началото до ~ 0.001 – 0.005 в последните епохи. Медианното представяне при валидация е високо (IoU ~ 0.95 , Dice ~ 0.96), като в късните епохи се достигаха IoU ≈ 0.99 и Dice ≈ 0.99 . Загубите при обучение и валидация следваха близки траектории, което показва ограничено пренапасване.

Качествена достоверност на маските. Предсказаните маски улавят пълната геометрия на грейна (извити периметри, лобове), като изключват бункери, collars, пътеки и rough дори когато разликите в цвят/текстура са слабо изразени. Маските с пълна резолюция запазиха оригиналната решетка, което позволи директно повторно използване при извличане на UAV и PlanetScope VIs и percentile/CV статистики. В DSS качеството на сегментацията директно влияе върху калибрацията на VI възлите и следователно върху надеждността на извлечените доказателства за стрес, N статус и влагово състояние.

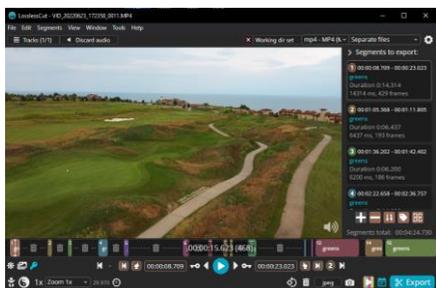


Figure 48. Example of UAV frame extraction for segmentation training



Figure 49. Manual annotation of putting-green boundaries for U-Net training.

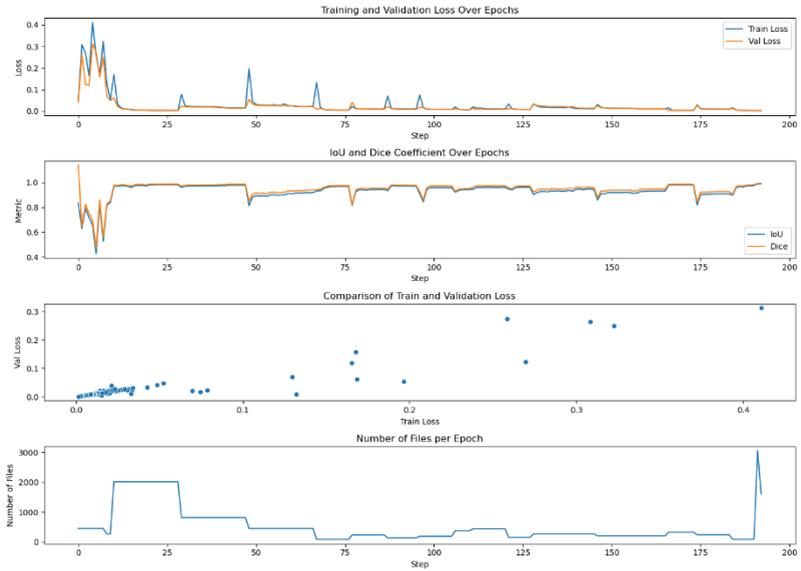


Figure 50. Training and validation performance of the U-Net segmentation model.

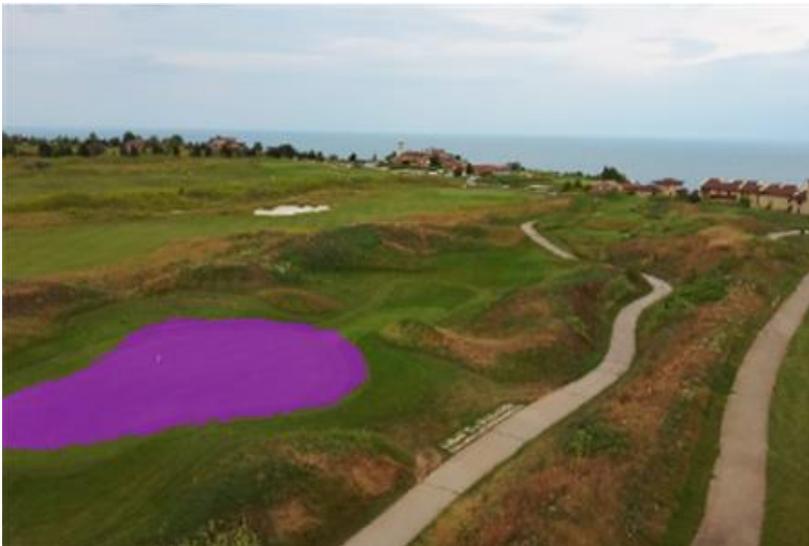


Figure 51. Predicted segmentation masks on held-out UAV frames. An example demonstrating the U-Net's ability to capture curved perimeters, narrow collars, and subtle geometric features while excluding bunkers, paths, and rough.

2) Многосезонни режими на тревната повърхност чрез клъстеризация на времеви признаци ($k = 10$)

Многосезонният архив беше компресиран чрез изчисляване, за всеки пиксел и за всеки VI, на три времеви дескриптора (средна стойност, вариация, тренд), след което пикселите бяха клъстеризирани в $k = 10$ режима. Идентификаторите на клъстерите бяха преетикетирани по нарастваща средна стойност, за да се получи интуитивна подредба от хронично слаби/оголени повърхности към устойчиво плътен тревни повърхности с високи VI стойности.

Резултати за целия обект (GCA, GCB). Клъстеризацията по NDVI и NDRE формира последователна пространствена структура: клъстерите с ниска средна стойност (0–3) бяха основно нетревни площи (дървета/сгради/периферни rough зони) и участъци, повлияни от облачно замърсяване. Междинните клъстери (4–6) се съгласуваха с феъруите и semi-rough, характеризиращи се с умерени VI стойности и по-висока вариация. Клъстерите с висока средна стойност (7–9) се съгласуваха със сегментираните пътинг грийнове и ограничен брой интензивно напоявани околни зони, характеризирани с високи средни VI стойности и относително ниска вариация. Подобна подредба се наблюдава и при други индекси, което показва, че режимите отразяват устойчиви мозаики тревна–нетревна покривка, а не артефакти на индекса.

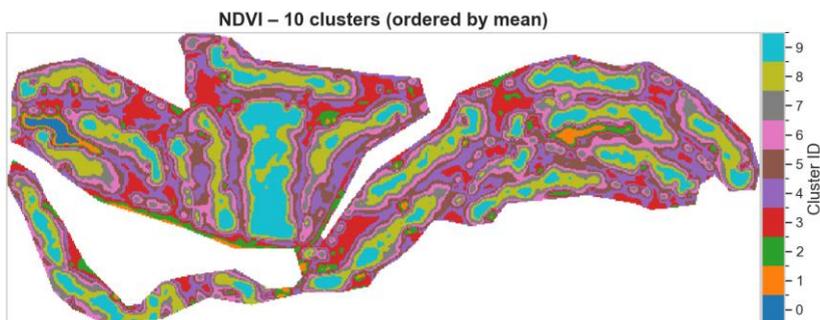


Figure 52. Example of multi-season NDVI clustering results ($k = 10$) across the full GCA

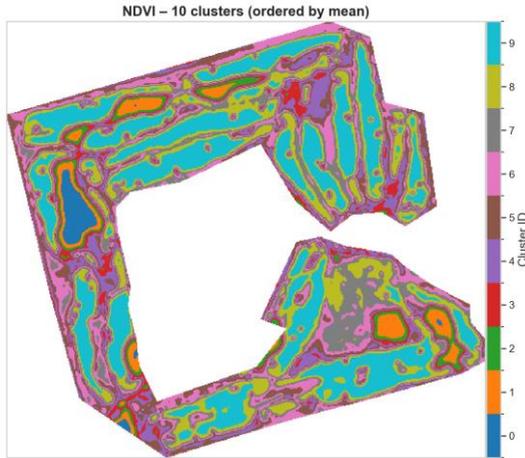
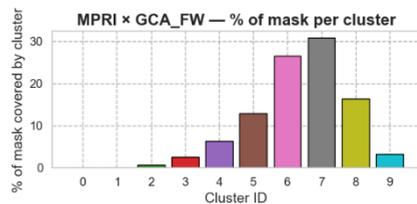
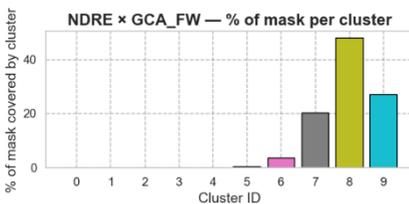


Figure 53. Example of multi-season NDVI clustering results ($k = 10$) across the full GCB.

3) Грийнове спрямо феъруеи в пространството на режимите (припокриване/състав на клъстерите)

Пресичането на клъстерните карти с бинарни маски за грийнове и феъруеи определи количествено как всяка зона се представя. Феъруеите се разпределяха между междинни и високи клъстери, което отразява хетерогенност поради частично напояване, вариации в косенето, наклони и епизодичен стрес. Грийновете бяха доминирани от най-високите режими, като повече от половината площ на грийновете попадеше в най-горния клъстер (ID 9), а останалата част основно в клъстер 8, в съответствие с плътни и стабилни тревни покрития. Ограниченията на VIs също са видими: NDVI показва сатурация (силна концентрация в най-високите клъстери), докато MPRI запази по-широка вариабилност между клъстерите дори при грийнове. Същото качествено разделение (грийнове, концентрирани в най-високите режими; феъруеи, разпределени в междинни режими) се наблюдаваше и при двата обекта, GCA и GCB.



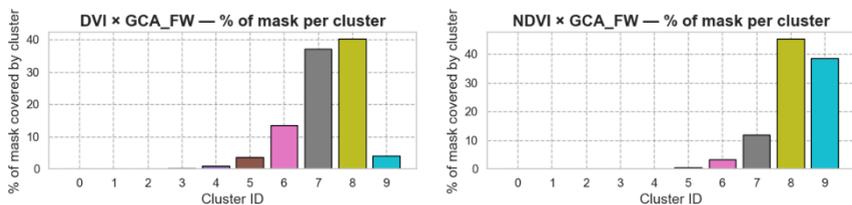


Figure 54 . Cluster-composition of fairway pixels: example distribution for NDRE, MPRI, DVI, NDVI (GCA).

