

Universitatea "Politehnica" din București
Facultatea de Electronică, Telecomunicații și Tehnologia Informației

**Metode de detecție a semnalelor audio specifice
destinate implementărilor de tip *embedded*, cu
aplicații în prevenirea exploatărilor forestiere
ilegale**

Lucrare de disertație

prezentată ca cerință parțială pentru obținerea titlului de
Master în domeniul *Telecomunicații*
programul de studii de masterat *Tehnologii multimedia în
aplicații de biometrie și securitatea informației*

Conducător științific:
Prof. dr. Inginer Burileanu Corneliu

Absolvent:
Gaiță Andrei

Anul 2018

TEMA LUCRĂRII DE DISERTAȚIE
a masterandului **GAÎȚĂ D. Andrei , 421-BIOSINF**

1. Titlul temei: Metode de detecție a semnalelor audio specifice destinate implementărilor de tip embedded, cu aplicații în prevenirea exploatărilor forestiere ilegale

2. Descrierea contribuției originale a masterandului (în afara părții de documentare):

- Evidențierea comparativă a rezultatelor metodelor reprezentând starea artei în domeniul temei de cercetare.
- Proiectarea și construirea unei baze de semnale audio specifice.
- Testarea unor metode de detecție a sunetului produs de motofierăstrău atât cu baza de date proprie cât și cu o altă bază de date de referință disponibilă.
- Implementarea metodei care oferă cele mai bune rezultate pentru scopul propus, pe o platformă embedded.
- Se vor trage concluzii asupra rezultatelor practice obținute și a contribuției originale și se vor enunța perspective ulterioare de cercetare.

3. Resurse folosite la dezvoltarea proiectului:

Pentru testarea metodelor și analiza rezultatelor se va folosi mediul de simulare MATLAB, iar platforma embedded va fi reprezentată de un sistem de calcul Raspberry Pi.

4. Proiectul se bazează pe cunoștințe dobândite în principal la următoarele 3-4 discipline:

Interfațare vizuală om-mașină, Tehnici de analiză și clasificare automată a informației

5. Proprietatea intelectuală asupra proiectului aparține: masterandului

6. Data înregistrării temei: 2017-12-03 23:18:13

Conducător(i) lucrare,
Prof. dr. ing. Corneliu BURILEANU

semnătura:

Responsabil program master,
Prof. dr. ing. Dragoș BURILEANU

semnătura:

Student,

semnătura:

Decan,
Prof. dr. ing. Cristian NEGRESCU

semnătura:

Cod Validare: **532ab4a645**

Declarație de onestitate academică

Prin prezenta declar că lucrarea cu titlul "*Metode de detectie a semnalelor audio specifice destinate implementărilor de tip embedded, cu aplicații în prevenirea exploatărilor forestiere ilegale*", prezentată în cadrul Facultății de Electronică, Telecomunicații și Tehnologia Informației a Universității "Politehnica" din București ca cerință parțială pentru obținerea titlului de Master în domeniul *Inginerie Electronică și Telecomunicații*, programul de studii **BIOSINF**, este scrisă de mine și nu a mai fost prezentată niciodată la o facultate sau instituție de învățământ superior din țară sau străinătate.

Declar că toate sursele utilizate, inclusiv cele de pe Internet, sunt indicate în lucrare, ca referințe bibliografice. Fragmentele de text din alte surse, reproduse exact, chiar și în traducere proprie din altă limbă, sunt scrise între ghilimele și fac referință la sursă. Reformularea în cuvinte proprii a textelor scrise de către alți autori face referință la sursă. Înțeleg că plagiatul constituie infracțiune și se sancționează conform legilor în vigoare.

Declar că toate rezultatele simulărilor, experimentelor și măsurărilor pe care le prezint ca fiind făcute de mine, precum și metodele prin care au fost obținute, sunt reale și provin din respectivele simulări, experimente și măsurători. Înțeleg că falsificarea datelor și rezultatelor constituie fraudă și se sancționează conform regulamentelor în vigoare.

București, iunie 2018

Absolvent *Andrei GAIȚĂ*



(semnătura în original)

CUPRINS

Lista Figurilor
Lista Tabelelor
Lista Acronimelor

Introducere.....15

Cap. 1 Metode de detecție a modelelor audio

1.1 Scurtă introducere 17
1.2 Concepte de bază și terminologie 18
1.3 Clasificatori discriminatori..... 19
1.4 Clasificatori non-discriminatori. Modele Markov ascunse..... 21

Cap. 2 Metode de detecție audio a drujbelor din starea artei

2.1 Metoda TESPAR..... 23
2.2 Metode bazate pe funcția de autocorelație 25
2.3 Analiza computațională a scenei audio (CASA)..... 30
2.4 Metoda LPC 33
2.5 Metoda MFCC 37

Cap. 3 Metoda propusă de detecție audio a drujbelor

3.1 Fundamente teoretice 39
3.2 Motivația metodei propuse..... 41
3.3 Construirea bazei de date 44
3.4 Prezentarea metodei propuse..... 45
3.5 Rezultate obținute..... 47
3.6 Implementarea metodei propuse pe un sistem *Embedded* 48

Cap. 4 Comparatie între metoda propusă și metodele din starea artei.....49

Concluzii.....51

Anexa 155

Lista figurilor

- Figura 1.1 - Relația de definire a perceptronului
- Figura 1.2 - Fluxul de semnal al operației matematice MLP
- Figura 1.3 - Rețea neurală MLP
- Figura 1.4 - Planul punctelor divizate în două categorii
- Figura 1.5 - Relația distribuției compuse
- Figura 2.1 - Procesul de limitare a amplitudinii
- Figura 2.2 - Rezultatul autocorelației în cazul sunetului produs de drujbă (în stânga) și în cazul unui sunet produs de vânt (în dreapta)
- Figura 2.3 - Rata de identificări cu succes folosind diferiți arbori de decizie
- Figura 2.4 - Rata de identificări pozitive normalată la rata de identificări negative
- Figura 2.5 - Relația funcției de autocorelație
- Figura 2.6 - Primul element al secvenței de autocorelație
- Figura 2.7 - Distanța medie dintre două maxime locale
- Figura 2.8 - Variația distanțelor dintre maximele locale
- Figura 2.9 - Schemă bloc ce ilustrează cei doi pași din topologia pentru detecția prezenței umane în mediile naturale
- Figura 2.10 - Funcția de estimare (predicție)
- Figura 2.11 - Eroarea de predicție
- Figura 2.12 - Funcția de transfer a filtrului FIR
- Figura 2.13 - Varianta erorii de predicție
- Figura 2.14 - Informația de conținut a nodului N
- Figura 2.15 - Subclasele stânga-dreapta (NO-YES)
- Figura 2.16 - Schema bloc a metodei de detecție MFCC
- Figura 2.17 - Funcția spectrului de putere trecută printr-un filtru trece bandă triunghiular
- Figura 2.18 - Funcția MFCC
- Figura 3.1 - Forma semnalului audio. Spectrul de frecvență al semnalului audio
- Figura 3.2 - Spectrogramă cuvântului *stamp*
- Figura 3.3 - Spectrograme drujbă - funcționare activă vs. funcționare în gol
- Figura 3.4 - Spectrograma sunetului ambiental de pădure
- Figura 3.5 - Spectrograma sunetului produs de vânt
- Figura 3.6 - Spectrograma sunetului produs de drujbă
- Figura 3.7 - Schema bloc a procesului de clasificare a semnalelor audio
- Figura 3.8 - Performanțele metodei propuse
- Figura 3.9 - Curba ROC a metodei propuse
- Figura 4.1 - Acuratețea generală a metodelor comparate
- Figura 4.2 - Curbele ROC aferente metodelor comparate

Lista tabelelor

Tabelul 2.1- Matricea de confuzie (în procente %) a arborelui de decizie ADT

Tabelul 2.2 - Descriptorii audio MPEG-7 de nivel redus

Tabelul 2.3 - Structura bazei de date audio

Tabelul 2.4 - Matricea de confuzie pentru sunete specifice activității umane

Tabelul 2.5 - Matricea de confuzie pentru sunete specifice naturale

Tabelul 3.1 - Distribuția bazei de date

Lista acronimelor

3G = Third Generation

ADT = Alternating Decision Tree

CASA = Analiza computațională a scenei audio

DCT = Transformata Cosinus Discretă

FFT = Fast Fourier Transform

FIR = Filtru cu răspuns finit la impuls

FNR = False Negative Rate

FPR = False Positive Rate

GMM = Gaussian Mixture Model

HMM = Hidden Markov Model

LLD = Low Level Descriptor

LPC = Linear Prediction Coder

MFCC = Mel-frequency cepstrum

MLP = Multilayer Perceptron

MPEG-7 = Multimedia content description interface

PWP = Pachet integrat de analiză perceptuală wavelet

RF = Random Forests

ROC = Receiver operating characteristic

SNR = Signal-Noise Ratio

STI = Short Time Intensity

SVM = Support Vector Machines

TESPAR = Time Encoded Signal Processing and Recognition

TNR = True Negative Rate

TPR = True Positive Rate

WiMAX = Worldwide Interoperability for Microwave Access

Introducere

Despăduririle ilegale devin o amenințare majoră pentru mediul înconjurător, având un impact devastator asupra pădurilor din întreaga lume. Printre efectele sale numărăm pierderi de biodiversitate și schimbări climatice.

Există diverse soluții pentru rezolvarea problemei despăduririlor. Una dintre acestea este monitorizarea pădurilor prin intermediul imaginilor satelitare de înaltă rezoluție și detecția schimbărilor ce intervin, folosind metode de procesare a imaginilor. Marele dezavantaj al imaginilor satelitare este acela că procesarea imaginilor nu se face în timp real. Astfel, o detecție reușită poate apărea prea târziu, atunci când o zonă întinsă de pădure este deja pierdută. Pentru a minimiza aceste pierderi, trebuie dezvoltat un sistem de alarmare sau notificare imediat după observarea unei mici schimbări în mediul respectiv. Un astfel de sistem s-ar dovedi mai eficient datorită faptului că detecția este făcută în timp real, iar timpul de răspuns al autorităților responsabile este mai mic. De exemplu, un sistem de monitorizare video precum cel prezentat în [1] poate fi ușor modificat pentru a detecta și tăieri ilegale pe lângă monitorizarea incendiilor. Autorii lucrării [1] propun o rețea video de supraveghere distribuită compusă din camere video digitale conectate la un server de *management* central via comunicației *wireless* (pot fi folosite comunicații Wi-Fi, WiMAX, 3G etc.)

O altă abordare a unui sistem cu răspuns în timp real se bazează pe achiziția și procesarea de sunete. De obicei, în despăduririle ilegale vaste instrumentul cel mai folosit este motofierăstrăul. De aceea, o soluție constă în detecția și urmărirea sunetului produs de un astfel de instrument.

Soluția cunoscută sub numele de *Rainforest Connection* [2] folosește telefoane mobile pentru achiziția și procesarea de sunete, fiind alimentate cu energie solară. Fiecare telefon mobil este atașat la un copac, fiind responsabil cu monitorizarea unei zone specifice. Dispozitivele sunt distribuite uniform în cadrul pădurii, formând o rețea celulară capabilă să detecteze tăieri ilegale de copaci într-o zonă mare a pădurii.

De-a lungul timpului, o problemă majoră în detecția despăduririlor ilegale a fost determinarea exactă a coordonatelor sursei de sunet. În lucrarea [3] autorii prezintă o schemă de principiu pentru implementarea unei topologii de rețea celulară capabilă să determine locația exactă a sunetelor, prin minimizarea costurilor de implementare.

