



Universitatea
Ștefan cel Mare
Suceava

Contribuții în domeniul monitorizării spectrului de radiofrecvență pentru rețelele sistemelor IoT

Rezumatul Tezei

Conducător de doctorat:

Prof. univ. dr. ing. Valentin POPA

Doctorand:

ing. Partemie-Marian MUTESCU

Cuprins

I. Introducere	1
II. Fundamente și tehnici de monitorizare a spectrului radio.....	3
III. Îmbunătățirea tehnicilor clasice de monitorizare a spectrului radio prin algoritmi AI	6
IV. Monitorizarea spectrului radio în rețele IoT utilizând algoritmi AI aplicați pe serii temporale IQ.....	8
V. Monitorizarea spectrului radio în rețele IoT utilizând algoritmi AI aplicați pe reprezentări timp-frecvență	11
VI. Proiectarea, dezvoltarea și implementarea unui model AI de monitorizare a spectrului radio cu capabilități extinse de generalizare. Detecția zgomotului.....	15
VII. Concluzii și contribuții	17
Lucrări publicate	24
Bibliografie selectată	26

I. Introducere

Dezvoltarea rețelelor Internet of Things (IoT) a schimbat modul în care sistemele informatice colectează și transmit date. Aplicațiile de tip oraș inteligent [1], [2], automatizarea proceselor industriale și paradigma Industrie 4.0 [3] se bazează pe infrastructuri extinse de dispozitive radio conectate care monitorizează și controlează procese și infrastructuri. Aceste sisteme utilizează rețele wireless de senzori distribuiți care transmit informațiile către entități centrale de procesare prin protocoale de comunicații radio. Scalarea acestor rețele presupune interconectarea unui număr mare de dispozitive IoT distribuite pe arii geografice extinse, în condițiile unor constrângeri energetice ridicate, deoarece majoritatea nodurilor sunt alimentate din baterii și trebuie să funcționeze perioade îndelungate.

În arhitecturile IoT, interfața radio reprezintă componenta dominantă din punct de vedere al consumului energetic, iar performanța acesteia depinde de utilizarea eficientă a resurselor spectrului radio. Conectivitatea este asigurată în principal prin protocoale LPWAN precum: LoRa [4], Sigfox [5] sau Zigbee [6], caracterizate prin consum energetic redus și acoperire extinsă [7]. În paralel, rețelele celulare au integrat servicii dedicate IoT prin NB-IoT [8] în cadrul LTE și prin scenarii massive Machine Type Communications (mMTC) în 5G New Radio [8], standardul 5G definind densități de până la 1 milion de dispozitive/km² [9].

Majoritatea tehnologiilor IoT operează în benzi nelicențiate precum 868 MHz SRD, 915 MHz ISM și 2,4 GHz ISM, care permit implementarea rețelelor fără costuri de licențiere, dar sunt caracterizate de lățime de bandă limitată, constrângeri de tip factor de umplere [10] și absența unui mecanism centralizat de coordonare a accesului la canal. În aceste condiții, coexistența mai multor tehnologii radio în aceleași benzi conduce la interferențe și la variații ale gradului de ocupare a spectrului radio. Literatura de specialitate evidențiază impactul acestor limitări asupra performanței comunicațiilor IoT, fiind raportate valori ale Packet Error Rate de până la 80% pentru Sigfox [11] sau 68% pentru protocoalele bazate pe IEEE 802.15.4, precum Zigbee [12]. Pentru a reduce complexitatea și consumul energetic, anumite tehnologii LPWAN utilizează mecanisme simple de acces la canal, precum ALOHA [13], în care dispozitivele transmit fără verificarea stării canalului. În scenarii dense, caracterizate prin interferențe și propagare pe multiple căi, probabilitatea coliziunilor crește, iar efectul de captură [14] poate conduce la pierderea pachetelor și la necesitatea retransmisiilor. Retransmisiile determină consum energetic suplimentar și contribuie la congestionarea spectrului radio.

Chiar și în rețelele celulare de generație nouă, accesul inițial la canal se realizează prin proceduri de acces aleatoriu bazate pe un număr finit de secvențe de preambul [15]. În scenarii mMTC, caracterizate prin densități ridicate de dispozitive, probabilitatea coliziunilor crește, ceea ce conduce la întâzieri suplimentare în procesul de acces.

În contextul creșterii exponențiale a numărului de dispozitive IoT [16], spectrul radio devine o resursă limitată, caracterizată printr-un grad ridicat de utilizare și o distribuție neuniformă în timp și frecvență. Utilizarea eficientă a spectrului radio devine astfel o condiție principală în scalarea sustenabilă a rețelelor IoT.

Monitorizarea spectrului radio reprezintă un mecanism fundamental pentru evaluarea modului de utilizare a resurselor spectrale. În sistemele tradiționale sunt utilizate mecanisme precum Carrier Sense Multiple Access [13] sau detecția pe baza nivelului de energie (ED) [17], care permit estimarea stării canalului, dar oferă informații limitate privind natura semnalelor

detectate. În arhitecturile IoT moderne, caracterizate prin coexistența mai multor tehnologii radio, monitorizarea spectrului trebuie extinsă de la simpla identificare a ocupării canalului către caracterizarea și clasificarea transmisiilor radio și generarea unor metrice avansate privind utilizarea spectrului radio.

În acest context, metodele clasice de monitorizare sunt completate de abordări bazate pe inteligență artificială (AI), capabile să extragă caracteristici relevante din semnalele radio și să modeleze relații complexe între datele de intrare și cele de ieșire. Lucrarea de față se înscrie în acest context, având ca obiectiv dezvoltarea și evaluarea unor metode moderne de monitorizare și analiză a spectrului radio adaptate sistemelor IoT, bazate atât pe tehnici clasice, cât și pe algoritmi AI, pentru detecția și clasificarea transmisiilor radio și pentru obținerea de metrice avansate de analiză a spectrului radio precum determinarea gradului de ocupare a spectrului sau gradul de ocupare a canalelor de comunicație în vederea optimizării utilizării resurselor radio.

II. Fundamente și tehnici de monitorizare a spectrului radio

Monitorizarea spectrului radio a fost utilizată inițial în diferite sisteme de comunicații prin mecanisme precum Clear Channel Assessment [18] și Listen Before Talk [19], integrate în protocoale precum Wi-Fi [20] și Zigbee [21]. În contextul dezvoltării aplicațiilor de tip oraș inteligent [2] și Industrie 4.0 [3], precum și al creșterii accelerate a numărului de dispozitive IoT interconectate [16], monitorizarea spectrului radio a devenit o necesitate a sistemelor moderne de comunicații. Rolul acesteia este de a permite coexistența mai multor tehnologii radio prin optimizarea utilizării resurselor de spectru radio și menținerea unui nivel ridicat al calității serviciilor prin furnizarea de metrici privind starea spectrului radio.

Una dintre cele mai utilizate tehnici din literatura de specialitate este ED [17], în care energia din banda analizată este comparată cu un prag prestabilit pentru a determina dacă aceasta este ocupată sau liberă. Metoda are avantajul simplității și al generalizării, deoarece nu necesită informații despre modulația utilizată sau lățimea de bandă a semnalului analizat. Totuși, performanța sa este afectată de incertitudinea nivelului de zgomot [22], care influențează probabilitatea de detecție și de alarmă falsă. Variante îmbunătățite, precum tehnici cu prag dublu [23], detecția pe baza a trei evenimente succesive [24] sau ferestre glisante [25], reduc parțial aceste limitări, însă necesită informații suplimentare. În plus, ED furnizează doar o decizie binară privind ocuparea întregului canal de comunicație analizat, insuficientă pentru cerințele sistemelor de comunicație moderne.

În ultimii ani, monitorizarea spectrului radio a evoluat către abordări bazate pe AI, care permit modelarea relațiilor complexe dintre parametrii semnalelor radio și oferă capabilități extinse de detecție și clasificare. Algoritmii AI pot utiliza diferite forme de reprezentare a semnalelor radio, precum coordonate IQ, reprezentări în domeniul frecvență sau spectrograme timp-frecvență. În literatura de specialitate, algoritmii AI au fost utilizați pentru detectarea transmisiilor radio și clasificarea modulațiilor. De exemplu, Bassel et al. [26] au utilizat algoritmul DBSCAN pentru gruparea transmisiilor detectate în medii radio zgomotoase. Un rol important în dezvoltarea domeniului l-au avut lucrările lui Tim O'Shea et al. [27], [28], care au introdus seturi de date dedicate clasificării modulațiilor radio [29]. Utilizând aceste seturi de date, au fost evaluate performanțele unor algoritmi precum CNN [30] sau rețele neuronale reziduale [31], obținând acuratețe ridicată pentru valori ale SNR peste 0 dB, dar evidențiind degradări semnificative ale performanței în condiții de zgomot sau propagare pe multiple căi.

Alte abordări au utilizat rețele neuronale de tip LSTM pentru clasificarea modulațiilor radio [32], precum și reprezentări grafice ale semnalelor radio, cum ar fi spectrograme sau diagrame de constelație, utilizate ca date de intrare pentru CNN [33], [34], [35]. Utilizarea rețelelor neuronale de detecție a obiectelor [36] a extins capabilitățile monitorizării spectrului radio. Acestea permit detectarea, clasificarea și localizarea simultană a mai multor transmisiilor radio în interiorul aceleiași benzi de frecvență analizate. Literatura de specialitate a demonstrat aplicabilitatea acestor metode în diferite scenarii, precum detectarea modulațiilor radio [37], identificarea transmisiilor în benzi extinse [38], [39], detectarea semnalelor radio provenite de la drone [40] sau identificarea modulațiilor analogice și digitale [41].

Cu toate acestea, majoritatea soluțiilor existente au fost dezvoltate în contexte care nu reflectă pe deplin specificul comunicațiilor IoT. Tehnologiile IoT funcționează predominant în benzi nelicențiate [42], sunt caracterizate de transmisii de bandă îngustă, intermitente și

asincrone și de puteri reduse de emisie, ceea ce conduce frecvent la valori scăzute ale SNR la recepție. În aceste condiții, atât tehnicile clasice, cât și multe dintre abordările AI prezintă limitări semnificative.