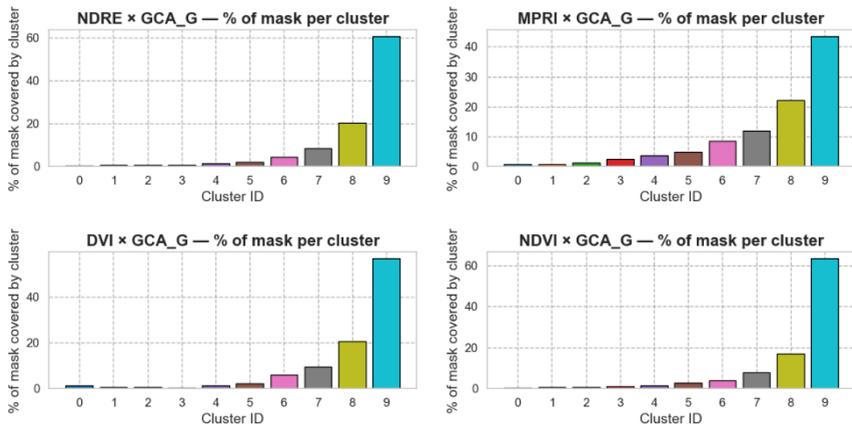


Figure 55. Cluster-composition of putting-green pixels: example distribution for NDRE, MPRI, DVI, NDVI (GCA).

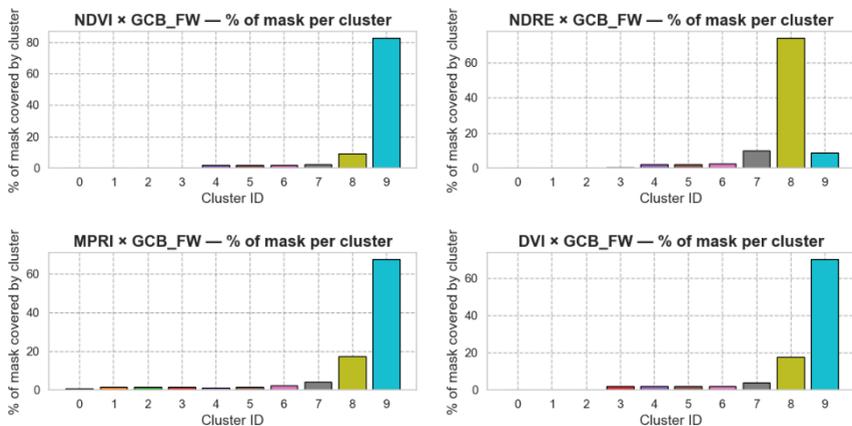


Figure 56. Cluster-composition of fairway pixels: examples for NDRE, MPRI, DVI, NDVI (GCB)

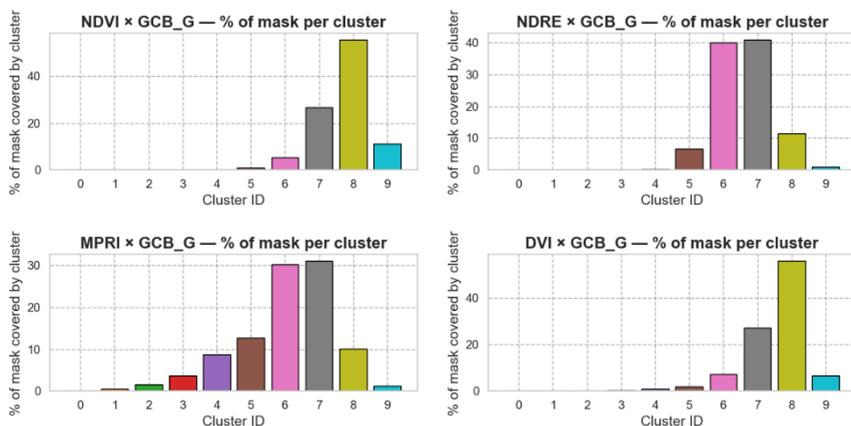


Figure 57. Cluster-composition of putting-green pixels: examples for NDRE, MPRI, DVI, NDVI (GCB).

4) Сходни семейства на VIs (по повърхност и по обект)

Тъй като много индекси носят припокриваща се информация, анализът на сходни семейства групира VIs със споделено многосезонно поведение отделно за феъруеи (FW) и грийнове (G).

GCA fairways (Table 30; Figure 78). Семействата включват: (i) контраст във видимите канали плюс почвено-коригиран NIR (DVI/GLI/MSAVI/SAVI), (ii) индекси за цвят-стрес (EXG/MGVRI/MPRI/VARI), (iii) green–NIR структурна двойка (GBNDVI/GNDVI), (iv) самостоятелен MSR, (v) самостоятелен RVI, (vi) структурен ансамбъл при висока плътност (GRNDVI/IPVI/IRPVI/NDVI), и (vii) red-edge/почвено-коригирани хибриди (GOSAVI/NDRE/NLI).

Table 13. GCA Fairways *similarity groups*, Similarity families obtained from multi-season clustering of VI trajectories across fairways. Each group represents a set of indices with shared temporal behaviour and physiological meaning (colour-based stress, structural NIR–green ensembles, red-edge variants).

GCA Fairways Similarity groups		
Group	VI	
Group 0 Visible-band contrast with soil-adjusted NIR VIs	DVI, GLI, MSAVI, SAVI	This group blends simple visible-band contrast indices (DVI, GLI) with soil-adjusted NIR formulations (MSAVI, SAVI). Their shared overlap pattern suggests that under fairway conditions, soil brightness, partial canopy cover, and moderate biomass levels create conditions where visible-band contrast and soil-adjusted NIR ratios respond similarly.
Group 1 Colour-contrast indices	EXG, MGVRI, MPRI, VARI	These indices cluster together because they emphasise short-term colour changes linked to heat, drought, mowing patterns, and surface quality. Their grouping confirms that colour-space transformations (EXG, VARI) and green–red

		gradients (MGVRI, MPRI) encode a shared stress-sensitive signal.
Group 2 Green–NIR two-band structural VIs	GBNDVI, GNDVI	These indices form a compact family capturing NIR–green structure in medium-density canopies. Their behaviour remains distinct from NDVI or red-edge formulations, indicating unique sensitivity to moderate canopy thinning.
Group 3	MSR	The Modified Simple Ratio forms a unique group. Its normalisation of RVI and reduced sensitivity to illumination produces a signature that does not align with any other family on fairways.
Group 4 Ratios	RVI	This index stands alone, reflecting its tendency to saturate more quickly and produce behaviour distinct from difference-based indices.
Group 5 High-density NIR-green/red families	GRNDVI, IPVI, IRPVI, NDVI	These indices cluster into a shared structural family representing stable chlorophyll-related behaviour. They capture the higher-end of canopy reflectance dynamics and share nearly identical spatial signatures.
Group 6 Red-edge and soil-adjusted hybrids	GOSAVI, NDRE, NLI	These indices express the red-edge and soil-adjusted behaviour under fairway heterogeneity. Their grouping indicates sensitivity to intermediate canopy density and subtle biochemical variation.

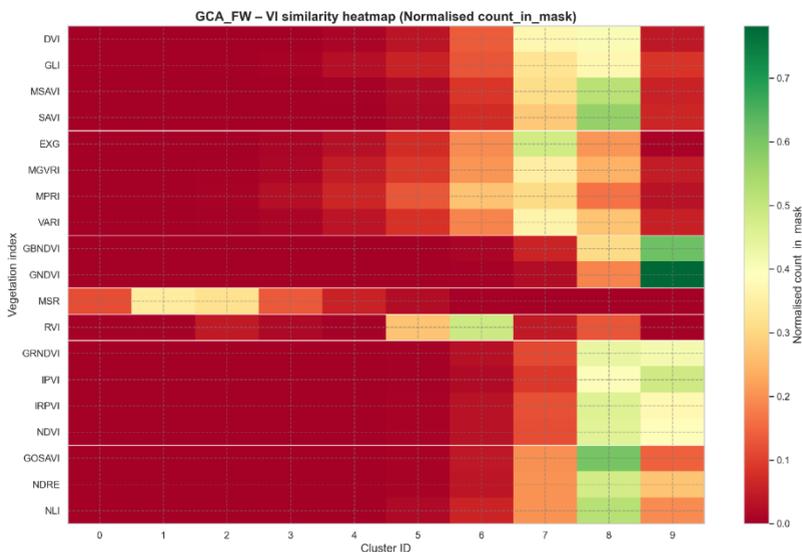


Figure 58. Visualisation of VI similarity groups for GCA fairways

GCA greens (Table 31; Figure 79). При грийновете се наблюдаваше по-голяма диференциация въпреки относителната еднородност на тревната повърхност: (i) семейство за цвят/яркост (EXG/GLI/MGVRI/VARI), (ii) широко структурно NIR семейство (GBNDVI/GOSAVI/GRNDVI/IRPVI/NDVI/NLI), (iii) семейство почвено-коригирани + red-edge (DVI/MSAVI/NDRE/SAVI), като RVI/MSR останаха изолирани, а MPRI формира независим клъстер.

Table 14. GCA G Similarity groups. Similarity groupings of multi-season VI behaviour on putting greens. Structural NIR–red/green families dominate, while colour-based VIs form a distinct group capturing subtle brightness and hue shifts on dense turf.