Paragrafele anterioare pun în evidență motivația alegerii acestei teme. Prin intermediul acestei lucrări, propun o nouă metodă de clasificare a semnalelor sonore ce pot fi întâlnite într-o scenă audio din pădure, sunete pe care le încadrez în două clase: cele produse de un motofierăstrău și alte tipuri de sunete. Găsirea unor exemple negative de sunete precum vânt, ploaie, păsări ciripind, animale din pădure și alte sunete nerelaționate cu activități de despădurire, însă prezente în pădure, joacă un rol foarte important la performanța metodei. Mai mult decât atât, discriminarea sunetelor între motoare de fierăstrău și alte tipuri de motoare precum tractoare și motociclete a fost luată în considerare pentru creșterea acurateței detecției. În cazul exemplelor pozitive, distanța dintre dispozitivul de achiziție și sursa de sunet trebuie să fie cât mai variată astfel încât să se obțină un sistem eficient, capabil să clasifice sunetele dintr-o anumită zonă. Pe parcursul dezvoltării sistemului, construirea bazei de date a fost un pas major și deloc neglijat.

Lucrarea de față este structurată în 4 capitole, după cum urmează: primul capitol introduce noțiunile de bază ale determinării și clasificării sunetelor, al doilea capitol pune în evidență cele mai frecvente metode de detecție a sunetelor din starea artei, următorul capitol descrie pe larg metoda propusă, iar în ultimul capitol se prezintă rezultatele metodei propuse, comparative cu alte metode convenționale.

Capitolul 1

Metode de detecție a modelelor audio

1.1 Scurtă introducere

Distrugerea constantă a mediului natural se dovedește tot mai mult a fi în detrimentul vieții noastre, iar nevoia urgentă de a soluționa această gravă problemă nu mai poate fi evitată. Există multe regiuni considerate a fi rezervații naturale, a căror protecție survine din cauza pagubelor deja aduse zonei sau pentru prevenirea acestora în viitor. În ciuda anumitor măsuri luate de către autorități, implicarea oamenilor în activități ilegale precum tăierea ilegală a copacilor, nu poate fi întotdeauna descoperită la timp. Această activitate este una dintre cele mai periculoase care duc la despăduriri rapide, lucru care s-a și întâmplat în ultimele decenii pe întreaga planetă. De aici provin multe probleme sociale și de mediu, precum eliminarea biodiversității, schimbări climatice, alunecări de teren, inundații frecvente și chiar dispariția anumitor specii de animale care trăiesc doar în pădure. Nu în ultimul rând, replantarea altor copaci și ajungerea acestora la maturitate necesită o perioadă îndelungată de timp și nu pot fi reparate multe dintre problemele enumerate înainte.

Detecția imediată a activităților ce pot amenința mediul natural este vitală pentru a limita consecințele negative cât mai mult. Monitorizarea constantă a anumitor regiuni este necesară pentru a prevedea conservarea acestora. Totuși, supervizarea unei astfel de regiuni pentru o singură zi ajunge la costuri foarte ridicate, iar unele zone sunt greu de accesat în persoană. În multe cazuri, simpla prezență umană poate periclita ceea ce trebuie de fapt protejat. Din cauza acestor impedimente, se recurge la metode de supervizare autonome și neasistate cunoscute sub numele de monitorizare automată. Sistemul propus este unul de supraveghere audio, pentru a diferenția sunetele activităților umane față de sunetele mediului natural.

În momentul actual există o serie de astfel de sisteme destinate detecției sunetelor de drujbă sau alte altor instrumente de tăiere a copacilor. Un exemplu este proiectul *Rainforest Connection* [1], care folosește tehnologia telefoanelor mobile inteligente cu sistemul de operare Android și capacitatea acestora de înregistrare audio pentru a determina dacă sunetele din pădure sunt produse de instrumente de tăiat copaci, sau sunt sunete naturale, specifice mediului respectiv (ploaie, animale, vânt etc.). Aceste telefoane mobile inteligente sunt montate în diverse puncte cheie din pădure, pentru a acoperi o suprafață cât mai mare, au datele mobile pornite constant, cu ajutorul cărora transmit datele audio înregistrate către un server central care realizează detecția audio. Acestea sunt alimentate cu ajutorul energiei solare. Acest simplu sistem are multiple avantaje, precum: capacitatea de alertare a localnicilor cu ajutorul unei alarme într-un timp foarte scurt de la detecția unui sunet malițios, spre deosebire de sistemele ce folosesc imagini satelitare (o alarmă poate fi declanșată cu o întârziere de câteva zile de la preluarea acesteia), instrumentele și tehnologiile folosite nu sunt create special pentru această întrebuințare, iar costurile lor sunt destul de scăzute având în vedere nivelul de dezvoltare tehnologică actuală, detecția sunetului de drujbă se face pe o rază de 1 km, ceea ce reprezintă o distanță remarcabilă.

1.2 Concepte de bază și terminologie

Recunoașterea sunetului se bazează pe presupunerea că fiecare sursă de sunet pune în evidență un model acustic consistent, a cărui reprezentare este specifică modului de distribuție a energiei. Acest model unic poate fi descoperit și construit prin utilizarea algoritmilor de recunoaștere statistică a modelelor. În cadrul comunității specialiștilor în recunoașterea de sunete, există două tipuri de clasificatori utilizați în acest scop: clasificatori discriminatori și non-discriminatori. Primul tip de clasificatori este folosit pentru aproximarea unei limite între categoriile de date de antrenare. Câteva exemple de clasificatori discriminatori sunt: clasificatorul polinomial [4], perceptronul multi-strat [5] și *Support Vector Machine (SVM)* [6]. Pe de altă parte, clasificatorii non-discriminatori sunt folosiți pentru estimarea distribuției datelor de antrenare. Cele mai reprezentative exemple pentru acest tip de clasificatori sunt modelele mixte Gaussiene [4][5] și modele Markov ascunse [6][7]. Principala caracteristică a acestui tip de clasificatori o reprezintă faptul că operează cu fiecare instanță a unei clase, independent față de celelalte clase.

Într-un context general, clasificarea poate fi definită ca acel proces de învățare a asemănarilor și deosebirilor dintre modele, care reprezintă instanțe ale unor obiecte dintr-o populație de obiecte neidentice. În cadrul unui proces de clasificare, obiectele sunt grupate în clase, conform asemănarilor și deosebirilor sesizate. Astfel, pornind de la attribute specifice fiecărui obiect, se formează clase care descriu proprietățile generale ale obiectelor respective. Obiectivul final al oricărui proces de clasificare este acela de a permite sistemului să identifice/recunoască obiectele din mediul său, pe baza proprietăților ce caracterizează clase de obiecte.

În consecință, în contextul problemei de clasificare, un sistem trebuie să parcurgă două etape:

- *clasificarea*, în cursul căreia sistemul învață caracteristicile generale ale claselor pe baza caracteristicilor specifice instanțelor,
- *recunoașterea*, în cursul căreia sistemul suprapune caracteristicile unei instanțe peste caracteristicile claselor cunoscute și determina clasa căreia aparține instanța respectivă.

Pentru majoritatea rețelelor neuronale artificiale se consideră că, pentru fiecare model din setul de antrenare, se cunosc atât vectorul de intrare, cât și vectorul de ieșire. Algoritmii de antrenare încearcă să modifice structura rețelei (valorile ponderilor conexiunilor și pragurilor neuronilor) astfel încât să asigure o corespondență cât mai bună între intrările și ieșirile rețelei neuronale. Acest model de antrenare este cunoscut sub numele de *învățare supravegheată*. În sinteză, se poate spune că orice model de antrenare pentru care se cunosc mărimile de ieșire intră sub incidența învățării supravegheate.

Există însă numeroase situații practice - mai cu seamă în problemele de clasificare - în care nu se cunoaște în prealabil răspunsul pe care ar trebui să-l furnizeze rețeaua pentru un anumit vector de intrare. În asemenea cazuri ar fi de dorit ca rețeaua să identifice de una singură caracteristicile datelor de intrare. Altfel spus, rețeaua ar trebui să "*înțeleagă*" singură modul în care trebuie să organizeze informația. Asemenea procese sunt cunoscute sub numele de *auto-organizare* sau *învățare nesupravegheată* și tratează cu precădere probleme de clasificare.

În cazul proceselor de auto-organizare, clasificarea mai este denumită și *zonare* (în engleză, *clustering*). Această denumire provine de la dispunerea punctelor corespunzătoare vectorilor de intrare în anumite zone, sub forma unor nori sau ciorchini. În interiorul unei asemenea zone punctele sunt mai apropiate între ele sau în raport cu un centru comun, decât în raport cu centrele altor zone.

1.3 Clasificatori discriminatori

1.3.1 Clasificatorul polinomial

Rețelele polinomiale sunt cunoscute în literatură de mulți ani, având proprietăți excelente sub formă de clasificatori [8][1]. Datorită teoremei Weierstrass, clasificatorii polinomiali au devenit aproximatori universali ai clasificatorului optimal Bayes [9][10].

Metodele tipice de antrenare a clasificatorilor polinomiali sunt bazate în general pe metode statistice sau pe criteriul minimizării erorii pătratice medii. Accentul s-a pus cel mai mult pe clasificatorii polinomiali liniari sau de gradul doi. Ambele metode tradiționale au avut însă limitări. Metodele clasice statistice estimează media și covarianța datelor audio pentru un model parametric. Dezavantajul acestei abordări este reprezentat de faptul că date din afara clasei nu sunt folosite pentru a maximiza performanța. Metodele discriminatoare implică de cele mai multe ori matrici de mari dimensiuni, ceea ce conduce la probleme dificil de rezolvat.

1.3.2 Perceptronul multi-strat (MLP)

MLP reprezintă o rețea formată din neuroni simpli, cunoscuți sub numele de perceptroni [11]. Conceptul de bază de simplu perceptron a fost introdus prima oară de către Rosenblatt în anul 1958. Perceptronul calculează o singură ieșire pe baza unor valori multiple și reale de intrare, prin formarea unei combinații liniare în corelație cu tăria intrărilor, iar mai apoi ieșirile sunt trecute printr-o funcție neliniară de activare. Din punct de vedere matematic, această relație poate fi scrisă sub următoarea formă:

$$y = \varphi\left(\sum_{i=1}^n w_i x_i + b\right) = \varphi(\mathbf{w}^T \mathbf{x} + b)$$

Figura 1.1 - Relația de definire a perceptronului [11]

unde $\mathbf{w}$ = vectorul tărilor intrărilor,
 $\mathbf{x}$ = vectorul intrărilor,
 b = bias,
 φ = funcția de activare.

În figura 1.2 este reprezentat un grafic al fluxului de semnal al acestei operații.

Perceptronul inițial considerat de Rosenblatt folosea pentru funcția de activare o funcție treaptă. În zilele actuale, mai ales în rețelele multistrat, funcția de activare este deseori aleasă ca fiind tangentă hiperbolică sau funcția sigmoid $1/(1 + e^{-x})$. Aceste două funcții sunt utilizate datorită faptului că sunt comode din punct de vedere matematic și datorită faptului că sunt aproape liniare în apropiere de origine și se saturează destul de rapid la îndepărtarea de origine. Acest lucru permite rețelelor cu perceptron multistrat să modeleze la fel de bine atât mapări neliniare puternice sau medii.




Figura 1.2 - Fluxul de semnal al operației matematice MLP [11]




Figura 1.3 - Rețea neurală MLP [11]

Un singur perceptron nu este foarte folositor din cauza capacităților limitate de mapare. Totuși, perceptronii pot fi folosiți ca blocuri de construcții pentru structuri mai mari și mai practice. O rețea cu perceptron multistrat tipică este formată dintr-un set de noduri sursă ce formează un strat de intrare, unul sau mai multe straturi ascunse de noduri de calcul și un strat al valorilor de ieșire. Semnalul de intrare se propagă prin rețea strat cu strat. O astfel de rețea este reprezentată în figura 1.3.

1.3.3 Support Vector Machine (SVM)

SVM reprezintă modele de învățare supervizate, ce au asociat algoritmi de învățare care analizează datele folosite pentru clasificare și analiză [12]. Pentru un set de exemple de antrenare, fiecare marcat ca aparținând unei categorii, un algoritm de antrenare SVM construiește un model ce asignează noi exemple într-o categorie sau în alta. Astfel, acest clasificator este unul liniar, binar și non-probabilistic. În cadrul modelului SVM, exemplele de antrenare sunt reprezentate ca puncte în spațiu, mapate astfel încât exemplele din cadrul unei categorii sunt divizate clar de un gol cât mai lat posibil. Noi exemple sunt mapate în același spațiu și se prezice cărei categorii aparțin.

