

**НАЦИОНАЛНА СИГУРНОСТ
NATIONAL SECURITY**

**ОТ ОРБИТА ДО БРЕГА: ИНСТРУМЕНТИ С ИЗКУСТВЕН ИНТЕЛЕКТ
ЗА ОТКРИВАНЕ НА НЕФТЕНИ РАЗЛИВИ С ПОМОЩТА НА ПЛАТФОРМИ
С ОТВОРЕНИ ДАННИ**

Васил Михалков

Военна академия „Георги С. Раковски“

<https://doi.org/10.70300/XNLI6419>

Резюме: Своевременното откриване на морски нефтени разливи е критично глобално екологично предизвикателство. Традиционните методи за мониторинг с корабни патрули и въздушно наблюдение са ограничени от разходите, обхвата и времето. В ход е промяна на парадигмата, подхранвана от сливането на три трансформативни технологии: сателитни данни с отворен код, безпилотни летателни апарати (БЛА) и изкуствен интелект (ИИ). Този синтез разглежда настоящата екосистема от инструменти, задвижвани от изкуствен интелект, които използват свободно достъпни данни от орбитални платформи и изображения, базирани на дронове, за да автоматизират и подобрят наблюдението на нефтени разливи. Анализирани са стандартният процес на обработка с изкуствен интелект – от предварителна обработка на данни и класическо машинно обучение до усъвършенствани модели за сегментиране с дълбоко обучение като U-Net. Бъдещата траектория сочи към интегрирани, многоплатформени системи за мониторинг, където изкуственият интелект не само открива, но и прогнозира динамиката на разливите, изграждайки мощен набор от инструменти с отворен достъп за опазване на морските екосистеми.

Ключови думи: откриване на нефтени разливи; изкуствен интелект; безпилотни летателни апарати (UAV); сателити с отворени данни; наблюдение на околната среда

ВЪВЕДЕНИЕ

Разливите на нефт в морето, независимо дали са причинени от катастрофални изригвания на кладенци, аварии на танкери, или хронични оперативни изхвърляния, представляват сериозна и трайна заплаха за океанските екосистеми, крайбрежните икономики и общественото здраве. Неотложната необходимост от бърза реакция е неразривно свързана с точността и скоростта на откриване и картографиране. В продължение на десетилетия наблюдението се основава на конвенционални методи: патрулиране на кораби, пилотирано въздушно наблюдение и спорадичен сателитен анализ. Тези подходи, макар и ценни, образуват разпокъсана система, страдаща от високи оперативни разходи, ограничено пространствено и времево покритие, както и уязвимост към неблагоприятни метеорологични условия. Към това трябва да се добави и зависимост от субективната човешка интерпретация.

Нова технологична триада, в която влизат дистанционното сондиране с отворени данни, дроновете и изкуственият интелект (Fingas, Brown 2018; Leifer et al. 2012), премахва тези бариери и „демократизира“ наблюдението на околната среда. Стартирането на програмата „Коперник“ от Европейската космическа агенция, заедно с нейното съзвездие от спътници Sentinel, предостави на света безплатни, систематични и висококачествени данни от наблюдение на Земята. Успоредно с това разпространението на съвременни и достъпни безпилотни летателни апарати (БЛА) (Jiao et al. 2019) дава възможност за дистанционно наблюдение в локален мащаб, позволявайки на агенции и изследователи да развързват сензори при поискване, заснемайки изображения и данни със сантиметрова разделителна способност, недостъпни от орбита.

ИЗТОЧНИЦИ НА ДАННИ И ФИЗИЧЕСКИ ПРИНЦИПИ ЗА ОТКРИВАНЕ НА НЕФТЕНИ РАЗЛИВИ


Ефикасността на всеки инструмент за откриване с изкуствен интелект е фундаментално ограничена от качеството и характеристиките на входните му данни. Този раздел очертава двата основни потока от данни с отворен код – сателитно и дистанционно наблюдение, чрез безпилотни летателни апарати и изяснява ключовите физически принципи, които позволяват разграничаването на нефтени разливи от морския фон в различни сегменти на електромагнитния спектър.

Спътниково наблюдение за откриване на нефтени разливи

Сателитните платформи осигуряват незаменяемата широкообхватна, многократно преминаваща способност, която е от решаващо значение за първоначалното откриване и наблюдение на разливи в обширни и често отдалечени океански региони. Сред изобилието от сензори два основни типа, използващи различни физически взаимодействия, формират съвременното наблюдение на нефтени разливи чрез свободно достъпни отворени данни.

