

(12)

CERERE DE BREVET DE INVENȚIE

(21) Nr. cerere: a 2020 00331

(22) Data de depozit: 15/06/2020

(41) Data publicării cererii:
28/05/2021 BOPI nr. 5/2021

(71) Solicitant:

- DUMITRESCU CĂTĂLIN, STR.SF.MARIA, NR.1, BL.10 A4, SC.A, ET.6, AP.39, SECTOR 1, BUCUREȘTI, B, RO;
- MINEA MARIUS, ALEEA CĂMPUL CU FLORI, NR.1, SC.C, ET.4, AP.108, BUCUREȘTI, B, RO;
- COSTEA ILONA - MĂDĂLINA, STR. VIILOR, NR.1ABIS, SAT DUDU, COMUNA CHIAJNA, IF, RO;
- CHIVA IONUȚ COSMIN, STR.ECONOMU CEZĂRESCU, NR.52, TRONSON 2, BL.4, ET.6, AP.4611, BUCUREȘTI, B, RO;
- MINEA VIVIANA LAETIȚIA, ALEEA CĂMPUL CU FLORI, NR.1, SC.C, ET.4, AP.108, SECTOR 6, BUCUREȘTI, B, RO;
- SEMENESCU AUGUSTIN, STR.ECONOMU CEZĂRESCU, NR.52, BL.3, AP.3401, SECTOR 6, BUCUREȘTI, B, RO

(72) Inventatori:

- DUMITRESCU CĂTĂLIN, STR.SF.MARIA, NR.1, BL.10 A4, SC.A, ET.6, AP.39, SECTOR 1, BUCUREȘTI, B, RO;
- MINEA MARIUS, ALEEA CĂMPUL CU FLORI, NR.1, SC.C, ET.4, AP.108, BUCUREȘTI, B, RO;
- COSTEA ILONA - MĂDĂLINA, STR. VIILOR, NR.1ABIS, SAT DUDU, COMUNA CHIAJNA, IF, RO;
- CHIVA IONUȚ COSMIN, STR.ECONOMU CEZĂRESCU, NR.52, TRONSON 2, BL.4, ET.6, AP.4611, BUCUREȘTI, B, RO;
- MINEA VIVIANA LAETIȚIA, ALEEA CĂMPUL CU FLORI, NR.1, SC.C, ET.4, AP.108, SECTOR 6, BUCUREȘTI, B, RO;
- SEMENESCU AUGUSTIN, STR.ECONOMU CEZĂRESCU, NR.52, BL.3, AP.3401, SECTOR 6, BUCUREȘTI, B, RO

(54) **SISTEM ȘI METODĂ DE DETECȚIE A VEHICULELOR AERIE NE FĂRĂ PILOT (DRONE) ACTIVE PRIN ANALIZA CU ALGORITMI DE TIP DEEP LEARNING A SUNETULUI ȘI IMAGINII CAPTATE**

(57) Rezumat:

Invenția se referă la un sistem și la o metodă de detecție, identificare și clasificare a dronelor bazate pe conceptul de concurență la nivelul unei colecții de rețele neuronale cu eficiență în identificarea semnalelor acustice. Sistemul conform invenției cuprinde următoarele părți componente: un modul de achiziție a semnalelor audio constând dintr-o arie de microfoane dispuse în spirală, cu cameră video încorporată, cu ponderi adaptive de tip multi-canal cu pas variabil, un modul de prelucrare a semnalelor pentru segmentarea semnalelor audio și normalizarea acestora, un modul de analiză audio care realizează ferestruirea semnalelor și analiza simultană în planurile temporal și spectral, un modul de analiză a componentelor audio care realizează extragerea trăsăturilor semnalelor acustice specifice dronelor utilizând algoritmi statistici, un modul de decizie și clasificare pentru formarea bazei de antrenare pe baza trăsăturilor specifice, utilizarea unor rețele neuronale de tip concurențial care lucrează în paralel pentru clasificarea semnalelor acustice detectate, prin intermediul unor module de tip perceptron multistrat

(MLP-CNN), de tip rețea neurală cu întârziere în timp (TDNN-CNN) și de tip hartă cu autoorganizare (SOM-CNN) și un bloc de generare a unor alerte de detecție.

Revendicări: 2
Figuri: 5




Fig. 1

Cu începere de la data publicării cererii de brevet, cererea asigură, în mod provizoriu, solicitantului, protecția conferită potrivit dispozițiilor art.32 din Legea nr.64/1991, cu excepția cazurilor în care cererea de brevet de invenție a fost respinsă, retrasă sau considerată ca fiind retrasă. Întinderea protecției conferite de cererea de brevet de invenție este determinată de revendicările conținute în cererea publicată în conformitate cu art.23 alin.(1) - (3).



| | |
|------------------------------------------|------------|
| OFICIUL DE STAT PENTRU INVENȚII ȘI MĂRCI | |
| Cerere de brevet de invenție | |
| Nr. | a 20 00331 |
| Data depozit | 15-06-2020 |

1

SISTEM ȘI METODĂ DE DETECȚIE A VEHICULELOR AERIENE FĂRĂ PILOT (DRONE) ACTIVE, PRIN ANALIZA CU ALGORITMI DE TIP DEEP LEARNING A SUNETULUI ȘI IMAGINII CAPTATE

DUMITRESCU Cătălin, MINEA Marius, COSTEA Ilona-Mădălina, CHIVA Ionuț-Cosmin, MINEA Viviana - Laetitia, SEMENESCU Augustin

Invenția se referă la un sistem și la o metodă de detecție, identificare și clasificare a dronelor, bazată pe conceptul de concurență la nivelul unei colecții de rețele neuronale cu eficiență în identificarea semnalelor acustice. Invenția se referă la determinarea caracteristicilor specifice utilizând rețele neuronale, funcționând pe baza recunoașterii sunetelor proprii funcționării dronelor. Caracterizată prin aceea că sunt introduse mai multe modele originale de recunoaștere, iar dezvoltările teoretice și rezultatele experimentale demonstrează unicitatea acestei metode. Soluția de sistem propusă în invenție este caracterizată prin independență dar și integrabilitate cu alte sisteme de detecție a dronelor realizate în tehnologie multi-senzor, ce pot utiliza detecție electro-optică în infraroșu, termică și o gamă de senzori RF.

În prezent, dronile comerciale sunt un produs de piață, deoarece tehnologia de control și funcționare a acestor aeronave fără pilot sunt ieftine, fiind disponibile pe scară largă și caracterizate de o dezvoltare rapidă. Aplicațiile dronelor poate varia de la simpla utilizare ca hobby și pentru distracție la supraveghere aeriană mergând până la activități ilegale și/sau criminale [1].

