



UNIVERSITATEA NAȚIONALĂ DE  
ȘTIINȚĂ ȘI TEHNOLOGIE  
POLITEHNICA BUCUREȘTI



Școala Doctorală de Electronică, Telecomunicații  
și Tehnologia Informației

Decizie nr. \_\_\_\_ din \_\_\_\_-\_\_\_\_-2026

# REZUMAT TEZĂ DE DOCTORAT

Ing. Alexandru POHONȚU

---

SISTEM INTELIGENT DE MONITORIZARE RADIO-  
ELECTRONICĂ A TRAFICULUI NAVAL

INTELLIGENT SYSTEM FOR NAVAL RADIO-  
ELECTRONIC SURVEILLANCE

---

## COMISIA DE DOCTORAT

\_\_\_\_\_  
\_\_\_\_\_

**Prof. Dr. Ing. Constantin VERTAN**  
Univ. Politehnica din București

\_\_\_\_\_  
\_\_\_\_\_

\_\_\_\_\_  
\_\_\_\_\_

\_\_\_\_\_  
\_\_\_\_\_

Președinte

Conducător de doctorat

Referent

Referent

Referent

**BUCUREȘTI 2026**



# Cuprins

1	Introducere.....	1
1.1	Prezentarea domeniului tezei de doctorat.....	1
1.2	Scopul tezei de doctorat .....	1
1.3	Conținutul tezei de doctorat .....	2
2	Stadiul actual al cercetărilor .....	3
2.1	Surse de date specifice domeniului maritim .....	3
2.1.1	Sistemul Automat de Identificare - AIS.....	3
2.1.2	Sisteme de detecție radar .....	3
2.2	Arhitectură conceptuală de sistem MDA .....	4
2.3	Detectarea anomaliilor maritime .....	5
2.3.1	Metode de definire a comportamentului anormal .....	5
2.3.2	Metode de sesizare a excepțiilor de la comportamentul normal.....	6
3	Studiu asupra dinamicii traficului din Marea Neagră.....	7
3.1	Metodologia cercetării.....	7
3.2	Situația navelor aflate în detenție .....	7
4	Modele probabilistice de sesizare a anomaliilor maritime .....	9
4.2	Metodă parametrică de reprezentare a activităților maritime.....	9
4.2.1	Abordări similare .....	9
4.2.2	Metodologia cercetării .....	10
4.2.3	Rezultate .....	11
4.2.4	Concluzii asupra metodei.....	11
4.3	Metodă de extragere a valorilor aberante pentru detectarea profilurilor maritime anormale.....	11
4.3.1	Metodologia cercetării .....	11
4.3.2	Rezultate .....	13
4.3.3	Concluzii asupra metodei.....	14
4.4	Metodă de descoperire a track-urilor maritime simulate .....	14
4.4.1	Abordări similare .....	14
4.4.2	Metodologia cercetării .....	15
4.4.3	Rezultate .....	16
4.4.4	Concluzii asupra metodei.....	18
5	Modele AI pentru aplicații de supraveghere maritimă .....	19
5.2	Metodă de identificare a claselor de nave specializate .....	19
5.2.1	Abordări similare .....	19
5.2.2	Verificarea semnăturilor scrise de mână.....	19
5.2.3	Metodologia cercetării .....	20
5.2.4	Rezultate .....	21
5.2.5	Concluzii asupra metodei.....	22
5.3	Metodă de predicție a limitelor de descoperire pentru senzorii de supraveghere maritimă .....	22
5.3.1	Abordări similare .....	22
5.3.2	Metodologia cercetării .....	22
5.3.3	Rezultate .....	23

5.3.4	Concluzii .....	24
5.4	Metodă de detecție în timp real a navelor falsificate cu zgomot.....	24
5.4.1	Abordări similare .....	24
5.4.2	Metodologia cercetării .....	24
5.4.3	Rezultate .....	25
5.4.4	Concluzii asupra metodei.....	27
6	Concluzii.....	28
6.1	Contribuții originale .....	28
6.2	Lista lucrărilor originale.....	29

# Capitolul 1

## Introducere

Complexitatea crescândă a activităților socio-economice din domeniul maritim a făcut din acesta un scenariu pentru numeroase activități cu impact ridicat asupra siguranței, securității, economiei și mediului.

De vreme ce un procent mic, dar încă semnificativ, din flota globală poate fi implicat în activități ilegale, ilicite sau periculoase, numeroase agenții și autorități au început să desfășoare operațiuni pentru sporirea transparenței în domeniul naval și pentru detectarea, descurajarea și gestionarea acestor amenințări.

Trebuie remarcat faptul că nu există senzori sau tehnologii ideale care să poată îndeplini toate cerințele de supraveghere, deoarece toate tipurile de date prezintă limitări intrinseci specifice. În consecință, întreaga sarcină cognitivă se bazează acum, în mare măsură, pe expertiza umană.

### 1.1 Prezentarea domeniului tezei de doctorat

În era tehnologică actuală, domeniul supravegherii maritime se confruntă cu provocări complexe și cerințe tot mai ridicate, datorate evoluției rapide și a extinderii activităților maritime.

În prezent, sistemele MDA (*în lb. engleză* Maritime Domain Awareness) pot integra o varietate de surse (e.g., date provenite de la sateliți, radare, camere). Această abordare a condus la apariția unui nou set de provocări precum suprasolicitarea operatorilor cu cantități masive de date. În acest context, AI a apărut ca un instrument esențial pentru gestionarea și analiza eficientă a acestor volume mari de date și pentru transformarea informațiilor brute în cunoștințe operaționale utile.

Sistemele MDA moderne sunt capabile să detecteze anomalii maritime și evenimente relevante precum pirateria, pescuitul ilegal sau contrabanda, utilizând algoritmi de învățare automată (*în lb. engleză* Machine Learning - ML) și tehnologii specifice AI.

### 1.2 Scopul tezei de doctorat

Scopul acestei teze de doctorat este cel de a investiga și de a prezenta principalele descoperiri din domeniul automatizării activităților de supraveghere maritimă. Acest obiectiv a fost realizat prin analizarea literaturii de specialitate și prin evidențierea

diferiților algoritmi utilizați în aplicațiile de sesizare a anomaliilor maritime. De asemenea, această teză își propune să analizeze evoluția dinamică a traficului din Marea Neagră, și să identifice oportunitatea implementării acestor algoritmi în aplicațiile de sesizare a anomaliilor.

În plus, această teză aduce contribuții semnificative prin prezentarea a șase metodologii inovatoare, bazate pe modele statistice și rețele neuronale.

Prin automatizarea procesului de achiziție, integrare și descoperire a informațiilor, s-a urmărit realizarea posibilității de a monitoriza zone maritime extinse și de a detecta anomaliile cu intervenție umană minimă. Rezultatele acestei cercetări sunt așteptate să ofere perspective valoroase pentru cercetători, practicieni și factori de decizie interesați de utilizarea AI pentru îmbunătățirea conștientizării domeniului maritim și a siguranței transportului naval.

## 1.3 Conținutul tezei de doctorat

Teza de doctorat este structurată în șase capitole care urmăresc dezvoltarea unui sistem inteligent de supraveghere maritimă prin integrarea algoritmilor de inteligență artificială.

**Capitolul 1** introduce domeniul supravegherii maritime și subliniază relevanța aplicării AI în identificarea și gestionarea amenințărilor maritime.

**Capitolul 2** prezintă stadiul actual al cercetării, sursele de date utilizate și modele AI existente, propunând totodată o arhitectură conceptuală a unui sistem inteligent.

**Capitolul 3** oferă o analiză a traficului naval din Marea Neagră și identifică oportunități pentru detectarea anomaliilor maritime.

**Capitolul 4** propune trei modele probabilistice noi pentru detecția anomaliilor în activitatea navală, iar în **Capitolul 5** sunt prezentate trei modele bazate pe rețele neuronale pentru identificarea navelor neidentificate, a activităților ascunse și a traiectoriilor falsificate.

**Capitolul 6** formulează concluziile, evidențiază contribuțiile originale și propune direcții de cercetare viitoare.

# Capitolul 2

## Stadiul actual al cercetărilor

Odată cu disponibilitatea tehnologiilor radar pentru producția în masă, diferite sisteme de supraveghere maritimă au fost dezvoltate la nivel global pentru a colecta date referitoare la evoluțiile traficului naval.

Supravegherea maritimă automată a devenit un subiect interdisciplinar care necesită cunoștințe din domenii precum informatica, securitatea, și transportul naval.