În ultimii ani, piața dispozitivelor IoT a înregistrat o creștere semnificativă, fiind estimate aproximativ 2 miliarde de noi dispozitive conectate anual, iar numărul total de dispozitive IoT conectate la internet este estimat la aproximativ 29,42 miliarde în anul 2030 [16]. Întrucât majoritatea acestor dispozitive utilizează protocoale de comunicație radio, implementarea și scalarea rețelelor IoT necesită resurse de spectru radio. După cum se poate observa în figura 2.1, deși spectrul radio utilizabil este extins, benzile utilizate de sistemele de comunicație IoT reprezintă doar o mică parte a acestuia și sunt adesea partajate cu alte tehnologii radio.




Figura 2.1. Poziționarea benzilor IoT, 4G și 5G în spectrul radio și distribuția resurselor spectrale între tehnologiile IoT

Majoritatea tehnologiilor IoT funcționează în benzi nelicențiate precum 868 MHz, 915 MHz sau 2,4 GHz, caracterizate prin lățime de bandă redusă și partajare între multiple tehnologii de comunicație. În aceste condiții, un număr foarte mare de dispozitive trebuie să opereze într-un spațiu spectral restrâns, ceea ce conduce la interferențe și la o eficiență scăzută a utilizării spectrului radio.

Literatura de specialitate evidențiază impactul acestor limitări asupra performanței comunicațiilor IoT. De exemplu, pentru protocolul Sigfox au fost raportate valori PER de până la 80% pentru aproximativ 1400 de noduri IoT active [11]. În cazul LoRaWAN, s-a demonstrat că un număr maxim de aproximativ 8000 de noduri pot comunica simultan pe cele opt canale uplink disponibile, respectând limitarea de ciclu de funcționare de 1% [43], [44], [45]. În mod similar, protocoalele bazate pe IEEE 802.15.4, precum Zigbee, pot ajunge la valori PER de până la 68% în banda ISM de 2,4 GHz [46]. Chiar și în rețelele 5G, accesul dispozitivelor IoT devine problematic în scenarii caracterizate prin densități ridicate de terminale conectate [15].

Creșterea numărului de dispozitive IoT, limitarea resurselor spectrale și utilizarea benzilor nelicențiate conduc la interferențe frecvente, congestionarea canalelor radio și scăderea calității serviciilor. În aceste condiții, spectrul radio devine un factor limitativ pentru dezvoltarea și scalarea rețelelor IoT.

Pentru a aborda aceste provocări, sunt necesare mecanisme capabile să detecteze și să clasifice tehnologiile de comunicație prezente în spectrul radio și să genereze metrice avansate privind utilizarea acestuia, precum localizarea în timp și frecvență a transmisiilor radio, estimarea lății de bandă și determinarea gradului de ocupare a canalelor radio. Aceste informații pot sta la baza dezvoltării mecanismelor de evitare a interferențelor și de alocare dinamică a resurselor de spectru radio.

III. Îmbunătățirea tehnicilor clasice de monitorizare a spectrului radio prin algoritmi AI

Acest capitol analizează limitările tehnicii clasice de monitorizare a spectrului radio bazată pe tehnica ED și propune o metodă de îmbunătățire a acesteia prin integrarea algoritmilor AI. În metoda ED, energia semnalului recepționat este comparată cu un prag de detecție pentru a decide dacă banda analizată este ocupată sau liberă. Performanța acestei tehnici depinde în mod direct de estimarea corectă a varianței zgomotului, pe baza căruia este determinată valoarea de prag, iar în medii radio dinamice, specifice comunicațiilor IoT, variațiile zgomotului și valorile reduse ale SNR conduc frecvent la degradarea performanței de detecție.

Pentru a depăși această limitare, este propusă o metodă hibridă care combină tehnica ED cu o rețea neuronală de tip Feed Forward (FFN) utilizată pentru estimarea componentei de zgomot din semnalul recepționat. Sistemul, prezentat în figura 3.1 utilizează două ramuri de procesare: una pentru detecția prin ED și una pentru estimarea zgomotului prin modelul AI. Pe baza estimării realizate de rețea, varianța zgomotului este recalculată, iar pragul de detecție este actualizat adaptiv, în funcție de condițiile curente ale canalului radio.




Figura 3.1. Schema bloc funcțională a tehnicii ED cu estimator al varianței zgomotului bazat pe algoritmi AI

Pentru antrenarea modelului a fost generat un set de date sintetic compus din semnale modulate afectate de zgomot Gaussian, corespunzătoare unor valori SNR între -20 dB și 10 dB, incluzând diferite scheme de modulație. Au fost evaluate mai multe configurații ale rețelei FFN, rezultatele arătând că arhitectura FFN cu 256 de neuroni oferă un compromis între performanță și complexitate.




Figura 3.2. Compararea tehnicii ED propuse cu ED ideal (SNR cunoscut)

Rezultatele experimentale prezentate în figura 3.2 arată că metoda propusă obține performanțe comparabile cu scenariul ideal în care SNR este cunoscut, iar pentru valori SNR scăzute prezintă chiar îmbunătățiri ale probabilității de detecție. Totuși, rezultatele confirmă existența limitei fundamentale cunoscute ca „SNR wall” [47], care determină scăderea performanței pentru valori foarte reduse ale SNR.

Rezultatele demonstrează că integrarea algoritmilor AI poate îmbunătăți tehnica ED în medii radio dinamice, însă metoda rămâne limitată de natura sa binară (canal ocupat/liber). Din acest motiv, capitolele următoare explorează metode bazate integral pe algoritmi AI, capabile să ofere o analiză mai detaliată a spectrului radio.

Contribuțiile asociate acestui capitol au fost diseminate în cadrul lucrării:

- **P. -M. Mutescu**, V. Popa and A. Lavric, "Artificial Intelligence Noise Estimation for Adaptive Energy Detection in Dynamic Radio Environments," prezentată în cadrul conferinței *2025 IEEE PES Conference on Innovative Smart Grid Technologies - Middle East (ISGT Middle East)*, Dubai, United Arab Emirates; anul 2025.

IV. Monitorizarea spectrului radio în rețele IoT utilizând algoritmi AI aplicați pe serii temporale IQ

Acest capitol prezintă metode de monitorizare a spectrului radio bazate exclusiv pe algoritmi AI aplicați direct pe serii temporale IQ, cu scopul de a depăși limitările tehnicilor clasice. Spre deosebire de metodele convenționale, care oferă în principal o decizie binară asupra ocupării canalului, abordările propuse urmăresc detecția și clasificarea modulațiilor radio specifice comunicațiilor IoT, precum și extinderea analizei către scenarii cu transmisii multiple simultane.

Într-o etapă preliminară au fost evaluate tehnici clasice de învățare automată (ML) pentru clasificarea modulațiilor radio IoT, utilizând setul de date RadioML.2018 și diferite forme de reprezentare a semnalelor radio: IQ, amplitudine/fază și FFT. Evaluarea acestora a arătat performanțe limitate, cea mai bună acuratețe de testare fiind de 58,4% pentru reprezentarea FFT, ceea ce a evidențiat limitele modelelor ML clasice în separarea unor clase de semnal puternic suprapuse. În plus, identificarea unor erori în setul de date RadioML.2018 a motivat dezvoltarea unui set de date propriu și trecerea către modele de tip Deep Learning (DL).




Figura 4.1. Metodologia de implementare a tehnicilor de monitorizare a spectrului radio bazate pe algoritmi AI aplicați pe serii temporale IQ

Metodologia propusă pentru abordarea DL, prezentată în figura 4.1, este structurată în două etape: dezvoltarea și evaluarea empirică a modelului AI și evaluare în regim de inferență. În prima etapă a fost generat un set de date sintetic destinat comunicațiilor IoT, construit prin utilizarea mai multor scheme de modulație relevante domeniului IoT: QPSK, 16QAM, 64QAM, DBPSK, GFSK și LoRa, pentru care fiecare factor de împrăștiere LoRa a fost tratat ca o clasă distinctă. A fost introdusă și o clasă suplimentară de tip „zgomot”, corespunzătoare absenței unei transmisii radio. Pentru fiecare clasă au fost generate instanțe de semnal cu lungimea de 4096 eșantioane IQ, la 1 MS/s, iar pentru creșterea capacității de generalizare semnalele au fost afectate de zgomot AWGN, atenuare de tip Rician, efect Doppler și desincronizări între emițător și receptor. Setul de date rezultat a fost publicat pe GitHub [48].

Pentru detecția și clasificarea modulațiilor radio am proiectat un algoritm AI de tip CNN 1D, capabil să opereze direct pe serii temporale IQ. Arhitectura este alcătuită din mai

multe blocuri convoluționale secvențiale, urmate de straturi de normalizare, activare, max-pooling și dropout, iar etapa finală de clasificare utilizează global average pooling, un strat fully connected și un strat softmax. Modelul a fost antrenat timp de 100 de epoci utilizând optimizatorul SGDM. În procesul de antrenare acuratețea obținută a fost de 98,4%.

Evaluarea empirică pe setul de test a confirmat performanța ridicată a modelului, cu o acuratețe globală de 98%. Cele mai frecvente erori de clasificare au apărut între 16QAM și 64QAM, datorită similarității dintre constelațiile acestora, în timp ce clase precum GFSK și factorii de împrăștiere LoRa au fost clasificate cu acuratețe de peste 99%. Pentru validarea în mediu real, modelul a fost testat în două scenarii experimentale. În primul scenariu, utilizând două dispozitive SDR într-un spațiu interior, algoritmul a obținut o acuratețe de 95,6%. În al doilea scenariu, bazat pe transceivere reale LoRa și Sigfox amplasate la aproximativ 50 m distanță, performanța medie de inferență a fost de 78,8%, cu rezultate foarte bune pentru LoRa și performanță mai redusă pentru Sigfox, din cauza lății foarte mici de bandă și a dificultăților de sincronizare. Aceste rezultate sunt importante deoarece modelul a fost antrenat exclusiv pe date sintetice, fără capturi OTA în etapa de antrenare.

O limitare a modelului CNN aplicat direct pe serii IQ este faptul că acesta poate clasifica corect doar o singură transmisie prezentă în banda analizată. Pentru depășirea acestei limite, capitolul propune o arhitectură hibridă care combină tehnici clasice de procesare a semnalelor cu algoritmi AI, având ca studiu de caz comunicațiile LoRa. Scopul acestei arhitecturi este detectarea, separarea și clasificarea mai multor transmisii radio simultane, precum și extragerea unor metrici de analiză a canalului de comunicație.