GCA G Similarity groups		
Group	VI	
<u>Group 0</u> Surface colour and brightness	EXG, GLI, MGVRI, VARI	These indices isolate rapidly changing colour and brightness patterns on greens. Their grouping shows that despite canopy uniformity, subtle surface colour variations remain detectable at pixel scale
<u>Group 1</u> Structural NIR/green–red	GBNDVI, GOSAVI, GRNDVI, IRPVI, NDVI, NLI	This broad family represents the dominant structural signal of dense turf. Here, NDVI merges with G*NDVI-type indices and soil-adjusted variants (GOSAVI, NLI), indicating that under high canopy density, multiple NIR-based formulations converge to the same spectral behaviour.
<u>Group 2</u> Soil-adjusted and red-edge VIs	DVI, MSAVI, NDRE, SAVI	Unlike fairways, these indices form a separate group. The presence of NDRE shows that even on greens, slight biochemical variation persists, while MSAVI and SAVI map small changes in canopy thickness. DVI joins this group because visible-band differences become structurally similar when the canopy is uniformly dense.
<u>Group 3</u>	RVI	Still behaves independently because ratio-based indices saturate strongly on greens and lose contrast relative to difference-based indices.
<u>Group 4</u> NIR–green structural	GNDVI, IPVI	This group captures the most stable portion of the high-density canopy signal. Their convergence suggests consistency in how green–NIR ratios behave across multi-season imagery.
<u>Group 5</u>	MSR	Again isolated as a standalone group, consistent with fairway behaviour.
<u>Group 6</u>	MPRI	Forms its own cluster, indicating that on greens it captures a colour variation distinct from the broader stress-colour family.

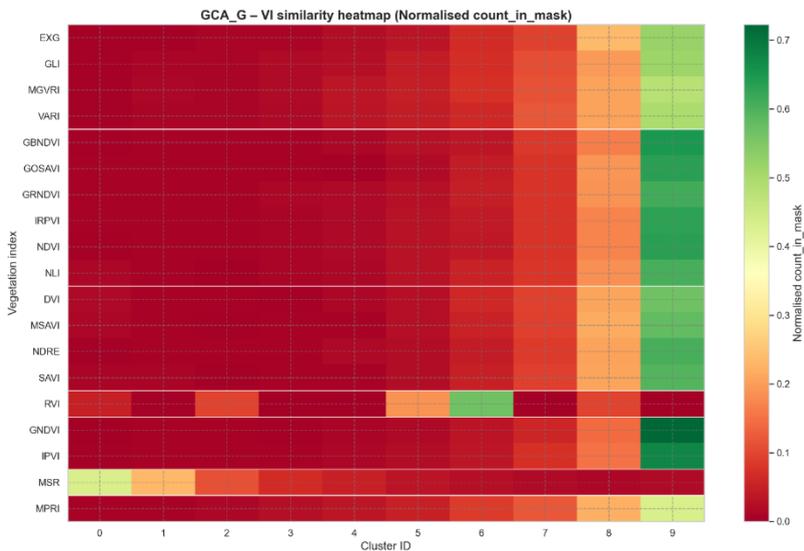


Figure 59. Visualisation of VI similarity groups for GCA greens

GCB fairways and greens (Tables 32–33; Figures 80–81). Общата структура наподобява тази при GCA, но няколко измествания предполагат по-силно разделение между цветови и структурни индекси и по-специфично за red-edge. При GCB fairways VARI се отдели като самостоятелно семейство, а NDRE формира собствена група, вместо да се слива с почвено-коригирани/red-edge хибриди. При GCB грийнове се формира смесено семейство между цветови индекси и NDRE, докато структурният ансамбъл остана доминиращ; EXG се отдели самостоятелно.

И при двата обекта моделите подкрепят физически обосновано опростяване: структурните NIR-базирани индекси формират гръбнака на информацията за плътност на тревната покривка, цветовите индекси улавят краткосрочни промени на стрес/яркост, почвено-коригираните индекси се държат различно в зависимост от плътността и почвено-оголване, а red-edge индексите могат или да се слят със структурните сигнали, или да се отделят в зависимост от специфични за обекта биохимични градиенти.

Table 15. GCB fairways VI similarity groups. Similarity families for GCB fairways. The grouping shows stronger separation between colour-based indices and structural ensemble VIs compared with GCA, with site-specific behaviour for VARI and NDRE.

GCB Similarity groups		
Group	VI	
Group 0 Visible-band contrast + soil-adjusted indices	DVI, MPRI, MSAVI, SAVI	This group merges simple visible-index differences (DVI, MPRI) with soil-adjusted NIR indices (MSAVI, SAVI). Their overlap pattern suggests that fairway canopy density at GCB often exposes soil background (regular hollow tine aeration), causing these indices to respond similarly.
Group 1 High-density structural NIR/green/red ensemble	GBNDVI, GNDVI, GOSAVI, GRNDVI, IPVI, IRPVI, NDVI, NLI	This large family represents the structural canopy signal across fairways. These VIs converge where the canopy is moderately stable, irrigated, and biochemical variation is low. Their grouping matches what was observed at GCA, but with stronger consolidation, indicating reduced separation between green- and red-edge-driven formulations.
Group 2 Colour-based stress/brightness indices	EXG, GLI, MGVRI	This group captures rapid colour or spectral brightness changes associated with mowing, traffic, partial drought, or shallow soil moisture variability. The separation from Family 3 (VARI alone) suggests GLI and EXG behave differently at GCB than at GCA, likely due to different mowing height (FW is creeping bentgrass, maintained at lower height) and soil type (FW is sand, compared to top soil for GCA).
Group 3	VARI	VARI isolates into its own group, reflecting its strong sensitivity to green/red/blue balance under uneven illumination. On GCB fairways, VARI identifies stress signatures not fully captured by the EXG-GLI cluster.
Group 4	RVI	As in GCA, RVI saturates quickly and remains isolated.
Group 5	MSR	Non-linear scaling causes MSR to behave uniquely, separating from the red-edge and NIR families.
Group 6	NDRE	Unlike GCA where NDRE grouped with soil-adjusted indices, it forms its own family at GCB. This indicates unique behaviour of the red-edge on these fairways, possibly due to stronger spatial heterogeneity, surface maintenance or red-edge sensitivity to subtle canopy stress.

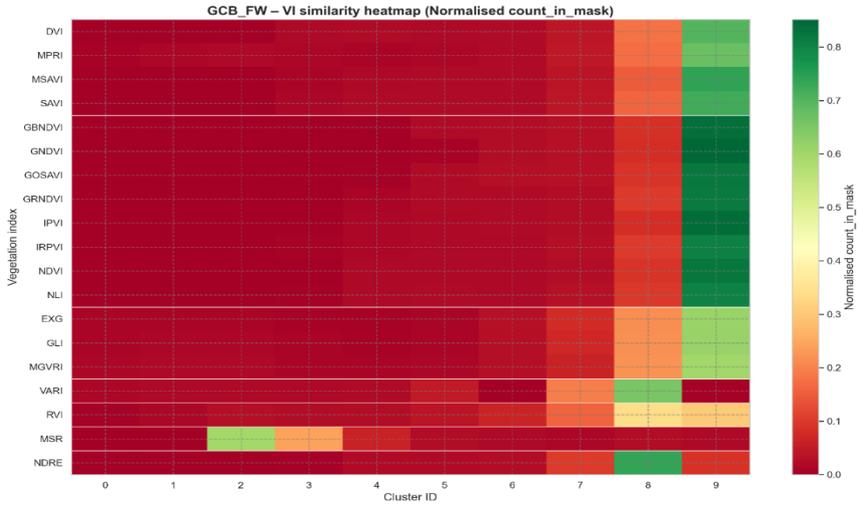


Figure 60. Visualisation of VI similarity groups for GCB fairways.

Table 16. GCB greens VI similarity groups. Grouping results for putting greens at GCB, with colour-based indices and NDRE forming a mixed family, and structural NIR–red/green indices forming the dominant ensemble. MSR and RVI remain isolated due to saturation properties.

GCB- G Similarity groups		
Group	VI	
Group 0 Colour-space and partial red-edge	GLI, MGVRI, MPRI, NDRE	A unique mixture of colour-based indices. On dense greens, NDRE often collapses into the structural family, but here it aligns with colour indices, likely reflecting slight biochemical variations correlated with colour variability.
Group 1 Broad structural NIR–red/green	DVI, GRNDVI, IRPVI, MSAVI, NDVI, NLI, SAVI	This large family captures the core structural signature of dense greens, where soil-adjusted indices and NIR–green/red ratios converge. This matches GCA, but with GRNDVI and DVI added, showing stronger convergence across canopy thickness gradients.
Group 2 Green–NIR subset	GBNDVI, GNDVI, GOSAVI, IPVI	A stable NIR–green subset reflecting consistent structural behaviour under irrigated high-density greens
Group 3	RVI	Again isolated because of saturation effects
Group 4	VARI	VARI maintains independence, capturing colour behaviour distinct from structural indices.
Group 5	MSR	Behaves as a unique non-linear formulation
Group 6	EXG	Separates from other colour indices at GCB, reflecting distinctive contrast behaviour on these greens (likely influenced by mowing patterns and localised colour variation).