### 2.1 Surse de date specifice domeniului maritim

Sistemele convenționale cu specific MDA sunt concepute pentru a crește gradul de conștientizare în domeniul naval prin utilizarea diferiților senzori, și prin construirea unei reprezentări digitale, definită uzual drept Imaginea Maritimă Recunoscută (*în lb. engleză*: Recognized Maritime Picture - RMP).

În prezent, există varietate de senzori și surse de date care pot fi integrate într-un mod eterogen pentru generarea MAP.

#### 2.1.1 Sistemul Automat de Identificare - AIS

AIS este un sistem de supraveghere prin raportare automată și voluntară, utilizat la bordul navelor și de către autoritățile navale. Rolul de bază al acestui sistem este cel de a identifica și de a localiza platformele navale în timp real, prin schimbul electronic de date cu alte nave din apropiere, stații fixe de bază dispuse la coastă sau sateliți.

#### 2.1.2 Sisteme de detecție radar

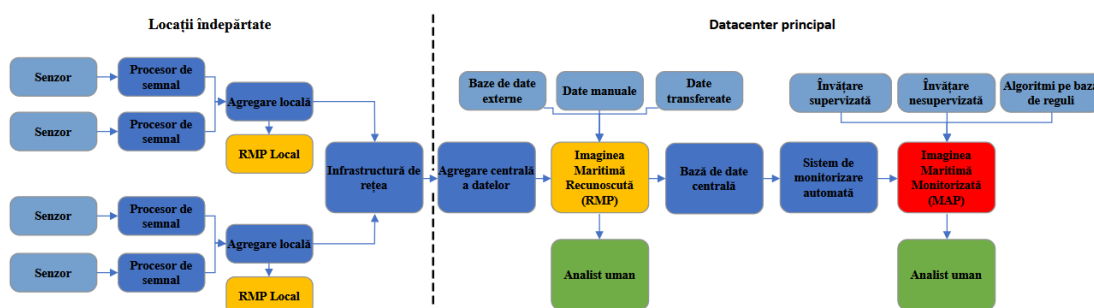
Din cauza faptului că sistemele de auto-raportare sunt obligatorii doar pentru navele de dimensiuni mari, senzorii maritimi activi reprezintă o necesitate pentru acțiunile de detectare a navelor de mici dimensiuni sau a celor non-cooperante. Adesea, datele AIS nu sunt disponibile întotdeauna în mediul operațional maritim. Astfel, doar datele senzorilor activi pot fi utilizate, precum cele provenite de la sistemele radar.

Radarele reprezintă senzori activi care emit impulsuri artificiale de energie electromagnetică pentru a ”ilumina” mediul, și care folosesc caracteristicile răspunsului pentru a crea o imagine.

## 2.2 Arhitectură conceptuală de sistem MDA

Imaginea RMP este constituită din toate contactele obținute din mediul maritim (i.e., nave de suprafață/subacvatice, nave comerciale/guvernamentale). Generarea imaginii RMP reprezintă o sarcină continuă de colectare, corelare, integrare și de analiză a datelor provenite de la diferiți senzori. Abghari și colab. prezintă un model de procesare a datelor care este structurat pe șase nivele, fiind dezvoltat de către U.S. Joint Directors of Laboratories, și care întrunește pașii necesari pentru generarea RMP [1].

În Figura 2.5 este reprezentat un flux teoretic de date pentru generarea RMP și MAP. Primul pas implică procesul de colectare a semnalelor de la diverse tipuri de senzori (e.g., AIS, radare, camere), din diferite locații de coastă sau fluviale. După ce aceste semnale sunt procesate, acestea sunt corelate și integrate în sisteme locale pentru a genera un RMP zonal (o subimagine a RMP global). Aceste imagini integrate sunt apoi transmise către un centru de supraveghere maritimă, de obicei, printr-o rețea extinsă. Aici, imaginea RMP globală este generată prin îmbinarea tuturor subimaginilor RMP, a datelor introduse manual de operatori, a datelor transferate de la alți senzori offline (e.g., transfer air-gap) sau a datelor obținute de la alte sisteme de supraveghere independente. După generarea imaginii RMP globale, aceasta este diseminată către diferiți analiști umani, de obicei, prin aplicații vizuale, și este stocată în diverse baze de date, pentru reluări istorice sau analize post-eveniment.



**Figura 2.1** Sistem MDA conceptual

În sistemele moderne de supraveghere, după ce sunt combinate și stocate, datele RMP sunt procesate de diverși agenți inteligenți și tehnici de informare contextuală. În cele din urmă, datele generate pot fi interpretate pentru a monitoriza traficul naval și pentru a descoperi activități anormale, realizând astfel o imagine de monitorizare maritimă MAP.



## 2.3 Detectarea anomaliilor maritime

În domeniul naval, detectarea anomaliilor în timp real reprezintă sarcina continuă de identificare a potențialelor amenințări și pericole pentru securitatea maritimă și siguranța navigației.

În recenzia lor, Riveiro și colab. studiază multiple articole referitoare la domeniul detectării anomaliilor maritime și le clasifică funcție de patru criterii: tip de date, metode, sisteme și aspecte ale utilizatorilor [2]. Autorii clasifică algoritmi și abordările utilizate în trei grupe principale:

- Abordări bazate pe date;
- Abordări bazate pe semnătură;
- Soluții hibride.

În funcție de modul în care punctele traiectoriilor sunt procesate, metodele de detectare a anomaliilor pot fi distinse în două clase principale:

- Bazate pe locații punctuale;
- Bazate pe traiectorii;

O altă taxonomie cuprinzătoare de detectare a anomaliilor este furnizată de Wolsing și colab. într-o revizuire a 44 de lucrări referitoare la diferite abordări de detectare a anomaliilor pentru datele AIS [3]. Punctual, în conținutul lucrării sunt studiate multiple abordări (i.e., DBSCAN, GMM, rețele Bayes, procese Gauss, clustering).

Martineau și colab. prezintă o taxonomie a metodelor de detectare a anomaliilor maritime bazată pe parametri cinematici. Autorii lucrării au realizat, de asemenea, o mapare a anomaliilor detectate în comparație cu metodele care pot fi utilizate [4].

### 2.3.1 Metode de definire a comportamentului anormal

Comportamentul unei nave poate fi reprezentat ca "*suma*" tuturor parametrilor observați pe o perioadă extinsă de timp (e.g., tipul navei, poziția, viteza, cursul, portul de destinație, naționalitatea echipajului). Astfel, pot fi construite diferite reguli și modele bazate pe date contextuale, expertiză umană sau prin observarea unor evenimente repetabile care au loc în intervale de timp specifice și în moduri previzibile.

Lane și colab. definesc în lucrarea lor cinci comportamente anormale derivate din date AIS [5]. Fiecare dintre aceste categorii este enumerată mai jos, împreună cu alte metode identificate în literatură și în practică.

- A. Abateri de la rutele standard;
- B. Situații de întâlnire sau de urmărire pe mare;
- C. Pătrunderea în raioane interzise sau zone periculoase;
- D. Oprirea emisiilor AIS și desfășurarea de activități ascunse;
- E. Sosiri neașteptate și abateri de la tiparul de activitate specific;

- F. Manevre ale unor activități specifice;
- G. Manipulări ale datelor AIS;
- H. Reguli și filtre simple.

### **2.3.2 Metode de sesizare a excepțiilor de la comportamentul normal**

Aceste metode bazate pe date sunt utilizate pentru a construi modele de comportament ale navelor din datele istorice de mișcare, pentru a clasifica noile observații ale navelor drept normale sau anormale.

Cele mai comune metode de detectare a anomaliilor bazate pe date sunt clasificate în două categorii: metode statistice și metode de învățare automată [6].

Un grup major de modele de supraveghere MDA automată are legătură cu învățarea automată, fie cu rețele neuronale, fie cu metode de grupare (*în lb. engleză*: clustering). Un alt grup mare de lucrări ține seama de metodele stocastice precum modelele GMM, rețelele Bayes sau estimatori KDE [3].

Tu și colab. clasifică aceste metode în funcție de caracteristicile de învățare ale modelelor utilizate: geografice și parametrice [6]. În lucrarea lor, autorii studiază patru modele dependente de hărți (i.e., zonă de normalitate, rețea Fuzzy ARTMAP, model Holst, metoda câmpurilor potențiale) și trei modele independente de hărți (i.e., model de grupare a traiectoriilor, proces Gaussian, rețea Bayes). Metodele chestionate sunt enumerate în subparagrafele care urmează, împreună cu alte metode identificate în literatura de specialitate.