Figura 4.2. Schema generală a arhitecturii hibride de monitorizare a spectrului radio

Arhitectura hibridă prezentată în figura 4.2 pornește de la semnalul recepționat de un SDR și utilizează un algoritm de detecție și clusterizare a transmisiilor radio (TDCA). Acesta transformă semnalul în domeniul frecvență prin FFT, aplică o etapă de filtrare și un prag inspirat din tehnica ED pentru identificarea regiunilor spectrale active, apoi grupează bin-urile de frecvență în clustere corespunzătoare transmisiilor individuale. Fiecare cluster este izolat, filtrat, translatat în banda de bază și trimis către două fluxuri paralele: unul pentru clasificarea prin algoritmul AI, iar celălalt pentru extragerea metricilor de analiză a canalului, precum frecvența purtătoare, lățimea de bandă ocupată și gradul de ocupare a spectrului radio.

Pentru această extensie, a fost antrenat un model CNN dedicat exclusiv transmisiilor LoRa, folosind un set de date de 156.000 de instanțe distribuite uniform pentru fiecare factor

de împrăștiere, pe intervalul SNR de la -20 dB la 30 dB. Modelul a obținut o acuratețe de $98,4\%$ la finalul procesului de antrenare. Arhitectura hibridă a fost apoi testată în condiții reale, utilizând cinci noduri IoT echipate cu transceivere LoRa și un receptor SDR. Dintr-un total de 500 de transmisii, sistemul a detectat 481 , corespunzând unei rate de detecție de $96,2\%$. Precizia clasificării a fost de $99,16\%$, iar reamintirea de $95,4\%$. Estimarea parametrilor fizici ai transmisiilor a obținut deviații ale frecvenței centrale de $9,13$ kHz și deviații ale lățimii de bandă de $10,2$ kHz.

În ansamblu, capitolul demonstrează că modelele DL aplicate pe serii temporale IQ pot detecta și clasifica modulații radio IoT, inclusiv în condiții reale de propagare, chiar atunci când sunt antrenate pe date sintetice. Totodată, prin integrarea tehnicilor clasice de procesare a semnalelor într-o arhitectură hibridă, metoda propusă depășește limitarea clasificării unei singure transmisii și permite monitorizarea simultană a mai multor transmisii radio, oferind și metrice avansate de analiză a spectrului radio.

Contribuțiile asociate acestui capitol au fost diseminate în cadrul lucrărilor:

- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "Evaluation of a new spectrum sensing technique for Internet of Things: An AI approach," prezentată în cadrul conferinței *2022 International Conference on Development and Application Systems (DAS)*, Suceava, Romania; anul 2022.
- **P. -M. Mutescu**, V. Popa and A. Lavric, "Dataset Creation Strategies for Future AI-based Radio Spectrum Sensing Applications," prezentată în cadrul conferinței *2025 International Conference on Control, Automation and Diagnosis (ICCAD)*, Barcelona, Spain; anul 2025.
- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu and V. Popa, "AI-Powered Capabilities for IoT Spectrum Sensing Applications," prezentată în cadrul conferinței *2025 International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA)*, Antalya, Turkiye; anul 2025.
- **P.-M. Mutescu**, V. Popa, and A. Lavric, "LoRa Communications Spectrum Sensing Based on Artificial Intelligence: IoT Sensing," publicată în jurnalul *MDPI Sensors (Q2)* cu IF de $3,5$; anul 2025.

Seturile de date rezultate au fost puse la dispoziția comunității academice prin intermediul platformei GitHub, putând fi accesate utilizând link-urile:

- **Spectrum Hive IQ Dataset :**
https://github.com/WirelessLabUSV/spectrumHiveDatasets/blob/main/spectrumHive_IoT_Dataset_IQstream.md
- **Spectrum Hive LoRa Dataset :**
https://github.com/WirelessLabUSV/spectrumHiveDatasets/blob/main/spectrumHive_LoRa.md

V. Monitorizarea spectrului radio în rețele IoT utilizând algoritmi AI aplicați pe reprezentări timp-frecvență

În acest capitol este prezentată dezvoltarea unei arhitecturi de monitorizare a spectrului radio pentru comunicații IoT bazată pe algoritmi AI aplicați pe reprezentări timp-frecvență (spectrograme) ale semnalelor radio. Studiile preliminare au indicat că spectrogramele radio permit detectarea transmisiilor radio utilizând algoritmi AI și că arhitecturile de detecție a obiectelor din familia YOLO oferă cele mai bune performanțe pentru identificarea simultană și localizarea transmisiilor în spectrul radio.

Arhitectura dezvoltată, prezentată în figura 5.1 este structurată în două etape principale: etapa de antrenare a algoritmului AI și etapa de inferență în timp real. În etapa de antrenare sunt generate și captate transmisi radio IoT utilizând transceivere dedicate și dispozitive SDR, iar semnalele IQ sunt transformate în spectrograme prin aplicarea transformatei STFT. Spectrogramele rezultate sunt etichetate automat utilizând tehnici de procesare a imaginilor pentru identificarea regiunilor de interes corespunzătoare transmisiilor radio. Pentru a crește diversitatea datelor și capacitatea de generalizare a modelului AI au fost aplicate tehnici de augmentare a imaginilor asupra spectrogramelor. Setul de date final conține 6.190 de spectrograme corespunzătoare celor șase factori de împrăștiere LoRa și protocolului Sigfox, obținute atât prin capturi realizate prin cablu coaxial într-un mediu controlat, cât și prin capturi OTA, pentru a integra efecte reale de propagare.

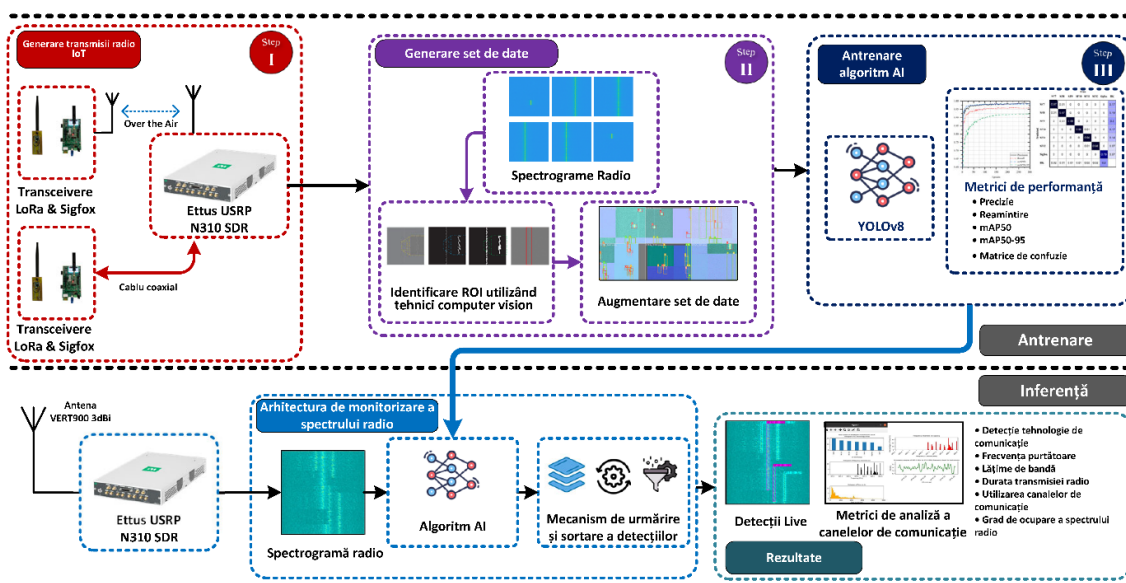


Figura 5.1. Structura generală a arhitecturii de monitorizare a spectrului radio propusă pentru sisteme de comunicații IoT

Pentru detectarea transmisiilor radio a fost utilizată rețeaua neuronală YOLOv8, selectată datorită performanțelor ridicate în detecția și localizarea obiectelor. Modelul YOLOv8 nano a fost adaptat prin tehnici de învățare prin transfer pentru recunoașterea transmisiilor radio IoT și a fost antrenat timp de 300 de epoci utilizând optimizatorul SGDM și accelerare GPU. Evaluarea pe setul de date de testare a evidențiat un nivel ridicat de performanță, obținându-se o precizie de 0,97, o reamintire de 0,96, o valoare mAP50 de 0,968 și o valoare mAP50-95 de 0,905. Au fost evaluate și variantele YOLOv8 small, medium, large și Xlarge pentru a analiza impactul creșterii complexității modelului AI asupra performanței.

Deși aceste modele au generat îmbunătățiri marginale ale performanței, latența de inferență a crescut semnificativ, motiv pentru care modelul YOLOv8 nano a fost selectat pentru implementarea finală, oferind cel mai bun compromis între performanță și eficiență computațională.

Pentru a permite utilizarea arhitecturii dezvoltate în scenarii operaționale reale a fost dezvoltat un mecanism de urmărire și sortare a detecțiilor. În practică, durata unei transmisii radio poate depăși durata ferestrei de spectrogramă, ceea ce conduce la apariția mai multor detecții pentru aceeași transmisie. Fără un mecanism de agregare, aceste detecții ar putea fi interpretate eronat ca transmisii distincte. Pentru a rezolva această problemă, arhitectura utilizează modulul de urmărire integrat în YOLOv8 pentru a atribui un identificator unic fiecărei transmisii detectate. Parametrii detecțiilor sunt stocați într-o memorie buffer, unde sunt agregate și sortate informațiile provenite din spectrograme succesive.

Pe baza informațiilor furnizate de algoritmul AI sunt calculate frecvența centrală a transmisiei, momentul de început și momentul de sfârșit al transmisiei, precum și durata acesteia (Time-on-Air). Pentru fiecare transmisie detectată sunt determinate valorile agregate ale acestor parametri, eliminând detecțiile duplicate și oferind o caracterizare completă a transmisiei în domeniul timp-frecvență. În plus, pe baza poziției și suprafeței regiunilor de interes este calculat gradul de ocupare al spectrului radio și pot fi identificate cazuri de suprapunere sau interferență între transmisii.

Performanța arhitecturii a fost analizată și din perspectiva latenței de procesare. Testele au fost realizate pe parcursul a 1200 de iterații de detecție, crescând progresiv numărul de transmisii radio prezente în spectrogramă. Rezultatele indică o latență medie de aproximativ 29,12 ms pentru procesul de detecție realizat de rețeaua YOLO, în timp ce procesarea rezultatelor și mecanismul de sortare introduc o latență suplimentară de aproximativ 1 ms. Latența totală a arhitecturii este astfel de aproximativ 30 ms pe spectrogramă, ceea ce permite procesare de aproximativ 30–33 spectrograme pe secundă și detectarea chiar și a transmisiilor IoT de durată foarte scurtă.