Радарът със синтезирана апертура (SAR) (Brekke, Solberg 2005) е приет за най-надеждния сателитен инструмент за откриване на нефтени разливи, главно поради оперативната си независимост от слънчевата светлина и облачната покривка. Принципът на действие се основава на промяната на грапавостта на морската повърхност.

По същество SAR сензорът е радар. Сателитът активно излъчва микровълнови импулси към земната повърхност и измерва обратно разсеяния сигнал. Интензитетът на обратно разсеяния сигнал, който се появява като яркост (или „сигма нула“) в полученото изображение, е предимно функция на локалния релеф на повърхността, по-специално капилярни и къси гравитационни вълни, резултат от т.нар. разсейване на Брег. Наличието на нефтен филм върху морската повърхност заглушава тези малки вълни поради по-високия вискозитет и повърхностно напрежение на нефта. Това потискане води до значително намаляване на радарното обратно разсейване, което кара покритите с нефт области да изглеждат като отчетливи тъмни образувания („тъмни петна“) на фона на по-светлата и по-грапава околна морска вода (фиг. 1).



Фиг. 1. SAR сателит, който засича спокойна зона на нефтено петно. Зоната лесно може да се обърка с други спокойни региони, като например зони със слаб повърхностен вятър или цъфтеж на водорасли.

Ключова платформа за свободен достъп е платформата „Коперник“, с данни от съзвездията спътници Sentinel-1 на Европейската космическа агенция (с нейния SAR сензор в С-обхвата) (Torres et al. 2012). Това е водещият свободно достъпен източник на SAR данни за оперативен мониторинг на нефтени разливи. Неговото гарантирано, систематично глобално покритие с честота на повторно посещение от 6 дни на Екватора с два спътника и значително по-често – на по-високи географски ширини, осигурява безпрецедентен оперативен набор от данни.

Основното предимство на SAR е неговата всесезонна и денонощна работа. Полезността му обаче може да бъде редуцирана при условия на много слаб вятър (където морето е вече спокойно, което намалява контраста) или много силен вятър (където нефтените петна могат да бъдат разкъсани или потопени). Освен това „тъмните петна“ на SAR не са уникални

за петрола. Те могат да бъдат объркани с други явления, като например естествени петна от водорасли, зони на ветрови сенки (например зад острови) или зони на издигане на повърхността, което води до критичното предизвикателство на „приликите“. Ето защо като алтернатива често се използват и оптични сензори за наблюдение във видимия светлинен диапазон, което позволява извличане на спектрална характеристика на наблюдавания обект.

Оптичните сензори във видимия, а също в инфрачервения (IR) и ултравиолетовия (UV) диапазон измерват отразената или излъчена слънчева радиация в специфични спектрални ленти, предлагайки допълнителна химическа и физическа информация за повърхностните петна (Chuanmin et al. 2021). Те предоставят богата спектрална информация, която може да помогне за разграничаване на видовете петрол, оценка на дебелината на пластовете и идентифициране на подобни обекти по-ефективно, отколкото само чрез SAR. Сравнително високата пространствена разделителна способност на Sentinel-2 е особено ценна за наблюдение в близост до брега. Основното и често възпиращо ограничение е неговата зависимост от лоши метеорологични условия и използването му само през деня. Облачността, мъглата и нощното време правят оптичните данни неизползваеми за откриване на разливи.

Безпилотни апарати за откриване на нефтени разливи

Дистанционното наблюдение, базирано на безпилотни летателни апарати, предоставя канал за верифициране на нефтени разливи с висока разделителна способност. Безпилотните летателни апарати (БЛА) или дронове работят в долните слоеве на атмосферата, като запълват критичната празнина между сателитното наблюдение и вземането на проби на място. Те предоставят изключително гъвкава платформа за дистанционно наблюдение по заявка.

Принципите на откриване на нефтени разливи с безпилотни летателни апарати (БЛА) са аналогични на сателитното оптично наблюдение, но се прилагат в значително по-висока пространствена резолюция (от сантиметри до метри). Това позволява визуализация на текстурите на маслените емулсии, диференциране на блясъка от по-дебелите слоеве на петното и директна корелация на спектралните и термичните сигнатури с точни местоположения за вземане на проби.