Creșterea eficienței dronelor, prin utilizarea controlului GPS și al pilotului automat permit acestora să zboare pe trasee programate fără pilot și pe distanțe mari [2]. Acest aspect crește riscul de securitate prin posibilitatea de a realiza filmări neautorizate asupra clădirilor, instalațiilor sensibile și a persoanelor [3]. Prin urmare, în anumite contexte, necesitatea detectării și restrângerea utilizării ilegale a dronelor devine o necesitate. Cu toate acestea, datorită vitezei de zbor și a utilizării unui sistem de pilotare automată, detecția dronelor reprezintă o activitate complexă și dificilă, mai ales că aceste vehicule aeriene fără pilot (*Unmanned Aerial Vehicles - UAV*) au dimensiuni mici și atunci când este utilizată o singură metodă de detectare, folosind senzori RF sau optici. Studiarea semnăturilor acustice ale dronelor comerciale a demonstrat posibilitatea de dezvoltare a sistemelor cu analiză de sunet pentru monitorizarea dronelor prin utilizarea unor funcții de identificare a sunetelor produse de aceste UAV [4, 5, 6]. Mai exact, Mezei [7] a propus o detecție acustică pentru monitorizarea dronelor utilizând tehnica de corelație a amprentării audio. De asemenea, Souli [8] a prezentat o spectrogramă sonoră de mediu și utilizarea algoritmului de clasificare SVM bazată pe reassignarea spectralului de patch-uri. Aceste cercetări propun un sistem ieftin și portabil de detectare, care extrage și clasifică în domeniul timp și în frecvență caracteristicile spectrale ale sunetelor determinând astfel dacă există sau nu un UAV în apropiere.

Cu toate acestea, sistemele de identificare, recunoaștere și clasificare a semnalelor acustice prezintă unele aspecte sensibile. Câteva dintre acestea ar fi: acuratețea sistemului, timpul în care acesta procesează semnalul acustic, resursele consumate, etc. Fiecare aspect poate fi mai mult sau mai puțin relevant, în funcție de scopul final al aplicației. O acuratețe scăzută va conduce la identificări greșite / eronate ale semnalului acustic, iar acest fapt va genera interpretări greșite. O latență mare a sistemului îl va face foarte greu de utilizat într-un scenariu de interacțiune în timp real, de tip multiple drone. Problema resurselor consumate (energie, putere de calcul) poate să devină serioasă dacă dispozitivul pe

| | | | | | | | | | | | |
|---|--|---|--|---|--|---|--|---|--|---|--|
| 1 | | 2 | | 3 | | 4 | | 5 | | 6 | |
|---|--|---|--|---|--|---|--|---|--|---|--|

care va rula aplicația este un terminal portabil, alimentat de către o baterie sau dacă există limitări din punct de vedere hardware: putere de procesare, memorie etc.

Cea mai grea problemă în verificarea și clasificarea semnalelor acustice este normalizarea variației similarității intra-sunet, de asemenea apar și diferențe între condițiile de înregistrare, transmisie și zgomot, semnalele acustice pot varia de la o autentificare la alta - astfel s-au investigat metode bazate pe rata de probabilitate și metode bazate pe *adaptarea a posteriori*. Pentru a reduce costul computațional al termenului de normalizare s-a propus "*metoda cohortelor*" sau "*modelul universal*". Începând cu anii 2000 s-au propus noi metode de normalizare în care scorurile obținute sunt normalizate prin scăderea mediei și raportarea la deviația standard obținute din distribuția scorurilor de eroare. Există diferite metode de a calcula distribuția scorurilor de eroare prin funcții de clasificare, ca de exemplu: Z_{norm} , H_{norm} , T_{norm} , H_{tnorm} , C_{norm} și D_{norm} . La ora actuală, în ceea ce privește verificarea, identificarea și clasificarea independentă de semnale acustice sunt utilizate unul sau mai multe niveluri de normalizare (*CMS* și *normalizarea mediei parametrilor cepstrali*) împreună cu o normalizare a modelului universal și una sau mai multe normalizări ale scorurilor.

În prezent s-a observat că supervectorii generați în acest fel nu sunt ideali, *adaptarea a posteriori* nu adaptează doar caracteristicile specifice fiecărui semnal acustic, pornind de la modelul universal, el adaptează și caracteristicile canalului de comunicații, precum și alți factori perturbatori. Un supervector ar trebui să poată fi descompus în caracteristici specifice semnalului acustic, caracteristici dependente de semnalele sonore, caracteristici dependente de canal și componente reziduale.

Invenția are ca obiectiv îmbunătățirea sistemelor de detecție a vehiculelor aeriene de tip drone pe baza amprentelor lor acustice, astfel încât în final să permită clasificarea acestora după modelele lor constructive

Problema tehnică rezolvată de invenție este realizarea unui sistem și conceperea unei metode pentru detecția, identificarea și clasificarea dronelor după amprenta lor acustică, utilizând un sistem de rețele neuronale concurente.

Sistemul pentru detecția dronelor utilizând un modul de achiziție de semnale audio, cu o arie de microfoane cu camera video încorporată, și rezolvă această problemă tehnică prin aceea că, pentru detecția, recunoașterea (identificarea) și clasificarea dronelor după modul de construcție al acestora și pentru îmbunătățirea semnalului acustic utilizează o arhitectură de calcul pentru prelucrarea semnalelor acustice și extragerea trăsăturilor caracteristice amprentei acustice specifice donelor și clasificarea acestora, compusă din: un modul de prelucrare a semnalelor, un modul de analiză audio, un modul de analiză componente audio și un modul de decizie și clasificare.