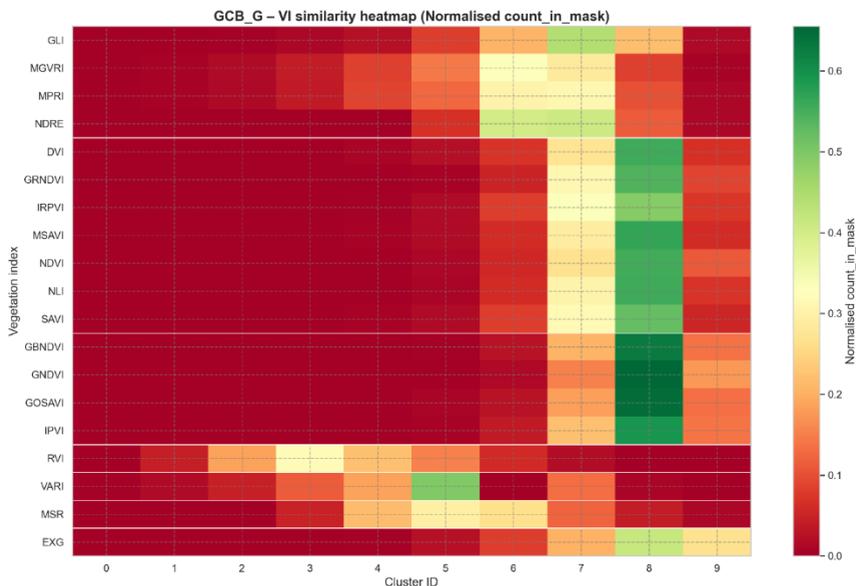


Figure 61. Visualisation of VI similarity groups for GCB greens

5) Дневна чувствителност и предиктивно представяне в рамките на VI семействата (подбор на представители)

Дневно интерполирани VIs са обединени с дневни метеорологични променливи (Tmax, Tmin, ET0, VPD, rainfall, wind и др.) и оценени чрез: (i) най-добра Pearson корелация, (ii) най-добра Spearman корелация и (iii) многовариантни метрики за представяне от Random Forest. Резултатите са последователни между повърхности и обекти:

- **Структурните индекси (NDVI/GNDVI)** показват най-висока обяснителна сила и стабилно поведение между двата обекта и различните повърхности.
- **Цветово-стресовите индекси (MGVRT и VARI)** са най-чувствителни към бърз стрес и промени в цвета, свързани с косене.
- **Почвено-коригираните индекси (MSAVI)** показаха най-силно представяне при частично почвено оголване, особено на феъруеите.
- **Red-edge (NDRE)** има различно поведение, но по-силна обяснителна сила там, където биохимичните градиенти са по-изразени (особено при GCB).
- **Нелинейни/сатуриращи индекси (MSR, RVI)** показват ограничена добавена стойност и по-ниска интерпретируемост.

Тези резултати подкрепиха избора на един представителен VI за всяко семейство за интеграция в DSS.

Table 17. Daily sensitivity and predictive performance of VIs (GCA fairways). Summary of Pearson/Spearman correlations, optimal lags, and Random Forest performance metrics for each VI. Structural indices (NDVI, GOSAVI) and soil-adjusted indices (MSAVI) show highest explanatory power, while visible-range colour indices respond primarily to stress and mowing patterns

Daily sensitivity and predictive performance GCA FW							
VI	Best_Pearson	Best_Spearman	Best_Lag	Lag_Corr	RF_R2	RF_RMSE	Group
DVI	0.651	0.562	0	0.651	0.943	0.013	0
MSAVI	0.649	0.521	0	0.649	0.945	0.020	0
GLI	0.190	0.156	6	0.213	0.898	0.019	0
SAVI	0.630	0.504	0	0.630	0.941	0.017	0
MGVRI	0.227	0.242	3	0.236	0.908	0.038	1
EXG	0.436	0.341	2	0.442	0.923	0.001	1
MPRI	0.226	0.243	3	0.236	0.908	0.020	1
VARI	0.226	0.244	3	0.235	0.908	0.026	1
GBNDVI	0.234	0.204	1	0.241	0.882	0.019	2
GNDVI	0.229	0.208	6	0.237	0.879	0.011	2
MSR	0.219	0.176	6	0.245	0.894	0.004	3
RVI	0.185	0.161	6	0.212	0.896	0.726	4
GRNDVI	0.239	0.196	6	0.257	0.885	0.022	5
IPVI	0.238	0.183	6	0.261	0.890	0.008	5
IRPVI	0.235	0.182	6	0.259	0.889	0.015	5
NDVI	0.238	0.183	6	0.261	0.889	0.017	5
GOSAVI	0.593	0.492	0	0.593	0.931	0.014	6
NDRE	0.339	0.383	14	0.399	0.897	0.014	6
NLI	0.368	0.344	3	0.375	0.907	0.055	6

Table 18. Daily sensitivity and predictive performance of VIs (GCA greens). Performance metrics for each VI on dense green canopies. DVI, MSAVI and SAVI rank highest in structural sensitivity; NDRE captures red-edge biochemical variation; colour indices show weaker but complementary signals.

Daily sensitivity and predictive performance GCA G							
VI	Best_Pearson	Best_Spearman	Best_Lag	Lag_Coeff	RF_R2	RF_RMSE	Group
EXG	0.416	0.354	1	0.421	0.916	0.002	0
GLI	0.213	0.194	6	0.242	0.891	0.020	0
MGVRI	0.188	0.167	12	0.235	0.896	0.042	0
VARI	0.186	0.163	12	0.232	0.896	0.029	0
GBNDVI	0.250	0.219	14	0.258	0.877	0.019	1
GOSAVI	0.559	0.477	0	0.559	0.928	0.014	1
GRNDVI	0.264	0.217	5	0.292	0.881	0.021	1
IRPVI	0.256	0.208	14	0.288	0.884	0.014	1
NDVI	0.259	0.210	14	0.288	0.885	0.016	1
NLI	0.337	0.357	1	0.341	0.902	0.054	1
DVI	0.631	0.533	0	0.631	0.941	0.014	2
MSAVI	0.624	0.497	0	0.624	0.942	0.021	2
NDRE	0.399	0.491	14	0.478	0.903	0.014	2
SAVI	0.602	0.484	0	0.602	0.937	0.018	2
RVI	0.228	0.195	7	0.276	0.888	0.721	3
IPVI	0.259	0.210	14	0.288	0.885	0.008	4
GNDVI	0.269	0.251	11	0.280	0.878	0.011	4
MSR	0.244	0.203	7	0.283	0.887	0.004	5
MPRI	0.188	0.167	12	0.235	0.896	0.021	6

Table 19. Daily sensitivity and predictive performance of VIs (GCB fairways). Performance summary showing strong predictive power of MPRI, MGVRI, EXG and NLI for stress-related responses, and GNDVI/IPVI/NDVI for structural behaviour. NDRE shows strong lagged correlation at GCB.

Daily sensitivity and predictive performance GCB FW							
VI	Best_Pearson	Best_Spearman	Best_Lag	Lag_Coeff	RF_R2	RF_RMSE	Group
DVI	0.374	0.345	11	0.389	0.900	0.032	0
MPRI	0.654	0.641	14	0.775	0.956	0.021	0
MSAVI	0.410	0.401	14	0.481	0.912	0.037	0
SAVI	0.439	0.428	14	0.517	0.919	0.030	0
GBNDVI	0.244	0.323	14	0.285	0.900	0.068	1
GNDVI	0.276	0.329	14	0.314	0.905	0.039	1
GOSAVI	0.362	0.308	14	0.474	0.934	0.015	1
GRNDVI	0.372	0.395	14	0.479	0.921	0.052	1
IPVI	0.482	0.482	14	0.594	0.943	0.016	1
IRPVI	0.477	0.479	14	0.591	0.942	0.026	1
NDVI	0.482	0.482	14	0.594	0.943	0.032	1
NLI	0.544	0.540	14	0.706	0.954	0.047	1
EXG	0.622	0.572	14	0.691	0.947	0.004	2
GLI	0.468	0.490	14	0.575	0.928	0.021	2
MGVRI	0.655	0.641	14	0.776	0.957	0.040	2
VARI	0.583	0.577	14	0.677	0.936	0.060	3
RVI	0.372	0.456	3	0.404	0.912	1.240	4
MSR	0.375	0.421	8	0.406	0.915	0.006	5
NDRE	0.508	0.536	14	0.583	0.937	0.030	6

Table 20. Daily sensitivity and predictive performance of VIs (GCB greens). Metrics showing that colour-stress indices (GLI, MGVI, MPRI) outperform structural indices in explaining variability on dense greens at GCB, reflecting local sensitivity to subtle colour shifts and stress gradients.

Daily sensitivity and predictive performance GCB G							
VI	Best_Pea rson	Best_Spearn an	Best_L ag	Lag_Co rr	RF_R 2	RF_RMS E	Grou p
GLI	0.587	0.606	14	0.653	0.937	0.017	0
MGVRI	0.698	0.693	14	0.761	0.947	0.039	0
MPRI	0.697	0.694	14	0.761	0.947	0.020	0
NDRE	0.546	0.560	14	0.592	0.934	0.028	0
DVI	0.487	0.431	0	0.487	0.906	0.029	1
GRNDVI	0.424	0.444	14	0.500	0.918	0.049	1
IRPVI	0.548	0.546	14	0.626	0.940	0.024	1
MSAVI	0.552	0.530	11	0.569	0.917	0.033	1
NDVI	0.552	0.547	14	0.630	0.941	0.029	1
NLI	0.720	0.708	14	0.801	0.959	0.043	1
SAVI	0.581	0.563	12	0.604	0.924	0.027	1
GBNDVI	0.268	0.356	14	0.336	0.899	0.067	2
GNDVI	0.306	0.362	14	0.377	0.903	0.038	2
GOSAVI	0.565	0.493	14	0.663	0.942	0.013	2
IPVI	0.552	0.547	14	0.630	0.941	0.015	2
RVI	0.467	0.537	14	0.539	0.919	0.845	3
VARI	0.614	0.615	14	0.669	0.930	0.052	4
MSR	0.447	0.515	14	0.476	0.916	0.005	5
EXG	0.710	0.692	11	0.746	0.948	0.004	6

Table 21. Representative VI selection for DSS integration based on family behaviour, sensitivity and predictive accuracy. Representative indices (NDVI/GNDVI, MGVI/VARI, MSAVI, NDRE) summarise distinct physiological components—structural density, colour-stress response, soil adjustment, and red-edge biochemical sensitivity—ensuring interpretable and non-redundant BN nodes.