În mod formal, un SVM construiește un hiperplan sau un set de hiperplanuri într-un spațiu multi-dimensional sau chiar infinit-dimensional, care pot fi folosite pentru clasificare, regresie sau alte cerințe. O separare bună a punctelor în spațiu este realizată în cadrul unui hiperplan care are cea mai mare distanță până la cel mai apropiat punct din cadrul setului de date de antrenare (cunoscută și sub numele de margine).

Situația originală care implică un spațiu finit-dimensional s-a dovedit a nu fi îndeajuns de puternică pentru a separa liniar punctele din spațiu. De aceea, s-a recurs la ideea de spațiu infinit-dimensional, cu presupunerea că separarea punctelor se va face mult mai ușor.




Figura 1.4 - Planul punctelor divizate în două categorii [12]

1.4 Clasificatori non-discriminatori. Modele Markov ascunse

Modelele Markov ascunse (HMM) reprezintă un utilitar impresionant pentru modelarea datelor [13]. Acestea sunt folosite în aproape toate sistemele curente de recunoaștere a vorbirii, în numeroase aplicații de biologie moleculară, în compresia de date și în alte arii de inteligență artificială și recunoaștere de modele. Recent, modelele Markov ascunse au început să fie folosite și în aplicații de *computer vision*.

Modelul Markov ascuns reprezintă o modalitate de a reprezenta distribuții de probabilități pe baza unor secvențe de observare. Observația se face la un anumit moment de timp t , de către o variabilă Y_t . Aceasta poate fi un simbol al unui alfabet discret, o variabilă reală, un întreg sau orice alt obiect, atâta timp cât putem defini o distribuție de probabilitate asupra ei. Putem asuma faptul că observațiile sunt făcute la intervale de timp discrete, egal distanțate, astfel că t poate fi un index de timp de valoare întreagă.

Modelul Markov ascuns are acest nume datorită a două proprietăți definitorii. Prima se referă la faptul că observația de la timpul t a fost generată de către un proces a cărui stare S_t este ascunsă de observator. A doua proprietate stipulează faptul că starea procesului ascuns satisface următoarea proprietate Markov: cunoscând valoarea stării anterioare S_{t-1} , starea curentă S_t este independentă de toate stările anterioare lui $t-1$. În alte cuvinte, starea unui proces la un anumit moment de timp încapsulează toate informațiile necesare pe care trebuie să le cunoaștem legate de istoria procesului, astfel că putem prezice viitorul procesului.

În urma celor prezentate, putem reprezenta distribuția compusă a tuturor secvențelor de stări și de observații într-un produs de tipul:

$$P(S_{1:T}, Y_{1:T}) = P(S_1)P(Y_1|S_1) \prod_{t=2}^T P(S_t|S_{t-1})P(Y_t|S_t),$$

Figura 1.5 - Relația distribuției compuse [13]

Capitolul 2

Metode de detecție audio a drujbelor din starea artei

2.1 Metoda TESPAP

Conceptele TESPAP [14] sunt procesele prin referința la studii de caz recente care pun în evidență clasificări ale semnalelor aflate într-un spectru de frecvențe larg, incluzând lungimi cu una de ordinul nanosecundelor până la lungimi de undă în domeniul sub-Herzi. Caracteristicile de bază ale metodei TESPAP în zona de procesare a vorbirii sunt următoarele:

- capacitatea de a separa și clasifica semnale de interes ce sunt insesizabile în domeniul frecvenței,
- abilitatea de a coda forme de undă variabile în timp ale vorbirii în configurații optime pentru procesare de către rețele neurale artificiale,
- abilitatea de a desfășura, din punct de vedere economic, arhitecturi paralele masive pentru producerea fuziunii de date.

În cadrul literaturii de specialitate a teoriei informației, prima teoremă a lui Shannon legată de eșantionarea unui semnal analog stă la baza unei varietăți de transformări liniare, precum Fourier sau predicția liniară. Astfel, strategiile de codare actuale implică un grup de trei necesități:

- a) utilizarea descriptorilor de amplitudine,
- b) utilizarea eșantionării uzuale,
- c) un domeniu de aproximare, bazat fie pe magnitudine, fie pe amplitudine, dependent de numărul de biți per eșantion, număr folosit pentru a procesa valorile eșantionate în ordine.

În aceeași perioadă cu faimoasa lucrare a matematicianului Shannon care a enunțat teorema eșantionării, alți oameni de știință investigau efectele "limitării amplitudinii" pentru formele de undă ale semnalului vocal, un proces folosit pe larg în comunitatea amatorilor radio. În continuare, conceptul de limitare a amplitudinii a fost extins către formatul de limitare infinită, la care toată informația despre amplitudine este eliminată din cadrul semnalului, rezultând o transformare binară ce conservă doar punctele de trecere prin 0 ale semnalului original. Folosind metoda limitării amplitudinii, inteligibilitatea aleatoare a cuvintelor din cadrul unui semnal vocal atingea un scor de aproximativ 97.9%, lucru ce demonstrează clar faptul că o proporție substanțială a informației de interes din cadrul unui semnal de acest tip se află cu precădere în trecerile prin 0. Mai mult decât atât, aceste dovezi pun sub semnul întrebării cele 3 proprietăți a), b) și c) enunțate mai sus. Odată ce s-au eliminat toate informațiile legate de valorile intermediare, eșantioanele obținute reprezintă "durata" intervalelor dintre trecerile prin 0 ale formei de undă. Astfel, aceste durate bazate pe trecerile prin 0 sunt derivate din semnal și nu generate la intervale de timp egale, iar aceste eșantioane vor exista la distanțe inegale. Toate aceste observații au furnizat catalistul intelectual care a rezultat în crearea și dezvoltarea metodei TESPAP.




Figura 2.1 - Procesul de limitare a amplitudinii [14]

Desigur, orice metodă prezintă atât avantaje, cât și dezavantaje. De aceea, câțiva oameni de știință au propus introducerea unui concept în cadrul modelului limitării infinite, fiind cunoscut sub numele de zerouri complexe. Problema practică a extragerii zerourilor, precum construirea unei secvențe de zerouri reale și complexe care să corespundă unei forme de undă date nu este trivială. Zerourile reale ale unei funcții, care reprezintă de fapt convenționalele treceri prin 0 ale semnalului sunt mult mai ușor de determinat decât zerourile complexe. Inspectia vizuală a formei de undă ar putea furniza informații legate de locația a câteva zerouri complexe, însă singura metodă cantitativă cunoscută pentru a găsi locația tuturor zerourilor complexe implică factorizarea numerică a $2TW^{th}$ - ordinul unei polinom trigonometric. Calculul unei astfel de funcții nu este fezabil, de aceea metoda TESPAP nu folosește de acest calcul. Procedura propusă de TESPAP presupune segmentarea semnalului între zerouri reale succesive și combinarea acestei durate cu aproximări simple ale formei semnalului între aceste două locații. Mai simplu, determinarea și clasificarea zerourilor complexe se poate face direct din forma de undă.

Într-o astfel de împărțire a semnalului în zerouri reale și complexe, se observă faptul că zerourile reale din domeniul timp sunt identice cu locațiile zerourilor reale din domeniul zero. Zerourile complexe apar în perechi conjugate, ce sunt asociate cu perturbări precum minime, maxime, puncte de inflexiune. În cadrul celei mai simple implementări TESPAP, doar doi descriptori asociați fiecărui segment pot fi folosiți pentru a genera un alfabet de simboluri TESPAP de bază:

- durata dintre 2 zerouri reale succesive,
- forma semnalului între cele 2 zerouri succesive.

În modelul de bază TESPAP nu toate zerourile complexe pot fi identificate din forma semnalului, ceea ce înseamnă că aproximarea este limitată doar la acele zerouri ce pot fi determinate. Fiecare segment al semnalului eșantionat poate fi clasificat cu ajutorul a două elemente: durata (D) și numărul de minime (S).

2.2 Metode bazate pe funcția de autocorelație

2.2.1 Detecție simplă bazată pe metoda autocorelației

2.2.1.1 Descriere generală

Această primă metodă de detecție audio a drujbelor este menționată în lucrarea [15], ținându-se cont de limitările unui dispozitiv *embedded* care are capacitatea de a capta sunetul extern și de a realiza o procesare ușoară asupra acestuia, pentru ca apoi să transmită datele prin GPRS către o stație de bază aflată în apropiere. Aceste dispozitive *embedded* au capacitatea de a înregistra sunete cu frecvență de eșantionare mare. Totuși, deoarece sunetele produse de un motofierăstrău au frecvență joasă, iar memoria dispozitivului *embedded* utilizat este limitată, se folosește o frecvență de eșantionare de 8333 Hz, cu 10 biți per eșantion. Pentru a ușura calculele și pentru minimizarea volumului de date, se realizează o decimare cu un raport 1:4 și o filtrare trece-jos, cu ajutorul unui filtru FIR. Pentru a putea face o detecție corectă într-un interval de distanțe 0-50 metri față de dispozitiv, s-a implementat un mecanism de auto-reglaj al amplitudinii. În urma acestor optimizări, dispozitivul *embedded* are capacitatea de a stoca și de a procesa un număr de 4 eșantioane audio succesive, fiecare dintre acestea cu o durată de 1.8 secunde.

2.2.1.2 Extragerea parametrilor

Conform lucrării [16], se cunoaște faptul că sunetul produs de motoarele drujbelor se încadrează între 100 și 300 Hz, caracteristică ce depinde de producător și de versiunea motorului. Pot exista și alte surse acustice care să producă sunete în aceeași gamă de frecvențe, însă sunetul motorului de drujbă are o amprentă spectrală diferită. S-ar putea folosi spectrul de frecvențe ca parametru de detecție, însă calculul transformatei Fourier rapide depășește cu mult capacitatea de procesare a dispozitivului *embedded* utilizat de autorii lucrării precizate anterior, astfel că este nevoie de o altă soluție în acest sens. Aceștia au decis în final să folosească funcția de autocorelație, deși pare să aibă o complexitate de calcul mai mare ($n \times n$), spre deosebire de transformata Fourier ($n \times \log n$), însă ambii termeni ai sumei sunt valori ale eșantioanelor semnalului și se exclude din start calculul unei funcții exponențiale.

Formula generală a funcției de autocorelație este următoarea:

$$R(m) = \sum_{n=-\infty}^{\infty} s_n \cdot s_{n+m}$$

în timp ce în cazul de față aceasta este:

$$R(m) = \sum_{n=0}^{|s|} (s_n - \bar{s}) \cdot (s_{((n+m) \bmod |s|)} - \bar{s})$$

unde s_n este eșantionul de intrare nr. n , $\bar{s}$ este media acestora și $|s| = 256$ este nr. de eșantioane de intrare. Rezultatul acestei funcții este ilustrat în figura 2.2 unde se poate observa diferența dintre un sunet produs de un motofierăstrău și un sunet produs de vânt.




Figura 2.2 - Rezultatul autocorelației în cazul sunetului produs de drujbă (în stânga) și în cazul unui sunet produs de vânt (în dreapta) [15]

Se poate observa din figura 2.2 că funcția de autocorelație prezintă maxime periodice în cazul sunetului produs de drujbă, în timp ce în cazul sunetului produs de vânt nu există caracteristici vizibile definitorii. Pentru început se determină maximul local, după care se efectuează extragerea unor parametri din această funcție. În continuare, sunt calculate următoarele caracteristici:

- distanța medie între maximele locale max_i :

$$avgDist = \frac{1}{|max|} \sum_{i=1}^{|max|} dist_i$$

unde max este numărul de maxime locale și

$$dist_i = poziție(max_i) - poziție(max_{i-1})$$

- varianța distanței între minimele locale:

$$varianța = \frac{1}{|max|} \sum_{i=1}^{|max|} (dist_i - avgDist)^2$$

- numărul de maxime locale:

$$|max|$$

- energia pe termen scurt a semnalului de intrare:

$$STE = \sum_{n=0}^{|S|} s_n^2, n \in N$$

2.2.1.3 Clasificarea la nivelul fiecărui dispozitiv

Conform precizărilor anterioare, memoria dispozitivului este limitată ceea ce impune stocarea a maxim 4 eşantioane, fiecare cu o durată maximă de 1/8 secunde. Durata de extragere şi de clasificare a parametrilor este de 3 secunde. Clasificarea s-a făcut folosind diferiţi arbori de decizie şi anume : *Alternating Decision Tree* (ADT) [17], *Best-First decision tree* [18], *Decision Stump* [19], *J48* (C4.5) [20], *J48Graft* (grafted C4.5) [21], *LogitBoost Alternating Decision Tree* (LADTree) [17], *Random Forest* [22], *Random Tree* [19], *Reduced-Error Pruning Tree* [19], *Simple Classification and Regression Tree* (CART) [23]. Pentru recunoaşterea tiparelor, arborii de decizie sunt buni clasificatori, iar principalele avantaje în această situaţie sunt: implementare facilă, care necesită un nivel scăzut de memorie şi sunt destul de rapizi.




