

# **STRUCTURI, METODE ȘI APLICAȚII UTILIZATE LA ANALIZA SEMNALULUI DIN PLÂNSUL NOU-NĂSCUTULUI ÎN VEDEREA ASISTĂRII DECIZIEI MEDICALE**

Teză destinată obținerii  
titlului științific de doctor inginer  
la  
Universitatea Politehnica Timișoara  
în domeniul INGINERIA SISTEMELOR  
de către

**Ing. Flaviu-Mircea Feier**

Conducător științific:  
Referenți științifici:

prof.univ.dr.ing. Ioan Silea  
prof.univ.dr. Constantin Ilie  
prof.univ.dr.ing. Liviu Miclea  
conf.univ.dr.ing. Nicolae Robu

Ziua susținerii tezei: 3.09.2015

Seriile Teze de doctorat ale UPT sunt:

- |   |  |
|---|--|
| 1. Automatică                               | 9. Inginerie Mecanică                      |
| 2. Chimie                                   | 10. Știința Calculatoarelor                |
| 3. Energetică                               | 11. Știința și Ingineria Materialelor      |
| 4. Ingineria Chimică                        | 12. Ingineria sistemelor                   |
| 5. Inginerie Civilă                         | 13. Inginerie energetică                   |
| 6. Inginerie Electrică                      | 14. Calculatoare și tehnologia informației |
| 7. Inginerie Electronică și Telecomunicații | 15. Ingineria materialelor                 |
| 8. Inginerie Industrială                    | 16. Inginerie și Management                |

Universitatea Politehnica Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul Școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2015

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității Politehnica Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,  
Tel./fax 0256 403823  
e-mail: editura@edipol.upt.ro

## Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Automatică și Informatică Aplicată al Universității Politehnica Timișoara.

Această lucrare a fost finanțată parțial din proiectul strategic POSDRU/159/1.5/S/137070 (2014) al Ministerul Educației Naționale, România, cofinanțat din Fondul Social European-Investește în oameni, în cadrul Programului Operațional Sectorial Dezvoltarea Resurselor Umane 2007-2013.

Doresc să adresez mulțumiri deosebite conducătorului meu de doctorat, prof. univ. dr. ing. Ioan SILEA pentru sprijinul acordat pe toată durata studiilor doctorale, pentru răbdarea deosebită, înțelegerea și sfaturile care m-au ajutat să duc la capăt o muncă presărată cu multe provocări însă și satisfacții.

Mulțumiri d-lui prof. dr. ing. Liviu MICLEA pentru amabilitatea și disponibilitatea de a recenza teza și de a participa la această susținere într-o perioadă foarte încărcată.

Adresez profunde mulțumiri prof. univ. dr. Constantin ILIE, alături de care am pornit această aventură în studiul semnalului din plânsul nou-născuților în urmă cu 7 ani și care mi-a oferit tot sprijinul posibil atât în plan profesional cât și personal.

Mulțumesc prof. dr. ing. Nicolae ROBU, care în ciuda unui program extrem de aglomerat a avut deosebita amabilitate de a recenza lucrarea de față.

Mulțumesc colectivului domnului profesor, între care dr. Ileana ENĂTESCU, dr. Alexandra NYIREDI și dr. Claudiu ANGELESCU care mi-au fost alături pe toată durata muncii desfășurate la Secția de Neonatologie a Spitalului Județean de Urgență Timișoara, Clinica de Obstetrică-Ginecologie „BEGA” și a secției de Prematuri a Spitalului Clinic de Urgență pentru Copii „Louis Țurcanu” Timișoara. Împreună am reușit înregistrarea a peste 500 de nou-născuți.

Mulțumesc domnului prof. univ. dr. ing. Toma-Leonida DRAGOMIR pentru toate sfaturile utile oferite în toate momentele importante ale activității mele doctorale.

Mulțumesc domnului Ș.I. dr. ing. Antonius STANCIU care mi-a oferit deschiderea către acest domeniu fascinant și care m-a convins prin exemplul personal să nu abandonez această temă în momentele în care rezultatele nu erau deloc promițătoare. Mulțumesc domnului Ș.I. dr. ing. Raul ROBU pentru toate eforturile depuse în a-mi sprijini această activitate încă de la primii pași, pentru sfaturile și disponibilitatea în orice moment.

Mulțumesc colegilor și prietenilor mei de la firma Amoph Systems, cu sprijinul cărora am avut posibilitatea de a desfășura activitatea profesională în paralel cu cea doctorală.

Vreau să mulțumesc părinților mei, Carmen și Mircea FEIER, pentru educația oferită și efortul în a mă forma ca și om, aflat acum în postura susținerii unei teze de doctorat.

Mulțumiri din suflet prietenei mele, Anamaria TODEA, care mi-a servit ca exemplu de dăruire, pasiune și abnegație și alături de care am parcurs până la final acest drum lung care ne-a adus pe amândoi în fața finalizării studiilor doctorale.

Timișoara, Septembrie 2015

Flaviu-Mircea FEIER

Feier, Flaviu-Mircea

**STRUCTURI, METODE ȘI APLICAȚII UTILIZATE LA ANALIZA SEMNALULUI DIN PLÂNSUL NOU-NĂSCUTULUI ÎN VEDEREA ASISTĂRII DECIZIEI MEDICALE**

Teze de doctorat ale UPT, Seria 12, Nr. 17 Editura Politehnica, 2015, 158 pagini, 97 figuri, 14 tabele.

ISSN: 2068-7990

ISBN: 978-606-554-984-5

Cuvinte cheie: semnalul din plânsul nou-născutului, *Data Mining* medical, NEONAT, analiza cuvintelor din plâns

Rezumat:

Tema centrală a activității de cercetare a fost reprezentată de analiza plânsului nou-născuților în vederea extragerii de informație utilă pentru diagnosticul medical. Plânsul nou-născutului reprezintă unul din puținii indicatori care pot fi obținuți pe cale non-invazivă, iar analiza acestuia ca semnal purtător de informație prin metode ingineresti este încă în fază incipientă, neexistând la momentul actual în spitale o instrumentație specializată de analiză a lui. În cadrul activității de cercetare a fost dezvoltată o pentru achiziția și prelucrarea semnalului din plânsul nou-născuților, denumită Neonat. Acest instrument software este tratat ca bloc decizional în cadrul unui sistem de analiză a plânsului care primește la intrarea sa semnalul de plâns, producând la ieșire, pe baza unor funcții interne ce vizează o achiziție configurabilă, valori reprezentabile ale spectrului de frecvență și ale amplitudinii vocale. După primele utilizări ale aplicației în mediul de spital de către cadrele medicale a rezultat și un protocol de lucru generat de problemele întâmpinate și soluționările acestora. După colectarea datelor cu aplicația Neonat s-a realizat un studiu de *Data Mining* în vederea clasificării plânsului nou-născuților grupați în funcție de anumite afecțiunile diagnosticate. Utilizând mediu Weka, s-a reușit clasificarea, folosind algoritmi din clasa arborilor de decizie, a nou-născuților sănătoși de alte trei grupuri patologii similare. În ultima parte a cercetării au fost studiate elemente constitutive ale plânsului, referite ca și „cuvinte”. Studiul a vizat două direcții: pe de o parte evoluția parametrului de saturație la nivel cerebral (la recoltarea de probe sangvine) și corelarea acestuia cu parametrii din plâns (frecvența dominantă) și pe de altă parte evidențierea în mod grafic a suferinței neurologice, prin aplicarea transformatei wavelet discrete pe cuvintele extrase din plâns.

## Cuprins

<b>Lista de figuri.....</b>	<b>8</b>
<b>Lista de tabele .....</b>	<b>11</b>
<b>Lista de abrevieri .....</b>	<b>12</b>
<b>1. Introducere .....</b>	<b>14</b>
1.1 Analiza plânsului la nou-născuți.....	14
1.2 Ingineria în domeniul medical.....	15
1.3 Prezentarea temei de cercetare .....	17
1.4 Obiectivele tezei de doctorat.....	19
1.5 Structura lucrării.....	21
<b>2. Stadiul actual al cercetării în domeniu .....</b>	<b>23</b>
2.1 Cunoașterea la momentul actual .....	23
2.2 Metode utilizate în studiile asupra plânsului infantil .....	28
2.2.1 Achiziția și preprocesarea semnalului din plâns .....	28
2.2.2 Extragerea coeficienților Mel cepstrali .....	29
2.2.3 Extragerea coeficienților de predicție liniară.....	30
2.2.4 Ortogonal Least Square .....	30
2.2.5 Analiza în componente principale .....	31
2.2.6 Rețele neuronale artificiale .....	31
<b>3. Fundamentarea teoretică a cercetării .....</b>	<b>32</b>
3.1 Fonația și mecanismul fonației.....	32
3.2 Reprezentarea digitală a semnalului vocal .....	34
3.3 Analiza Fourier .....	37
3.4 Microsoft Visual Studio .....	38
3.5 Bibliotecile AudioLab, SignalLab și PlotLab .....	39
3.6 Microsoft SQL Server.....	41
3.7 WEKA .....	41
<b>4. Neonat – Aplicație pentru achiziția și prelucrarea semnalului de plâns .....</b>	<b>43</b>
4.1 Arhitectura sistemului.....	43
4.2 Schema bloc și arhitectura aplicației.....	44
4.2.1 Peak Program Meter (PPM) .....	48
4.2.2 Volume Unit Meter (VU) .....	49

<b>4.3</b>	<b>Arhitectura bazei de date .....</b>	<b>57</b>
<b>4.4</b>	<b>Funcții (proceduri) speciale .....</b>	<b>59</b>
<b>4.5</b>	<b>Concluzii parțiale .....</b>	<b>68</b>
4.5.1	Protocolul de înregistrare .....	68
4.5.2	Dificultăți întâmpinate.....	70
<b>5.</b>	<b>Studii de <i>Data Mining</i> în realizarea de clasificări....</b>	<b>72</b>
<b>5.1</b>	<b>Data Mining .....</b>	<b>72</b>
<b>5.2</b>	<b>Studiul de Data Mining în domeniul medical.....</b>	<b>73</b>
<b>5.3</b>	<b>Studiu de <i>Data Mining</i> pentru clasificarea plânsului la nou-născuți .....</b>	<b>75</b>
5.3.1	Definirea problemei de studiat în accepțiunea <i>Data Mining</i> .....	76
5.3.2	Achiziția și preprocesarea datelor .....	77
5.3.3	Protocolul de selecție și post-procesare a datelor pentru <i>Data Mining</i> .....	78
5.3.4	Construirea modelului.....	79
5.3.5	Validarea modelului.....	80
5.3.6	Aplicarea modelului de Data Mining .....	82
<b>5.4</b>	<b>Algoritmii utilizați în construirea modelelor de clasificare ...</b>	<b>82</b>
5.4.1	Arbori de decizie .....	82
5.4.2	Algoritmii „leneși” (lazy) .....	84
5.4.3	Reguli de clasificare.....	84
<b>5.5</b>	<b>Lotul martor (clasa M) .....</b>	<b>85</b>
<b>5.6</b>	<b>Lotul de nou-născuți cu circulară de cordon ombilical (clasa CO) .....</b>	<b>87</b>
5.6.1	Rezultatele cu VU Meter .....	88
5.6.2	Rezultatele cu PP Meter .....	92
<b>5.7</b>	<b>Lotul de prematuri (clasa P) .....</b>	<b>97</b>
5.7.1	Rezultatele cu VU Meter .....	99
5.7.2	Rezultate cu PP Meter .....	101
<b>5.8</b>	<b>Studiul de clasificare al nou-născuților cu patologii severe (PS) .....</b>	<b>105</b>
5.8.1	Rezultatele cu VU Meter .....	106
<b>5.9</b>	<b>Concluzii parțiale .....</b>	<b>110</b>
<b>6.</b>	<b>Analiza „cuvintelor” din semnalul de plâns.....</b>	<b>112</b>
<b>6.1</b>	<b>Achiziția semnalului din plâns cu instrumente profesionale .....</b>	<b>112</b>
<b>6.2</b>	<b>Testarea și calibrarea dispozitivului de achiziție a semnalului din plâns .....</b>	<b>114</b>

<b>6.3</b>	<b>Experimentele cu dispozitivul Olympus și echipamentul medical INVOS .....</b>	<b>117</b>
<b>6.4</b>	<b>Prezentarea studiului și a protocolul de lucru .....</b>	<b>119</b>
<b>6.5</b>	<b>Rezultatele studiului .....</b>	<b>120</b>
<b>6.6</b>	<b>Studiul suferinței neurologice .....</b>	<b>124</b>
<b>6.7</b>	<b>Analiza suferinței neurologice cu aplicarea transformatei wavelet discrete.....</b>	<b>128</b>
<b>6.8</b>	<b>Concluzii parțiale .....</b>	<b>132</b>
<b>7.</b>	<b>Concluzii, contribuții personale și direcții viitoare de cercetare.....</b>	<b>134</b>
<b>7.1</b>	<b>Concluzii și contribuții personale .....</b>	<b>134</b>
<b>7.2</b>	<b>Direcții viitoare de cercetare .....</b>	<b>137</b>
	<b>Bibliografie .....</b>	<b>138</b>
	<b>ANEXA 1 – Experimente cu echipamentul INVOS .....</b>	<b>145</b>
	<b>ANEXA 2 – Analiza suferinței neurologice .....</b>	<b>149</b>
	<b>Lista de lucrări publicate în domeniul temei de cercetare .....</b>	<b>155</b>

## Lista de figuri

Figura 1.1 Sistemul de suport al diagnosticului medical .....	20
Figura 2.1 Etapele extragerii coeficienților cepstrali .....	29
Figura 3.1 Elemente ale aparatelor digestiv și respirator implicate în fonație .....	33
Figura 3.2 Modelul simplificat al producerii vorbirii .....	34
Figura 3.3 Model al producerii vorbirii .....	34
Figura 3.4 Eșantionarea unui semnal continuu .....	35
Figura 3.5 Fereastra dreptunghiulară .....	36
Figura 3.6 Fereastra Hamming .....	36
Figura 4.1 Schema arhitecturii sistemului de înregistrare .....	44
Figura 4.2 Schema bloc a aplicației .....	45
Figura 4.3 Diagrama ACR a aplicației .....	46
Figura 4.4 Modulul „Formular” .....	48
Figura 4.5 Dispozitiv de măsură Peak Progam Meter .....	49
Figura 4.6 Dispozitiv de măsură Volume Unit Meter .....	50
Figura 4.7 Achiziția cu Neonat a unui semnal din plâns .....	50
Figura 4.8 Modulul „Înregistrare” .....	52
Figura 4.9 Modulul „Testare” .....	53
Figura 4.10 Structura fișierelor spectrum.txt, ppmMeter.txt, vuMeter.txt .....	54
Figura 4.11 Structura internă a unui fișier weka.arff .....	55
Figura 4.12 Modulul „Încărcare” .....	56
Figura 4.13 Modulul „Registru” .....	57
Figura 4.14 Arhitectura bazelor de date .....	58
Figura 4.15 Modelul construirii numelui tabelului de valori pentru o înregistrare .....	59
Figura 4.16 Evenimentele din timpul și de la oprirea înregistrării .....	61
Figura 4.17 Organigrama funcționării afișajului duratei înregistrării .....	62
Figura 4.18 String-ul de conectare al aplicației la baza de date .....	63
Figura 4.19 Funcția de conectare și extragere de valori dintr-o tabelă a bazei de date .....	64
Figura 4.20 Funcția de căutare cu actualizarea tuturor tabelor .....	65
Figura 4.21 Validarea adăugării datelor unui nou-născut și ale mamei .....	66
Figura 4.22 Încărcarea din aplicație a datelor conținute în fișierele de intensități .....	67
Figura 4.23 Parcurgerea hash-ului și afișarea conținutului lui .....	68
Figura 4.24 Lansarea aplicației WEKA prin codul aplicație .....	68
Figura 5.1 Pașii urmați în rezolvarea unei probleme de <i>Data Mining</i> .....	74
Figura 5.2 Schema generală a sistemului pentru clasificarea plânsului .....	75
Figura 5.3 Încărcarea datelor în WEKA .....	79
Figura 5.4 Funcționarea clasificării în studiul de față .....	80
Figura 5.5 Forma matricei de confuzie .....	81
Figura 5.6 Arbore de decizie generat cu Random Tree .....	83
Figura 5.7 Exemplu de semnal vocal din lotul martor .....	86
Figura 5.8 Schema modelelor de clasificare cu cele mai bune performanțe cu VU Meter .....	88
Figura 5.9 VU: M – C – Arborele de decizie (pe mulțimea de antrenament) .....	89
Figura 5.10 M – C – Arborele de decizie (pe mulțimea de test) .....	89
Figura 5.11 VU: M – C – Curba ROC (clasele M și CO) .....	90
Figura 5.12 VU: Sinteza metricilor de evaluarea a arborelui de decizie cu datele de test .....	90
Figura 5.13 Grafic "Precision & Recall" (clasele M și CO) .....	91



Figura 5.14 Schema modelelor de clasificare cu cele mai bune performanțe cu PP Meter .....	93
Figura 5.15 Arborele de decizie (mulțimea de antrenament).....	93
Figura 5.16 Arborele de decizie (mulțimea de test) .....	94
Figura 5.17 PPM: M-C: Curba ROC (clasele M și CO).....	94
Figura 5.18 PPM: Sinteza metricilor de evaluarea a arborelui de decizie cu datele de test.....	95
Figura 5.19 PPM: "Precision & Recall" (clasele M și CO) .....	95
Figura 5.20 Prematur ID_GOM.....	97
Figura 5.21 Prematur ID_CRI .....	98
Figura 5.22 Prematur ID_RAD .....	98
Figura 5.23 Schema modelelor de clasificare cu cele mai bune rezultate cu VU Meter .....	99
Figura 5.24 VU: Curba ROC (clasale M și P).....	100
Figura 5.25 VU: Sinteza metricilor de evaluarea a arborelui de decizie cu datele de test.....	100
Figura 5.26 PPM: Schema modelelor de clasificare cu cele mai bune performanțe	102
Figura 5.27 PPM: Arborele de decizie generat (clasele M și P) .....	102
Figura 5.28 PPM: Curba ROC (Clasele M și P) .....	103
Figura 5.29 PPM: Graficul "Precision & Recall" (clasa M și P).....	103
Figura 5.30 PPM: Sinteza metricilor de evaluarea ale clasificatorului date de test	104
Figura 5.31 Secvență de plâns pentru un nou-născut cu suferință neurologică majoră .....	106
Figura 5.32 VU: M – PS – Mulțimea de antrenament.....	107
Figura 5.33 VU: Arborele de clasificare (clasele M și PS) .....	107
Figura 5.34 VU: Curba ROC (Clasele M și PS) .....	108
Figura 5.35 VU: Graficul "Precision & Recall" .....	109
Figura 5.36 Sinteza metricilor de evaluarea ale clasificatorului date de test .....	109
Figura 6.1 Cuvânt, propoziție și frază pe o înregistrare de plâns .....	112
Figura 6.2 Dispozitivul Olympus LS-100 PCM Multi-Track Recorder.....	113
Figura 6.3 Poziționarea la 90° a microfoanelor încorporate.....	113
Figura 6.4 Testarea echipamentului Olympus .....	114
Figura 6.5 Schema de calibrare a echipamentului de achiziție Olympus PCM.....	115
Figura 6.6 Semnalul generat și stocat în memoria osciloscopului.....	115
Figura 6.7 Frecvența fundamentală a semnalului sinusoidal achiziționat cu Olympus PCM .....	116
Figura 6.8 Evidențierea unei latențe inițiale de 200 ms .....	116
Figura 6.9 Senzorii INVOS și aplicarea lor pe capul nou-născutului.....	118
Figura 6.10 Experiment: echipamentul INVOS, aplicația Neonat și dispozitivul Olympus.....	119
Figura 6.11 Exemplu de nou-născut cu scădere a parametrului rSO2 sub limita admisibilă .....	121
Figura 6.12 Semanlul din plâns în timpul monitorizării cu INVOS(Figura 6.11) la recoltarea unui nou-născut.....	121
Figura 6.13 Spectrul de frecvență aferent semanlului din plâns din Figura 6.12 ..	122
Figura 6.14 Primul cuvânt după recoltarea din braț .....	123
Figura 6.15 Spectru frecvență pe cuvânt la durere .....	123
Figura 6.16 Valorile maxime de deviație a saturației la fiecare nou-născut din studiu .....	124
Figura 6.17 Cuvânt aparținând unui nou-născut cu suferință neurologică .....	126
Figura 6.18 Coeficienții Mel cepstrali suprapuși peste forma de undă .....	126

Figura 6.19 Coeficienții Bark suprapuși peste forma de undă .....	127
Figura 6.20 Funcția de autocorelația aplicată cuvântului din plâns (Figura 6.17) .	127
Figura 6.21 Transformata wavelet discretă aplicată pe cuvântul din plâns din Figura 6.17 .....	128
Figura 6.22 Filtrarea semnalului segmentat.....	129
Figura 6.23 Eșantionarea diadică peste întreg cuvântul din plâns .....	129
Figura 6.24 a) Cuvânt extras din plâns pentru nou-născut (ID_SN_3) cu suferință neurologică b) transformata wavelet in reprezentare 3D a cuvântului de la a) ...	130
Figura 6.25 a) Cuvânt extras din plâns pentru nou-născut (ID_SN_27) cu suferință neurologică b) transformata wavelet in reprezentare 3D a cuvântului de la a) ....	130
Figura 6.26 Cuvânt extras din plâns pentru nou-născut (ID_N_3) fără afecțiune b) transformata wavelet in reprezentare 3D a cuvântului de la a) .....	131
Figura 6.27 Spectru de frecvență a întregului cuvând din Figura 6.24 .....	131
Figura 6.28 Spectru de frecvență a întregului cuvând din Figura 6.25 .....	132
Figura 6.29 Cuvântul din plâns peste reprezentarea transformatei wavelet discrete a cuvântului (nou-născutul diagnosticat cu suferință neurologică ID_SN_11) .....	132

## Lista de tabele

Tabel 2.1 Sinteza cercetării corelației plânsului infantil cu afecțiuni specific .....	24
Tabel 4.1 Simbolurile dintr-o diagramă ACR .....	47
Tabel 5.1 Forma generală a unui tabel de decizie .....	84
Tabel 5.2 VU: Metrici de validare a modelului clasificator .....	91
Tabel 5.3 VU: Clasificatorii cu cele mai bune rezultate (clasele M și CO).....	92
Tabel 5.4 PP: Metrici de validare a modelului clasificator.....	96
Tabel 5.5 PP Meter: Clasificatorii cu cele mai bune rezultate.....	96
Tabel 5.6 Metrici de validare a modelului clasificator .....	101
Tabel 5.7 VU Meter: Clasificatorii cu cele mai bune rezultate .....	101
Tabel 5.8 Metrici de validare a modelului clasificator .....	104
Tabel 5.9 PP Meter: Clasificatorii cu cele mai bune rezultate.....	105
Tabel 5.10 Metrici de validare a modelului clasificator.....	110
Tabel 5.11 VU : Clasificatorii cu cele mai bune rezultate .....	110
Tabel 6.1 Sinteza măsurătorilor semnalului generat și a celui achiziționat .....	117

## Lista de abrevieri

AI – **A**rtificial **I**ntelligence (Inteligența Artificială)  
AN – **A**pneea **N**eonatală  
ARFF (.arff) – **A**tttribute **R**elation **F**ile **F**ormat  
BD – **B**ază de **D**ate  
CO – **C**irculară de **C**ordon **O**mbilical  
CD – HMN – **C**ontinuos **D**ensity **H**idden **M**arkov**M**odel  
CIL – **C**ommon **I**ntermediate **L**anguage  
CLR – **C**ommon **L**anguage **R**untime  
DCT – **D**iscrete **C**osine **T**ransform (Transformata Cosinus Discretă)  
EDA – **E**xploratory**D**ata **A**nalysis (Analiza exploratorie a datelor)  
EEG – **E**lectro**e**ncefalogramă  
EHIP – **E**ncehalopatie **H**ipoxico-**I**schemică **P**erinatală  
EKG – **E**lectro**k**ardiogramă  
EMG – **E**lectro**m**iogramă  
exp – Experiment  
ENNS – **E**volutionary **N**eural **N**etwork **S**ystem (Sistem rețea neuronală evolutivă)  
FFT – **F**ast **F**ourier **T**ransform (Transformata Fourier Rapidă)  
FRNN – **F**uzzy **R**elational **N**eural **N**etwork  
FSVM – **F**uzzy **S**upport **V**ector **M**achine (Mașini cu suport vectorial fuzzy)  
GRNN – **G**eneral **R**egresion **N**eural **N**etwork  
GUI – **G**raphical **U**ser **I**nterface (Interfața Grafică Utilizator)  
HC – **H**emoragie **C**erebrală  
IFSM – **I**terative **F**orward **S**election **M**ethod  
IT – **I**nformation **T**echnology (Tehnologia Informației)  
LDA – **L**inear **D**escriptive **A**nalysis (Analiza Liniar Descriptivă)  
LP – **L**inear **P**rediction (Predicție Liniară)  
LPC – **L**inear **P**rediction **C**oefficients  
LSTM – **L**ong **S**hort **T**erm **M**emory  
MFBEC – **M**el-**F**ilter **B**and **E**nergy **C**oefficients  
MFCC – **M**el **F**requency **C**epstral **C**oefficients (Coeficienții Mel Cepstrali)  
MFECs – **M**el **F**requency **S**pectral**E**ntropy **C**epstrum **c**oefficients  
MLP – **M**ulty **L**ayer **P**erceptron (Rețea Perceptron Multistrat)  
OLS – **O**rthogonal **L**east **S**quare (Denumire consacrată în literatură)  
PCA – **P**rinciple **C**omponent **A**nalysis (Analiza Componentelor Principale)  
PHNN – **P**aralel **H**idden **M**arkov **M**odel  
PP Meter – **P**eak **P**rograme **M**eter  
RCIU – **R**estricție de **C**reștere **I**ntra-**U**terină  
rSO2 – Indicator procentual pentru nivelul saturației de oxigen din sânge  
SCJ – **S**caled **C**onjugate **G**radient  
SIFT – **S**imple **I**nvers **F**iltering **T**racking  
SOAP – **S**imple **O**bject **A**ccess **P**rotocol  
SSM – **S**mothed **S**pectrum **M**ethod  
SDR – **S**indrom **D**etresă **R**epiratorie  
STFT – **S**hort **T**ime **F**ourier **T**ransform  
SOM – **S**elf **O**rganizing **M**ap (Rețele Neuronale cu Autoorganizare)  
T2FPM – **T**ype **2**Fuzzy **P**attern **M**atching  
TpMF – **T**rapezoidal **M**embership **F**unction  
TrMF – **T**riunghiular **M**embership **F**unction  
TDNN – **T**ime **D**elayed **N**eural **N**etworks (Rețele Neuraonale cu întârziere temporală)

TDS – **T**abular **D**ata **S**tream

VU Meter – **V**olume **U**nit **M**eter

WLT – **W**avelet **P**acket **T**ransform

WLPC – **W**eight **L**inear **P**rediction **C**epstral **C**oefficients

# 1. Introducere

Materialul acestui capitol al lucrării realizează introducerea cititorului în domeniul și subiectul prezentei activități de cercetare. Este descrisă tema centrală a activității de cercetare, constând în analiza plânsului nou-născuților în vederea extragerii de informație utilă pentru diagnosticul medical postnatal. Ulterior prezentării relativ detaliate a temei de cercetare și a necesității efectuării unui astfel de studiu, sunt definite obiectivele avute în vedere. Finalul capitolului prezintă structura lucrării de față, cu rezumarea conținutului fiecărui capitol din cadrul acesteia.

## 1.1 Analiza plânsului la nou-născuți

Plânsul reprezintă prima modalitate de comunicare a nou-născutului cu mediul înconjurător, odată cu venirea sa pe lume și continuă ca formă singulară de manifestare a stării interioare până la verbalizarea comunicării. Cu toate că pe parcursul sarcinii starea fătului este de cele mai multe ori atent monitorizată de către cadrele medicale specializate prin efectuarea diverselor teste și analize, anumite afecțiuni sunt depistate după perioade mai lungi de timp, când apar primele simptome și manifestări ale suferinței. Tratarea în vederea vindecării, sau cel puțin pentru stoparea progresiunii unei afecțiuni, trebuie începută din primele momente ale instalării acesteia. Diagnosticarea nou-născuților este dificil de realizat în cazul multor afecțiuni, și ca urmare acestea ajung să progreseze până la stadii în care tratarea lor nu mai este posibilă. O analiză exhaustivă a stării nou-născutului în vederea determinării problemelor posibil instalate deja, însă nevizibile la momentul nașterii ar presupune efectuarea a numeroase teste medicale, mare parte dintre ele fiind invazive. În absența unor suspiciuni care să dicteze necesitatea efectuării testărilor cu anumite specificități, pentru nou-născuții cu indicatori fizici și fiziologici considerați între limitele statistice normale, această analiză detaliată nu mai prezintă justificare. Acest aspect este și unul conform bunelor practici, nedorindu-se în lumea medicală o stresare a pacientului prin numeroase teste care, de cele mai multe ori sunt invazive (recoltări de sânge, înțepări, fotostimulare și altele). Luând în considerare cele menționate, rezultă foarte clar că se justifică necesitatea de a identifica și alți indicatori care să ofere informație suplimentară asupra stării nou-născutului.

Plânsul, ca mijloc de comunicare directă între nou-născut, mama sa și personalul medical specializat constituie în sine un indicator al stării sale interioare. Ca unică formă de comunicare în primele momente din viață, acesta poate încuiba informație care se poate dovedi foarte utilă în luarea deciziilor de către personalul specializat. Astfel, analiza în detaliu a plânsului, dată fiind și natura non-invazivă a acestui procedeu se poate impune ca metodă de screening postnatal, extrem de utilă în sălile de naștere ale spitalelor. Plânsul este la momentul actual un constituenț al unui indicator, anume scorul Apgar, calculat imediat după naștere precum și la 5 și la 10 minute de la naștere. La calcularea acestui indicator se ține cont de o serie de observații de la naștere, plânsul fiind prezent în două dintre cele cinci categorii de observații care conduc la obținerea acestui indice. Într-una din aceste observații

se urmărește răspunsul nou-născutului la stimuli externi, fiind urmărită o formă vocalizată de reacție. Cealaltă evaluare este una calitativă, însă subiectivă cu privire la primul plâns din timpul nașterii- fără utilizarea vreunui instrument de analiză vocală de către personalul medical.

Ideea studierii plânsului la nou-născuți datează din anii 1960 când au fost generate primele spectrograme din plâns în vederea realizării unei corelații ale acestuia cu posibile patologii. Pe măsura dezvoltărilor tehnologice, cu posibilități extinse de achiziție, prelucrare și analiză a semnalelor vocale în context general, studiile au putut fi diversificate, iar în zilele noastre, cu instrumentele actuale pot fi realizate cercetări foarte ample care să cuprindă echipe multidisciplinare necesare unei riguroase și abilitate tratări ale acestui subiect. Lucrarea de față se înscrie pe această direcție.

## 1.2 Ingineria în domeniul medical

Domeniul medical a devenit, în ultimele decenii, de mare interes pentru ingineri, aspect ce poate fi demonstrat prin existența unor tehnici tot mai avansate/complexes în spitale. Prin creșterea volumului de date stocabile, prelucrabile și interpretabile computațional, în jurul anilor 1950 se poate afirma că a luat naștere domeniul ingineriei medicale; se publică tot mai multe articole științifice în această direcție, iar începând cu anii 1970 domeniul acesta devine oficial recunoscut de comunitățile științifice. Sistemele complexe care compun organismul uman, precum și interconexiunile și interdependențele dintre ele, oferă multiple teme de cercetare pentru ingineri, în special pentru domeniul „Ingineria Sistemelor”. Domeniul ingineriei medicale atrage domeniile calculatoarelor și tehnologiei informației, ingineria și tehnologia de ultimă oră în toate ramurile medicale în tot ce înseamnă cercetare, educație și metodologii de diagnostic. Evoluția acestui nou domeniu se manifestă mult mai pregnant în prezent, când lumea medicală continuă să aprecieze capabilitățile computaționale și să le utilizeze din ce în ce mai mult ca suport în luarea deciziilor [1].

După cum a fost menționat anterior, la jumătatea secolului 20 se materializează primele utilizări ale informaticii în domeniul medical. Primele raportări sunt din stomatologie, când în ciuda existenței unui număr foarte redus de calculatoare, un medic stomatolog american, dr. Robert Ledley, utilizează pentru prima dată puterea computațională în studiile sale de cercetare-acestea necesitau prelucrări numerice ale datelor sale medicale. Ledley este un pionier al domeniului informaticii medicale, lucrarea sa din 1955, „Medical progress – medical electronics” fiind considerată de referință și o pledoarie pentru utilitatea electronicii vremii în studiile medicale avansate [2].

La începutul anilor '60 apar primele evidențe electronice în studii veterinare urmate apoi, la sfârșitul deceniului, de prime evidențe electronice ale pacienților umani. În prezent, în țările dezvoltate există evidențe naționale care centralizează toate datele necesare ale pacientului. În spațiul european, un raport al membrilor unei comisii europene prezintă programele dedicate acestui subiect, dorindu-se ca în viitorul apropiat toate țările membre ale UE să posede sisteme naționale de evidență a pacienților, capabile să fie scalate către un sistem informatic european central [3], [4].

Pe lângă utilizarea noii tehnici pentru menținerea evidențelor, apare și unul din primele sisteme expert, Mycin, ce utilizează inteligența artificială în vederea identificării bacteriilor care provoacă infecții severe precum meningita [5].

Deși nu se impune realizarea unei istorii a implicării ingineriei în medicină, se cuvine a menționa câteva realizări care au un impact deosebit în diagnosticarea, tratarea sau intervenția în diverse afecțiuni. În zilele noastre, aportul ingineriei și tehnicii ingineresti în medicină și practicile medicale este deosebit de consistentă. În continuare, într-o enumerare selectivă, sunt menționate realizări ingineresti ale zilelor noastre care facilitează munca medicilor și contribuie la bunăstarea generală a pacienților:

- **Microscopie chirurgicale 3D** - facilitează realizarea de operații complexe în neurochirurgie sau oftalmologie, pe zone aproape invizibile ochiului uman. În trecut nu foarte îndepărtat, pentru asemenea operații, chirurgii erau nevoiți să opereze folosindu-se de lupe sau ochelari chirurgicali. Acum, cu această descoperire, asemenea operații pot fi efectuate mai precis prin vizualizarea imaginii furnizate de aceste microscopie pe monitoare. Astfel, zona operată este vizibilă cu o claritate sporită, dar și în condiții mult mai bune pentru personalul medical datorită sporirii ergonomiei poziției chirurgului în timpul operației. Transmiterea prin rețea a unor astfel de operații constituie un important instrument didactic și în același timp pune bazele operațiilor la distanță; toate deservind în cele din urmă pacientul și calitatea serviciilor oferite acestuia;
- **Implantul cohlear** este un dispozitiv medical care înlocuiește funcția urechii interne afectate. Spre deosebire de protezele auditive, care fac sunetul mai puternic, implantul cohlear lucrează în locul părții afectate a urechii interne (cochlee) pentru a oferi semnale sonore către creier. Implanturile cohleare au ajutat peste 150.000 de persoane să audă pentru prima dată. Dispozitivele acestea se adresează persoanelor care au o pierdere moderată până la profundă a auzului în ambele urechi sau obțin rezultate nesatisfăcătoare sau nu au rezultate cu protezele auditive. Multe persoane au implanturi cohleare bilaterale (la ambele urechi). Auzul cu două urechi poate îmbunătăți abilitatea de a identifica direcția sunetului și de a separa sunetele pe care dorim să le auzim de cele pe care nu dorim să le auzim [6], [7];
- **Echipamentul de rezonanță magnetică nucleară (RMN)** și investigația prin această tehnică este o procedură de înaltă performanță, minim invazivă, care nu provoacă trauma și nu iradiază. Se folosește un câmp magnetic cu intensitate mare și radiofrecvența pentru obținerea imaginilor multiplan de înaltă rezoluție ale corpului uman, permițând evidențierea leziunilor cu precizie milimetrică. Scanarea RMN este aplicabilă pentru toate organele corpului omenesc, constituind metoda determinată pentru depistarea afecțiunilor sistemelor nervos, musculo-scheletal, respirator, genital și circulator [8];
- **Sistemul chirurgical da Vinci** reprezintă cea mai nouă tehnică chirurgicală de asistență robotizată a personalului medical care permite realizarea de operații complexe cu doar câteva incizii minore. Acest sistem este compus din mai multe subsansamble constând dintr-un subsistem microscopic 3D de înaltă definiție (HD) pentru mărirea imaginilor și instrumentație articulată menită a se îndoi și roti mai bine decât încheietura chirurgului în vederea realizării de incizii minime și precizie sporită. Rolul sistemului este acela de a-i facilita chirurgului o vedere mai detaliată precum și precizie, dexteritate și control mult îmbunătățit. Până în prezent sistemul da Vinci a fost utilizat în lumea întreagă în ultimii 10 ani, în peste 1.5 milioane de proceduri chirurgicale (ginecologice,



urologice, cardiace, toracice sau generale), sprijinind medicii și confortul final al pacientului [9];

- **Tehnologia imprimării 3D** a cunoscut în ultimii ani o dezvoltare tot mai pronunțată. Astfel, cercetările pe această temă cu implicații în domeniul medical vizează utilizarea acestei tehnologii în vederea creării de organe artificiale utilizabile în diversele operații de implanturi. Se dorește astfel eliminarea acelor lungi liste de așteptare în vederea efectuării unui transplant și implicit conferirea mai multor șanse de supraviețuire a pacienților în cauză.

### 1.3 Prezentarea temei de cercetare

Având în vedere consistentul progres tehnologic introdus inevitabil și în medicină, devine firească abordarea unor probleme medicale pentru care încă tehnica nu a venit cu o soluție. Analiza plânsului la nou-născuți prin tehnici moderne și nu doar o evaluare subiectivă a acestuia de către cadrele medicale, pentru a determina semnalmamente patologice diverse în vederea investigării țintite și mai amănunțite, constituie ideea centrală abordată în această lucrare. Există, desigur, o serie de analize și teste medicale, invazive sau non-invazive, care se fac încă de la naștere și care conturează într-o oarecare măsură starea de sănătate a nou-născutului. Acestea vizează, pentru început posibile malformații fizice care pot fi imediat detectabile și mai apoi, diverse suferințe care nu puteau fi determinate în etapa de viață intrauterină a fătului. Spre exemplu, unele manifestări patologice pulmonare și în special neurologice pot trece neobservate în anumite forme și necesită investigare bine ținută în vederea diagnosticării precise. Experiența dobândită în timp, de către un cadru medical, poate servi ca metodă empirică de observare a diferitelor suferințe, dar nu constituie un instrument viabil pentru detectarea acestora în fiecare caz de apariție a unei afecțiuni.

O privire de ansamblu asupra celor mai întâlnite afecțiuni ale nou-născutului este necesară în contextul unei lucrări care urmărește asistarea diagnosticului medical. În cele ce urmează, se prezintă pe scurt unele dintre aceste situații patologice, văzute din perspective medicală. Aceasta este realizată în forma unei sinteze, rezultate în urma mai multor discuții cu personalul medical din cadrul:

- Secției Clinice de Neonatologie a Spitalului Clinic Județean de Urgență Timișoara;
- Spitalului Clinic de Urgență pentru Copii „Louis Țurcanu” Timișoara, Secția de Nou-Născuți Prematuri.

Suferința neurologică, la nou-născuții cu patologie neurologică perinatală, s-a aflat în centrul preocupărilor științifice ale ultimului deceniu, principalul motiv fiind: înțelegerea mecanismelor neurochimice implicate în constituirea leziunilor cerebrale și salvarea nou-născuților cu vârstă de gestație tot mai mică prin serviciile de terapie intensivă neonatală.

Patologia neurologică a nou-născutului poate fi declanșată de numeroși factori care acționează asupra sistemului nervos în perioada perinatală. De cele mai multe ori, aceasta se întâlnește într-un context larg de modificări patologice pulmonare, cardiovasculare, renale și metabolice [10].

Trebuie lămurit faptul că patologia respiratorie manifestată cel mai frecvent, în unitățile de terapie intensivă neonatală, prin **Sindromul de Detresă Respiratorie (SDR)** și **Apneea Neonatală (AN)** acționează indirect la nivel cerebral prin

modificarea valorii gazelor sanguine și a hemodinamicii cerebrale, determinând instalarea tulburărilor neurologice cu posibila evoluție spre suferința neurologică.

De asemenea trebuie menționat faptul că orice nou-născut cu patologie, exceptând cea neurologica, prezintă un risc neurologic crescut datorită instabilității hemodinamice, metabolice și acido-bazice, factori principali ai reglării circulației și metabolismului celular cerebral.