Modulul de achiziție de semnale audio este compus dintr-o arie de microfoane cu 30 capsule digitale (MEMS) dispuse în spirala și camera video încorporată, cu ponderi adaptive de tip multi-canal cu pas variabil, modulul de prelucrare a semnalelor este compus dintr-un sistem National Instruments de tip Compact RIO modular, controler cu procesoare FPGA programabile de către utilizator, 4 module de I/O pentru achiziția semnalelor acustice și amplificatoare Texas Instruments, model INA 163 (Low-Noise, Low-Distortion), dintr-un sub-modul de segmentare audio a semnalelor și un sub-modul de normalizare a segmentelor, modulul de analiză audio este compus dintr-un sub-modul de ferestruire subframe și un sub-modul de analiză temporală și spectrală, pentru ferestruirea semnalelor și analiza simultană în planele temporal și spectral, modulul de analiză componente audio este compus dintr-un sub-modul de

| | | | | | | | | | | | |
|---|--|---|--|---|--|---|--|---|--|---|--|
| 1 | | 2 | | 3 | | 4 | | 5 | | 6 | |
|---|--|---|--|---|--|---|--|---|--|---|--|

calcul statistic și un sub-modul de modelare-extragere caracteristici, pentru extragerea trăsăturilor semnalelor acustice specifice dronelor utilizând algoritmi statistici, iar modulul de decizie și clasificare este compus dintr-un sub-modul de antrenare bază de date, un sub-modul CNN de antrenare, un sub-modul de clasificare și etichetare și un sub-modul decizie alertă sistem, pentru formarea bazei de antrenare pe baza trăsăturilor specifice, utilizarea unor rețele neuronale de tip concurențial care lucrează în paralel pentru clasificarea semnalelor acustice detectate, prin intermediul unor module de tip perceptron multistrat (MLP-CNN), de tip rețea neurală cu întârziere în timp (TDNN-CNN) și de tip hartă cu autoorganizare (SOM-CNN), sistemul incluzând și un bloc de generare alerte de detecție.

Metoda pentru recunoașterea/identificarea și clasificarea dronelor, utilizând amprente acustice ale acestora, conform invenției, pentru protecția unor zone împotriva zborurilor neautorizate ale dronelor, este caracterizată prin aceea că include următoarele etape de antrenare pentru CNN :

- **Etapa 1.** Se creează baza de date, care conține vectorii de instruire obținuți în urma preprocesării semnalului acustic specific dronelor.
- **Etapa 2.** Se extrag din baza de date seturile de vectori specifice fiecărei rețele neurale în parte și se stabilesc ieșirile dorite dacă este cazul.
- **Etapa 3.** Se aplică algoritmul de instruire fiecărei rețele neurale folosind seturile de vectori create la pasul 2.

etapele de recunoaștere / clasificare pentru CNN fiind:

- **Etapa a.** Este creat vectorul de test prin preprocesarea semnalului acustic specific dronelor.
- **Etapa b.** Vectorul de test este transmis în paralel tuturor celor n rețele neurale instruite în prealabil.
- **Etapa c.** Blocul de selecție stabilește indicele rețelei cu răspunsul cel mai bun și acesta va fi indicele clasei în care este încadrat vectorul,


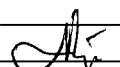
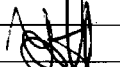
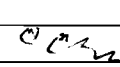
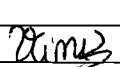
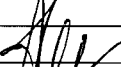
prin utilizarea unui algoritm complex de integrare a informațiilor obținute din surse diferite (Data Fusion), sonore și imagini, crescând astfel probabilitatea de recunoaștere și clasificarea a dronelor utilizând integrarea rezultatelor de clasificare obținute de la rețelele CNN, rezultând astfel o dublă identificare a dronelor prin amprente lor acustice specifice corelate cu detecția video a acestora, în recunoașterea amprentelor acustice fiind utilizate descompunerile în clasa Cohen.

Metoda, conform invenției, introduce ca element de noutate principal folosirea rețelelor neuronale pentru antrenarea modelelor componente ale sistemului: acustic și de amprenta sonoră. Pentru eficiență, infrastructura de calcul va fi îmbunătățită prin utilizarea procesoarelor grafice.

Deoarece crearea unor astfel de sisteme de recunoaștere a dronelor depinde în mod esențial de antrenarea pe baza unui corpus de amprente sonore cât mai mare, a fost implementată o aplicație ce colectează și analizează date audio automat. Apoi au fost implementate metodele de adnotare automată a acestor date și posibilitatea de creere de noi corpusuri de sunete specifice dronelor.

Sistemul, conform invenției, are în componență următoarele soluții tehnice:

- realizarea unui model de arie de microfoane în formă de spirală, cu cameră video încorporată;
- extinderea infrastructurii de calcul în vederea procesării distribuite folosind procesoare FPGA;
- crearea unor modele acustice mai puternice, folosind tehnici ce conduc la optimizarea modelelor statistice și crearea unor modele noi, pe bază de rețele neuronale;
- crearea unor modele de antrenare mai puternice, prin extinderea vocabularului și a complexității, dar și prin antrenarea unor modele noi, pe bază de rețele neuronale;

| | | | | | | | | | | | |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|
| 1 |  | 2 |  | 3 |  | 4 |  | 5 |  | 6 |  |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|

- crearea unui sistem de colectare și adnotare automată a corpurilor audio;
- reantrenarea sistemelor pe baza corpurilor nou achiziționate.

Avantajele invenției sunt:

- Utilizarea unui sistem hardware și software pentru recunoașterea automată a dronelor utilizând componentele acustice specifice cu scopul de a proteja zonele de demarcație a Infrastructurilor Critice, conform figurii 1.
- Utilizarea unei arii de microfoane cu cameră video încorporată.
- Realizarea unei metode de vârf de recunoaștere a dronelor, care să funcționeze pe o bază cât mai mare de modele, să poată fi aplicată independent de modelul dronelor, să fie robustă la zgomot și în același timp să ofere un răspuns cât mai corect într-un timp cât mai scurt.
- Soluția realizează o analiză complexă de spectru utilizând spectrograme din clasa Cohen.
- Soluția permite integrarea sistemului acustic de recunoaștere a dronelor cu Imaginile video detectate de camera încorporată arii de microfoane.
- Soluția introduce un nou concept de rețele neuronale concurente pentru detecția semnalelor acustice specifice dronelor.
- Soluția propusă conform invenției are impact minim asupra mediului.
- Soluția propusă necesită un nivel minim de mentenanță.

Invenția este prezentată pe larg în continuare în legătură și cu figurile 1 – 4, care reprezintă:

- Figura 1: Arhitectura sistemului acustic pentru detectia dronelor.
- Figura 2: Configurația arii de microfoane tip spirală cu camera video încorporată.
- Figura 3: Modelul folosit la antrenarea rețelelor neurale concurente.
- Figura 4: Modelul folosit la clasificarea de rețelele neurale concurente.

Invenția rezolvă problema tehnică menționată prin utilizarea rețelelor neurale concurente, acestea reprezentând un model conexiionist de recunoaștere care pornește de la observația că o rețea neurală este mai eficientă atunci când implementează o problemă mai puțin complexă sau când este specializată pe o subproblemă a problemei globale de recunoaștere și clasificare. Modelul propus în acest invenție este o colecție de rețele neurale care lucrează în paralel, iar decizia de recunoaștere și clasificare se ia conform regulii "câștigătorul ia tot". Fiecare rețea neurală componentă este instruită individual cu un set propriu de date. Fiind vorba de module care rezolvă probleme cu o complexitate intrinsecă mai scăzută, numărul de neuroni pentru fiecare modul poate fi redus semnificativ. Au fost instruite rețele neurale concurente având drept unități elementare perceptroni multistrat, rețele neurale cu întârziere în timp și hărți cu autoorganizare - pentru aceeași problemă de recunoaștere a semnalelor acustice generate de către drone, iar performanțele pentru cele două baze de date create au crescut semnificativ.