Family	Representative VI	Rationale
Structural indices	NDVI or GNDVI	Highest RF_R2, stable across clubs and surfaces, interpretable canopy-thickness signal
Colour-based stress	MGVRI or VARI	Strong response to heat/drought stress events; VARI independent at both clubs
Soil-adjusted	MSAVI	Best performance across fairways and greens; robust under partial soil exposure
Red-edge	NDRE	Useful for biochemical stress detection; site-specific value at 27Club
Nonlinear/saturated families	Excluded	Limited added value, low interpretability

6) DSS-ориентирана схема: входни BN възли, производни от VI семействата

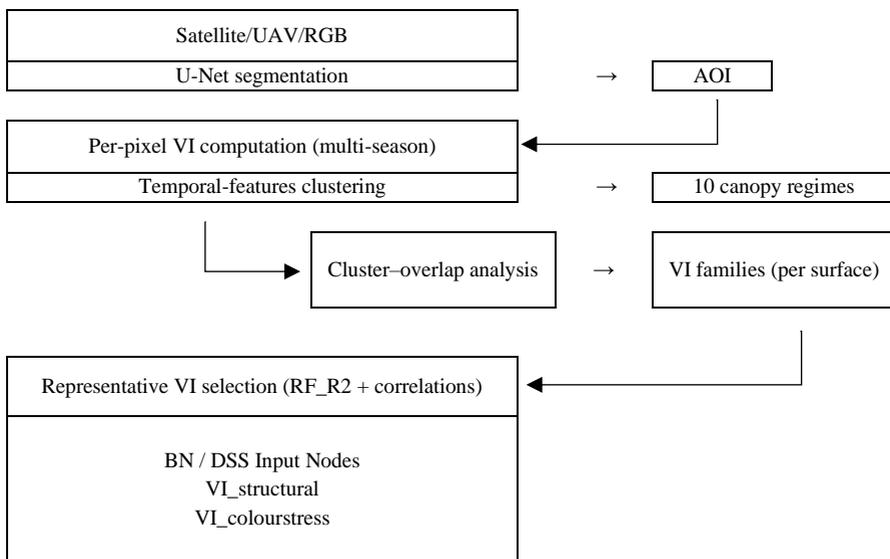


Figure 62. Schematic workflow of the Remote Sensing chapter and DSS integration. Process diagram connecting UAV/satellite imagery, U-Net segmentation, pixel-wise VI extraction, temporal-features clustering, VI family formation, representative VI selection, and downstream BN/DSS node construction (*VI_structural*, *VI_colourstress*, *VI_soiladjusted*, *VI_rededge*).

За да се намали повторението и да се запази висока възможността за интерпретация, DSS използва представителите на VI семействата като възли за доказателства в BN, вместо множество сурови индекси. Предложено е следното разделение:

- **VI_structural:** NDVI или GNDVI
- **VI_colourstress:** MGVRI или VARI
- **VI_soiladjusted:** MSAVI
- **VI_rededge:** NDRE (по избор, в зависимост от сложността на BN и релевантността за обекта)

Тези възли захранват различни модули на DSS: Азот (структурен + цветово-стресов), Напояване (структурен + цветово-стресов + почвено-коригиран), Развитие на корените (структурен с лаг + цветово-стресов), както и общи причинни възли като *canopy_density_state*, *stress_state* и *water_deficit_state*.

3.5 Част 5. AI-базирана Bayesian система за подпомагане на вземането на решения (BN-DSS)

Част 1–4 генерират отделни, богати на доказателства компоненти (азотна динамика и динамика на SOM, прагове за напояване и пространствена хетерогенност, коренови реакции и VI прокси показатели, както и оперативен работен поток за дистанционни изследвания). Част 5 интегрира тези изходи в единна вероятностна рамка за подпомагане на решенията. Тъй като Bayesian Networks са по-слабо познати за много аудитории в turf изследванията, резултатите по-долу запазват повече методологичен контекст, за да се изясни какво прави BN, как се изгражда и как се валидира върху реални данни от пътинг грийнове.

1) Какво представя BN-DSS и върху какво е оценена

BN-DSS реконструира причинно-следствената логика на дисертационния труд в явна вероятностна рамка, съставена от взаимодействащи подграфи за торене, напояване, почвена влага, климатичен стрес, вегетативен растеж, VI сигнали и изходи, свързани с въглеродния цикъл. Системата следва рамката за разработване, дефинирана в Методите, и я разширява чрез използване на емпирични резултати от Част 1–4 за калибрация и валидация.

Имплементацията и оценяването са извършени върху един пясъчно-базиран пътинг грийн по спецификация USGA (P14), оборудван с дневни почвени сензори (влага, температура, соленост) и локална метеорологична станция. Управленските дневници за 2022–2024 предоставиха пълни записи за азотни входи, обеми на напояване, обем откос и повърхностни операции, формирайки емпиричната основа за обновяване и оценка на BN. Инициализацията на модела използва сезони 2022–2023, а всички представени тук показатели за представяне се отнасят до независим 93-дневен прозорец на валидация (31 May до 1 September 2024).

Бяха избрани три цели за оценка, тъй като обхващат състояние на тревната повърхност, растежен отговор и ефективност на напояването, които са ключови за ресурсно ефективно управление на тревния чим:

1. Класификация на състоянието на NDVI (ниско/средно/високо спрямо хиперспектрален референт),
2. Дневен обем откос MAE,
3. WUE, свързан с напояването.

2) Стъпка 1. Извличане на знание от публикации (NLP → knowledge graph → BN priors)

Беше събран корпус от 136 рецензирани статии (2000–2023) за управление на вода и хранителни елементи при turfgrass. От тях секциите „Results“ бяха филтрирани до 1 712 изречения, анотирани с 11 агрономични типа релации. Съгласието между анотатори беше съществено (общо $\kappa = 0.74$), като κ по релации варираше приблизително 0.68–

0.78, а съответните F1 стойности бяха ~0.76–0.85 за отделните етикети (Table 39; Figure 83).

Table 22. Inter-annotator agreement for eleven agronomic relation types extracted from scientific publications.

Relation	Agreement Metrics		
	Kappa	F1	N of positives
relates_to_biomass	0.74	0.81	284
relates_to_eto	0.71	0.79	60
improves_soil	0.77	0.83	35
relates_to_n_rate	0.69	0.77	170
affects_quality	0.72	0.80	450
correlates_with_gp	0.75	0.82	98
improves_nutrient_efficiency	0.73	0.80	170
water_use	0.78	0.85	150
enhances_root	0.7	0.78	90
relates_to_vi	0.68	0.76	92
increases_vigor	0.72	0.80	113

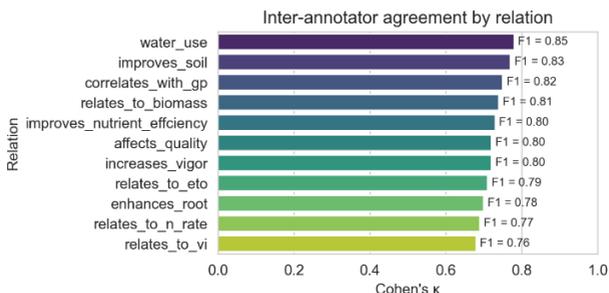


Figure 63. Inter-annotator agreement by relation (Cohens 'k' and F1)results_5

Разпределение на агрономическите релации (етикети) и сравнение на модели.

Етикетите са показани на Figure 84. Сравнени са моделите BERT, SciBERT и GPT-4 за извличане на релации. GPT-4 постигна най-високо общо представяне (Precision 0.81, Recall 0.74, F1 0.77, AP 0.79), превъзхождайки SciBERT и BERT (Table 40), като precision–recall кривите показват, че GPT-4 поддържа по-висока прецизност до ~0.60 recall, преди да се влоши (Figures 85–86).

Table 23. Model comparison metrics

Model	Comparison metrics			
	Precision	Recall	F1	AP
BERT	0.65	0.66	0.66	0.67
SciBERT	0.77	0.69	0.72	0.73
GPT-4	0.81	0.74	0.77	0.79

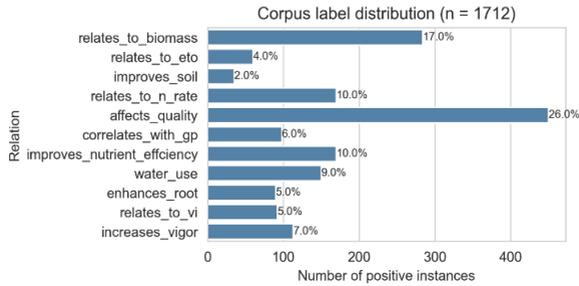


Figure 64. Label distribution for the annotated relation corpus. Frequency distribution of relation labels across the 1,712 annotated sentences used for training and evaluating the NLP extraction pipeline

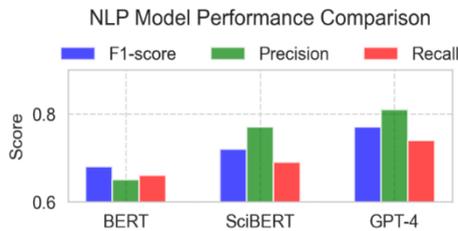


Figure 65. Model performance comparison (BERT, SciBERT, GPT-4) for agronomic relation extraction. Precision, recall, F1, and average precision (AP) metrics demonstrating superior performance of GPT-4 for extracting agronomically meaningful relations, justifying its selection for BN knowledge graph construction

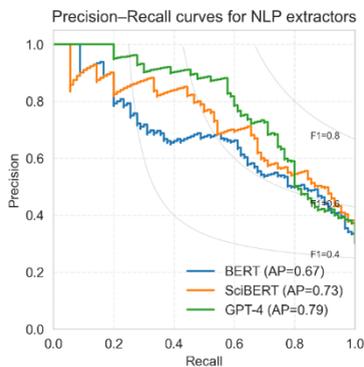


Figure 66. Precision–recall curves for BERT, SciBERT, and GPT-4. Curves illustrating model trade-offs across recall levels. GPT-4 maintains the highest precision for moderate recall values before degrading, making it the most reliable option for high-confidence relation extraction.