**Encefalopatia Hipoxic - Ischemică Perinatală (EHIP) și Hemoragia Cerebrală (HC)** reprezintă cele mai comune leziuni cerebrale în perioada neonatală. În ciuda avantajelor majore ale îngrijirii în neonatologie, injuria cerebrală hipoxic – ischemică perinatală rămâne o cauză majoră de sechele neurologice pe termen lung. În esență, suferința neurologică a nou-născutului se datorează reducerii oxigenării creierului și/sau reducerii irigației acestuia. **EHIP** reprezintă o afecțiune severă a fătului și nou-născutului prematur (rar la nou-născutul la termen), 90% din cauzele bolii apar în timpul vieții uterine (pre/intra-partum) și 10% după naștere (postpartum). Riscul **EHIP** rezultă din particularitățile anatomice și fiziopatologice ale acestei categorii de vârstă: capacitatea scăzută de autoreglare a fluxului sanguin cerebral (presiunea de perfuzie cerebrală este direct proporțională cu tensiunea arterială sistemică și astfel creșterea acesteia poate duce la hemoragie cerebrală, respectiv scăderea tensiunii arteriale sistemice poate determina hipoperfuzia cerebrală cu ischemia țesutului cerebral și apariția leziunilor cerebrale), vascularizație periventriculară săracă și prezența unor mici suprapuneri între marile artere cerebrale. De o importanță deosebită în etichetarea acestei entități, o reprezintă recunoașterea asfixiei ante-, intra- și postnatale. Asfixia perinatală reprezintă reducerea semnificativă și chiar întreruperea fluxului sanguin către creier.

Factorii patogenici generali ai asfixiei perinatale includ [11], [12]:

- a. → *factori antepartum* reprezentați de afecțiuni materne cronice sau acute.
- b. → *factori intrapartum*: prezența anormală, travaliu prelungit, expulzie dificilă.
- c. → *factori neonatali*: prematuritate, tulburări respiratorii.

Cheia diagnosticului este evaluarea clinică a statusului neurologic al nou – născutului în perioada neonatală precoce.

Leziunile neuropatologice ale **EHIP** sunt complexe, multiple, adeseori difuze și intricate. Aceste leziuni pot să fie prezente de la naștere (adică s-au constituit chiar din viața intrauterină), sau pot apare după naștere ca urmare a imaturității structurilor cerebrale, incapabile să facă față stresului reprezentat de nașterea propriuzisă (așa cum este cazul prematurului). Indiferent cum s-au constituit, aceste leziuni prezintă două direcții evolutive:

- direcția favorabilă reprezentată de refacerea integrală a structurilor neurologice (la cazurile cu suferința neurologică ușoară și medie);
- direcția nefavorabilă reprezentată de apariția complicațiilor și sechelelor care fac din suferința neurologică una durabilă uneori pe parcursul întregii vieți, sau conduc spre evoluție fatală.

Evoluția și prognosticul **EHIP** depind de următorii factori:

- stadiul (severitatea) și durata hipoxiei antenatale;
- prezența asfixiei intranatale;
- prematuritate, la nou-născut;
- diagnosticarea și inițierea rapidă a tratamentului;
- caracteristici funcționale ale deficitului imunologic și homeostatic la nou-născut;
- comorbidități somatice în primul an de viață.

Combinarea acestor factori, poate determina diferite tipuri de evoluție și prognostic.

În prezent, cea mai importantă măsură de prevenire a EHIP rămâne o bună monitorizare a travaliului și nașterii, precum și o intervenție terapeutică promptă ori de câte ori este necesar, atât în perioada de gestație cât și în perioada neonatală.

Deși nu se pot defini în mod concret valori ale gazelor sanguine la care să apară leziunile neurologice și nici durata necesară de modificare a acestora, există totuși o corelație statistică între prezența acestor modificări și apariția suferinței neurologice. În acest context, relativ recent, se utilizează echipamentul de oximetrie cerebrală INVOS în vederea identificării acestor modificări. Posibilitatea de a diagnostica patologia neurologică prin înregistrarea și analiza plânsului, ar facilita depistarea precoce, cu costuri reduse și aparatură minimă, a cazurilor care pot beneficia de intervenție terapeutică rapidă putând astfel oferi o cât mai bună calitate a vieții copilului și familiei acestuia.

Orice suferință neurologică (chiar minimă) poate să lase o amprentă mai mult sau mai puțin importantă asupra funcțiilor organice. Aceasta demonstrează încă odată, dacă mai este cazul, că sistemul nervos central este coordonatorul funcționării normale a tuturor organelor, aparatelor și sistemelor. Din punct de vedere senzorial, suferința neurologică poate afecta pe termen scurt sau lung organele și funcțiile senzoriale de bază și implicit procesul de comunicare și de învățare. Prin funcțiile senzoriale copilul achiziționează toate informațiile necesare din mediul de viață și răspunde adaptativ prin mijloacele de comunicare acestor percepții. La nou-născut singura posibilitate de comunicare este reprezentată de plâns catalogat drept un limbaj primitiv, direct, nonverbal. Prin acest limbaj, nou-născutul își exprimă starea de confort sau disconfort precum și starea de sănătate sau boală.

Pornind de la aceste considerente, este evidențiată necesitatea unui sistem nervos normal, matur și sănătos care va reprezenta un substrat ideal pentru o comunicare excelentă a acestuia cu părinții și ambientul. Invers, un sistem nervos imatur, lezat sau sechelar, va reprezenta un handicap important în realizarea acestei comunicări sau chiar va bloca această comunicare. În esență, acest blocaj se traduce prin modificarea mai mult sau mai puțin semnificativă a principalului semnal de comunicare al acestuia cu mediul, adică a vocii și plânsului copilului [13].

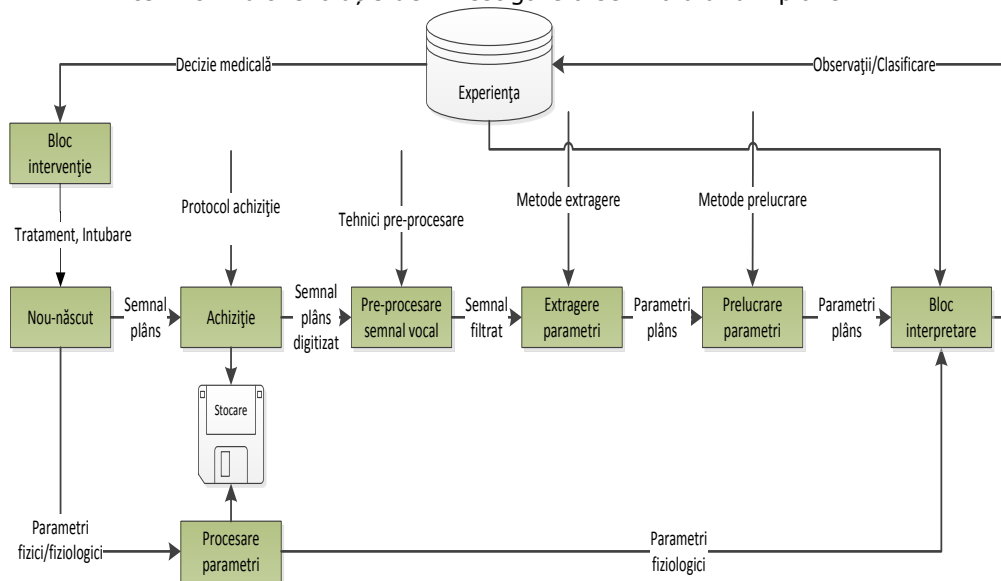
Acest scurt preambul medical are scopul de a evidenția cele mai comune situații patologice ale nou-născutului și implicațiile acestora. Pentru identificarea unei patologii sunt necesare numeroase informații asupra nou-născutului obținute direct din parametri fiziologici sau prin teste invazive, care presupun recoltări de sânge și monitorizare prin conectare la aparatură medicală. Un studiu asupra plânsului nou-născutului are rolul de a determina corelații între parametri obținuți din plâns și cei rezultați din diferite teste și măsurători medicale sau clasificarea plânsului provenit de la nou-născuți cu afecțiuni similare pe baza unor caracteristici comune din semnalul vocal. Studiul are rolul de a genera noi abordări, protocoale de lucru și înțelegere la modul cel mai general în vederea sprijinirii domeniului neonatal cărui aplecare finală este viața și calitatea ei, încă din primele clipe ale sale.

## 1.4 Obiectivele tezei de doctorat

Obiectivul principal al tezei de doctorat constă în definirea și utilizarea unor tehnici de analiză de semnal aferente ingineriei sistemelor și aplicate asupra semnalului asociat plânsului nou-născutului, care să conducă la realizarea unui sistem de suport pentru personalul medical în vederea luării de decizii, pe baza

informațiilor obținute fără a utiliza metode invazive. Acest sistem se va compune din mai multe subsisteme, vizualizabile grafic în Figura 1.1:

- un subsistem de achiziție a semnalului din plânsul nou-născutului, capabil să interpreteze semnalul de la intrare și să prezinte în mod vizual informație de interes;
- subsistemul de preprocesare a informației care trebuie să asigure o primă filtrare a informației înaintea începerii analizei propriu-zise;
- un subsistem de extragere al parametrilor de interes care vor fi studiați/analizați;
- subsistem de prelucrare a parametrilor în care se vor efectua operațiuni asupra datelor extrase în vederea utilizării lor în studii;
- subsistem de procesare a parametrilor fiziologici ai nou născutului achiziționați prin tehnică medicală specializată;
- un subsistem sub forma unui bloc de interpretare în cadrul căruia trebuie să se realizeze procesarea parametrilor de la intrare pe baza experienței dobândite, prin tehnici de *Data Mining*, iar mai apoi corelații între indicatorii fizici respectiv fiziologici și cei extrăși din semnalul de plâns;
- pe de altă parte se urmărește stabilirea unor strategii de analiză și clasificare sistematică a cazurilor cuprinse în înregistrările plânsului, corelate cu alte rezultate provenite de la alte echipamente utilizate de medici, ceea ce constituie un alt obiectiv al lucrării. Se au în vedere aspectele privitoare la nivelul oxigenării cerebrale, analiza spectrală și tehnici multirezoluție de investigare a semnalului din plâns.



**Figura 1.1 Sistemul de suport al diagnosticului medical**

Conform cu Figura 1.1, se pot deduce și obiectivele subsecvente celui principal. Acestea urmăresc elaborarea protocoalelor de achiziție a semnalului de plâns al nou-născutului, stabilirea tehnicilor de preprocesare, a metodelor de filtrare și extragere a parametrilor ce pot prezenta interes, sintetizarea unor metode de prelucrare și interpretare a rezultatelor ținându-se cont și de parametrii fiziologici.

Se ajunge astfel la generarea unei decizii medicale privind starea de sănătate a nou-născutului bazată pe informații obținute neinvaziv.

## 1.5 Structura lucrării

Subcapitolul de față are ca scop înțelegerea modului de prezentare a cercetării efectuate, prin realizarea unei treceri în revistă a structurii prezentei lucrări, cu evidențierea părților esențiale ale acesteia. Totodată se argumentează ordinea logică a capitolelor și a subiectelor dezvoltate astfel încât să se atingă obiectivele propuse.

Primul capitol realizează o introducere în domeniul tezei de doctorat, prin prezentarea temei centrale a cercetării, analiza plânsului la nou-născuți și încadrarea acesteia în contextul general al informaticii medicale unde, în ultimii ani, dezvoltările și implicarea ingineriei devin din ce în ce mai vizibile și chiar spectaculoase. În capitolul de debut sunt de asemenea trasate și principalele obiective ale cercetării doctorale, sintetizate într-un sistem de colectare, preprocesare și interpretare a informației provenite din plâns, augmentată de parametri fizici și fiziologici rezultați din măsurători cu dispozitive medicale.

Capitolul al doilea prezintă stadiul actual al cunoașterii în ceea ce privește studiile asupra plânsului infantil cu rezultatele obținute până la momentul actual. În cadrul acestui capitol este prezentată o procedură generală de studiu urmată în majoritatea cercetărilor pe această temă și sunt detaliate metodele de analiză și extragere a parametrilor, cele mai des utilizate și pentru care rezultatele sunt cele mai promițătoare. Capitolul cuprinde și o sinteză a rezultatelor obținute de cercetători și metodele utilizate de aceștia în studiile întreprinse pe diverse baze de date cu plâns.

În al treilea capitol este prezentat suportul teoretic care stă la baza prezentei cercetări precum și mijloacele tehnice utilizate în abordările practice. Se prezintă un cadru teoretic pentru semnalul vocal în general, pornind de la modelul sistemului fonator și anatomia acestuia. Modelul de producere a vorbirii este tratat din perspectiva inginerescă, prin care, acest sistem generează semnale cu conținut informatic, iar apoi este interpretat prin instrumente și cu metode specializate. Acestea din urmă sunt prezentate în contextul studiului de față, exemplificând și descriind uneltele software de specialitate, utilizate pentru extragerea și prelucrarea informației de interes din semnalul de plâns.

În al patrulea capitol se oferă o descriere amplă a arhitecturii și funcțiilor principale ale aplicației Neonat, special dezvoltată pentru a oferi suport în cadrul prezentului studiu de analiză a plânsului nou-născuților. Sunt prezentate modulele constituente ale aplicației cu detalieri asupra interacțiunii dintre acestea, precum și o prezentare succintă a elementelor special realizate pentru achiziția semnalului din plâns și procesarea acestuia în vederea studierii ulterioare a parametrilor extrași.

În capitolul cinci este detaliat studiul de Data Mining realizat pentru efectuarea de clasificări între nou-născuții grupați în loturi în funcție de patologii, parametri fizici și indicatori medicali. Capitolul este structurat după o metodă generală de realizare a unui studiu de *Data Mining*, dar a fost adaptat pentru problema realizării de clasificări din plânsul nou-născuților. Rezultatele și validarea acestora se constituie ca și subcapitole ce urmează definiției studiului realizat.

Al șaselea capitol este destinat prezentării studiilor întreprinse și a rezultatelor în investigarea suferinței neurologice și a riscului lezional cerebral. În cadrul acestui capitol sunt prezentate și alte tehnici, prin utilizarea de echipamente

auxiliare, cum ar fi aparatul medical INVOS pentru determinarea saturației centrale a oxigenului la nivel cerebral și dispozitivul profesional de achiziție de sunet Olympus LS-100 PCM Multi-Track recorder.

În ultimul capitol, destinat concluziilor, este realizată o sinteză a rezultatelor obținute în acord cu obiectivele trasate la începutul cercetării. În acest cadru final sunt menționate și direcțiile avute în vedere pentru continuarea muncii de cercetare.

Desigur că realizarea experimentelor într-o clinică/spital a necesitat rezolvarea unor probleme colaterale care nu sunt menționate în teză. Unele dintre ele au fost de natură obiectivă (spre exemplu ritmul nașterilor), iar altele au vizat organizarea în vederea achiziției datelor în condiții cvasi asemănătoare, doar așa putându-se valida rezultatele cercetării.

## 2. Stadiul actual al cercetării în domeniu

În capitolul de față se realizează o sinteză a cunoașterii în materie de analiză a plânsului nou-născuților. Sunt prezentate rezultatele mai multor cercetări într-o formă tabelară care, de asemenea, cuprinde și metodele utilizate de diversele grupuri de cercetători precum și bazele de date investigate. Similitudinile în etapele urmate în realizarea acestui tip de analiză au facilitat prezentarea unei metodologii de abordare, fiind detaliate cele mai des întâlnite metode de lucru pentru fiecare etapă.

### 2.1 Cunoașterea la momentul actual

Studiile de cercetare privind plânsul la nou-născuți au o istorie relativ recentă. Primele investigații documentate în acest sens au ca referință anul 1968 [14], când sunt generate primele spectrograme din plâns cu scopul asocierii acestora cu diverse situații patologice. Această apariție oarecum târzie trebuie pusă pe seama lipsei unor instrumente care să faciliteze astfel de investigații. Cu toate acestea, în ultimii 20 de ani se observă o creștere a numărului de lucrări publicate ce au ca preocupare analizarea plânsului copiilor și al nou-născuților. Tot în această perioadă, în cercetările apărute se constată implicarea tot mai pronunțată a echipelor de ingineri sau cercetători din domeniul ingineresc. Astfel, procesarea digitală a semnalului din plâns constituie un element comun al tuturor articolelor perioadei respective pe această temă. Achiziția semnalului vocal se realizează cu ajutorul mai multor tipuri de dispozitive, cum ar fi: diverse tipuri de microfoane, reportofoane, camere video digitale sau dictafoane. Deși toate aceste dispozitive au în comun partea de microfonie, enunțarea lor separată se datorează caracteristicilor fiecăruia dintre ele, acestea din urmă influențând achiziția semnalului.

Scopul studiilor realizate pe plânsul nou-născuților constă, în mare parte, din cercetări în determinarea unui set de parametri care pot fi utilizați în stabilirea unei relații între plâns și o anumită patologie (hipotiroidism, hipoxie, tulburări de auz, asfixie, autism și altele) sau simptome (discomfort, durere, supărare, nervozitate, foame) care pot fi definatorii pentru starea generală de sănătate [15], [16], [17], [18], [19], [20]. Ca exemple de astfel de indicatori, între cei mai utilizați în studiile întreprinse, se numără:

- Frecvența fundamentală ( $F_0$ ) [14], [21], [22], [23] definită astfel în majoritatea studiilor, deși semnalul din plâns nu este unul periodic, studiile investigând mai degrabă o frecvență dominantă [24] a semnalului sau chiar frecvența fundamentală dar în contextul unor cadre extrase din acesta;
- Melodia plânsului (modificările în timp ale fundamentalei) [25];
- Frecvența de rezonanță a tractului vocal [14];
- Primii trei formanți  $F_1, F_2, F_3$  [25], [26], [27];
- Energia semnalului și numărul trecerilor prin zero pentru analizele în domeniul timp.

Acești indicatori sunt toți tratați din perspectiva plânsului ca semnal audio fiind asociați cu caracteristici de la naștere și/sau parametri fiziologici (puls,

frecvență respiratorie, gazele sangvine, tensiune arterială, oxigenarea periferică sau centrală a sângelui precum și alți indicatori fiziologici măsurabili).

În studiile din literatura de specialitate se definește *plânsul unui nou-născut sănătos* ca având următoarele caracteristici:

- Valorile medii ale frecvenței fundamentale sunt în jurul a 450 Hz, sau cu valori cuprinse în intervalul [400 Hz, 600 Hz] [14], [21], [25];
- Melodia plânsului este oscilantă [28];
- Prezența mai multor segmente de plâns într-o comunicare [28];

*Plânsul patologic* este definit și el în cadrul mai multor studii observându-se următoarele aspecte:

- Frecvența fundamentală are valori extreme comparativ cu plaja de valori asociată plânsului sănătos [28], [29];
- Melodia plânsului prevalează în coborâșuri și coborâșuri urmate de urcușuri [30].

Indicatorii colectați din semnalul vocal sunt utilizați în studii împreună cu caracteristici ale nou-născutului imediat după naștere, între care se pot enumera: greutatea, perimetrul toracic, perimetrul cranian, circumferința craniană, vârsta gestațională a mamei sau scorul Apgar la 5 și la 10 minute de la naștere. Pe de altă parte sunt luate în considerare și măsurători fiziologice cum ar fi pulsul, saturația sangvină periferică a oxigenului (măsurată cu pulsoximetrul) sau saturația sangvină centrală (măsurată cu spectrometrul de infraroșu apropiat - NIRS) [31].

Studiile privitoare la plânsul nou-născutului și corelația acestuia cu diverse patologii au fost realizate, o bună parte dintre ele, de către grupuri de cercetători pe durata mai multor ani de studiu. În aceste perioade au fost publicate mai multe lucrări cu rezultatele obținute. Între aceste grupuri se evidențiază cel format din Zabidi, Mansour, Sahak, ([25], [29], [30], [32]) și colectivele acestora care pe parcursul a trei ani (între 2009 și 2012) au publicat 15 lucrări care vizează corelația plânsului cu situații patologice precum hipotiroidismul sau asfixia.

În Tabel 2.1 se regăsește o sinteză a cercetării ultimilor 20 de ani pe tema plânsului nou-născutului sau a celui infantil, pentru realizarea de clasificări pe diverse suferințe și patologii. Acesta este parțial preluat din studiul de sinteză a cercetării asupra analizei plânsului la nou-născuți [33] și extins cu studii ulterioare acestui articol sau omise de către autorul acestuia. Studiul literaturii de specialitate a fost extins și către plânsul infantil, dată fiind apropierea metodelor de analiză a acestuia cu cel al nou-născutului. Tabelul condensează informații cu privire la autorii studiilor, bazele de date utilizate în studiu, modelul de extragere al parametrilor din plâns, clasificatorii utilizați și acuratețea modelului pe baza de date utilizată.

**Tabel 2.1 Sinteza cercetării corelației plânsului infantil cu afecțiuni specific**

Referințe	Baza de date/ numar copii	Model extragere caracteristici	Clasificatori	Acuratețe model
Sănătos vs Hipoacustic				
J. O. Garcia 2003	BD/31	LPC	SCJ	91,8% (314 cazuri); 86,20 % (1036 cazuri)
J. O. Garcia 2003	BD/53	MFCC & LPC	SCJ NN	96,8% (314 cazuri)



J. O. Garcia 2003	BD/53	MFCC & LPC	SCJ NN	97,43% (506 cazuri)
J. O. Garcia 2003	BD/53	MFCC & PCA	SCJ NN	97.43%
Varallyay Jr. 2004	BD/37	F0 (SSM)	-	-
Varallyay Jr. 2004	BD/70	Caracteristici domeniul timp	-	-
O. Reyes-Galaviz, 2009	BD Mexic-Cuba	MFCC	ENNS	100% (unele experimente)
M. Mansouri 2009	Chillanto/24	MFECs	MLP	88.30%
M. Hariharan 2011	Chillanto	STFT	GRNN	99.00%
Sănătos vs Asfixie				
O. Reyes-Galaviz. 2009	BD Mexic-Cuba	MFCC	ENNS	100% (unele experimente)
R. Sahak 2010	BD a Univ. Milano-Bicocca	MFCC & OLS	SVM	93.16%
A. Zabidi 2010	Chillanto	MFCC (F-ratio)	MLP	93.38%
A. Zabidi 2010	Chillanto și BD a Univ. Milano-Bicocca	MFCC & OLS	MLP	94.00%
A. Zabidi 2010	Chillanto	MFCC & BPSO	MLP	95.07%
M. Hariharan 2011	Chillanto	WPT	PNN	99.00%
M. Hariharan 2011	Chillanto	STFT	PNN& GRNN	99.00%
Sănătos vs Hipotiroidism				
A. Zabidi 2009`	BD a Institutului Superior de Tehnologie Atlixco	MFCC & F-ratio	-	-

Sănătos vb Hiperbilirubinemie				
K. Santiago-Sanches 2009	BD	MFCC & LP, Intensitate, Cohleograme	t2-FPM	95,56% (LPC-MFCC)
Sănătos vs Palatoschizis				
Ledeman 2002	BD Germania-Israel/47	MFCC & coef. derivați	CD-HMN	91.00%
Sănătos vs SDS				
Ledeman 2002	BD Israel/40	MFCC și coef derivați	CD-HMN	63.00%
Sănătos vs Phenylketonuria (PKU)				
C. Manfredi 2006	BD Italia	F0, F1-F3, zgomot	-	1 caz depistat
Palatoschizis cu placă palatală vs Palatoschizis fără placă palatală				
Ledeman 2008	BD Germania/7	MFCC & LPC și coef. derivați	PHMN	90.00%
Sănătos vs ankyloglossia cu deviația epiglotei și a laringelui				
Yoshifumi Okada 2011	Wang/49	IFSM	LDA	~100%
Sănătos vs Plâns dureros				
R. Hidayati 2009	BD Indonezia/50	F0, F1 - F3,	k-means	90%, eroare 10%
Sănătos vs Autism				
S. Orlandi 2012	BD Italia/24	F0	-	-
3 clase de probleme				
M. Petroni 1995	BD Nervozitate, frica panica/16	MFCC, MFBECC	FFNN, RNN, TDNN, CCNN	90.40%
O. Reyes Galaviz 2004	Chillanto (sănătoși, hipoacustic, asfixie)	MFCC	ANFIS	96.00%

O. Reyes Galaviz 2004	Chillanto (sănătoși, hipoacustic, asfixie)	MFCC & LPC	TDNN	98.67%
I. Suaste-Rivas 2004	Chillanto (sănătoși, hipoacustic, asfixie)	MFCC	FRNN (cu TrMF)	88.00%
I. Suaste-Rivas 2004	Chillanto (sănătoși, hipoacustic, asfixie)	MFCC	FRNN (cu TpMF)	98.00%
O. Reyes Galaviz 2005	Chillanto (sănătoși, hipoacustic, asfixie)	MFCC & LPC	ENNS	96.79%
O. Reyes Galaviz 2005	Chillanto (sănătoși, hipoacustic, asfixie)	MFCC	FFIDNN	96,08%- 97,39%
S. Montiel 2006	Chillanto exp 1. sănătos, surd, asfixie; exp 2 durere, foame și fără durere și fără foame	MFCC	FSVM	exp1:94,98% exp2: 97,83%
K. Santiago-Sanchez 2009	BD normal, asfixie, Hiperbilirubinemi e	MFC, LPC, coef. intensit., cohleograme	t2-FPM	91,74% LPC-Cochleogram
M. Hariharan 2010	Chillanto, sănătos, hipoacustic, asfixie)	WLPCC	PNN	Peste 98,00%
4 clase de probleme				
Lederman 2010	BD, sănătos, "cri-du-chat", hidrocephalus, Palatoschizis	F0 (SIFT)	-	-
A. Mesaoud 2010	BD durere, discomfort, foame și boala	MFCC	PNN	71.40%

## 2.2 Metode utilizate în studiile asupra plânsului infantil

Cercetările ultimilor ani oferă multe similitudini din punctul de vedere al strategiei de interpretare al plânsului nou-născutului. Etapele urmate respectă anumite tipare, discriminarea între studii realizându-se la nivelul tehnicilor aplicate în fiecare etapă. Astfel, procesul de clasificare al plânsului infantil poate fi divizat (ca demers pentru prediagnosticare) în următoarele etape:

1. **Etapa de achiziție a semnalului**, în care cu ajutorul diverselor dispozitive enumerate în paragrafele anterioare (microfoane de studio, reportofoane, camere video și altele), se realizează digitizarea vocalizării și stocarea ei pe un mediu magnetic;
2. **Etapa de preprocesare a semnalului**, în cadrul căreia se realizează o pregătire inițială în vederea analizării ulterioare prin aplicarea de filtre, utilitare de extragere a zonelor nevocale și eliminare a zgomotului precum și alte operațiuni de natură să aducă semnalul brut într-o formă adecvată metodei de studiu alese;
3. **Etapa de extragere a parametrilor** în care, fie sunt extrase date în domeniul timp (intensități vocale, forma de undă), fie se aplică transformări în vederea trecerii în alte domenii, cum ar fi cele bazate pe frecvență (frecvența fundamentală, formații, puterea semnalului, coeficienții Mel cepstrali (detaliați în secțiunea 2.2.2 sau coeficienții liniari predictivi, detaliați în secțiunea 2.2.3);
4. **Etapa de reducere a numărului parametrilor** apare des în studii datorită cantității mari de informație care face, deseori, operarea și interpretarea mult prea dificilă, chiar și în contextul tehnicii actuale. Mulți din parametri extrași nu conțin informație utilă astfel că, prin metode specifice studiului propus se realizează reducerea acestora; un exemplu în acest sens este analiza componentelor principale (PCA), prezentată în cadrul secțiunii 2.2.5, analiza liniară discriminativă (LDA) sau Ortogonal Least Square (OLS), detaliată în secțiunea 2.2.4;
5. **Etapa de clasificare** a plânsului când se realizează diferențierea în grupurile de nou-născuți asupra cărora se dorește realizarea diferenței (la modul general, normal versus patologic). În această ultimă etapă, mare parte din studii utilizează diverse forme de rețele neuronale artificiale (ANN) oferite în secțiunea 2.2.6, modele Markov ascunse (HMM) sau mașini cu suport vectorial (SVM). Acestea ocupă o mare parte din studiile pe tema clasificării plânsului infantil.

### 2.2.1 Achiziția și preprocesarea semnalului din plâns

În etapa de achiziție a semnalului vocal din plâns, acesta este preluat cu ajutorul diverselor tipuri de echipamente de achiziție care pot fi numite generic microfon. Din perspectiva acestei etape, cercetările se diferențiază prin tipul de microfon utilizat și caracteristicile de digitizare ale semnalului vocal. Considerând cercetările actuale și dezvoltările tehnologice din domeniul prelucrării semnalelor, problema achiziției fidele și reprezentarea pe o rezoluție corespunzătoare nu constituie un aspect menționat în multe din studiile recente. Din acest motiv, pentru studiul de față s-a insitat pe furnizarea de informație cât mai detaliată care să facă posibilă reproducerea experimentelor realizate. Fundamentarea teoretică a acestei etape va fi detaliată în capitolul următor, în care vor fi prezentate modelul fonator

uman și instrumentele teoretice de interpretare ale acestuia. Pentru situațiile în care achiziția nu poate fi realizată respectând anumite rigori, se trece în etapa de preprocesare a semnalului din plâns în vederea producerii unui semnal cât mai util studiului în următoarele etape.

### 2.2.2 Extragerea coeficienților Mel cepstrali

Analiza coeficienților Mel cepstrali reprezintă tehnica cea mai utilizată în studiile privind analiza plânsului infantil, în etapa de extragere a parametrilor din semnalul vocal [34], [35], [36]. Mai precis, se determină coeficienții Mel cepstrali ca parametri de analiză ulterioară, de forma:

$$c(n) = DCT(\log(|FFT(s(n))|)), \quad (1)$$

unde:

$n$  reprezintă ordinul coeficientului Mel cepstral,

$c(n)$  reprezintă coeficientul Mel cepstral rezultat, iar

$s(n)$  un cadru al semnalului vocal asupra căruia se aplică o serie de prelucrări în vederea obținerii coeficienților  $c(n)$ .

Tehnica este foarte des folosită ca urmare a faptului că prin procedeul de obținere a parametrilor de studiu se imită foarte fidel caracteristicile fiziologice ale urechii umane în recepționarea sunetelor. Este cunoscut faptul că urechea umană percepe liniar frecvențele joase (până în 1 kHz) și logaritmice frecvențele înalte (peste 1 kHz) [30]. În realizarea acestei tehnici de extragere a parametrilor vocali sunt urmate o serie de etape în studiile întreprinse, sintetizate în schema din Figura 2.1.




Figura 2.1 Etapele extragerii coeficienților cepstrali

Într-o prima etapă studiile cu această aplicare optează univoc pentru utilizarea ferestrei Hamming cu o suprapunere între 10%-50% peste cadre de 10ms-30ms considerate ca fiind cvasistaționare ale semnalului vocal prelucrat [30]. Pe fiecare fereastră rezultată se aplică, într-o următoare etapă, transformata Fourier (FT). Din rațiuni de reducere a complexității se optează în studii pentru obținerea Transformatei Fourier Discrete (TFD) prin aplicarea calculelor specifice Transformatei Fourier Rapide (FFT) (posibile prin alegerea numărului eșantioanelor ca putere a lui 2). Pe spectrele rezultate se aplică un banc de filtre triunghiulare trece-bandă. Numărul filtrelor aplicate depinde de frecvența de eșantionare aleasă la achiziția semnalului, cel mai comun număr de filtre utilizate fiind 26. Coeficienții Mel cepstrali rezultă în final prin aplicarea Transformatei Cosinus Discrete (DCT) pe valorile logaritmice ale răspunsului frecvenței filtrate - în vederea reducerii numărului coeficienților.

### 2.2.3 Extragerea coeficienților de predicție liniară

Analiza prin predicție liniară (*LP – Linear Prediction*), numită și modelare autoregresivă, reprezintă un instrument deosebit de puternic pentru analiza semnalului vocal. Este întâlnită în etapa de extragere a parametrilor, fiind utilizată ca tehnică în studiile asupra plânsului infantil. Metoda are la bază modelul producerii sunetului de aparatul fonator uman, iar ideea de analiză din cadrul metodei are la bază corelația care există între eșantioanele succesive ale semnalului. S-a observat, că eșantionul curent poate fi exprimat (aproximat) printr-o combinație liniară a eșantioanelor anterioare [21], [31], [37]:

$$s[n] = \sum_{k=1}^p a_k s[n-k] + G \cdot u[n] \quad (2)$$

unde,

$u$  reprezintă sursa de excitație,  $G$  valoarea câștigului și  $a_k$  reprezintă coeficienți de predicție liniară.

Reducerea numărului de coeficienți de predicție liniară se obține minimizând eroarea de aproximare (predicție) pe un interval finit. Acești coeficienți pot descrie semnalul și spectrul pe un interval scurt de timp și sunt utilizați în următoarele faze ale analizei vocale.

### 2.2.4 Ortogonal Least Square

În urma etapelor în care semnalul este preprocesat și apoi supus diverselor tehnici de extragere a parametrilor considerați necesari în studiu, se poate opta pentru o reducere a numărului parametrilor. Această etapă este realizată, în anumite studii, pe considerentul eliminării acelor parametri cu valoare neînsemnată pentru investigația întreprinsă sau în cazul existenței redundanței informației. Una din aceste tehnici de reducere al numărul parametrilor este Ortogonal Least Square (OLS) [25], [28], [29] [32]. Prin această metodă se dorește determinarea impactului (importanței) fiecărui termen într-un model de regresie liniară. Astfel, algoritmul calculează raportul reducerii erorii (*ERR*) pentru fiecare parametru al modelului, cuantificând și ierarhizând aportul fiecărui termen la reducerea acestei valori a *ERR*. Succesiunea de operații din algoritmul OLS este prezentată în cele ce urmează [25], [28], [29]:

- se consideră, în primă fază, vectorul dorit ca ieșire prin ecuația (3):

$$y = P \theta + \varepsilon \quad (3)$$

unde:

$P$  este matricea datelor de intrare,  $\theta$  reprezintă un vector de coeficienți, iar  $\varepsilon$  corespunde vectorului erorilor.

- pe baza descompunerii *QR* Householder, matricea de intrare  $P$  se poate descompune într-o matrice ortogonală  $Q$  de dimensiune  $N \times M$  și o matrice triunghiular superioară  $R$  de dimensiune  $M \times M$ , precum în egalitatea (4):

$$P = QR \quad (4)$$

- se consideră  $Q_i$ , coloanele ortogonale ale matricii  $Q$  și identitatea  $Q^T \cdot Q = I$ ,  $I$  fiind matricea unitate, iar vectorii  $P_i$  din matricea datelor de intrare având aceeași dimensiune cu vectorii  $Q_i$  din descompunerea ortogonală, ecuația (3) poate fi rescrisă în forma:

$$y = Qg + \varepsilon \quad (5)$$

unde  $g$  este soluția  $LS$  (Least Square) dată prin:

$$g = \frac{Q_i^T \cdot y}{Q_i^T \cdot Q_i} \quad 1 \leq i \leq M \quad (6)$$

- estimarea  $LS$  (Least Square)  $\theta$  poate fi calculată utilizând relația matriceală

$$R \cdot \theta = g \quad (7)$$

- dat fiind că vectorul  $P_i$  a fost transformat în vectorii în bază ortogonală  $Q_i$ , ieșirea dorită se poate calcula pe baza fiecărui vector în bază ortogonală folosind ecuația (8)

$$y^T \cdot y = \sum_{i=1}^M g_i^2 \cdot Q_i^T \cdot Q_i + \varepsilon^T \cdot \varepsilon \quad (8)$$

- expresia erorii devine astfel:

$$ERR_i = \frac{g_i^2 \cdot Q_i^T \cdot Q_i}{y^T \cdot y} \quad 1 \leq i \leq M \quad (9)$$

Utilitatea acestei metode se regăsește în studiile [29], [25], [32] unde după determinarea coeficienților Mel cepstrali se urmărește stabilirea unei ierarhii a importanței acestora în realizarea clasificării din ultima etapă a analizei plânsului. Ierarhizarea se face după valoarea  $ERR$  în ordine descrescătoare; cu cât mai mare valoarea  $ERR$  cu atât este mai semnificativ aportul coeficientului asociat [28].

### 2.2.5 Analiza în componente principale

Analiza în componente principale (*Principle Component Analysis* – PCA) reprezintă o tehnică statistică utilizată pentru extragerea unui set de parametri relevanți dintr-un set de parametri obținut inițial [38], [39], [40]. Aceasta este utilizată asemenea tehnicii Orthogonal Least Square pentru reducerea numărului de parametri, și se regăsește în studii asupra plânsului nou-născutului, însă nu atât de frecvent ca precedentă. Astfel nu se va mai insista pe detalierea acestei analize.

### 2.2.6 Rețele neuronale artificiale

Într-o ultimă etapă a studiilor de analiză a plânsului infantil se realizează clasificarea nou-născuților pe diverse clase de patologii prin utilizarea de diverse metode, prin care cea mai utilizată abordare este cea folosind rețele neuronale artificiale.

Principalele tipuri de rețele neuronale utilizate pentru estimarea probabilității fonemelor sunt rețelele perceptron multistrat (*Multi Layer Perceptron MLP*), rețelele neuronale cu întârziere în timp (*Time Delayed Neural Network TDNN*), rețelele neuronale cu autoorganizare (*Self Organizing Maps – SOM*) sau rețele LSTM (*Long Short Term Memory*) [28], [41], [42], [43], [44].

### 3. Fundamentarea teoretică a cercetării

Capitolul de fundamentare teoretică a activității de cercetare prezintă noțiunile de bază cu privire la tema aleasă, într-o abordare medical-inginerească. Se pornește de la elemente de anatomie umană, componente ale sistemului fonator, care sunt apoi tratate din punct de vedere ingineresc, prin utilizarea de modele în vederea definirii noțiunii de semnal de plâns, element care stă la baza prezentei cercetării. Deasemenea sunt prezentate metodele de prelucrare ale semnalelor vocale, utilizate în capitole ulterioare precum și instrumentele software folosite pe parcursul studiului.

#### 3.1 Fonația și mecanismul fonației

Realizarea unui studiu în detaliu ce vizează prelucrarea semnalului vocal și interpretarea informațiilor rezultate, presupune într-o fază incipientă cunoașterea modului de producere al fonației sau semnalului acustic de către aparatul fonator uman. Semnalul acustic este compus dintr-o secvență de sunete generate de sistemul fonator la comanda creierului.


Vocea umană este rezultatul aparatului fonator format din:

- Generator (plămâni);
- Vibrator (corzile vocale);
- Rezonator (cavitatea bucală);
- Articulator (buze, limbă).

Plămâni comprimându-se, trimit aerul prin trahee înspre exterior. Sub acțiunea aerului trimis de plămâni, corzile vocale vor intra în rezonanță producând sunetul. Rezonanța corzilor vocale este determinată de anumite proprietăți fizice și fiziologice ale acestora, distincte la fiecare individ în parte. Sunetul este preluat de aerul aflat în mișcare și transportat mai departe spre exterior prin tractul vocal. Acesta este compus din cavitatea laringeală, bucală și nazală. Forma acestor cavități va modula rezonanța acustică fundamentală dând naștere unui sunet produs din multiplii ai frecvenței fundamentale de rezonanță, fiecare multiplu având amplitudine și fază determinată de forma tractului vocal. Intensitatea sunetului este direct determinată de presiunea cu care plămâni elimină aerul. Înălțimea sunetului este dată de frecvența fundamentală a corzilor. Deoarece tractul vocal se modifică pe durata vorbirii rezultă sunete variate. Vorbirea nu ar fi posibilă fără existența limbii și buzelor a căror acțiune duce la producerea unor sunete specifice care se produc prin blocarea fluxului de aer sosit de la plămâni și apoi eliberarea bruscă a acestuia. Ca urmare a acestor caracteristici, astfel de sunete poartă denumirea de nesonore. Pe lângă buze și limbă, elemente ale cavității bucale, în producerea vorbirii un rol important îl are și cavitatea nazală care are misiunea de a nazaliza sunetele [45].

În Figura 3.1 este prezentată o schema selectivă cu elementele amintite anterior, care compun sistemul fonator uman. Aceste elemente sunt parte ale aparatului digestiv și cel respirator.





**Figura 3.1 Elemente ale aparatelor digestiv și respirator implicate în fonație**

Componentele spectrale în care este concentrată o mare parte din energia semnalului, și care corespund frecvențelor de rezonanță ale tractului vocal reprezintă formanții. Formantul se definește ca o componentă sinusoidală amortizată a răspunsului la impuls a tractului vocal. În modelul clasic al sistemului vocal această definiție este echivalentă cu o pereche de poli complecși în funcția de transfer a tractului vocal. Pentru un tract vocal mediu, cu lungimea de 17cm, există 3-4 formanți în banda de 3KHz [46].

Pentru sunete sonore prezintă importanță frecvențele primilor 3 formanți, notați în literatură cu  $F_1, F_2$ , respectiv  $F_3$ . Ei sunt specifici pentru fiecare individ, pentru fiecare sunet, depind de forma tractului vocal și nu au valori fixe datorită contextului în care se pronunță sunetul. Procesul prin care caracteristicile fonemelor (unități fundamentale în vorbire care diferențiază cuvintele) se modifică în funcție de context se numește coarticulare. Acustica modernă a pus în evidență faptul că structura formantică a unui fonem este rezultatul efectelor rezonante ale tractului vocal în întregime.  $F_1$  corespunde frecvenței de rezonanță a cavității glotale, în vreme ce  $F_2$  caracterizează frecvența de rezonanță a cavității bucale.  $F_2$  este cu atât mai înaltă cu cât cavitatea bucală este mai mică [46]. Acest aspect este evident la nou-născuți, ale caror frecvențe fundamentale sunt cu mult mai înalte decât ale adulților.