Figura 2.3 - Rata de identificări cu succes folosind diferiţi arbori de decizie [15]

Figura 2.3 ilustrează rata identificării cu succes, în care se folosesc mai mulţi clasificatori bazaţi pe arbori de decizie, evaluaţi pe prima de bază. Pentru o imagine de ansamblu a acestor date, trebuie luate în considerare rata de identificare negativă şi alarmă falsă, deoarece într-un sistem real de supraveghere o intervenţie a echipajului uman ar produce costuri suplimentare. Astfel, în figura 2.4 se observă rata de identificare cu succes raportată la numărul de alarme false produse de fiecare algoritm de clasificare în parte:




Figura 2.4 - Rata de identificări pozitive normalată la rata de identificări negative [15]

Analizând figura 2.4, observăm că algoritmul de clasificare ADT oferă cel mai bun rezultat, atât din punctul de vedere al identificărilor pozitive, cât și din punctul de vedere al celor negative. ADT (arbore de decizie alternativă) este construit din clasificatoare slabe. Pentru a obține rezultate cu o performanță mai ridicată se poate folosi o tehnică de îmbunătățire (*boosting*). La ieșirea acestui clasificator binar avem un număr real între 1 și 100. Clasificarea binară se face setând un prag pentru valoarea de la ieșire, de regulă 50. În Tabelul 2.1 este prezentată matricea de confuzie pentru arborele ADT.

Sunet	Decizie	
	Motofierăstrău	Altceva
Motofierăstrău	76.19	23.81
Altceva	2.67	97.33

Tabelul 2.1- Matricea de confuzie (în procente %) a arborelui de decizie ADT [15]

2.2.2 Detecția acustică bazată pe analiza parametrilor extrași din autocorelația semnalului

Metoda propusă are la bază informații esențiale, precum banda de frecvență în care se găsesc cele mai importante esențiale spectrale din semnalul sonor produs de un motofierăstrău. Implementarea unor algoritmi complecși cu ajutorul unui sistem *embedded* presupune o serie de probleme referitoare la timpul de calcul până la obținerea rezultatelor (riscându-se astfel pierderea unor informații) și la aspectul energetic: reducerea timpului de calcul implică un sistem mai performant, dar în majoritatea cazurilor acesta va impune o putere electrică ridicată. Ne propunem astfel implementarea unui algoritm care să fie capabil de realizarea unei decizii binare pe baza unor criterii cât mai simple.

Calculul funcției de autocorelație poate avea o complexitate ridicată de calcul, mai ales din punct de vedere temporal. Funcția de autocorelație a unei secvențe de lungime finită (s_n), cu $|s|$ elemente, este următoarea:

$$R_{ss}(m) = \sum_{n=0}^{|s|} (s_n - \bar{s})(s_{((n+m) \bmod |s|)} - \bar{s})$$

Figura 2.5 - Relația funcției de autocorelație

unde $\bar{s}$ reprezintă media secvenței. Datorită simetriei ecuației, aceasta trebuie calculate doar pentru $m = 0, 1, 2, \dots, \frac{|s|}{2}$.

În cadrul metodei autocorelației, se calculează valoarea a patru descriptori ai secvenței de autocorelație:

- STI (Short Time Intensity) - primul element al secvenței autocorelației:

$$STI = R_{ss}(0) = \sum_{n=0}^{|s|} s_n^2, n \in$$

Figura 2.6 - Primul element al secvenței autocorelației

- numărul maximelor locale (N_p) în funcția $R_{ss}(m)$. Se consideră că fiecare vârf al secvenței de autocorelație este un maxim local dacă valoarea sa este mai mare decât un anumit prag (α) ce depinde de STI și dacă nu mai are niciun alt maxim într-o fereastră de căutare dată (lățimea ferestrei este β).
- distanța medie dintre două maxime locale:

$$avgDist = \frac{1}{N_p - 1} \sum_{i=2}^{N_p} D_i$$

Figura 2.7 - Distanța medie dintre două maxime locale

unde D_i reprezintă distanța dintre ith și vârful $i - ith$.

- variația distanțelor dintre maximele locale (uniformitatea frecvenței fundamentale):

$$variance = \frac{1}{N_p - 1} \sum_{i=2}^{N_p} (D_i - avgDist)^2$$

Figura 2.8 - Variația distanțelor dintre maximele locale

În cadrul celor 4 descriptori, STI poate fi considerat un descriptor slab, deoarece depinde în mare parte de setările de câștig și de distanța dintre microfon și sursa sunetului. Totuși, valoarea acestui descriptor poate fi normalizată înainte de clasificare, știind valorile de câștig ale amplificatorului.

În cadrul creării unui sistem de clasificare eficient, nu doar descriptorii trebuie să fie creați corespunzător, ci și mecanismele de decizie, pentru a genera rezultate precise și corecte. Există multe instrumente bine cunoscute de clasificare ce pot fi considerate, precum rețelele neurale, SVM, arbori de decizie. Limitările platformei *hardware* legate de puterea de calcul și utilizarea memoriei trebuie avute în vedere. Arborii de decizie pot fi ușor aplicați, există mecanisme de comparare ușor de aplicat cu ajutorul operațiilor cu valori întregi (spre deosebire de SVM, care evaluează cereri prin adunări și înmulțiri de numere reale).

2.3 Analiza computațională a scenei audio (CASA)

2.3.1 Descriere

Lucrarea [24] propune o abordare folosind tehnologia CASA [25], o tehnologie în continuă dezvoltare care își propune descrierea completă a unei scene acustice cu ajutorul unei serii de metode și algoritmi. Pentru a realiza o descriere completă a unei scene acustice este nevoie de separarea surselor de sunet diferite, localizarea acestora în contextul scenei și recunoașterea individuală a fiecăreia în parte. Lucrarea [25], considerată una de referință în acest domeniu, pune în evidență principii de bază, algoritmi, arhitecturi de sisteme și potențiale aplicații pentru această tehnologie. Lucrarea abordează diverse metode absolut necesare într-un sistem CASA:

- estimarea multipleror frecvențe fundamentale,
- abordări CASA bazate pe vectori de caracteristici și modele,
- separarea sunetelor bazată pe localizarea în spațiu,
- tehnici de procesare audio în medii reverberant,
- separarea semnalului de vorbire față de semnalul de muzică,
- recunoașterea automată a vorbirii în medii cu zgomot,
- modelarea neurală a scenei audio.

Lucrarea menționată anterior este structurată în două mari părți: prima abordează extragerea și analiza seturilor de caracteristici pe baza cărora se va face clasificarea, iar cea de-a doua parte pune în evidență modul de aplicare a algoritmilor modelelor Markov ascunse (HMM) pentru rezolvarea problemelor de detecție și clasificare a sunetelor.

2.3.2 Parametri acustici

În cadrul lucrării de față, se folosesc 3 tipuri de parametri acustici pentru clasificare:

- *coeficienți Mel-Cepstrali (MFCC)* : sunt folosiți 23 astfel de coeficienți. După filtrarea transformatei Fourier rapide cu un banc de filtre triunghiulare în scară Mel a ferestrelor de semnal, se aplică logaritmarea și transformata Cosinus Discretă (**DCT**) pentru a obține acești parametri. Aceștia sunt importanți din punctul de vedere al percepției umane asupra sunetelor. Ultima etapă din acest algoritm de extragere este foarte importantă, având rolul de a decorela datele, folosind puține resurse computaționale.
- *descriptori audio MPEG-7 de nivel redus (LLD)* : protocolul audio MPEG-7 oferă o serie de unelte cu scopul de a genera automat un descriptor capabil să ilustreze informații esențiale despre semnalul audio. Acești parametri sunt prezentați în Tabelul 3.2. iar o prezentare mai detaliată se poate găsi în lucrarea [15].

Descriptor	Dimensiune	Abreviere
Audio Waveform	2	AW
Audio Power	1	AP
Audio Specrum Centroid	1	ASC
Audio Spectrum Spread	1	ASS
Audio Spectrum Flatness	19	ASF
Harmonic ratio	1	HR
Upper Limit of Harmonicity	1	ULH
Audio Fundamental Frequency	1	AFF

Tabelul 2.2 - Descriptorii audio MPEG-7 de nivel redus [24]

- *pachet integrat de analiză perceptuală wavelet (PWP)*: parametrii acustici prezentați în tabelul 2.2 oferă o definiție a semnalului atât în domeniul timp, cât și în domeniul frecvență. Lucrarea [15] pune în evidență cum parametri din domenii diferite pot îmbunătăți performanța de clasificare a întregului sistem. Spre deosebire de sinusoidalele predictibile, funcțiile *wavelet* tind să fie neregulate și asimetrice.

Cei trei parametri au fost folosiți separat la început pentru a stabili nivelul de eficiență al fiecăruia. În acest scop, au fost dezvoltate o serie de experimente pentru a stabili eficiența.

2.3.3 Metodologia de estimare a modelelor audio

Recunoașterea sunetelor se bazează pe faptul că orice sursă de semnal audio este caracterizată printr-un model de distribuție al energiei în funcție de frecvență. Acest model poate fi determinat folosind algoritmi statistici de recunoaștere a formelor. În cadrul comunicației, cei mai folosiți clasificatori ce se ocupă de recunoașterea sunetelor se împart în două categorii, așa cum am precizat în capitolul precedent: clasificatori discriminatori și clasificatori non-discriminatori. Clasificatorii discriminatori încearcă să găsească o suprafață de separație între clasele date spre antrenare.

Această metodă folosește teoria Modelelor Markov Ascunse, unde fiecare stare este modelată prin Mixuri Gaussiene. Algoritmul Baum-Welch a fost folosit pentru a antrena un HMM pentru fiecare clasă de sunet în parte. Acesta împarte secvența de succesiune a caracteristicilor într-un număr predefinit de stări și învață modul de asociere al acestora. Rezultatul este o matrice de tranziție compusă din elemente ce indică probabilitatea succesiunii între stări. Un HMM este definit de următoarele elemente:

- numărul de stări, S ,
- numărul de observații posibile, O ,
- tipul de distribuție pentru fiecare stare în parte, în acest caz fiind vorba despre GMM,
- matricea de tranziție, ce conține probabilitățile de succesiune de la o stare la cealaltă,
- distribuția stărilor inițiale, ce indică probabilitatea ca HMM-ul să înceapă dintr-o anumită stare.

2.3.4 Dezvoltarea sistemului

În scopul determinării topologiei care asigură cea mai mare precizie din punctul de vedere al clasificării, s-a conceput un experiment folosind coeficienții MFCC. Acest experiment constă din două etape: prima etapă folosește o singură stare, iar cea de a doua etapă utilizează o schemă ierarhică cu scopul principal de a separa activitățile umane de restul. Setul de date folosit pentru antrenare și testare are un rol esențial în privința rezultatelor sistemului construit, de aceea s-au înglobat diverse sunete dintr-o gamă largă, precum sunete folosite în industria cinematografică. Baza de date trebuie de asemenea să ofere o calitate ridicată a sunetelor și un număr mare de înregistrări. Topologia în cauză este reprezentată în figura 2.9, iar caracteristicile bazei de date audio sunt descrise în tabelul 2.3:

Categorie audio	Nr. de eșantioane audio	Durata totală [s]
Păsări	187	6.159,78
Motocicletă	79	1.169,2
Mașină	81	2.195,2
Ploaie	53	2.209,8
Vorbire	1680	5.073,6
Sunet de armă	131	1.803,87
Vânt	66	3.234
Total	2277	21.845,35

Tabelul 2.3 - Structura bazei de date audio [24]




Figura 2.9 - Schemă bloc ce ilustrează cei doi pași din topologia pentru detecția prezenței umane în mediile naturale [24]

Din cadrul acestor date, un procent de 70% a fost folosit pentru antrenare, iar restul de 30% a fost utilizat pentru procesul de evaluare. Datele au fost alese în mod aleator pentru a asigura relevanța rezultatelor.