Figura 5.2. Interfața implementării live a arhitecturii de monitorizare a spectrului radio pentru comunicații IoT

Arhitectura a fost evaluată într-un scenariu operațional real prin monitorizarea spectrului radio în banda SRD 868 MHz pe o perioadă de 24 de ore în zona Universității Ștefan cel Mare din Suceava. Pe baza detecțiilor realizate au fost generate mai multe metrice de analiză a spectrului radio prezentate în interfața din figura 5.2 și figura 5.3, printre care distribuția tehnologiilor IoT detectate, utilizarea canalelor de comunicație, distribuția duratelor de transmisie și gradul de ocupare a spectrului radio.




Figura 5.3. Interfața implementării live a arhitecturii de monitorizare a spectrului radio pentru comunicații IoT.
Metrice avansate de analiză a spectrului radio

Comparativ cu arhitecturile existente de monitorizare a spectrului radio bazate pe YOLO din literatura de specialitate, soluția propusă introduce mai multe îmbunătățiri. Printre acestea se numără utilizarea unei metodologii automate de generare și etichetare a seturilor de date, integrarea unui mecanism de urmărire și sortare a detecțiilor pentru eliminarea detecțiilor duplicate și generarea automată a unor metrice avansate de analiză a spectrului radio.

Pe baza performanțelor obținute, arhitectura a fost extinsă pentru detectarea semnalelor radio LTE și 5G utilizând o rețea neuronală de segmentare semantică aplicată de asemenea pe spectrograme. Setul de date utilizat pentru antrenare a fost generat sintetic utilizând generatorul de forme de undă LTE și 5G NR din MATLAB, iar fiecărei spectrograme i-a fost asociată o mască de segmentare. Rețeaua neuronală a fost antrenată pentru clasificarea semnalelor LTE, 5G și zgomot de fundal, obținând o acuratețe de aproximativ 99% pentru detecția semnalelor LTE și 92% pentru semnalele 5G. Arhitectura a fost testată atât într-un mediu controlat utilizând o cameră anecoică, cât și într-un scenariu de funcționare real în benzile de telefonie Orange Romania.

Rezultatele obținute demonstrează că utilizarea algoritmilor AI de detecție a obiectelor și a rețelelor neuronale de segmentare aplicate pe spectrograme reprezintă o soluție viabilă pentru monitorizarea spectrului radio. Arhitectura propusă permite detectarea și clasificarea simultană a transmisiilor radio, localizarea acestora în timp și frecvență și generarea unor metrice avansate de analiză a spectrului radio, fiind totodată scalabilă și ușor extensibilă către noi tehnologii de comunicație.

Contribuțiile asociate acestui capitol au fost diseminate în cadrul lucrărilor:

- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "A Hybrid Deep Learning Spectrum Sensing Architecture for IoT Technologies Classification," prezentată în cadrul conferinței **2023 17th International Conference on Engineering of Modern Electric Systems (EMES)**, Oradea, Romania; anul 2023.
- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "Deep Learning Enhanced Spectrum Sensing for LoRa Spreading Factor Detection," prezentată în cadrul conferinței **2023 13th International Symposium on Advanced Topics in Electrical Engineering (ATEE)**, Bucharest, Romania; anul 2023.
- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," publicată în jurnalul **IEEE Access (Q2)** cu **IF** de 3,6; anul 2025.
- **Mutescu, P.-M.**; Petrariu, A.-I.; Coca, E.; Patachia-Sultanoiu, C.; Mihai, R.M.; Lavric, A. AI-Native PHY-Layer in 6G Orchestrated Spectrum-Aware Networks. publicată în jurnalul **MDPI Sensors (Q2)** cu **IF** de 3,5; anul 2025.
- A. Lavric, C. Patachia-Sultanoiu, R. M. Mihai and **P. -M. Mutescu**, "AI-Powered Spectrum Sensing Capabilities for Future Networks Beyond 5G," în cadrul conferinței **2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)**, Chania Crete, Greece; anul 2024.

VI. Proiectarea, dezvoltarea și implementarea unui model AI de monitorizare a spectrului radio cu capacități extinse de generalizare.

Detecția zgomotului

Acest capitol prezintă o schimbare de paradigmă în monitorizarea spectrului radio, orientată spre creșterea capacității de generalizare a modelelor AI. Spre deosebire de abordările clasice și de majoritatea soluțiilor bazate pe AI, care urmăresc identificarea directă a transmisiilor radio, metoda propusă inversează problema: transmisiile radio sunt tratate drept fundal, iar algoritmul AI este antrenat să detecteze regiunile de zgomot din spectrogramă. Ideea centrală este că zgomotul prezintă caracteristici mai consistente în reprezentarea timp-frecvență decât semnalele radio, ale căror forme variază în funcție de modulație, lățime de bandă, putere, durată sau tehnologie. Prin urmare, antrenarea pe zgomot permite dezvoltarea unui model cu potențial ridicat de generalizare, capabil să identifice direct regiunile neocupate din spectru fără a necesita reantrenare pentru fiecare nouă tehnologie radio.

Metodologia urmează trei etape principale: antrenarea și evaluarea empirică a modelului, analiza capacităților de generalizare și validarea în scenarii reale de operare. Pentru antrenare a fost generat un set de date sintetic format din spectrograme care acoperă 5 MHz și 500 ms și conțin între 0 și 15 transmisiile radio. În construcția acestora au fost utilizate un set limitat de modulații radio generice precum QAM, PSK, FSK și CSS, variind frecvența purtătoare, lățimea de bandă, ordinul de modulație, durata transmisiei și puterea de emisie. Semnalele au fost trecute printr-un model de canal care introduce AWGN, atenuare de tip Rician, propagare pe multiple căi, efect Doppler și erori de sincronizare, astfel încât setul de date să reflecte condiții de propagare variate. În total au fost generate 14.000 de spectrograme, câte 1.000 pentru fiecare valoare SNR între -16 dB și 10 dB.




Figura 6.1. Etapele procesului de adnotare a spectrogramelor: a) Spectrograma generată; b) Aplicarea unei grile de 2 pixeli; c) Verificarea suprapunerii cu transmisiile radio; d) Îmbinarea celulelor pe orizontală; e) Îmbinarea ROI pe verticală (generarea finală a regiunilor de interes cu zgomot)

O contribuție a metodologiei prezentate este procesul de adnotare a setului de date prezentat în figura 6.1. Deoarece zgomotul nu apare ca o singură regiune compactă, ci este distribuit în mai multe zone nesuprapuse, a fost dezvoltat un algoritm de construire automată a regiunilor de interes prin scanare pe grilă și fuziune a celulelor care nu se suprapun peste transmisii radio. Setul de date rezultat a fost împărțit în subseturi pentru antrenare, validare și testare, iar modelul utilizat a fost bazat pe arhitectura YOLOv11.

Evaluarea modelului AI a fost realizată prin compararea directă, la nivel de pixel, dintre zonele prezise ca zgomot și zonele de zgomot din referință. Folosind această metodă, algoritmul AI de detecție a zgomotului a obținut o precizie medie de 0,96, o reamintire medie de 0,95, un scor F1 de 0,95 și un IoU mediu de 0,924. Aceste rezultate arată că modelul poate identifica cu acuratețe regiunile neocupate din spectrul radio și confirmă capacitățile de detecție ale noii paradigme de monitorizare a spectrului radio bazate pe detecția zgomotului.

Analiza capacităților de generalizare a inclus variații ale lății de bandă, a duratei spectrogramei, a SNR-ului și, mai ales, în prezența unor tehnologii de comunicație care nu au fost incluse în setul de antrenare. În testele privind lățimea de bandă, modelul AI a fost evaluat pe spectrograme între 1 MHz și 4 MHz, iar în cazul modificării duratei spectrogramei, aceasta a fost variată între 100 ms și 600 ms, în ambele cazuri metricile de performanță având variații minimale. Analiza sensibilității la SNR a arătat că degradarea nivelului de performanță apare gradual pentru valori ale SNR sub -6 dB ajungând la un minim de 0,89 precizie la SNR de -16 dB. Cea mai importantă validare a capacității de generalizare a fost realizată pe tehnologii de comunicație necunoscute pentru model, precum Bluetooth, Wi-Fi, LTE și 5G NR. Rezultatele au arătat că algoritmul menține performanțe comparabile cu cele de referință și în aceste scenarii, arătând avantajul major al detecției pe baza zgomotului, mai exact modelul nu trebuie să învețe explicit fiecare modulație sau protocol radio, ci poate identifica regiunile neocupate chiar și în prezența unor protocole radio nevăzute anterior.

Algoritmul a fost validat și în scenarii reale de operare. Într-un test OTA realizat cu două dispozitive SDR Ettus USRP N310 amplasate la aproximativ 50 m, modelul a obținut o precizie de 0,952, o reamintire de 0,745, un scor F1 de 0,828 și un IoU de 0,721. O a doua validare a fost realizată într-o rețea privată openRAN 5G, dezvoltată în parteneriat cu Orange România. În acest scenariu, algoritmul a obținut un IoU de 0,925, o precizie de 0,957, o reamintire de 0,965 și un scor F1 de 0,961, demonstrând performanțe ridicate și în prezența traficului 5G real.

În ansamblu, acest capitol introduce o nouă paradigmă de monitorizare a spectrului radio, în care detecția este orientată către zgomot și nu către semnal. Avantajul major al acestei abordări este generalizarea extinsă: modelul poate opera pe lățimi de bandă, durate de observație, valori SNR și tehnologii radio diferite, fără a necesita reantrenare specifică. Deși metoda nu identifică direct tipul de modulație sau tehnologia utilizată, ea poate semnala cu acuratețe prezența sau absența transmisiei și poate furniza direct metrici privind disponibilitatea canalelor.

Această contribuție a fost diseminată în cadrul lucrării intitulate „**NORSS: Noise Oriented Radio Spectrum Sensing**” acceptată pentru prezentare și publicare în cadrul conferinței *2026 IEEE International Symposium on Antennas & Propagation and USNC-URSI Radio Science Meeting*, Detroit, Michigan, USA.