Източници на грешки и резултати от knowledge graph. Ръчната проверка на 300 случайно избрани false positives/negatives идентифицира два доминиращи източника: полисемични термини като „stress“, използвани както в абиотичен, така и в биотичен контекст (41% от грешките), и вложени релации, обхващащи множество клаузи (>27%). Стъпка 1 генерира компактен knowledge graph от 32 високонадеждни тройки, покриващи ключовите взаимодействия, необходими за началното състояние на DSS. Този knowledge graph задава структурата на BN и осигурява prior разпределения, които впоследствие са обновени със специфични за обекта данни.

3) Стъпка 2. Изграждане и валидиране на BN (DAG + CPTs + calibration)

Simplified Bayesian Network DAG

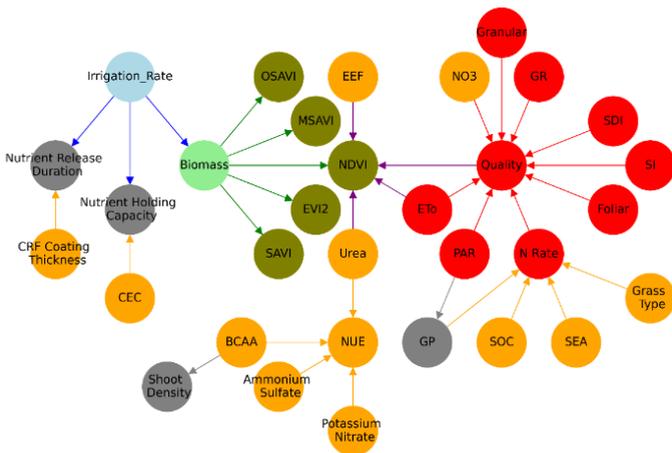


Figure 67. Simplified BN DAG extracted from literature

Структура (DAG). На база изхода от knowledge graph, BN е проектирана да улавя причинната верига от климатични драйвери → управленски действия → физиологични отговори → наблюдавани метрики за представяне. Крайният DAG (Figure 87) съдържа 32 възела, представящи взаимодействащи процеси, релевантни за управлението на азота, напояването, състоянието на тревната повърхност и наблюдаваните резултати.

Инициализация и обновяване на CPT. Conditional probability tables (CPTs) са инициализирани от стойности, извлечени от литературата, и обновени чрез Bayesian оценка с Dirichlet priors ($\alpha = 1.0$). Пример за проверка на условни вероятности за NDMI, Irrigation Rate и N Rate е показан на Figure 88, за да се демонстрира как priors взаимодействат с емпиричните доказателства в триада от управленски–повърхностни взаимоотношения.

Predictive performance (93-дневен hold-out). В независимия 93-дневен период на оценка BN постигна:

- **NDVI:** accuracy **0.830**, balanced accuracy **0.710** (n = 93)
- **Irrigation_Rate:** accuracy **0.865**, balanced accuracy **0.833** (n = 93)
- **N_Rate:** accuracy **0.873**, balanced accuracy **0.860** (n = 93) (Table 41).

Walk-forward тест с 14-дневен warm-up даде същата класификация на NDVI състоянието за всеки ден от периода на оценка (accuracy 0.830; balanced accuracy 0.710). Blocked split (June–July train, August test) намали accuracy за NDVI до 0.74 (не е показано), което подкрепя твърдението, че високото представяне не се дължи на target leakage. Общото ранжиране и представянето, отчитащо дисбаланса между класовете, са обобщени на Figure 89, а грешките по класове са показани чрез confusion matrices в Table 42

Table 24. Predictive performance of the BN on the 93 days evaluation window (31 May – 1 Sep 2024). Confidence intervals calculated with Wilson method (n = 93).

Target	Performance metrics		
	accuracy	balanced_accuracy	n_samples
NDVI	0.830	0.710	93
Irrigation_Rate	0.865	0.833	93
N Rate	0.873	0.860	93

Table 25. Confusion matrices for BN model predictions of (a) Irrigation Rate, (b) NDVI, and (c) Nitrogen Rate on the validation set. Each matrix shows the number of observations in each true–predicted class combination, illustrating classification performance across the three-class targets.

True class	Predicted class								
	Irrigation_Rate			NDVI			N_Rate		
	0	1	2	0	1	2	0	1	2
true_0	48	2	1	48	3	0	24	0	6
true_1	1	17	2	0	23	5	6	20	0
true_2	4	1	24	3	4	4	0	0	37

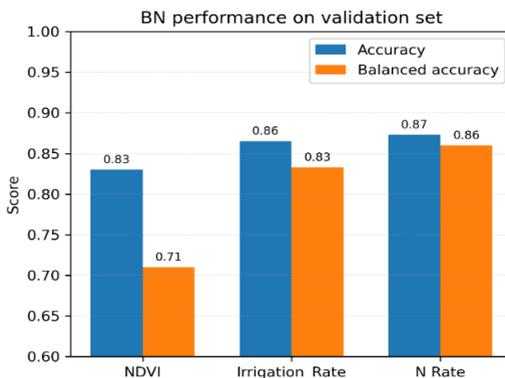


Figure 68. Grouped bar chart showing accuracy (blue) and balanced accuracy (orange) for BN predictions of Irrigation Rate, NDVI, and Nitrogen Rate. Balanced accuracy accounts for class imbalance by averaging recall across classes

Калибрация (probabilistic trust). Reliability диаграми бяха генерирани за NDVI, Irrigation_Rate_state и N_Rate_state чрез binning с равна честота (минимум 20 наблюдения на бин; сливане на редки бинове). Калибрацията беше квантифицирана чрез Expected Calibration Error (ECE). NDVI показа отлична калибрация (ECE = 0.002), докато Irrigation Rate (ECE = 0.112) и N Rate (ECE = 0.084) показаха лека некалибрация, основно подценена увереност при средни вероятности (Figure 90).

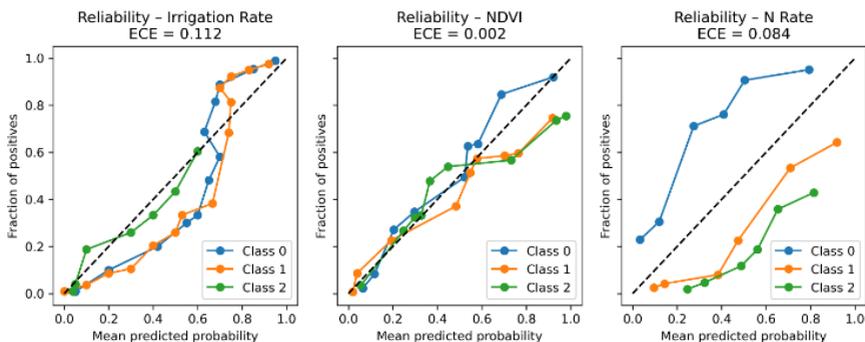


Figure 69. Multi-class reliability diagrams for (a) Irrigation Rate, (b) NDVI, and (c) Nitrogen Rate. Curves plot observed class frequency vs mean predicted probability; the diagonal denotes perfect calibration. ECE (lower is better) is reported per target. Equal-frequency binning (deciles) with ≥ 20 samples per bin; sparse neighboring bins merged.

4) Стъпка 3. Хибридна интеграция на data-driven модели (обновяване по обект без double counting)

Дневен evidence pipeline. Дневните записи от сензори и метеорология за периода 1 Jan до 31 Aug 2024 ($n = 244$) бяха отделени за динамично обновяване на BN. За фокусни точки (Irrigation_Rate \rightarrow Biomass \rightarrow NDVI; N_Rate \rightarrow Quality \rightarrow NDVI) gradient-boosted логистични калибратори (XGBoost; max_depth = 3; n_estimators = 150) оценяват edge-специфични likelihood ratios, които коригират редовете на CPT, последвани от renormalization.

Предпазване от double-counting. Предиктори, които вече са представени другаде в BN (пример: Penman–Monteith ET_0), са изключени от feature set-овете на калибраторите, за да се предотврати използването на едно и също доказателство два пъти. Това е важно, тъй като повтарящите се доказателства могат изкуствено да увеличат posterior увереността и да влошат способността за интерпретация.

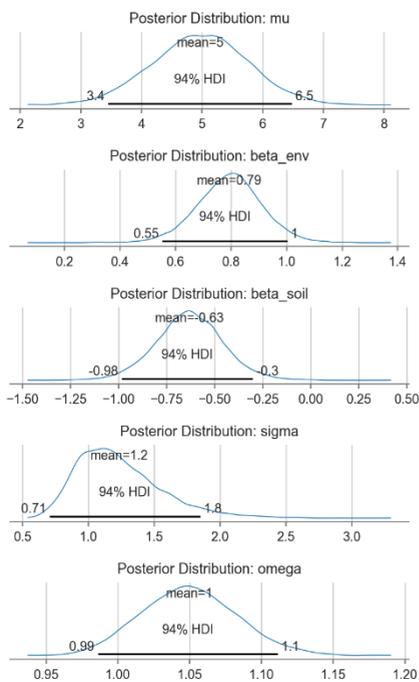


Figure 70. Bayesian model diagnostics. Posterior distributions of key parameters with means and 94% HDIs.