Безпилотните летателни апарати (БЛА) варират от леки многороторни системи, идеални за локализиране, стационарни инспекции, до самолети с фиксирани крила, които са способни да покриват по-големи крайбрежни зони. Последните могат да бъдат оборудвани с разнообразен полезен товар. Цветните (RGB) камери с висока разделителна способност създават подробна визуална документация и картографиране на обхвата и морфологията на петното. За да заснемат подробни спектрални сигнатури, мулти- и хиперспектралните сензори позволяват разграничаване на видовете петрол и изчисляване на усъвършенствани индекси. Термични инфрачервени (TIR) камери помагат за картографиране на топлинни контрасти, показващи вариации в дебелината на нефтения филм, ключов параметър за оценка на обема и планиране на отстраняване на проблеми. LiDAR може да се използва за измерване на много фина повърхностна топография и дебелината на нефтения филм при специфични условия (Zhengsin et al. 2023).


Най-голямото предимство на безпилотните летателни апарати (БЛА) (Krestenitis et al. 2019) са пространствената разделителна способност и гъвкавостта на разполагане. Те могат да бъдат мобилизирани бързо в отговор на сателитно предупреждение, да летят под облачна покривка и да предоставят данни с несравними детайли за криминалистичен анализ и оценка на щетите. Тяхната роля в събирането на наземни данни за обучение и валидиране на сателитни модели с изкуствен интелект е незаменима. Ограниченията включват ограничен оперативен обхват и продължителност на полета поради живота на батерията, капацитета на полезния товар и регулаторните ограничения на въздушното пространство, което ги ограничава предимно до крайбрежни и близо до брега операции.

Безпилотните летателни апарати (БЛА) предоставят окончателна, висококачествена наземна информация и подробна характеристика. Ефективната система за откриване, основана на изкуствения интелект, няма да разчита на един-единствен източник, а ще интегрира данни от мултиплатформена и мултисензорна екосистема с свободен достъп. Именно изкуст-

веният интелект трябва да превърне тези разнообразни потоци от данни в съгласуван набор от инструменти за откриване и анализ. Именно тук третият стълб – изкуственият интелект (ИИ), и по-специално дълбокото обучение (ДО), се превръща в незаменим интерпретатор.

ПРИЛОЖЕНИЕ НА ИЗКУСТВЕНИЯ ИНТЕЛЕКТ ЗА ИНТЕГРИРАНЕ И АНАЛИЗ НА ДАННИ ОТ САТЕЛИТНО И БЕЗПИЛОТНО НАБЛЮДЕНИЕ

Трансформирането на суровите сензорни данни в надеждна карта за откриване на нефтени разливи е многоетапен изчислителен процес. Този раздел анализира стандартния процес при анализ на данни с изкуствения интелект, който започва с подготовката на данните, преминава през извличане и инженеринг на основните характеристики и завършва с усъвършенствани архитектури за дълбоко обучение, представляващи съвременното ниво на развитие в областта. Този работен процес, визуализиран на фиг. 2, формира гръбнака на всички съвременни автоматизирани инструменти за откриване на обекти.



Фиг. 2. Диаграма на съвременния автоматизиран работен процес за обработка с изкуствения интелект

Предварителна обработка и подготовка на данните

Преди да може да се приложи който и да е модел с изкуствен интелект, суровите изображения трябва да бъдат калибрирани, почистени и структурирани във форма, подходяща за алгоритмично обучение. Този етап е критичен, тъй като качеството на входните данни пряко определя производителността на цялата система.

Преди доминирането на дълбокото обучение откриването на нефтени разливи се е основавало на извличане на ръчно създадени характеристики от предварително обработени изображения, които след това са били въвеждани в класическите класификатори за машинно обучение (Suresh et al. 2024). Процесът започва с извличане на характеристики – за всяка област (тъмно петно в SAR, аномалия в оптичния анализ) се изчислява набор от количествени параметри. Геометричните характеристики включват: площ, периметър и сложност, като компактност и фрактална размерност. Радиометричните характеристики са средна стойност, стандартно отклонение и контраст на стойностите на пикселите в петното и неговия фон. Текстурните характеристики се извличат от матрици за корелация на нива на сивото (GLCM) и включват параметри като хомогенност, контраст, ентропия и корелация – нефтените петна често показват по-гладка текстура от заобикалящото ги бурно море. Следват ги контекстуални характеристики, като разстояние от брега, близост до корабни пътища или нефтени платформи.

Всички горепосочени характеристики се подават към алгоритми за класификация, за да

се обучат класификаторите да различават „нефтен разлив“ от „приличащи“, например район със слаб вятър, биогенен филм и т.н. Тези алгоритми за класификация използват методи като „случайна гора“ (random forest) и машина на опорни вектори. Първият е метод, който конструира множество дървета на решенията, много ефективен за тази задача поради своята устойчивост на шум и способността си да обработва многомерни пространства от характеристики. Вторият се стреми да намери оптималната хиперравнина, която максимално да разделя различните класове в многомерното пространство от характеристики. Този метод е особено ефективен при ясно разграничаване на характеристиките.