VII. Concluzii și contribuții

Rețelele de senzori fără fir reprezintă elementul fundamental în cadrul sistemelor IoT, realizând legătura între mediul fizic și internet prin intermediul senzorilor, actuatorilor și a tehnologiilor de comunicații radio. Având în vedere versatilitatea în aplicații a WSN-urilor în cadrul sistemelor IoT, acestea au prezentat în ultimii ani un interes ridicat atât în industrie cât și în mediul academic. Ca dovadă, numeroase studii preconizează că sectorul IoT va înregistra o creștere semnificativă, numărul de dispozitive IoT conectate fiind anticipat să ajungă la 30 miliarde până în 2030 cu un trend ascendent de 2 miliarde de noi dispozitive conectate în fiecare an. Pentru a transmite aceste date, dispozitivele IoT utilizează protocoale LPWAN precum LoRa, NB-IoT și Sigfox, în ultimii ani fiind exploatate inclusiv rețelele celulare prin comunicații LTE și 5G NR. Un factor comun al acestor protocoale și tehnologii de comunicații radio este reprezentat de necesitatea de resurse de spectru radio pentru a transmite informațiile de la senzori către gateway-uri sau base station-uri la nivelul cărora este realizată legătura senzor – internet. Având în vedere acest lucru și luând în considerare creșterea rapidă a numărului de dispozitive care necesită resurse spectrale, putem preconiza o scădere a QoS în cadrul sistemelor IoT, datorat în principal de interferențe, coliziuni și valori ale PER ridicate, limitând scalabilitatea rețelelor de senzori din cadrul sistemelor IoT la ritmul și necesitatea preconizată.

Pentru a depăși aceste provocări, punerea în aplicare a tehnicilor de monitorizare a spectrului radio devine esențială. Aceste tehnici implică detectarea și clasificarea transmisiilor din spectrul radio, oferind informații valoroase ce pot fi utilizate pentru a gestiona resursele de spectru radio limitate.

În cadrul acestei teze au fost prezentate contribuțiile aduse domeniului monitorizării spectrului radio, cu accent pe îmbunătățirea performanțelor sistemelor IoT. Aceste contribuții sunt rezultatul unei documentări extinse, care a permis identificarea principalelor provocări, limitări și direcții de cercetare din literatura de specialitate, precum și al unor experimente proprii care au ghidat și validat direcțiile de dezvoltare propuse.

Contribuțiile aduse sunt detaliate după cum urmează:

Contribuția 1: Analiză extinsă a comunicațiilor radio specifice domeniului IoT, a cerințelor de resurse de spectru radio aferente, precum și a problemelor și limitărilor comunicațiilor IoT în rețele de senzori de mare densitate.

În cadrul acestei contribuții a fost efectuată o analiză aprofundată a literaturii de specialitate, cu scopul identificării principalelor provocări asociate sistemelor IoT, precum și implementarea unor aplicații IoT bazate pe protocoale de comunicații de tip LPWAN. Rezultatele acestor implementări au fost diseminate în cadrul următoarelor lucrări:

- Lavric, G. Alexandrin, A. -I. Petrariu and **P. -M. Mutescu**, "IoT-Based Adaptive Street Lighting: Scalable Solutions for High-Density Large-Scale Smart City Networks," prezentat în cadrul conferinței **2025 IEEE PES Conference on Innovative Smart Grid Technologies - Middle East (ISGT Middle East)**, Dubai, United Arab Emirates; anul **2025**.
- Lavric, **P. -M. Mutescu**, A. -I. Petrariu and E. Coca, "Enhancing Emergency Communication with SDR Based PMR Capture and Speech Recognition," prezentată în cadrul conferinței **2025 IEEE 31st International Symposium for Design and Technology in Electronic Packaging (SIITME)**, Brasov, Romania; anul **2025**.

- Anchidin, L.; Lavric, A.; **Mutescu, P.-M.**; Petrariu, A.I.; Popa, V. "The Design and Development of a Microstrip Antenna for Internet of Things Applications" publicat în jurnalul *MDPI Sensors (Q2)* cu IF de 3,4; anul 2023
- Lavric, A.; Petrariu, A.I.; **Mutescu, P.-M.**; Coca, E.; Popa, V. „Internet of Things Concept in the Context of the COVID-19 Pandemic: A Multi-Sensor Application Design” publicat în jurnalul *MDPI Sensors (Q2)* cu IF de 3,9; anul 2022.
- A.I. Petrariu, **P.-M. Mutescu**, E. Coca, A. Lavric, "A Study on LoRa Signal Propagation Models in Urban Environments for Large-scale Networks Deployment," publicat în *Advances in Electrical and Computer Engineering (Q3)* cu IF de 0,825; anul 2021.

Contribuția 2: Dezvoltarea, implementarea și evaluarea unui algoritm AI de estimare a zgomotului, bazat pe o rețea neuronală Feed Forward, pentru optimizarea detecției semnalelor pe baza nivelului de energie în medii radio dinamice.

În cadrul acestei contribuții a fost dezvoltată o rețea neuronală de tip Feed Forward, având ca obiectiv estimarea componentei de zgomot din semnalul radio recepționat, în scopul îmbunătățirii procesului de calcul al pragului de detecție în medii radio dinamice, unde estimarea varianței zgomotului este dificil de realizat. Metoda propusă a demonstrat performanțe comparabile cu cele ale unui scenariu ideal, în care pragul de detecție este determinat pe baza unei valori cunoscute a SNR.

Această contribuție a fost diseminată în lucrarea:

- **P. -M. Mutescu**, V. Popa and A. Lavric, "Artificial Intelligence Noise Estimation for Adaptive Energy Detection in Dynamic Radio Environments," prezentată în cadrul conferinței *2025 IEEE PES Conference on Innovative Smart Grid Technologies - Middle East (ISGT Middle East)*, Dubai, United Arab Emirates; anul 2025.

Contribuția 3: Dezvoltarea, implementarea și evaluarea unui algoritm AI de monitorizare a spectrului radio pentru comunicații IoT, bazat pe serii temporale IQ.

Analiza literaturii de specialitate a evidențiat lipsa unor soluții eficiente de monitorizare a spectrului radio, capabile să identifice și să clasifice modulații utilizate în comunicațiile IoT, în condiții reale de operare. Astfel, în această contribuție a fost proiectat, antrenat și testat un algoritm AI bazat pe serii temporale IQ, capabil să identifice 11 tipuri de modulații radio utilizate în comunicații IoT. Algoritmul a atins o acuratețe de 98% în testele empirice și 78.8% în condiții reale de inferență, fiind antrenat exclusiv pe semnale generate sintetic cu efecte de propagare simulate.

Această contribuție a fost diseminată într-o serie de lucrări după cum urmează.

Studiile preliminare privind posibilitatea de detecție și clasificare a modulațiilor radio IoT prin utilizarea de algoritmi AI au fost diseminate în cadrul lucrării:

- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "Evaluation of a new spectrum sensing technique for Internet of Things: An AI approach," prezentată în cadrul conferinței *2022 International Conference on Development and Application Systems (DAS)*, Suceava, Romania; anul 2022.

Metodologia de creare a setului de date utilizat a fost diseminată în cadrul lucrării:

- **P. -M. Mutescu**, V. Popa and A. Lavric, "Dataset Creation Strategies for Future AI-based Radio Spectrum Sensing Applications," prezentată în cadrul conferinței **2025 International Conference on Control, Automation and Diagnosis (ICCAD)**, Barcelona, Spain; anul 2025.

Seturile de date rezultate au fost puse la dispoziția comunității academice prin intermediul platformei GitHub, putând fi accesate utilizând link-urile:

- **Spectrum Hive IQ Dataset :**
https://github.com/WirelessLabUSV/spectrumHiveDatasets/blob/main/spectrumHive_IoT_Dataset_IQstream.md
- **Spectrum Hive LoRa Dataset :**
https://github.com/WirelessLabUSV/spectrumHiveDatasets/blob/main/spectrumHive_LoRa.md

Dezvoltarea antrenarea și evaluarea algoritmului AI bazat pe serii temporale IQ, capabil să identifice 11 tipuri de modulații radio utilizate în comunicații IoT a fost diseminată în cadrul lucrării:

- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu and V. Popa, "AI-Powered Capabilities for IoT Spectrum Sensing Applications," prezentată în cadrul conferinței **2025 International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA)**, Antalya, Turkiye; anul 2025.

Totodată, algoritmul a fost integrat într-o arhitectură hibridă de monitorizare a spectrului radio, capabilă să detecteze, să clasifice și să genereze metrici de analiză a canalelor de comunicație, precum frecvența centrală, lățimea de bandă și gradul de ocupare, pentru multiple transmisii LoRa simultane. Rezultatele acestei contribuții au fost diseminate în cadrul lucrării:

- **P.-M. Mutescu**, V. Popa, and A. Lavric, "LoRa Communications Spectrum Sensing Based on Artificial Intelligence: IoT Sensing," publicată în jurnalul **MDPI Sensors (Q2)** cu IF de **3,5**; anul 2025.

Contribuția 4: Dezvoltarea unei arhitecturi inovative de monitorizare a spectrului radio pentru sisteme IoT, bazată pe algoritmi AI de detecție a obiectelor.

Având în vedere absența unor soluții complete de monitorizare a spectrului radio dedicate comunicațiilor IoT, această contribuție propune o arhitectură integrată, construită pe baza utilizării de echipamente SDR și algoritmi de inteligență artificială.

Studiile preliminare care au condus la dezvoltarea acestei arhitecturi au fost diseminate în cadrul lucrărilor:

- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "A Hybrid Deep Learning Spectrum Sensing Architecture for IoT Technologies Classification," prezentată în cadrul conferinței **2023 17th International Conference on Engineering of Modern Electric Systems (EMES)**, Oradea, Romania; anul 2023.
- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "Deep Learning Enhanced Spectrum Sensing for LoRa Spreading Factor Detection," prezentată în cadrul conferinței **2023 13th**

International Symposium on Advanced Topics in Electrical Engineering (ATEE), Bucharest, Romania; anul 2023.

Dezvoltarea și validarea arhitecturii de monitorizare a spectrului radio pentru sisteme IoT, bazată pe algoritmi AI de detecție a obiectelor a fost diseminată în cadrul lucrării:

- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," publicată în jurnalul *IEEE Access (Q2)* cu IF de 3,6; anul 2025.

Contribuția 5: Dezvoltarea unei metodologii pentru generarea seturilor de date utilizate în antrenarea algoritmilor AI de monitorizare a spectrului radio și realizarea unui set de date propriu.