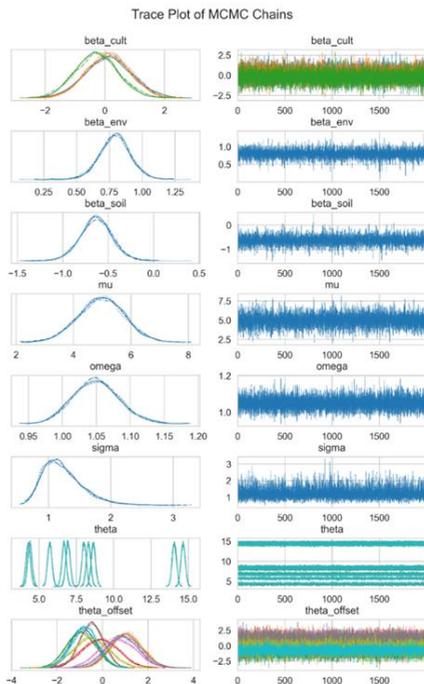


Figure 71. Bayesian model diagnostics. Trace plots for all parameters showing well-mixed Markov chains, indicating good convergence and accurate posterior distribution

Bayesian оценка и диагностика. Posterior параметрите са семплирани с NUTS Hamiltonian Monte Carlo (PyMC 5.13; 4 вериги; 2 000 итерации; 1 000 warm-up). Posterior разпределенията бяха унимодални и приблизително симетрични (Figure 91), trace графиките показаха добре смесени вериги (Figure 92), а стойностите на Gelman–Rubin бяха ≤ 1.01 за всички наблюдавани параметри (Figure 93), което показва удовлетворителна конвергенция.

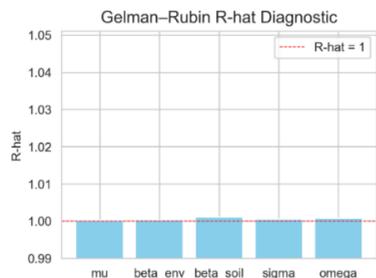


Figure 72. Gelman–Rubin \hat{R} values (all ≤ 1.01)

Posterior predictive checks. Posterior predictive overlays (Figure 94) показват близко съответствие между симулираните и наблюдаваните NDVI състояния (Bhattacharyya distance 0.06). Непрекъснатите метрики (clipping volume и дневна водна употреба) попадаха в 95% posterior predictive interval съответно в 89% и 92% от дните. Тези проверки показват, че хибридните обновявания коригират малки пристрастия, отчетени в по-ранни изходи на BN, без да се компрометираща калибрацията..

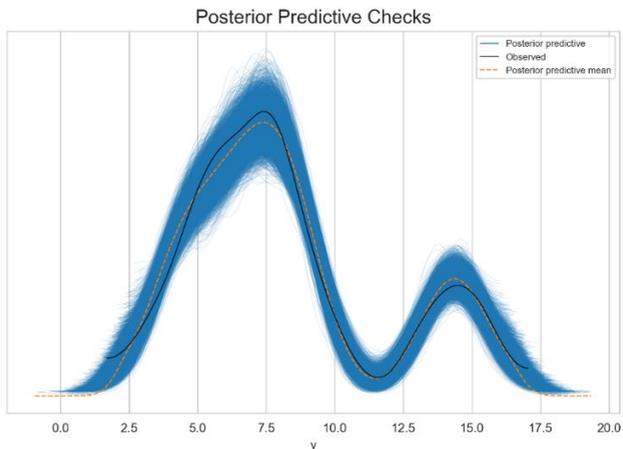


Figure 73. Posterior predictive checks for the Bayesian model. Thin blue curves are draws from the posterior predictive distribution (\hat{y}); the orange dashed line is the posterior-predictive mean; the solid black line is the observed response. The observed series lies largely within the envelope of simulated curves, indicating that the model reproduces the main structure and variability of the data.

5) Анализ на ефекта от решенията (контрафактни сценарии)

Използвайки обновените posterior средни стойности на мрежата, изходите бяха симулирани за три управленски сценария в рамките на периода на оценка: базов (както е управлявано), -25% азот и ET-оптимизирано 80% напояване. Спрямо базовия сценарий, ET-оптимизираното напояване поддържа почти същата вероятност за висок NDVI, като едновременно подобрява irrigation WUE, докато еднородното намаляване на N редуцира продукцията на откос и понижава вероятността за NDVI. (Table 43):

- **Baseline:** Mean NDVI_{state}=High **0.86**; Clip-volume **9.58 ml m⁻² d⁻¹**; Irrigation WUE **1.53 g biomass L⁻¹**
- Reduced N (-25%): NDVI_{high} 0.78 (-10.3%); Clip-volume 8.19 (-16.3%); WUE 1.35 (-16.3%)
- ET-optimized irrigation (80%): NDVI_{high} 0.84 (-2.4%); Clip-volume 8.95 (-6.4%); WUE 1.65 (+14.9%)

В допълнително контрафактично твърдение преминаването от ниско към високо дневно приложение на N увеличи вероятността NDVI=High с 0.18 ± 0.05 ($p < 0.01$), като същевременно включваше 12% риск от over-fertilization..

Table 26. Decision impact analysis (Bayesian network counterfactuals)

Scenario	Impact metrics		
	Mean NDVI_state = High	Mean Clip-volume (ml m ⁻² d ⁻¹)	Mean Irrigation WUE (g biomass L ⁻¹)
Baseline (as managed)	0.86	9.58	1.53
Reduced N (-25 %)	0.78 (-10.3 %)	8.19 (-16.3 %)	1.35 (-16.3 %)
ET-optimized irrigation (80%)	0.84 (-2.4 %)	8.95 (-6.4 %)	1.65 (+14.9 %)

С това, Част 5 демонстрира, че отделните аналитични компоненти на дисертационния труд могат да бъдат реконструирани в вероятностна система, която (i) предсказва ключови състояния на тревния чим с добра точност и интерпретируема неопределеност, (ii) остава възможна за калибриране при постъпване на нови данни от обекта и (iii) поддържа ясни контрафактични сравнения на управленски стратегии. Това осигурява необходимия мост към Заключениеята и Приносите, където работата се позиционира едновременно като научна рамка и като оперативен път към по-ресурсоефективно, въглеродно-осъзнато управление на пясъчно-базирани пътинг грийнове.

4 Изводи

Дисертационният труд интегрира четири управленски лоста, азотно привнасяне, стратегия за напояване, развитие на кореновата система и състояние на тревната повърхност, в общо разбиране за почвеното отлагане на въглерод при интензивно управлявани пясъчно-базирани пътинг грийнове. В рамките на проведените експерименти, моделиране и анализ чрез дистанционно наблюдение, резултатите клонят към следната въглеродните заключения:

1. Въглеродните входове се определят от обема откос и оборота на корените, докато въглеродните загуби зависят от влагово-обусловената минерализация, разграждането на thatch, както и когато абиотичен или биотичен стрес потиска физиологичния въглероден прираст.
2. Пясъчно-базирани пътинг грийнове могат да се доближат до въглеродно-неутрално или слабо въглеродно-положително поведение в рамките на благоприятен оперативен диапазон. В изследваните пясъчни профили този режим се характеризираше с умерени азотни входове, дефицитно-ориентирано напояване, поддържащо стабилен влагов диапазон (особено около 18–26% VWC), по-дълбоко и сезонно стабилно вкореняване и положителни или неутрални VI траектории, съответстващи на устойчив растеж без продължителен стрес.
3. При режим на неблагоприятно управление системата се измества към нетна загуба на въглерод. Това обясняват бавната, но насочена промяна на SOM. Устойчиви влажни петна, хронично свръхподаване на азот, плитко вкореняване и повтарящ се високотемпературен стрес увеличават вероятността за нетна загуба на въглерод. Многогодишните траектории на SOM се променят бавно, но в определена посока, тъй като интегрират натрупаните ефекти на управлението върху продуктивността, динамиката на разлагане и подземното разпределение на въглерод през сезоните.
4. Азотната динамика е модулирана от стрес и свързва краткосрочните сигнали за представяне с дългосрочните тенденции на SOM. Кратките стресови прозорци ограничават растежа и усвояването, като оформят моделите на азотно привнасяне и кумулативното отнемане на азот. В многогодишен мащаб устойчивите азотни режими се отразяват в траекториите на SOM, позиционирайки SOM като бавно-циклично ограничение за устойчивост.
5. Напояването определя динамиката на изчерпване–възстановяване на почвената влага при пясъчни грийнове, а пространствената хетерогенност прави средните стойности недостатъчни. Изчерпването, задвижвано от ET_c, и влагата инерция контролират дневното поведение на VWC, но нееднородността в рамките на грийна обяснява защо локален стрес или насищане могат да възникнат дори когато средната VWC изглежда приемлива. Следователно пространствената диагностика съществено подобрява интерпретацията на рисковете, свързани с влагата.
6. Кореновото състояние е стабилизиращ медиатор, който свързва водната и азотната ефективност с подземното разпределение на въглерод. Дефицитно-ориентираното

напояване последователно поддържа по-дълбоки и по-устойчиви корени в периоди на топлинен стрес, а кореновата дължина предоставя практическо средносрочно ограничение за интерпретация на устойчивостта, капацитета за усвояване и потенциала за въглеродно разпределение.

7. Дистанционните изследвания предоставят мащабируеми доказателства за състоянието на тревната повърхност, когато AOIs са стандартизирани и VI пространството е редуцирано. U-Net сегментацията позволява turf-only AOI маскиране, което защитава валидността на VI, а редукцията до VI семейства дава интерпретируеми индикатори за тревната повърхност, които могат да допълват in-situ измерванията при мониторинг на стрес и представяне.
8. Байесова DSS предлага причинно-следствената структура и остава адаптивна при постъпване на нови доказателства. BN рамката интегрира priors, извлечени от литературата, със специфични за обекта сензорни и VI доказателства, поддържа вероятностна инференция на състояния с калибрационни диагностики и позволява тестване на различни сценарии при неопределеност. Между обектите праговете могат да се изместват, но йерархията на контролите, свързваща влагов режим, азотно снабдяване, експозиция на стрес и подземна устойчивост, остава стабилна.