Описаният горе подход е силно зависим от качеството и релевантността на ръчно проектираните характеристики. Процесът често отнема повече време, специфичен е за дадена област и може да не се обобщава добре за нови сензори или сложни, нелинейни модели в данните. За SAR изображенията (предимно Sentinel-1) първата стъпка е радиометричното калибриране и корекцията на терена. Суровите числови данни се преобразуват в калибрирани стойности на коефициента на обратно разсейване на радара (σ°), като осигуряват физическа съгласуваност между изображенията. Корекцията на терена с помощта на цифров модел на релефа (DEM) премахва геометричните изкривявания. SAR изображенията също така са по своята същност засегнати от „петна“ – гранулиран шум, причинен от интерференция на кохерентни вълни. Адаптивни филтри (например Lee, Frost или Refined Lee филтри) се прилагат за потискане на петната, като същевременно се запазват ръбовете и характеристиките, които са от решаващо значение за откриване на хлъзгави граници. Последната стъпка е маскиране на сухите райони с помощта на глобални набори от данни за бреговата линия, за да се предотвратят фалшиви положителни резултати от спокойни вътрешни води или радарни сенки от топографията.

За оптични изображения (отново Sentinel-2, Landsat и др.) обработката започва с атмосферна корекция. Прилагат се алгоритми (например Sen2Cor, ACOLITE) за преобразуване на сиянието на горните слоеве на атмосферата в повърхностно отражение, като се премахват ефектите на разсейване и абсорбция от атмосферата. Следващата стъпка е маскиране на облаците и сенките от облаците. Пикселите на облаците трябва да бъдат надеждно идентифицирани и маскирани с помощта на специални алгоритми (например Fmask, s2cloudless) или прагове на лентите (например с използване на SWIR или облачни ленти). Като последна стъпка, слънчевият отблясък трябва да бъде филтриран. За сцени, засегнати от огледално отражение, може да се приложат емпирични (например с използване на NIR лентата) или физически модели за смекчаване на отблясъците, които могат да замъглят или имитират петролни сигнатури.

Изборът на данни за обучение играе решаваща роля. Моделите с контролиран изкуствен интелект изискват големи, висококачествени етикетирани набори от данни. Всяко изображение трябва да има съответстваща маска за „ground truth“, където пикселите са етикетирани като „нефт“, „вода“, „подобни“ или „земя“. Създаването на тези етикети е съществено затруднение. Те се създават чрез ръчна анотация, като за основа се използват исторически случили се нефтени разливи (например Deepwater Horizon, 2010 г., разливът на остров Мавриций, 2020 г.), или посредством полуавтоматично генериране чрез използване на традиционни алгоритми за откриване (например постоянна честота на фалшиви аларми – CFAR за SAR), с последващо експертно уточняване. Синтезът на данни при използване на безпилотни летателни апарати (UAV) осигурява проверка. Използването на прецизно геореферирани изображения и спектрални данни от безпилотни летателни апарати служи за валидиране и коригиране на етикети. Известни отворени набори от данни, като например тези от Службата за реагиране и възстановяване на Националната агенция за океаните и атмосферата на САЩ (NOAA) или анотирани сцени от Sentinel-1 в каталога за отворена наука на Европейската космическа агенция, са безценни споделени ресурси за обучение и сравнителен анализ.

Дълбокото обучение за откриване на нефтени разливи

Дълбокото обучение (DL), по-специално конволюционните невронни мрежи (CNN), ко-

ренно променя съществуващата парадигма, като изучава йерархични характеристики директно от суровите или минимално предварително обработени изображения, автоматизирайки процеса на проектиране на характеристики (Ronneberger et al. 2015; Chen et al. 2018).

Семантичните модели на сегментиране (пикселна класификация) са доминиращият DL подход за откриване на нефтени разливи, като на всеки пиксел в изображението се присвоява етикет „нефт“ или „вода“. U-Net архитектурата е де факто стандартът за сегментиране на биомедицински и екологични изображения. Нейната симетрична структура на енкодер-декодер, с прескачащи връзки, ѝ позволява да улавя както контекст на високо ниво („какво“ на петното), така и прецизна локализация („къде“ на неговите граници). Вариации като Attention U-Net или ResU-Net (с остатъчни блокове) са често срещани подобрения, които подобряват производителността при сложни петна. DeepLab (DeepLabv3+) използва разширени конволюционни методи за улавяне на многомащабна контекстуална информация без загуба на разделителна способност и структура енкодер-декодер за прецизиране на границите на обектите.