Având în vedere limitările identificate în literatura de specialitate, în special lipsa unor mecanisme de etichetare automată și a seturilor de date relevante pentru monitorizarea spectrului radio, a fost elaborată o metodologie proprie, bazată pe tehnici de computer vision și augmentare a datelor. Această metodologie contribuie la creșterea flexibilității și scalabilității arhitecturii propuse, permițând integrarea rapidă a unor noi protocoale de comunicație în seturile de date de antrenare, validare și testare.

Metodologia de generare a seturilor de date utilizate pentru antrenarea algoritmilor de inteligență artificială destinați monitorizării spectrului radio, bazată pe algoritmi de detecție a obiectelor, a fost diseminată în cadrul următoarelor lucrări:

- **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "A Hybrid Deep Learning Spectrum Sensing Architecture for IoT Technologies Classification," prezentată în cadrul conferinței *2023 17th International Conference on Engineering of Modern Electric Systems (EMES)*, Oradea, Romania; anul 2023.
- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," publicată în jurnalul *IEEE Access (Q2)* cu IF de 3,6; anul 2025.

Contribuția 6: Antrenarea, evaluarea și implementarea unei rețele neuronale YOLOv8 nano pentru identificarea comunicațiilor IoT de tip LoRa și Sigfox.

În urma analizei tendințelor din literatura de specialitate, precum și a experimentelor proprii, rețelele neuronale de detecție a obiectelor au fost identificate ca fiind cele mai potrivite pentru aplicațiile de monitorizare a spectrului radio, în special cele bazate pe arhitectura YOLO. Astfel, utilizând arhitectura YOLOv8, tehnici de învățare prin transfer și un set de date proprietar, a fost antrenată, validată și evaluată o rețea neuronală capabilă să detecteze, clasifice și localizeze în timp și frecvență șapte clase de tehnologii IoT: cei șase factori de împrăștiere LoRa și tehnologia Sigfox. Dintre toate variantele testate, modelul YOLOv8 nano a prezentat cele mai bune performanțe, obținând o precizie medie de 0.968 și o latență medie de detecție de 29,12 ms.

Această contribuție a fost diseminată în cadrul lucrării:

- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," publicată în jurnalul *IEEE Access (Q2)* cu IF de 3,6; anul 2025.

Contribuția 7: Dezvoltarea unui mecanism de urmărire și sortare în timp a detecțiilor radio generate de rețelele AI de monitorizare.

Pentru a răspunde limitărilor identificate atât în literatura de specialitate, cât și în implementările proprii (ferestre de timp reduse, detecții duplicate, localizare imprecisă în planul timp-frecvență), a fost dezvoltat un mecanism de urmărire a transmisiilor radio pe spectrograme succesive. Acest mecanism permite agregarea instanțelor multiple de detecție într-o singură detecție coerentă, eliminând duplicatele și estimând precis caracteristicile transmisiei.

Această contribuție a fost diseminată în cadrul lucrării:

- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," publicată în jurnalul *IEEE Access (Q2)* cu IF de 3,6; anul 2025.

Contribuția 8: Elaborarea unui algoritm de generare a metricilor avansate de analiză a spectrului radio și a unei interfețe de vizualizare.

Pentru a sprijini dezvoltarea unor mecanisme de evitare a interferențelor și modele de utilizare eficientă a spectrului, a fost dezvoltat un algoritm ce generează metrici avansate de analiză a spectrului radio pe baza detecțiilor AI și a mecanismului de urmărire. Aceste metrici includ:

- Histogramă de utilizare a tehnologiilor IoT;
- Histogramă de utilizare a canalelor de comunicație;
- Histogramă a duratelor de emisie (ToA);
- Gradul de ocupare în timp al canalelor;
- Gradul de ocupare instantanee a spectrului.

Metricile sunt afișate printr-o interfață grafică intuitivă, care permite vizualizarea în timp real a spectrogramei și ajustarea benzii de frecvență monitorizate.

Această contribuție a fost diseminată în cadrul lucrării:

- **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," publicată în jurnalul *IEEE Access (Q2)* cu IF de 3,6; anul 2025.

Contribuția 9: Extinderea arhitecturii de monitorizare a spectrului radio pentru rețelele de comunicații de nouă generație (5G și LTE).

În contextul creșterii interesului pentru aplicații IoT bazate pe infrastructura de comunicații mobile, a fost proiectată și evaluată o extensie a arhitecturii pentru monitorizarea comunicațiilor 5G și LTE. Aceasta a fost dezvoltată în cadrul unui parteneriat cu Orange România și este capabilă să detecteze forme de undă LTE, 5G, precum și trafic necunoscut sau anormal, cu o acuratețe de 97.1%. Evaluarea a fost realizată atât în medii controlate (camere anecoice), cât și în medii reale (rețele comerciale Orange România – campus USV).

Această contribuție a fost diseminată în cadrul lucrărilor:

- **Mutescu, P.-M.**; Petrariu, A.-I.; Coca, E.; Patachia-Sultanoiu, C.; Mihai, R.M.; Lavric, A. AI-Native PHY-Layer in 6G Orchestrated Spectrum-Aware Networks. publicată în jurnalul *MDPI Sensors (Q2)* cu IF de 3,5; anul 2025.

- A. Lavric, C. Patachia-Sultanoiu, R. M. Mihai and **P. -M. Mutescu**, "AI-Powered Spectrum Sensing Capabilities for Future Networks Beyond 5G," în cadrul conferinței **2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)**, Chania Crete, Greece; anul 2024.

Contribuția 10: Dezvoltarea și evaluarea unei metodologii de monitorizare a spectrului radio prin detecția zgomotului, bazată pe algoritmi AI de detecție a obiectelor, cu capacități extinse de generalizare.

Având în vedere limitările identificate privind capacitatea de generalizare în monitorizarea spectrului radio, a fost propusă o nouă metodologie bazată pe detecția zgomotului, capabilă să opereze pe o varietate largă de modulații și tehnologii, fără a necesita reantrenarea modelului. Algoritmul AI dezvoltat a demonstrat performanțe robuste atât în scenarii de generalizare, cât și în condiții reale de inferență, cu variații minime față de rezultatele obținute pe seturile de test.

Această contribuție a fost diseminată în cadrul lucrării intitulate „**NORSS: Noise Oriented Radio Spectrum Sensing**” prezentată cadrul conferinței **2026 IEEE International Symposium on Antennas & Propagation and USNC-URSI Radio Science Meeting**, Detroit, Michigan, USA.

Toate tehnicile de monitorizare a spectrului radio dezvoltate și analizate în cadrul tezei sunt centralizate în tabelul 7.1, pentru o viziune unitară asupra acestora.

Tabel 7.1. Sumarizarea contribuțiilor și implementărilor prezentate în teză

Lucrare publicată	Contribuție	Algoritm AI utilizat	Date de intrare	Rezultat	Limitări
[49]	Rețea Feed Forward de estimare a zgomotului pentru îmbunătățirea tehnicii ED	Feed Forward Network cu două straturi ascunse	Serii temporale IQ	Probabilitate de detecție similară cu scenariul ideal caracterizat de SNR cunoscut	Rezultat binar al detecției (Canal Ocupat/Liber) Problematika SNR Wall
[50]	Rețea neuronală convoluțională de detecție a modulațiilor radio din sfera IoT	Rețea neuronală convoluțională cu 23 de straturi	Serii temporale IQ	Acuratețe de detecție de 98% în evaluare empirică și 78.8% în inferență în mediu real	Poate detecta o singură transmisie radio în cadrul benzii de frecvență analizate
[51]	Arhitectură hibridă de monitorizare a spectrului radio pentru comunicații LoRa bazată pe algoritmi AI	Rețea neuronală convoluțională cu 23 de straturi	Serii temporale IQ	Rată de detecție de 96,2% și precizie de clasificare de 99.6%	Necesită multiple procesări ale semnalului radio analizat pentru separarea transmisiilor radio și generarea metricilor de

					analiza a canalelor de comunicație
[52]	Arhitectură de monitorizare a spectrului radio pentru comunicații IoT bazată pe algoritmi AI de detecție a obiectelor	YOLOv8	Spectrograme Radio	Acuratețe de detecție de 96,6% și o latență de 29.1 ms	Necesită reantrenare pe date noi în vederea scalării către noi protocoale de comunicație
[53]	Arhitectură de monitorizare a spectrului radio pentru comunicații 5G NR și LTE bazată pe algoritmi AI de segmentare	Rețea neuronală de segmentare a imaginilor cu 24 de straturi	Spectrograme Radio	Acuratețe de detecție de 97,1%	Timpi mari de procesare a spectrogramei (detecție la nivel de pixel)
	Algoritm AI de monitorizare a spectrului radio bazat pe detecția zgomotului cu capabilități extinse de generalizare	YOLOv11	Spectrograme Radio	Precizie de 96% în evaluare empirică și 95% în inferență în mediu real	Poate detecta prezența sau absența unui semnal radio, nu și modulația sau tehnologia de comunicație radio utilizată
[48], [54]	Publicare set de date cu comunicații IoT pentru antrenarea și evaluarea algoritmilor AI	-	Serii temporale IQ	Acuratețe de detecție de 98% în evaluare empirică și 78.8% în inferență în mediu real	-
[55]	Publicare set de date cu comunicații LoRa pentru antrenarea și evaluarea algoritmilor AI	-	Serii temporale IQ	Rată de detecție de 96,2% și precizie de clasificare de 99.6%	-

Prezenta teză de doctorat a beneficiat de suport financiar din următoarele surse:

1. Proiect IoT Sensing

Acknowledgement: “This work was supported by a grant of the Ministry of Research, Innovation and Digitization, CNCS-UEFISCDI, project number PN-IV-P2-2.1-TE-2023-1476, within PNCDI IV.”

2. Proiect IPCEI

Acknowledgement: “This work was supported by the European Union – NextGenerationEU, through the National Recovery and Resilience Plan (PNRR), Component 9, Investment 4, under project Innovation in Smart Automotive Systems Design, Test and Certification) – ISACert, Contract no. 1. PI/I4/C9”

3. Bursă ORANGE România în cadrul Orange Educational Program

Lucrări publicate

I. Lucrări publicate în jurnale

1. Mutescu, P.-M.; Petrariu, A.-I.; Coca, E.; Patachia-Sultanoiu, C.; Mihai, R.M.; Lavric, A. AI-Native PHY-Layer in 6G Orchestrated Spectrum-Aware Networks. *Sensors* 2025, 25, 7206. <https://doi.org/10.3390/s25237206>.

2. P.-M. Mutescu, V. Popa, and A. Lavric, “LoRa Communications Spectrum Sensing Based on Artificial Intelligence: IoT Sensing,” *Sensors* 2025, Vol. 25, Page 2748, vol. 25, no. 9, p. 2748, Apr. 2025, doi: 10.3390/S25092748.