- Cu același model a fost implementată și recunoașterea unui subset de șase amprente acustice ale unor drone, baza de date fiind alcătuită prin segmentarea manuală a semnalelor acustice, în scopul extragerii secvențelor de unicitate. S-a realizat o activitate de preprocesare, care constă în calculul coeficienților cepstrali reprezentând vectorii de instruire. Rețeaua neurală concurentă care folosește hărți cu autoorganizare specializate pe recunoașterea câte unei amprente sonore are performanțe mai bune decât o hartă unică, instruită cu toate amprente acustice.

Sistemul conform invenției, de detecție, recunoaștere și clasificare automată a dronelor utilizând amprenta acustică, este caracterizat prin aceea că este compus dintr-un ansamblu hardware – software prezentat în figura 1.

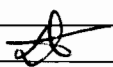
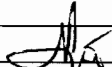
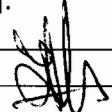
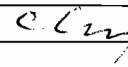
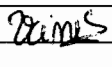
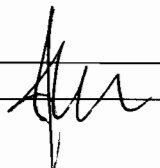
| | | | | | | | | | | | |
|---|--|---|--|---|--|---|-----|---|--|---|--|
| 1 | | 2 | | 3 | | 4 | com | 5 | | 6 | |
|---|--|---|--|---|--|---|-----|---|--|---|--|

Prima problemă tehnică pe care invenția o rezolvă este aria de microfoane, aleasă de tip spirală cu cameră video încorporată, prezentată în figura 2. Aria de microfoane este compusă din 30 de microfoane digitale (MEMS) dispuse în formă de spirală, cu ponderi adaptive de tip multi-canal cu pas variabil.

Sistemul hardware de achiziție și prelucrare a semnalelor acustice este compus dintr-un sistem National Instruments de tip Compact RIO modular, controler cu procesoare FPGA programabile de către utilizator, 4 module de I/O pentru achiziția semnalelor acustice și amplificatoare Texas Instruments, model INA 163 (Low-Noise, Low-Distortion). Sistemul permite detecția prezenței semnalului acustic de complexitate redusă. Pentru îmbunătățirea semnalului acustic recepționat au fost utilizate metode adaptive de anulare a reacției acustice, dar și metode adaptive de reducere a zgomotului acustic.

Al doilea obiectiv pe care invenția îl rezolvă este recunoașterea amprentelor acustice ale dronelor prin extragerea caracteristicilor specifice. Procesul comun cu care operează toate tipurile de sisteme de recunoaștere acustică a dronelor este reprezentat de extragerea vectorilor de caracteristici din segmente uniform distribuite în timp ale semnalului acustic eșantionat. Blocurile software funcționale de prelucrare și analiză ale semnalului acustic dezvoltate în cadrul invenției, prezentate în figura 1, sunt următoarele:

- a) **Accentuare:** un filtru trece sus este folosit pentru a accentua frecvențele înalte și a compensa faptul că sistemul tinde să atenueze aceste frecvențe [9].
- b) **Segmentare:** semnalul acustic este nestaționar în timp lung însă cvasi-staționar în timp scurt, de ordinul 10-30 ms de aceea semnalul sonor este împărțit în segmente de durată fixă numite *cadre*. Dimensiunea tipică a unui cadru este 20 ms ele generându-se din 10 în 10 ms astfel încât să aibă loc o suprapunere de 15 ms de la o fereastră la alta [9].
- c) **Atenuare:** fiecare fereastră este multiplicată cu o funcție fereastră, de obicei fereastra Hamming, pentru a atenua efectul cauzat de segmentarea cu ferestre finite [9].
- d) **Parametrii MFCC (Mel Frequency Cepstral Coefficients):** Pentru recunoașterea semnalelor acustice generate de drone este important ca din fiecare cadru să se extragă acele caracteristici specifice acestora. Multe astfel de caracteristici au fost investigate, invenția utilizând coeficienții de predicție liniară (LPC – Linear Prediction Coefficients), ei fiind derivați direct din modul de producere al vorbirii cât și coeficienții predicției liniare perceptuali (PLP – Perceptual Linear Prediction), ei fiind bazați pe sistemul uman de percepție și auditiv. Cu toate acestea însă în ultimele două decenii caracteristicile bazate pe spectru au devenit populare în special datorită faptului că provin direct din transformata Fourier; Caracteristicile bazate pe spectru sunt coeficienții cepstrali în scară Mel (MFCC), iar succesul lor se datorează faptului că utilizează un banc de filtre, cu o scară perceptuală similară cu sistemul auditiv uman, pentru a procesa transformata Fourier. De asemenea acești coeficienți prezintă o robustețe la zgomot și flexibilitate datorită procesării cepstrale.
- e) **Compensarea zgomotului:** Principalul avantaj al transformării amplitudinii spectrului în coeficienți cepstrali logaritmați este transformarea efectului multiplicativ al zgomotului de canal și ambiental (mai ales de la utilizarea de microfoane diferite în procesul de antrenare și testare) într-un efect aditiv. Deoarece aceste efecte sunt invariante pe durata generării semnalului acustic provenit de la drone se poate aplica o procedură simplă de scădere a mediei coeficienților cepstrali totali în fiecare fereastră. Inovația constă în înlăturarea oricărui efect invariant în timp împreună cu informația medie de recepție, lăsând în urmă doar variațiile importante, dinamice, care caracterizează cel mai bine semnalul acustic provenit de la drone. Acești coeficienți compensați sunt obținuți prin procesul de normalizare a mediei cepstrale (CMN) precum urmează [9]:

| | | | | | | | | | | | |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|
| 1 |  | 2 |  | 3 |  | 4 |  | 5 |  | 6 |  |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|

- 1) Calcularea mediei tuturor coeficienților MFCC specifici amprentei acustice ale dronelor.
- 2) Compensarea vectorului de coeficienți MFCC ai fiecărei ferestre de analiză.