Un model matematic al producerii sunetului vocal poate fi reprezentat în următoarea formă:

$$S(z) = U(z) \cdot H(z) \cdot R(z) \quad (10)$$

unde:

$U(z)$  – reprezintă excitația sonoră sau nesonoră. În cazul excitației sonore aceasta generează un tren de impulsuri de frecvența fundamentală a corzilor vocale ale vorbitorului și amplitudine constantă pe o scurtă perioadă. În cazul excitației nesonore aceasta este un zgomot alb: zgomot aleator cu spectru plat.

$H(z)$  – reprezintă funcția de transfer a tractului vocal, caracterizat de frecvența de rezonanță, ce determină formanții. Datorită faptului că analiza se face pe o perioadă de 50-75ms, când semnalul vocal se consideră ca fiind în regim cvasistaționar, parametri funcției de transfer rămân nemodificați într-un cadru supus analizei.

$R(z)$  – reprezintă radiația care apare de-a lungul tractului și atenuarea efectuată de buze.

Un model simplificat al producerii vorbirii (similar și în cazul plânsului infantil) prezentat în Figura 3.2 se obține din alternarea unei unde vocale cu impulsuri de amplitudinea frecvenței fundamentale, semnalul rezultat fiind trecut printr-un filtru al tractului vocal, la ieșirea căruia va fi vorbirea propriu-zisă, sau sunetul produs de aparatul fonator.




Figura 3.2 Modelul simplificat al producerii vorbirii

În Figura 3.3 este prezentat un alt model, al producerii vorbirii, în cadrul căruia unda vocală este înlocuită de un generator de zgomot aleator, iar impulsurile ce alternează cu zgomotul sunt generate și ele în tren. Ca și intrare în modelul tractului vocal se ia în considerare aportul (câștigul) adus de volumul de aer inspirat (funcția  $G$ ) împreună cu unda rezultantă a generatoarelor.

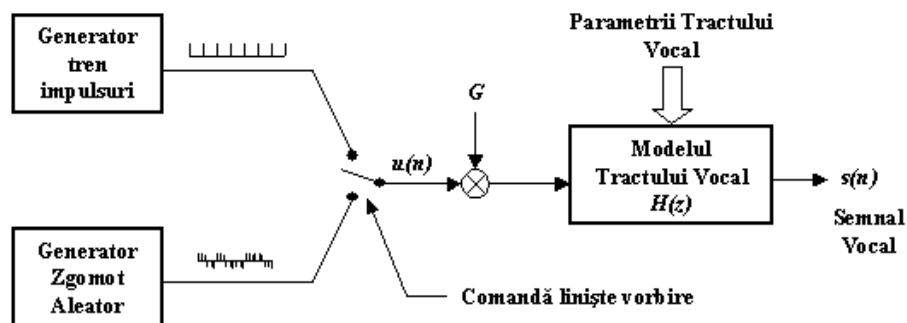



Figura 3.3 Model al producerii vorbirii

### 3.2 Reprezentarea digitală a semnalului vocal

Majoritatea semnalelor asociate sunetelor, în zilele noastre, sunt stocate digital. Într-o primă etapă, sunetul este convertit în curent electric utilizând microfonul. Presiunea oscilațiilor continue de aer devine oscilație continuă de tensiune într-un circuit electric. Modificările continue de tensiune sunt convertite în serii numerice de un digitizor (convertor analogic-numeric). Digitizorul are

comportamentul unui voltmetru digital cu o frecvență a măsurătorilor configurabilă. Rezultatul fiecărei măsurări realizate de digitizor reprezintă o valoare care se stochează digital. Această valoare reprezintă un eșantion, iar întreg procesul de conversie a sunetului în serii numerice reprezintă procesul de eșantionare. Figura 3.4 prezintă procesul de eșantionarea unui semnal continuu, cu linia albastră fiind reliefată evoluția în tensiune iar cu linia roșie sunt reprezentate eșantioanele semnalului [47], [48].



**Figura 3.4 Eșantionarea unui semnal continuu**

Ipoteza de staționaritate pe termen scurt este folosită în multe aplicații de analiză a semnalului vocal. Semnalul vocal este împărțit în segmente scurte (grupuri de eșantioane) ce sunt analizate individual. Un segment este reprezentat de obicei prin componentele spectrale (spectrul de amplitudini, spectrul de faze și puterea/energia spectrală). Reprezentările spectrale produse în lucrare conduc la un semnal bidimensional, reprezentat în timp și în frecvență. Dimensiunea temporală se referă la poziția segmentului analizat (variabila fiind timpul reflectat prin numărul eșantionului), iar dimensiunea frecvențială se referă la componentele spectrale ale segmentului (valoarea puterii/energiei spectrale a segmentului). Aceste reprezentări bidimensionale se pot prezenta sub forma spectrogramelor (reprezentări ale amplitudinii în funcție de timp și frecvență). Astfel, semnalul bidimensional poate fi văzut ca o secvență de cadre sau vectori caracteristici, fiecare vector fiind indexat de dimensiunea temporală (numărul cadrului). Vectorii sunt formați din componentele spectrale ale semnalului la un anumit moment. Fiecare vector descrie astfel un semnal unidimensional în timp [48].

Una dintre problemele prelucrării unui semnal vocal este modificarea tractului vocal în timp, element care influențează orice operațiune. Aceasta implică necesitatea analizării semnalului vocal pe perioade scurte de timp, perioade în care unda sonoră este cvasistaționară, dat fiind faptul că forma tractului vocal nu se modifică semnificativ. O astfel de perioadă este estimată la 10-40 ms, iar segmentarea semnalului vocal digitizat se realizează prin operațiunea de ferestruire. Operațiunea presupune aplicarea de-a lungul semnalului a unei funcții cu anumite proprietăți, prelucrarea efectuându-se asupra fiecărui segment astfel obținut (prin ferestruire).

Fie semnalul sursă  $s$  unde  $s(n)$  reprezintă al  $n$ -lea eșantion din cadrul semnalului. Se observă că semnalul nu este analizat funcție de timp ci funcție de numărul eșantionului. Aplicarea asupra acestui semnal a unei ferestre  $w$  va duce la obținerea unui semnal  $s'$  având forma:

$$s'(k+n) = s(k+n) \cdot w(n); k \geq 0, n \in [0; N-1] \quad (11)$$

$k$  reprezintă în această formulă numărul de ordine al segmentului, în timp ce  $n$  reprezintă numărul de ordine al eșantionului în cadrul segmentului, unde fiecare segment conține  $N$  eșantioane. În literatura de specialitate termenul de eșantion este întâlnit de multe ori ca „sample” [49].

Fereastra care se aplică asupra semnalului poate fi de mai multe tipuri. Cel mai utilizat tip de fereastră este cea dreptunghiulară prezentată în Figura 3.5 având forma:

$$w(n) = \begin{cases} 1, & n \in [0..N-1] \\ 0, & \text{altfel} \end{cases} \quad (12)$$




Figura 3.5 Fereastra dreptunghiulară

Deși foarte frecvent utilizată, această fereastră are o mare problemă determinată de limitarea bruscă la capătul segmentului eșantioanelor. Această problemă se rezolvă printr-o atenuare treptată a eșantioanelor la capetele segmentului, prin aplicarea ferestrei Hamming. Această fereastră este descrisă prin relația:

$$w(n) = \begin{cases} 0.54 - 0.46 \cdot \cos\left(\frac{2\pi n}{N-1}\right), & n \in [0..N-1] \\ 0, & \text{altfel} \end{cases} \quad (13)$$




Figura 3.6 Fereastra Hamming

Fereastra Hamming prezentată în Figura 3.6 se aplică de regulă asupra unui număr de eșantioane putere a lui 2: 128, 256, 512. Pentru obținerea unor rezultate și mai relevante, printr-o urmărire continuă a variației parametrilor semnalului vocal, de multe ori în cadrul prelucrării se alege o ferestruire prin acoperire, numită „overlapping” în literatura de specialitate. Această acoperire presupune suprapunerea

a doua segmente într-o proporție bine definită, care poate varia între 10% și 80%. Folosirea acestei ferestre duce la creșterea importanței eșantioanelor din centrul ferestrei, iar aplicarea și a unei suprapuneri a ferestrelor asigură calcularea netezită a parametrilor semnalului vocal. Parametrii se vor calcula cadru cu cadru în întreg semnalul vocal de analizat.

Alte ferestre folosite adesea în domeniul prelucrării semnalelor vocale sunt:

- Fereastra Hanning:

$$w(n) = \begin{cases} 0.5 - 0.5 \cdot \cos\left(\frac{2\pi n}{N-1}\right), n \in [0..N-1] \\ 0, \text{ altfel} \end{cases} \quad (14)$$

- Fereastra Barlett:

$$w(n) = \begin{cases} \frac{2n}{N-1}, 0 \leq n \leq \frac{N-1}{2} \\ 2 - \frac{2n}{N-1}, \frac{N-1}{2} \leq n \leq N-1 \end{cases} \quad (15)$$

- Fereastra Blackman:

$$w(n) = \begin{cases} 0.42 - 0.5 \cdot \cos\frac{2\pi n}{N-1} + 0.08 \cos\frac{4\pi n}{N-1}, n \in [0..N-1] \\ 0, \text{ altfel} \end{cases} \quad (16)$$

Durata unui cadru (în analiza vorbirii), adică lungimea în eșantioane a acestuia este direct proporțională cu viteza de articulare a sistemului de producere a vorbirii. Astfel, lungimea cadrelor trebuie să îndeplinească următoarele două cerințe:

- să nu aibă o lungime mai mică decât cea necesară cuprinderii unei perioade de semnal;
- lungimea să nu fie una prea mare încât să compromită caracteristica de cvasistaționaritate a semnalului.

De aici, dimensiunea de care se amintea anterior, anume de 10ms-40ms pentru fiecare cadru în parte.

### 3.3 Analiza Fourier

În matematică, analiza Fourier reprezintă un domeniu vast ale cărui origini sunt bazate pe studiul seriilor Fourier. Acest subiect a fost dezvoltat din dorința de a determina dacă o anumită funcție, indiferent de complexitatea ei, ar putea fi reprezentată ca o sumă de funcții trigonometrice elementare. Încercarea de a înțelege funcții sau alte „obiecte” prin descompunerea lor în entități elementare care sunt perceptibile mai facil, este unul din dezideratele ce stau la baza analizei Fourier. Astfel, se consideră că orice semnal periodic poate fi reprezentat ca o sumă de sinusoidale (serie Fourier):

$$x(t) = \frac{A_0}{2} + \sum_{n=1}^{\infty} [A_n \cos(2\pi n f_0 t) + B_n \sin(2\pi n f_0 t)] \quad (17)$$

unde  $f_0$  reprezintă frecvența fundamentală sau armonica fundamentală. Multiplii de  $f_0$  sunt definiți ca armonici, iar  $f_0$  este inversa perioadei  $T$  a semnalului [50].

Pentru un semnal aperiodic, cum este și semnalul din plânsul nou-născutului, spectrul constă în frecvențe continue. Acest spectru poate fi definit de transformata Fourier. Dacă  $x(t)$  reprezintă semnalul și  $X(F)$  spectrul acestui semnal atunci avem următoarele relații:

$$x(t) = \int_{-\infty}^{+\infty} X(F)e^{j2\pi Ft} dF \quad (18)$$

$$X(F) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi Ft} dt \quad (19)$$

După cum se poate observa, formulele anterioare se aplică pe mulțimi infinite. În practică însă, și considerând aici procesarea semnalelor vocale, domeniul de aplicare este unul finit și mai mult, unul discret. În acest caz se folosește Transformata Fourier Discretă (DFT) [51].

Transformata Fourier rapidă permite calculul eficient al transformatei Fourier discrete. Spectrul discret al secvenței de eșantionare a unui semnal periodic se definește ca:

$$X(k) = \sum_{n=0}^{N-1} x(n) \cdot e^{-2\pi jk/N}, k = 1, \dots, N \quad (20)$$

Pentru o rezoluție în domeniul timp de  $T = 1/f_e$ , va rezulta o rezoluție  $\Omega = 1/NT$  în domeniul frecvență.

Reprezentările în frecvență folosesc spectrul de putere  $|X(k)|$ , adică neglijează informația de fază conținută în spectrul  $X(k)$ . Acest lucru se datorează faptului că urechea umană este, în mare măsură, insensibilă la fază.

Pentru calculul spectrului se folosește transformata Fourier rapidă (FFT), ce permite reducerea numărului de operații (înmulțiri și adunări) astfel că timpul de calcul se reduce semnificativ. Lungimea secvenței pentru care se aplică FFT depinde de durata segmentului vocal analizat și de frecvența de eșantionare. Deoarece numărul de puncte rezultat nu este, în general, o putere a lui 2, se completează secvența cu valori de zero.

O formă de reprezentare frecvențială este spectrograma, amintită și în paragrafele anterioare. Aceasta se obține prin reprezentarea spectrului de putere, de obicei pe o scară logaritmică, în funcție de frecvență dar și de timp. De regulă, se reprezintă secvențe de spectre de putere obținute pentru segmente de date rezultate în urma unei ferestruiri.

Altă formă de reprezentare în frecvență este reprezentarea bidimensională a spectrului de putere pentru un segment din semnalul vocal obținut prin ferestruire [48].

### 3.4 Microsoft Visual Studio

În vederea realizării unei aplicații specializate în achiziția semnalului din plânsul nou-născuților este necesară găsirea unei platforme de dezvoltare care să permită crearea unui soft capabil să interacționeze cu periferice și să facă posibilă interpretarea informației de la acestea. În acest sens a fost aleasă platforma Microsoft Visual Studio, care reprezintă un mediu integrat de dezvoltare (IDE) creat de compania Microsoft, și care răspunde cerințelor ce vizează implementarea software-ului dorit. Acesta oferă un set complet de unelte pentru dezvoltarea de aplicații pentru desktop (tip consolă sau GUI-uri – Graphical User Interface), aplicații mobile, aplicații web în ASP.NET și servicii web XML. Visual Studio include un editor de cod dotat cu IntelliSense (implementare adusă de Microsoft pentru autocompletare de cod) și "code refactoring" (proces de modificare a structurii interne a unui program fără a-i modifica funcționalitatea externă cu scopul de a îmbunătăți proprietățile interne mai puțin funcționale). Depanatorul integrat funcționează atât la nivel de cod sursă cât și la nivel de cod mașină. Există și alte unelte integrate în acest mediu, dintre care cele mai importante ar fi: uneltele

de construire a ferestrelor pentru aplicații GUI, a paginilor web, a claselor sau bazelor de date [52].

Microsoft Visual Studio încapsulează o serie de limbaje de programare, cum ar fi: C/C++, C#, Visual Basic, care sunt fiecare gestionate de mașina virtuală CLR (Common Language Runtime) inclusă în .NET Framework. Există versiuni de Visual Studio destinate doar unui limbaj, printre acestea se numără Microsoft Visual Basic, Visual J#, Visual C# sau Visual C++.

.NET Framework (Cadrul de lucru .NET) este plasat între limbajul de programare (Visual Basic, C#, C/C++) și sistemul de operare (de la Windows 98 și Windows NT până la Windows XP și Windows 8, sau orice alte sub-versiuni ale acestora, cum ar fi cele destinate dispozitivelor mobile). .NET Framework oferă funcționalități specifice sistemului de operare Windows, furnizând însă și biblioteci care extind aceste funcționalități (calculul matematic, accesarea bazelor de date). Programele scrise pentru .NET Framework sunt executate în mașina virtuală CLR care gestionează programele în timpul rulării din punct de vedere al necesităților acestora.

C# este un limbaj de programare orientat pe obiecte dezvoltat de Microsoft ca parte a platformei .NET și acceptat ca standard de ISO. C# are o sintaxa procedurală și orientată pe obiecte bazată pe C++ dar include și aspecte a mai multor alte limbaje de programare (mai ales Delphi și Java) cu un accent pe simplificare. Limbajul C# nu specifică ce cod trebuie să genereze compilatorul, dar în practică toate implementările de compilatoare generează cod în *Common Intermediate Language* (CIL) [52].

### 3.5 Bibliotecile AudioLab, SignalLab și PlotLab

Pentru realizarea unei aplicații software într-un timp cât mai scurt, utilizarea unor componente deja create și testate este întotdeauna un deziderat. Compania Mitov [53] a produs o serie de pachete software care vin în sprijinul dezvoltatorilor software ce au ca și preocupare procesarea semnalelor audio și video. Produsele oferite de această companie pot fi utilizate de studenți sau cadre didactice în scopuri academice sau de cercetare în regim gratuit pe o perioadă nelimitată de timp. Aceste biblioteci sunt destinate mediilor .NET, Visual C++ sau Delphi.

Pentru dezvoltarea aplicațiilor ce vizează analiza semnalelor audio sunt disponibile bibliotecile AudioLab, SignalLab și PlotLab, fiecare cu pachete și componente aferente. În cele ce urmează se prezintă o descriere sumară a fiecărei biblioteci în parte.

AudioLab conține un set de componente pentru procesare audio foarte rapidă. Librăria permite captura, redarea sau mixarea unor semnale audio complexe, analiza și vizualizarea fără a necesita prea multe linii de cod.

Din pachetul AudioLab fac parte:

- Generatoare audio: generatoare de semnal sinusoidal, triunghiular sau dreptunghiular;
- Componente WIN32 API: de captură date audio de la o intrare analogică (Microfon, Modem, tuner Radio TV), ieșiri de date audio pe calea Speaker-elor sau Modem-ului, de stocare audio în format WAV, de reproducere fișiere sunet chiar și în format brut (neformatate);
- Componente DirectShow cu funcționalități similare celor WIN32 API;
- Componente de compresie și decompresie;
- Filtre audio;

- Metrici: Volume Unit si Peak Programme (valori medii și maxime ale intensității sonore).

Principalele funcționalități aduse de AudioLab constau în:

- Pornire audio -> Ascultare;
- Captură de la microfon -> Înregistrare;
- Captură de la microfon -> Procesare -> Înregistrare;
- Pornire audio -> Analiză -> Ascultare sau Afișare;
- Captură audio sau Pornire audio -> Mixare -> Ascultare sau Înregistrare;

Înzestrat cu un design atractiv, AudioLab are aceeași implementare în cod gestionat .NET și medii WIN32. Codul pentru gestionarea componentelor din VB.NET, C++/CLI, C# și J#, Visual C++ MFC, Delphi și C++ Builder este aproape identic. Acest lucru permite dezvoltatorilor să migreze și să partajeze cod între diferitele medii, îmbunătățindu-și semnificativ productivitatea.

SignalLab este un set de componente pentru procesare digitală de semnal (DSP) foarte rapidă. Librăria permite manipularea foarte rapidă a unor semnale deosebit de complexe și vizualizarea fără a utiliza linii de cod prea multe.

Din pachetul SignalLab fac parte:

- Generatoare de semnal: sinusoidal, triunghiular, dreptunghiular sau DC;
  - Componente aritmetice: adunare, scădere, înmulțire, împărțire, aplicare de funcții fereastră peste semnalul de la intrare, aplicarea de constante întregi, reale sau complexe;
  - Componente de acces la fișiere: stocare/încărcare de date reale, întregi sau complexe în/din fișiere binare;
  - Filtre: trece-sus, trece-jos, trece-bandă, trece-tot, oprește-bandă, recursive și nerecursive, de mediere și altele;
  - Componente pentru transformări: Fourier rapidă directă și inversă, Cosinus discretă directă și inversă, Haar directă și inversă.
  - Componente pentru conversii: de la vectori întregi sau complecși la reali, de la reali la complecși, din coordonate polare în carteziene, deplasări de fază ale semnalului și altele;
  - Componente statistice: calcularea valorilor zgomotului dintr-un semnal.
- SignalLab dispune de asemenea de multe funcționalități cum ar fi:
- Achiziția de semnal -> Procesare -> Afișare sau Înregistrare;
  - „Ascultare” semnal -> Analiză -> Afișare;
  - Generare -> Afișare sau Scoatere la ieșire -> Utilizare;
  - „Ascultare” semnal sau Achiziție -> Mixare -> Afișare sau Scoatere la ieșire;

În versiunea pentru .NET 4.0, SignalLab utilizează componente gestionate .NET 4.0. Această are aceleași performanțe ca și versiunile în cod nativ și suportă toate limbajele .NET 4.0: Visual Basic, C#, J# și C++/CLI. La fel ca și în cazul AudioLab, implementarea pachetului este aceeași în .NET gestionat ca și în medii WIN32, iar migrarea și partajarea codului îmbunătățesc semnificativ productivitatea.

PlotLab este un set de componente pentru trasare de grafice și diagrame. Librăria include o diagramă ca și componentă de trasare a graficelor și o componentă „model cascadă”. Cu PlotLab se pot adăuga aplicațiilor .NET, Visual C++ sau Delphi grafice complexe, diagrame, sau modele cascadă cu minim de efort.

Versiunea .NET a bibliotecii conține un set de componente .NET gestionate, având aceeași performanță ca și versiunile în cod nativ ale Microsoft .NET 4.0. La fel ca și AudioLab sau SignalLab, PlotLab permite migrarea și partajarea codului.



### 3.6 Microsoft SQL Server

În cadrul unei aplicații care are ca scop procesarea unei cantități însemnate de date, este necesară utilizarea unor baza de date accesibile atât din mediu de dezvoltare cât și din exteriorul acesteia. În acest sens, Microsoft SQL Server reprezintă o alegere normală în contextul dezvoltării aplicației folosind platforma de dezvoltare Microsoft Visual Studio. Microsoft Microsoft SQL Servereste un model relațional de server de baze de date produs de compania Microsoft și utilizat pentru managementul și analiza datelor, oferind securitate, scalabilitate și disponibilitate crescute pentru date și aplicațiile analitice. Crearea, implementarea și managementul bazelor de date sunt mai facile, SQL Server oferind o soluție integrată de management și analiză a datelor, care ajută la:

- Dezvoltarea, implementarea și administrarea aplicațiilor la nivel mai mare (de întreprindere) mai sigure, scalabile și fiabile;
- Maximizarea productivității IT prin reducerea complexității creării, implementării și administrării aplicațiilor pentru baze de date;
- Partajarea datelor pe mai multe platforme, aplicații și dispozitive pentru a facilita conectarea sistemelor interne și externe;
- Controlarea costurilor fără a sacrifica performanța, disponibilitatea, scalabilitatea sau securitatea [54].

SQL Server consta din trei servicii primare:

- MSSQLServer - serviciul de date și procesarea interogărilor;
- SQL Server Agent – serviciu pentru organizarea activităților și notificărilor;
- Microsoft Distributed Transaction Coordinator - manipulează datele provenite din surse multiple.

SQL Server include suport nativ pentru manipularea datelor XML, în completare la datele relaționate. În acest sens, s-a definit un tip de dată xml care poate fi folosit fie ca un tip de dată din coloanele unei baze de date, fie literal într-o interogare. Coloanele XML pot fi asociate cu scheme XSD, datele XML stocate fiind verificate conform schemei. XML este convertit la un tip intern de dată binar înainte de a fi stocat în baza de date. SQL Server permite unui server de baze de date să fie expus serviciilor web prin folosirea pachetelor TDS (Tabular Data Stream) încapsulate în cererile protocolului SOAP. Când datele sunt accesate prin intermediul serviciilor web, rezultatele sunt returnate în format XML.

SQL CLR a fost introdus începând cu SQL Server pentru a putea fi integrat în .NET Framework [55].

### 3.7 WEKA

Pentru realizarea unui studiu de *Data Mining*, folosind aplicații dedicate acestui scop a fost considerată aplicația WEKA (Waikato Environment for Knowledge Analysis). Acesta este un instrument software compus dintr-o colecție de programe ce au la bază algoritmi de învățare automată. WEKA este realizat în limbajul Java, distribuția lui fiind gratuită sub licența general publică GNU [56].

Mediul de lucru WEKA conține o colecție de instrumente de vizualizare și algoritmi pentru analiza datelor și modelare predictivă, toate sub o interfață grafică foarte prietenoasă, destinată utilizării cât mai facile și pentru un acces cât mai ușor la funcționalitățile programului.

Versiunea originală WEKA, care nu a fost realizată în Java, a constituit un software dedicat analizei datelor din domeniul agricol. Versiunea cea mai recentă,

creată în limbaj Java, a fost dezvoltată începând cu anul 1997, iar în prezent este utilizată în diverse arii de activitate. În particular, WEKA se folosește în scopuri educaționale și în diverse domenii de cercetare. Caracteristicile esențiale ale mediului WEKA sunt:

- Disponibilitatea gratuită sub licența general publică GNU;
- Portabilitatea conferită de implementarea completă în limbajul Java, care o fac să ruleze pe aproape orice platformă de calcul modernă;
- Un număr foarte mare de colecții de algoritmi implementați pentru preprocesarea datelor și tehnici de modelare;
- Ușor de utilizat și pentru un utilizator mai puțin inițiat, datorită interfeței grafice destul de intuitive [57].

WEKA oferă posibilitatea realizării mai multor activități de *Data Mining*, mai precis se pot realiza pre-procesări ale datelor, *clustering*, clasificări, regresii și vizualizări. Toate tehnicile din WEKA pornesc de la premiza că datele se găsesc într-un singur fișier sau într-o relație, unde fiecare instanță are un număr bine precizat de atribute (numerice, nominale, booleene, dar și alte tipuri).

Mediul WEKA oferă acces către baze de date SQL prin utilizarea JDC (*Java Database Connectivity*) și poate procesa rezultatul returnat de o interogare asupra bazei de date. Acesta nu oferă însă capabilități de *Data Mining* multi-relaționat, dar există aplicații ce convertesc colecții de tabele relaționate într-un singur tabel care poate fi procesat utilizând WEKA.

Interfața principală pentru WEKA este „Explorer”-ul, însă aproximativ aceleași funcționalități pot fi accesate și prin interfața bazată pe componente, „Knowledge Flow”. Mai există și o a treia interfață, „Experimenter”, care realizează comparații sistematice ale performanțelor predictive pe care algoritmi de învățare automată din WEKA îi aplică asupra colecțiilor de date.

## **4. Neonat – Aplicație pentru achiziția și prelucrarea semnalului de plâns**

În această secțiune este prezentată în detaliu aplicația special dezvoltată pentru achiziția și prelucrarea semnalului din plânsul nou-născuților, denumită Neonat, deoarece vizează nou-născuții și prezintă utilitate pe ramura medicală a neonatologiei. Acest instrument software este tratat ca bloc decizional în cadrul sistemului de analiză a plânsului care primește la intrarea sa semnalul de plâns, producând la ieșire, pe baza unor funcții interne, valori reprezentabile ale spectrului de frecvență și ale amplitudinii vocale. Sunt detaliate și celelalte funcții ale aplicației prin diagrame în metodologia Mascot, limbaj pseudocod sau limbaj de programare. Finalul capitolului prezintă rezultatele intermediare precum și un protocol de lucru rezultat în urma depășirii problemelor întâmpinate în această etapă în mediul de spital.

### **4.1 Arhitectura sistemului**

Pentru realizarea unui studiu complet în care să se facă o analiză profesională a datelor prelevate din plânsul nou-născuților a fost necesară crearea unui sistem complet de achiziție a semnalului audio dedicat situației de cercetare, care mai apoi va furniza toate datele necesare prelucrării, stocării și interpretării.

Procesul de înregistrare are loc într-o incintă din cadrul spitalului, unde se desfășoară studiul, un loc în care perturbația zgomotoasă este redusă. Incubatorul în care este introdus copilul pentru a fi înregistrat conferă și el o izolare fonică suplimentară, rezultând astfel un mediu ambiat adecvat pentru o analiză audio. O reducere cât mai bună a nivelelor zgomotoase este foarte importantă pentru prevenirea apariției efectului Lombard (un mediu zgomotos va conduce la modificarea parametrilor semnalului vocal prin creșterea energiei și a frecvenței fundamentale [48]).

Microfonul este dispozitivul folosit pentru a recepționa semnalul vocal. Acesta este amplasat în interiorul incubatorului, suspendat și bine ancorat deasupra capului nou-născutului la o distanță constantă pentru fiecare înregistrare efectuată. Acest aspect este deosebit de important datorită dependenței dintre intensitatea sonoră și distanța la care se află receptorul. Este cunoscut faptul că o dată cu dublarea distanței va scădea presiunea acustică (nivelul sonor) cu aproximativ 3dB pentru o sursă acustică punctiformă și cu 6dB pentru una liniară [58], [59].

De la microfon informația sonoră, sub formă de semnal, va fi preluată de către sistemul de calcul pe intrarea destinată special acestui scop. Pentru sistemul de față, partea computațională este realizată de un laptop, utilizat ca și calculator de proces. La acest nivel se face preluarea semnalului vocal cu toate operațiile specifice, de conversie a semnalului analogic produs de microfon în semnal digital, urmată de eșantionare și cuantizare pentru a avea astfel o reprezentare digitală a informației vocale.

Tot la acest nivel se va realiza stocarea înregistrării și a datelor personale ale nou-născutului înregistrat, se va face extragerea componentelor spectrale din semnalul audio care vor fi reprezentate și într-un mod grafic. După efectuarea

tuturor acestor prelucrări se poate trece la un studiu de *Data Mining* având extras tot suportul informațional necesar.

Sistemul în ansamblul său nu are o structură complexă, fiind unul tipic destinat achiziției de semnal audio în timp real. Chiar dacă locația de desfășurare a activității nu este un studio profesional unde să fie asigurate toate rigorile tehnice relative la zgomot și alte perturbații exterioare, s-a încercat găsirea unui ambient care să ofere cel puțin un nivel acceptabil de condiții astfel încât studiul să se desfășoare în bune condiții. Schema din Figura 4.1 prezintă în mod grafic această arhitectură a sistemului, elementele fiind cele descrise anterior.




Figura 4.1 Schema arhitecturii sistemului de înregistrare

## 4.2 Schema bloc și arhitectura aplicației

După prezentarea unei vederi de ansamblu asupra întregului sistem, este necesar a trece la o privire mai în detaliu a aplicației în sine. Astfel, atenția se concentrează pe partea computațională, unde se află aplicația ce realizează prelucrarea informației primite de la mediul exterior. Aceasta poate fi descompusă în mai multe module constitutive, după funcțiile pe care le îndeplinește fiecare. Se menționează că funcționalitatea sistemului de a realiza proceduri de *Data Mining* se consideră ca fiind una exterioară aplicației, prin prisma încărcării datelor prelucrate într-un alt mediu, diferit de aplicația asupra căreia arhitecturii se concentrează paragrafele următoare.

Aplicația dispune de un meniu principal de unde în funcție de dorința utilizatorului pot fi încărcate diferitele module. Acest meniu principal joacă rolul unei funcții *Main*, de unde se realizează opțiunea aleasă, instanțierea tuturor claselor reprezentând modulele aplicației.

Principalele elemente, vizibile și utilizatorului prin meniu, sunt cele de „Registru”, „Înregistrare” și „Încărcare”. Dintre acestea, modulele „Înregistrare” și „Testare” fiind cele cu care utilizatorul nu va acționa imediat, fiind nevoit să parcurgă și modulul „Formular” până să fie accesat cel de „Înregistrare” și mai apoi și pe acesta din urmă pentru ajungerea la „Testare”. Fiecare modul accesează una sau mai multe componente externe aplicației, cum ar fi: baza de date, sistemul de fișiere, microfonul sau speaker-ele, elemente de la care fie primesc, fie trimit informație. O utilizare mai specială a unor elemente din exterior este realizată din cadrul modului de încărcare către *Data Mining*. Deși într-o primă etapă a proiectului, prin modulul de încărcare se vor trimite fișiere mediului WEKA, o dezvoltare ulterioară ar putea face legătura și cu alte medii. Schema bloc din Figura 4.2 definește relațiile dintre module și legătura lor cu elementele externe menționate anterior.



Figura 4.2 Schema bloc a aplicației

Parcurgând pașii incipienți, arhitectura sistemului și schema bloc a aplicației, se ajunge în faza de proiectare și implicit la necesitatea unei descrieri mai ample a aplicației. Ținând cont de caracterul on-line al software-ului realizat în această teză, în cadrul proiectării de detaliu a acestuia, o abordare în sistemul MASCOT este

foarte utilă în contextul implementării și pentru a avea o imagine mai detaliată a modului său de funcționare.

Sistemul MASCOT de proiectare și dezvoltare a programelor pentru aplicații în timp real (cu ajutorul căruia se dorește a fi construită aplicația) impune o abordare sistematică și ordonată a activităților, bazată pe o structură accentuată modularizată și care nu depinde de limbajul de programare, cu ajutorul căruia se dorește a fi construită aplicația. MASCOT se definește astfel ca metodă formală utilă în reprezentarea structurii programelor, latura ei vizuală ușurând munca proiectantului și sporind gradul de inteligibilitate al aplicației pentru cei care încearcă să deslușească modul de realizare al acesteia. În Figura 4.3 este prezentată diagrama Activități-Canale-Rezervoare (ACR) a aplicației, a cărei întocmire este primul pas în metodologia de proiectare MASCOT.

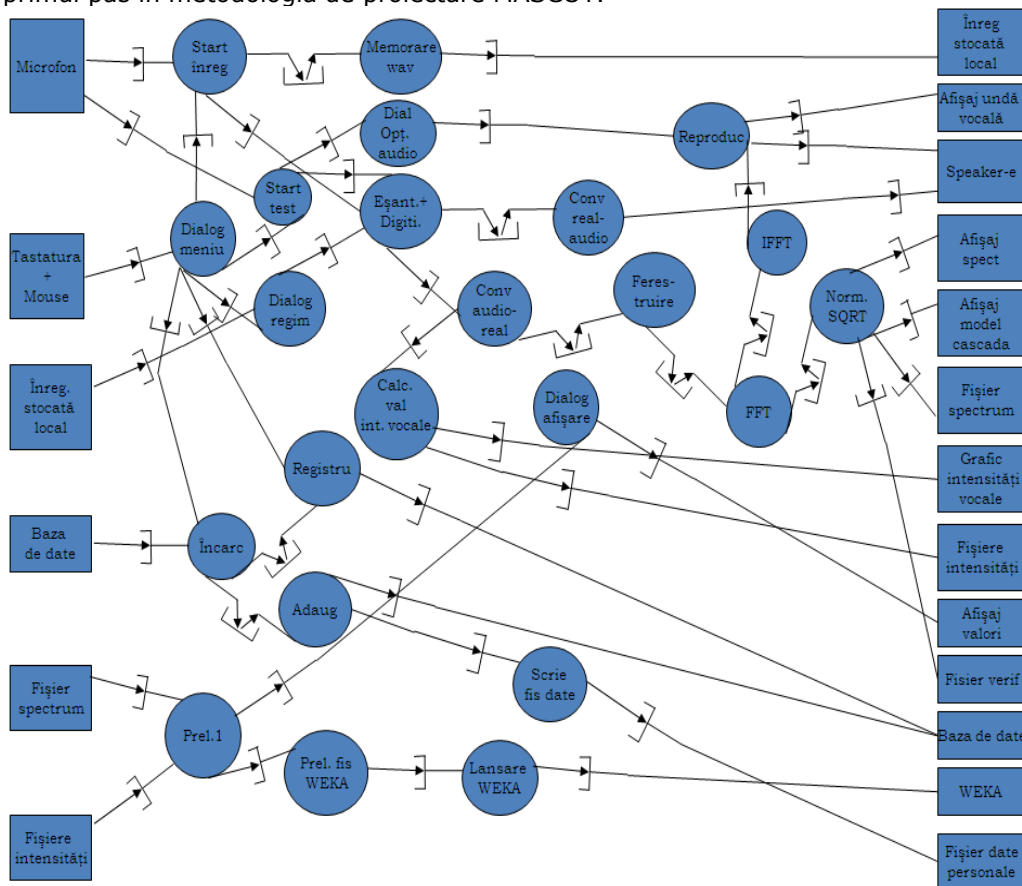




Figura 4.3 Diagrama ACR a aplicației

Simbolurile utilizate în diagramă sunt definite în Tabel 4.1, cu mențiunea că elementele canal și rezervor sunt două clase importante din așa-numita Zonă de Intercomunicare Date (ZID), după cum este referită în literatura de specialitate.

**Tabel 4.1 Simbolurile dintr-o diagramă ACR**

Simbol	Semnificație
	Simbolul desemnează un <b>dispozitiv</b> . Rolul acestuia este de a da o semnificație grafică intrărilor și ieșirilor din aplicație. Acestea pot fi dispozitive periferice, fișiere sau baze de date.
	Simbolul sugerează o <b>activitate</b> sau un <b>task</b> . Activitățile/task-urile sunt anumite funcționalități pe care aplicația le îndeplinește.
	Datele în cadrul aplicației sunt transportate printr-un <b>canal</b> . Dat fiind faptul că există mai multe surse de date, aplicația dispune de un număr mare de canale.
	În aplicație există zone în care se acumulează un număr mare de date (vectori, matrici, tabele de dispersie, structuri) care sunt simbolizate printr-un <b>rezervor</b> .

Într-o a doua fază a metodei MASCOT, fiecare element de pe diagramă este luat în parte și dezvoltat, iar în etapa finală elementele sunt implementate prin cod și testate. În contextul capitolului de față se va insista pe detalierea modulelor esențiale, care cuprind mai multe dispozitive și elemente din ZID, iar elementele de cod mai importante vor fi dezbătute în secțiunea dedicată funcțiilor cu caracter mai special ale aplicației.

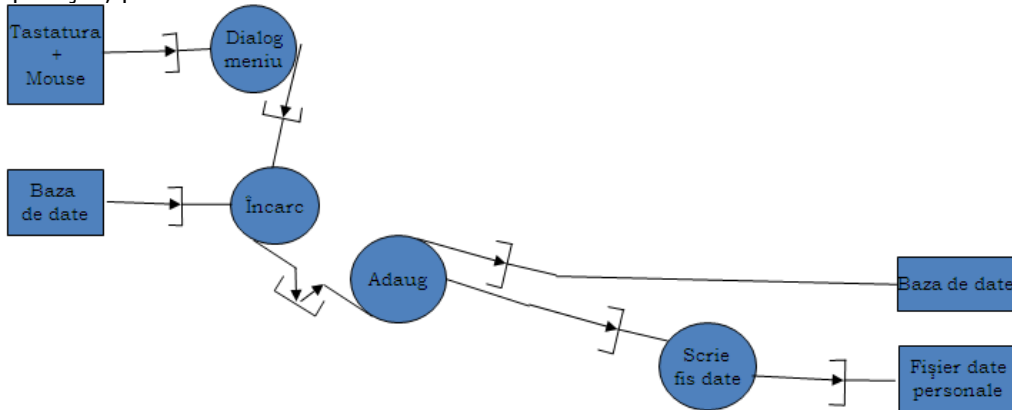
Un prim modul al aplicației este cel dedicat înregistrării unui nou-născut. Până la realizarea înregistrării propriu-zise va fi necesară completarea unui formular cuprinzând datele personale ale copilului și ale mamei. Astfel se va interacționa în primă fază cu modulul „Formular”. Accesul către oricare din modulele aplicației se face doar după un dialog cu utilizatorul care comunică cu aplicația prin intermediul unor periferice de intrare cum sunt tastatura și mouse-ul.

După cum s-a putut sesiza, din schema bloc a aplicației, modulul „Formular” este într-o așa-zisă comunicație duplex cu baza de date. Acest lucru se referă la faptul că modulul va prelua date din tabelele bazei de date și va trimite la rândul lui altă informație către baza de date. Pentru început se execută activitatea „Încarc”, unde se realizează conectarea la baza de date pentru a avea ulterior acces la toate informațiile de acolo și a putea trimite o înregistrare nouă pentru stocare. Trimiterea efectivă a datelor către tabelele bazei de date se face în cadrul activității „Adaug”, când s-a făcut deja completarea câmpurilor din program de către utilizator și se execută salvarea. Tot în cadrul acestei activități se realizează și validarea datelor. Există situații în care unele date există deja în evidență și nu mai este necesară reintroducerea lor; astfel utilizatorul dispune de opțiuni specifice prin care este permisă trimiterea doar a unei informații (CNP mamă sau Număr fișă) pentru data existentă deja în evidență. Validarea ei se face în acest modul și astfel se reduce numărul datelor necesare a fi introduse. Procedura de validare este necesară și pentru acceptarea unor date introduse, care chiar dacă sunt unice pot să nu fie corecte ca tip sau ca structură.

Între activitățile de „Încărcare” și „Adăugare” este prezent un rezervor care are rolul de a reține toată informația aferentă unei înregistrări. Toată această

informație este trimisă bazei de date pentru a fi reținută, precum și activității „Scrie fis date” pentru a fi prelucrată în vederea stocării ei și în sistemul de fișiere aferent aplicației.

În Figura 4.4 a fost extrasă porțiunea aferentă acestui modul din diagrama aplicației, pentru o redare vizuală bună a celor relatate.