Din diagrama bloc a sistemului de detecție atașată anterior observăm că în prima fază, sistemul realizează o clasificare generalizată, în care se încadrează eșantioanele de sunet în două clase pe baza tipului de sursă audio: artificială (activitate umană) sau naturală (fenomen al naturii, sunet generat de animale/păsări). Scopul lucrării este determinarea sursei sunetului din punctul de vedere al activităților umane, deci zona superioară a graficului prezintă o importanță deosebită pentru această lucrare.

Standardul MPEG-7 recomandă extracția parametrilor de nivel redus la nivelul unei ferestre de 30 ms cu o suprapunere de 10 ms. Fereastra folosită este cea Hamming, cu scopul minimizării discontinuităților, iar lungimea FFT este 512.

2.3.5 Rezultate

Precizia totală obținută este 81.5%, în timp ce precizia pentru primul pas al topologiei este 87.7%. Cele două matrici de confuzie obținute la pasul 2 sunt prezentate în tabelele 2.4 și 2.5.

Tip	Răspuns			
	Motocicletă	Mașină	Vorbire	Sunet de armă
Motocicletă	70.1	24.3	0	5.6
Mașină	20.4	75.8	0	3.8
Vorbire	0	0	100	0
Sunet de armă	15.7	3.1	0	80.2

Tabelul 2.4 - Matricea de confuzie pentru sunete specifice activității umane [24]

Tip	Răspuns		
	Motocicletă	Mașină	Vorbire
Motocicletă	70.1	24.3	0
Mașină	20.4	75.8	0
Vorbire	0	0	100
Sunet de armă	15.7	3.1	0

Tabelul 2.5 - Matricea de confuzie pentru sunete specifice naturale [24]

2.4 Metoda LPC

Metoda codării prin predicție liniară [26] modelează fiecare eșantion al semnalului audio pe baza sumei mediate a eșantioanelor precedente. Coeficienții sunt folosiți pentru a realiza filtrul liniar de predicție. Predictorul liniar calculează o anvelopă spectrală adaptată special pentru elementul audio, alegând convenabil ordinul acestuia. Datorită erorii minimize de către predictorul liniar, vârfurile spectrale sunt puse în evidență în cadrul anvelopei, la fel ca în sistemul auditiv.

Pentru analiza LPC, intrarea predictorului liniar este reprezentată de eşantioanele semnalului audio digital $x(n)$ (un proces staţionar şi aleator în sens larg), iar ieşirea este obţinută sub forma unui set de $M+1$ coeficienţi, $b_{M,i}$, $i = \overline{0, M}$, unde M este ordinul filtrului liniar de predicţie. Coeficienţii $b_{M,i}$ sunt aleşi pentru a prezice cu acurateţe cât mai mare valoarea curentă a datelor eşantionate, $x(n)$ dintr-un set de M cele mai recente eşantioane. Funcţia de estimare, sau de predicţie, are următoarea formă:

$$\hat{x}_M(n) = -\sum_{i=1}^M b_{M,i} x(n-i)$$

Figura 2.10 - Funcţia de estimare (predicţie) [26]

Unde $b_{M,i} = [1 \ b_1 \dots b_M]$. Eroare de predicţie $e_M(n)$ poate fi calculate ca diferenţa dintre semnalul audio actual şi cel estimat:

$$e_M(n) = x(n) - \hat{x}_M(n) \stackrel{(1)}{=} x(n) + \sum_{i=1}^M b_{M,i} x(n-i)$$

Figura 2.11 - Eroarea de predicţie [26]

Eroarea de predicţie reprezintă toate noile informaţii care intră în semnalul $\widehat{x}_M(n)$, la momentul n . Deoarece informaţia este nouă, eroarea de predicţie este "imprevizibilă". Componenta ce poate fi prezisă nu conţine informaţii noi. Eroarea de predicţie poate fi considerată a fi ieşirea unui filtru FIR cu următoarea funcţie de transfer:

$$H_M(z) = 1 + \sum_{i=1}^M b_{M,i} z^{-i}$$

Figura 2.12 - Funcţia de transfer a filtrului FIR [26]

ca răspuns la semnalul staţionar în sens larg de la intrare. Varianţa erorii de predicţie este dată de ecuaţia:

$$\sigma_e^2 = E \left\{ [e_M(n)]^2 \right\} = \sum_{n=1}^M [e_M(n) - \bar{e}_M]^2$$

Figura 2.13 - Varianţa erorii de predicţie [26]

unde $\bar{e}_M$ reprezintă media aritmetică a erorii de predicţie $e_M(n)$.

Cele două metode clasice implicate în predicția liniară sunt metoda autocorelației și metoda covarianței. În cazul metodei autocorelației, recursia Levinson-Durbin este utilizată pentru a rezolva ecuațiile normale care apar din formula celor mai mici pătrate. Metoda covarianței este bazată pe o estimare imparțială a autocorelației.

Random Forests (RF) este unul dintre cei mai cunoscuți algoritmi ce folosește arbori de decizie în scopul unui clasificator de bază. Arborii de decizie sunt folosiți din ce în ce mai mult în momentul actual, reprezentând modele predictive de învățare automată (ca ramură a inteligenței artificiale) ce decid valoarea țintă a unui nou eșantion, bazându-se pe diverse atribute ale datelor disponibile.

Construirea unui arbore de decizie este conformă cu procesul general de creare a unui ansamblu; construirea acestuia constă în 3 faze de bază:

1. obținerea diversității ansamblului - RF manipulează seturi de date de antrenare; este creată o listă de seturi de învățare, folosind metoda de eșantionare treptată;
2. construirea clasificatorilor de bază - RF face disponibil arborele aleator pentru diferite seturi de antrenare. În fiecare nod, un mic grup de atribute de intrare sunt selectate în mod aleator. Dimensiunea grupului este aleasă de obicei ca fiind cea mai mare valoare întreagă mai mică decât $\log_2 M + 1$, unde M reprezintă numărul atributelor de intrare; în continuare sunt alese cele mai bune atribute sau cel mai bun punct de ramificare; toți acești arbori nu sunt retezați;
3. combinarea clasificatorilor de bază - RF utilizează metoda votului majoritar.

Construirea unui RF constă în generarea unor vectori aleatori pentru a crește un ansamblu de arbori și permiterea acestora să voteze pentru cea mai populară clasă. Pentru a evita corelarea în cadrul arborilor, algoritmul de învățare selectează aleator un subset de caracteristici pentru a găsi cea mai bună ramificație la fiecare nod. În RF, arbori diferiți au acces la diferite subcolecții aleatoare ale setului de caracteristici sau la diverse subcolecții aleatoare de date. Dacă un vector original de caracteristici are D caracteristici A_i , $i = \overline{1 : D}$, atunci:

- fiecare arbore folosește o selecție aleatoare de $m \sim \sqrt{D}$ caracteristici de tipul $\{A_{i_j}\}_{j=1}^m$; spațial caracteristicilor este diferit (dar fix) pentru fiecare arbore și este reprezentat de către F_k , $1 \leq k \leq K = \# \text{ arbori}$ (K este de ordinul sutelor);
- pentru fiecare ramificație la un nod al arborelui pentru o variabilă dată, se alege o variabilă A_i care va fi folosită pe baza informației sale de conținut;
- valoarea lui m este păstrată constantă în timpul creșterii ansamblului de arbori.

Pentru a se calcula informația de conținut a unui nod:

- se presupune că setul de intrare la nod este S ; în continuare, informația de conținut a nodului N este:

$$I(N) = |S|H(S) - |S_L|H(S_L) - |S_R|H(S_R)$$

Figura 2.14 - Informația de conținut a nodului N

unde:

- (1) $|S|$ este dimensiunea eşantioanelor de intrare,
- (2) $|S_{L,R}|$ este dimensiunea subclaselor de la stânga (NU) și respectiv subclaselor de la dreapta (DA),




Figura 2.15 - Subclasele stânga-dreapta (NO-YES) [26]

- (3) $H(S)$ reprezintă entropia Shannon a $S = - \sum_{i=\pm 1} p_i \log_2 p_i$, cu $p_i = \hat{P}(C_i | S)$ fiind proporția clasei C_i în eşantionul S ; $H(S)$ este numită variabilitatea în probabilități p_i ce formează eşantioane de intrare S pentru nodul current N ,
- (4) $I(N)$ denotă informații de la nodul N .

- Pentru a găsi informația de conținut medie $H_{av}(A_i)$ pentru A_i , pentru fiecare variabilă A_i , media peste toate nodurile N din toți arborii care implică această variabilă este utilizată astfel:
 - în primul rând, toate variabilele A_i sunt clasificate în funcție de informația de conținut;
 - în al doilea rând, pentru fiecare valoare fixă $n_1 < n$, RF este reconstruit folosind doar primele n_1 variabile;
- n_1 care maximizează eroarea de predicție este selectată.

Fiecare arbore este construit cât mai mult posibil. Nu există retezări ale arborilor. Cele mai importante caracteristici ale RF sunt următoarele:

- este de necomparat în ceea ce privește acuratețea printre alți algoritmi de minare a datelor;
- metoda de clasificare funcționează eficient pe seturi de date extinse cu un număr ridicat de caracteristici;
- aceasta poate oferi o estimare privind variabilele care sunt importante în clasificare;
- generează o estimare internă fără precedent a erorii de generalizare a progresului de construire a arborilor;
- are metode de echilibrare a erorii în populații de clase cu seturi de date instabile.

Până în momentul de față, metoda de clasificare RF a fost aplicată în domenii variate, precum modelare, predicție și sisteme de detecție a intruziunilor.

2.5 Metoda MFCC

Descriptorii MFCC [27] sunt cei mai populari descriptori acustici de nivel scăzut (LLDs), datorită eficienței computaționale și robusteții zgomotului. Această tehnică realizează o analiză spectrală bazată pe un filtru logaritmico-triunghiular plasat în frecvență. Acești coeficienți necorelați furnizează o reprezentare compactă a unui semnal, bazându-se pe informația lor legată de frecvență.