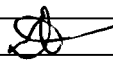
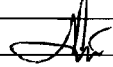
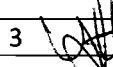
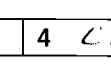
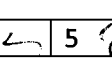
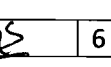
f) **Modelare Joint Factor Analysis:** În recunoașterea amprentelor acustice cu ajutorul modelului universal se poate adapta un model specific unui semnal sonor numit supervector, acest lucru se face prin interpolare liniară a tuturor componentelor de mixturi Gaussiene ale modelului universal pentru a crește probabilitatea logaritmică a unei anumite amprente acustice. În cadrul invenției utilizăm descompunerile în clasa Cohen, această abordare fiind cu caracter de inovație pentru prelucrarea semnalelor acustice.

Această invenție realizează implementarea conceptului de concurență la nivelul unei colecții de rețele neuronale și determină importanța intrărilor care influențează performanțele în recunoașterea amprentei acustice utilizând rețele neuronale. Recunoașterea formelor, domeniu în care se plasează și subiectul acestei invenții, oferă un câmp foarte larg cercetării. Majoritatea modelelor neuronale abordează recunoașterea formelor ca o problemă unitară, globală, fără a face distincția între aportul individual diferit al intrărilor. Este cunoscut faptul că modularitatea și principiul "divide et impera" aplicate rețelelor neuronale le pot îmbunătăți performanțele.

Invenția utilizează modelul rețelelor neuronale concurente (*Concurrent Neural Networks - CNN*) care îmbină paradigmele învățării supervizate și nesupervizate și oferă o soluție optimă detectării amprentelor acustice specifice dronelor. Ideea concurenței este folosită în cadrul invenției la nivelul unei colecții de rețele neuronale care sunt instruite independent pentru a rezolva subprobleme diferite. Recunoașterea se face prin identificarea rețelei neuronale care furnizează cel mai bun răspuns. Așa cum o demonstrează și rezultatele experimentale, acuratețea recunoașterii este mai mare atunci când se utilizează modelul propus prin prezenta invenție, față de cazurile în care nu este utilizată concurența.

Instruirea rețelelor neuronale concurente se bazează pe ipoteza că fiecare modul este instruit cu propriul set de date. Sistemul este alcătuit din rețele neuronale cu diverse arhitecturi. Noi am folosit module de tip perceptron multistrat, de tip rețea neurală cu întârziere în timp și de tip hartă cu autoorganizare. Schema de recunoaștere constă dintr-o colecție de module instruite pe câte o subproblemă și un modul care selectează cel mai bun răspuns. Algoritmii de instruire și de recunoaștere, prezentați în figurile 3 și 4, implementează aceste două tehnici pentru perceptroni multistrat, rețele neuronale cu întârziere în timp și hărți cu autoorganizare. MLP-CNN (Multi-Layer Perceptron - Convolutional Neural Network) și TDNN-CNN (Time-Delay Neural Network – Convolutional Neural Network) folosesc module instruite supervizat și seturile de vectori de instruire conțin atât exemple pozitive cât și negative. Spre deosebire de acestea, SOM-CNN (Self-Organizing Maps – Convolutional Neural Network) constă din module care sunt instruite printr-un algoritm nesupervizat și datele constau doar din exemple pozitive.

Rețelele neuronale modulare / concurente au la bază ideea că, pe lângă nivelurile ierarhice de organizare a rețelelor neuronale artificiale: sinapse, neuroni, straturi de neuroni și rețeaua însăși, se poate crea un nou nivel care combină mai multe rețele neuronale. Modelul propus de invenție numit *Concurrent Neural Networks (CNN)* introduce o nouă tehnică neurală de recunoaștere care se bazează pe ideea competiției între mai multe rețele neuronale modulare care lucrează în paralel. Numărul de rețele folosite este egal cu numărul de clase în care sunt grupați vectorii, iar instruirea este supervizată. Fiecare rețea este proiectată să recunoască corect vectorii dintr-o singură clasă, astfel că răspunsurile cele mai bune apar doar atunci când îi sunt prezentați vectorii din clasa cu care a fost instruită. Acest model este de fapt un cadru care oferă flexibilitate arhitecturii fiindcă modulele pot fi reprezentate de diverse tipuri de rețele neuronale.

| | | | | | | | | | | | |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|--------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|
| 1 |  | 2 |  | 3 |  | 4 |  | 5 |  | 6 |  |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|--------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|

Pornind de la modelul CNN propus în invenție a fost introdus modelul *Concurrent Self-Organizing Maps (CSOM)* care se detașează ca o tehnică nouă cu performanțe excelente.

Schema generală folosită pentru instruirea rețelelor neurale concurente este cea din Figura 3.

În această schemă, n reprezintă numărul de rețele neurale care lucrează în paralel, dar este egal totodată și cu numărul de clase în care sunt grupați vectorii de instruire.

Mulțimea X de vectori este obținută în urma preprocesării semnalelor vocale achiziționate în scopul instruirii rețelelor. Din această mulțime sunt extrase seturile de vectori X_j , $j=1,2 \dots n$ cu care vor fi instruite cele n rețele neurale. În urma aplicării procedurii de învățare, fiecare rețea neurală va trebui să răspundă pozitiv unei singure clase de vectori și să dea răspunsuri negative pentru toți ceilalți vectori. Algoritmul de instruire pentru rețeaua concurentă este următorul:

Etapa 1. Se creează baza de date. Aceasta conține vectorii de instruire obținuți în urma preprocesării semnalului acustic.

Etapa 2. Se extrag din baza de date seturile de vectori specifice fiecărei rețele neurale în parte. Dacă este cazul, se stabilesc ieșirile dorite.

Etapa 3. Se aplică algoritmul de instruire fiecărei rețele neurale folosind seturile de vectori create la pasul 2. Recunoașterea se desfășoară în paralel, conform schemei din Figura 4.

Se presupune că cele n rețele neurale au fost instruite prin algoritmul descris anterior. La aplicarea vectorului de test, rețelele generează câte un răspuns individual, iar selecția constă în alegerea rețelei care a generat răspunsul cel mai puternic. Rețeaua selectată prin regula *câștigătorul ia tot* este declarată câștigătoare. Indicele rețelei câștigătoare va fi indicele clasei în care este plasat vectorul de test. Această metodă de recunoaștere a formelor presupune, așadar, că este *a priori* cunoscut numărul de clase cu care va lucra rețeaua concurentă și că pentru fiecare clasă există suficienți vectori de instruire. Algoritmul de recunoaștere este cel de mai jos.

Etapa a. Este creat vectorul de test prin preprocesarea semnalului acustic.







Etapa b. Vectorul de test este transmis în paralel tuturor celor n rețele neurale instruite în prealabil.

Etapa c. Blocul de selecție stabilește indicele rețelei cu răspunsul cel mai bun. Acesta va fi indicele clasei în care este încadrat vectorul.