3. P. -M. Mutescu, A. Lavric, A. -I. Petrariu, A. -M. Cailean and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," in *IEEE Access*, vol. 13, pp. 64594-64609, 2025, doi: 10.1109/ACCESS.2025.3558746.

4. Anchidin, L.; Lavric, A.; **Mutescu, P.-M.;** Petrariu, A.I.; Popa, V. The Design and Development of a Microstrip Antenna for Internet of Things Applications. *Sensors* **2023**, 23, 1062. <https://doi.org/10.3390/s23031062>.

5. Lavric, A.; Petrariu, A.I.; **Mutescu, P.-M.;** Coca, E.; Popa, V. Internet of Things Concept in the Context of the COVID-19 Pandemic: A Multi-Sensor Application Design. *Sensors* **2022**, 22, 503. <https://doi.org/10.3390/s22020503>.

6. A. I. Petrariu, P.-M. Mutescu, E. Coca, A. Lavric, "A Study on LoRa Signal Propagation Models in Urban Environments for Large-scale Networks Deployment," *Advances in Electrical and Computer Engineering*, vol.21, no.4, pp.61-68, 2021, doi:10.4316/AECE.2021.04007

II. Lucrări publicate în volumele conferințelor internaționale

1. P. -M. Mutescu, V. Popa and A. Lavric, "Artificial Intelligence Noise Estimation for Adaptive Energy Detection in Dynamic Radio Environments," *2025 IEEE PES Conference on Innovative Smart Grid Technologies - Middle East (ISGT Middle East)*, Dubai, United Arab Emirates, 2025, pp. 1-5, doi: 10.1109/ISGTMiddleEast65737.2025.11314420.

2. A. Lavric, G. Alexandrin, A. -I. Petrariu and **P. -M. Mutescu,** "Iot-Based Adaptive Street Lighting: Scalable Solutions for High-Density Large-Scale Smart City Networks," *2025*

IEEE PES Conference on Innovative Smart Grid Technologies - Middle East (ISGT Middle East), Dubai, United Arab Emirates, 2025, pp. 1-5, doi: 10.1109/ISGTMiddleEast65737.2025.11314385.

3. A. Lavric, **P. -M. Mutescu**, A. -I. Petrariu and E. Coca, "Enhancing Emergency Communication with SDR Based PMR Capture and Speech Recognition," *2025 IEEE 31st International Symposium for Design and Technology in Electronic Packaging (SIITME)*, Brasov, Romania, 2025, pp. 441-444, doi: 10.1109/SIITME67657.2025.11293698.

4. **P. -M. Mutescu**, A. Lavric, A. -I. Petrariu and V. Popa, "AI-Powered Capabilities for IoT Spectrum Sensing Applications," *2025 International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA)*, Antalya, Turkiye, 2025, pp. 1-6, doi: 10.1109/ACDSA65407.2025.11165847.

5. **P. -M. Mutescu**, V. Popa and A. Lavric, "Dataset Creation Strategies for Future AI-based Radio Spectrum Sensing Applications," *2025 International Conference on Control, Automation and Diagnosis (ICCAD)*, Barcelona, Spain, 2025, pp. 1-6, doi: 10.1109/ICCAD64771.2025.11099123.

6. A. Lavric, C. Patachia-Sultanoiu, R. M. Mihai and **P. -M. Mutescu**, "AI-Powered Spectrum Sensing Capabilities for Future Networks Beyond 5G," *2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)*, Chania Crete, Greece, 2024, pp. 1-7, doi: 10.1109/IISA62523.2024.10786649.

7. **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "A Hybrid Deep Learning Spectrum Sensing Architecture for IoT Technologies Classification," *2023 17th International Conference on Engineering of Modern Electric Systems (EMES)*, Oradea, Romania, 2023, pp. 1-4, doi: 10.1109/EMES58375.2023.10171667.

8. **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "Deep Learning Enhanced Spectrum Sensing for LoRa Spreading Factor Detection," *2023 13th International Symposium on Advanced Topics in Electrical Engineering (ATEE)*, Bucharest, Romania, 2023, pp. 1-5, doi: 10.1109/ATEE58038.2023.10108224.

9. **P. M. Mutescu**, A. Lavric, A. I. Petrariu and V. Popa, "Evaluation of a new spectrum sensing technique for Internet of Things: An AI approach," *2022 International Conference on Development and Application Systems (DAS)*, Suceava, Romania, 2022, pp. 91-94, doi: 10.1109/DAS54948.2022.9786101.

Bibliografie selectată

- [1] M. Centenaro, L. Vangelista, A. Zanella, and M. Zorzi, “Long-range communications in unlicensed bands: The rising stars in the IoT and smart city scenarios,” *IEEE Wirel. Commun.*, vol. 23, no. 5, pp. 60–67, Oct. 2016, doi: 10.1109/MWC.2016.7721743.
- [2] A. Lavric, G. Alexandrin, A.-I. Petrariu, and P.-M. Mutescu, “IoT-Based Adaptive Street Lighting: Scalable Solutions for High-Density Large-Scale Smart City Networks,” *2025 IEEE PES Conference on Innovative Smart Grid Technologies - Middle East (ISGT Middle East)*, pp. 1–5, Nov. 2025, doi: 10.1109/ISGTMIDDLEEAST65737.2025.11314385.
- [3] K. C. Rath, A. Khang, and D. Roy, “The Role of Internet of Things (IoT) Technology in Industry 4.0 Economy,” *Advanced IoT Technologies and Applications in the Industry 4.0 Digital Economy*, pp. 1–28, Jan. 2024, doi: 10.1201/9781003434269-1/ROLE-INTERNET-THINGS-IOT-TECHNOLOGY-INDUSTRY-4-0-ECONOMY-KALI-CHARAN-RATH-ALEX-KHANG-DEBANIK-ROY.
- [4] A. Lavric and A. I. Petrariu, “LoRaWAN communication protocol: The new era of IoT,” *2018 14th International Conference on Development and Application Systems, DAS 2018 - Proceedings*, pp. 74–77, Jun. 2018, doi: 10.1109/DAAS.2018.8396074.
- [5] A. Lavric, A. I. Petrariu, and V. Popa, “SigFox Communication Protocol: The New Era of IoT?,” *2019 International Conference on Sensing and Instrumentation in IoT Era, ISSI 2019*, Aug. 2019, doi: 10.1109/ISSI47111.2019.9043727.
- [6] H. Alobaidy and J. Mandeep, “A review on ZigBee based WSNs: concepts, infrastructure, applications, and challenges,” *ijeetc.com*, doi: 10.18178/ijeetc.9.3.189-198.
- [7] P. M. Mutescu, A. I. Petrariu, and A. Lavric, “Wireless Communications for IoT: Energy Efficiency Survey,” *12th International Symposium on Advanced Topics in Electrical Engineering, ATEE 2021*, Mar. 2021, doi: 10.1109/ATEE52255.2021.9425330.
- [8] S. N. K. Veedu *et al.*, “Toward Smaller and Lower-Cost 5G Devices with Longer Battery Life: An Overview of 3GPP Release 17 RedCap,” *IEEE Communications Standards Magazine*, vol. 6, no. 3, pp. 84–90, Sep. 2022, doi: 10.1109/MCOMSTD.0001.2200029.
- [9] L. Miuccio, D. Panno, and S. Riolo, “A DNN-based estimate of the PRACH traffic load for massive IoT scenarios in 5G networks and beyond,” *Computer Networks*, vol. 201, p. 108608, Dec. 2021, doi: 10.1016/j.comnet.2021.108608.
- [10] Y. Tripathi, A. Prakash, and R. Tripathi, “A novel slot scheduling technique for duty-cycle based data transmission for wireless sensor network,” *Digital Communications and Networks*, vol. 8, no. 3, pp. 351–358, Jun. 2022, doi: 10.1016/j.dcan.2022.01.006.
- [11] A. Lavric, A. I. Petrariu, and V. Popa, “Long Range SigFox Communication Protocol Scalability Analysis under Large-Scale, High-Density Conditions,” *IEEE Access*, vol. 7, pp. 35816–35825, 2019, doi: 10.1109/ACCESS.2019.2903157.
- [12] “IEEE SA - IEEE 802.15.4g-2012.” Accessed: Apr. 24, 2025. [Online]. Available: <https://standards.ieee.org/ieee/802.15.4g/5053/>
- [13] M. Baddula, B. Ray, and M. Chowdhury, “Performance Evaluation of Aloha and CSMA for LoRaWAN Network,” *2020 IEEE Asia-Pacific Conference on Computer Science*