- A. Definirea zonelor de normalitate;
- B. Rețele Fuzzy ARTMAP;
- C. Model Holst;
- D. Metoda câmpurilor potențiale;
- E. Modele de grupare (clustering);
- F. Modele statistice
- G. Rețele Bayes

# Capitolul 3


## Studiu asupra dinamicii traficului din Marea Neagră

### 3.1 Metodologia cercetării

În cadrul unui studiu desfășurat în perioada 1 iulie 2021 – 30 iunie 2022, au fost colectate și procesate date din multiple transponder-e AIS care au înregistrat traficul naval din Zona Economică Exclusivă (ZEE) a României.

Analiza efectuată a inclus statistici referitoare la activitățile portuare din principalele porturi românești, având drept obiectiv identificarea oportunităților de implementare a algoritmilor AI pentru detectarea automată a situațiilor maritime anormale.

Pe parcursul etapei de colectarea a mesajelor AIS, s-a înregistrat un număr de 1674 de nave distincte, care au efectuat aproximativ 78.500 de intrări în zona portului Constanța. Durata medie de acostare a fost de aproximativ 130 ore, iar traficul a fost aproximativ constant (Figura 3.10).



**Figura 3.1** Dinamica traficului de date AIS din portul Constanța

### 3.2 Situația navelor aflate în detenție

Listele PSC (*în lb. engleză*: Port State Control) reprezintă instrumente esențiale care includ nave care au fost supuse inspecțiilor și care nu au respectat standardele impuse, fiind astfel sancționate sau interzise să opereze în anumite regiuni maritime.

Memorandumurile de Înțelegere (*în lb. engleză*: Memorandum of Understanding - MoU) sunt acorduri regionale care facilitează implementarea PSC prin coordonarea inspecțiilor și partajarea informațiilor.

Într-o primă etapă de analiză a datelor primite de la transponder-ele AIS, s-a realizat o statistică privind navele incluse în memorandumurile și listele PSC prezentate în Anexa 3 (liste actualizate la data de 20.06.2022). Astfel, au fost identificate acele nave interzise prin embargou sau sancționate, care au tranzitat regiunea în perioada efectuării studiului (Figura 3.12).

Trebuie remarcat că, dintr-un total de aproximativ 1.142 de nave suspecte (dintre care 898 active în ultimele 60 de zile ale înregistrărilor), 101 dintre acestea au tranzitat Marea Neagră prin 509 activități. În porturile românești, au fost identificate 84 de intrări ale 33 de nave distincte, majoritatea fiind incluse în lista PSC a memorandumului Mării Negre.

Numele listei PSC	Numărul total de nave din listă (30.06.2022)	Numărul navelor inactive pe o perioadă mai mare de 60 de zile (30.06.2022)	Marea Neagră		ZEE România		Apele Teritoriale		Porturile Românești	
			Numărul de nave distincte	Numărul de tranzituri	Numărul de nave distincte	Numărul de tranzituri	Numărul de nave distincte	Numărul de tranzituri	Numărul de nave distincte	Numărul de tranzituri
MoU Abuja	10	1	0	0	0	0	0	0	0	0
MoU Marea Neagră	21	0	21	155	13	105	12	86	10	23
MoU Oceanul Indian	88	2	6	12	6	11	4	5	4	5
MoU Paris	57	24	6	31	4	11	3	36	1	25
MoU Riyadh	17	0	1	3	1	5	1	6	1	2
MoU Tokyo	13	1	0	0	0	0	0	0	0	0
MoU Vina Del Mar	0	0	0	0	0	0	0	0	0	0
OFAC CAATSA Russia	1	0	0	0	0	0	0	0	0	0
OFAC DPRK	277	95	6	16	5	13	2	3	2	2
OFAC IFSR	4	2	0	0	0	0	0	0	0	0
OFAC Iran	224	8	8	22	6	16	6	15	6	14
OFAC Libya	8	1	0	0	0	0	0	0	0	0
OFAC NPWMD	127	2	8	22	6	16	6	15	6	14
OFAC PEESA	16	0	0	0	0	0	0	0	0	0
OFAC Syria	77	23	16	99	7	23	6	27	4	7
OFAC SDGT	13	1	0	0	0	0	0	0	0	0
OFAC Venezuela	60	3	1	2	1	3	1	4	1	1
OFAC Ukraine	7	0	3	31	0	0	0	0	0	0
Lista IUU a navelor de pescuit	128	112	0	0	0	0	0	0	0	0
Lista Gărzii de Coastă S.U.A.	36	2	4	6	2	3	1	1	1	1
Nave aflate în detenție	522	0	45	237	13	32	12	40	10	20
<b>Total</b>	<b>1142</b>	<b>274</b>	<b>101</b>	<b>509</b>	<b>50</b>	<b>200</b>	<b>40</b>	<b>201</b>	<b>33</b>	<b>84</b>

**Figura 3.2** Situația navelor sancționate care au tranzitat porturile românești

Rezultatele acestei analize statistice indică faptul că există posibilitatea ca și în regiunea Mării Negre să apară situații în care siguranța și securitatea maritimă să fie afectate de prezența unor platforme navale care pot reprezenta un pericol. Astfel, se deduce oportunitatea implementării unor algoritmi inteligenți, precum cei descriși în literatura de specialitate (Capitolul 2) sau cei propuși în prezenta lucrare (Capitolele 4 și 5), care să poată sesiza automat anomalii maritime și să informeze operatorii maritimi în vederea luării unor decizii informate.

# Capitolul 4

## Modele probabilistice de sesizare a anomaliilor maritime

Modelele probabilistice oferă un cadru robust pentru identificarea comportamentelor anormale și a potențialelor amenințări, prin analiza datelor și observarea devierilor de la modelele statistice. În această secțiune sunt descrise trei noi metode stochastice de sesizare a anomaliilor maritime.

### 4.2 Metodă parametrică de reprezentare a activităților maritime

Caracterizarea traficului naval și detectarea automată a anomaliilor maritime reprezintă un domeniu activ de cercetare. Cu toate că au fost propuse multiple abordări de analiză probabilistică pentru diferite fenomene maritime parametrice, majoritatea acestora se concentrează pe analiza unor date cinematice primare, precum poziția, viteza, cursul navelor sau deplasarea laterală față de un obstacol. În cadrul acestui subcapitol este prezentată o analiză asupra unor activități maritime complexe (e.g., pescuit, derivă, activități AIS ascunse) care au fost derivate prin procesarea de mesaje AIS înregistrate în Marea Neagră (ZEE România).

#### 4.2.1 Abordări similare

Kim și colab. și Son și colab. prezintă în două lucrări separate mai multe teste de analiză statistică a traficului naval în regiunea portului Busan. Ambele lucrări demonstrează faptul că traficul pe canalele de navigație observate poate fi reprezentat ca o distribuție normală gaussiană, în special în cazul datelor legate de poziționarea laterală a navelor în canale [7] [8]. Totodată, Rong și colab. sugerează printr-o analiză a parametrilor cinematici faptul că traficul maritim în zona maritimă portugheză este caracterizat probabilistic în ceea ce privește distribuția laterală a traiectoriilor și a profilurilor de viteză [9].

## 4.2.2 Metodologia cercetării

### A. Colectarea și pre-procesarea datelor

Pentru prezentul studiu, date de la multiple transponder-e AIS au fost colectate și procesate. Aceste transponder-e au înregistrat traficul naval din ZEE România în perioada 01.07.2021 - 30.06.2022. Ulterior, prin aplicarea unor algoritmilor bazați pe reguli, și prin implementarea unor agenți de tipul web-scraping, au fost extrase informații privind duratele mai multor tipuri de activități specifice traficului naval (i.e., activități de acostare, ancorare, pescuit, derivă, ascunderea emisiilor AIS, întâlniri pe mare sau vechimea de exploatare a navelor).

### B. Reprezentări statistice ale datelor înregistrate

Următorul pas al studiului a constat în calcularea valorilor medii  $\mu$  (4.1) și a deviațiilor standard  $\sigma$  (4.2) pentru duratele fiecărui tip de activitate înregistrată.

$$\mu = \frac{\sum x}{n} \quad (4.1)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_x (x - \mu)^2} \quad (4.2)$$

, unde  $x$  reprezintă valorile fiecărei durate înregistrate pentru evenimente, iar  $n$  este numărul total de înregistrări.

Următorul pas a implicat realizarea histogramelor și a funcțiilor PDF (*în lb. engleză*: Probability Density Function) și CDF (*în lb. engleză*: Cumulative Density Function), prin aplicarea unei aplicații KDE (*în lb. engleză*: Kernel Density Estimation).

### C. Potrivirea datelor în distribuții parametrice cunoscute

Următorul pas al acestui studiu a fost să realizeze o evaluare statistică pentru mai multe colecții de PDF-uri parametrice pentru a găsi cea mai bună potrivire dintre funcțiile empirice obținute și acele modele care reflectă precis caracteristicile variabilelor. Pentru aceasta, distribuțiile empirice de date înregistrate au fost comparate cu mai multe distribuții teoretice (e.g., Gaussiană, Gamma, Rayleigh, Log-normal, Weibull).