Трансформаторите за зрение (ViT) (Zheng et al. 2021; Dosovitskiy et al. 2020; Xie et al.) са нововъзникваща ИИ архитектура, която третира изображението като поредица от петна. Чрез прилагане на механизми за самовнимание ViT могат да моделират зависимости на дълги разстояния в цялата сцена, потенциално подобрявайки разбирането на морфологията на петната и взаимодействието им с фона. Те все по-често се прилагат в задачи за наблюдение на Земята, но изискват големи количества данни за обучение.

Моделите за откриване на обекти (Slick-Level Detection) включват рамки като Faster R-CNN и YOLO. Те са по-рядко срещани, но могат да се използват, когато задачата е формулирана като откриване на дискретни екземпляри на нефтен разлив, а не като извършване на класификация на плътни пиксели. Те извеждат ограничаващи рамки и оценки за достоверност за отделните разливи. Обучението на тези модели изисква значителна изчислителна мощност (обикновено графични процесори) и големи, разнообразни набори от данни с етикети, за да се предотврати преобучение. Основно предизвикателство остава дисбалансът в класовете – пикселите с нефт са значително по-малко от пикселите с вода. Техники като претеглени функции за загуба (например загуба на зарчета, фокална загуба) или увеличаване на данните (въртене, обръщане, добавяне на шум) са от съществено значение за справянето с това.

Постобработка и интеграция

Суровият краен резултат от DL модел рядко представлява напълно завършена и оперативно използвана карта на откритите обекти (нефтени разливи). Необходима е постобработка за усъвършенстване на резултата. Използваните методи включват морфологични операции: прилагане на „затваряне“ (разширение, последвано от ерозия) за запълване на малки дупки в открито петно или „отваряне“ (ерозия, последвана от разширение) за премахване на изолирани малки фалшиво положителни пиксели. Анализът на свързаните компоненти е процесът на идентифициране и етикетиране на отделни обекти на нефтеното петно, което позволява изчисляването на ключовите му показатели: обща площ, периметър, местоположение и ориентация на главната ос. За сателитни времеви серии от изображения проследяването на движението и еволюцията на петно през последователни наблюдения, с използване на алгоритми за съвпадение на формата или вероятностни алгоритми, позволява моделиране на дрейфа и идентифициране на източника.

Процесът на обработка на изображения с помощта на изкуствения интелект се е развил от многостепен и зависим от човешко участие до по-самостоятелен и основан на данни подход за дълбоко обучение. Докато класическото машинно обучение (ML) остава обект на интерпретация, който несъмнено е полезен за специфични задачи, моделите за дълбоко обучение (DL), особено архитектурите, базирани на U-Net, демонстрират превъзходна точност и устойчивост при справянето със сложни, нелинейни модели на нефтени разливи в различни морски среди. Способността им да се възползват директно от нарастващия обем данни с отворен код, е ключов двигател за тяхното все по-често използване.

**ПОДХОД ЗА ИЗГРАЖДАНЕ НА МНОГОПЛАТФОРМЕНА РАМКА
ЗА НАБЛЮДЕНИЕ С ИЗКУСТВЕН ИНТЕЛЕКТ**

По-горе са описани подробно компонентите на инструментариума за откриване на нефтени разливи. Интеграцията на тези елементи дава възможност за сравнение на възможностите, производителността и оптималните случаи на употреба на различните платформи и подходи с изкуствен интелект. Според съществуващата литература нито една платформа или алгоритъм не са универсално превъзходни; по-скоро бъдещето е в интелигентното обединяване на данни и модели от орбитални и въздушни платформи с отворен код в сплотена, управлявана от изкуствения интелект рамка за наблюдение.

Дефиниране на оперативна ниша чрез матрица на платформата и възможностите

Изборът на платформа за наблюдение диктува мащаба, разделителната способност и вида на получената информация, определяйки нейната ниша във веригата за мониторинг. Таблица 1 синтезира основните характеристики и последиците от изкуствения интелект на всяка основна платформа с отворен код.