Modelele din figurile Figura 3 și Figura 4 pot fi particularizate plasând în locul celor n rețele neurale diferite arhitecturi. În propunerea din invenție s-au utilizat utilizat perceptroni multistrat (MLP), rețele neurale cu întârziere în timp (TDNN) și hărți Kohonen (SOM), obținând astfel trei tipuri diferite de rețele neurale concurente.

Contribuțiile cu caracter de noutate ale invenției sunt:

- Utilizarea unei arii de microfoane dispusă în formă de spirală, cu ponderi adaptive de tip multi-canal cu pas variabil, care oferă posibilitatea detecției de către sistemul acustic propus a prezenței semnalului acustic de complexitate redusă (energie acustică redusă);
- Introducerea unui nou model de clasificare a Rețelelor Neurale Concurente (Concurrent Neural Networks - CNN) ca o colecție de rețele neurale de dimensiuni reduse ce lucrează în paralel, clasificarea efectuându-se conform regulii "câștigătorul ia tot";
- Sistemul este alcătuit din rețele neurale cu diverse arhitecturi;
- Utilizarea module de tip perceptron multistrat, de tip rețea neurală cu întârziere în timp și de tip hartă cu autoorganizare (SOM);
- Schema de recunoaștere constă dintr-o colecție de module instruite pe câte o subproblemă și un modul care selectează cel mai bun răspuns, fiecare rețea neurală componentă a sistemului fiind instruită separat pentru a răspunde corect intrărilor dintr-o singură clasă;
- Numărul de rețele folosit este egal cu numărul de clase în care sunt grupați vectorii, iar instruirea este supervizată;

| | | | | | | | | | | | |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|--------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|
| 1 |  | 2 |  | 3 |  | 4 |  | 5 |  | 6 |  |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|--------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|

- Utilizarea unui algoritm complex de integrare a informațiilor obținute din surse diferite, acustic și video, crescând astfel probabilitatea de recunoaștere și clasificare a dronelor.

Se da în continuare un exemplu de realizare practică a invenției, prezentat în figura 5. Arhitectura sistemului hardware dezvoltat în cadrul invenției, are în componere următoarele: rack National Instruments (NI) Compact cRIO-9042, cu 4 slot-uri de achiziție semnale acustice, controlerul (NI embedded computer) încorporat în cRIO, are un procesor Intel Atom Quad Core cu 1.60 GHz, hard drive 4GB, RAM 4GB, iar procesoarele FPGA sunt model Kintex-7 70T, 4 plăci de achiziție model NI-9231, specializate pentru sunete și vibrații, cu 8 canale diferențiale de intrare, cu 51,2 kS/s/ch, amplificatoarele sunt produse de Texas Instruments, model INA 163 (Low-Noise, Low-Distortion). Componentele electronice ale sistemului sunt în sine cunoscute specialiștilor în domeniu, procurabile din comerț.

- Bibliografie

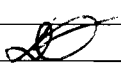
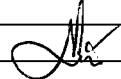
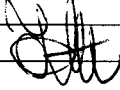
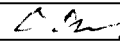
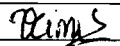
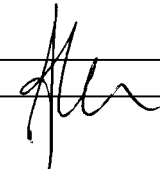
- [1] E. Vattapparamban, A. Gven, Yurekli, K. Akkaya and S. Uluaa, "Drones for smart cities: Issues in cybersecurity, privacy, and public safety," 2016 International Wireless Communications and Mobile Computing Conference (IWCMC), Paphos, 2016, pp. 216-221.
- [2] A. Harrington, "Who controls the drones? [Regulation Unmanned Aircraft]," in Engineering & Technology, vol. 10, no. 2, pp. 80-83, March 2015.
- [3] K. Hartmann and K. Giles, "UAV exploitation: A new domain for cyber power," 2016 8th International Conference on Cyber Conflict (CyCon), Tallinn, 2016, pp. 205-221.
- [4] S. Chu, S. Narayanan, C. C. J. Kuo and M. J. Mataric, "Where am I - Scene Recognition for Mobile Robots using Audio Features," 2006 IEEE International Conference on Multimedia and Expo, Toronto, Ont., 2006, pp. 885-888.
- [5] A. Rabaoui, M. Davy, S. Rossignol and N. Ellouze, "Using One-Class SVMs and Wavelets for Audio Surveillance," in IEEE Transactions on Information Forensics and Security, vol. 3, no. 4, pp. 763-775, Dec. 2008.
- [6] R. Serizel, V. Bisot, S. Essid and G. Richard, "Machine listening techniques as a complement to video image analysis in forensics," 2016 IEEE International Conference on Image Processing (ICIP), Phoenix, AZ, USA, 2016, pp. 948-952.
- [7] J. Mezei, V. Fiaska and A. Molnr, "Drone sound detection," 2015 16th IEEE International Symposium on Computational Intelligence and Informatics (CINTI), Budapest, 2015, pp. 333-338.
- [8] Sameh Souli, Zied Lachiri, and Alexander Kuznietsov, "Using Three Reassigned Spectrogram Patches and Log-Gabor Filter for Audio Surveillance Application". In Proceedings, Part I, of the 18th Iberoamerican Congress on Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications - Volume 8258 (CIARP 2013), Jos Ruiz-Shulcloper and Gabriella Sanniti Di Baja (Eds.), Vol. 8258. Springer-Verlag New York, Inc., New York, NY, USA, 527-534.
- [9] Francis F. Li, Trevor J. Cox, "Digital Signal Processing in Audio and Acoustical Engineering", CRC Press, ISBN 9781466593886 – CAT#K20654, April 11, 2019

| | | | | | | | | | | | |
|---|--|---|--|---|--|---|--|---|--|---|--|
| 1 | | 2 | | 3 | | 4 | | 5 | | 6 | |
|---|--|---|--|---|--|---|--|---|--|---|--|