### D. Extragerea unei distribuții parametrice universale

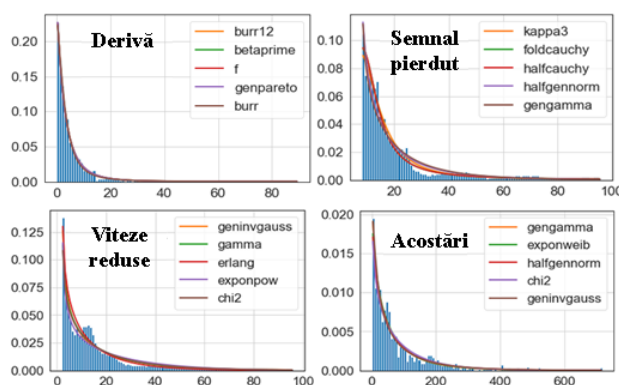
Adițional, au fost calculate patru metrici de potrivire suplimentare, standardizate și mediate. Scopul a fost cel de a găsi o distribuție universală care să se potrivească cel mai bine tuturor tipurilor de activități maritime. Statistica KS (4.7) a fost calculată pentru a cuantifica distanța dintre toate distribuțiile empirice și parametrice. Această metrică se bazează pe cea mai mare diferență verticală între CDF-urile teoretice și cele empirice.

$$KS = \max_{i=1}^n (E(x_i) - P(x_i), P(x_i) - E(x_i)) \quad (4.7)$$

, unde  $n$  reprezintă numărul total de înregistrări ale variabilei aleatoare  $X$  și  $E(x_i)$  și  $P(x_i)$  reprezintă valorile de densitate empirică și ajustată pentru înregistrările  $x_i$  [10].

### 4.2.3 Rezultate

Toți pașii anteriori au fost aplicați pentru fiecare distribuție empirică asociată activităților maritime înregistrate. Exemple de potriviri se regăsesc în Figura 4.5.



*Figura 4.1 Cele mai potrivite distribuții ale activităților înregistrate*

### 4.2.4 Concluzii asupra metodei

Acest subcapitol propune o soluție hibridă pentru analizarea activităților navale complexe. Această soluție constă într-o combinație de algoritmi bazați pe reguli și o aplicație de potrivire statistică.

Astfel, s-a demonstrat că pentru toate distribuțiile empirice extrase din activitățile navelor, este posibil să se obțină un model adecvat, sub forma unor distribuții parametrice cunoscute.

## 4.3 Metodă de extragere a valorilor aberante pentru detectarea profilurilor maritime anormale

Acest subcapitol prezintă o nouă abordare statistică asupra duratelor temporale ale patru tipuri de stări navale: în marș, acostare în port, așteptare la ancoră și ascundere emisii AIS.

### 4.3.1 Metodologia cercetării

#### A. Colectarea datelor

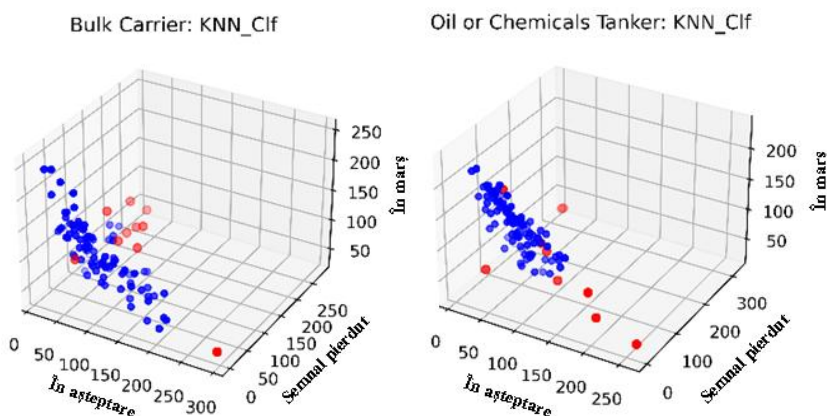
Pentru acest studiu, date de la multiple transponder-e AIS au fost colectate pe parcursul unui an. În continuare, prin decodarea mesajelor formate NMEA-0183, au

fost extrase toate codurile MMSI pentru acele nave care au tranzitat regiunea ZEE România în anul 2022.


În cea de-a doua etapă, a fost implementat un modul de tipul web scrapping pentru a extrage date suplimentare disponibile pe multiple platforme web (i.e., Marine Traffic – Professional Plan, FleetMon, Vessel Finder). Datele extrase au inclus subclasa navelor, lungimea, tonajul, distanța totală parcursă și profilul de utilizare.

## B. Implementare OD multivariat

Ultima parte a acestui studiu a constatat în compararea performanței mai multor algoritmi OD (e.g., KNN, MCD, LOF, Isolation Forest, PCA). Acești algoritmi au analizat toate stările navale într-un mod multivariat pentru fiecare categorie de nave (Figura 4.8 și Figura 4.9). Pentru aceasta, a fost aleasă biblioteca open-source PyOD [11].



**Figura 4.2** Rezultatele KNN pentru vrachiere



**Figura 4.3** Rezultatele OCSVM pentru vrachiere

Ulterior, a fost efectuată o comparație preliminară după ce curbele Caracteristicii Operative a Receptorului (*în lb. engleză*: Receiver Operating Characteristic- ROC) au fost construite pentru toți algoritmi OD (Figura 4.10). Acest lucru a fost realizat sub ipoteza naivă că ar exista o corelație între scorul de anomalie ale tuturor seturilor de date specifice stărilor de navigație și riscul asociat navelor (date etichetate pe baza expertizei umane). Curbele ROC au reprezentat ratele de pozitivi reali (*în lb. engleză*: True Positive Rate - TPR) față de ratele de fals pozitiv




(în lb. engleză: False Positive Rate - FPR) la diverse niveluri de contaminare  $c$  ( $0,01 \leq c \leq 0,50$ ). TPR (4.21) a reprezentat proporția de cazuri pozitive adevărate identificate corect de către clasificatori, în timp ce FPR (4.22) a reprezentat proporția de cazuri pozitive false identificate incorect ca fiind adevărate.

$$TPR = \frac{TP}{TP + FN} \quad (4.21)$$

$$FPR = \frac{FP}{FP + TN} \quad (4.22)$$

, unde TP, FN, FP, TN reprezintă ratele de real pozitiv, fals negativ, fals pozitiv și real negativ între rezultatele algoritmilor OD și etichetele de risc ale navelor.




**Figura 4.4** Exemple de curbe ROC pentru multipli algoritmi OD


### 4.3.2 Rezultate

Toate etapele anterioare au fost aplicate pentru a descrie profilurile comportamentale ale mai multor clase de nave.

Figura 4.13 și Figura 4.14 prezintă performanțele mai multor algoritmi OD, la diverse rate de selectare. Aceste performanțe sunt reprezentate de numărul total de descoperiri ale navelor suspecte (pozitivele reale) și de performanța generală față de șansa aleatorie de selectare.



**Figura 4.5** Numărul mediu de nave suspecte descoperite



**Figura 4.6** Îmbunătățirea algoritmilor OD față de selecția aleatoare

La o primă vedere, algoritmi OD au adus o îmbunătățire semnificativă față de selecția aleatoare a navelor de aproximativ 50%. Astfel, rezultatele susțin ipoteza naivă cum că ar exista o corelație între scorul calculat și riscul asociat al navelor.

### 4.3.3 Concluzii asupra metodei

Accesul restricționat la informații și lipsa etichetelor de date reprezintă două provocări semnificative în dezvoltarea algoritmilor eficienți de detectare a anomaliilor maritime. Cu toate acestea, acest subcapitol propune o abordare diferită care ar putea ajuta autoritățile maritime să selecteze cele mai relevante nave pentru investigații și inspecții la bord. Abordarea combină rezultatele mai multor algoritmi de detectare a anomaliei care folosesc patru stări de navigație ca intrări.

Un avantaj al acestei abordări îl reprezintă transparența sa, făcând imposibilă suspectarea discriminării împotriva oricăror nave sau operatori economici. În plus, această abordare utilizează date disponibile în platforme web publice, ceea ce ar putea ajuta la diseminarea datelor și testarea algoritmilor în cazul în care se efectuează analize suplimentare.