Figura 2.16 - Schema bloc a metodei MFCC [27]

Descriptorii MFCC s-au dovedit a fi foarte eficienți. Calculul acestora include următoarele etape, ca în figura 2.16:

- se calculează transformata Fourier discretă, aceasta transformând semnalul în domeniul frecvență, iar spectrul de putere $P(f)$ poate fi ușor obținut;
- spectrul de putere $P(f)$ este deviat de-a lungul axei sale de frecvență (în Hertzi) către axa de frecvență Mel $P(M)$, unde M reprezintă frecvența Mel. Pentru această operație se folosește ecuația de mai jos. Acest proces reflectă aproximativ percepția audio a urechii umane.

$$M(f) = 2595 \log_{10}(1 + f/700)$$

- spectrul puterii rezultat este trecut prin filtrul trece bandă triunghiular, iar funcția spectrului de putere $P(M)$ devine $\theta(M)$. Acest proces de convoluție va reduce semnificativ rezoluția spectrală a $\theta(M)$ în comparație cu $P(M)$. Convoluția discretă pune în evidență eșantioane din banda critică a spectrului de putere, sub forma $\theta(M_k)$ ($k = 1, \dots, K$) din ecuația de mai jos, unde Ω_k sunt spațiate liniar pe scara Mel. Cele K ieșiri de forma $X(k) = \ln(\theta(M_k))$ ($k = 1, \dots, K$) sunt astfel obținute. De asemenea, în ecuația de mai jos observăm o simulare a celor K filtre. În implementare, $\theta(M_k)$ este mai degrabă o medie decât o sumă.

$$\theta(M_k) = \sum_M P(M - M_k) \psi(M), \quad k = 1, \dots, K$$

Figura 2.17 - Funcția spectrului de putere trecută printr-un filtru trece bandă triunghiular [27]

- funcția MFCC este calculată folosind ecuația 2.18, iar deseori $D \ll S$ din cauza abilității de compresie a funcției MFCC.

$$\text{MFCC}(d) = \sum_{k=1}^K X_k \cos \left[d(k - 0.5) \frac{\pi}{K} \right], \quad d = 1, \dots, D$$

Figura 2.18 - Funcția MFCC [27]

Capitolul 3

Metoda propusă de detecție audio a drujbelor

3.1 Fundamente teoretice

3.1.1 Coeficienți Haar

Coeficienții de bază Haar [28] au fost folosiți de-a lungul timpului în recunoașteri versatile ale imaginilor și ale sunetelor. Un parametru Haar este un simplu filtru diferențial de cost computațional redus, ce necesită doar adunări și scăderi pentru a extrage valoarea unei caracteristici. Original, această idee a fost introdusă în domeniul recunoașterii de imagini, însă studiile au dovedit că parametrii Haar 1-D pot fi de asemenea aplicați în probleme de recunoaștere ale altor tipuri de semnale, precum clasificări verbale/non-verbale și clasificări ale activităților umane. Prin aplicarea unui singur parametru Haar 1-D asupra unui semnal temporal obținem un simplu filtru trece bandă, însă prin formarea unei combinații liniare de câțiva coeficienți Haar, se creează un clasificator puternic, cu o capacitate ridicată de a recunoaște cu acuratețe diverse forme sau tipuri de sunete. Acest tip de clasificator se dovedește versatil prin simplul fapt că putem schimba combinația liniară.

În studiile de recunoașterea a formelor din cadrul semnalelor audio, forma spectrului este folosită în principal ca parametru de bază. De exemplu, semnalele vocale furnizează forme concave și convexe aflate în benzi de frecvență între 400 Hz și 4kHz, așa cum se observă în figura 3.1:




Figura 3.1 - Formă semnalului audio. Spectrul de frecvență al semnalului audio [28]

3.1.2 Spectrograme

Spectrul [29] unui semnal pune în evidență conținutul de frecvență a unei scurte secțiuni din cadrul forme de undă. Totuși, în cazul în care dorim să observăm cum un spectru se modifică în timp în cadrul unei secțiuni de semnal audio/vocal, apare necesitatea unui alt tip de instrument spectral. Un astfel de instrument standard este spectrograma, care reprezintă o diagramă bi-dimensională a frecvenței în funcție de timp, în care amplitudinea pentru fiecare frecvență este descrisă prin nuanța de gri a punctului corespunzător din plan. Figura de mai jos reprezintă un exemplu de spectrogramă în concordanță cu forma de undă a cuvântului "stamp" din limba engleză (în traducere, timbru). Putem observa câteva elemente de bază: nuanțele mai închise de gri corespund cu energia de frecvență înaltă a fonemului "s", striatiile verticale în fonemul "A" corespund cu faptul că această vocală caracterizează un semnal periodic, iar saltul brusc către zona albă din cadrul literei "m" corespunde cu finalizarea cuvântului prin intermediul literei "p".




Figura 3.2 - Spectrograma cuvântului *stamp* [29]

Striațiile verticale pentru vocala cuvântului *stamp* permit folosirea unei alte modalități de măsurare a frecvenței fundamentale a semnalului în acest punct. În acest tip de spectrogramă (cunoscută sub numele de spectrogramă de bandă largă), fiecare striatie verticală corespunde unui ciclu de deschidere-inchidere a glotei. Astfel, măsurarea timpului dintre striatii ne indică perioada de oscilație, deci frecvența fundamentală a semnalului vocal în fiecare moment de timp.

3.2 Motivația metodei propuse

Această metodă își propune să diferențieze sunetele produse de motofierăstrău față de o gamă largă de sunete cum ar fi sunetele ambientale de pădure, sunetele produse de motoare de capacitate mai mare decât cea a drujbei sau sunete produse de diferite animale. Această clasă de sunete negative va fi descrisă mai detaliat într-un capitol destinat special creării bazei de date în care vom exemplifica fiecare clasă de sunete și în care vom specifica și ponderea ocupată de fiecare clasă de sunet în raport cu întreaga bază de date. Pentru a realiza o clasificare cât mai bună între sunetele de drujbă și sunetele de non-drujbă a fost necesară realizarea unui studiu exhaustiv asupra parametrilor extrași din semnalul sonor, pentru a putea determina care dintre acești parametri are o capacitate mai bună de clasificare între aceste 2 clase de sunet menționate anterior.

În urma acestui studiu aprofundat asupra parametrilor extrași din semnalul sonor am constatat că există o diferență ușor de observat între sunetele produse de o drujbă care taie în mod activ și o drujbă care funcționează în gol. Această diferență o observăm în figura 3.3.




Figura 3.3 - Spectrograme drujba - funcționare active vs. funcționare în gol

Funcționarea activă este reprezentată de momentul în care drujba taie lemnul rezonând cu întreaga masa lemnoasă, iar funcționarea în gol poate fi reprezentată atât de momentul în care este turat motorul de drujbă cat și de momentul când acesta este lăsat liber, neturat.

Pentru a putea observa diferențele dintre drujba care taie activ și alte tipuri de sunete am analizat în continuare și spectrograma sunetului ambiental de pădure din figura 3.4, dar și spectrograma sunetului produs de vânt din figura 3.5.




Figura 3.4 - Spectrograma sunetului ambiental de pădure




Figura 3.5 - Spectrograma sunetului produs de vânt

În urma acestei analize a multiplelor spectrograme am decis că un criteriu bun de clasificare între sunetele de drujbă și sunetele de non-drujbă ar fi reprezentat de prezența armonicilor specifice figurii 3.6. Prin urmare am considerat doar sunetele de drujbă care funcționează activ ca fiind din clasa pozitivă, iar drujbele care funcționează în gol au fost considerate ca aparținând clasei negative, datorită faptului că nu prezintă caracteristicile spectrale potrivite detecției implementate.




Figura 3.6 - Spectograma sunetului produs de drujbă

Pentru detectarea acestor caracteristici ale spectrogramei am utilizat un descriptor Haar capabil să genereze în urma multiplelor prelucrări un set de parametri care pot fi folosiți cu ușurință în cadrul oricărui tip de clasificator. Un aspect foarte important în cadrul acestei metodei a fost alegerea unui interval de frecvență identic pentru toate semnalele, tocmai pentru a păstra un anumit factor de aspect al spectrogramei. De asemenea, fiecare semnal a fost în ferestre de timp egale tocmai pentru a nu influența într-un mod negativ funcția de extragere a coeficienților Haar.

3.3 Construirea bazei de date

Un pas important în proiectarea acestei metode a fost crearea unei baze de date adecvate. Setul meu de date are 2 clase principale: negative, care sunt sunete ce se găsesc în păduri și o altă clasă care constă în sunete produse de drujbă. Pentru clasa negativă am încercat să am o gamă de sunete foarte variată. Pentru clasa de sunete considerate pozitive am mostre de la diferite tipuri de fierăstraie, la distanțe diferite față de dispozitivul de înregistrare. Numărul total de înregistrări este de 1397 din care 910 sunt negative și 487 sunt pozitive.

O distribuție mai precisă a bazei de date bazată pe sursa sunetului poate fi observată în tabelul 3.1.

Tipul de sunet	Numărul de înregistrări	Distribuția bazei de date [%]
Drujbă	487	34.86
Câine	40	2.86
Cocoș	40	2.86
Broască	40	2.86
Sunet ambiental de pădure	60	4.29
Pisică	40	2.86
Găină	40	2.86
Insecte	40	2.86
Oaie	40	2.86
Cioara	40	2.86
Voce Umană	64	4.58
Ploaie	40	2.86
Lemne Arzând	40	2.86
Greiere	40	2.86
Cerb	15	1.07
Păsări	40	2.86
Picături de apă	40	2.86
Vânt	60	4.29
Râu ce curge	40	2.86
Tunete	40	2.86
Pași	40	2.86
Motor tractor	41	2.93

Tabelul 3.1 - Distribuția bazei de date

3.4 Prezentarea metodei propuse

Metoda propusă prin intermediul acestei lucrări clasifică semnale audio fie în sunete de drujbă, fie în non-sunete de drujbă, pe baza proprietăților spectrale ale forme de undă. Caracteristica extrasă reprezintă de fapt un coeficient de similaritate relaționat cu un spectru ideal care constă în urme de frecvență distribuite uniform. Au fost obținute rezultate foarte bune având în vedere restricțiile legate de sunete de drujbă și adăugarea unor pași de rafinare a sunetelor. Întregul proces de clasificare este prezentat în diagrama bloc din figura 3.7, urmând ca în continuare să prezint pe larg blocurile de bază.




Figura 3.7 - Schema bloc a procesului de clasificare a semnalelor audio

Primul pas constă în procesarea pe ferestre a semnalului original înregistrat cu ajutorul unui microfon. În acest punct, alegerea unei lungimi inadecvate a ferestrei conduce la rezultate incorecte în cadrul blocului FFT și la rezultate de clasificare eronate. Am decis să aleg o fereastră Hamming cu o lungime de aproximativ 30ms și un procentaj de suprapunere de 50%.

Blocul FFT este folosit pentru a realiza transformarea Fourier a semnalului pentru fiecare fereastră în parte. În această lucrare am ales 1024 de puncte N_{FFT} pentru care am obținut o estimare bună a spectrului. Următorul pas presupune calculul unei valori absolute FFT, iar rezultatul acestui calcul este livrat către următorul bloc unde este stocat și plasat într-o coadă pentru procesări ulterioare.

Blocul de extragere a parametrilor Haar are rolul de a calcula o serie de coeficienți care sunt principalele caracteristici utilizate în procedura de clasificare. Metodele care au la bază coeficienți Haar au fost utilizate cu succes în *computer-vision* pentru recunoașterea obiectelor [6, 7].

În această lucrare, îi folosim pentru a detecta modele specifice de frecvență în reprezentarea de sunete în domeniul frecvențelor. Prin urmare, motivația pentru alegerea coeficienților Haar pentru a reprezenta spectrograma semnalelor de intrare stă în necesitatea de a detecta modelul caracteristic al armonicilor pentru o spectrogramă a sunetului produs de un motofierăstrău ce taie o masă lemnoasă. După cum am observat în experimentele precizate anterior, acest model al armonicilor pentru spectrograma unei drujbe are un grad înalt de stabilitate în timp.

Inițializarea algoritmului constă în definirea măștii Haar folosită pentru determinarea coeficienților bazați pe Haar:

$$MASK = \begin{bmatrix} -1 & -1 & -1 & 1 & 1 & 1 & -1 & -1 & -1 \\ -1 & -1 & -1 & 1 & 1 & 1 & -1 & -1 & -1 \\ -1 & -1 & -1 & 1 & 1 & 1 & -1 & -1 & -1 \end{bmatrix}$$

Funcția de extragere a caracteristicilor prezentată mai pe larg în [30] se aplică peste matricea M care conține 3 blocuri FFT de semnale pentru ferestre consecutive:

$$H = \frac{\sum_{i=1}^3 \sum_{j=1}^9 [MASK * M(:, F_{in}:F_{in}+8)](i,j)}{\max[MASK * M(:, F_{in}:F_{in}+8)]}$$

Prelucrarea în blocul de decizie cuprinde două etape descrise în detaliu în [30]. Prima etapă utilizează ca intrări caracteristicile Haar și detectează vârfurile de frecvență. A doua etapă face deosebirea între sunetele de drujbă și alte tipuri de sunete cu proprietăți spectrale similare.