Таблица 1. Сравнителен анализ на платформи с отворен код за откриване на нефтени разливи, задвижвани от изкуствения интелект

Платформа и основен сензор	Пространствена разделителна способност	Времева рамка	Ключови характеристики	Основни силни страни на ИИ метода	Основни ограничения и предизвикателства пред ИИ
Сателит: SAR (например Sentinel-1)	~10 – 40 м	12 дни (глобално)	Затихване на разсейването на Браг (грапавост на повърхността).	Работа при всякакви метеорологични условия, денем/нощем.	Разграничаване по сходство (слаб вятър, биогенни филми).
Сателит: Оптичен/Мултиспектрален (например Sentinel-2)	10 – 60 м	5 дни (глобално)	Спектрално поглъщане, отражение и термичен контраст.	Позволяват разграничаване на материалите и потенциално определяне на типа на нефта.	Изключителна зависимост от безоблачни, дневни условия.
БЛА: RGB/Мултиспектрален/Термичен	1 см – 1 м	При поискване	Спектрални/термични сигнатури с висока резолюция и визуална морфология.	Несравнима пространствена детайлност за структура на гладки повърхности, оценка на дебелината (термична) и валидиране на наземни данни.	Изключително ограничено пространствено покритие. Кратка продължителност на полета. Регулаторни пречки.

Горната таблица разкрива естествена йерархия от мащаб и надеждност. Сателитните SAR системи действат като широкообхватна мрежа, сканирайки океаните непрекъснато, за да сигнализират за потенциални инциденти. Сателитните оптични данни осигуряват спектрално потвърждение, когато е възможно. Безпилотните летателни апарати (БЛА) след това действат като окончателен верификатор, разположен към идентифицирана от SAR цел, за да събират приложими, високоточни данни за реагиращите и да генерират безупречни анотации за подобряване на сателитните модели с изкуствен интелект.

Еволюция на алгоритмите от ръчно създадени функции до контекстно осъзнато обучение

Преходът от класическо машинно обучение към дълбоко обучение представлява повече от постепенно повишаване на точността; той означава преминаване от експлицитна, дефинирана от човека логика към имплицитно, управлявано от данни разпознаване на модели. Таблица 2 сравнява тези парадигми.

Таблица 2. Еволюция и сравнение на методите с изкуствен интелект за откриване на нефтени разливи. F1-оценката (0-1) е хармоничната средна стойност на прецизността и пълнотата, стандартен показател за небалансирани задачи за класификация, като например откриване на нефтени разливи.

Парадигма на алгоритъма	Примерни модели	Ключови характеристики	Типична точност (F1-оценка)	Идеален случай на употреба и източник на данни
Класическо машинно обучение (базирано на характеристики)	Случайна гора, машина с опорни вектори (SVM)	Разчита на ръчно извлечени характеристики (текстура, геометрия).	0,75 – 0,88	Добре дефинирани проблеми с ограничени, хомогенни данни. Ефективни за предварителна SAR класификация на тъмни петна.
Дълбоко обучение: Семантична сегментация	U-Net, DeepLabv3+	Изучава характеристики директно от пиксели. Отлично се справя с улавянето на сложни форми и контексти. Изисква големи набори от данни и GPU изчисления.	0,89 – 0,97	Най-съвременна технология за пикселна класификация както на SAR, така и на оптични данни.
Дълбоко обучение: Трансформатори на зрението	SegFormer, U-Net с трансформаторни блокове	Използва самовнимание, за да моделира глобален контекст в цялото изображение. По-малко зависи от локалните индуктивни отклонения на CNN.	Развиващи се (0,90+ в проучвания)	Бъдеща посока. За предсказващи задачи, като прогнозиране на дрейф на петрол или разграничаване на петрол от подобни, с използване на хидродинамичен контекст.
Хибридни/физически информирани модели	PINN-и, модели, интегриращи данни за вълни/вятър	Интегрира физически уравнения (например дрейф на нефт) или спомагателни данни във функцията за загуби на ИИ.	В процес на активно проучване	Бъдеща посока. За предсказващи задачи, като прогнозиране на дрейф на петрол или разграничаване от подобни явления.

Преходът към DL, особено към архитектури, подобни на U-Net, осигурява значителен скок в устойчивостта, особено при обработката на шумните и променливи сигнатури в SAR данните. Това обаче идва за сметка на проблема с „черната кутия“ – намаляване на интерпретацията, което е значителна пречка за регулаторното приемане и последващия анализ. Нарастващата тенденция не е да се изоставят класическите методи, а да се използват като интерпретируеми допълнения или да се интегрират физически принципи директно в DL архитектурите (например Physics-Informed Neural Networks), за да се създадат по-надеждни и физически последователни модели.