## 4.4 Metodă de descoperire a track-urilor maritime simulate

Acest subcapitol investighează comportamentul stochastic al multiple nave care au navigat în Marea Neagră, și testează diferite modele de învățare automată capabile să distingă traseele reale de cele simulate. Modelele au atins o acuratețe de peste 98%. Studiul a pornit de la faptul că estimarea traiectoriilor viitoare ale navelor este afectată de erori, atât de măsurare, cât și de proces. Erorile de măsurare sunt cauzate în principal de impreciziile sistemelor de navigație prin satelit, în timp ce erorile de proces sunt influențate de factori precum vremea, curenții marini, vântul și variațiile în direcția de deplasare a navei.

### 4.4.1 Abordări similare

O metodă relevantă abordează provocarea determinării fiabilității datelor AIS prin utilizarea măsurătorilor radar și a informațiilor din sistemele de urmărire. Această


abordare presupune o aplicare inovatoare a testului secvențial al raportului de verosimilitate într-o formă generalizată. Metoda urmărește identificarea situațiilor în care navele reale transmit inițial date AIS corecte, dar încep ulterior să trimită coordonate false pentru a pătrunde nedetectate în zone restricționate. Probabilitatea de a detecta o astfel de înșelăciune se apropie de 100% pe măsură ce discrepanța dintre traseele raportate de AIS și cele radar crește și pe măsură ce numărul de sisteme radar utilizate este mai mare [12]. Deși această metodă oferă o acuratețe ridicată în identificarea semnalelor AIS falsificate, ea necesită utilizarea unor echipamente radar costisitoare.

## 4.4.2 Metodologia cercetării

### A. Colectarea și pre-procesarea datelor

Prima fază a acestui studiu a constat în colectarea timp de șapte zile a datelor de urmărire în timp real provenite de la multiple transponder-e AIS amplasate în apropierea țărmului românesc. În plus, au fost obținute fluxuri AIS în timp real din alte regiuni, prin intermediul unor platforme web dedicate.

Prelucrarea preliminară a implicat calculul diferitor parametri pentru fiecare poziție  $k$  a traiectoriilor înregistrate și a fost realizată prin analiza perechilor de coordonate de latitudine și longitudine secvențiale  $(\phi, \lambda)$  ale navelor:  $k-1$  (poziția anterior înregistrată),  $k$  (poziția curentă) și  $k+1$  (următoarea poziție înregistrată) (Fig. 4.15). Pentru a înțelege dinamica mișcării navelor, analiza a fost efectuată de mai multe ori la diferite perioade minimale  $\Delta t$  între două înregistrări consecutive. Aceste intervale au inclus setările de 1 secundă, 30 de secunde, 60 de secunde, 30 de minute și 1 oră.



**Figura 4.7** Reprezentări secvențiale ale coordonatelor specifice unei nave

În fiecare interval de eșantionare  $k$ , au fost calculați diferiți parametri, inclusiv magnitudinile vitezelor  $|\vec{V}|$ , unghiurile azimutale  $\theta$  și distanțele parcurse  $d$  între locațiile consecutive. Valorile  $d$  (4.24) și  $\theta$  (4.25) au fost determinate ca fiind distanțele și azimuturile dintre două puncte consecutive pe suprafața unei sfere.

$$d = 2r \cdot \arcsin \sqrt{\sin^2 \left( \frac{\phi_1 - \phi_2}{2} \right) + \cos(\phi_1) \cdot \cos(\phi_2) \cdot \sin^2 \left( \frac{\lambda_1 - \lambda_2}{2} \right)} \quad (4.24)$$

$$\theta = \text{atan2}(\sin(\lambda_1 - \lambda_2) \cdot \cos(\phi_2) \cdot \cos(\phi_1) \cdot \sin(\phi_2) - \sin(\phi_1) \cdot \cos(\phi_2) \cdot \cos(\lambda_1 - \lambda_2)) \quad (4.25)$$

, unde  $(\phi, \lambda)$  reprezintă coordonatele de latitudine și longitudine exprimate în radiani, iar  $r$  este raza Pământului.

## B. Implementare algoritmi de învățare automată


După analizarea distribuțiilor parametrilor  $|\vec{V}|$ ,  $\varepsilon_d$ ,  $\varepsilon_\alpha$  și  $\varepsilon_{dk}$  din toate traiectoriile înregistrate, s-a observat că navele autentice prezintă modele statistice distincte. Aceste modele permit identificarea navelor falsificate, care prezintă adesea variații limitate ale vitezelor și poziții viitoare previzibile, din cauza erorilor aproape inexistente înregistrate între pozițiile consecutive.

### 4.4.3 Rezultate

#### A. Aspecte generale


Identificarea navelor falsificate aflate în staționare a devenit evidentă după reprezentarea grafică a traiectoriilor tuturor platformelor înregistrate și calcularea vitezei medii, a direcției și a erorilor estimate între locațiile consecutive. Pentru această analiză au fost folosite traiectoriile ATON.

Figura 4.16 prezintă coordonatele înregistrate ale două platforme marine nepropulsate (o navă în derivă și o navă la ancoră), care prezintă o mișcare limitată, influențată de factori de mediu precum vântul și curenții.



**Figura 4.8** Navă în derivă (stânga) și navă la ancoră (dreapta)

Figura 4.17 prezintă coordonatele înregistrate ale două platforme staționare (o navă ancorată într-un port și un echipament de semnalizare maritimă – ATON). Spre deosebire de ATON-uri, toate navele staționare au prezentat variații de poziție cauzate de inexactități ale GPS-ului și de mișcarea în derivă.




**Figura 4.9** Navă ancorată (stânga) și ATON staționar (dreapta)


În urma unei analize mai detaliate a datelor înregistrate, a devenit evident că este posibilă diferențierea între navele în mișcare autentice și cele falsificate. O metodă de diferențiere constă în analizarea variațiilor vitezei la suprafața apei (*în lb. engleză*: Speed over Ground-SOG) și ale drumului navei la suprafața apei (*în lb.*

*engleză*: Course over Ground-COG), în special atunci când se utilizează intervale de timp mai mici.

De asemenea, s-a observat că este posibilă diferențierea între navele autentice și cele falsificate prin analizarea distribuțiilor erorilor filtrului Kalman. Navele falsificate tind să aibă traiectorii perfect liniare, cu erori Kalman aproape de zero, în timp ce navele autentice prezintă neregularități. Figura 4.21 prezintă două nave autentice: una care încearcă să mențină un COG constant și alta care prezintă multiple schimbări de direcție, în timp ce Figura 4.22 ilustrează comportamentul unei nave falsificate.



**Figura 4.10** Traiectorii reale



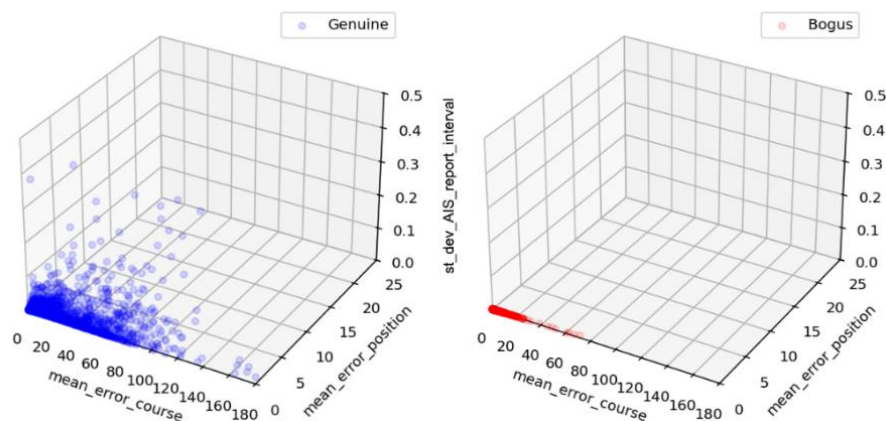
**Figura 4.11** Traiectorii falsificate

## B. Rezultate ale modelelor de învățare automată

Pentru acest studiu, mai multe modele de învățare automată au fost antrenate folosind seturi de date colectate la diferite intervale de timp: 1 secundă, 30 de secunde, 60 de secunde, 30 de minute și 1 oră. Caracteristicile de intrare pentru aceste modele au inclus mediile și deviațiile standard calculate pentru diverși parametri, precum vitezele navelor, intervalele de timp dintre rapoartele AIS și erorile de distanță și direcție între locații consecutive. Performanța fiecărui model ML a fost evaluată pe baza acestor caracteristici de intrare, iar rezultatele sunt rezumate în Tabelul 4.10.

În ansamblu, modelele Random Forest, Modelul Ensemble, Arborii de decizie și KNN au obținut cele mai mari precizii în toate configurațiile, cu valori apropiate de 99%, chiar și la intervale de timp mai mari.