**Figura 4.4 Modulul „Formular”**

După salvarea tuturor datelor introduse prin modulul „Formular” se poate trece la realizarea înregistrării propriu-zise. Modulul „Înregistrare” are o structură mai complexă, datorită multitudinii de operații care se execută în cadrul lui. Ca dispozitive de intrare din acest modul sunt doar microfonul și perifericele; la ieșire însă, se găsește întreg sistemul de fișiere, afișajul grafic și sistemul audio reprezentat de speaker-e.

La trimiterea mesajului de începere a înregistrării, activitatea „Start înreg” va declanșa pornirea sistemului de memorare al semnalului audio primit de la microfon, în paralel cu începerea procesului de eșantionare și digitizare a acestuia, care apoi convertit va fi scos la ieșirea audio. Task-ul „Memorare wav” va înregistra semnalul până ce utilizatorul nu va trimite mesajul de oprire prin activitatea „Stop înreg”. „Start înreg” și „Stop înreg” sunt controlate de utilizator prin intermediul dialogului cu utilizatorul „Dial. Start/Stop”. Implementarea efectivă a task-urilor de pornire și oprire a înregistrării va fi detaliată în subcapitolul destinat funcțiilor speciale.

Pe întreaga durată a înregistrării sunt realizate o serie de măsurători, printre care și cele ale amplitudinii semnalului provenit din plâns. În vederea efectuării acestora, au fost emulate două dispozitive de măsură: Peak Program Meter și Volume Unit Meter.

#### 4.2.1 Peak Program Meter (PPM)

Peak Program Meter (PPM) sau Peak Reading Meter (PRM) reprezintă în lumea reală un instrument audio de măsură, fiind prezentat în Figura 4.5. Acesta își găsește primele menționări încă din anii 1930 când era utilizat (sub o formă de modul hardware) în emisia radio-urilor cu modelare în amplitudine a semnalului audio. Dezvoltările ulterioare l-au consacrat ca unealtă exclusiv de măsurare a semnalului audio. Acesta prezintă câteva similitudini cu Volume Unit Meter (VU Meter), care va fi detaliat într-un paragraf ce urmează.





**Figura 4.5 Dispozitiv de măsură Peak Program Meter**

În contextul prezentului studiu, varianta fizică a unui PPM a fost emulată prin utilizarea unui software care redă fidel comportamentul echipamentului real, lucru des întâlnit în ziua de azi în cadrul analizelor profesionale de sunet. Între caracteristicile esențiale ale acestui instrument de măsură pot fi enumerate următoarele:

- Timpul de achiziție al unui PPM – reprezintă timpul necesar de achiziție al nivelului unui semnal. Acesta este mult mai rapid decât în cazul unui VU Meter, fiind aproximativ 10 milisecunde. În acest fel, tranzițiile dintre vârfurile energetice ale semnalului vocal pot fi mult mai ușor de sesizat;
- Timpul de recalibrare al unui PPM – reprezintă timpul necesar revenirii la o valoare scăzută în vederea unei noi achiziții și interpretări. Acest timp este mai mare decât în cazul VU Meter.

Utilitatea unui astfel de instrument în contextul prezentului studiu a fost susținută și prin cele enunțate anterior respectiv măsurarea foarte rapidă și bună a unor segmente de sunet insesizabile ca valoare ridicată a intensității pentru urechea umană, care au și o staționaritate foarte scăzută [60].

#### 4.2.2 Volume Unit Meter (VU)

Volume Unit Meter (VU) reprezintă asemenea dispozitivului prezentat anterior, un instrument de măsură care însă are rolul de a reprezenta vizual măsura tăriei semnalului vocal pe perioade mai mari (Figura 4.6). Ca și în cazul instrumentului prezentat anterior și VU a fost emulat în prezentul studiu. Începuturile VU Meter-ului datează din anii 1940 când a fost introdus pentru standardizarea transmisiilor pe liniile telefonice. Evoluția l-a plasat însă, la fel ca și în cazul PPM, în rândul instrumentelor standard din cadrul industriei audio.

VU măsoară valori medii ale semnalului audio și scopul lui este de a reprezenta valoric percepția sunetului din punctul de vedere al urechii umane. Făcând distincția între PPM, unde erau reliefate elemente care nu sunt sesizabile urechii umane, în timp ce în cazul măsurării cu VU există aprecieri în formă numerică a semnalului la valori sesizabile de om [61].

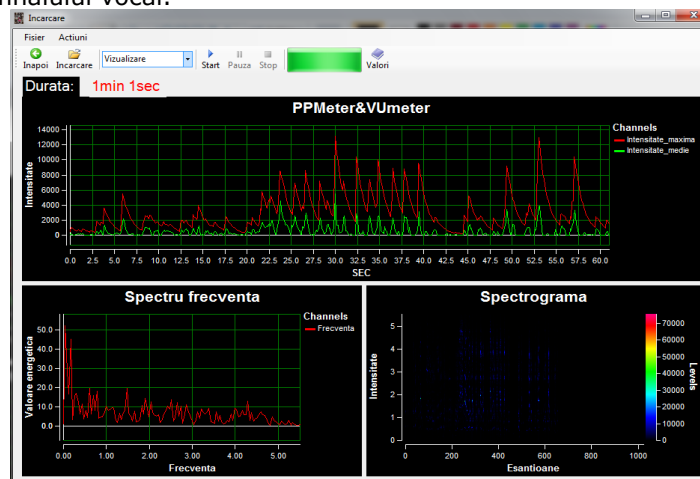
Timpul de achiziție pentru un VU și cel de recalibrare sunt în jurul valorii de 300 de milisecunde, astfel că în cazul prezentelor înregistrări se vor observa valori numerice semnificative pentru analiza cu VU, pe tronsoanele de semnal vocal continuu, mediate pe intervalul de 300 de milisecunde.



**Figura 4.6 Dispozitiv de măsură Volume Unit Meter**

Figura 4.7 oferă imaginea achiziției și măsurătorile efectuate prin aplicația Neonat cu instrumentele menționate. Pe lângă graficul aferent măsurătorilor realizate cu VU respectiv PPM a fiecărei înregistrări de plâns, se mai urmărește și spectrul de frecvențe aferent unui eșantion prelevat pe durata a aproximativ 100 milisecunde și respectiv spectrograma întregului semnal vocal. Graficul din partea stângă inferioară prezintă spectrul de frecvență. Valorile sunt instantanee și corespund fiecărui eșantion din plâns.

Graficele ce vor fi prezentate în continuare reprezintă capturi de ecran din software-ul utilizat în conducerea studiului. Graficul din partea superioară a fiecărei figuri prezintă evoluția amplitudinii semnalului vocal reprezentat prin două semnale: cel aferent intensităților maxime respectiv cel reprezentat de valorile medii ale intensității sunetului. Graficul PPMeter&VUMeter corespunde acestor două semnale: Peak Program Meter (valorile maxime ale intensității plânsului) și Volume Unit Meter (valori medii ale amplitudinii vocale ale semnalului din plâns). Graficul din partea dreaptă inferioară prezintă spectrograma întregii durate a plânsului. Aici, se poate observa atât cantitativ cât și calitativ frecvențele atinse în fiecare moment al înregistrării, prin valori numerice pe abscisă și ordonată, iar o a treia dimensiune este dată de coloratura frecvențelor care corespunde legendei din extrema dreaptă. Colorarea este realizată dinamic astfel că de la un subiect din studiu la altul acest cod de culoare poate diferi funcție de plaja de frecvențe care a fost atinsă în timpul achiziției semnalului vocal.



**Figura 4.7 Achiziția cu Neonat a unui semnal din plâns**

Odată pornită înregistrarea, se vor efectua o serie de prelucrări asupra semnalului primit de la microfon. Într-o primă fază se va face eșantionarea semnalului cu o frecvență de 11025 Hz și o reprezentare a amplitudinii pe 16 bit. Pentru trimiterea semnalului la sistemul audio de ieșire se trece printr-un task de conversie a valorilor eșantionate înapoi în valori audio, după ce în prealabil a fost umplut rezervorul dintre activități, acesta constând într-un *buffer* de 1024 de elemente. Altfel, se face o conversie a valorilor eșantionate în numere reale recunoscute de aplicație urmând apoi o serie de activități specifice prelucrării semnalelor vocale. Pentru început se aplică o funcție de fereastră peste semnalul convertit din faza anterioară. Această funcție este una dreptunghiulară, care asigură preluarea din porțiunea de semnal a unei zone în care acesta nu-și modifică esențial caracteristica datorită schimbărilor efectuate de sistemul fonator. După operația de ferestruire se va aplica transformata Fourier rapidă, rezultând semnalul discretizat. Ordinul transformatei Fourier se alege 8 pentru a conferi o rezoluție bună spectrului, acest lucru însemnând că se va aloca câte un buffer de 128 de elemente pentru coeficienții seriei Fourier. Astfel cei 5KHz de semnal studiat vor fi discretizați în 128 de frecvențe, coeficienții seriei desemnând intensitatea vocală pe fiecare din aceste 128 de frecvențe. Buffer-ul de 128 de elemente va fi supus în finalul prelucrării și unei normalizări geometrice în task-ul „Norm. SQRT”. Canalele dintre activitățile „Ferestruire” și „FFT” și între „FFT” și „Norm. SQRT” sunt proiectate ca *buffer*-e de câte 128 de elemente. Toate aceste operații se repetă la un interval de 50ms. Acest cadru temporal este unul dedus matematic ca fiind necesar pentru caracteristicile menționate anterior. S-a adoptat o valoare mai mică decât cea rezultată din calcule, pentru a asigura că nu se pierde din eșantioane.

Astfel, având:

$$F_e = 11025 \text{ Hz} \xrightarrow{F_e = 1/T_e} T_e = \frac{1}{11025} = 90,7 \mu\text{s} = 0,0907 \text{ ms}$$

timpul necesar procesării unui singur eșantion, iar pentru 1024 eșantioane, avem:

$$T_e = 1024 \cdot 0,0907 = 92,8 \text{ ms}$$

timpul necesar eșantionării unui calup de 1024 eșantioane, atât cât are dimensiunea buffer-ului de la intrarea audio. După finalizarea normalizării datele preluate din rezervor și prelucrate, vor fi trimise pe rând fișierului *spectrum.txt*, spectrogramei și modelului cascada pentru afișare.

Calculul valorilor medii și maxime ale amplitudinii (intensității) semnalului vocal la fiecare 100ms se face în task-ul „Calcul val int. vocale” de unde sunt trimise spre afișare și către fișierele *PPmeter.txt* și *VUmeter.txt*. Afișarea valorilor amplitudinii se face pe același grafic pentru a putea sesiza gradul de oscilație al valorilor.

În Figura 4.8 este prezentat modulul de înregistrare, parte din diagrama ACR a aplicației.

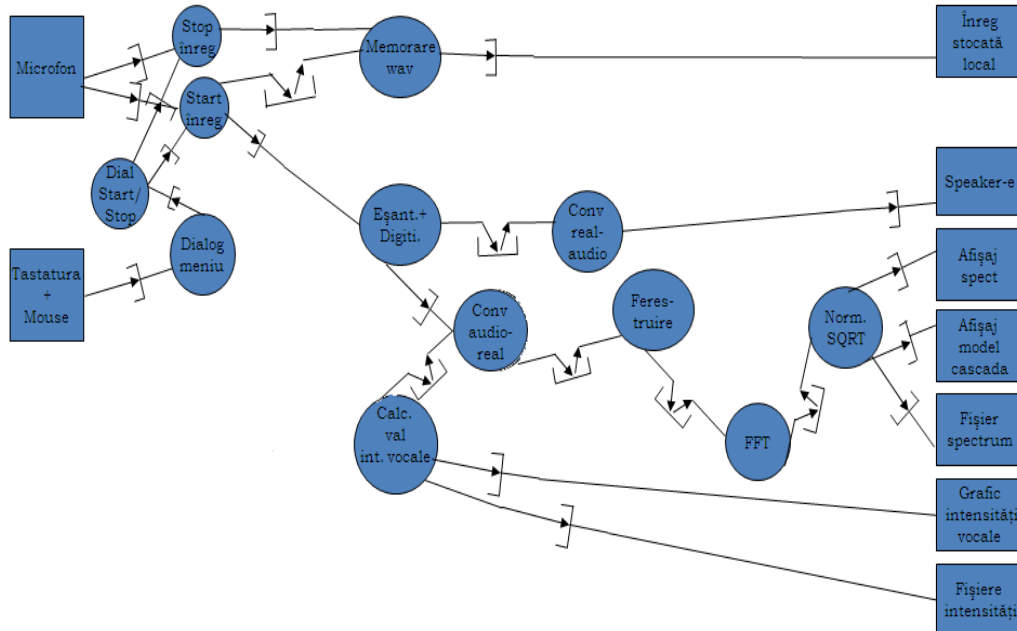
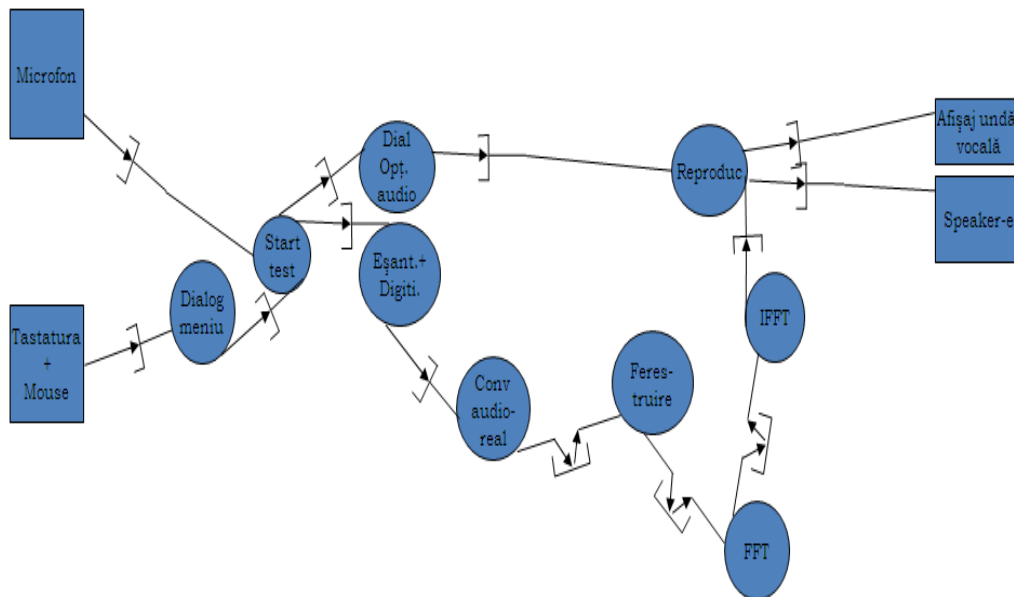


Figura 4.8 Modulul „Înregistrare”

Modulul „Testare” este accesibil utilizatorului din cadrul opțiunii de înregistrare. Rolul acestui modul este de a observa modul de reproducere al sunetului de la intrarea în sistem prin microfon la ieșirea audio, în urma setării unui număr de parametri. Funcționalitatea modului este similară celei din cadrul modului de înregistrare în zona de achiziție a semnalului. Astfel, în urma activității de dialog cu utilizatorul, inițializarea intrării și ieșirii și setarea parametrilor pentru semnalul reprodus se poate începe testarea propriu-zisă. Drumul parcurs de semnalul de la intrare este, după cum s-a mai menționat, similar celui de la înregistrare: se face eșantionarea și digitizarea, urmată de task-ul de conversie al valorilor audio în valori reale și task-urile ce vizează în final obținerea coeficienților seriei Fourier, „Feres-truire” și „FFT”. Lipsește din acest modul activitatea de normalizare geometrică care succede aplicarea transformatei Fourier rapide în cazul modului de înregistrare. Acest lucru se datorează faptului că nu se poate efectua o operațiune inversă normalizării în cazul în care aceasta a fost aplicată. Astfel, după realizarea transformării Fourier rapide peste semnal se aplică transformata Fourier inversă, iar rezultatul este trimis eșantion cu eșantion task-ului „Reproduc”. De aici informația va putea lua două căi: una este calea prin care este trimisă pentru afișare rezultând forma de undă a semnalului vocal, iar pe cealaltă valorile reale sunt convertite în valori audio pentru a putea fi reproduse de speaker-e.

Parametrii care se setează în faza preliminară începerii testării vizează intervalul reprezentării amplitudinii semnalului vocal, frecvența de eșantionare a semnalului de intrare, tipul de fereastră aplicată peste semnalul eșantionat și ordinul transformatei Fourier rapide. În Figura 4.9, se regăsește traseul urmat de semnalul de la intrarea prin microfon și până la ieșirea prin speaker-e.



**Figura 4.9 Modulul „Testare”**

Modulul „Încărcare” este o replică aproape fidelă a modului „Înregistrare”, micile diferențe fac însă necesară implementarea separată a acestuia. Un prim aspect esențial ce diferențiază cele două module este lipsa (dintre dispozitivele de intrare) microfonului, în cazul încărcării intrarea pentru semnalul audio fiind deja o înregistrare realizată anterior și stocată local, iar la ieșire nu se mai regăsesc dispozitivul aferent fișierelor de intensități.

Chiar de la inițializarea modului, task-ul „Dialog regim” va permite două moduri în care va funcționa, alegerea făcându-se prin mesajul primit pe canalul de transmisie. Astfel, „Încărcare” va putea funcționa fie în regim de analiză, fie în regim de vizualizare.

În regimul de analiză modulul va avea un dispozitiv în plus la ieșire, „Fișier verif” și toate activitățile ce țin de prelucrarea semnalului de la intrare, detaliate în paragrafele anterioare. În acest regim modulul va funcționa aproape similar cu modulul înregistrare, diferențierea făcându-se doar la natura dispozitivului de intrare și prin lipsa unui dispozitiv la ieșire.

În ambele moduri de funcționare modulul dispune, ca și dispozitive de intrare de „Fișier spectrum” și „Fișiere intensități”. Aceste dispozitive de intrare vor trimite succesiv mesaje către activitatea „Prel 1”, care va face decodificarea mesajelor și în funcție de conținut va face prelucrările aferente. Fișierele *spectrum.txt* și cele de intensități, *ppmMeter.txt*, respectiv *vuMeter.txt* au structura din Figura 4.10:

	spectrum.txt	ppmMeter.txt	vuMeter.txt
indice	0-----	0 ---->0	0 ---->0
calup date	0 -->100	1 ---->225	1 ---->43
	1 --->211	2 ---->211	2 ---->100
Intensitate	...	3 ---->133	3 ---->35
frecvență	127 --->0	4 ----> 57	4 ---->11
	1-----	5 ---->123	5 ---->100
	0 --->57	6 ---->10	6 ---->1
	1 --->123	7 ---->11	7 ---->1
	...	8 ---->77	8 ---->19
	127 --->1	9 ---->579	9 ---->321
	2-----	10---> 432	10--->212
	0 --->11	11--->123	11 --->53
	1 --->77	...	...
	...		

Figura 4.10 Structura fișierelor spectrum.txt, ppmMeter.txt, vuMeter.txt

Fișierele *spectrum.txt* vor trebui să fie unice pentru fiecare înregistrare și vor fi stocate în directorul aferent înregistrării din care au fost extrase datele, lucru realizat din aplicație. După cum se poate observa și din Figura 4.10, un fișier *spectrum.txt* are pe prima linie indicele calupului de 1024 de eșantioane prelevate în 50ms din înregistrare, iar liniile ce urmează, vor cuprinde valorile indicilor din vectorul cu coeficienții seriei Fourier, în număr de 128. La prelucrarea unui nou eșantion din înregistrare fișierul va fi completat după aceeași regulă în cadrul activității „Prel. 1”. La apariția de eșantioane duplicate, introduse prin alegerea mai mică a perioadei de achiziție, se face o eliminare a eșantioanelor inutile.

Fișierele *ppmMeter.txt* și *vuMeter.txt* au structura identică așa că pot fi tratate împreună. Ele conțin pe fiecare linie indicele calupului de eșantioane curente și valoarea energetică maximă în cazul *ppmMeter.txt* sau valoarea medie a intensității în cazul *vuMeter.txt* dintre toate eșantioanele în 100ms. Rezervoarele dintre aceste fișiere (ca dispozitive) și activitatea „Prel. 1” au o structură mai specială. Astfel, rezervorul dintre dispozitivul de intrare „Fișier spectrum” se constituie ca o tabelă de dispersie (*hash*). Această structură se definește ca o succesiune de perchi (*cheie, valoare*). Cheile sunt identificatori unici în tablou și vor fi reprezentate de indicii vectorului ce conține coeficienții seriei Fourier (numerele între 0 și 127 ce se regăsesc la începutul liniilor care nu sunt cu indicele calupului de eșantioane procesat), iar valoarea pentru fiecare cheie va fi reprezentată de valoarea corespunzătoare indicelui respectiv de pe acea linie din fișier, adică chiar coeficienții seriei Fourier. Vectorul care conține coeficienții seriei Fourier obținut prin tot procesul de prelucrare al semnalului de la intrare, va conține de fapt valorile energetice ale intensității vocale pe fiecare frecvență între 0 și 4KHz, cu un pas de aproximativ 40Hz pentru fiecare 50ms din sunetul procesat.

Rezervorul dintre dispozitivele „Fișiere intensități” este proiectat din două buffer-e care vor fi simultan alimentate cu elemente din fișierele *ppmMeter.txt* și *vuMeter.txt*, după prelucrarea în prealabil, linie cu linie a fiecărui fișier.

După cum s-a mai menționat, în cazul regimului de analiză vom avea la ieșire un dispozitiv „Fișier verif”. În acest regim se va face o reprocesare a semnalului încărcat și se va obține un fișier identic ca structură cu *spectrum.txt*. Rolul acestui fișier este de a obține un al doilea spectru de frecvențe pentru aceeași

înregistrare, însă obținut off-line, pentru a vedea diferențele față de cel creat în timp real. Activitatea „Prel. 1” va putea porni două alte activități: „Prel. Fis WEKA” sau, prin „Dialog afișare” poate determina afișarea în cadrul unui dispozitiv dedicat (construit în genul unui modul) conținutul fișierelor realizate pentru înregistrarea încărcată. „Prel. Fis WEKA” va realiza o transformare a conținutului fișierului *spectrum.txt* într-un fișier *.arff* care odată creat va putea fi lansat din cadrul acestui modul în mediul WEKA. În urma trimiterii mesajului de lansare prin activitatea „Lansare WEKA” se permite efectuarea studiilor de *Data Mining*. Structura unui fișier WEKA este prezentată în Figura 4.11, aceasta fiind extrasă dintr-un fișier real:

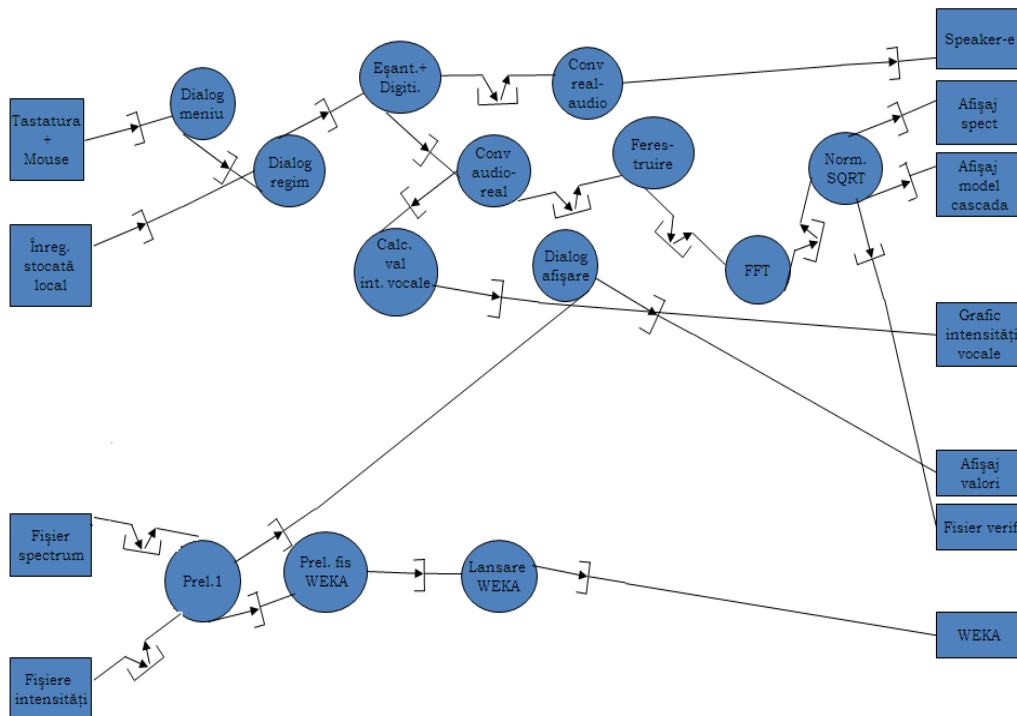
```
@relation neonat-clasificare-sex
@attribute '39Hz' numeric
@attribute '78Hz' numeric
@attribute '117Hz' numeric
...
@attribute '4992Hz' numeric
@attribute sex { masculin, feminin}
@data
26,440,453,81,75,63,54,46,40,36,32,30,28,26,23,22,21,19
,18,17,16,16,15,16,14,15,12,13,12,12,12,11,11,9,11,11,9,9,9,7
,7,7,9,9,9,8,7,7,8,7,7,6,8,7,7,6,6,7,7,7,6,7,6,6,6,6,6,5,7,6,
6,6,6,5,6,6,5,5,4,5,4,5,5,4,4,5,5,5,5,5,5,4,4,5,4,4,4,4,4,5,4
,4,4,6,5,4,5,4,4,4,4,5,4,4,5,4,5,3,4,4,5,4,4,4,4,4,4,4,4
...
28,21,8,4,6,2,3,2,3,2,3,1,1,1,0,1,1,1,1,1,1,1,1,1,1,1,0,0
,1,0,1,1,1,1,1,1,1,1,2,1,1,2,1,1,1,1,1,1,1,1,1,1,1,1,1,2,
0,0,1,1,1,0,1,1,1,0,1,1,1,1,0,1,3,2,1,2,1,0,1,1,1,0,1,1,0,1,1
,1,0,0,1,1,1,1,1,1,0,1,1,0,1,1,1,0,0,3,1,6,2,1,1,1,1,0,
```

**Figura 4.11** Structura internă a unui fișier weka.arff

Acesta este doar un model de fișier utilizat în studiul de *Data Mining*, realizat pe baza spectrului de frecvență al unui semnal din plâns. În vederea obținerii unor rezultate relevante ale studiului este necesară și crearea unor fișiere pentru datele de amplitudine vocală provenite de la cele două instrumente de măsură emulate. Toate aceste fișiere vor avea diverse forme, în funcție de scopul studiului putându-se opta și pentru fișiere mixte în care să fie integrate și date ale nou-născutului sau ale mamei, considerate ca relevante în procedura de „minerit”.

Fișierul oferit ca exemplu conține în cadrul unui antet declararea unor atribute care sunt asemenea unor nume de câmpuri de tabel. După realizare acestor declarații urmează datele corespunzătoare fiecărui atribut, pe câte o linie, fiecare set de 128 de valori câte se regăsesc și pentru exemplul de față.

Aceasta, în Figura 4.12, este în ansamblu arhitectura modulului „Încărcare”, reprezentată prin elementele corespunzătoare din cadrul diagramei ACR generale:



**Figura 4.12 Modulul „Încărcare”**

Modulul „Registru” este un al treilea modul după „Încărcare” și „Formular” care derivă direct din activitatea „Dialog meniu”. Modulul va permite accesul către toate înregistrările din tabelele bazei de date, peste care se vor putea efectua diverse prelucrări prin activitatea „Registru”. La fel ca și modulul de încărcare, și modulul „Registru” va avea două regimuri de funcționare: anonim și neanonim. Acest element de confidențialitate este necesar în contextul unei aplicații cum este cea de față, care tratează date personale reale ale unor persoane participante la un studiu.

Trimiterea mesajului de regim anonim către activitatea „Registru” va determina pierderea anumitor drepturi pe care utilizatorul le poate avea asupra operațiilor ce se pot efectua asupra bazei de date (stergere, modificare, vizualizarea anumitor câmpuri).

Operațiile în regim neanonimizat sunt realizate în activitatea „Registru”, care trimite succesiv mesaje bazei de date pentru salvarea tuturor modificărilor realizate, dar și dispozitivului „Afișaj BD” pentru actualizarea înregistrărilor afișate.

Rezervorul dintre task-ul „Încarcă” și „Registru” va fi reprezentat de o tabelă care va cuprinde în funcție de mesajele de la utilizator, înregistrări din fiecare tabel al bazei de date, luate bineînțeles pe rând. Detalierea tabelor și a câmpurilor acestora va fi făcută în subcapitolul ce urmează în Figura 4.13 sunt prezentate elementele diagramei ACR care țin de acest modul.



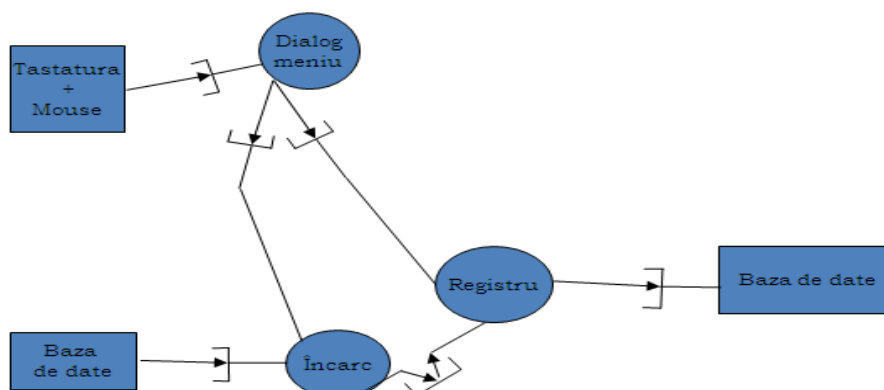


Figura 4.13 Modulul „Registru”

### 4.3 Arhitectura bazei de date

Orice aplicație care operează cu date numeroase și care necesită stocare îndelungată, are nevoie de una sau mai multe baze de date. Când aplicația are ca și țintă realizarea de *Data Mining*, noțiunea de bază de date este indispensabilă. Baza de date concepută, oferă structuri de tabele în care datele pot fi stocate și organizate în orice fel se dorește.

În vederea stocării datelor provenite din înregistrări ale semnalului din plâns și cele care vizează informații personale ale mamei și nou-născutului, se utilizează în cadrul aplicației de față, pe lângă sistemul de fișiere, și o bază de date. Aceasta a fost realizată utilizând sistemul de gestiune al bazelor de date, Microsoft SQL Server Express Edition, care este oferit în mod gratuit pentru utilizare. Acesta este utilizat doar pentru partea de stocare, deoarece crearea tabelor, inserarea înregistrărilor noi sau modificări ale datelor deja existente sunt realizate direct din aplicație. Tot din cadrul software-ului realizat se face și vizualizarea datelor, prin modulul menționat în subcapitolul precedent, „Registru”, care oferă și posibilitatea căutării în tabelele bazei de date.

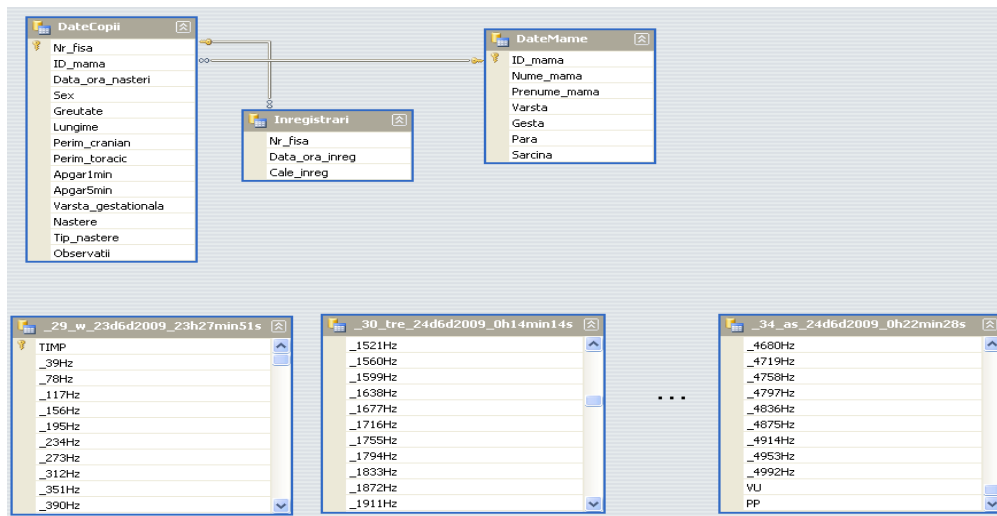


Figura 4.14 Arhitectura bazelor de date

Baza de date cuprinde trei tabele relaționate câte două: „DateMame”, „DateCopii” și „Înregistrări”. Acestea au următoarele câmpuri, cu tipurile aferente din SQL Server, ilustrate și în Figura 4.14:

- Tabela „DateMame”: cod numeric personal (numeric(18,0)), nume (varchar(50)), prenume (varchar(50)), gesta (smallint), para (smallint), varsta (smallint), sarcina (varchar(14));
- Tabela „DateCopii”: numărul foii de observație (numeric(18,0)), codul numeric personal al mamei (numeric(18,0)), data nașteri în formatul: zz/ll/aaaa ora:min:sec (datetime), sex (bit), greutate (int), lungime (int), perimtru cranian (int), perimetru toracic (int), indice Apgar la 1 minut și la 5 minute (smallint), vârsta gestațională (smallint), naștere (varchar(11)) și tipul nașterii (varchar(10)), observatii (text);
- Tabela „Înregistrări”: numărul foii de observație (numeric(18,0)), data și ora înregistrării în formatul: zz/ll/aaaa ora:min:sec (datetime), calea către înregistrare (text);

După cum se poate observa și din Figura 4.14, între tabelele „DateMame” și „DateCopii” precum și între „DateCopii” și „Înregistrări” există o relație de unu-la-mai mulți. Astfel, datele unei mame vor fi înscrise o singură dată în tabelul „DateMame”, unde codul numeric al acesteia este cheie primară fiind astfel unic pe tabelă, în timp ce în tabelul „DateCopii” vom putea avea mai multe apariții ale codului numeric personal. Această situație poate să apară în cazul în care aceeași mamă va avea mai mulți copii participanți la studiu.

Numărul fișei de înregistrare a nou-născutului este cheie primară în tabelul „DateCopii”, aceasta jucând însă și rolul de cheie externă în cadrul tabelului „Înregistrări”. La fel ca și în situația precedentă, la aceste ultime două tabele avem o relație de unu-la-mai mulți, datorită faptului că același copil poate fi înregistrat de mai multe ori, datele lui nefiind nevoie să fie copiate din nou, relaționarea adăugând o intrare nouă în tabelul „Înregistrări”.

După efectuarea unei înregistrări, toate valorile reprezentând spectrul de frecvență și valorile medii și maxime ale amplitudinii semnalului din plâns sunt stocate în cadrul unui tabel al bazei de date. Acest tabel se va crea dinamic, fiind unic pentru fiecare înregistrare în parte. Tabelul creat va avea ca și linii cele 128 de

câmpuri destinate spectrului de frecvență, un câmp pentru intensitatea sonoră maximă și unul pentru cea minimă, toate pe fereastra de 100ms. Ultimul câmp, cel de timp, va fi destinat momentului temporal când aceste valori au fost extrase, adică multipli de 100ms până la durata totală a înregistrării. Acest din urmă tabel, care de fapt este doar o structură de tabel - el „personalizându-se” pentru fiecare înregistrare în parte, va primi și un nume în conformitate cu aceasta. Numele tabelului este creat prin alipirea la numărul fișei de înregistrare, a numelui mamei, a datei și orei înregistrării, ca în exemplul din Figura 4.15. În acest fel - s-a evitat alocarea unui alt câmp într-un tabel care pe lângă faptul că necesită alocarea unei dimensiuni considerabile, este unic pentru fiecare înregistrare, iar în contextul unui lot mare de înregistrări, aceste tabele vor ocupa mult spațiu. Dacă se consideră o înregistrare de 30 de secunde, tabelul de valori al acesteia va avea 300 de linii cu câte 131 de date pe fiecare linie, adică un total de 39300 de valori.

Deși nu este realizată o relaționare a acestor tabele de valori cu celelalte tabele, din numele oricărui tabel de valori poate fi extrasă informația utilă pentru a ști cărui copil îi aparține înregistrarea (numărul fișei este unic pentru fiecare copil din evidență, el putând fi extras cu ușurință din numele tabelului), iar cunoscându-se copilul, din relaționarea cu tabelul de date ale mamelor se pot imediat determina cu ușurință și restul datelor.



```
_NumărFișă_NumeMama_ZIdLUNAdAN_ORAhMINUTULminSECUNDAs
```

**Figura 4.15 Modelul construirii numelui tabelului de valori pentru o înregistrare**

## 4.4 Funcții (proceduri) speciale

În secțiunile destinate arhitecturii aplicației și a bazelor de date au fost amintite o serie de funcții pe care aplicația le îndeplinește, prezentându-se funcționalitatea lor și eventuale structuri de date cu care operează. Această secțiune este destinată detalierei anumitor funcții și metode mai importante din program prin prezentarea unor scurte secțiuni de cod, componente utilizate și eventuale organigrame de funcționare ale acestora.

Tratând pentru început modulul „Înregistrare”, se va dezvolta metodologia de înregistrare a unui plâns. Pentru a face misiunea preluării datelor de la microfon mai ușoară se utilizează o serie de componente din pachetele AudioLab și SignalLab care oferă facilități de prelucrare digitală de semnal.

Pentru recepția semnalului de la microfon se utilizează componenta „AudioIn”. Această componentă trebuie configurată pentru aplicație în scopul de a obține rezultate corecte. Printre cele mai importante proprietăți care necesită setare sunt cele ale numărului de canale pentru recepția semnalului audio (2 canale), numărul de biți alocați reprezentării amplitudinii (16), perifericul intern pe la care semnalul este recepționat (placa audio de pe sistemul gazdă al aplicației), frecvența de eșantionare (11025 Hz), dar și alte proprietăți care nu sunt de o așa mare importanță comparativ cu cele menționate. La nivelul acestei componente se execută procesul de eșantionare și digitizare. Această componentă permite conectarea la intrările mai multor alte componente, asemenea unui circuit electric. Astfel, „AudioIn” se conectează la componente de tipul: „AudioOut”, „WaveLogger”, „PPmeter”, „VUMeter” sau „AudioToReal”. Fiecare din componentele la care este

legată intrarea audio se conectează la o altă componentă, creîndu-se astfel o arhitectură mai complexă de componente interconectate.

„AudioOut” este ieșirea audio la nivelul căreia semnalul eșantionat și digitizat este refăcut în valori audio și este trimis la placa audio și mai apoi se scoate spre exterior prin speaker-e. La fel ca toate celelalte componente, și aceasta are o serie de proprietăți care necesită setare în faza de implementare.

„WaveLogger” este o componentă ce are ca scop stocarea semnalului ce trece prin „AudioIn” sub forma unui fișier *wav*. Există componente care stochează semnale audio și în alte formate, însă nu au multe din avantajele pe care le oferă un *wav*. **WaveForm Audio Format** (*wav*) este printre puținele formate audio care nu sunt supuse compresiei în faza de creare. Un fișier *wav* va conține informația brută necomprimată și neformatată în zona alocată pentru informație din cadrul său. Formatul este unul pentru sistemul de operare Windows, fiind astfel recunoscut pe majoritatea platformelor.

„PPmeter” și „VUmeter” implementează prin cod funcționarea dispozitivelor similare din lumea fizică. Componentele vor măsura nivelele de intensitate vocală pe intervale stabile de programator; una din componente, „PPmeter” pe cele maxime în intervalul stabilit și cealaltă, „VUmeter”, valorile medii pe același interval. Cele două componente vor fi conectate la câte un „Scope” pentru afișarea valorilor măsurate.

„Scope” face parte din pachetul „PlotLab”, la fel ca și „Watterfall”. Acestea două au rolul de a afișa în mod grafic informația primită pe la intrările lor. Componentele au un număr foarte mare de proprietăți, a căror valorificare cade în sarcina programatorului. „Scope” dispune de mai multe canale de intrare, în cazul în care se dorește afișarea pe același grafic a mai multor semnale. Această posibilitate este pusă în evidență, prin legarea la intrările lui a ieșirilor de la „PPmeter” și „VUmeter”. Printre proprietățile mai importante se numără aceea prin care componenta poate răspunde la diverse evenimente (aparitia unei frecvențe, o anume intensitate, după timp sau în funcție de eșantioane), valori maxime sau minime care să fie afișate, tipul axelor (logaritmice sau nelogaritmice) și multe altele.

„AudioToReal” face conversia valorilor audio recepționate în valori reale reprezentabile. În cadrul modului de înregistrare, această componentă se conectează la două „Fourier”, prin două ieșiri, nerealizându-se însă o divizare de semnal. Acest aspect este foarte important, deoarece în cazul în care s-ar realiza divizarea, valorile de la ieșirea din componentă nu ar mai reflecta trăsăturile semnalului studiat.