Prima etapă implică analiza matricei caracteristice H și determină criteriul de clasificare. Coeficientul H are o valoare mare atunci când sunt prezente vârfurile de frecvență specifice și o valoare scăzută în lipsa vârfurilor. Pe baza acestei proprietăți, am stabilit un prag cu cele mai bune rezultate de recuperare pentru setul de date de antrenament. Acest prag reprezintă criteriul de clasificare al primei etape.

A doua etapă a blocului de decizie reprezintă o procedură de rafinare a sunetelor care au un spectru similar cu cel de drujbă. Diferența principală dintre spectrogramele sunetelor de drujbă și alte sunete cu modele spectrale similare cum ar fi oile, vacile, cerbii a fost că nivelul zgomotului de înaltă frecvență față de benzile inferioare de frecvență. Prin urmare, pentru a determina dacă un semnal aparține clasei pozitive, am extras un alt coeficient care măsoară nivelul zgomotului de înaltă frecvență. În mod specific, acest coeficient este raportul dintre amplitudinea maximă pătrată și media amplitudinilor pătratului în bandă de frecvență înaltă. Criteriul de clasificare pentru a doua etapă se realizează prin aplicarea unui prag peste coeficientul de zgomot. Acest al doilea prag a fost ales, de asemenea, pe baza celor mai bune rezultate de recuperare din setul de date de antrenare.

Astfel, un sunet este clasificat ca pozitiv dacă trece cu succes prin ambele etape de decizie.

3.5 Rezultate obținute

Pentru o descriere cât mai exactă și concisă a rezultatelor am ales diferite metrici cum ar fi acuratețea sau curba ROC. Pentru a evidenția cât mai clar rezultatele și performanțele de care este capabilă această metodă am ales să prezint în figura 3.8 acuratețea de clasificare ca fiind din clasa non-drujbă a fiecărui tip de sunet negativ din baza de date dar și acuratețea clasificării sunetelor de drujbă ca aparținând clasei de sunete pozitive. De asemenea, în figura 3.9 putem observa caracteristica curbei ROC pentru metoda propusă.




Figura 3.8 - Performanțele metodei propuse




Figura 3.9 - Curba ROC a metodei propuse

3.6 Implementarea metodei propuse pe un sistem *Embedded*

Pentru implementarea și testarea metodei propuse ce are la bază coeficienți Haar am utilizat platforma *embedded* Raspberry, iar ca suport *software* am utilizat sistemul de operare Raspbian ce are la bază o distribuție Debian.

În cadrul lucrării de față a fost implementat în limbajul de programare C++ modulul de extragere a coeficienților de tip Haar dar și modulul de decizie. Acest lucru a fost realizat pentru a testa performanța metodei propuse în cadrul unui sistem *embedded* dar și pentru a putea demonstra faptul că procesarea *live* a unui semnal audio folosind această metodă este posibilă pe o astfel de platformă.

S-a observat că durata medie de procesare a unui minut de înregistrare durează aproximativ 40 de secunde, prin urmare se observă că prin utilizarea unui buffer de aproximativ 1 minut puteam dezvolta un sistem *live* de supraveghere a pădurilor deoarece raportul între durata necesară procesării și durata înregistrării este de aproximativ 68%.

Codul aferent acestei implementări este atașat în anexa 1, în cadrul funcției **get_features.c**.

Capitolul 4

Comparație între metoda propusă și metodele din starea artei

În cadrul comparării celor 5 metode prezentate în paragrafele anterioare, putem folosi diverse metrici. Figura 4.1 ilustrează comparația unor rezultate utilizând metrici comune pentru clasificarea TPR, TNR, FPR și FNR.

$$\text{Overall Accuracy} = \frac{TP+TN}{N} \times 100$$

unde TP reprezintă numărul de exemple pozitive ce sunt clasificate corect, TN este numărul de exemple negative clasificate corespunzător, iar N este numărul total de exemple de test. Curbele ROC le observăm în figura 4.2.




Figura 4.1 - Acuratețea generală a metodelor comparate




Figura 4.2 - Curbele ROC aferente metodelor comparate

Caracteristicile din domeniul timp, precum cele extrase din funcția de autocorelație și TESPAP sunt foarte sensibile la SNR (signal to noise ratio). Aceste metode au un TPR și un FPR înalt, deci și o acuratețe slabă. În cazul metodei TESPAP, rata înaltă a trecerilor prin 0 într-un mediu zgomotos conduce la clasificări eronate. În cazul caracteristicilor extrase din funcția de autocorelație, acestea nu reușesc să ofere o descriere clară a semnalului deoarece parametrul STI pune în evidență energia semnalului care nu este considerat un criteriu puternic de discriminare între diferitele tipuri de sunete.

Marele dezavantaj al utilizării coeficienților de predicție liniară este faptul că oferă o reprezentare lipsită de zgomot când sunt aplicați pe o fereastră largă a unui semnal staționar zgomotos, dar acest lucru vine totuși cu un cost semnificativ, acela că se pierde informații discriminative la utilizarea coeficienților pentru semnale nestaționare în totalitate.

Parametrii domeniului spectral se dovedesc a avea o performanță mai bună, considerând faptul că parametrii MFCC furnizează o aproximare spectrală bună. În acest caz, faptul că semnalele nu sunt staționare de-a lungul unor perioade lungi de timp poate conduce la pierderea semnificativă a unor informații discriminative.

Concluzii

Metoda propusă prin intermediul acestei lucrări prezintă rezultate foarte bune, comparative cu cele ale metodelor convenționale folosite în detecția și clasificarea sunetelor. Utilizarea parametrilor Haar, cunoscuți din domeniul procesării de imagini, s-a dovedit o alegere foarte bună pentru extragerea caracteristicilor unui semnal audio, iar acest aspect se observă imediat în cadrul spectrogramelor. Consider că metoda propusă în cadrul lucrării de față poate duce la construirea unei sistem eficient de detecție a despăduririlor ilegale.

Performanța obținută prin metoda propusă este comparată cu alte metode din literatură în termeni de cinci valori (adică precizia generală, TPR, TNR, FPR, FNR) și curbele ROC. Toate experimentele au fost realizate pe o bază de date cu 1397 sunete împărțite în 487 exemple pozitive și 910 exemple negative. Rezultatele raportate demonstrează eficacitatea metodei propuse pentru a discrimina sunetele produse de lanț. Acest lucru se datorează în principal faptului că algoritmul propus consideră că semnalul sonor al lanțului de drujba este staționar pentru o anumită perioadă de timp.

Bibliografie

- [1] Shishalov, I.S. and Gromazin, O.A. and Solovyev, Y.S. and Romanenko, A.V. and Esin, I.V., "Forest fire video monitoring system and method", US Patent 9,686,513, Jun. 20, 2017
- [2] Lucian Petrică, Gheorghe Ștefan, "Energy-Efficient WSN Architecture for Illegal Deforestation Detection", *International Journal of Sensors and Sensor Networks*. Vol. 3, No. 3, pp. 24-30, 2015
- [3] L. Todor, V. Zoicaș, L. Grama, C. Rusu, "The SPG (Signal Processing Group) Sound Database," *Novice Insights în Electronics, Communications and Information Technology*, Issue 15, 2014
- [4] D. F. Specht, "Generation of Polynomial Discriminant Functions for Pattern Recognition," *IEEE Transactions on Electronic Computers*, vol. 16, pp. 308-319 (1967 June).
- [5] F. Rosenblatt, "The Perceptron: A Probabilistic Model for Information Storage and Organization în the Brain," *The Perceptron: A Probabilistic Model for Information Storage and Organization în the Brain*, *Psychological Review*, vol. 65, pp. 386-408 (1958 Nov.).
- [6] V. N. Vapnik, *The Nature of Statistical Learning Theory* (Springer-Verlag, 1995).
- [7] G. Tzanetakis and P. Cook, "Musical Genre Classification of Audio Signals," *IEEE Transactions on Speech and Audio Processing*, vol. 10, no. 5, pp. 293-302 (2002 July).
- [8] K. Fukunaga, *Introduction to Statistical Pattern Recognition*. Academic Press, 1990
- [9] L. Devroye, L. Györfi, and G. Lugosi, *A Probabilistic Theory of Pattern Recognition*. Springer-Verlag, 1996.
- [10] G. H. Golub and C. F. Van Loan, *Matrix Computations*. John Hopkins, 1989
- [11] <http://www.helsinki.fi/~ahonkela/dippa/node41.html>
- [12] http://www.saedsayad.com/support_vector_machine.htm
- [13] <http://mlg.eng.cam.ac.uk/zoubin/papers/ijprai.pdf>
- [14] R. A. King and T. C. Phipps, "Shannon, TESPAP and approximation strategies," *Computers & Security*, Volume 18, Issue 5, pp. 445-453, 1999.
- [15] *Lightweight Acoustic Detection of Logging în Wireless Sensor Networks*
- [16] Papán, Jozef, Matús Jurecka, and Jana Púchyová. "WSN for Forest Monitoring to Prevent Illegal Logging." în *Proceedings of the Federated Conference on Computer Science and Information Systems*, pp. 809-812. 2012.
- [17] Freund, Y., Mason, L.: The alternating decision tree learning algorithm. *Proceeding of the Sixteenth International Conference on Machine Learning*, Bled, Slovenia, (1999) 124-133.
- [18] Haijian Shi (2007). *Best-first decision tree learning*. Hamilton, NZ.
- [19] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, Ian H. Witten (2009); *The WEKA Data Mining Software: An Update*; *SIGKDD Explorations*, Volume 11, Issue 1.
- [20] Ross Quinlan (1993). *C4.5: Programs for Machine Learning*. Morgan Kaufmann Publishers, San Mateo, CA.
- [21] Geoff Webb: *Decision Tree Grafting From the All-Tests-But-One Partition*. În: , San Francisco, CA, 1999.
- [22] Leo Breiman (2001). *Random Forests*. *Machine Learning*. 45(1):5-32.

- [23] Leo Breiman, Jerome H. Friedman, Richard A. Olshen, Charles J. Stone (1984). Classification and Regression Trees. Wadsworth International Group, Belmont, California.
- [24] Acoustic Detection of Human Activities în Natural Environments
- [25] D. Wang, and G. J. Brown, Computational Auditory Scene Analysis: Principles, Algorithms and Applications (Wiley-Blackwell, Oxford, 2006).
- [26] L. Grama and C. Rusu, "Audio signal classification using Linear Predictive Coding and Random Forests," 2017 International Conference on Speech Technology and Human-Computer Dialogue (SpeD), Bucharest, pp. 1-9, 2017.
- [27] J. G. Colonna, B. Gatto, E. M. D. Santos and E. F. Nakamura, "A Framework for Chainsaw Detection Using One-Class Kernel and Wireless Acoustic Sensor Networks into the Amazon Rainforest," 2016 17th IEEE International Conference on Mobile Data Management (MDM), Porto, pp. 34-36, 2016.
- [28] Nishimura D., Kuroda, T., 2010, Versatile Recognition Using Haar-Like Feature and Cascade Classifier, IEEE Sensors Journal, 10, 5, 942-961.
- [29] <http://web.science.mq.edu.au/~cassidy/comp449/html/ch03s05.html>
- [30] Andrei Gaiță, Georgian Nicolae, Anamaria Rădoi, Corneliu Burileanu, "Chainsaw sound detection based on spectral Haar coefficients", în the Proceedings of 60th International Symposium "ELMAR 2018", 16-19 September