Figura 4.24 prezintă un grafic 3D al 4000 de nave autentice și falsificate (în proporții egale), bazat pe trei caracteristici calculate selectate. Așa cum se poate observa, navele simulate nu au prezentat variații în intervalele de raportare AIS și în erorile de distanță. Totuși, au fost observate variații limitate în erorile de direcție, deoarece multe dintre navele simulate au fost programate să afișeze schimbări multiple, bruște și abrupte ale direcției.



*Figura 4.12 Plot-uri 3D pentru parametrii reali și cei falsificați*

#### 4.4.4 Concluzii asupra metodei

Sistemul AIS este esențial pentru siguranța maritimă, permițând monitorizarea navelor și evitarea coliziunilor. Cu toate acestea, vulnerabilitățile sistemului, inclusiv susceptibilitatea la falsificare și manipulare, evidențiază necesitatea unor măsuri robuste de detecție. Traseele AIS falsificate prezintă riscuri semnificative, putând duce la interpretări greșite ale activităților navelor și compromiterea siguranței navigației.

Până la adoptarea la nivel global a unei versiuni mai sigure a sistemului AIS, pot fi utilizate diverse modele statistice și de învățare automată pentru a detecta situațiile în care sunt transmise prin sistem trasee false ale navelor. Studiul de față demonstrează eficiența utilizării metodelor stochastice și a modelelor ML pentru a distinge între traseele autentice și cele generate de computer.

# Capitolul 5

## Modele AI pentru aplicații de supraveghere maritimă

În subcapitolele următoare sunt detaliate trei noi metodologii de clasificare a tipului de navă, în funcție de parametrii cinematici ai acesteia, a unei aplicații de predicție a performanței de descoperire pentru senzorii AIS și a unui model îmbunătățit de predicție a traiectoriilor AIS falsificate cu zgomot.

### 5.2 Metodă de identificare a claselor de nave specializate

În prezentul studiu sunt propuse și analizate mai multe modele AI pentru clasificarea tipurilor de nave, pe baza analizei traiectoriei lor. Aceste abordări sunt inspirate din diverse tehnici de verificare a semnăturii scrise de mână (*în lb. engleză*: Handwritten Signature Verification - HSV).

#### 5.2.1 Abordări similare

Afflisio și colab. prezintă în lucrarea un proces stocastic Ornstein–Uhlenbeck care modelează viteza navelor cu un parametru mediu pe termen lung. Aceasta a fost realizată pentru a determina dacă perioada de indisponibilitate a AIS a fost cauzată de lipsa comunicațiilor sau de oprirea deliberată a sistemului AIS [13]. Mazzarella și colab. prezintă o abordare nouă care implică captarea indicilor de putere a semnalului primit de la stațiile de bază AIS și clasificarea activităților navelor folosind două abordări: una bazată pe mașina de suport vectorial cu o singură clasă, iar cealaltă bazată pe distribuția geospațială a puterii semnalului primit [14]. Lane și colab., și Singh și colab. prezintă, de asemenea, două metode similare [5] [15].

#### 5.2.2 Verificarea semnăturilor scrise de mână

Procesul de validare a identității unei persoane pe baza semnăturii sale scrise este cunoscut sub numele de Verificarea Semnăturii Scrise de Mână. Semnăturile scrise de mână reprezintă în mod tipic acele caracteristici biometrice complexe rezultate dintr-o secvență de acțiuni predefinite efectuate de sistemele motorii de scriere ale unui

semnatar. Traseul de deplasare al unei nave maritime poate fi reprezentat ca o succesiune temporală de coordonate geografice, similar cu modul în care semnăturile scrise de mână pot fi reprezentate ca o secvență de trăsături (Figura 5.5).



**Figura 5.1** Semnătură scrisă de mână (stânga), Navă de Căutare și Salvare (centru) și Navă de Aplicare a Legii (dreapta)

Metodele de verificare offline a semnăturii constau în general în patru etape principale: colectarea imaginilor, pre-procesarea, extragerea caracteristicilor și verificarea lor. O schemă generală a acestor sisteme este prezentată în Figura 5.6.



**Figura 5.2** Etapele generale în verificarea HSV offline

## 5.2.3 Metodologia cercetării

### A. Colectarea datelor

Prima etapă a acestui studiu a implicat colectarea datelor AIS din regiunea Mării Negre (ZEE România). Aceste date au fost colectate pe o perioadă de 477 de zile de la mai multe transponder-e AIS și diverse platforme web publice (i.e., Marine Traffic, Fleet Mon, Vessel Finder, Open AIS, AIS Hub). După decodarea propozițiilor NMEA-0183, au fost extrase codurile MMSI unice pentru toate navele care au tranzitat regiunea. În plus, au fost extrase și pozițiile geodezice ale navelor, vitezele SOG și drumurile COG. Următorul pas a implicat extragerea atributelor de clasă și subclasă ale navelor folosind tehnici de web scrapping.


### B. Pre-procesarea datelor

Viteza și traiectoriile navelor au fost codificate în pixelii cu trei canale, unde canalul roșu reprezenta valoarea standardizată a vitezei navei, iar canalele verde și albastru reprezentau valorile cosinus și sinus ale traiectoriei navei.



### C. Extragerea trăsăturilor


În cea de-a treia etapă, caracteristicile locale au fost extrase din imaginile rezultate utilizând o fereastră glisantă de 50x50 pixeli (Figura 5.8).



*Figura 5.3 Abordarea cu ferestre glisante pentru extragerea caracteristicilor locale*

### D. Implementarea clasificatoarelor

În cadrul acestui studiu, mai multe modele, precum KNN, SVM și rețele CNN (Figura 5.11), au fost antrenate pentru a clasifica navele pe baza caracteristicilor locale extrase.



*Figura 5.4 Implementare model HSV-CNN*

### 5.2.4 Rezultate

În timpul etapei de antrenare a celui de-al treilea set de date, unele clase generale au fost combinate. De exemplu, navele „Cargo Hazard A”, „Cargo Hazard B” și „Cargo Hazard C” au fost unite într-o singură clasă "Cargo".

Dintre cele patru modele antrenate, algoritmul KNN a prezentat cea mai bună performanță și s-a dovedit a fi cel mai eficient din punct de vedere computațional. Descoperirile experimentale au relevat faptul că KNN a obținut cea mai mare acuratețe generală în comparație cu celelalte clasificatoare. Pentru clasificarea celor 12 clase principale de nave, acesta a obținut o acuratețe de 75% și a înregistrat cea mai mică rată FNR pentru navele specializate și cea mai mică rată FPR pentru navele descrise ca "nespecializate".

### **5.2.5 Concluzii asupra metodei**

Această abordare are potențialul de a îmbunătăți supravegherea maritimă și de a detecta activități specializate cu care metodele convenționale întâmpină dificultăți. Principala avantaj al acestei metodologii propuse este că a înregistrat rezultate promițătoare în identificarea navelor ne-cooperative implicate în activități complexe precum pescuitul, dragarea, căutarea și salvarea pe mare, sau chiar operațiunile de aplicare a legii.

## **5.3 Metodă de predicție a limitelor de descoperire pentru senzorii de supraveghere maritimă**

Sistemele moderne de supraveghere maritimă integrează diverși senzori RF pentru a construi imagini RMP cât mai complete. Astfel de senzori includ sisteme AIS, radare costiere, radare cu propagare peste lini orizontului sau sisteme de analiză pasivă a semnalelor radio.

Aceste tehnologii prezintă limite intrinseci datorate condițiilor variabile de propagare. Acest studiu propune o abordare nouă bazată pe seturi de date meteorologice și date maritime pentru a prezice limitele de detecție pentru receptoarele AIS.

### **5.3.1 Abordări similare**

Kammerer și colab. propun o combinație de trei modele numerice. Aceste modele au fost utilizate în timp real pentru a coordona operațiuni zilnice de emisie și pentru a evalua impactul mediului asupra propagării RF. Astfel, aceștia au simulat și au prognozat parametrii atmosferici cheie. Acest lucru a permis calculul refractivității modificate, care a servit ca intrare principală pentru modelele de propagare RF [16].

### **5.3.2 Metodologia cercetării**


#### **A. Colectarea datelor**

Prima etapă a acestui studiu a implicat colectarea de date meteorologice și hidrologice în regiunea Mării Negre, provenite de la Institutul Național de Geologie Marină și Geoecologie al României (GeoEcoMar). Seturile de date au fost obținute pe parcursul a două perioade, totalizând un număr de 365 de zile.

#### **B. Extragerea limitelor de detecție pentru senzorul AIS**

Următoarea etapă a studiului a presupus extragerea datele istorice specifice traiectoriilor navale, de la multiple transponder-e AIS poziționate de-a lungul litoralului românesc.