- and Data Engineering, CSDE 2020, Dec. 2020, doi: 10.1109/CSDE50874.2020.9411539.
- [14] L. Chasserat, N. Accettura, and P. Berthou, “Experimental throughput models for LoRa networks with capture effect,” *International Conference on Wireless and Mobile Computing, Networking and Communications*, vol. 2022-October, pp. 36–41, 2022, doi: 10.1109/WiMob55322.2022.9941715.
 - [15] W. G. Abera, T. O. Olwal, and Y. W. Marye, “Deep reinforcement learning-based access class barring for mMTC access control in cellular networks,” *Array*, vol. 28, p. 100533, Dec. 2025, doi: 10.1016/j.array.2025.100533.
 - [16] “IoT connected devices worldwide 2019-2030 | Statista.” Accessed: Feb. 26, 2023. [Online]. Available: <https://www.statista.com/statistics/1183457/iot-connected-devices-worldwide/>
 - [17] S. Atapattu, C. Tellambura, and H. Jiang, “Energy Detection for Spectrum Sensing in Cognitive Radio,” 2014, doi: 10.1007/978-1-4939-0494-5.
 - [18] I. Ramachandran and S. Roy, “Clear channel assessment in energy-constrained wideband wireless networks,” *IEEE Wirel. Commun.*, vol. 14, no. 3, pp. 70–78, Jun. 2007, doi: 10.1109/MWC.2007.386615.
 - [19] A. E. Leu, M. McHenry, and B. L. Mark, “Modeling and analysis of interference in Listen-before-talk spectrum access schemes,” *International Journal of Network Management*, vol. 16, no. 2, pp. 131–147, Mar. 2006, doi: 10.1002/NEM.610.
 - [20] Y. Huang and K. W. Chin, “A Hierarchical Deep Learning Approach for Optimizing CCA Threshold and Transmit Power in Wi-Fi Networks,” *IEEE Trans. Cogn. Commun. Netw.*, vol. 9, no. 5, pp. 1296–1307, Oct. 2023, doi: 10.1109/TCCN.2023.3282984.
 - [21] K. Il Hwang, “Energy efficient channel agility utilizing dynamic multi-channel CCA for ZigBee RF4CE,” *IEEE Transactions on Consumer Electronics*, vol. 57, no. 1, pp. 113–119, Feb. 2011, doi: 10.1109/TCE.2011.5735490.
 - [22] J. Lorincz, I. Ramljak, and D. Begušić, “A review of the noise uncertainty impact on energy detection with different OFDM system designs,” *Comput. Commun.*, vol. 148, pp. 185–207, Dec. 2019, doi: 10.1016/J.COMCOM.2019.09.013.
 - [23] S. Yu, J. Liu, J. Wang, and I. Ullah, “Adaptive Double-Threshold Cooperative Spectrum Sensing Algorithm Based on History Energy Detection,” *Wirel. Commun. Mob. Comput.*, vol. 2020, no. 1, p. 4794136, Jan. 2020, doi: 10.1155/2020/4794136.
 - [24] C. Vladeanu, C. V. Nastase, and A. Martian, “Energy Detection Algorithm for Spectrum Sensing Using Three Consecutive Sensing Events,” *IEEE Wireless Communications Letters*, vol. 5, no. 3, pp. 284–287, Jun. 2016, doi: 10.1109/LWC.2016.2543723.
 - [25] X. Tian, Z. Tian, E. Blasch, K. Pham, D. Shen, and G. Chen, “Sliding window energy detection for spectrum sensing under low SNR conditions,” *Wirel. Commun. Mob. Comput.*, vol. 16, no. 12, pp. 1654–1663, Aug. 2016, doi: 10.1002/WCM.2639.
 - [26] B. Al Homssi, A. Al-Hourani, Z. Krusevac, and W. S. T. Rowe, “Machine Learning Framework for Sensing and Modeling Interference in IoT Frequency Bands,” *IEEE Internet Things J.*, vol. 8, no. 6, pp. 4461–4471, Mar. 2021, doi: 10.1109/JIOT.2020.3026819.

- [27] N. E. West and T. O'Shea, "Deep architectures for modulation recognition," *2017 IEEE International Symposium on Dynamic Spectrum Access Networks, DySPAN 2017*, May 2017, doi: 10.1109/DYSPAN.2017.7920754.
- [28] T. J. O'Shea, T. Roy, and T. C. Clancy, "Over-the-Air Deep Learning Based Radio Signal Classification," *IEEE Journal on Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 168–179, Feb. 2018, doi: 10.1109/JSTSP.2018.2797022.
- [29] "Datasets - DeepSig." Accessed: Jan. 28, 2025. [Online]. Available: <https://www.deepsig.ai/datasets/>
- [30] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 12, pp. 6999–7019, Dec. 2022, doi: 10.1109/TNNLS.2021.3084827.
- [31] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," 2016. Accessed: Feb. 11, 2026. [Online]. Available: <http://image-net.org/challenges/LSVRC/2015/>
- [32] S. Rajendran, W. Meert, D. Giustiniano, V. Lenders, and S. Pollin, "Deep learning models for wireless signal classification with distributed low-cost spectrum sensors," *IEEE Trans. Cogn. Commun. Netw.*, vol. 4, no. 3, pp. 433–445, Sep. 2018, doi: 10.1109/TCCN.2018.2835460.
- [33] M. Zhang, M. Diao, and L. Guo, "Convolutional Neural Networks for Automatic Cognitive Radio Waveform Recognition," *IEEE Access*, vol. 5, pp. 11074–11082, Jun. 2017, doi: 10.1109/ACCESS.2017.2716191.
- [34] N. Daldal, Z. Cömert, and K. Polat, "Automatic determination of digital modulation types with different noises using Convolutional Neural Network based on time–frequency information," *Appl. Soft Comput.*, vol. 86, p. 105834, Jan. 2020, doi: 10.1016/J.ASOC.2019.105834.
- [35] B. Tang, Y. Tu, Z. Zhang, and Y. Lin, "Digital Signal Modulation Classification With Data Augmentation Using Generative Adversarial Nets in Cognitive Radio Networks," *IEEE Access*, vol. 6, pp. 15713–15722, Mar. 2018, doi: 10.1109/ACCESS.2018.2815741.
- [36] Z. Q. Zhao, P. Zheng, S. T. Xu, and X. Wu, "Object Detection with Deep Learning: A Review," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, Nov. 2019, doi: 10.1109/TNNLS.2018.2876865.
- [37] T. O'Shea, T. Roy, and T. C. Clancy, "Learning robust general radio signal detection using computer vision methods," *Conference Record of 51st Asilomar Conference on Signals, Systems and Computers, ACSSC 2017*, vol. 2017-October, pp. 829–832, Jul. 2017, doi: 10.1109/ACSSC.2017.8335463.
- [38] T. Le Truong, N. T. Le, and W. Benjapolakul, "An Application of Deep Learning YOLOv5 Framework to Intelligent Radio Spectrum Monitoring," *ITC-CSCC 2022 - 37th International Technical Conference on Circuits/Systems, Computers and Communications*, pp. 1031–1034, 2022, doi: 10.1109/ITC-CSCC55581.2022.9894862.
- [39] H. N. Nguyen, M. Vomvas, T. Vo-Huu, and G. Noubir, "Wideband, Real-time Spectrooral RF Identification," *MobiWac 2021 - Proceedings of the 19th ACM International Symposium on Mobility Management and Wireless Access*, pp. 77–86, Nov. 2021, doi: 10.1145/3479241.3486688.

- [40] S. Basak, S. Rajendran, S. Pollin, and B. Scheers, "Combined RF-Based Drone Detection and Classification," *IEEE Trans. Cogn. Commun. Netw.*, vol. 8, no. 1, pp. 111–120, Mar. 2022, doi: 10.1109/TCCN.2021.3099114.
- [41] A. Vagollari, V. Schram, W. Wicke, M. Hirschbeck, and W. Gerstacker, "Joint Detection and Classification of RF Signals Using Deep Learning," *IEEE Vehicular Technology Conference*, vol. 2021-April, Apr. 2021, doi: 10.1109/VTC2021-SPRING51267.2021.9449073.
- [42] A. Azari and M. Masoudi, "Interference management for coexisting Internet of Things networks over unlicensed spectrum," *Ad Hoc Networks*, vol. 120, p. 102539, Sep. 2021, doi: 10.1016/J.ADHOC.2021.102539.
- [43] A. Lavric and V. Popa, "Performance Evaluation of LoRaWAN Communication Scalability in Large-Scale Wireless Sensor Networks," *Wirel. Commun. Mob. Comput.*, vol. 2018, 2018, doi: 10.1155/2018/6730719.
- [44] "LoRaWAN® Specification v1.0.3." Accessed: Jun. 06, 2023. [Online]. Available: <https://resources.lora-alliance.org/technical-specifications/lorawan-specification-v1-0-3>
- [45] A. Ioan Petrariu, M. Partemie Marian, A. Lavric, and E. Coca, "A Study on LoRa Signal Propagation Models in Urban Environments for Large-scale Networks Deployment," *Advances in Electrical and Computer Engineering*, vol. 21, no. 4, p. 2021, 2021, doi: 10.4316/AECE.2021.04007.
- [46] A. Lavric, V. Popa, I. Finis, A. M. Gaitan, and A. I. Petrariu, "Packet error rate analysis of IEEE 802.15.4 under 802.11g and bluetooth interferences," *2012 9th International Conference on Communications, COMM 2012 - Conference Proceedings*, pp. 259–262, 2012, doi: 10.1109/ICCOMM.2012.6262616.
- [47] R. Tandra and A. Sahai, "SNR walls for signal detection," *IEEE Journal on Selected Topics in Signal Processing*, vol. 2, no. 1, pp. 4–17, Feb. 2008, doi: 10.1109/JSTSP.2007.914879.
- [48] "spectrumHiveDatasets/spectrumHive_IoT_Dataset_IQstream.md at main · WirelessLabUSV/spectrumHiveDatasets · GitHub." Accessed: Oct. 08, 2025. [Online]. Available: https://github.com/WirelessLabUSV/spectrumHiveDatasets/blob/main/spectrumHive_IoT_Dataset_IQstream.md
- [49] P.-M. Mutescu, V. Popa, and A. Lavric, "Artificial Intelligence Noise Estimation for Adaptive Energy Detection in Dynamic Radio Environments," pp. 1–5, Jan. 2026, doi: 10.1109/isgtmiddleeast65737.2025.11314420.
- [50] P.-M. Mutescu, A. Lavric, Petrariu Adrian-Ioan, and Popa Valentin, "AI-Powered Capabilities for IoT Spectrum Sensing Applications," in *International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA)*, 2025.
- [51] P.-M. Mutescu, V. Popa, and A. Lavric, "LoRa Communications Spectrum Sensing Based on Artificial Intelligence: IoT Sensing," *Sensors* 2025, Vol. 25, Page 2748, vol. 25, no. 9, p. 2748, Apr. 2025, doi: 10.3390/S25092748.
- [52] P. M. Mutescu, A. Lavric, A. I. Petrariu, A. M. Cailean, and V. Popa, "Radio Spectrum Sensing Framework for Large-Scale, High-Density IoT Sensor Networks," *IEEE Access*, 2025, doi: 10.1109/ACCESS.2025.3558746.

- [53] A. Lavric, C. Patachia-Sultanoiu, R. M. Mihai, and P.-M. Mutescu, “AI-Powered Spectrum Sensing Capabilities for Future Networks Beyond 5G,” *2024 15th International Conference on Information, Intelligence, Systems & Applications (IISA)*, pp. 1–7, Jul. 2024, doi: 10.1109/IISA62523.2024.10786649.
- [54] P. M. Mutescu, A. Lavric, and V. Popa, “Dataset Creation Strategies for Future AI-based Radio Spectrum Sensing Applications ,” in *2025 International Conference on Control, Automation and Diagnosis (ICCAD’25)* , 2025.
- [55] “spectrumHiveDatasets/spectrumHive_LoRa.md at main · WirelessLabUSV/spectrumHiveDatasets · GitHub.” Accessed: Oct. 08, 2025. [Online]. Available: https://github.com/WirelessLabUSV/spectrumHiveDatasets/blob/main/spectrumHive_LoRa.md