„Fourier” implementează operațiile ce se realizează la aplicarea unei transformate Fourier rapide peste un set de valori dintr-un semnal eșantionat și cuantizat. Între proprietățile componenteii cele mai importante sunt funcția de ferestruire ce se aplică, ordinul transformatei și tipul de normalizare.

Cu aceste elemente prezentate și cu alte câteva componente specifice mediului Visual C# s-a construit modulul de înregistrare. În organigramele din Figura 4.16 sunt prezentate acțiunile ce se succed după pornirea înregistrării la fiecare 50ms în cadrul unui timer care se rearmorează la acest interval și finalul înregistrării când aceasta este oprită de utilizator. Pornirea înregistrării nu a mai fost prezentată, ea realizând doar armarea timer-ului și inițializarea stream-ului asociat fișierului *spectrum.txt* și a tuturor componentelor ce se regăsesc în cele două metode prezentate în Figura 4.16.

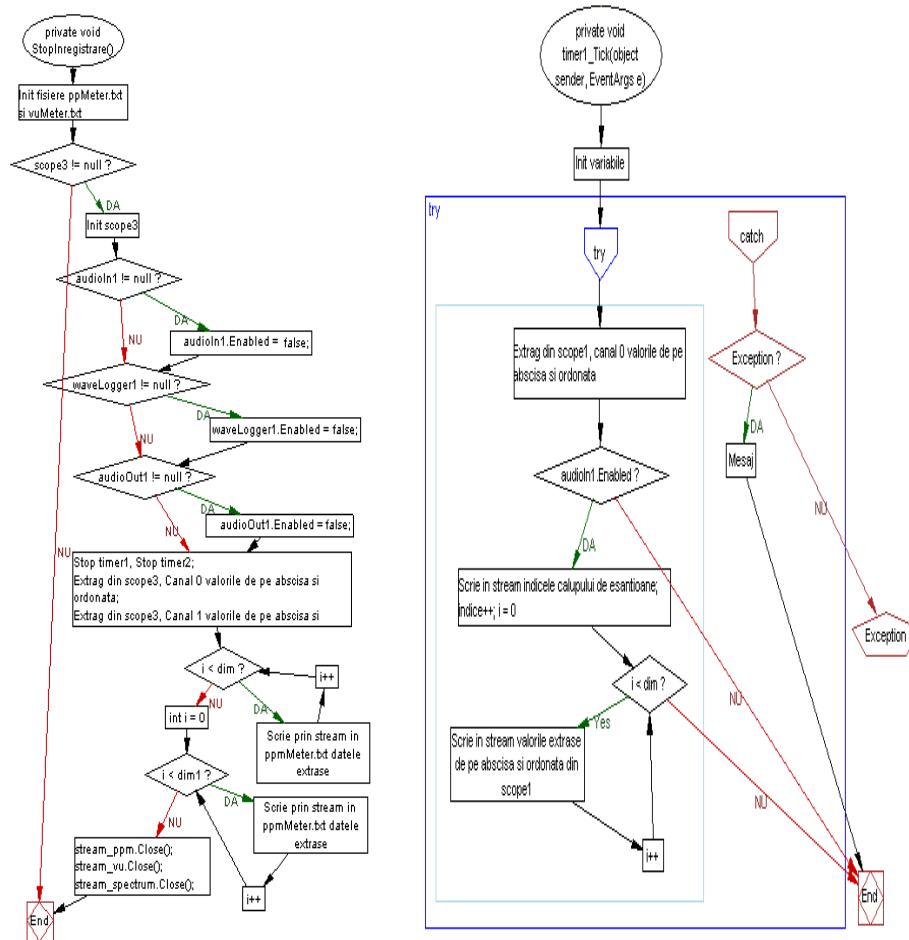


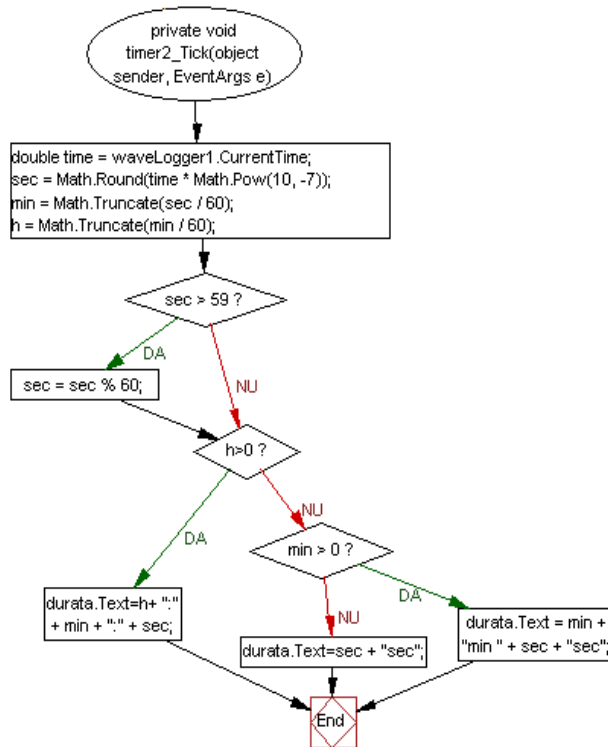
Figura 4.16 Evenimentele din timpul și de la oprirea înregistrării

a)

b)

Pe perioada cât se înregistrează va fi afișat un cronometraj al timpului de înregistrare disponibil doar pentru vizualizare și informarea utilizatorului. Timpul este extras din componenta „WaveLogger” care furnizează durata înregistrării stocate la un moment dat, în microsecunde. Astfel, în cadrul unui timer care se reinițializează la fiecare secundă se extrage durata piesei și printr-o serie de prelucrări se afișează curgerea naturală a timpului. Valoarea temporală este adusă în unitățile de măsură corespunzătoare, mai precis în secunde și minute. După scurgerea firească a celor 60 de secunde, se incrementează valoarea minutelor, iar variabila asociată secundelor se reinițializează.

Organigrama funcționalității menționate mai sus este prezentată în Figura 4.17:



**Figura 4.17** Organigrama funcționării afișajului duratei înregistrării

Modulul „Înregistrare” mai cuprinde și alte funcții ce implementează lucrul cu meniuri, bara de unelte, schimbări de stare a unor butoane în funcție de contextul curent sau deschideri de ferestre noi. Acestea prezintă o realizare clasică în ceea ce înseamnă lucrul cu medii de programare vizuală și nu se va insista pe detalierea lor.

Aplicația conține o parte consistentă de lucru cu baze de date. Pentru lucrul cu baze de date mediul Visual Studio dispune de spațiul de nume *SqlClient* conținut în *System.Data*. Acesta pune la dispoziția programatorilor o serie de obiecte care facilitează accesul și lucrul cu baze de date:

- *SqlConnection* – permite conectarea la o bază de date prin intermediul string-ului de conectare;
- *SqlCommand* – face posibilă editarea unei interogări asupra bazei de date, dar și executarea unei comenzi SQL NonQuery (insert,create,update sau delete);
- *SqlDataAdapter* – reprezintă adaptorul de servicii utilizate pentru a efectua interogări asupra surselor de date. Acesta poate fi asemănat unei punți de trecere dintre un *DataSet* și o sursă de date (o tabelă a unei baze de date) pentru a extrage datele sau a le salva. Adaptorul furnizează această punte prin utilizarea metodei *Fill*, pentru a încărca datele din sursa de date într-un *DataSet*, respectiv *Update*, pentru a trimite schimbările făcute în *DataSet* înapoi în sursa de date;

- SqlCommandBuilder – generează automat comenzile necesare pentru ca schimbările făcute într-un tabel dintr-un DataSet să se reflecte și în baza de date din care a fost încărcat;
- DataSet – nu face parte din spațiul de nume SqlClien ci direct din spațiul *System.Data* dar este utilizat în lucrul cu baze de date deoarece el stochează în memorie o copie a datelor extrase dintr-o sursă de date. Un DataSet constă dintr- colecție de tabele;

Referitor la string-ul de conectare la baza de date, există un număr mare de forme pentru acesta. În cazul utilizării versiunii Express a Microsoft SqlServer este necesară adăugarea numelui `.\SqlExpress` la sursa de date. În alte versiuni de SqlServer această construcție suplimentară nu este necesară.

Pentru conectarea aplicației la baza de date, este utilizat un string special de conectare, prezentat în Figura 4.18:

```
publicstring      ConnectionString      =      "Integrated
Security=SSPI;"      +      "Initial      Catalog=;"      +      "Data
Source=.\SQLEXPRESS;AttachDbFilename="      +      @"C:\Documents and
Settings\EchoBlaster\Desktop\Neonat\Test1\Neonat.mdf;";
```

**Figura 4.18 String-ul de conectare al aplicației la baza de date**

Această structură de conectare se folosește pentru realizarea conexiunii cu baza de date. După deschiderea acesteia, ea se asociază unui SqlCommandBuilder care va conține comanda SQL pentru extragerea datelor dintr-un tabel anume al bazei de date. Prin alocarea unui tabel nou într-un DataSet, folosind metoda *Add* a acestei componente, înregistrările vor fi aduse aici și stocate local cu ajutorul obiectului SqlDataAdapter prin metoda *Fill* a acestuia, care după cum s-a mai menționat, face trecerea datelor din baza de date în aplicație.

În cadrul aplicației s-a realizat o funcție specială, *încarcă*, care efectuează toate aceste operațiuni expuse mai sus, ușurând astfel munca de programare și contribuind la modularizarea aplicației. Această funcție va fi apelată ori de câte ori este necesară încărcarea unei informații din oricare din tabelele bazei de date. Funcția va primi ca și parametri tabelul din care se face extragerea datelor și o comandă SQL în formă text pentru interogarea care va fi efectuată asupra tabelului dat ca parametru. Codul aferent acestei funcții este prezentat integral în Figura 4.19.

```

private void incarca(string tabel, string sql)
{
    if (conn.State == ConnectionState.Open) conn.Close();
    conn = new SqlConnection(connectionString);
    conn.Open();

    cmd = new SqlCommand(connectionString);
    cmd.Connection = conn;
    cmd.CommandText = sql;

    ds = new DataSet(tabel);
    ds.Tables.Add(tabel);

    da = new SqlDataAdapter(cmd);
    da.Fill(ds.Tables[tabel]);

    builder = new SqlCommandBuilder(da);
}

```

**Figura 4.19** Funcția de conectare și extragere de valori dintr-o tabelă a bazei de date

Comunicarea cu baza de date se realizează în cadrul modulelor „Formular” respectiv „Registru”. În cadrul modulului „Registru” se face încărcarea tuturor informațiilor din baza de date spre vizualizare, iar în cazul operării în regim de neanonimat se pot efectua și modificări și ștergeri, iar căutarea se poate face în ambele regimuri de funcționare.

Pentru vizualizarea datelor din baza de date în cadrul unor elemente ca *TextBox*-ul, *CheckBox*-ul, *ComboBox*-ul sau *DateTimePicker*-ul s-au utilizat legături din cod, *DataBindings* prin intermediul unui *BindingSource*. În acest mod a fost posibilă asocierea fiecărei componente cu o anumită coloană dintr-un tabel, ținându-se cont de tipul coloanei și al obiectului cu care urmează să fie legată.

Parcurgerea datelor dintr-un tabel în cadrul aplicației determină actualizarea datelor preluate și din celelalte tabele, datorită relaționărilor dintre acestea. În cadrul operațiilor de modificare sau ștergere s-au utilizat comenzi SQL *nonquery*. În acest fel se elimină utilizarea unor elemente, cum ar fi *BindingSource*-ul, asigurându-se însă ducerea la bun sfârșit a operației dorite.

*BindingSource*-ul este un element ale cărui capabilități pot fi valorificate cel mai bine în operații cum ar fi cea de cautare a unei înregistrări într-o tabelă. Următoarea funcție prezintă modul de căutare al unei înregistrări într-o tabelă, dar care va actualiza și informația afișată din celelalte tabele (Figura 4.20). Astfel, la căutarea unei mame după codul numeric personal al acesteia, dacă aceasta este găsită vom avea afișate și informațiile despre copiii acesteia care se regăsesc în evidență, iar pentru fiecare copil înregistrările vocale corespunzătoare.



```

private void CautaToolStripButton_Click(object sender,
EventArgs e)
{
    bool flag = false;
    int total = bindingSource1.Count;
    bindingSource1.MoveFirst ();

    do
    {
        if
        (ID_mamaTextBox.Text.Equals (CNPcautatToolStripTextBox.Text))
        {
            MessageBox.Show ("S-a gasit inregistrarea");
            flag = true;
        }
        try
        {
            incarca ("DateCopii", "select * from
                DateCopii where ID_mama=" +
                ID_mamaTextBox.Text);
            bindingSource3.DataSource =
ds.Tables ["DateCopii"];
            incarca ("Inregistrari", "select *
                from Inregistrari where Nr_fisa="
                + Nr_foaietextBox.Text);
            bindingSource2.DataSource =
ds.Tables ["Inregistrari"];
            actualizare ();
        }
        catch (SqlException ex) {ex.Message.ToString ();}
        break;
    }
}

```

**Figura 4.20 Funcția de căutare cu actualizarea tuturor tabelor**

În modulul „Formular” se realizează adăugarea unei înregistrări după caz în una, două sau trei tabele. Acest lucru se datorează unor facilități pe care le are utilizatorul care, de exemplu, dacă un copil există deja în evidență nu va fi nevoit să introducă toate datele acestuia ci doar un câmp de validare. Astfel, în cadrul acestui modul este necesară și încărcarea datelor din tabele pentru a putea efectua verificările de rigoare, care se impun în cadrul acestui tip de facilități.

În Figura 4.21 este prezentată organigrama funcției ce se apelează la evenimentul „Click” al butonului de salvare al înregistrării în baza de date. Se menționează că în această funcție nu se utilizează metoda de încărcare prezentată mai sus, preferându-se utilizarea unui obiect de tip *DataReader*. Acesta are rolul de a parcurge liniile extrase dintr-o tabelă în funcție de interogarea primită ca parametru la inițializare. Metoda de interogare „HasRows” a obiectului de tip *DataReader*, determină dacă există linii din tabelă extrase în cadrul acestui obiect.

Elementele „CopilCheckBox” și „MamaCheckBox” sunt facilitățile de care se dispune, iar bifarea lor va conduce la necesitatea introducerii CNP-ului mamei pentru *MamaCheckBox.Checked*, respectiv a numărului fișei de observație a copilului pentru *CopilCheckBox.Checked*, ca informație de validare a existenței mamei sau copilului în evidență.



vederea afișării este realizată cu ajutorul unui enumerator din clasa *IdictionaryEnumerator*.

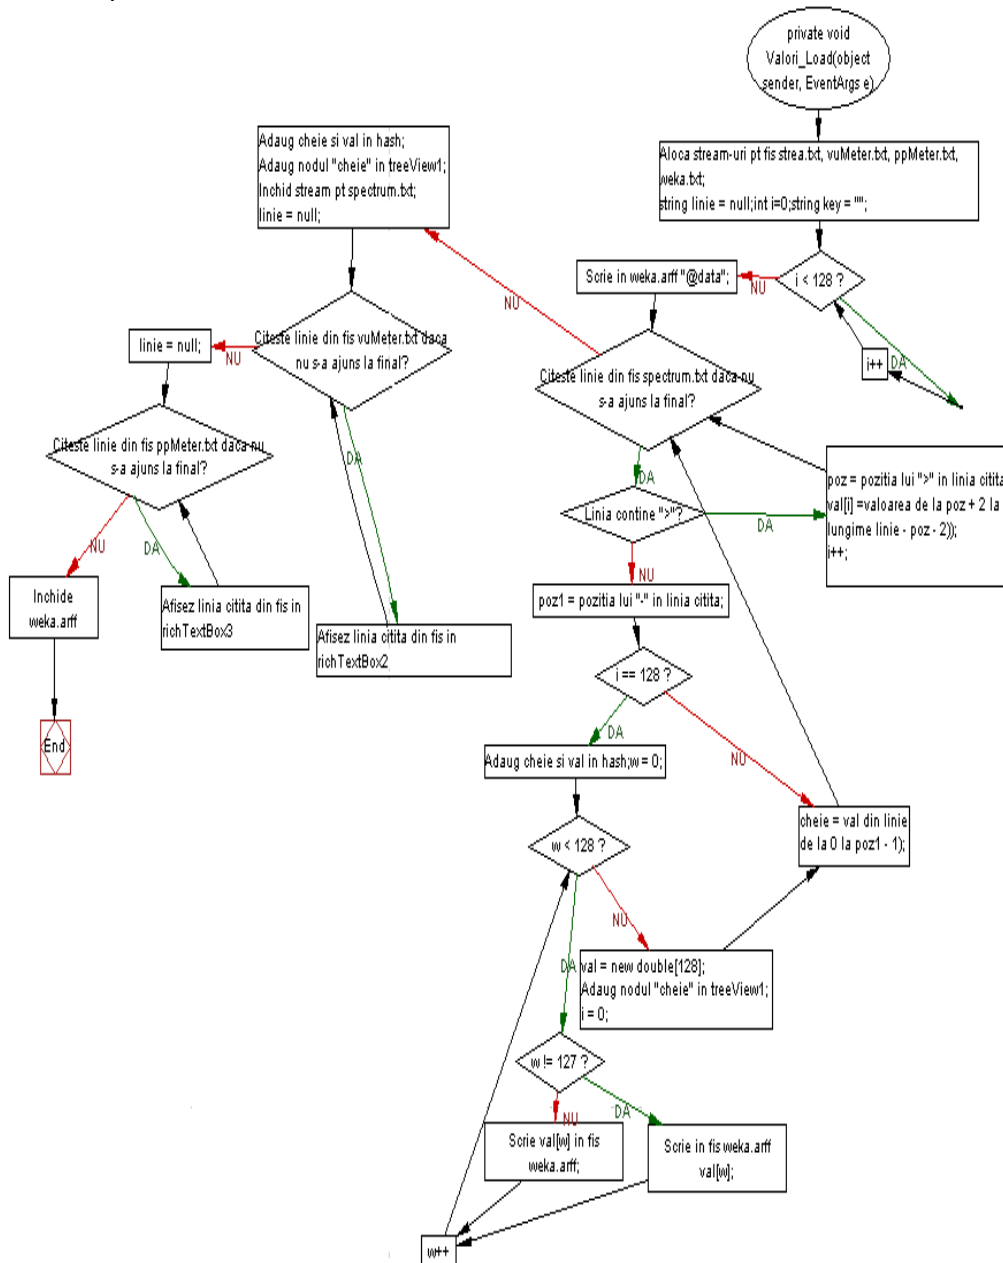


Figura 4.22 Încărcarea din aplicație a datelor conținute în fișierele de intensități

După ce în prealabil controlul *TreeView* a fost populat cu valorile cheilor din *hash*, acestea reprezentând momentul de timp din înregistrare când au fost prelucrate o serie de 1024 de eșantioane, evenimentul de selectare al unui nod din

acest control va trebui să copieze în *RichTextBox* toate valorile ce se regăsesc la cheia din *hash* cu numele identic cu cel al nodului selectat. Funcția ce realizează acest lucru în cadrul evenimentului *AfterSelect* corespunzător *TreeView*-ului este cea prezentată în Figura 4.23:

```
private void treeView1_AfterSelect(object sender,
TreeViewEventArgs e)
{
    double[] val_afis = newdouble[128];
    richTextBox1.Text = "";
    IDictionaryEnumerator en = hash.GetEnumerator();
    while (en.MoveNext())
    {
        if
(treeView1.SelectedNode.Text.Equals(en.Key.ToString()))
((double[])en.Value).CopyTo(val_afis, 0);
    }
    for (int i = 0; i < 128; i++)
    {
        richTextBox1.Text = richTextBox1.Text +
39*(i+1) + " Hz ---> " + val_afis[i].ToString()
+ "\n";
    }
}
```

Figura 4.23 Parcurgerea hash-ului și afișarea conținutului lui

Pentru lansarea unei alte aplicații din cadrul unui program realizat, cum este WEKA în cazul de față în Visual Studio sub limbaj C# este necesară utilizarea proceselor. După crearea și instanțierea unui proces, va fi necesară oprirea evenimentelor ridicate de acesta. Se va asocia procesul cu un fișier dorit de programator, iar la lansarea procesului se va porni aplicația (Figura 4.24) care utilizează ca dată de intrare respectivul fișier.

```
System.Diagnostics.Process proc = new System.Diagnostics.Process();
proc.EnableRaisingEvents = false;
proc.StartInfo.FileName = Logo.cale + "/weka.arff";
proc.Start();
```

Figura 4.24 Lansarea aplicației WEKA prin codul aplicație

## 4.5 Concluzii parțiale

### 4.5.1 Protocolul de înregistrare

În realizarea studiilor pe datele achiziționate, s-a construit pentru început un protocol pentru efectuarea înregistrărilor. Rolul acestuia este de a trasa un set de

reguli de conduită și de a crea un cadru propice în care activitatea să se desfășoare, cu evitarea a cât mai multor perturbații care pot influența datele analizate ulterior. Un deziderat important este reprezentat de asigurarea de condiții identice fiecărui nou-născut înregistrat și nu în ultimul rând, un ultim aspect extrem de important în cadrul protocolului vizează și etica ce trebuie să guverneze întreg studiul. Astfel, protocolul prezintă următoarele puncte:

- Înregistrările se efectuează pe toți nou-născuții pentru care mamele acestora și-au exprimat consimțământul să participe la acest studiu;
- Doctorii care au însoțit nașterea trebuie să își dea și ei acordul pentru efectuarea înregistrării asupra copilului pe care tocmai l-au asistat la naștere;
- Nou-născuții participanți la studiu vor fi înregistrați în primele minute de la naștere, excepție făcând doar cei asupra cărora planează suspiciuni de suferință neurologică pentru care se vor putea face și înregistrări ulterioare;
- Înregistrările se efectuează cu un singur microfon, iar în cazul defectării acestuia se va utiliza doar unul similar, de la aceeași firmă producătoare și care să aibă caracteristici funcționale identice;
- La un moment dat se efectuează o înregistrare doar asupra unui singur copil;
- În momentul înregistrării vor fi prezente doar două persoane în sala unde se realizează aceasta, operatorul și un asistent medical;
- Operatorul va trebui să ancoreze microfonul în incubator după un model realizat, urmărind să păstreze aceeași distanță între microfon și platforma incubatorului, ca în cazul precedentelor înregistrări. Se va face o testare pentru verificarea funcționalității microfonului utilizând aplicația. După aducerea nou-născutului operatorul va trebui să introducă datele personale ale copilului înregistrat și ale mamei, să pornească și să oprească înregistrarea în curs de derulare, iar în final să facă o verificare a datelor introduse și a înregistrării realizate;
- Asistentul medical are rolul de a sprijini operatorul în realizarea înregistrărilor. Acesta va trebui să aducă nou-născuții și fișa nou-născutului de la sala de naștere și până la locul de desfășurare al înregistrării după ce s-au realizat toate testele medicale obligatorii după naștere. Copilul va fi așezat pe spate de către asistent cu gura orientată către microfon, fiind stimulat tactil numai dacă este necesar pentru provocarea plânsului. După terminarea înregistrării, nou-născutul va fi dus în unul din saloanele destinate monitorizării acestora;
- Durata unei înregistrări nu trebuie să depășească 90 de secunde, nedorindu-se suprasolicitarea nou-născutului;
- La finalizarea unei sesiuni de înregistrări, se va elibera incubatorul, pentru a fi disponibil utilizării de către cadrele medicale;

Având conturat acest protocol, a fost începută etapa de înregistrare a nou-născuților în conformitate cu cele menționate mai sus.

Revenind la realizarea efectivă a aplicației, partea de testare a aplicației s-a făcut în paralel cu dezvoltarea modulelor ei. Acest tip de abordare este specifică ciclului de viață V, pe care software-ul de față l-a urmat în implementarea lui. Testele unitare au vizat funcționarea fiecărui subsistem constitutiv al aplicației, mai precis modulele de înregistrare, încărcare, testare, formular și registru.

Modulul de testare a fost conceput pentru a verifica reproducerea semnalului vocal colectat, în funcție de valorile a diverși parametri, care mai apoi a fost adaptat pentru versiunea finală a modulelor de înregistrare respectiv încărcare.

Validarea funcționării modulelor „Registru” respectiv „Formular” a fost realizată în paralel. Modulul formular a servit introducerii datelor în baza de date respectiv sistemul de fișiere, vizualizarea celor introduse făcându-se din modulul registru. S-a avut în vedere introducerea tuturor situațiilor posibile de date: copil cu mama lui inexistenți în evidență, un copil neînregistrat dar care are mama în evidență sau copil existent pentru care se dorește realizarea unei noi înregistrări. Deși până la momentul prezent în utilizarea aplicației în mediul destinat nu a existat decât prima situație, în care nici mama și nici copilul nu au fost introduși în baza de date, se are în vedere utilizarea aplicației pe termen lung, fapt care ar putea aduce și situațiile de excepție enumerate mai sus.

În faza de integrare a aplicației s-au realizat conexiunile dintre module în scopul realizării testelor de acceptanță, care validează funcționarea modulelor ca un tot unitar. S-a constatat că software-ul realizează corect trecerea prin modulele distincte, mesajele trimise între acestea funcționând după cum a fost prevăzut.

Partea finală a testării aplicației a fost chiar în mediul de lucru cu aceasta, când s-a putut vedea cu exactitate funcționarea ei. Micile ajustări necesare unei operări cât mai bune au fost realizate și în funcție de preferințe ale personalului medical.

Pentru această etapă din cadrul proiectului, software-ul realizat se poate considera funcțional, ca urmare a utilizării lui de către cadrele medicale, fără semnalarea vreunei nefuncționalități.

#### 4.5.2 Dificultăți întâmpinate

În realizarea software-ului prezentat au apărut și o serie de probleme până la finalizarea acestuia. În construcția aplicației majoritatea problemelor întâmpinate au fost pe partea de achiziție în timp real a semnalului vocal provenit din plâns. Pentru facilitarea acestei sarcini au fost utilizate o serie de componente cu funcționalitățile testate, dar care au necesitat adaptare pentru cerințele aplicației de față. Operațiile efectuate de sistemul de calcul în timp real implică deseori interacțiuni cu alte procese ce își desfășoară activitatea în tot acest timp. În rezolvarea acestei probleme s-a făcut o analiză a proceselor ce pot cauza conflictul, iar soluția a constat în decalarea anumitor procese.

Efectuarea prelucrării unui semnal vocal este un element deasemenea dificil de realizat, care dă naștere la rândul său la multe probleme. Printre acestea se numără:

- Eșantionarea cu o frecvență mai mică decât cea Nyquist produce efectul de alias;
- Alegerea unui vector de dimensiune prea mare pentru coeficienții Fourier va determina întârzieri mari în program și astfel toată achiziția poate fi compromisă;
- Considerarea unei valori mici (4 biți) pentru reprezentarea amplitudinii va afecta valoarea măsurată a acesteia în cazul depășirii acestui număr.

Dificultățile menționate au fost rezolvate prin studiul atent al surselor bibliografice citate, unde au fost punctate posibile probleme ce pot să apară în astfel de aplicații, întâmpinate de altfel și în cea de față.

După punerea în funcțiune a aplicației și începerea procesului de înregistrare, o importantă problemă a apărut odată cu defectarea microfonului. Date fiind caracteristicile tehnice diferite ale fiecărui microfon în parte ce există pe piață și lipsa unui microfon de rezervă care să aibă aceeași firma producătoare și

configurația celui defectat a fost necesară reluarea procesului de acumulare al lotului de subiecți. Înregistrările realizate până în acel moment nu s-au mai luat în considerare, fiind menținute pentru o posibilă prelucrare în viitor, când se dorește testarea funcționalității modelelor de *Data Mining* și asupra acestora, pentru a observa diferențele ce pot să apară la schimbarea caracteristicilor microfonului, ca sursă de preluare a semnalului vocal.

Pentru realizarea unui studiu de *Data Mining* este nevoie de un lot considerabil de înregistrări astfel încât acuratețea lui să fie cât mai ridicată. Pentru acumularea unui număr de copii cu suferință cerebrală, durata în timp pentru constituirea unei mulțimi utile studiului este de ordinul lunilor, poate chiar al anilor. La momentul redactării prezentei lucrări au fost înregistrați aproximativ 50 de copii din care în jur de 5 au fost suspecți de suferință neurologică. Acest aspect a determinat ramificarea studiului și pe alte arii, cum este aceea de deferențiere în funcție de plâns a fetelor de băieți.

În realizarea unui studiu de *Data Mining* o parte dificilă este organizarea datelor pentru obținerea modelelor corecte. În lucrarea de față s-au prezentat toate datele pe care aplicația le preia și care urmează a fi suportul informațional pentru studiu. Mulțimea gigant de date este constituită din date ale mamei, date de la naștere ale copilului și datele extrase din plâns. Deși studiul vizează detecția din plâns a suferinței neurologice, informația suplimentară furnizată prin datele de la naștere poate aduce completări viitoarelor rezultate și astfel poate fi luată în considerare.

## 5. Studii de *Data Mining* în realizarea de clasificări

Acest capitol este dedicat studiului de *Data Mining* realizat în vederea clasificării plânsului nou-născuților (achiziționat cu aplicația Neonat) grupați în funcție de afecțiunile diagnosticate. Capitolul debutează cu prezentarea domeniului de *Data Mining*, detaliindu-se metodele de analiză specifice, care au fost adaptate cercetării realizate într-un mediu medical. Modele de analiză create sunt explicate și rezultatele semnificative sunt reliefate pentru fiecare studiu realizat. Sinteza rezultatelor obținute este prezentată la finalul capitolului, ca și concluzii parțiale, în contextul întregii cercetări desfășurate.

### 5.1 Data Mining

*Data Mining* sau „minerul în seturi mari de date” reprezintă analiza observațională a mulțimilor foarte mari de date cu scopul identificării de relații/legături și de a rezuma datele în colecții care sunt atât inteligibile cât și de folos deținătorilor datelor [62]. Domeniu recent apărut, *Data Mining* are o istorie relativ scurtă, aproximativ 25 de ani, fiind însă considerat unul din cele mai revoluționare ale ultimului deceniu și între primele 10 tehnologii emergente care ar urma să schimbe lumea, în opinia prestigioasei reviste MIT Technology Review [63].

Utilitatea, sau poate chiar necesitatea procesului de „minerit” în date poate fi evidențiată din perspectiva mai multor domenii unde astfel de tehnici de investigație, fie constituie deja o practică sau ar putea deveni un instrument viabil în cercetări ulterioare:

- În spațiul economic (afaceri-finanțe) – există un imens volum de date deja colectate în diverse segmente: date Web, *e-commerce*, hyper-market-uri, tranzacții financiar bancare, care sunt pregătite pentru a fi analizate în vederea luării de decizii [64], [65];
- Pe domeniul medical – la momentul actual se dispune de numeroase și diverse baze de date din sfera sănătății (medico-farmaceutic) care sunt doar parțial analizate, iar această analiză se efectuează cu precădere prin mijloacele specifice medicinei, existând, de asemenea, și foarte multă informație neexplorată încă [66], [67];
- În context pur științific și de cercetare – s-au colectat până în prezent baze de date gigant din domeniul cercetării științifice din cele mai diverse domenii (astronomie, meteorologie, biologie, lingvistică și altele) care nu pot fi utilizate pentru generarea de cunoaștere, sunt foarte dificil de exploatat cu mijloace tradiționale [68], [69], [70].

În cele ce urmează, se vor face referiri la domeniului medical, asupra căruia se concentrează lucrarea de față, acesta bucurându-se de un interes crescând din partea studiilor de *Data Mining* [71].



## 5.2 Studiul de *Data Mining* în domeniul medical

Medicina modernă generează o cantitate mare de informație stocată în bazele de date medicale. Extragerea de cunoștințe utile luării unor decizii științifice în vederea diagnosticării și tratării unor boli, din cadrul unei baze de date cu informații de la diverse sisteme de investigare (EKG, EEG, EMG) poate deveni extrem de utilă. Alte segmente din lumea medicală cărora „mineritul” le-ar putea crește substanțial productivitatea sunt situate la nivelul de management al tuturor informațiilor ce țin de evidența pacienților dintr-un spital (date personale pacienți, istoricul evoluției stării lor de sănătate, tratamente) și telemedicina.

Datorită redundanței, atributelor multiple, al incompletitudinii sau al relației stânse cu cadrul temporal care caracterizează informațiile din lumea medicală, *Data Mining*-ul medical diferă de cel aplicat pe alte domenii. Metodele și aplicațiile de *Data Mining* medical au (în preponderență) la bază rețelele neuronale, sistemele fuzzy, algoritmi evolutivi (genetici) sau mașini cu suport vectorial [72].

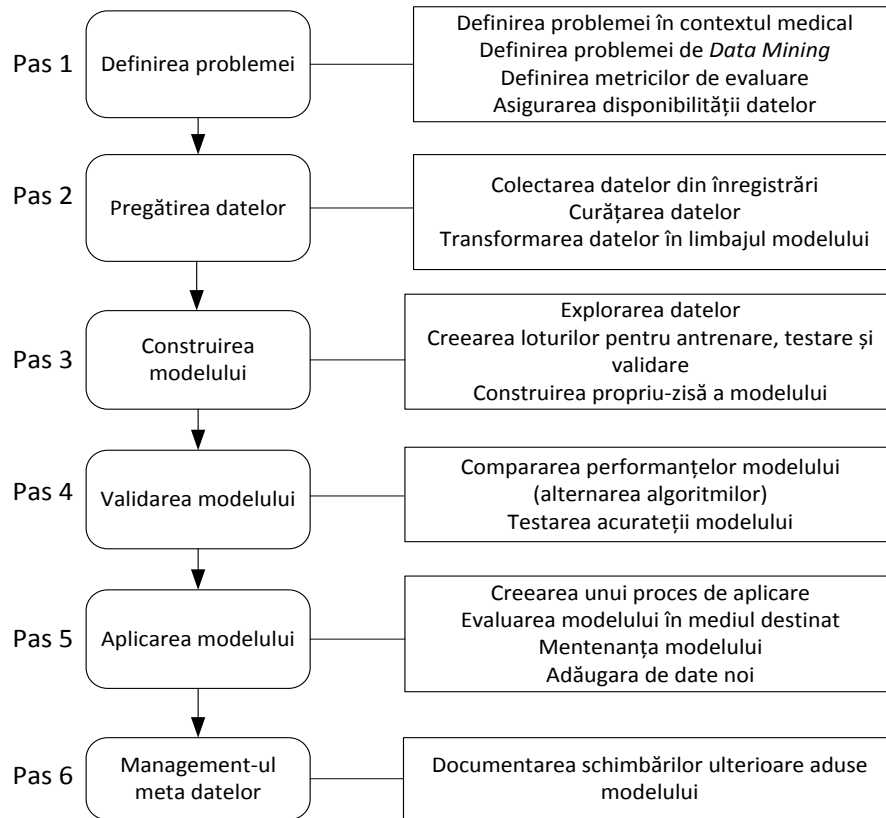
Exemple ale utilizării *Data Mining* în domeniul medical:

- Culegerea și depozitarea datelor în industria farmaceutică;
- Sistem informatic integrat de evaluare complexă a factorilor asociați predicției riscului și calității în obstetrică (Proiect finanțat în cadrul Programului de Cercetare de Excelență) – MaternQual [73];
- Investigații în imagistica creierului uman prin analiza semnalului generat de EEG [74];
- Genetica (exemplu: prezicerea structurilor proteice, determinarea structurii 3D a proteinelor dată fiind secvența lor amino-acidă) [75], [76];

*Data Mining* înglobează un număr mare de tehnici utilizate într-o varietate mare de domenii. Această analiză, cunoscută și ca „descoperirea de cunoștințe în baze de date” (*KDD = knowledge-discovery in databases*), are trei rădăcini generice, de la care a împrumutat atât tehnici de lucru cât și terminologie:

- **Statistica** – reprezintă cea mai longevivă rădăcină a *Data Mining* și fără de care acesta nu ar putea să existe. Elementele clasice ale statisticii aduc în *Data Mining* tehnici de lucru, care se pot rezuma în ceea ce este denumită ca „Analiza exploratorie a datelor” (*EDA = Exploratory Data Analysis*), utilizată pentru a identifica relații între diferitele variabile atunci când nu există informații suficiente asupra naturii acestora;
- **Inteligența artificială** (*AI = Artificial Intelligence*), construită pe heuristici, spre deosebire de partea statistică, contribuie la argumentarea *Data Mining*-ului prin tehnici de procesare a informației bazate pe modelul raționamentului uman. Învățarea automată (*ML = Machine Learning*) reprezintă o arie extrem de importantă a inteligenței artificiale care contribuie la dezvoltarea *Data Mining*, prin utilizarea tehnicilor ce permit construirea unui model prin învățare și antrenament pe baza datelor existente
- **Sisteme de baze de date** (*DBS = database systems*) reprezintă cea de a treia rădăcină a *Data Mining*, procurând și stocând materialul care trebuie „minerit” în vederea prelucrării ulterioare de care sunt responsabile domeniile anterior menționate [68].

Pentru rezolvarea unei probleme de *Data Mining* literatura de specialitate sugerează urmarea unor pași [77], necesari în realizarea unui studiu riguros care să ofere rezultate credibile. Acești pași sunt detaliați în Figura 5.1, iar demersurile specifice fiecărui pas sunt dezvoltate în contextul prezentei teme:



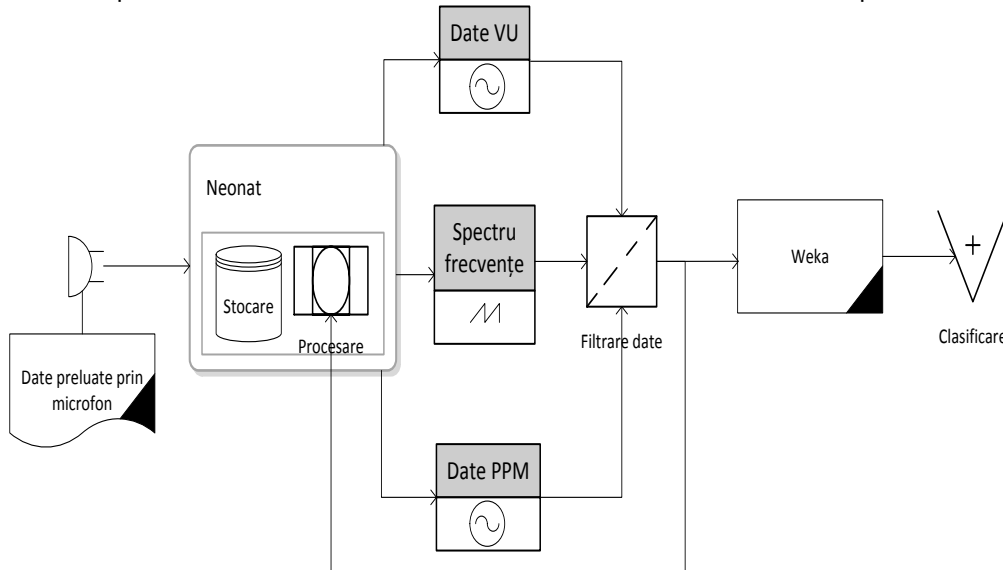
**Figura 5.1 Pașii urmați în rezolvarea unei probleme de *Data Mining***

În situațiile în care se recurge la *Data Mining* pentru rezolvarea unor probleme concrete se are în vedere în principal tipologia acestora, care poate fi încadrată în două categorii principale:

- Probleme de previzune în care se utilizează o parte dintre variabilele existente pentru a prognoza valori ulterioare, necunoscute, ale altor variabile. Pentru astfel de probleme se utilizează metodele clasificării, regresiei sau a detectării deviațiilor;
- Probleme descriptive în care se dorește descoperirea de șabloane în date (*pattern-uri*) care să fie ușor interpretabile de către utilizator. În cazul acestor probleme se folosesc regulile de asociere sau metoda *pattern*-urilor secvențiale.

### 5.3 Studiu de *Data Mining* pentru clasificarea plânsului la nou-născuți

Având la dispoziție o cantitate mare de informație extrasă din semnalul de plâns cu ajutorul aplicației Neonat, s-a realizat un modul pentru prelucrarea acesteia în vederea realizării studiului de *Data Mining* folosind mediul dedicat Weka. În Figura 5.2 este prezentată schema de ansamblu a sistemului de clasificare a plânsului.



**Figura 5.2** Schema generală a sistemului pentru clasificarea plânsului

Schema sistemului surprinde preluarea datelor din plânsul nou-născutului, care sunt stocate și procesate prin aplicația Neonat, urmând a fi apoi generate/organizate în formatul acceptat de mediul WEKA [78], prin fișierele dedicate *.arff* ce cuprind informații asupra intensităților vocale preluate cu cele două instrumente (VU și PPM). Înaintea procesării propriu-zise a datelor ele sunt filtrate. Această filtrare constă în eliminarea datelor care nu corespund cerințelor impuse:

- zgomot ridicat – evaluare subiectivă a înregistrării pentru identificarea de sunete străine, altele decât plânsul nou născutului evaluat;
- dimensiune insuficientă – s-a considerat lungimea de 30 de secunde a unui plâns ca fiind cea acceptată pentru studiu. Înregistrările sub această durată au fost eliminate din studiu, iar cele cu dimensiune mai mare au fost trunchiate urmărind însă surprinderea plânsului pe primul expir în zona selectată pentru analiza ulterioară;
- date eronate la achiziție – corespund la înregistrări în timpul cărora au fost generate excepții software, opriri neprogramate ale aplicației Neonat, deconectarea microfonului sau nerespectări ale protocolului de înregistrare - care vor fi prezentate ulterior.