5 Приноси

5.1 Научни приноси

1) Въглеродно-осъзната рамка за „тесен оперативен диапазон“ при пясъчно-базирани пътинг грийнове

Настоящата дисертация въвежда въглеродно-осъзната рамка за „тесен оперативен диапазон“ при интензивно поддържани пясъчно-базирани пътинг грийнове, като формализира как азотното снабдяване, влаговият режим, експозицията на стрес, поведението на вкореняване и динамиката на тревната повърхност съвместно ограничават нетните почвено-въглеродни резултати в пясъчни профили с бърз оборот. Рамката свързва четири контролируеми лоста (N, напояване, корени, състояние на тревната повърхност) с два въглеродни пътя: въглеродни входове, определяни от продукцията на окосен обем и оборота на корените, и въглеродни загуби, определяни от влагово-обусловена минерализация, разграждане на thatch и стрес-медиирани ограничения върху физиологичния въглероден прираст. Чрез представяне на тези зависимости като механистична йерархия работата осигурява структурирана основа за интерпретация защо сходно качество на тревния чим може да съответства на различни дългосрочни въглеродни траектории при различни управленски варианти.

2)Обяснима времева динамика на напояване с приложими прагове за VWC и ETc

Анализът на напояването определя влаговото поведение на пясъчните профили като тесен работен диапазон, с горно плато, обусловено от дренажа, и повишена

нестабилност при изчерпване. Интерпретацията чрез SHAP потвърждава физически последователна йерархия на драйверите, при която текущата VWC и ETс доминират динамиката на влагата, предсказана за следващия ден, и идентифицира прагоподобно поведение както при VWC, така и при ETс. Тези резултати подкрепят дискретизацията в интерпретируеми състояния на влага и ET, подходящи за моделиране на решения и за трансфер между грийнове със сходна хидравлична характеристика на пясъчната коренообитаема зона.

3) Пространствена хетерогенност на напояването като диагностичен слой в рамките на грийна

Дисертацията показва, че пространствената хетерогенност в рамките на грийна съществено определя реалната експозиция на стрес и не може надеждно да се изведе само от средната VWC. DU, CV, площните дялове по влагови класове и клъстеризацията на времеви редове разкриват устойчиви сухи и влажни зони и тяхната сезонна стабилност. Това осигурява научна основа за разграничаване между времевата динамика на изчерпване–възстановяване и пространствените ефекти на разпределението, както и за диагностика кога се задвижва от хидравлични характеристики, микрорелеф или ограничения, свързани с повърхностното състояние, а не единствено от графика на напояване.

4) Развитие на кореновата система като механистичен медиатор между управлението и подземното разпределение

Модулът за кореновата система установява предвидими сезонни траектории на вкореняване и устойчиви йерархии на третиранията при контрастни режими на напояване. Дефицитно-ориентираното напояване поддържа по-дълбоки и по-персистиращи корени в периоди на топлинни вълни. Предиктивното моделиране показва, че драйверите на водния баланс на средата обясняват значителна част от вариабилността на кореновата дължина, докато ляг-изравнените спектрални сигнали на тревната повърхност предоставят вторична, физиологично последователна прокси информация. По този начин кореновото състояние се позиционира като средносрочно ограничение, което свързва режима на напояване и хранителната динамика с процеси на подземно разпределение, относими към въглеродната устойчивост.

5) Защитим работен поток за дистанционни изследвания с turf-only AOIs и интерпретируема компресия на VI

Високоточен U-Net модул за семантична сегментация стандартизира turf-only AOIs и елиминира контаминация извън зоната на интерес от VI времевите редове, като позволява последователен многогодишен мониторинг върху хетерогенни изображения от голф игрища. Многосезонната клъстеризация компресира обширни VI архиви до повтаряеми режими на тревната повърхност, а анализът на сходство дефинира устойчиви функционални VI семейства (структурни NIR-базирани, цветово-стресови,

почвено-коригирани, red-edge и нелинейни/наситени). В съвкупност тези компоненти предоставят принципна, физиологично интерпретируема стратегия за редукция на размерността, която подпомага надеждна инференция на състоянието на чима през повърхности и обекти.

6)Вероятностна интеграция и валидация на Bayesian Network DSS

Дисертацията установява възпроизводим път „знание–модел“, при който priors, извлечени от литературата, се извеждат чрез NLP, кодират се като структура на BN и CPT priors и се обновяват със специфични за обекта доказателства. BN се валидира върху независими данни от пътинг грийн чрез ассигасу и метрики, отчитащи дисбаланса между класовете, а калибрационните диагностични подходи квантифицират вероятностната надеждност. Рамката позволява контрафактни сценарии и прави компромисите експлицитни при неопределеност, осигурявайки интегриращ слой, който свързва влагов режим, азотно снабдяване, състояние на тревната повърхност и коренови ограничения в единен обект на решение.

5.2 Научно-приложни приноси

1)Въглеродно-осъзната оперативна логика за вземане на решения при пясъчни грийнове

Рамката за „оперативен диапазон“ е трансформирана в практическа логика за решения и диагностичен чеклист за управление в дневен до седмичен мащаб: избягване на хронична влажност и хронично свръхподаване на азот, които ускоряват разлагането и загубите; избягване на хроничен дефицит, който води до срив на растежа и оборота на корените; проактивно управление на кратки стресови вълни; и защита на дълбочината на вкореняване като гаранция за устойчивост и въглеродно разпределение. Тази приложна рамка подпомага полевата диагностика дали въглеродният риск се доминира от влажност, свръхподаване, дефицит или повтаряща се експозиция на стрес, вместо да се приема, че представянето на тревния чим е достатъчен прокси показател за устойчивост.

2)Правила за напоително планиране на база прагови състояния на VWC и ETc

Дисертацията предоставя прагова система, приложима на практика за пясъчни грийнове: поддържане на VWC в стабилен диапазон 18–26%, третиране на ~16–18% като граница на изчерпване („старт на напояване“) и третиране на ~28–30% като таван на дренаж/неблагоприятно напояване за избягване на излишно подаване и потенциално излужване под дълбочината на сензора. Класовете на ETc (<2, 3–5, >5.5 mm day⁻¹) подпомагат риск-ориентирано таймиране чрез предвиждане на бързо засушаване при високо изпарително търсене, позволявайки решения, които балансират избягването на стрес с ресурсната ефективност.

3) Работен поток за пространствена ремедиация при неравномерна влага

Пространствените диагностични подходи позволяват приложно разграничаване между проблеми на планирането на поливките и проблеми на разпределението на приложената вода. Трендовете на DU/CV, площните дялове по влагови класове и идентичността на устойчивите зони подпомагат целеви интервенции (настройка на дюзи, локални корекции на дренаж, аерация, омокрящи агенти), без дестабилизиране на целия график на напояване на база подвеждащи средни стойности. Този вътрегрийнов слой предоставя практичен път за редуциране на локализиран риск от стрес и насищане и за повишаване на увереността в напоителните решения.

4) Прогнозиране на риск от загуба на коренова маса за прецизиране на праговете на напояване и „азотните“ граници на безопасност

Сезонните „envelopes“ на вкореняване и режим-специфичните предиктори подпомагат идентифицирането на рискови прозорци за загуба на коренова маса, особено в периоди на топлинни вълни. Кореновото състояние може да прецизира праговете и тайминга на напояване и да информира азотната „позиция на безопасност“ чрез отразяване на капацитета за усвояване и риска за устойчивост при повтарям стрес. Това позволява проактивно адаптиране на водните и азотните решения на база подземен капацитет, а не реакция единствено на надземни симптоми.

5) VI доказателствени възли за рутинен мониторинг и интеграция в DSS

Предложен е компактен, интерпретируем набор от представители на VI семейства за доказателства в DSS: структурен индекс (NDVI или GNDVI), цветово-стресов индекс (MGVRI или VARI), почвено-коригиран индекс (MSAVI) и, при необходимост, red-edge индекс (NDRE), когато биохимичните градиенти са информативни. В комбинация с turf-only AOI маски тези индекси позволяват мащабируем мониторинг на времеви редове и топлинни карти на грийновете, съгласувани с интерпретацията на стрес и представяне, като поддържат последователни потоци от доказателства за модулите за азот, напояване и дължина на корените.

6) BN-ориентирана подкрепа за решения с неопределеност и контрафактична оценка

BN-DSS превежда емпиричните резултати в оперативно вероятно разсъждение: обновява състоянията на обекта чрез сензорни и VI доказателства, пропагира неопределеността през свързаните процеси и поддържа контрафактична оценка на различни сценарии. Това позволява количествени сравнения на стратегиите за напояване и торене, намалявайки зависимостта от статични графици или еднопроменливи приближени правила и повишава прозрачността на логиката зад вземането на решения.

5.3 Практически приложен научен принос: имплементация на оперативен SMART dashboard

Разработен е функционален, модулен dashboard като потребителски слой за имплементация на SMART BN-DSS, който превежда праговете и дефинициите на състояния в оперативни решения в дневен до седмичен мащаб. Dashboard-ът консолидира метеорологични и сензорни доказателства, изчислява споделени производни драйвери, използвани във всички модули (GP, ET/ETc, стрес индикатори), и представя съгласувани интерпретации на състоянията за напояване, торене, развитие на корените, мониторинг на тревната повърхност и динамика на органичната материя. Това демонстрира, че рамката на дисертацията е приложима във възпроизводим работен поток, който отразява BN подграфите и техните зависимости.

Като практичен инструмент за подпомагане на решенията dashboard-ът позволява специфична за обекта историческа диагностика, краткосрочно планиране и сценарийно изследване, като същевременно поддържа следа на действия и резултати, която може да се проверява. Чрез интегриране на времеви правила (прагово-базирано планиране), пространствена диагностика (зонова интерпретация на влагата) и дистанционни доказателства (AOI-базирани VI траектории и топлинни карти) той предоставя кохерентен интерфейс за адаптивно управление при неопределеност и подпомага въглеродно-осъзната оптимизация в рамките на рутинните ограничения на поддръжката.