ЗАКЛЮЧЕНИЕ

Наблюдението на морските нефтени разливи се развива от традиционни ръчни методи към автоматизирани системи, базирани на изкуствения интелект и данни с отворен достъп. Сателитните сензорни платформи осигуряват широкомащабно и непрекъснато наблюдение, докато безпилотните летателни апарати предоставят проверка с висока разделителна способност на място. В основата на тази трансформация стоят моделите за дълбоко обучение, особено архитектури за семантична сегментация като U-Net, които позволяват бързо и точно откриване на нефтени разливи.

Най-големият потенциал се крие в интегрирането на различни източници на данни в единна интелигентна система. В такава среда сателитните наблюдения откриват потенциал-

ни разливи, дроновете извършват последваща проверка, а изкуственият интелект обединява информацията в обща оперативна картина в реално време. Получените полеви данни допълнително подобряват точността на моделите чрез непрекъснато обучение.

Въпреки постигнатия напредък остават предизвикателства, свързани с разграничаването на нефтени разливи от сходни явления, ограничените обучаващи данни и необходимостта от по-обясними и надеждни модели. Независимо от това комбинацията от отворени сателитни данни, дренови технологии и изкуствен интелект поставя основите на ново поколение системи за мониторинг, които позволяват по-бързо откриване, по-ефективна реакция и по-добра защита на морската среда.

ЛИТЕРАТУРА

- BAI, Y.; LI, C., 2021. A review on the applications of unmanned aerial vehicles in oil spill detection and monitoring. *Journal of Marine Science and Engineering*, vol. 9, no. 11, p. 1225. Available from: <https://doi.org/10.3390/jmse9111225>
- BREKKE, C.; SOLBERG, A. H., 2005. Oil spill detection by satellite remote sensing. *Remote Sensing of Environment*, vol. 95, no. 1, pp. 1–13. Available from: <https://doi.org/10.1016/j.rse.2004.11.015>
- CHEN, L. C.; ZHU, Y.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H., 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: *Proceedings of the European Conference on Computer Vision (ECCV)*, pp. 801–818. Available from: https://doi.org/10.1007/978-3-030-01234-2_49
- CHUANMIN, H.; YINGCHENG, L.; SHAOJIE, S.; YONGXUE, L., 2021. Optical remote sensing of oil spills in the ocean: what is really possible? *Journal of Remote Sensing*, vol. 2021, Article ID 9141902. Available from: <https://doi.org/10.34133/2021/9141902>
- DOSOVITSKIY, A.; BEYER, L.; KOLESNIKOV, A.; WEISSENBORN, D.; ZHAI, X.; UNTERTHINER, T.; HOULSBY, N. et al., 2020. *An image is worth 16×16 words: transformers for image recognition at scale*. arXiv preprint, arXiv:2010.11929. Available from: <https://doi.org/10.48550/arXiv.2010.11929>
- DUGGAN, A.; ANDRADE, B.; AFLI, H., 2025. *Advancing Earth observation: a survey on AI-powered image processing in satellites*. arXiv preprint, arXiv:2501.12030. Available from: <https://doi.org/10.48550/arXiv.2501.12030>
- ESPEDAL, H. A.; WAHL, T., 1999. Satellite SAR oil spill detection using wind history information. *International Journal of Remote Sensing*, vol. 20, no. 1, pp. 49–65. Available from: <https://doi.org/10.1080/014311699213659>
- FINGAS, M.; BROWN, C. E., 2018. A review of oil spill remote sensing. *Sensors*, vol. 18, no. 1, p. 91. Available from: <https://doi.org/10.3390/s18010091>
- JIAO, Z.; JIA, G.; CAI, Y., 2019. A new approach to oil spill detection that combines deep learning with unmanned aerial vehicles. *Computers & Industrial Engineering*, vol. 135, pp. 1300–1311. Available from: <https://doi.org/10.1016/j.cie.2018.11.048>
- KRESTENITIS, M.; ORFANIDIS, G.; IOANNIDIS, K.; AVGERINAKIS, K.; VROCHIDIS, S.; KOMPATSIARIS, I., 2019. Oil spill identification from satellite images using deep neural networks. *Remote Sensing*, vol. 11, no. 15, p. 1762. Available from: <https://doi.org/10.3390/rs11151762>
- LEIFER, I.; LEHR, W. J.; SIMECEK-BEATTY, D.; BRADLEY, E.; CLARK, R.; DENNISON, P.; JONES, B., 2012. State of the art satellite and airborne marine oil spill remote sensing: application to the BP Deepwater Horizon oil spill. *Remote Sensing of Environment*, vol. 124, pp. 185–209. Available from: <https://doi.org/10.1016/j.rse.2012.03.024>
- PAHLEVAN, N.; SARKAR, S.; FRANZ, B. A.; BALASUBRAMANIAN, S. V.; HE, J., 2017. Sentinel-2 MultiSpectral Instrument (MSI) data processing for aquatic science applications: demonstrations and validations. *Remote Sensing of Environment*, vol. 201, pp. 47–56. Available from: <https://doi.org/10.1016/j.rse.2017.08.033>
- RAISSI, M.; PERDIKARIS, P.; KARNIADAKIS, G. E., 2019. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, vol. 378, pp. 686–707. Available from: <https://doi.org/10.1016/j.jcp.2018.10.045>
- REICHSTEIN, M.; CAMPS-VALLS, G.; STEVENS, B.; JUNG, M.; DENZLER, J.; CARVALHAIS, N.; PRABHAT, 2019. Deep learning and process understanding for data-driven Earth system science. *Nature*, vol. 566, no. 7743, pp. 195–204. Available from: <https://doi.org/10.1038/s41586-019-0912-1>
- RONNEBERGER, O.; FISCHER, P.; BROX, T., 2015. U-Net: convolutional networks for biomedical image segmentation. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer, pp. 234–241. Available from: https://doi.org/10.1007/978-3-319-24574-4_28
- SURESH, L.; ABHILASH, S.; ADITHYA, M.; ANIRUDH, N.; CHANDAN, S., 2024. A survey on satellite image processing using machine learning. *International Journal of Innovative Science and Research Technology*, vol. 9, no. 11, pp. 2589–2594.
- TORRES, R.; SNOEIJ, P.; GEUDTNER, D.; BIBBY, D.; DAVIDSON, M.; ATTEMA, E.; ROSTAN, F. et al., 2012. GMES Sentinel-1 mission. *Remote Sensing of Environment*, vol. 120, pp. 9–24. Available from: <https://doi.org/10.1016/j.rse.2011.05.028>
- XIE, E.; WANG, W.; YU, Z.; ANANDKUMAR, A.; ALVAREZ, J. M.; LUO, P., 2021. SegFormer: simple and efficient