Datele rezultate în urma filtrării sunt preluate în mediul dedicat Weka unde se realizează modelul și clasificarea plânsului de la intrarea în sistem.

În paragrafele următoare se vor detalia pașii urmați în studiul de *Data Mining* pentru clasificarea plânsului nou-născuților cu detalierea acțiunilor întreprinse în fiecare etapă și rezultatele aferente.

### 5.3.1 Definirea problemei de studiat în accepțiunea *Data Mining*

Plânsul nou-născutului este singura formă de comunicare a acestuia cu mediul înconjurător, prin care sunt manifestate trăiri, emoții sau suferință. Plânsul reprezintă astfel un indicator esențial care poate fi coroborat eventual și cu parametri fiziologici în stabilirea stării de sănătate postnatale. Plânsul ca și semnal generează o cantitate semnificativă de date care poate fi procesată în vederea extragerii de informație cu potențială utilitate în luarea deciziilor medicale. Astfel, în această primă etapă a studiului de *Data Mining* se formulează obiectivul studierii plânsului la nou-născuți din perspectiva medicală. Aceasta presupune ca, fie prin metode predictive să se realizeze clasificarea unui plâns ca fiind patologic sau sănătos prin metode descriptive, determinarea unor șabloane care să permită categorisirea unui plâns într-una din clasele mai sus menționate (patologic sau sănătos).

Din enunțul problemei medicale se poate defini și problema din perspectiva *Data Mining*, anume o situație care impune realizarea prin metode predictive clasificarea semnalului din plâns. Clasificarea este procesul cognitiv fundamental care presupune organizarea informației pe clase sau categorii bine definite [79]. În procesul de clasificare se caută asignarea unor instanțe, aparținând unui domeniu și care sunt definite de un set de valori continue sau discrete denumite atribute, la o clasă care face parte dintr-o mulțime de clase (ca definiție a codomeniului). Această definiție poate fi formalizată ca:

$c : D_i \rightarrow C$ , unde  $c$  este funcția de clasificare,  $D_i$  reprezintă domeniul instanțelor, iar  $C$  este o mulțime finită a claselor (categoriilor) în care pot fi încadrate instanțele studiate prin aplicarea funcției de clasificare asupra instanțelor din domeniul acestora.

Funcția de clasificare este necunoscută cu excepția unei mulțimi de valori  $\subset D_i$ , pentru care se cunoaște apartenența instanțelor la una din mulțimile din codomeniul  $C$ . Această mulțime pentru care se cunoaște funcția de clasificare reprezintă mulțimea de antrenament ( $A, A \subseteq D$ ), fără de care studiul de *Data Mining* nu ar fi posibil.

Un model de clasificare  $M : D_i \rightarrow C$ , produce predicții de apartenență la o clasă (categorie) din codomeniu pentru fiecare instanță  $I \in D_i$ , fiind o aproximare bună a funcției de clasificare  $c$  pe întreg domeniul. Modelele de clasificare sunt denumite în formă simplă, clasificatori, confundându-se deseori cu algoritmi de clasificare care sunt definiți și ei de multe ori în același fel [79].

În evaluarea clasificatorilor se pot utiliza diferite metrici în vederea stabilirii unei bune aproximări asupra clasei de apartenență pe care o efectuează modelul de clasificare. Forma cea mai simplă și cea care poate fi primul criteriu de acceptare al modelului clasificatorului este reprezentată de rata de clasificare corectă. Prin aceasta se oferă un raport al instanțelor clasificate corect din totalul instanțelor clasificate. Totuși, în multe situații acest lucru nu este suficient pentru demonstrarea funcționalității clasificatorului pentru date și studii viitoare, astfel că se face uz și de alți indicatori. În testarea unui clasificator, în general se au în vedere o serie de criterii pentru stabilirea clasificatorului care poate face o precizie cât mai corectă a categoriei în care poate fi considerat subiectul pentru care se dorește detecția

apartenenței la un anumit grup. Între aceste criterii se numără: acuratețea prognozei, viteza, simplitatea și nu în ultimul rând robustețea (predicție de acuratețe bună și în prezența zgomotului în datele procesate). În practică, pentru sistemele predictive ce au la bază rețele neurale sau alte tipuri de inteligență artificială se consideră că doar cele care oferă o predicție bună în peste 85% din cazurile testate pot fi considerate valide.

Printre cei mai importanți indicatori pentru estimarea eficienței clasificatorilor și care sunt utilizați și în studiul de față se numără:

- Numărul de instanțe clasificate corect raportate la numărul total al instanțelor din studiu;
- Numărul de instanțe clasificate incorect raportate și ele la numărul total al instanțelor din studiu;
- Eroarea pătratică medie  $\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}$
- Eroare pătratică relativă  $\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}$
- Eroarea medie absolută  $\frac{|p_1 - a_1| + \dots + |p_n - a_n|}{n}$
- Eroare relativă absolută  $\frac{|p_1 - a_1| + \dots + |p_n - a_n|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|}$ 
  - unde:
    - $p_1, p_2, \dots, p_n$  reprezintă valorile de prognoză
    - $a_1, a_2, \dots, a_n$  reprezintă valorile adevărate
    - $\bar{a}$  reprezintă valoarea absolută a tuturor valorilor adevărate.

### 5.3.2 Achiziția și preprocesarea datelor

Achiziția datelor pentru studiu în forma lor neprelucrată s-a efectuat cu ajutorul aplicației dedicate Neonat. Înregistrările propriu-zise, s-au colectat de la nou-născuții din cadrul spitalului Județean de Urgență Timișoara în cadrul Clinicii de Obstetrică-Ginecologie BEGA. În acest mod este îndeplinită o condiție esențială în desfășurarea studiilor de *Data Mining*, anume asigurarea disponibilității datelor (a materialului de lucru). Colectarea datelor s-a realizat urmând protocolul rezultat în urma efectuării mai multor încercări și care a fost prezentat în detaliu în subcapitolul 4.5. În vederea utilizării datelor furnizate de aplicația Neonat în studiul de *Data Mining*, au fost necesare și s-au realizat o serie de operațiuni de filtrare și post-procesare a înregistrărilor cu scopul obținerii de instanțe cu același număr de atribute și neafectate de zgomot. Aceste operațiuni și considerentele ce stau la baza post-procesării servesc ca și completare la protocolul de achiziție al datelor și sunt descrise în paragraful de urmează.

### 5.3.3 Protocolul de selecție și post-procesare a datelor pentru *Data Mining*

În vederea realizării unui studiu util de *Data Mining* pentru problema detecției automate a diferențelor dintre diferitele grupuri de semnale din plâns luate în considerare în vederea clasificării s-au definit următoarele reguli:

- Studiul se bazează pe valorile numerice extrase din plâns cu aplicația Neonat prin instrumentele VU Meter, PP Meter și spectrul de frecvențe ale plânsului;
- La realizarea modelelor de clasificare se iau în considerare toate instanțele de plâns acceptate, fiind grupate în funcție de instrumentul de măsură menționat mai sus;
- Datele afectate de zgomot sesizabil sunt eliminate din studiu;
- Fiecare înregistrare din plâns trebuie să fie de durată a exact 30 de secunde. Înregistrările care sunt mai scurte ca durată nu sunt luate în considerare pentru studiu, iar cele cu durată mai mare vor fi trunchiate astfel încât să ajungă la durată a 30 de secunde. Trunchierea se realizează într-o aplicație externă și trebuie să conțină la începutul ei prima fonație dintr-o repriză de plâns. După realizarea editării înregistrărilor într-o aplicație externă, se va reprocesa secvența de plâns în cadrul aplicației Neonat, în vederea re-generării fișierelor de valori în limbajul Weka (fișierele *.arff*). Reprocesarea unei secvențe de plâns se realizează prin încărcarea în regim de analiză a înregistrării în Neonat;
- În modelele de clasificare cu date provenite de la VU Meter și PP Meter, în secțiunea de date, o linie din fișierul *.arff* va fi reprezentat de o instanță. Fișierul va fi astfel populat ca pe fiecare linie să existe câte o instanță reprezentând 300 de valori ale intensității vocale extrase din înregistrare și o ultimă valoare aferentă clasei de apartenență (categoria, lotul);
- Se creează categoriile (loturile) cu înregistrările de plâns pe categorii conform datelor din fișierele de pacient. Se admite existența unei înregistrări în mai multe categorii cu condiția ca la realizarea unui studiu, intersecția mulțimilor studiate să fie mulțimea vidă.

Structura generală a unui fișier *.arff* generat pentru studiu este următoarea:

```
@RELATION nume_relație
@ATTRIBUTE atribut1 NUMERIC
@ATTRIBUTE atribut2 DATE
@ATTRIBUTE atribut3 STRING
...
@ATTRIBUTE atributZ DECLARAȚIE_NOMINALĂ

@ATTRIBUTE class {tip1, tip2, ..., tipT}

@DATA
valoare_numerică1, valoare_numerică2, valoare_numerică3, ...,
valoare_numericăN tip1
valoare_numerică4, valoare_numerică5, valoare_numerică6, ...,
valoare_numericăM tip2
```

valoare\_numerică7, valoare\_numerică8, valoare\_numerică9, ...,  
 valoare\_numericăO tipT  
 valoare\_numerică10, valoare\_numerică11, valoare\_numerică12,  
 ..., valoare\_numericăP tip1  
 valoare\_numerică13, valoare\_numerică14, valoare\_numerică15,  
 ..., valoare\_numericăQ tip2

unde:

- zona de declarații în care se regăsește sintaxa @ATTRIBUTE corespunde definiției pe câte o linie a unui atribut al cărui tip poate fi unul dintre: real, numeric, întreg, valoare nominală, dată sau text;
- zona de date este cea în care sunt populate valori pentru attributele definite în zona declarativă.

### 5.3.4 Construirea modelului

Considerând schema pentru realizarea studiului din Figura 5.2, odată ce datele filtrate sunt disponibile acestea se prezintă ca intrări pentru modulul Weka din schema afișată în Figura 5.3. În această zonă (modulul Weka) se realizează construcția modelului. Aceasta începe prin explorarea datelor, care pot fi vizualizate prin mediul Weka odată cu încărcarea fișierelor *.arff*. În Figura 5.3 poate fi vizualizat un exemplu de valori statistice ale datelor încărcate, constând în minime, maxime sau medii ale valorilor atributelor numerice, distribuția acestora în intervalul dat de cea mai mică și cea mai mare valoare încărcată, deviația standard a valorilor de la medie precum și informații de date lipsă sau unicitatea valorilor atributelor. Aceste date statistice sunt utile în explorarea datelor încărcate, putându-se sesiza eventuale erori sau neconcordanțe cu ipoteze considerate.

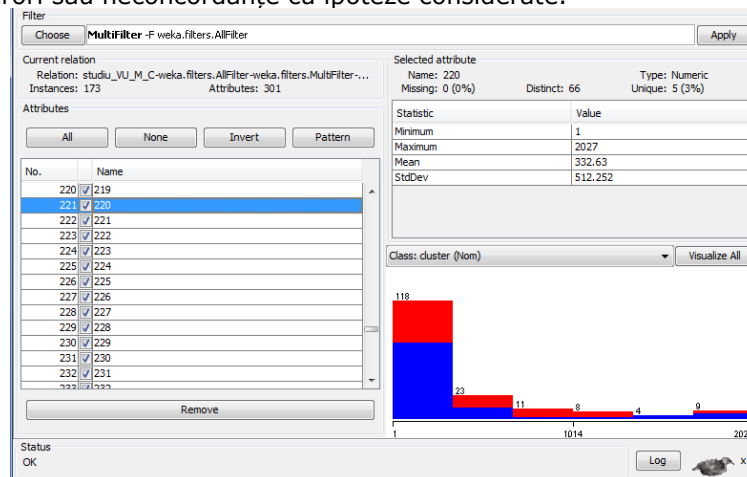


Figura 5.3 Încărcarea datelor în WEKA


În această secțiune de încărcare a datelor se poate realiza o filtrare suplimentară a datelor utilizând filtrele puse la dispoziție de mediul Weka. În funcție de filtru, acestea se aplică fie în vederea reducerii instanțelor, fie a atributelor sau se pot adresa exclusiv asupra claselor.

Pentru a avea un răspuns la problema apartenenței la un anumit grup s-a optat pentru utilizarea metodei clasificării deoarece dezideratul a fost ca elementele individuale să fie plasate în grupuri distincte ce au la bază informație similară cu mai multe din elementele constitutive ale grupului de apartenență.

Clasificatorii, ca modele care stau la baza metodei clasificării, sunt responsabili de realizarea mapării între clasă și atributele comune ale elementelor. Pentru studiul de față, numele grupului se consideră clasa în care va fi încadrată instanța cu semnalul provenit de la nou-născut, funcție de predictorii care sunt reprezentați de valorile atributelor fiecărei instanțe. De aici se poate observa existența unei inteligențe artificiale care poate să ia o anumită decizie în funcție de modelul clasificator obținut din mulțimea de antrenament și cea de test. Mulțimea de antrenament este reprezentată de instanțele regăsite în fișierul *.arff* menționat, în timp ce mulțimea de test este constituită dintr-un alt fișier *.arff* cu aceeași structură ca și cel utilizat pentru antrenament dar cu instanțe diferite. Mediul Weka oferă un număr foarte mare de clasificatori ce pot fi utilizați în vederea alegerii unuia care oferă rezultate acceptabile în studiul întreprins.

Mulțimea de antrenament pentru studiul apartenenței la un anumit grup trebuie să fie una echilibrată în ceea ce înseamnă raportul de instanțe din fiecare grup considerat. Având un lot total de studiu de 297 de subiecți, s-au construit 4 mulțimi de instanțe pentru fiecare din mulțimile: lotul martor, lotul de prematuri, mulțimea nou-născuților cu circulara (strangulare) de cordon ombilical la naștere și mulțimea nou-născuților cu patologii severe, neîncadrați în grupurile menționate anterior.

Încărcarea datelor în modelul clasificator și rezultatul acestuia poate fi ușor explicată grafic prin Figura 5.4:



**Figura 5.4 Funcționarea clasificării în studiul de față**

### 5.3.5 Validarea modelului

În cadrul studiului de față, s-au utilizat clasificatori aparținând unei arii diversificate de modele (rețele neurale, clasificatori bayesieni, clasificatori bazați pe reguli, arbori de clasificare și alții) ale căror performanțe au fost evaluate prin trei tehnici: validare-încrucișată, împărțirea, utilizând mulțimea de antrenament și cu ajutorul unei mulțimi de test.

Validarea-încrucișată (*Cross-validation*) reprezintă o tehnică statistică ce estimează performanța unei scheme de învățare pe date noi. În cazul în care nu se beneficiază de mulțimi suficient de consistente, se pot pune deoparte seturi din această mulțime pentru care să se realizeze învățarea, iar restul să se considere ca date de test. Validarea-încrucișată exploatează la maxim datele ce se dețin, prin



divizarea acestora în  $n$  calupuri (*folds*) utilizând fiecare calup pentru evaluarea modelului obținut din cele  $(n-1)$  calupuri rămase. Performanța modelului pentru cele  $n$  calupuri este aproximată pentru a da o notă estimativă asupra eficienței schemei pentru date viitoare.

Studiul performanței unui model prin evaluarea mulțimii de antrenament este și el util în estimarea performanței acestuia, însă oferă totuși o notă foarte optimistă asupra posibilității de aplicabilitate a modelului pe date ulterioare. Acest lucru se datorează faptului că mulțimea de antrenament constituie și sursa de date pentru „învățare” a modelului rezultat. Utilitatea se poate totuși dovedi prin compararea performanței obținute cu cea de la validarea-încrucișată sau pentru o mulțime anume de test, când se poate vedea dacă estimarea eficienței prin utilizarea mulțimii de antrenament a fost mult prea optimistă.

Împărțirea (*Percentage split*), ca metodă de validare a performanței, reprezintă un raport de divizare a mulțimii de intrare în mulțime de antrenament și mulțime de test. Astfel, pentru un *factor* de 95, se consideră ca mulțime de antrenament pentru învățarea modelului, valoarea în procente a *factorului* din totalul instanțelor considerate, și restul de 5% ( $100\% - \text{factor}$ ) vor servi ca date de test.

Cea din urmă tehnică de validare, prin furnizarea unei mulțimi de testare explicite pentru model, este cel mai bine conturată în schema de mai sus. Având mulțimea de antrenament încărcată, s-a utilizat un fișier *.arff* diferit de primul, în care au fost introduse instanțe din fiecare clasă posibilă.

În subcapitolele ce urmează, vor fi detaliate modele care au generat rezultatele cele mai bune pentru diversele clasificări încercate. Evaluarea calitativă a rezultatelor se face prin urmărirea indicatorilor de eroare, menționați deja, precum și reprezentări vizuale prin curbe ROC, matricea de confuzie sau alți coeficienți statistici cum ar fi raportul Fischer (*F-ratio*).

Din perspectiva prezentării rezultatelor clasificării, în cadrul studiului a fost utilizată matricea de confuzie. Forma ei generală se regăsește în Figura 5.5, și curprinde rezultate ale clasificării pentru două clase (A și B), respectiv numărul instanțelor care au fost încadrate corect în clasa A (Adevărat pozitiv), cele încadrate corect în clasa B (Adevărat negativ), cele încadrate în clasa A deși fac parte din clasa B (Fals pozitiv) și cele încadrate în clasa B deși fac parte din clasa A (Fals negativ):

		Valoarea actuală Clasa A	Valoarea actuală Clasa B
Valoarea prezisă	Clasa A	Adevarat pozitiv	Fals pozitiv
Valoarea prezisă	Clasa B	Fals negativ	Adevarat negativ

**Figura 5.5** Forma matricei de confuzie

Pentru o mulțime de antrenament descrisă formal cu un număr  $N$  de instanțe, din care  $X$  aparțin unei anumite clase și  $Y$  celei de-a doua, validarea

modelului cu o acuratețe de 100% presupune o matrice de confuzie de forma dată de relația:

$$C = \begin{bmatrix} X & 0 \\ 0 & Y \end{bmatrix}$$

### 5.3.6 Aplicarea modelului de Data Mining

În contextul studiului de față, analiza de data mining a constat în realizarea unei clasificări pentru mulțimi de valori rezultate din plânsul nou-născuților definite în felul următor:

- S-au considerat cele 4 grupuri ca fiind: mulțimea lotului martor, mulțimea lotului de prematuri, mulțimea nou-născuților cu circulară de cordon ombilical la naștere și mulțimea nou-născuților cu patologii severe, neîncadrați în grupurile menționate anterior;
- Pentru fiecare din acest grup au fost create fișiere *.arff* în forma prezentată la începutul secțiunii (30 de secunde din fiecare plâns reprezentate în cadrul a două fișiere: unul corespunzător VUMeter, iar celălalt aferent PPMeter).
- S-a executat câte 2 studii de clasificare între mulțimea de antrenament și fiecare din celelalte grupuri pentru VUMeter și PPMeter:
  - VU Meter: M-P, M-CO; M-PS;
  - PPM Meter: M-P, M-CO; M-PS.
- Pentru fiecare studiu de data mining s-au utilizat algoritmi din mai multe familii diferite de modele de clasificare: arbori de decizie, reguli de decizie, algoritmi "leneși" (lazy), meta clasificatori, rețele neuronale.
- În funcție de modelul de clasificare algoritmi utilizați cu rezultatele aferente se încadrează astfel:
  - Arbori de decizie: Random Tree, Random Forest;
  - Modele bazate pe reguli : IB1, LWL;
  - Modele bazate pe algoritmi "leneși": Decision Table, Conjunctive Rule, OneR, NNge.
- Rezultatele cele mai bune au fost detaliate prin scheme de construcție și metrici de validare; pentru alte metode generatoare de rezultate considerate acceptabile sunt prezentate doar rezultatele într-o formă tabelară. Metodele și algorimii care nu au dat rezultate satisfăcătoare nu sunt menționate/menționați.

## 5.4 Algoritmii utilizați în construirea modelelor de clasificare

### 5.4.1 Arbori de decizie

Un arbore de decizie (arbore de clasificare) este o structură complexă folosită pentru a divide o colecție mare de instanțe în seturi mai mici, aplicând o secvență de reguli simple de decizie. O dată arborele construit, el este aplicat

fiecărui articol al bazei de date și rezultatelor clasificării acelui articol. Tehnica are doi pași de bază: construirea arborelui și aplicarea arborelui la baza de date.

Metoda alege în primul rând un subset din exemple antrenate pentru a forma un arbore de decizie. Dacă arborele creat nu oferă răspunsul corect pentru toate obiectele, se adaugă o selecție a excepțiilor la arbore și procesul continuă până când setul corect de decizie este găsit. Arborii de decizie execută mai multe teste, și apoi încearcă să ajungă la cea mai bună secvență pentru precizarea scopului. Fiecare test creează ramuri care conduc la mai multe testări, până când testarea se termină într-un nod frunză. Arborii de decizie pot fi construiți fie de sus în jos fie de la stânga la dreapta. Nodul de sus (marginea stângă) este nodul rădăcină. Nodurile descendente sunt noduri fii, iar nodurile de jos (marginea dreaptă) sunt noduri frunză. Calea unică de la nodul rădăcină la un nod frunză formează o regulă.

Calea de la nodul rădăcină la nodul frunză țintă este regula care clasifică scopul. Regulile sunt exprimate sub formă de expresii „dacă... atunci...”.

Un arbore de decizie este o structură în care:

- Nodurile interne indică un test pe un atribut;
- Ramurile reprezintă rezultatul unui test;
- Nodurile frunză reprezintă etichete ale claselor.

Algoritmul **RandomTree** consideră un set de  $N$  atribute ale fiecărei instanțe, alese aleator, pe care le împarte una câte una pe câte un nod al arborescenței.

Analiza prin **Random Forest** este o metodă alternativă la Random Tree, care produce o singură măsură a fiecărui atribut utilizat în prezicere. În practică, prin acest algoritm se generează o serie de arbori de decizie ca în cazul Random Tree, doar că în final decizia cu privire la clasificare se face pe baza numărului celui mai mare de arbori generați în favoarea unei anumite decizii.

În Figura 5.6 este prezentat modelul grafic al unui arbore de decizie, generat în studiul curent. Arborele are ca noduri atribute ale datelor de intrare în forma *atribut:valoare* iar ramurile surprind decizia ce stă la baza construcției acestuia sub forma de egalități și inegalități, de forma *valoare1 < valoare2* (de exemplu, pentru rădăcina arborelui 1:78 – 1 reprezintă ordinul atributului, iar 78 valoarea acestuia).

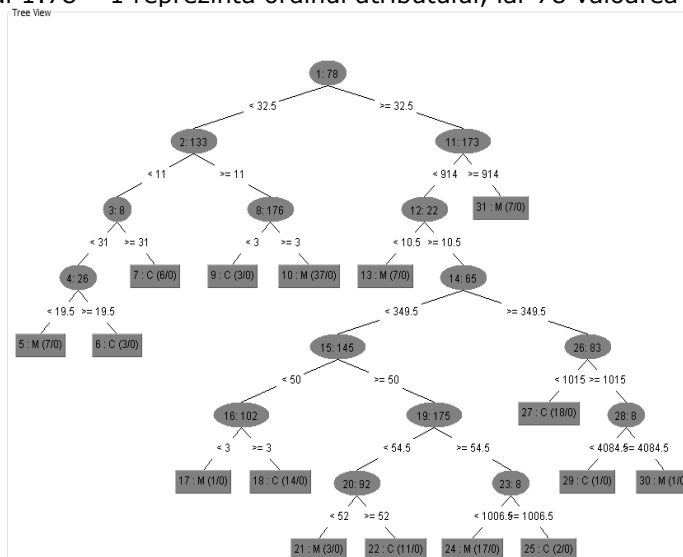


Figura 5.6 Arbore de decizie generat cu Random Tree

### 5.4.2 Algoritmii „leneși” (lazy)

Modelul clasificator al algoritmilor lazy a fost utilizat în toate studiile realizate, pentru augumentarea rezultatelor provenite de la arborii de decizie. Acest lucru a fost realizat din necesitatea de validare a rezultatelor precedente, mai precis clasificarea corectă prin utilizarea unui algoritm total diferit, care oferă în final același tip de serviciu, mai exact precizarea grupului de apartenență.

Algoritmii lazy nu construiesc schema de învățare prin înregistrarea pe rând a fiecărei instanțe. Aceștia parcurg toată mulțimea de antrenament, atunci când o valoare trebuie testată.

Clasificatorul **IB1** din familia clasificatorilor lazy, folosește distanța ca măsură de determinare a apropierii instanței de test față de o instanță din mulțimea de antrenament. În forma de bază, se utilizează distanța euclidiană. Aceasta este reprezentată de un număr de caracteristici care apropie o anumită instanță testată față de celelalte din mulțimea de antrenament. La finalul algoritmului, în cazul în care instanța testată se află la aceeași distanță minimă în raport cu alte instanțe, modelul clasificator consideră că instanța testată aparține grupului în care se găsește prima instanță de antrenament găsită la distanța minimă.

**LWL** (Locally-Weighted Learning) reprezintă un alt algoritm din familia lazy utilizat în studiu. Acesta atribuie ponderi în relațiile dintre diferitele instanțe, iar clasificarea o realizează prin NaiveBayes, iar pentru studiile de regresie este utilizată regresia liniară. În forma de bază attributele considerate de algoritm sunt normalizate.

### 5.4.3 Reguli de clasificare

Algoritmii care fac parte din regulile de clasificare sunt funcții euristice care reprezintă o alternativă bună la arborii de decizie, în momentul în care se caută o altă variantă pentru validarea unor rezultate obținute prin arborii de clasificare. O regulă de clasificare este în esență, o metodă prin care membrii mulțimii de test pot fi asociați unei anumite clase, în urma dobândirii experienței din cadrul mulțimii de antrenament. Din rândul regulilor de decizie vor fi prezentate în continuare: tabelele de decizie, regulile conjunctive și algoritmi OneR și NNGe.

- **Tabele de decizie (*Decision Table*)**

Tabelele de decizie (*Decision Table*) oferă o alternativă în abordarea clasică a clasificatorilor bazați pe reguli. Acestea poate fi văzută într-o formă tabelară pentru descrierea și analiza situațiilor decizionale, unde starea unor condiții puse laolaltă determină execuția unui set de acțiuni în vederea determinării rezultatului. Tabela de decizie poate fi vizualizată sub forma a patru cadrane separate printr-o linie verticală și una orizontală. Linia orizontală separă partea superioară care este reprezentată de o condiție, în timp ce partea inferioară este reprezentată de o acțiune. Linia verticală separă în plan superior subiecții de cercetat, de intrările care se regăsesc în partea inferioară. Subiecții împreună cu condiția servesc acțiunii de decizie cu privire la intrarea cercetată.

**Tabel 5.1 Forma generală a unui tabel de decizie**

CONDIȚIE	SUBIECT STUDIAT
ACȚIUNE	DATĂ INTRARE

- **Reguli conjunctive (*Conjunctive Rule*)**

O regulă conjunctivă constă într-o serie de instanțe puse una după cealaltă în „ȘI”-uri logice, și în final valoarea clasei de apartenență. Dacă instanța de testat nu poate fi clasificată prin această regulă, atunci se clasifică prin utilizarea unei valori de clasă a datelor care nu acoperă cerințele regulii conjunctive.

Instanțele puse una după cealaltă sunt selectate prin calcularea unui indicator aferent câștigului în cunoaștere al tuturor instanțelor premergătoare. Se poate astfel imagina o serie de instanțe cu atribute comune, puse laolaltă, care servesc drept regulă pentru stabilirea clasei de apartenență a instanței de studiat.

- **Algoritmul OneR**

Algoritmul OneR caută cea mai semnificativă informație din cadrul mulțimii de antrenament, astfel încât, pe baza acesteia să poată lua decizia de clasificare. În contextul studiului de față acest algoritm oferă informația relativă la un anumit atribut, care este o valoare a intensității vocale pe care o consideră relevantă în vederea asocierii instanței studiate la o anumită clasă.

- **Algoritmul NNge**

Algoritmul NNge are la bază studierea proprietăților vecinilor entității de testat. Mai precis, prin vecin, este descrisă o instanță din mulțimea de antrenament care se apropie prin valori ale atributelor, de instanța de clasificat. Clasificarea se face în cadrul clasei celui mai apropiat vecin, adică cel care are atributele cele mai apropiate ca valoare de instanța studiată.

## 5.5 Lotul martor (clasa M)

În realizarea studiului de *Data Mining* este necesară în primă fază construirea unui lot de bază (denumit lot martor în limbajul medical) care să servească drept etalon în comparație cu celelalte clase din studiu. Acesta lot de referință este notat ca și clasa M la momentul încărcării datelor în mediul Weka. Numărul total de instanțe din acest lot este de 101 de secvențe de plâns.

Nou-născuții incluși în lotul martor sunt considerați a fi sănătoși și reprezintă un etalon prin caracteristicile de plâns sesizate în urma analizei. Desigur că fiecare individ prezintă particularități care îl deosebesc de oricare altul, însă în analiza efectuată s-au urmărit parametri fiziologici prezenți în observațiile medicale și într-un mod subiectiv și plânsul spontan al acestora. Din punctul de vedere al plânsului s-au făcut aprecieri cu privire la calitatea acestuia la momentul includerii în studiu. Astfel s-a considerat necesară:

- existența mai multor cuvinte de plâns;
- prezența mai multor pauze de diferite durate între fonații;

- intensitate energetică mai consistentă pe intervalul de frecvențe [400Hz-700Hz] sau cel puțin prezența acestor frecvențe în spectrul în timp real generat de aplicația Neonat;
- existența variației în graficele intensităților vocale sub forma de undă a semnalului vocal;

Elemente mai sus menționate, care pot fi considerate ca așa-zise tipare pentru plânsul nou-născuților din lotul martor, se regăsesc în captura de ecran a aplicației Neonat (Figura 5.7). Ca privire de ansamblu se pot vizualiza mai multe vârfuri de intensitate (amplitudine) vocală (medie și maximă) unde se regăsesc vocalizările aferente fiecărei fonații. Se pot observa și valorile mici de intensitate corespunzătoare părților nevocale ale semnalului studiat. Exemplul ilustrat este de durată mai mare decât varianta finală utilizată în studiu, rațiunea prezentării fiind aceea de a surprinde toate aspectele în vederea evidențierii a caracteristicilor mai sus menționate. Pe lângă aceste valori de intensitate, sunt prezente și informațiile asupra frecvenței calupurilor de plâns, ajustabile prin alegerea ordinului transformatei Fourier Rapide. Întreg spectrul plânsului este disponibil și el, oferind și o mai bună vizualizare a zonelor vocale și nevocale, precum și valoarea energetică pe diferitele frecvențe.

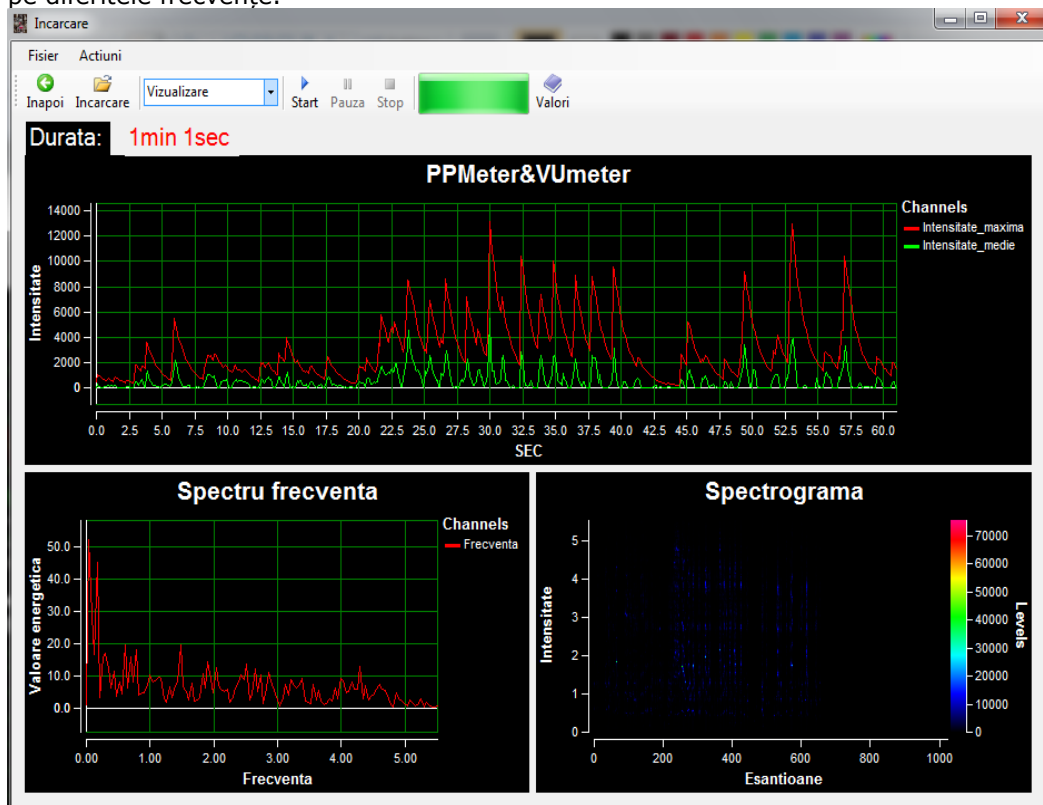


Figura 5.7 Exemplu de semnal vocal din lotul martor

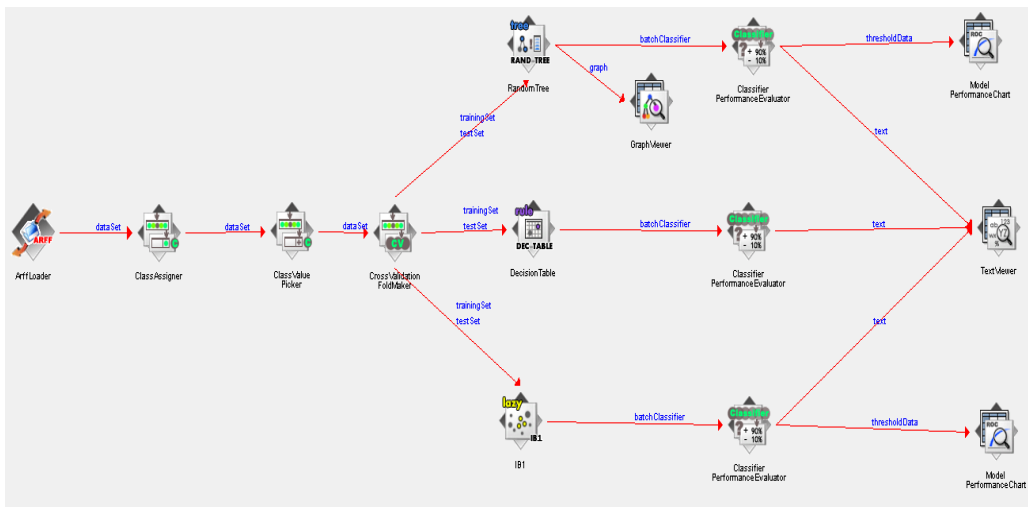
## 5.6 Lotul de nou-născuți cu circulară de cordon ombilical (clasa CO)

Lotul format din nou-născuți cu circulară de cordon ombilical (CO), constă în semnale de plâns provenite de la nou-născuți care au suferit de înfășurarea cordonului ombilical în jurul gâtului la naștere. Aceasta determină insuficiență respiratorie care poate conduce la leziuni cerebrale datorită lipsei oxigenării. Lotul considerat este compus din 72 de instanțe cu următoarele caracteristici:

- nou-născuți cu vârstă gestațională mai mare sau egală cu 38 de săptămâni;
- nou-născuți afectați la naștere de circulară de CO;
- indicele Apgar mai mare de 7;
- greutate mai mare de 2500g.

În schema din Figura 5.8 este prezentată o sinteză a construcției modelelor de clasificare pentru cei trei algoritmi care au oferit rezultatele cele mai bune. Schema cuprinde următoarele elemente:

- Obiectul *ArffLoader* ce realizează încărcarea datelor în model;
- Componenta *ClassAssigner* unde se realizează alegerea obiectivului clasificării prin furnizarea pentru fiecare instanță a clasei după care se va realiza clasificarea;
- *ClassValuePicker* este zona unde sunt atribuite valorile posibile pentru clasele alese în pasul anterior (clasa lotului martor și clasa CO pentru această situație);
- Obiectul *CrossValidationFoldMaker* efectuează împărțirea datelor în date pentru învățare, date de antrenament și mulțime de test;
- Algoritmii rezultați ca fiind cei mai performanți apar în schemă în componentele *RandomTree*, *DecisionTable* respectiv *IB1*;
- În vederea prezentării performanțelor modelelor de clasificare și vizualizarea acestora, în schemă se regăsesc:
  - obiectul *GraphViewer* pentru vizualizarea grafică a clasificatorului acolo unde este cazul (s-a utilizat de exemplu pentru arborele de decizie);
  - Obiectul *ClassifierPerformanceEvaluator* care generează metrici pentru stabilirea performanței algoritmului de clasificare;
  - Obiectul *ModelPerformanceChart* face posibilă afișarea metricilor pentru validare într-o formă grafică, mult mai intuitivă;
  - *TextViewer* este componenta care prezintă întreaga informație asupra modelului (date încărcate, rezultatele generate și metricile) sub formă de text în vederea utilizării ei pentru generarea altor tipuri de rapoarte.



**Figura 5.8** Schema modelelor de clasificare cu cele mai bune performanțe cu VU Meter

Schema din Figura 5.8 este valabilă atât pentru studiul realizat cu VU Meter cât și pentru cel cu PP Meter pentru clasificarea acestor două clase. Diferența între ele, din punctul de vedere al schemei, este dată de algoritmi selectați și conținutul datelor încărcate.

### 5.6.1 Rezultatele cu VU Meter

În Figura 5.9 și Figura 5.10 sunt prezentați arborii de decizie care au generat cel mai bun rezultat pentru mulțimea de antrenament și cea de test, folosind-se algoritmul *Random Tree*. Arborele de decizie realizează clasificarea pe baza porțiunilor de început ale înregistrărilor unde sunt semnalate corelații în valorile intensităților măsurate. Începuturile înregistrărilor surprind primele fonații, aspect asigurat prin operațiunea de trunchiere realizată într-o etapă incipientă a studiului, când s-a realizat alinierea semnalelor vocale astfel încât momentele inițiale ale înregistrărilor să surprindă primele vocalizări.



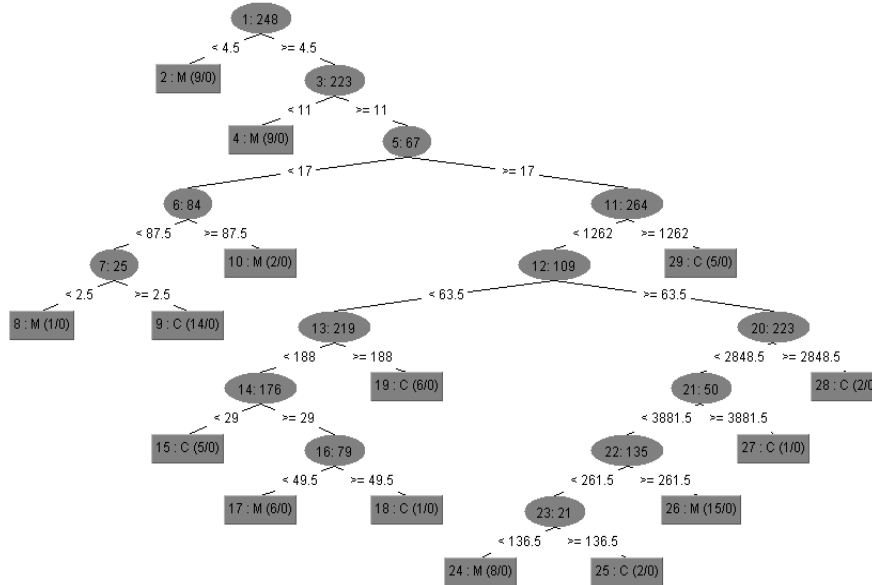


Figura 5.9 VU: M – C – Arborele de decizie (pe mulțimea de antrenare)

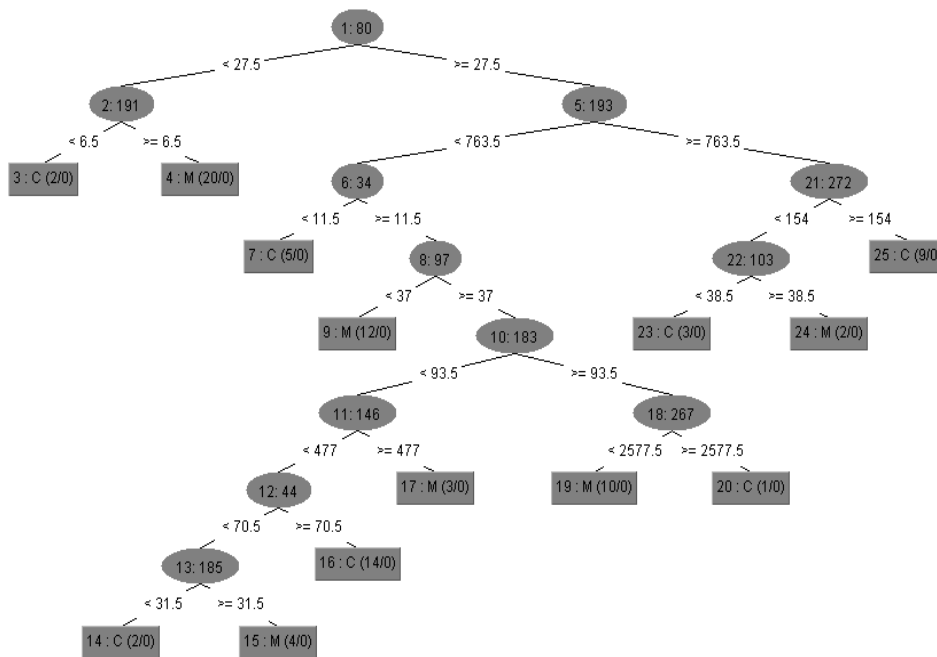



Figura 5.10 M – C – Arborele de decizie (pe mulțimea de test)

Una din metricile utilizate pentru validarea acestor rezultate și prezentată în Figura 5.11 este curba ROC care oferă evaluarea clasificatorului ca raport între instanțele clasificate incorect pe de o parte (axa X) și cele clasificate corect de pe alta (axa Y). La interpretarea curbelor ROC se urmărește obținerea unei suprafețe cât mai mari sub curbă, pentru rezultate ce pot fi acceptabile. În caz ideal, o predicție de acuratețe maximă ar consta într-o curbă paralelă cu axa X, adică absența instanțelor clasificate incorect.