După trasarea limitelor orare de descoperire pentru toate granițele inelelor de detectare (Figura 5.14), s-a observat faptul că sursele AIS au prezentat atât fluctuații zilnice cât și lunare.




*Figura 5.5 Zonele de descoperire ale AIS*

### C. Implementarea modelelor de deep-learning

În acest studiu, au fost antrenate mai multe modele capabile să prognozeze limitele de descoperire AIS pe 24 de ore.

Mai exact, modelele de rețele neuronale MLP și LSTM (Figura 5.18) au fost folosite în șase configurații, definite prin variații ale stratul de intrare. În toate configurațiile, datele au fost partiționate pe baza a două perioade de înregistrare, rezultând într-un raport de împărțire antrenament-test de 65-35.



*Figura 5.6 Implementare rețea recurentă pentru predicția limitei RF*

### 5.3.3 Rezultate

În cadrul acestei cercetări au fost dezvoltate și evaluate mai multe configurații de rețele neuronale adânci pentru a prezice performanța AIS pentru 24 de ore. Au fost folosite pentru antrenament atât datele meteorologice, cât și cele istorice referitoare la razele de detecție AIS.

Dintre modelele antrenate, LSTM a obținut cel mai mare scor de acuratețe pe setul de date de testare. În contrast, modelele MLP au prezentat semne de overfitting, așa cum este evidențiat de scorurile scăzute pe seturile de date de testare, față de scorurile lor ridicate pe seturile de antrenament.

### 5.3.4 Concluzii

Această cercetare a marcat un avans în domeniul supravegherii maritime. Abordarea prezentată a utilizat limite istorice de detecție AIS și date meteorologice pentru a prezice limitele viitoare de detecție AIS. Capacitatea de a anticipa modificările în limitele de descoperire AIS pot îmbunătăți semnificativ evaluarea situațiilor precum spoofing-ul AIS, bruiajul și activitățile AIS ascunse.

## 5.4 Metodă de detecție în timp real a navelor falsificate cu zgomot

În acest capitol, este propusă o metodologie avansată care permite clasificarea în timp real a navelor maritime, prin utilizarea unor arhitecturi moderne de rețele neuronale, printre care se numără rețelele convoluționale unidimensionale (1D CNN), rețelele LSTM, GRU și MLP. Aceste soluții permit analiza imediată a traiectoriilor navelor, spre deosebire de metodele tradiționale care operează în etapa de post-procesare. De asemenea, au fost investigate efectele introducerii de zgomot în datele AIS generate sintetic, arătând că metodele convenționale întâmpină dificultăți în diferențierea acestora față de traiectoriile reale.

### 5.4.1 Abordări similare

O abordare promițătoare constă în verificarea conformității mesajelor AIS cu protocolul TDMA. Louart et al. propun o abordare în timp real, bazată pe un filtru Kalman pentru a urmări dinamica navei, comparând poziția și viteza raportate cu valorile estimate [17].

Metoda descrisă în Capitolul 4.4 se concentrează pe diferențierea traseelor AIS simulate de cele reale, prin analiza erorilor cinetice stochastice. Deși această metodă a avut performanțe ridicate, cercetările ulterioare, prezentate în capitolele următoare, s-au concentrat pe îmbunătățirea capabilităților sale. Prin urmare, capitolele următoare introduc o versiune îmbunătățită a algoritmului original, concepută pentru a menține o performanță ridicată de detecție chiar și în fața unor încercări de spoofing mai sofisticate, care includ zgomot artificial.

### 5.4.2 Metodologia cercetării

#### A. Analiza datelor

După etapa de preprocesare, similară cu metodologia descrisă în Capitolul 4.3.3, au fost selectate și analizate mai multe traiectorii de nave, în funcție atât de tipul acestora (e.g., pescadoare, cargo, remorchere), cât și de starea de navigație (e.g., ancorată, acostată, în derivă, în deplasare).

Ulterior, a fost realizată o evaluare statistică detaliată pentru a determina cele mai potrivite funcții de densitate a probabilității care să modeleze cu acuratețe distribuțiile

empirice ale acestor parametri. Datele înregistrate au fost comparate cu un set de distribuții teoretice.

## B. Generarea track-urilor falsificate și adăugarea zgomotului


După realizarea unei analize detaliate a traiectoriilor reale ale navelor, au fost generate programatic mai multe trasee simulate pentru a reproduce tipare tipice de navigație maritimă. Fiecare traiectorie falsificată a fost alcătuită dintr-un număr predefinit de puncte de trecere (*în lb. engleză: waypoints*), cu parametri asociați precum viteza și direcția, care să imite profiluri cinematice navale reale. Aceste trasee au fost concepute pentru a raporta continuu poziții în intervale de timp variind de la 3 minute până la perioade extinse de până la 24 de ore.

## C. Implementare algoritmi de învățare automată

După extragerea parametrilor secvențiali descriși în secțiunea A, fiecare traiectorie a fost transformată într-un semnal de tip serie temporală care reflectă comportamentul cinematic dinamic al navei.

După preprocesare, semnalele rezultate au fost utilizate pentru antrenarea și evaluarea mai multor modele de învățare automată, recunoscute pentru eficiența lor în procesarea seriilor temporale și a semnalelor. Arhitecturile implementate au fost următoarele: 1D-CNN, LSTM, GRU, MLP, KNN și SVM.

Rețele 1D CNN au fost utilizate pentru a învăța automat caracteristici spațiale locale de-a lungul axei temporale, folosind filtre de convoluție. Arhitectura specifică utilizată este ilustrată în Figura 5.19, prezentând structura pe straturi și fluxul activărilor.



**Figura 5.7 Implementare rețea 1D CNN**


## 5.4.3 Rezultate

### A. Aspecte generale

Figura 5.21 (stânga) ilustrează traiectoria unei nave reale aflate în deplasare, afectată în mod natural atât de erori de măsurare, cât și de erori de proces. Erorile de măsurare provin în principal din inexactitățile sistemelor GNSS, în timp ce erorile de proces


sunt cauzate de factori dinamici precum vântul, curenții marini, condițiile meteorologice și mici variații în manevrarea navei. Prin contrast, Figura 5.21 (centru) prezintă traiectoria unei nave simulate, generată prin modele matematice. Aceste traiectorii nu conțin variabilitatea stocastică specifică datelor reale AIS, ceea ce duce la profiluri de mișcare excesiv de line și previzibile în cazul estimării pozițiilor, vitezelor sau direcțiilor viitoare.

Pentru a remedia această limitare, Figura 5.21 (dreapta) prezintă o navă simulată căreia i s-a injectat zgomot Gaussian în datele de poziție, pentru a crea zgomotul observat în comportamentul navelor reale.




**Figura 5.8** Nave aflate în marș: reală, simulată și simulată cu zgomot

Figurile 5.22 și 5.23 ilustrează evoluția erorilor de predicție a latitudinii și a variațiilor direcției de deplasare între pozițiile succesive pentru traiectoriile navelor prezentate în Figura 5.21. În Figura 5.22 (stânga), traiectoria navei reale prezintă variații semnificative și persistente ale erorilor pe tot parcursul fazei de deplasare. Este de remarcat că, după aproximativ indexul 2000, magnitudinea acestor variații scade considerabil – ceea ce sugerează că nava a devenit staționară și a continuat să transmită poziția sa fără influențe dinamice.




**Figura 5.9** Erori de predicție ale latitudinilor viitoare: Navă reală, simulată și simulată cu zgomot



**Figura 5.10** Variații ale schimbărilor COG: Navă reală, simulată și simulată cu zgomot

Rezultatele, rezumate în Figura 5.25, arată că fiecare parametru se potrivește cel mai bine cu anumite distribuții — de exemplu, schimbarea vitezei urmează o distribuție WrapCauchy, variația direcției se conformează unei distribuții NormInvGauss, iar erorile de predicție ale latitudinii și longitudinii corespund distribuțiilor ExponNorm și Normal.



**Figura 5.11** Potrivirea distribuțiilor parametrice: erori de predicție latitudine, schimbări de viteză și schimbări ale timpilor de raportare

## B. Eficiența modelelor implementate

Cele mai bune performanțe generale de clasificare au fost obținute de modelele de Rețea 1D CNN și GRU, ambele depășind o acuratețe globală de 99%.

### 5.4.4 Concluzii asupra metodei

Prin valorificarea arhitecturilor de învățare profundă în timp real, precum rețelele 1D CNN și GRU, noua metodologie menține o acuratețe ridicată a detecției chiar și în fața datelor falsificate cu zgomot indus. Cu toate acestea, această linie de apărare trebuie să continue să evolueze.