design for semantic segmentation with transformers. *Advances in Neural Information Processing Systems*, vol. 34. ZHENG, Z.; ZHONG, Y.; WANG, J.; MA, A., 2021. A deep learning based oil spill detection system using synthetic aperture radar imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 181, pp. 178–191. Available from: <https://doi.org/10.1016/j.isprsjprs.2021.09.007>

ZHENGSI, Z.; ZHU, L., 2023. A review on unmanned aerial vehicle remote sensing: platforms, sensors, data processing methods, and applications. *Drones*, vol. 7, no. 6, p. 398. Available from: <https://doi.org/10.3390/drones7060398>

FROM ORBIT TO COASTLINE: AI-POWERED TOOLS FOR OIL SPILL DETECTION USING OPEN-SOURCE PLATFORMS

Abstract: *Rapid and accurate detection of marine oil spills is a critical global environmental challenge. Traditional monitoring methods, relying on ship patrols and aerial surveillance, are limited by cost, scope, and time. A paradigm shift is underway, fueled by the convergence of three transformative technologies: open-source satellite data, unmanned aerial vehicles (UAVs), and artificial intelligence (AI). This synthesis examines the current ecosystem of AI-powered tools that use freely available data from orbital platforms and drone-based imagery to automate and improve oil spill monitoring. The standard AI workflow is analyzed, from data preprocessing and classical machine learning to advanced deep learning segmentation models such as U-Net. Satellite systems provide all-weather surveillance, and unmanned aerial vehicles (UAVs) provide unparalleled high-resolution inspection and thickness estimation. Despite progress, key challenges remain, including distinguishing “lookalike” phenomena and the need for explainable AI in operational contexts. The future trajectory points to integrated, multi-platform monitoring systems where AI not only detects but also predicts spill dynamics, building a powerful open-access toolkit for marine ecosystem conservation.*

Keywords: *Oil Spill Detection; Artificial Intelligence; Unmanned Aerial Vehicles (UAV); Sentinel; Environmental Monitoring*

Vassil Mihalkov, PhD Student
ORCID: 0000-0003-3630-0040
Rakovski National Defense College
Sofia, Bulgaria
E-mail: vmihalkov@icloud.com