**Figura 5.11 VU: M – C – Curba ROC (clasele M și CO)**

În valori numerice, arborele de decizie generat pentru datele de test, generează metricile prezentate în Figura 5.12, matricea de confuzie indicând numărul instanțelor clasificate corect ca fiind 170, restul de 3 din totalul instanțelor studiate fiind fals pozitive, adică un procent de 1,73% instanțe incorect clasificate.

=== Detailed Accuracy By Class ===

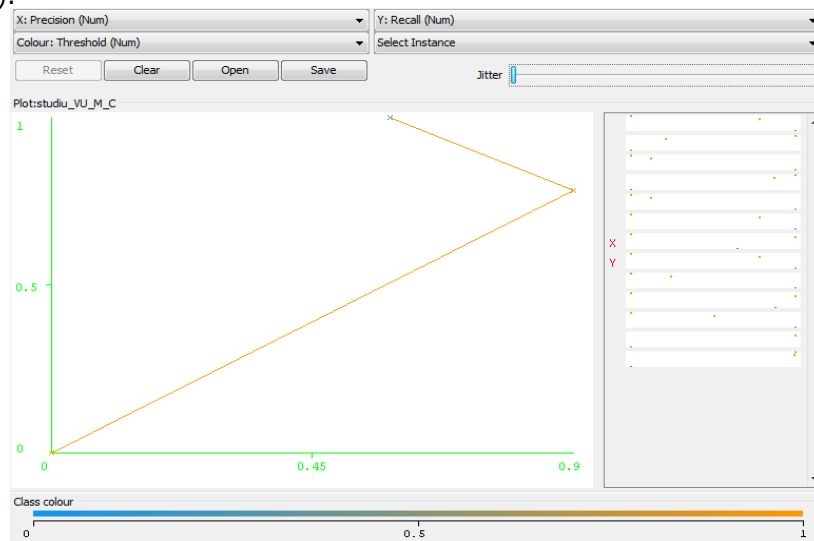
	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	0.97	0	1	0.97	0.985	0.985	M
	1	0.03	0.96	1	0.98	0.985	C
Weighted Avg.	0.983	0.012	0.983	0.983	0.983	0.985	

=== Confusion Matrix ===

```
a b <-- classified as
98 3 | a = M
0 72 | b = C
```

**Figura 5.12 VU: Sinteza metricilor de evaluarea a arborelui de decizie cu datele de test**

În Figura 5.13 este prezentat graficul "Precision & Recall". Precizia sau *Precision* dă măsura acurateții clasificării, adică a numărului instanțelor clasificate corect ca aparținând clasei pozitive (adevărat pozitivele) raportat la numărul total al instanțelor aparținând clasei pozitive (totalul falsurilor pozitive și adevărat pozitivelor). Caracteristica *Recall* surprinde relevanța celor clasificate, fiind definită ca raport între instanțele clasificate ca aparținând clasei pozitive (adevărat pozitivul) și numărul total al instanțelor aparțineau de fapt clasei pozitive, adică totalul celor clasificate corect și a celor neclasificate corect (tot din punctul de vedere al clasei pozitive).



**Figura 5.13** Grafic "Precision & Recall" (clasele M și CO)

Tabel 5.2 prezintă și alte metrice utilizate pentru validarea clasificării, cu aplecare asupra posibilelor erori în rezultatele prezentate. Un test suplimentar a constat în realizarea clasificării prin utilizarea mulțimii de antrenament și a celei de test considerate ca date de intrare, din care 75% fiind pentru antrenarea modelului și restul de 25% ca date de test pentru evaluarea rezultatului.

**Tabel 5.2 VU: Metrice de validare a modelului clasificator**

Clasificator: RANDOM TREE	Mulțime antrenament	Mulțime test	Împărțire (75%)
Instanțe clasificate corect	100%	98.27%	93.03%
Instanțe clasificate incorect	0%	1.73%	6.97%
Eroare medie relativă	0	0.01	0.06
Eroare medie absolută	0	0.13	0.26
Eroare pătratică medie	0%	3.56%	13.88%
Eroare pătratică absolută	0%	26.71%	51.25%

S-a menționat la începutul secțiunii despre utilizarea mai multor algoritmi pentru indentificarea celui cu posibilitățile de clasificare cele mai bune. S-a insistat asupra algoritmului *Random Tree* din clasa arborilor de decizie, el oferind cele mai bune rezultate. Pe lângă acesta au existat încă doi algoritmi care au oferit o posibilitate de predicție foarte bună, *Decision Table* și *IB1* - sinteza rezultatelor cu acești algoritmi fiind prezentată în

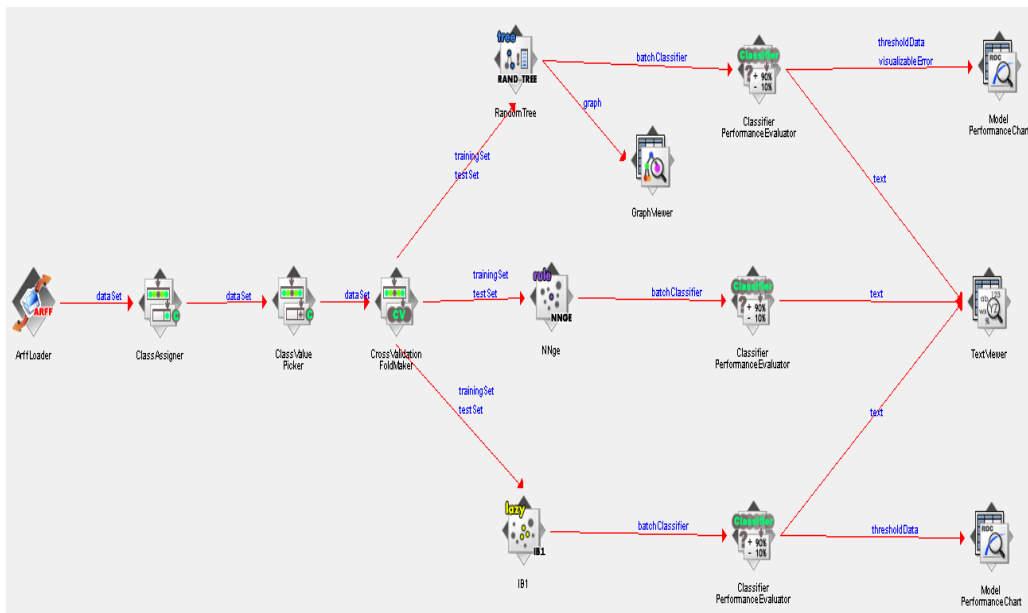
Tabel 5.3 împreună cu *Random Tree* pentru a se vedea comparative performanțele tuturor celor trei, subliniind instanțele clasificate corect, cele clasificate incorect, respectiv eroarea medie relativă a fiecărei clasificări.

**Tabel 5.3 VU: Clasificatorii cu cele mai bune rezultate (clasele M și CO)**

Clasificator	Metoda validare	Instanțe clasificate corect	Instanțe clasificate incorect	Eroare medie relativă
<b>RANDOM TREE</b>	Validare încrucișată	98.27%	1.73%	0.01
	Împărțire 75%	93.03%	6.97%	0.06
<b>DECISION TABLE</b>	Validare încrucișată	89.02%	10.98%	0.32
	Împărțire 75%	93.03%	6.97%	0.29
<b>IB1</b>	Validare încrucișată	94.80%	5.20%	0.20
	Împărțire 75%	81.40%	18.60%	0.24

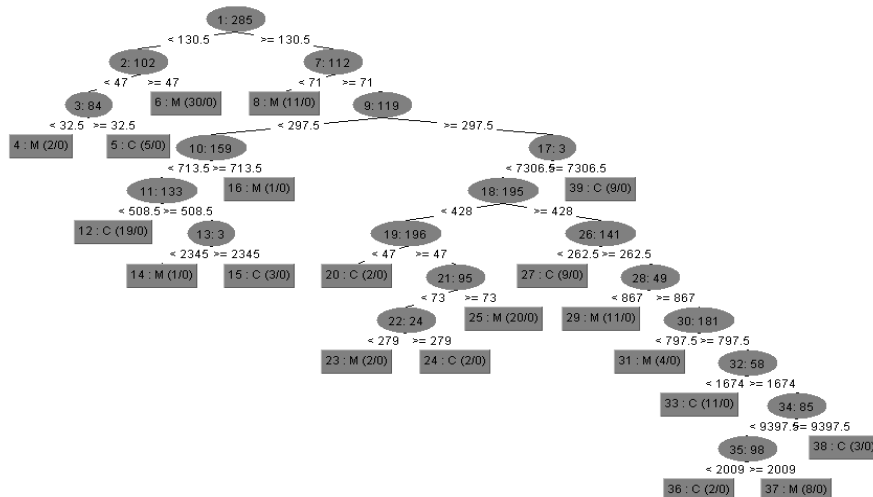
### 5.6.2 Rezultatele cu PP Meter

În schema din Figura 5.14 este prezentată sinteza construcției modelelor de clasificare pentru cei trei algoritmi care au oferit rezultatele cele mai bune în luarea deciziei de apartenență la una din cele două clase. Schema este similară celei din secțiunea dedicată măsurătorilor cu VU Meter, cu mențiunea că pentru acest studiu a existat și un alt algoritm care a generat rezultate acceptabile. Acest algoritm este *NNgeși* și se regăsește prin componenta *NNgecare* o înlocuiește pe cea reprezentată de *Decision Table*, deoarece nu a mai furnizat și pentru acest studiu rezultate satisfăcătoare. Clasificatorii și rezultatele înseși denotă legătura strânsă dintre cele două instrumente de măsură, în caracteristicile sau tendințele lor comune regăsindu-se informația necesară realizării acestor clasificări între clasele studiate.

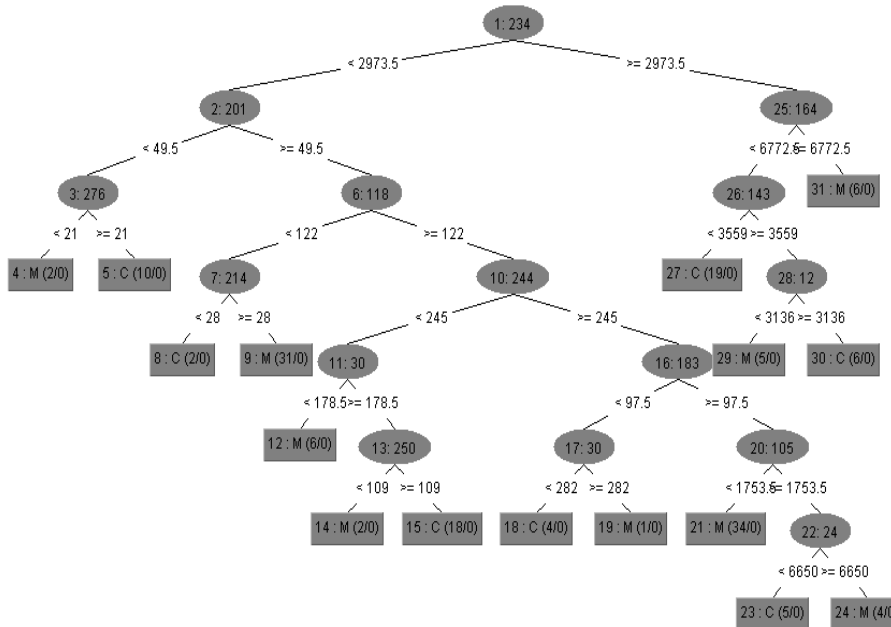


**Figura 5.14 Schema modelelor de clasificare cu cele mai bune performanțe cu PP Meter**

În Figura 5.15 și Figura 5.16 sunt prezentați arborii de decizie rezultați ca modele de realizare a clasificării. Arborii diferă de cei rezultați pentru VU Meter din punctul de vedere al nivelelor, dar și al conținutului pe baza căruia se ia decizia. Dat fiind că cele două instrumente efectuează măsurători în mod diferit, este de așteptat ca valorile să difere. După cum s-a enunțat anterior, date fiind rezultatele aproximativ similar, se poate afirma că tendința dată de evoluția valorilor intensităților și nu valorile efective ale acestora sunt elementele detectate în modelul clasificatorului. Și în acest caz, se pot observa că primele fonații sunt cele luate în considerare de modelul clasificator pentru luarea deciziei.

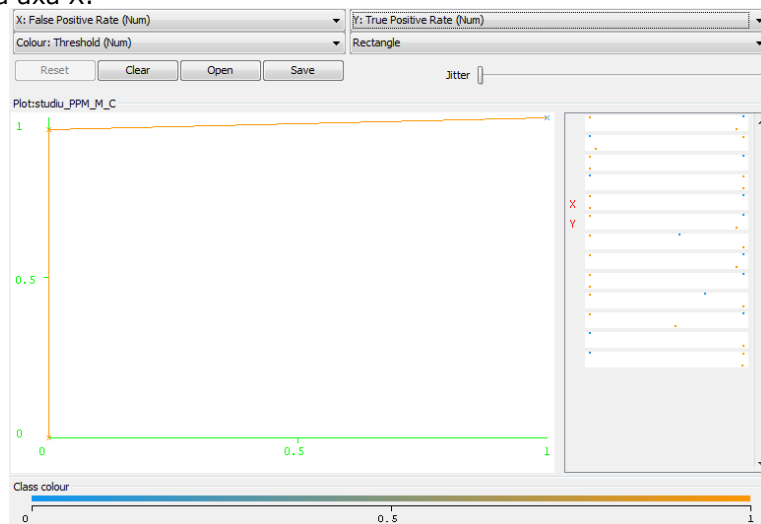


**Figura 5.15 Arborele de decizie (mulțimea de antrenament)**



**Figura 5.16 Arborele de decizie (mulțimea de test)**

Metrica reprezentată de curba ROC în vederea validării rezultatelor este prezentată în Figura 5.17 și oferă evaluarea clasificatorului ca raport între instanțele clasificate incorect pe de o parte (axa X) și cele clasificate corect de pe alta (axa Y). În cazul acestei clasificări, curba ROC generată este de forma unei drepte care tinde a fi paralelă cu axa X. Această reprezentare corespunde unei clasificări foarte bune, în mod ideal, în cazul unei clasificări corecte a tuturor instanțelor, curba fiind paralelă cu axa X.



**Figura 5.17 PPM: M-C: Curba ROC (clasele M și CO)**

În valori numerice, arborele de decizie pentru datele de test generează metricile prezentate în Figura 5.18, matricea de confuzie indicând numărul instanțelor clasificate corect ca fiind 169, restul de 4 din totalul instanțelor studiate fiind fals pozitive, adică un procent de 2,31%.

```

=== Detailed Accuracy By Class ===

              TP Rate  FP Rate  Precision  Recall  F-Measure  ROC Area  Class
              0.96    0        1          0.96   0.98       0.98     M
              1        0.04   0.947     1      0.973     0.98     C
Weighted Avg.  0.977   0.016   0.978     0.977  0.977     0.98

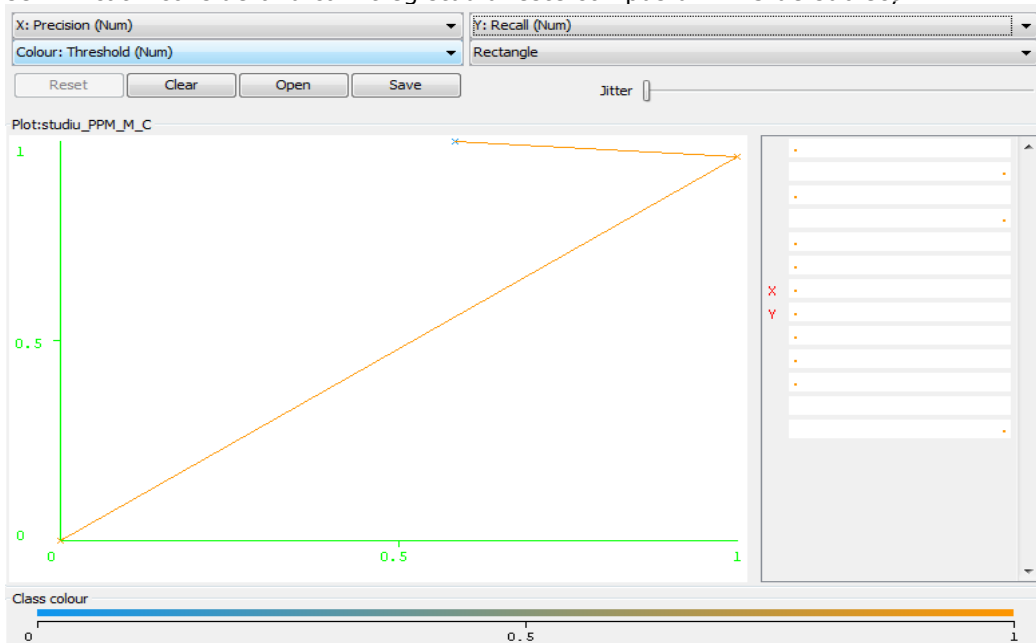
=== Confusion Matrix ===

  a  b  <-- classified as
 97  4 | a = M
  0 72 | b = C

```

**Figura 5.18 PPM: Sinteza metricilor de evaluarea a arborelui de decizie cu datele de test**

În Figura 5.19 este prezentat graficul "Precision & Recall", similar celui din secțiunea precedentă. Diferența dintre cele două constă într-o singură instanță clasificată incorect în cazul valorilor preluate de la PP Meter. Această instanță mărește cu o unitate numărul fals pozitivelor, însă impactul nu este unul semnificativ considerând că întreg studiul este compus din 173 de subiecți.



**Figura 5.19 PPM: "Precision & Recall" (clasele M și CO)**

Tabel 5.2 prezintă alte metrice pentru validarea clasificării, preponderent cu axare asupra estimării erorilor în rezultatele prezentate. Un test suplimentar a constatat în realizarea clasificării prin utilizarea mulțimii de antrenament și a celei de test considerate ca dată de intrare, din care 75% fiind pentru antrenarea modelului și diferența de 25% ca date de test pentru evaluarea rezultatului.

**Tabel 5.4 PP: Metrice de validare a modelului clasificator**

Clasificator: RANDOM TREE	Mulțime antrenament	Validare încrucișată	Împărțire 75%
Instanțe clasificate corect	100%	97.69%	90.70%
Instanțe clasificate incorect	0%	2.31%	9.30%
Eroare medie relativă	0	0.02	0.09
Eroare medie absolută	0	0.15	0.30
Eroare pătratică medie	0%	4.75%	18.50%
Eroare pătratică absolută	0%	30.84%	59.18%

Date fiind rezultatele foarte bune ale algoritmului *Random Tree* s-au detaliat rezultate utilizării acestuia. În afara acestui algoritm din clasa arborilor de decizie, alți doi clasificatori din rândul aceluiași clase (algoritmul *NNge*) respectiv al algoritmilor leneși (algoritmul *IB1*) au oferit rezultate de luat în considerare. Sinteza rezultatelor cu acești algoritmi fiind prezentată în Tabel 5.5 împreună cu algoritmul *Random Tree*.

**Tabel 5.5 PP Meter: Clasificatorii cu cele mai bune rezultate**

Clasificator	Metoda validare	Instanțe clasificate corect	Instanțe clasificate incorect	Eroare relativă medie
<b>RANDOM FOREST</b>	Validare încrucișată	97.69%	2.31%	0.02
	Împărțire 75%	90.70%	9.30%	0.09
<b>NNGE</b>	Validare încrucișată	98.85%	1.15%	0.02
	Împărțire 75%	90.70%	9.30%	0.09
<b>IB1</b>	Validare încrucișată	96.53%	3.46%	0.03
	Împărțire 75%	97.68%	2.32%	0.02



## 5.7 Lotul de prematuri (clasa P)

Lotul de prematuri este reprezentat de o mulțime constând în 72 de înregistrări ale plânsului cu aplicația Neonat. Criteriul de includere în această mulțime a fost reprezentat de nașterea prematură, adică o vârstă de gestație a fătului mai mică sau egală cu 37 de săptămâni.

Lotul studiat prezintă anumite particularități sesizate pe durata realizării colectării datelor, fiind subliniate în Figura 5.20, Figura 5.21 și Figura 5.22. S-au marcat regiuni din semnalul din plâns în care au fost sesizate similitudini între înregistrările mai multor prematuri, forma de tranziție dintre vârfurile de amplitudine fiind mult mai lină decât în cazul lotului martor.

Cele trei figuri oferite ca exemplu prezintă numeroase similitudini și au fost astfel selectate pentru exemplificare. Spectrele de frecvență din capturile de ecran, surprind slabe încărcări energetice pe tot intervalul audibil, astfel că analiza mai detaliată a fonațiilor de scurtă durată a prins contur ca direcție de cercetare. Acest aspect va fi prezentat în capitolul 6, care este dedicat acestei analize pe „cuvinte” a plânsului. Figura 5.20, Figura 5.21 și Figura 5.22 conțin adnotări ale identificatorilor nou-născuților considerați în studiu, semnificația abrevierilor fiind de interes doar în cadrul studiului.

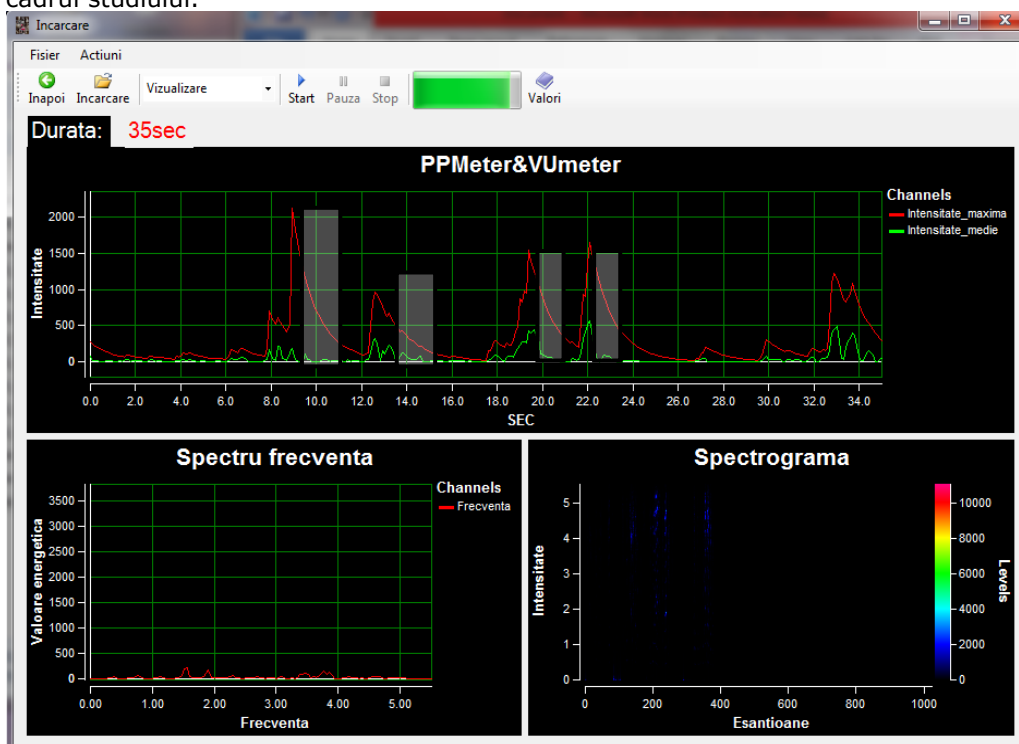


Figura 5.20 Prematur ID\_GOM

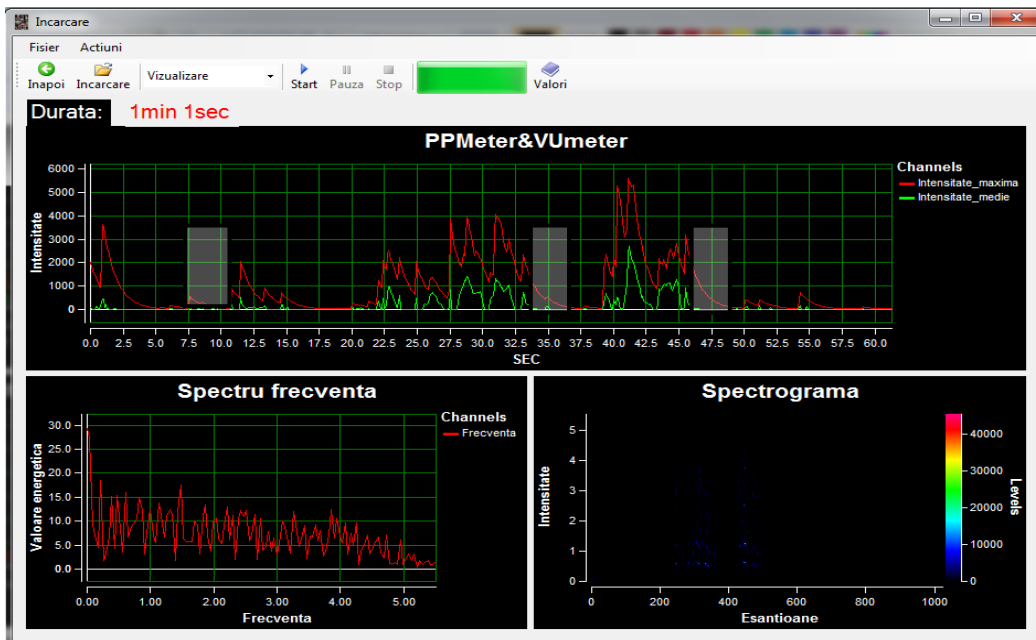


Figura 5.21 Prematur ID\_CRI

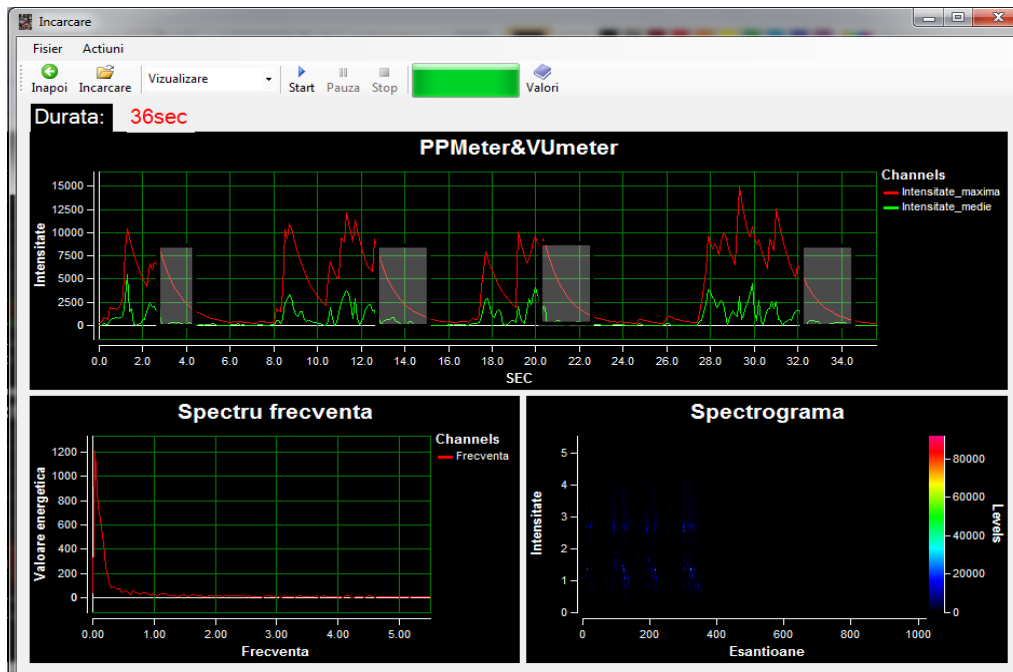
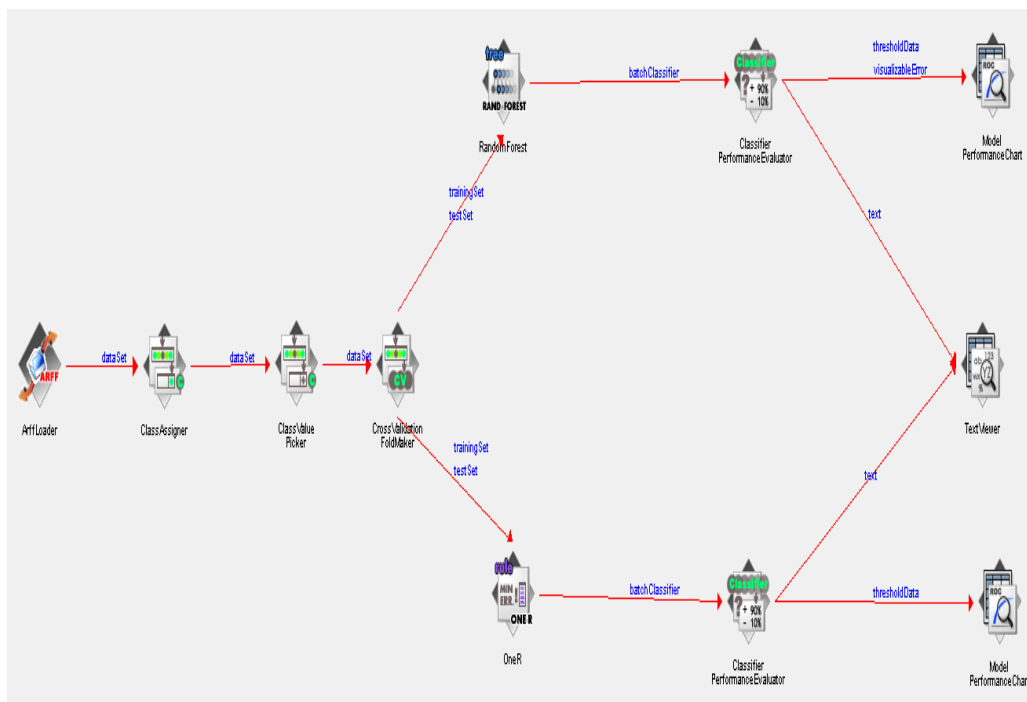


Figura 5.22 Prematur ID\_RAD

### 5.7.1 Rezultatele cu VU Meter

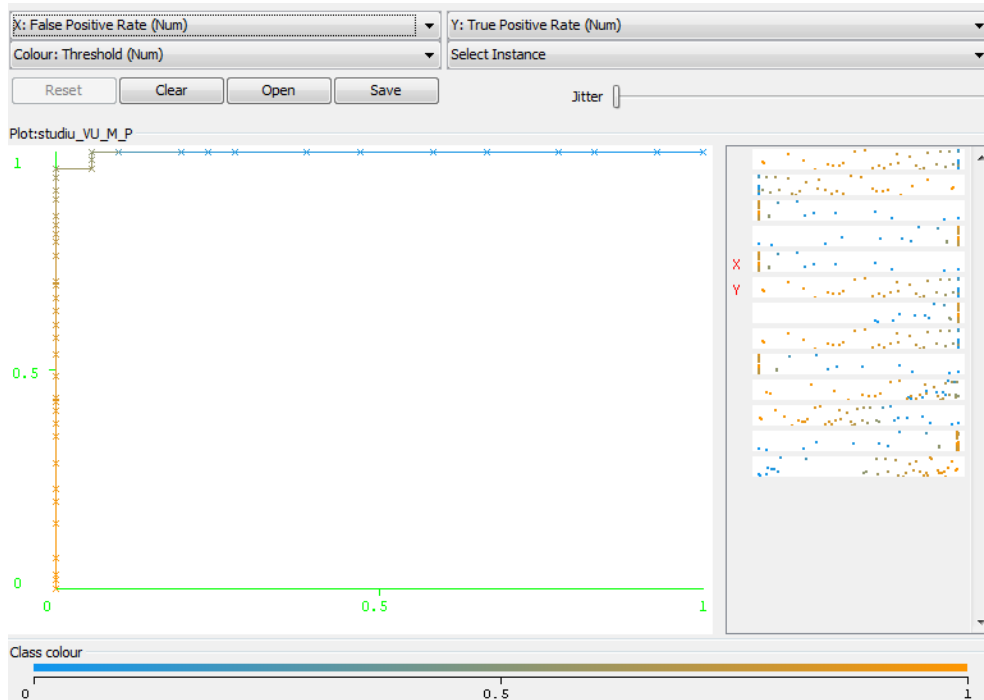
În schema din Figura 5.23 este prezentat modelul construit ce cuprinde clasificatorii cu rezultatele cele mai bune pentru studiul clasificării prematurilor. Elementele ce se regăsesc în schemă sunt similare cu cele prezentate în paragrafele anterioare cu următoarele mențiuni:

- Clasificatorii cei mai buni au fost reprezentați de *Random Forest* respectiv *OneR*;
- Din schemă lipsește componenta de vizualizare grafică a rezultatului. Acest aspect se datorează faptului ca deși algoritmul cel mai bun a fost din clasa arborilor de decizie (*Random Forest*) acesta generează un set de arbori a căror vizualizare este foarte greu de urmărit, mediul Weka nemaipermitând vizualizarea pentru acest algoritm (dată fiind încărcarea excesivă a mediului pentru o asemenea vizualizare).



**Figura 5.23** Schema modelelor de clasificare cu cele mai bune rezultate cu VU Meter

Rezultatele evaluării acurateții modelului clasificator realizat cu algoritmul *Random Forest* prin curba ROC se regăsesc în Figura 5.24. Se observă în graficul trasat existența preponderență a adevărat pozitivelor și adevărat negativelor, adică încadrarea corectă a unui număr consistent de instanțe din cele două clase (168 de subiecți) și un număr relativ mic de instanțe aparținând clasei M care au fost încadrate ca aparținând clasei P (4 cazuri), în mod evident eronat.



**Figura 5.24 VU: Curba ROC (clasale M și P)**

În Figura 5.25 se regăsește o captură de ecran din mediul Weka, în care sunt sintetizate o parte din metricile de evaluare ale clasificatorului *Random Forest*. Matricea de confuzie surprinde rezultate prezentate prin curba ROC asociată clasificatorului, adică totalul instanțelor clasificate corect, în număr de 169, respectiv cele 4 clasificate eronat care au fost considerate ca aparținând lotului de prematuri (clasa P) deși fac parte din mulțimea de martori (clasa M).

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	1	0.056	0.962	1	0.981	0.998	M
	0.944	0	1	0.944	0.971	0.998	P
Weighted Avg.	0.977	0.032	0.978	0.977	0.977	0.998	

=== Confusion Matrix ===

```

a  b  <-- classified as
101  0 |  a = M
  4 68 |  b = P
    
```

**Figura 5.25 VU: Sinteza metricilor de evaluarea a arborelui de decizie cu datele de test**

Erorile calculate pentru clasificator, desemnat ca fiind cel mai bun, respectiv diseminarea clasificării pe tipurile de mulțime considerate (antrenament, test și împărțirea aleatoare a întregului lot în 75% date antrenare și restul test) se regăsește în Tabel 5.6.

**Tabel 5.6 Metrice de validare a modelului clasificator**

Clasificator: RANDOM FOREST	Mulțime antrenament	Validare încrucișată	Împărțire 75%
Instanțe clasificate corect	100%	98.85%	100%
Instanțe clasificate incorect	0%	1.15%	0%
Eroare medie relativă	0.01	0.05	0.05
Eroare medie absolută	0.03	0.11	0.09
Eroare pătratică medie	1.90%	10.46%	11.54%
Eroare pătratică absolută	6.54%	22.97%	18.94%

După cum a fost menționat la începutul prezentului subcapitol, pe lângă algoritmul aparținând familiei arborilor de decizie, a fost găsit un alt algoritm, din clasa regulilor, *OneR* care a prezentat o acuratețe acceptabilă a clasificării, în jurul valori de 85%, ca medie a testelor efectuate.

**Tabel 5.7 VU Meter: Clasificatorii cu cele mai bune rezultate**

Clasificator	Metoda validare	Instanțe clasificate corect	Instanțe clasificate incorect	Eroare medie relativă
<b>RANDOM FOREST</b>	Validare încrucișată	98.85%	1.15%	0.05
	Împărțirea 75%	100%	0%	0.05
<b>OneR</b>	Validare încrucișată	86.71%	13.29%	0.13
	Împărțirea 75%	83.73%	16.27%	0.16

### 5.7.2 Rezultate cu PP Meter

În schema din Figura 5.26 este prezentată schema de sinteză a clasificatorilor cu rezultatele cele mai bune pentru studiul clasificării prematurilor pe datele provenite de la PP Meter. Spre deosebire de schema realizată pentru datele

provenite de la VU Meter, în acest caz au fost identificați trei algoritmi de clasificare cu rezultate apropiate ca performanță. Clasificatorii cei mai buni au fost reprezentați de *Random Tree*, *Conjunctive Rule* respectiv *IB1*. În schemă reapare componenta de vizualizare grafică a rezultatului ca urmare a utilizării algoritmului *Random Tree*. Arborele generat este prezentat în Figura 5.27.

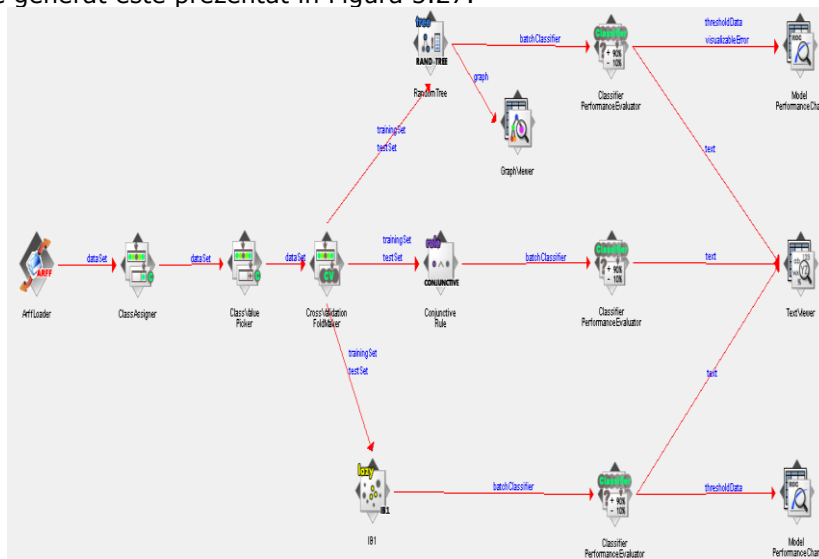


Figura 5.26 PPM: Schema modelelor de clasificare cu cele mai bune performanțe

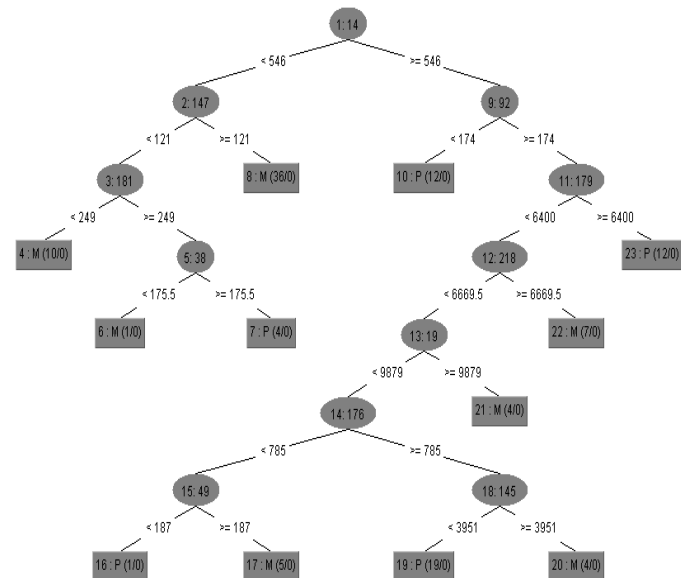


Figura 5.27 PPM: Arborele de decizie generat (clasele M și P)

Rezultatele evaluării acurateții modelului clasificator realizat cu algoritmul *Random Tree* prin curba ROC se regăsesc în Figura 5.28. Similar rezultatelor obținute cu VU Meter, în graficul trasat predomină rezultatele adevărat pozitive și adevărat negative, cu un total de 164 de instanțe clasificate corect și un număr relativ mic de instanțe aparținând clasei M care au fost încadrate ca aparținând clasei P (9 cazuri), spre deosebire de rezultatele precedente unde încadrările eronate au fost în sens invers (din clasa P ca având caracteristici din clasa M).