Revendicări




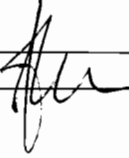
- 1 Sistem pentru detecția dronelor utilizând un modul de achiziție de semnale audio, cu o arie de microfoane cu camera video încorporată, care pentru detecția, recunoașterea (identificarea) și clasificarea dronelor după modul de construcție al acestora și pentru îmbunătățirea semnalului acustic utilizează o arhitectură de calcul pentru prelucrarea semnalelor acustice și extragerea trăsăturilor caracteristice amprentei acustice specifice donelor și clasificarea acestora, compusă din: un modul de prelucrare a semnalelor, un modul de analiză audio, un modul de analiză componente audio și un modul de decizie și clasificare, **caracterizat prin aceea că**, modulul de achiziție de semnale audio este compus dintr-o arie de microfoane cu 30 capsule digitale (MEMS) dispuse în spirala și cameră video încorporată, cu ponderi adaptive de tip multi-canal cu pas variabil, modulul de prelucrare a semnalelor este compus dintr-un sistem National Instruments de tip Compact RIO modular, controler cu procesoare FPGA programabile de către utilizator, 4 module de I/O pentru achiziția semnalelor acustice și amplificatoare Texas Instruments, model INA 163 (Low-Noise, Low-Distortion), dintr-un sub-modul de segmentare audio a semnalelor și un sub-modul de normalizare a segmentelor, modulul de analiză audio este compus dintr-un sub-modul de ferestruire subframe și un sub-modul de analiză temporală și spectrală, pentru ferestruirea semnalelor și analiza simultană în planele temporal și spectral, modulul de analiză componente audio este compus dintr-un sub-modul de calcul statistic și un sub-modul de modelare-extragere caracteristici, pentru extragerea trăsăturilor semnalelor acustice specifice dronelor utilizând algoritmi statistici, iar modulul de decizie și clasificare este compus dintr-un sub-modul de antrenare bază de date, un sub-modul CNN de antrenare, un sub-modul de clasificare și etichetare și un sub-modul decizie alertă sistem, pentru formarea bazei de antrenare pe baza trăsăturilor specifice, utilizarea unor rețele neuronale de tip concurențial care lucrează în paralel pentru clasificarea semnalelor acustice detectate, prin intermediul unor module de tip perceptron multistrat (MLP-CNN), de tip rețea neurală cu întârziere în timp (TDNN-CNN) și de tip hartă cu autoorganizare (SOM-CNN), sistemul incluzând și un bloc de generare alerte de detecție.

2. Metodă pentru recunoașterea/identificarea și clasificarea dronelor, utilizând amprentele acustice ale acestora, conform invenției, pentru protecția unor zone împotriva zborurilor nautorizate ale dronelor, caracterizată prin aceea că include următoarele etape de antrenare pentru CNN :
 - **Etapa 1.** *Se creează baza de date, care conține vectorii de instruire obținuți în urma preprocesării semnalului acustic specific dronelor.*
 - **Etapa 2.** *Se extrag din baza de date seturile de vectori specifice fiecărei rețele neuronale în parte și se stabilesc ieșirile dorite dacă este cazul.*
 - **Etapa 3.** *Se aplică algoritmul de instruire fiecărei rețele neuronale folosind seturile de vectori create la pasul 2.*
 etapele de recunoaștere / clasificare pentru CNN fiind:
 - **Etapa a.** *Este creat vectorul de test prin preprocesarea semnalului acustic specific dronelor.*
 - **Etapa b.** *Vectorul de test este transmis în paralel tuturor celor n rețele neuronale instruite în prealabil.*

| | | | | | | | | | | | |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|
| 1 |  | 2 |  | 3 |  | 4 |  | 5 |  | 6 |  |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|---|---------------------------------------------------------------------------------------|

- **Etapa c.** Blocul de selecție stabilește indicele rețelei cu răspunsul cel mai bun și acesta va fi indicele clasei în care este încadrat vectorul,

prin utilizarea unui algoritm complex de integrare a informațiilor obținute din surse diferite (Data Fusion), sonore și imagini, crescând astfel probabilitatea de recunoaștere și clasificarea a dronelor utilizând integrarea rezultatelor de clasificare obținute de la rețelele CNN, rezultând astfel o dublă identificare a dronelor prin amprentele lor acustice specifice corelate cu detecția video a acestora, în recunoașterea amprentelor acustice fiind utilizate descompunerile în clasa Cohen.

| | | | | | | | | | | | |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-----|---|------|---|---------------------------------------------------------------------------------------|
| 1 |  | 2 |  | 3 |  | 4 | com | 5 | Amis | 6 |  |
|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-------------------------------------------------------------------------------------|---|-----|---|------|---|---------------------------------------------------------------------------------------|

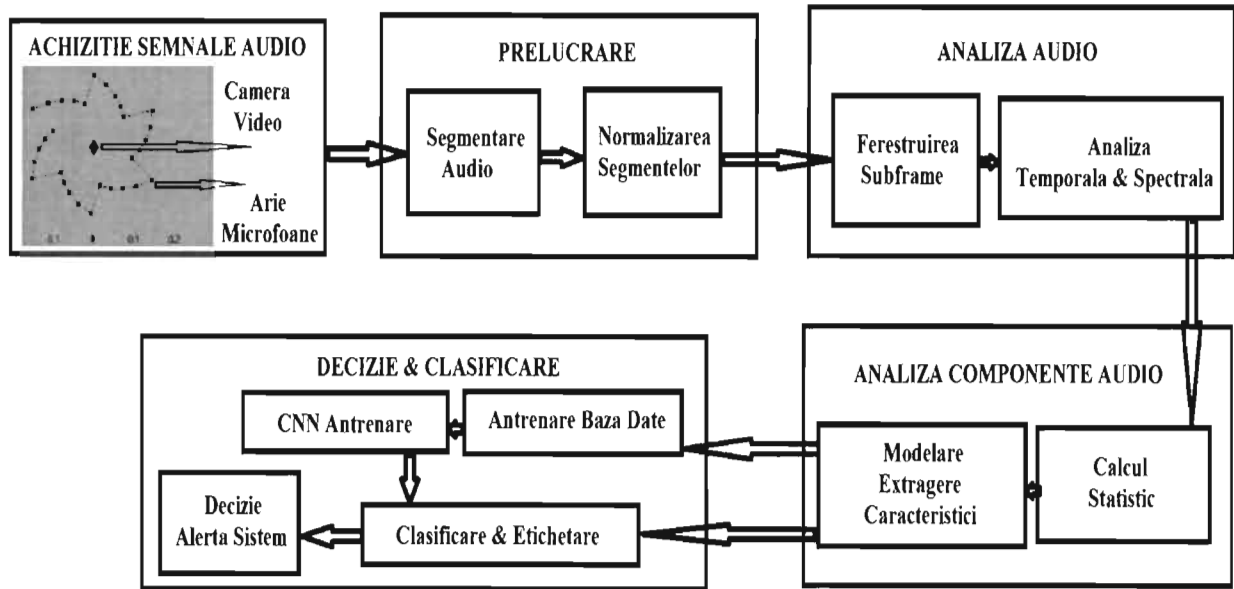


Figura 1. Arhitectura sistemului acustic pentru detectia dronelor.