# Capitolul 6

## Concluzii

În cadrul acestei teze, au fost investigate diverse aspecte ale automatizării supravegherii maritime, folosind inteligența artificială, pentru îmbunătățirea monitorizării și gestionării traficului naval. Prezenta cercetare propune o arhitectură conceptuală a unui sistem inteligent de supraveghere maritimă.

Un aspect crucial al cercetării a fost analiza dinamicii traficului naval din Marea Neagră, identificând oportunitatea realizării unui sistem inteligent pentru detectarea anomaliilor maritime în regiune. Totodată, sunt propuse șase noi metodologii de sesizare a anomaliilor traficului maritim.

### 6.1 Contribuții originale

Principalele contribuții ale acestei teze sunt date de realizarea unui model conceptual de sistem MDA și dezvoltarea a șase algoritmi noi de sesizare a anomaliilor maritime:

- **ALGORITM 1:** o metodă parametrică de reprezentare a distribuțiilor empirice pentru diverse tipuri de activități maritime;
- **ALGORITM 2:** o metodă de extragere a valorilor anormale din activitatea economică a navelor, utilizând date publice;
- **ALGORITM 3:** o soluție de descoperire a navelor falsificate prin analiza distribuțiilor parametrilor cinematici ai traiectoriilor;
- **ALGORITM 4:** un model de detectare a activităților maritime neidentificate folosind metode din recunoașterea semnăturii scrise de mână;
- **ALGORITM 5:** o metodă de predicție a factorilor de propagare pentru senzorii de supraveghere maritimă, pentru descoperirea navelor implicate în activități ascunse.
- **ALGORITM 6:** o metodă îmbunătățită de identificare în timp real a navelor falsificate cu zgomot.

Aceste contribuții oferă perspective valoroase pentru cercetătorii interesați de utilizarea inteligenței artificiale pentru îmbunătățirea conștientizării domeniului maritim și a siguranței transporturilor navale. Implementarea acestor soluții inovatoare poate reduce riscurile operaționale, poate îmbunătăți eficiența navigației și are potențialul de a contribui la o utilizare durabilă a resurselor marine.



## 6.2 Lista lucrărilor originale

### A. Lucrări în jurnale de conferințe

- [1] **A. Pohontu**, L. Nedelcu and C. Vertan, "Fitting Empirical Distributions for Vessels Behavioural Analysis and Maritime Anomaly Detection," 2023 17th International Conference on Engineering of Modern Electric Systems (EMES), Oradea, Romania, 2023, pp. 1-6, doi: 10.1109/EMES58375.2023.10171682.
- [2] **A. Pohontu**, R. Gheorghe and C. Vertan, "Outlier Detection Approach for Discovering Anomalous Maritime Profiles," 2023 15th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Bucharest, Romania, 2023, pp. 1-6, doi: 10.1109/ECAI58194.2023.10193981.
- [3] **A. Pohontu**, A. D. Deliu and C. Vertan, "Ship Type Classification: a Handwriting Signature Verification Approach for Maritime Trajectories", 2023 8th International Symposium on Electrical and Electronics Engineering (ISEEE), Galati, Romania, 2023, pp. 110-115, doi: 10.1109/ISEEE58596.2023.10310540.
- [4] **A. Pohontu**, A. T. Nedelcu, N.S. Popa and C. Vertan, "Predicting Detection Range of Maritime Sensors: a Meteorological Data-Driven Approach", 2024 16th International Conference on Electronics, Computers and Artificial Intelligence (ECAI), Iasi, Romania, 2024, pp. 1-6, doi: 10.1109/ECAI61503.2024.10607396.

### B. Lucrări în reviste

- [5] **Alexandru POHONTU**, Constantin VERTAN, Iancu CIOCIOI, Ciprian POPA, "Detection of spoofed AIS: Simulated tracks vs. real maritime data", Romanian Journal of InformationTechnology and Automatic Control, ISSN 1220-1758, vol. 35(1), pp. 37-50, 2025.<https://doi.org/10.33436/v35i1y202503>
- [6] **Alexandru POHONTU**, Constantin VERTAN, Vasile ERMOLAI, Andreea CHELARIU, "Real-time detection of spoofed AIS: enhancing maritime surveillance against induced noise", Studies in Informatics and Control, ISSN 1220-1766, vol. 34(3), pp. 51-61, 2025.<https://doi.org/10.24846/v34i3y202505>

### C. Capitole de cărți

- [7] **Pohontu, A.**, Ermolai, V. (2024).Artificial Intelligence in Maritime Domain Awareness Applications: Trends and Pro-spects. In: Ivascu, L., Cioca, LI., Doina, B., Filip, F.G. (eds) Digital Transformation.Intelligent Systems Reference Library, vol 257. Springer, Cham.[https://doi.org/10.1007/978-3-031-63337-9\\_10](https://doi.org/10.1007/978-3-031-63337-9_10)

# Bibliografie selectivă

- [1] S. Abghari și S. Kazemi, „Open Data for Anomaly Detection in Maritime Surveillance,” *School of Computing Blekinge Institute of Technology*, vol. Master’s Thesis Computer Science, p. 10, 2012.
- [2] M. Riveiro, G. Pallotta și M. Vespe, „Maritime Anomaly Detection: A Review,” *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2018.
- [3] K. Wolsing, L. Roepert, J. Bauer și K. Wehrle, „Anomaly Detection in Maritime AIS Tracks: A Review of Recent Approaches,” *Journal of Marine Science and Engineering*, vol. 10, p. 112, 2022.
- [4] E. Martineau, J. Roy și D. Valcartier, „Maritime Anomaly Detection: Domain Introduction and Review of Selected Literature,” *Defence R&D Canada – Valcartier Technical Memorandum*, 2011.
- [5] R. O. Lane și S. Hayward, „Maritime anomaly detection and threat assessment,” *International Conference on Information Fusion, Edinburgh*, vol. 13, pp. 1-8, 2010.
- [6] E. Tu, G. Zhang, L. Rachmawati, E. Rajabally și G. B. Huang, „Exploiting AIS Data for Intelligent Maritime Navigation: A Comprehensive Survey,” *IEEE Transactions on Intelligent Transportation Systems*, 2016.
- [7] J. K. Kim, „Semi-Continuous Spatial Statistical Analysis Using AIS Data for Vessel Traffic Flow Characteristics in Fairway,” *Marine Science and Engineering*, 2021.
- [8] S. Woo-Ju, L. Hyeong-Tak și C. Ik-Soon, „A Study on the Estimation of Optimal Traffic Distribution near Breakwater in Busan Port,” *Journal of International Maritime Safety, Environmental Affairs, and Shipping*, vol. 4, nr. 4, p. 151–161, 2020.
- [9] H. Rong, A. P. Teixeira și G. C. Soares, „Data mining approach to shipping route characterization and anomaly detection based on AIS data,” *Ocean Engineering*, 2020.
- [10] Y. Dodge, *The Concise Encyclopedia*, Neuchâtel: Springer, 2008.
- [11] Y. Zhao, Z. Nasrullah și Z. Li, „A Python Toolbox for Scalable Outlier Detection,” *Journal of Machine Learning Research*, vol. 20, vol. 20, pp. 1-7, 2019.
- [12] F. Katsilieris, P. Braca și S. Coraluppi, „Detection of malicious AIS position spoofing by exploiting radar information,” *16th International Conference on Information Fusion*, p. 1196–1203, 2013.
- [13] E. d’Afflisio, P. Braca, L. M. Millefiori și P. Willett, „Detecting Anomalous Deviations From Standard Maritime Routes Using the Ornstein–Uhlenbeck Process,” *IEEE Transactions On Signal Processing*, vol. 66, nr. 24, 2018.
- [14] F. Mazzarella, M. Vespe, A. Alessandrini, D. Tarchi, G. Aulicino și A. Vollero, „A novel anomaly detection approach to identify intentional AIS on-off switching,” *Expert Systems With Applications*, vol. 78, p. 110–123, 2017.
- [15] S. K. Singh și F. Heymann, „Machine Learning-Assisted Anomaly Detection in Maritime Navigation Using AIS Data,” *IEEE/ION Position, Location and Navigation Symposium (PLANS)*, 2020.
- [16] A. J. Kammerer, T. Haack, R. Norris, H. Hansen, A. Kulesa și A. Barrios, „Predicting RF Propagation with Numerical Models,” *2018 IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting*, pp. 1927–1928, 2018.
- [17] M. Louart, J. J. Szkolnik, A. O. Boudraa, J. C. Le Lann și F. Le Roy, „Detection of AIS messages falsifications and spoofing by checking messages compliance with TDMA protocol,” *Digital Signal Processing*, vol. 136, 2023.