Anexa 1

- **get_feature.c**

```
#include <string.h>
#include "get_features.h"
#include "sum.h"

double[10] get_features(double fft1[9], double fft2[9], double fft3[9])
{
    double refined_features[100];
    double haar_features[100];
    int k;
    int i;
    int j;
    int i0;
    int i1;
    double y;
    int b_k;
    double MASK[27];
    double dv0[9];
    static const signed char b_MASK[27] = { -1, -1, -1, -1, -1, -1, -1, -1, -1,
1,
    1, 1, 1, 1, 1, 1, 1, 1, -1, -1, -1, -1, -1, -1, -1, -1, -1 };

    double c_MASK[27];
    double d_MASK[27];
    double varargin_1[5];
    double e_MASK[27];
    int idx;
    boolean_T exitg1;
    memset(&refined_features[0], 0, 100U * sizeof(double));
    memset(&haar_features[0], 0, 100U * sizeof(double));

    k = 0;
    refined_features[0] = 0.0;

    for (i = 0; i < 12; i++) {
        i0 = (7 + i) << 1;
        i1 = (int)((93.0 + ((double)(i0 - i) - 7.0)) / (double)i0);
        for (j = 0; j < i1; j++) {
            for (b_k = 0; b_k < 27; b_k++) {
                MASK[b_k] = b_MASK[b_k];
            }

            sum(MASK, dv0);
            y = b_sum(dv0);
            for (b_k = 0; b_k < 27; b_k++) {
                MASK[b_k] = b_MASK[b_k];
            }

            for (b_k = 0; b_k < 27; b_k++) {
                c_MASK[b_k] = b_MASK[b_k];
            }
        }
    }
}
```

```

        for (b_k = 0; b_k < 27; b_k++) {
            d_MASK[b_k] = b_MASK[b_k];
        }

        for (b_k = 0; b_k < 27; b_k++) {
            e_MASK[b_k] = b_MASK[b_k];
        }

        varargin_1[0] = y;
        sum(MASK, fft1);
        varargin_1[1] = b_sum(fft1);
        sum(c_MASK, fft2);
        varargin_1[2] = b_sum(fft2);
        sum(d_MASK, fft3);
        varargin_1[3] = b_sum(fft3);

        idx = 0;
        b_k = 2;
        exitg1 = false;
        while ((!exitg1) && (b_k < 6)) {
            idx = b_k;
            exitg1 = true;
        }

        if (idx != 0) {
            y = varargin_1[idx - 1];
            while (idx + 1 < 6) {
                if (y < varargin_1[idx]) {
                    y = varargin_1[idx];
                }

                idx++;
            }
        }

        haar_features[(int)floor(((double)(i + j * i0) + 7.0) / (2.0 * (7.0 +
            (double)i)))] = y;
    }

    y = haar_features[0];
    for (b_k = 0; b_k < 99; b_k++) {
        y += haar_features[b_k + 1];
    }

    refined_features[k] = y / 100.0;
    k++;
}

for (j = 0; j < 10; j++) {
    features[j] = refined_features[10 * j];
    for (i = 0; i < 9; i++) {
        y = features[j];
        if ((refined_features[(i + 10 * j) + 1]) > (features[j]
            || (features[j] < refined_features[(i + 10 * j) + 1]))) {
            y = refined_features[(i + 10 * j) + 1];
        }
    }
}

```



```

    }

    features[j] = y;
}
}
return features;
}

```

- **sum.c**

```

#include "rt_nonfinite.h"
#include "get_features.h"
#include "sum.h"

double b_sum(const double x[9])
{
    double y;
    int k;
    y = x[0];
    for (k = 0; k < 8; k++) {
        y += x[k + 1];
    }

    return y;
}

void sum(const double x[27], double y[9])
{
    int i;
    int xpageoffset;
    int k;
    for (i = 0; i < 9; i++) {
        xpageoffset = i * 3;
        y[i] = x[xpageoffset];
        for (k = 0; k < 2; k++) {
            y[i] += x[(xpageoffset + k) + 1];
        }
    }
}

```

- **get_feature.h**

```

#ifndef GET_FEATURES_H
#define GET_FEATURES_H

#include <stddef.h>
#include <stdlib.h>
#include "get_features_types.h"

extern double[10] get_features(double fft1[9],double fft1[9],double fft1[9]);

#endif

```

- **run_haar_detection.m**

```
clear all; close all;

%% Define paths
negativePath = '../dataset-original/negative/';
positivePath = '../dataset-original/positive/';
negativeDir = dir(negativePath);
positiveDir = dir(positivePath);
decision_window = 1400;
threshold = 200;
iteration = 1;
count = 1;

%drujba remove samples at iteration = 1
%negative remove samples at iteration = 10

% for iteration = 1:2
%   for threshold = 40:2:60
%       %decision_window = 160 - iteration * 40;
%       %threshold = 31.5 - i/5;
tic
%% Positive
structure_size = length(positiveDir)-2;
bundle_pos(structure_size) = struct('name','', 'precision', 0.0);

% configura pool for multi-threading
myCluster = parcluster('local');
myCluster.NumWorkers = 8; % 'Modified' property now TRUE
saveProfile(myCluster); % 'local' profile now updated,
                        % 'Modified' property now FALSE
parpool(myCluster)
for index_bundle=1:length(positiveDir)-2
    bundle_name = positiveDir(index_bundle+2).name;
    bundle_files = dir(strcat(positivePath,bundle_name,'/*'));
    bundle_files = bundle_files(3:length(bundle_files));
    bundle_pos(index_bundle).name = bundle_name;
    counter_bundle_positive = 0;
    counter_fail = 1;
    bundle_pos(index_bundle).failed_records = [];
    parfor index_file = 1:length(bundle_files)
        full_path = strcat(positivePath,bundle_name,'/',...
            bundle_files(index_file).name);
        [y,Fs] = audioread(full_path);
        is_chainsaw = decision_tree(y,Fs,decision_window,threshold);
        if is_chainsaw
            counter_bundle_positive = counter_bundle_positive + 1;
        else
            failed_records{index_file} = bundle_files(index_file).name;
            counter_fail = counter_fail +1;
        end
    end
end
counter_failed_formatted = 1;
if counter_fail ~= 1
    for j=1:length(failed_records)
        if length(failed_records{j}) ~= 0
```

```

        failed_records_formatted{counter_failed_formatted} =
failed_records{j};
        counter_failed_formatted = counter_failed_formatted + 1;
    end
    end
    bundle_pos(index_bundle).failed_records =
failed_records_formatted;
    bundle_precision = counter_bundle_positive/length(bundle_files);
    bundle_pos(index_bundle).total_nr_files = length(bundle_files);
    bundle_pos(index_bundle).correct_classfied_nr_files =
counter_bundle_positive;
    bundle_pos(index_bundle).precision = bundle_precision;
else
    bundle_pos(index_bundle).precision = 100;
    bundle_pos(index_bundle).total_nr_files = length(bundle_files);
    bundle_pos(index_bundle).correct_classfied_nr_files =
counter_bundle_positive;
end
end

%find global mean
corect_nr = 0;
total_nr = 0;
for i=1:length(bundle_pos)
    total_nr = total_nr + bundle_pos(i).total_nr_files;
    corect_nr = corect_nr + bundle_pos(i).correct_classfied_nr_files;
end

bundle_pos_mean(count) = corect_nr/total_nr
delete(gcf('nocreate'))

%% Negative

structure_size = length(negativeDir)-2;
bundle_neg(structure_size) =
struct('name','', 'failed_records', [], 'precision', 0.0);

% configura pool for multi-threading
myCluster = parcluster('local');
myCluster.NumWorkers = 8; % 'Modified' property now TRUE
saveProfile(myCluster); % 'local' profile now updated,
% 'Modified' property now FALSE
parpool(myCluster)
for index_bundle=1:length(negativeDir)-2
    bundle_name = negativeDir(index_bundle+2).name;
    bundle_files = dir(strcat(negativePath,bundle_name,'/*'));
    bundle_files = bundle_files(3:length(bundle_files));
    bundle_neg(index_bundle).name = bundle_name;
    counter_bundle_positive = 0;
    counter_fail = 1;
    bundle_neg(index_bundle).failed_records = [];
    parfor index_file = 1:length(bundle_files)
        full_path = strcat(negativePath,bundle_name,'/',...
            bundle_files(index_file).name);
        [y,Fs] = audioread(full_path);
        is_chainsaw = decision_tree(y,Fs,decision_window,threshold);
    end
end
end

```

```

        if is_chainsaw == false
            counter_bundle_positive = counter_bundle_positive + 1;
        else
            failed_records{index_file} = bundle_files(index_file).name;
            counter_fail = counter_fail + 1;
        end
    end
    counter_failed_formated = 1;
    for j=1:length(failed_records)
        if length(failed_records{j}) ~= 0
            failed_records_formated{counter_failed_formated} =
failed_records{j};
            counter_failed_formated = counter_failed_formated + 1;
        end
    end
    bundle_neg(index_bundle).failed_records = failed_records_formated;
    bundle_precision = counter_bundle_positive/length(bundle_files);
    bundle_neg(index_bundle).total_nr_files = length(bundle_files);
    bundle_neg(index_bundle).correct_classfied_nr_files =
counter_bundle_positive;
    bundle_neg(index_bundle).precision = bundle_precision;
end

%find global mean
corect_nr = 0;
total_nr = 0;
for i=1:length(bundle_neg)
    total_nr = total_nr + bundle_neg(i).total_nr_files;
    corect_nr = corect_nr + bundle_neg(i).correct_classfied_nr_files;
end

bundle_neg_mean(count) = corect_nr/total_nr
%command for closing pool
delete(gcf('nocreate'))
%clear bundle_neg bundle_pos
toc
    count = count + 1;
% end
% end

figure(1)
plot(bundle_pos_mean),title('Precision for Positive Dataset over
Iterations'),...
    xlabel('Iteration'),ylabel('Precision')
figure(2)
plot(bundle_neg_mean),title('Precision for Negative Dataset over
Iterations'),...
    xlabel('Iteration'),ylabel('Precision')

```

- **decision-tree.m**

```
function [ decision_result ] = decision_tree( y, Fs, decision_window ,
threshold)
    N_fft = 1024;
    decision_result = false;

    [P,Q] = rat(1.4733e4/Fs);
    ynew = resample(y,P,Q);

    Fs_resample = 16000;
    window_samples = 442;
    %this is made to consider only frquency smaller than Fs/2
    freq_point_limit = floor(window_samples/2);
    k=1;

    for i = window_samples/2:window_samples/2:size(ynew,1)-window_samples/2
        % ynew is windowed
        s = ynew(i-window_samples/2+1:i+window_samples/2);
        if size(s,1) == window_samples
            s=s';
        end
        % S is actually the spectrogram
        S(k,:) = (real(abs(fft(s'.*hamming(window_samples),N_fft))));
        % the if is to take in account 3 consecutive windows S(i-2:i,...)
        if k>3
            ft(i-window_samples/2+1) = get_features(S(k-
2:k,1:freq_point_limit));
        end
        k=k+1;
    end

    % decision is made here
    for i = 1:decision_window:length(ft)-decision_window
        decision_mean = mean(ft(i:i+decision_window));
        if(decision_mean>0)
            %at 5kHz window of 500Hz
            floor(2*(i+decision_window)/window_samples);
            window_5khz = S(floor(2*i/window_samples+1):
floor(2*(i+decision_window)/window_samples+1),...
(floor((5000/Fs_resample)*N_fft)):floor((5500/Fs_resample)*N_fft));
            prag = max(max(S))/mean(mean(window_5khz));
            % prag chose through observation, needs to be optimised
            if prag < threshold
                decision_result = true;
            end
            break;
        end
    end
end

end
```

- **get_features.m**

```
function [ features ] = get_features( )

S = ones(3,9);
refined_features=zeros(10);
haar_features=zeros(10);
MASK = [ -1 -1 -1 1 1 1 -1 -1 -1; ...
          -1 -1 -1 1 1 1 -1 -1 -1; ...
          -1 -1 -1 1 1 1 -1 -1 -1];
k=1;
refined_features(1)=0;

for i= 7 : 18
    for j = i:2*i:100-7
        haar_features(floor(j/(2*i))+1) = max ([...
            sum(sum(MASK .* S(:,j-6:j+2)))/max(max(S(:,j-6:j+2)))...
            sum(sum(MASK .* S(:,j-5:j+3)))/max(max(S(:,j-5:j+3)))...
            sum(sum(MASK .* S(:,j-4:j+4)))/max(max(S(:,j-4:j+4)))...
            sum(sum(MASK .* S(:,j-3:j+5)))/max(max(S(:,j-3:j+5)))...
            sum(sum(MASK .* S(:,j-2:j+6)))/max(max(S(:,j-2:j+6)))]) );
    end
    refined_features(k) = mean(haar_features(:));
    k=k+1;
end
features = max(refined_features);
end
```