Figura 2. Configurația arie de microfoane tip spirala cu camera video încorporată.

| | | | | | | | | | | | |
|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|
| 1 | <i>[Signature]</i> | 2 | <i>[Signature]</i> | 3 | <i>[Signature]</i> | 4 | <i>[Signature]</i> | 5 | <i>[Signature]</i> | 6 | <i>[Signature]</i> |
|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|

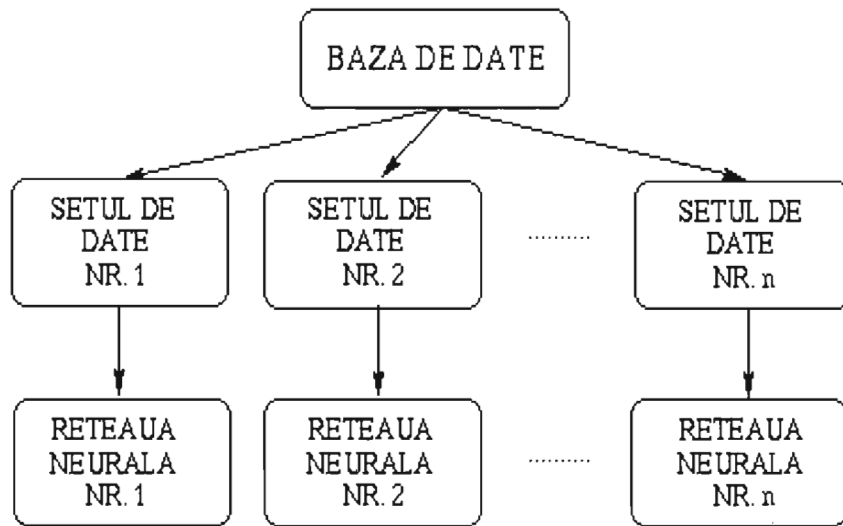


Figura 3. Modelul folosit la antrenarea rețelelor neurale concurente.

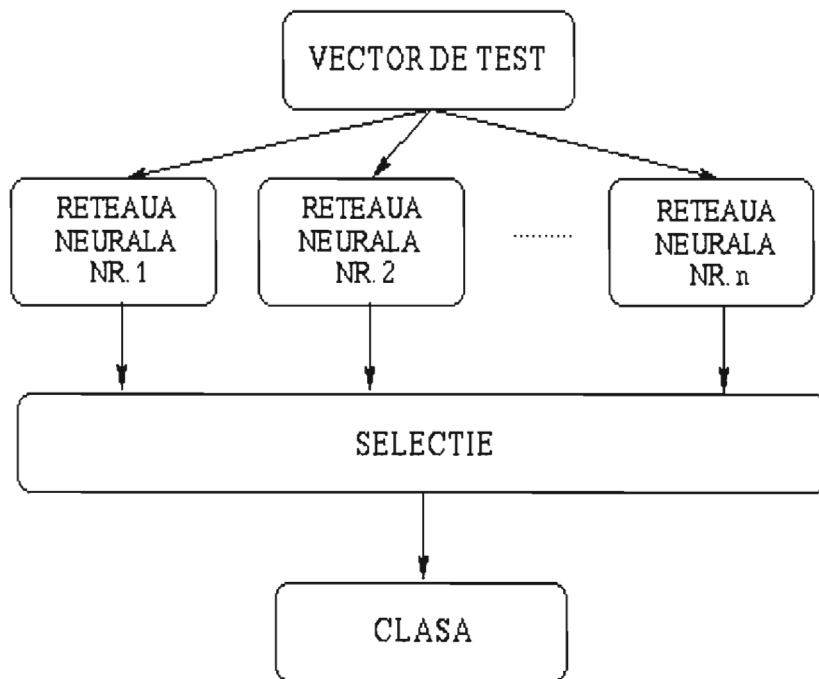


Figura 4. Modelul folosit la clasificarea dronelor de rețelele neurale concurente.

| | | | | | | | | | | | |
|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|
| 1 | <i>[Signature]</i> | 2 | <i>[Signature]</i> | 3 | <i>[Signature]</i> | 4 | <i>[Signature]</i> | 5 | <i>[Signature]</i> | 6 | <i>[Signature]</i> |
|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|---|--------------------|

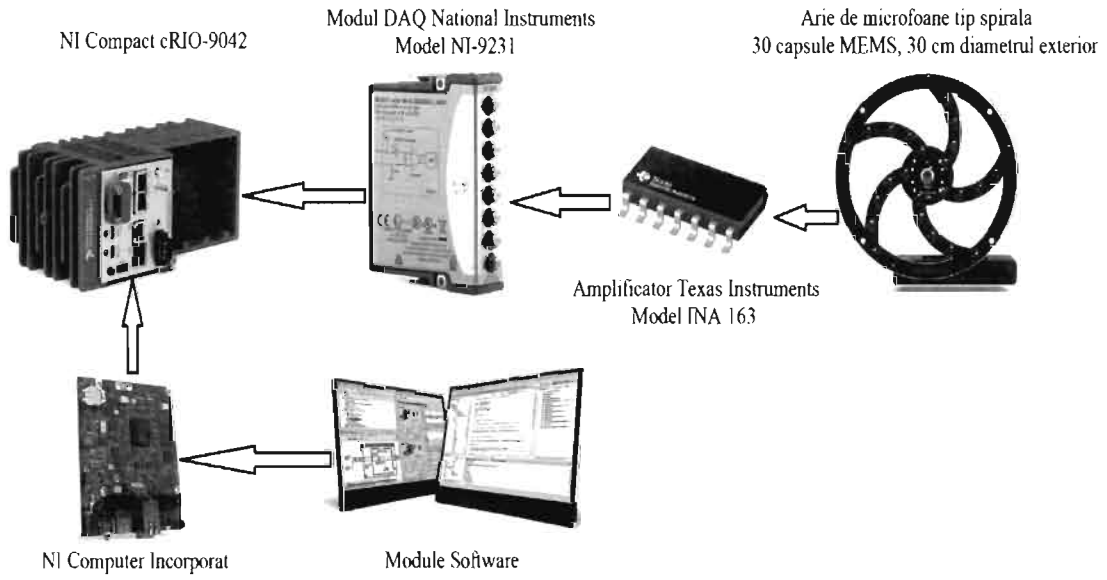


Figura 5. Arhitectura sistemului hardware.

| | | | | | | | | | | | |
|---|--|---|--|---|--|---|--|---|--|---|--|
| 1 | | 2 | | 3 | | 4 | | 5 | | 6 | |
|---|--|---|--|---|--|---|--|---|--|---|--|