Figura 5.28 PPM: Curba ROC (Clasele M și P)

În Figura 5.29 se regăsește graficul pentru măsura preciziei și al evaluatorului "Recall". Graficul, scoate în evidență fals negative rezultate în urma clasificării, adică încadrarea numărului de 9 instanțe din clasa P a prematurilor în clasa M constând din nou-născuții la termen fără probleme medicale. Comparativ cu rezultatul obținut în studiul cu VU Meter, acesta pe lângă o eroare mai mare, din punct de vedere medical, presupune lipsa intervenției ca urmare a încadrării în categoria fără semnalmente de patologie. Totuși, procentul redus de clasificări incorecte este relativ mic în contextual întregului studiu.

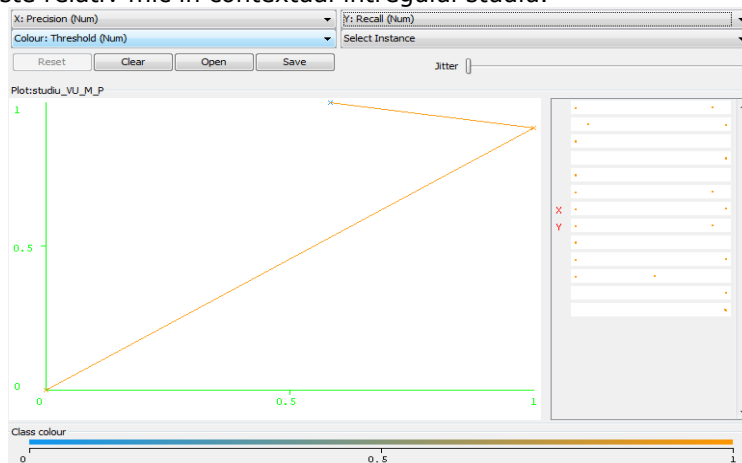


Figura 5.29 PPM: Graficul "Precision & Recall" (clasa M și P)

Figura 5.30 PPM: Sinteza metricilor de evaluarea ale clasificatorului date de test prezintă captura de ecran din Weka, în care sunt sintetizate o parte din metricele de evaluare ale clasificatorului *RandomTrees* și matricea de confuzie.

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	0.911	0	1	0.911	0.953	0.955	M
	1	0.089	0.889	1	0.941	0.955	P
Weighted Avg.	0.948	0.037	0.954	0.948	0.948	0.955	

=== Confusion Matrix ===

```

a b  <-- classified as
92 9 | a = M
0 72 | b = P

```

**Figura 5.30 PPM: Sinteza metricilor de evaluarea ale clasificatorului date de test**

Erorile calculate pentru clasificator, desemnat ca fiind cel mai bun, respectiv diseminarea clasificării pe tipurile de mulțime considerate (antrenament, test și împărțirea aleatoare a întregului lot în 75% date antrenare și restul test) se regăsește în Tabel 5.8.

**Tabel 5.8 Metrici de validare a modelului clasificator**

Clasificator: RANDOM TREE	Mulțime antrenament	Validare încrucișată	Împărțire 75%
Instanțe clasificate corect	100%	98.27%	93.03%
Instanțe clasificate incorect	0%	1.73%	6.97%
Eroare medie relativă	0	0.1	0.06
Eroare medie absolută	0	0.13	0.26
Eroare pătratică medie	0%	3.56%	13.88%
Eroare pătratică absolută	0%	26.71%	51.25%

După cum a fost menționat la începutul prezentului subcapitol, pe lângă algoritmul *Decision Tree*, au fost identificați și alți doi algoritmi cu performanțe de clasificare bune, *Conjunctive Rule* din familia regulilor, respective *IB1* din rândul algoritmilor leneși. Rezultatele acestora au fost sintetizate în tabelul de mai jos.



**Tabel 5.9 PP Meter: Clasificatorii cu cele mai bune rezultate**

Clasificator	Metoda validare	Instanțe clasificate corect	Instanțe clasificate incorect	Eroare medie relativă
<b>RANDOM TREE</b>	Validare încrucișată	98.27%	1.73%	0.1
	Împărțire 75%	93.03%	6.97%	0.06
<b>CONJUNCTIVE RULE</b>	Validare încrucișată	82.66%	17.34%	0.26
	Împărțire 75%	86.05%	13.95%	0.27
<b>IB1</b>	Validare încrucișată	100%	0	0.05
	Împărțire 75%	93.23%	6.77%	0.06

## 5.8 Studiul de clasificare al nou-născuților cu patologii severe (PS)

Lotul format din nou-născuți cu patologii severe (PS), constă în semnale din plâns provenite de la nou-născuți care au fost diagnosticați medical cu afecțiuni severe, dar care au fost stabili ca stare generală la momentul realizării înregistrării vocale. Lotul considerat este compus din 51 de instanțe cu următoarele caracteristici:

- indicele Apgar mai mic sau egal cu 5;
- vârstă gestațională între 28 și 40 de săptămâni
- greutate mai mare de 1100g;
- existența unei patologii diagnosticate: detresă respiratorie, suferință neurologică sau afecțiuni ale cordului.

Un nou-născut cu indice Apgar de 5 sau mai mic, prezintă o stare generală severă din punct de vedere medical și necesită în plus manevre de reanimare și terapie intensivă, care variază în funcție de situația clinică a nou-născutului: intubație, ventilație asistată, masaj cardiac extern și multe alte metode specific medicale.

Nou-născuții din această categorie ca și ceilalți prezintă diferențe clare vis-a-vis de lotul de referință al nou-născuților considerați sănătoși. Vizualizarea unei exemple de secvență din plâns pentru un nou-născut din această categorie se regăsește în Figura 5.31.

Rezultatele acestui studiu sunt detaliate doar pentru achiziția cu VU Meter, dată fiind performanța slabă a tuturor clasificatorilor utilizați în studiul valorilor măsurate cu PP Meter.

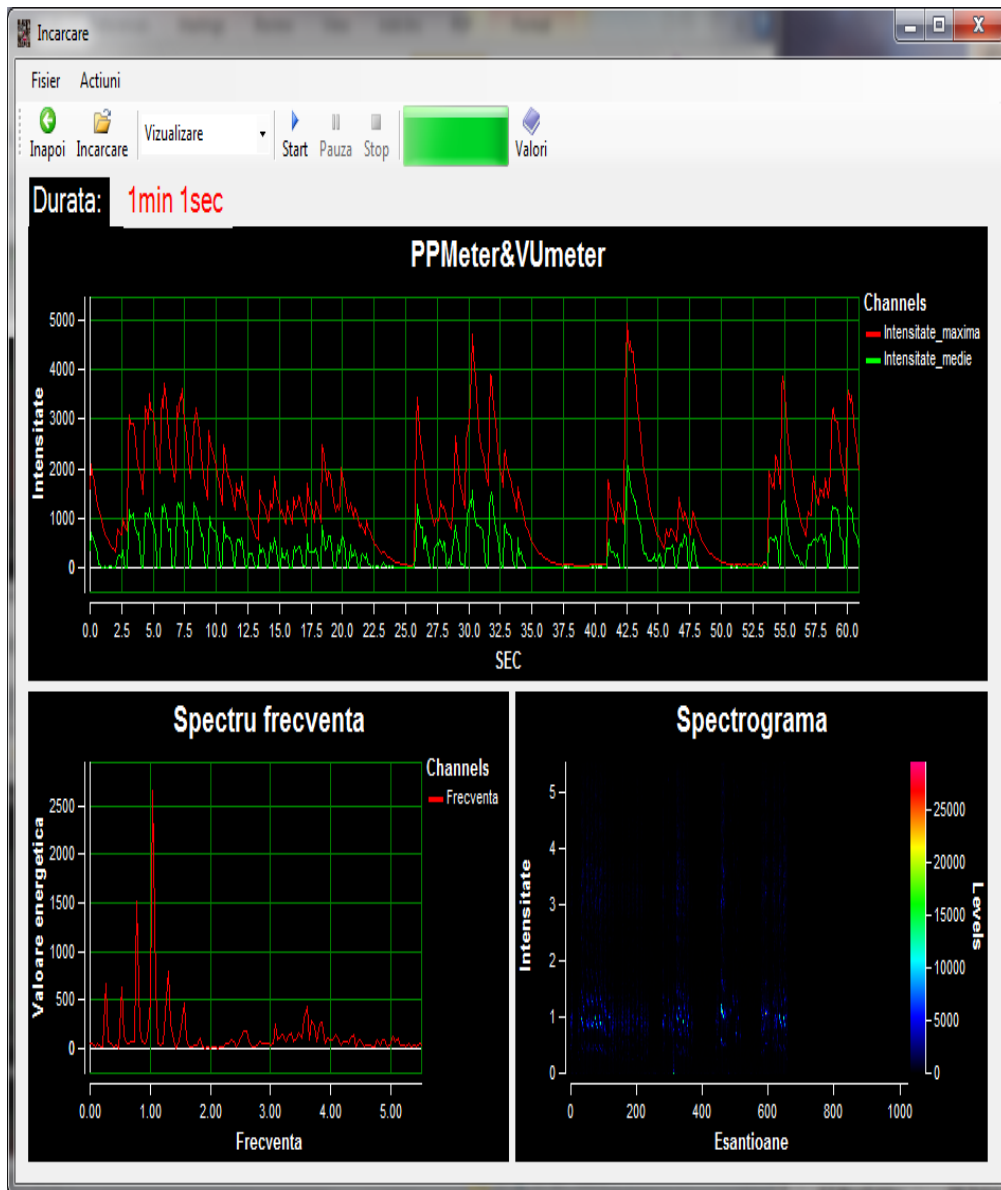


Figura 5.31 Secvență de plâns pentru un nou-născut cu suferință neurologică majoră

### 5.8.1 Rezultatele cu VU Meter

În schema din Figura 5.32 este prezentată o sinteză a clasificatorilor cu rezultatele cele mai bune pentru studiul clasificării secvențelor de plâns provenit de la nou-născuți cu patologii severe pe datele provenite de la VU Meter. Au fost identificați doi algoritmi de clasificare cu rezultate acceptabile. Clasificatorii cei mai

buni au fost reprezentați de *Random Tree*, respectiv algoritmul bazat pe reguli de decizie *NNge*.

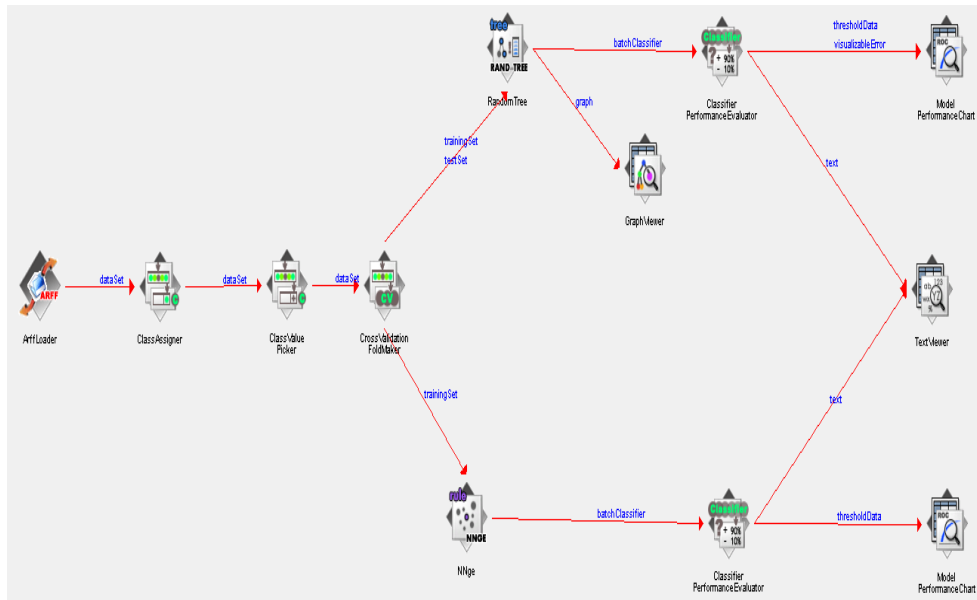


Figura 5.32 VU: M – PS – Mulțimea de antrenament

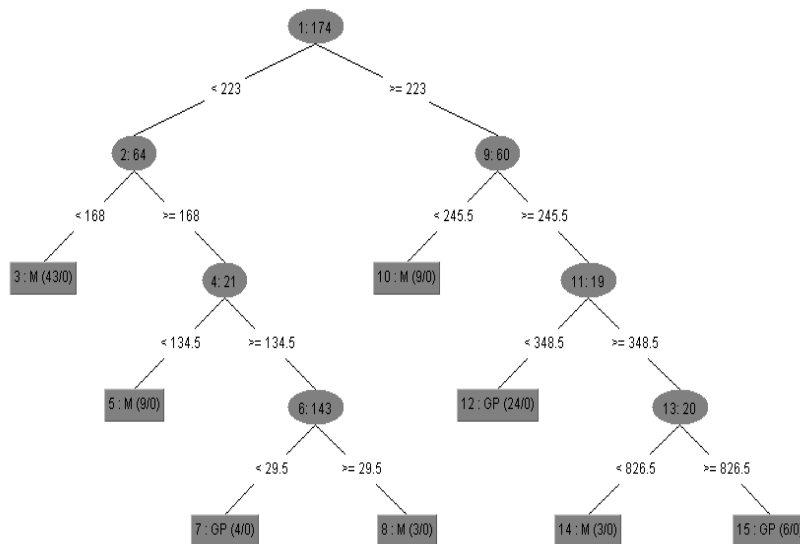
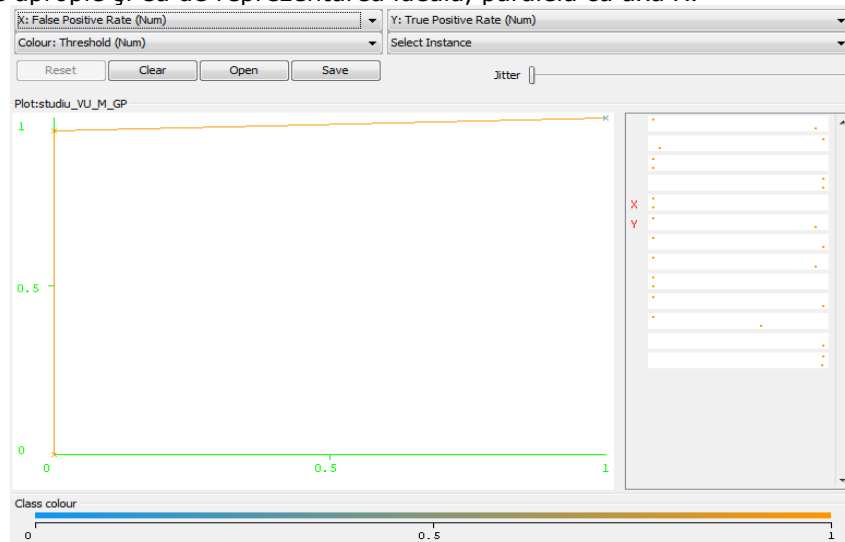


Figura 5.33 VU: Arborele de clasificare (clasele M și PS)

Rezultatele evaluării acurateții modelului clasificator realizat cu algoritmul *Random Tree* prin curba ROC se regăesc în Figura 5.34. Similar rezultatelor

obținute în precedentele studii cu clase CO și respectiv M, în graficul trasat pentru această analiză predomină rezultatele adevărat pozitive și adevărat negative, cu un total de 148 de instanțe clasificate corect și un număr relativ mic de instanțe aparținând clasei M care au fost încadrate ca aparținând clasei PS (4 cazuri). Curba ROC se apropie și ea de reprezentarea ideală, paralelă cu axa X.



**Figura 5.34 VU: Curba ROC (Clasele M și PS)**

În Figura 5.35 se regăsește graficul pentru măsura preciziei și al evaluatorului "Recall". Referitor la precizie, graficul scoate în evidență fals pozitive rezultate în urma clasificării, adică încadrarea numărului de 4 instanțe din clasa PS a celor cu suferințe diagnosticate în clasa M constând din nou-născuții la termen fără probleme medicale.

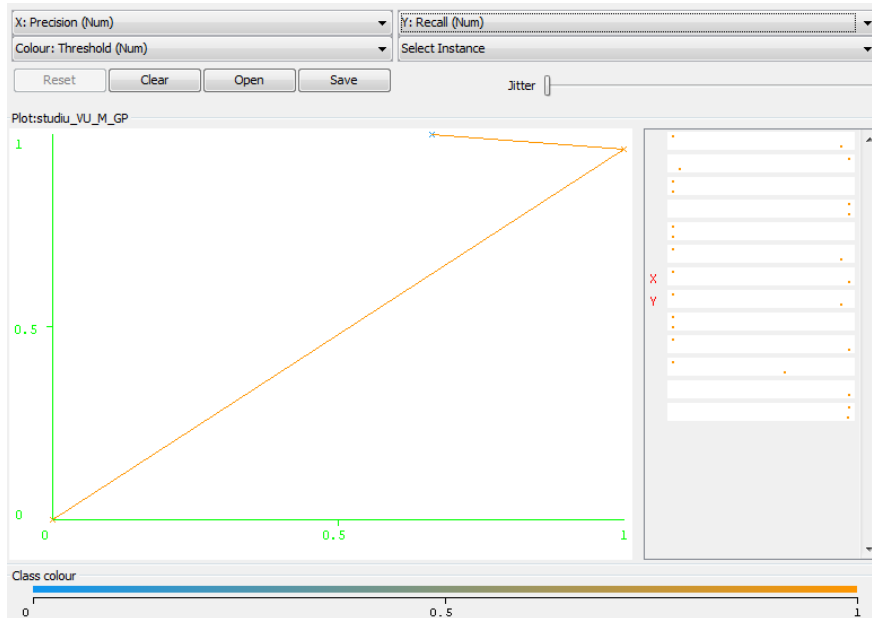


Figura 5.35 VU: Graficul "Precision & Recall"

Figura 5.36 prezintă captura de ecran din Weka, în care sunt sintetizate o parte din metricile de evaluare ale clasificatorului *RandomTree* și matricea de confuzie.

=== Detailed Accuracy By Class ===

	TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
	0.96	0	1	0.96	0.98	0.98	M
	1	0.04	0.927	1	0.962	0.98	GP
Weighted Avg.	0.974	0.013	0.976	0.974	0.974	0.98	

=== Confusion Matrix ===

```

a b <-- classified as
97 4 | a = M
0 51 | b = GP

```

Figura 5.36 Sinteza metricilor de evaluarea ale clasificatorului date de test

Erorile calculate pentru clasificator desemnat ca fiind cel mai bun, respectiv desemnarea clasificării pe tipurile de mulțime considerate (antrenament, test și împărțirea aleatoare a întregului lot în 75% date antrenare și restul test) se regăsește în Tabel 5.10.

**Tabel 5.10 Metrice de validare a modelului clasificator**

Clasificator: RANDOM TREE	Mulțime antrenament	Validare încrucișată	Împărțire 75%
Instanțe clasificate corect	100%	98.85%	100%
Instanțe clasificate incorect	0%	1.15%	0%
Eroare medie relativă	0.01	0.05	0.05
Eroare medie absolută	0.03	0.11	0.09
Eroare pătratică medie	1.90%	10.46%	11.54%
Eroare pătratică absolută	6.54%	22.97%	18.94%

După cum a fost menționat la începutul prezentului subcapitol, pe lângă algoritmul *Decision Tree*, a mai fost validat un clasificator în familia regulilor de decizie, respectiv *NNge*, care a furnizat deasemenea o acuratețe bună potrivit metricilor. Rezultatele acestora au fost sintetizate în Tabel 5.11.

**Tabel 5.11 VU: Clasificatorii cu cele mai bune rezultate**

Clasificator	Metoda validare	Instanțe clasificate corect	Instanțe clasificate incorect	Eroare medie relativă
<b>RANDOM TREE</b>	Validare încrucișată	98.85%	1.15%	0.05
	Împărțire 75%	100%	0%	0.05
<b>NNge</b>	Validare încrucișată	89.48%	10.52%	0.26
	Împărțire 75%	84.22%	15.78%	0.28

## 5.9 Concluzii parțiale

În cadrul acestui capitol a fost realizat un studiu de *Data Mining* în vederea realizării de clasificări ale plânsului nou-născuților după încadrarea acestora în grupuri cu specificități similare. Scopul studiului a constat în determinarea unor clasificatori capabili ca pe baza informației de intensitate vocală măsurată cu *Volume Unit Meter (VU Meter)* respectiv *Peak Program Meter (PP Meter)* din cadrul aplicației Neonat, să se realizeze o clasificare automată a clasei de apartenență a nou-născutului.

S-a constituit un lot martor cu 101 de secvențe de plâns a câte 30 de secunde aparținând nou-născuților cu diagnostic medical favorabil, adică o vârstă gestațională apropiată de 40 de săptămâni, o naștere fără incidente (fără circulara de cordon ombilical la naștere) și nici o patologie semnalată de personalul medical.

S-au construit și alte mulțimi în care au fost încadrați nou-născuți cu semnalmente de patologii, incidente la naștere, nou-născuți prematur sau cu anumiți parametri care nu corespundeau diagnosticului normal (indice Apgar scăzut, greutate mult sub cea normală (RCIU), izoimunizare Rh, afecțiuni pulmonare sau cardiace). Dintre acestea, rezultatele cele mai promițătoare au fost pentru lotul de nou-născuți prematur (de 72 de secvențe de plâns), lotul de nou-născuți cu circulara (strangulație) de cordon ombilical la naștere și lotul de nou-născuți cu patologii severe (suferință neurologică majoră, prematuritate în jurul a 30 de săptămâni sau indice Apgar sub 5).

Clasificarea a fost evaluată pe baza unor indicatori statistici, oferind rezultate foarte bune pentru cele trei loturi menționate. Astfel, pentru încadrarea corectă a nou-născuților cu circulara (strangulație) de CO la naștere s-a obținut un procent favorabil de 97%-98% cu ambele instrumente de măsură prin folosirea arborilor de decizie (algoritmul Random Tree), având o eroare medie relativă de doar 0.06.

La clasificarea nou-născuților prematuri s-a obținut o clasificare corectă a instanțelor de 98% de asemenea cu ambele instrumente de măsură și cu ajutorul aceleiași familii de algoritmi, arborii de decizie, de această dată folosind algoritmul *Random Forest*.

Cel din urmă rezultat, deasemenea relevant, este reprezentat de clasificarea unui lot în care au fost încadrați nou-născuți cu patologii severe. În acest caz rezultatul clasificării a fost pozitiv doar în cazul utilizării *VU Meter*, obținând o clasificare corectă pentru 98% dintre instanțe considerate în studiu.

Rezultatele prezentate constituie un indicator al existenței unei diferențieri în plânsul nou-născutului, dat de parametri fizici ai acestuia și starea de sănătate dată de o serie de teste medicale, o bună parte din ele invazive. Acestea au fost publicate într-o formă sintetizată într-un articol științific [103] și prezentate public în cadrul unei conferințe internaționale. Se întărește astfel ideea utilizării semnalului din plâns în vederea asistării deciziei medicale, în special în situațiile în care există indicatori în plâns ai suferinței care pot determina o cercetare mai amănunțită.

## 6. Analiza „cuvintelor” din semnalul de plâns

Capitolul de față este destinat studiului elementelor constitutive ale plânsului, referite ca și „cuvinte”. Cercetările realizate urmăresc două direcții: pe de o parte evoluția parametrului de saturație la nivel cerebral și corelarea acestuia cu parametrii din plâns (frecvența dominantă) și pe de altă parte evidențierea în mod grafic a suferinței neurologice, prin aplicarea transformatei wavelet discrete pe cuvintele extrase din plâns. Sunt utilizate în studiu echipamente noi, precum dispozitivul profesional de achiziție de sunet Olympus PCM și aparatul medical de măsură a saturației la nivel cerebral, INVOS. Finalul capitolului rezumă rezultatele studiilor conduse, precum și dificultățile întâmpinate și soluționarea acestora prin protocoalele și metodele de lucru create.

### 6.1 Achiziția semnalului din plâns cu instrumente profesionale

Analiza „cuvintelor” din semnalul de plâns, constă în extragerea și urmărirea unor formațiuni asemănătoare limbajului matur care pot fi astfel categorisite ca și cuvinte, propoziții și fraze ale semnalului vocal generat. Se va considera în continuare, asemenea reprezentării din Figura 6.1:

- **plânsul pe un expir** echivalentul unui **cuvânt**;
- **o repriză de plâns** care cuprinde mai multe cuvinte ca reprezentând o **propoziție**;
- **mai multe reprize** surprinse într-o înregistrare continuă în intervalul 120 – 180 de secunde ca formând o **frază**.




Figura 6.1 Cuvânt, propoziție și frază pe o înregistrare de plâns



În vederea studierii mai în detaliu a semnalului din plâns se pot urmări unitățile mai mici din care acesta se constituie. Se poate astfel realiza o analiză lexicală a plânsului ca semnal vocal în care unitățile constituente reprezintă cuvinte, propoziții și fraze. Pentru a surprinde subdiviziunile menționate anterior și a le delimita în mod cât mai corect este necesar un instrument de achiziție și redare cu fidelitate foarte ridicată. S-a recurs astfel la utilizarea unui instrument profesional de achiziție audio, constând în echipamentul *Olympus LS-100 PCM Multi-Track Recorder*, prezentat în Figura 6.2.



**Figura 6.2 Dispozitivul Olympus LS-100 PCM Multi-Track Recorder**

În analizele din paragrafele următoare, în care studiile s-au concentrat asupra formațiunilor constituente ale semnalului din plâns, s-a efectuat izolarea unei propoziții sau a unui cuvânt din întregul semnal.

Caracteristicile principale ale dispozitivului de achiziție audio constă în următoarele:

- Sistem de două microfoane încorporate, de înaltă sensibilitate, a căror poziționare este prin construcție pe o direcție la 90 de grade;



**Figura 6.3 Poziționarea la 90° a microfoanelor încorporate**

- Înregistrare necomprimată a semnalului audio și reprezentarea amplitudinii pe 24 bit la o frecvență de eșantionare maximă de 96 kHz;
- Partea de achiziție audio și circuitul electric al sistemului sunt separate în vederea minimizării degradării sunetului;
- Filtru trece jos activabil pentru eliminarea frecvențelor joase ce variază între 100Hz și 300Hz;
- Spațiu dedicat de stocare intern auxiliar pentru preînregistrare care captează 2 secunde de sunet înaintea începerii înregistrării propriu-zise;
- Posibilitatea începerii înregistrării când sunetul ajunge la un anumit nivel;

- Memorie flash NAND de 4GB încorporată;
- Frecvența de eșantionare aleasă pentru PCM: 96 kHz
- Caracteristici de frecvență în intervalul: 20 – 20.000 Hz.

## 6.2 Testarea și calibrarea dispozitivului de achiziție a semnalului din plâns

În vederea realizării unui studiu în cadrul căruia se dorește evaluarea celor achiziționate atât din punct de vedere calitativ cât și cantitativ este necesară testarea și eventual calibrarea aparatului care realizează măsurătorile. Pentru studiul de față, dispozitivul Olympus a fost supus unei serii de teste în vederea validării rezultatelor achiziției, operațiunile întreprinse fiind următoarele:

- Generarea unui semnal prin intermediul unui generator de semnal dedicat având o amplitudine configurabilă, cunoscută și o frecvență fundamentală ( $F_0$ ) în domeniul audibil (16Hz - 20 kHz). Acestea pot fi vizualizate cu utilizarea unui osciloscop.
- Transformarea semnalului generat în semnal audibil prin utilizarea unui amplificator care se conectează la un difuzor ce are caracteristica de transfer cunoscută prin date de catalog oferite de producător, sau determinabilă experimental.
- Semnalul audio rezultat este înregistrat cu dispozitivul de achiziție Olympus pentru care setările disponibile utilizatorului sunt cunoscute (filtrele active, amplificare internă).

Operațiunile menționate sunt creionate grafic în Figura 6.4, prezentată mai jos.


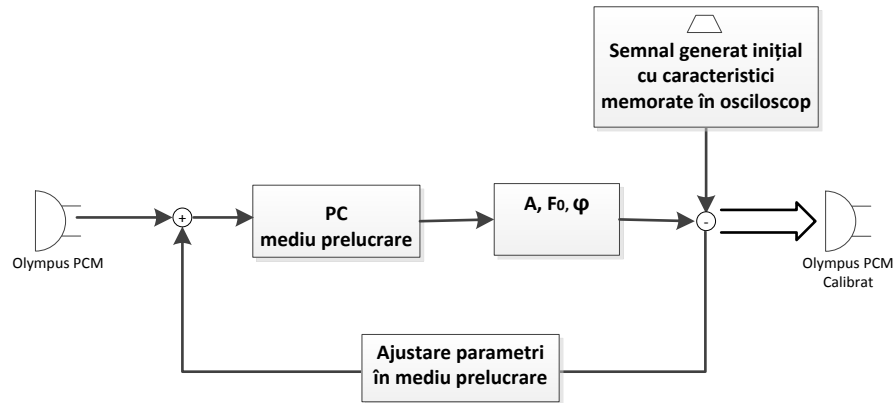


Figura 6.4 Testarea echipamentului Olympus


- Pentru verificarea preciziei achiziției, următoarea operație este reprezentată de transferul semnalului audio înregistrat cu dispozitivul de achiziție Olympus într-un mediu de prelucrare și extragere a caracteristicilor semnalului pe PC. Semnalul transferat se compară cu cel generat inițial, și care se află în forma reprezentată, în memoria osciloscopului. Prin compararea parametrilor celor două semnale, frecvență fundamentală, amplitudine sau fază, se poate realiza recalibrarea aparatului prin alegerea unei configurații diferite de a dispozitivului de achiziție Olympus, astfel încât caracteristicile semnalului generat să se regăsească în cel achiziționat (Figura 6.5).



**Figura 6.5 Schema de calibrare a echipamentului de achiziție Olympus PCM**

În vederea realizării calibrării conform celor specificate s-au generat o serie de semnale de test cu diferite caracteristici. Semnale generate au fost periodice, fiind reprezentate de cel dreptunghiular și cel sinusoidal, la diverse amplitudini și frecvențe fundamentale.


Pentru a oferi un exemplu asupra testelor efectuate vor fi prezentate în cele ce urmează detalii cu semnalul de test sinusoidal care a fost produs cu ajutorul generatorului de semnal *Sinometer YB1620A*. Semnalul sinusoidal prezentat prin captura de ecran a osciloscopului în Figura 6.6 a fost generat cu amplitudinea în tensiune de 600mV și o frecvență de fundamentală de 1.007Hz.



**Figura 6.6 Semnalul generat și stocat în memoria osciloscopului**


În Figura 6.7 este prezentat spectrul semnalului achiziționat de dispozitivul Olympus cu marcarea prin bara verticală albastră a frecvenței dominante a semnalului. Spectrul a fost obținut prin aplicarea FFT asupra înregistrării semnalului

audio generat. Frecvența dominantă corespunde frecvenței fundamentale a semnalului generat, valoarea acesteia, de 1007Hz regăsindu-se cu energia cea mai însemnată.



**Figura 6.7 Frecvența fundamentală a semnalului sinusoidal achiziționat cu Olympus PCM**

În Figura 6.8 se poate sesiza o întârziere inițială de 200 ms prin urmărirea barei orizontale în zona superioară unde este afișat timpul înregistrării. Această constatare se regăsește și în datele altor studii efectuate asupra reportofonului, dar și în datele de catalog ale acestuia [80].



**Figura 6.8 Evidențierea unei latențe inițiale de 200 ms**

Pentru testarea acurateții semnalului achiziționat cu dispozitivul Olympus au fost generate două tipuri de semnale: unul sinusoidal și unul dreptunghiular. Pentru fiecare din aceste semnale au fost configurate valori diferite ale frecvenței fundamentale, urmărindu-se apoi comparativ valoarea achiziționată. Valoarea achiziționată a fost determinată prin utilizarea unei aplicații externe care produce, ca și rezultat, spectrul unui semnal audio oferit la intrare. Din perspectiva studiului întreprins, valorile frecvenței fundamentale a semnalului achiziționat în fiecare caz și

amplitudinea semnalului au constituit elementele de interes. În Tabel 6.1 sunt oferite, ca și comparație, valorile de frecvență și amplitudine pentru semnalele generate, respectiv valorile extrase din semnalul achiziționat.

**Tabel 6.1 Sinteza măsurărilor semnalului generat și a celui achiziționat**

Tip semnal generat	Interval frecvență fundamentală semnal generat [Hz]	Frecvență fundamentală semnal achiziționat [Hz]	Amplitudine semnal generat [mV]	Amplitudine semnal achiziționat [mV]
Sinusoidal	[1.007 – 1.008]	1.007	302	116.8
	[2.992 – 2.999]	2.994	302	116.8
	[5.002 – 5.010]	5.003	302	116.8
Dreptunghiular	[1.008 – 1.009]	1.008	466	143.1
	[3.022 – 3.051]	3.028	466	143.1
	[5.040 – 5.056]	5.044	466	143.1

În realizarea calculului amplitudinii semnalului achiziționat s-a ținut cont de amplitudinea semnalului generat ca fiind cunoscută (urmare a setării în cadrul generatorului de semnal), iar amplitudinea semnalului achiziționat s-a determinat matematic prin cunoașterea valorii în decibeli a amplitudinii sunetului achiziționat ( $x_{dB}$ ).

$$x_{dB} = 20 \lg \frac{U}{U_0},$$

unde  $U$  – tensiunea măsurată și  $U_0$  – tensiunea de referință

$$\text{Rezultă astfel: } U = 10^{\frac{x_{dB} + 20 \lg U_0}{20}}$$

### 6.3 Experimentele cu dispozitivul Olympus și echipamentul medical INVOS

Echipamentul medical *INVOS 5100C* este un oximetru cerebral și somatic care ajută la determinarea non invazivă a riscului ischemic (deficitul local de sânge) la creier sau organe vitale, prin măsurarea oxigenării hemoglobinei chiar sub senzorii acestui dispozitiv, pe zona monitorizată. Acesta generează un parametru măsurabil, rSO2 (*regional hemoglobin oxygen saturation*) care reprezintă valoarea evaluată la nivel venos a oxigenului din hemoglobină rămas după irigarea țesuturilor [81]. Dispozitivul este unul din cele patru dispozitive de oximetrie cerebrală admise de organismul de control din S.U.A, FDA (*U.S Food and Drug Administration*) [82]. În studiul realizat, echipamentul *INVOS 5100C* a fost utilizat exclusiv ca oximetru cerebral, astfel că în paragrafele următoare oximetria somatică nu va fi detaliată.

Oximetria cerebrală are o istorie relativ scurtă, datând de trei decenii, însă doar în ultimii 20 de ani a devenit disponibilă pentru uzul clinic. Aceasta estimează oxigenarea anumitor zone de țesut prin măsurători transcutanate ale cortexului cerebral, unde de regulă se manifestă schimbări ale cererii și aprovizionării cu oxigen. Măsurătorile se bazează pe abilitatea luminii de a penetra scalpul și determinarea oxigenării hemoglobinei pe baza cantității de lumină absorbită de hemoglobină, proces denumit ca spectroscopie în infraroșu apropiat (*NIRS – Near*

*Infrared Spectroscopy*). În timp ce majoritatea aparatelor medicale tradiționale reflectă starea în întregime a corpului uman, în cazul echipamentului *INVOS* și al parametrului măsurat  $rSO_2$ , se oferă informație localizată, în timp real și continuă.


Aparatul medical *INVOS* dispune în vederea efectuării măsurărilor de o extensie cu plasture care se aplică pe craniul pacientului și care conține un emițător de lumină în infraroșu apropiat și doi senzori care recepționează lumina reflectată în urma trecerii de craniu și prin țesutul cerebral. Aplicarea acestui plasture și elementele prezentate sunt vizualizabile în Figura 6.9 [82].

În calculul oxigenării la nivel cerebral, toate dispozitivele utilizează următoarea formulă de calcul [83]:

$$\text{Oxigenarea cerebrală [\%]} = \text{HbO}_2 / (\text{Hb} + \text{Hb O}_2)$$

unde:

- Hb reprezintă nivelul hemoglobinei deoxygenate
- HbO<sub>2</sub> corespunde nivelului de hemoglobină oxigenată



**Figura 6.9 Senzorii *INVOS* și aplicarea lor pe capul nou-născutului**

Scăderea rezervei venoase de oxigen indică un risc ischemic ridicat și o perfuzare deficitară a țesutului în timp ce creșterea mult peste nivelul mediu al saturației de bază (referință, *baseline*) poate determina o inundare a țesutului care poate cauza distrugerea unor terminații nervoase. Astfel de interpretări oferă o indicație utilă echipei medicale pentru necesitatea intervenției.

Un aspect important al parametrului măsurat,  $rSO_2$  constă în dependența slabă a acestuia de parametri fiziologici, lucru care este extrem de util în cadrul studiilor medicale în care indivizii prezintă diverse particularități care pot afecta concluziile cercetării. Mai precis, valoarea de  $rSO_2$  este independentă de:

- Sex;
- Greutate;
- Înălțime;

- Dimensiunea cavității cefalice.

Dispozitivul *INVOS* dispune de un soft dedicat în vederea exportării și prezentării celor măsurate. În urma realizării unei colectări de date pot fi vizualizate mai apoi, în mod grafic, evoluția parametrului rSO<sub>2</sub> în timp, evenimentele externe care au fost marcate în timpul măsurărilor (setarea valorii de referință sau *baseline*, evenimentele invazive cum ar fi recoltarea sau evenimentele observabile care sunt predefinite în cadrul meniului echipamentului).

## 6.4 Prezentarea studiului și a protocolului de lucru

Studiul ce urmează a fi detaliat a avut ca scop principal urmărirea modificării saturației la nivel cerebral cu ajutorul dispozitivului *INVOS* ca urmare a recoltării de sânge de la nou-născut și corelarea acesteia cu plânsul dureros al acestuia achiziționat cu aplicația *Neonat*, dar și cu echipamentul *Olympus LS-100*.

**Acest studiu a fost realizat exclusiv pe nou-născuți care necesitau recoltarea, nedorindu-se efectuarea de teste invazive decât în cazul în care acestea erau solicitate de către cadrele medicale, iar recoltarea propriuzisă a fost deasemenea realizată de personal medical specializat.**

În Figura 6.10 este prezentată imaginea sistemului de achiziționare în timpul realizării unui experiment în cadrul căruia nou-născutul este conectat la echipamentul *INVOS* pentru măsurarea saturației la nivel cerebral (se pot observa senzorii atașați pe fruntea nou-născutului). În timpul recoltării probelor de sânge, plânsul este achiziționat prin intermediul dispozitivului *Olympus* (în stânga imaginii la o distanță de aproximativ 30cm de gura nou-născutului) și al aplicației *Neonat* în vederea vizualizării în timp real a formei de undă și a spectrului semnalului. În cadrul aplicației *Neonat* preluarea semnalului vocal se realizează prin ajutorul microfonului aflat în imediata vecinătate a dispozitivului *Olympus*.



**Figura 6.10 Experiment: echipamentul *INVOS*, aplicația *Neonat* și dispozitivul *Olympus***

Recoltările sangvine postnatale sunt efectuate pentru fiecare nou-născut. Practica medicală obligă la realizarea a cel puțin unui astfel de test pentru nou-născuți, testul Guthrie care presupune recoltarea prin întepare a patru picături de sânge din călcâiul nou-născutului în vederea depistării afecțiunii denumite fenilcetonuria [84], [85]. Acest test, presupus ca fiind foarte puțin invaziv, nu este

singurul realizat în cazul în care există anumite suspiciuni privitoare la posibile patologii ale nou-născutului. În acest caz se efectuează și alte recoltări, de această dată din scalp sau din braț, care sunt deasemenea invazive producând și durere crescută nou-născutului.

Dispozitivul *INVOS* are ca principal mod de întrebuințare urmărirea modificărilor parametrului  $rSO_2$  în timp, monitorizarea putând fi de ordinul orelor [86]. Echipamentul furnizează, prin colectarea de valori de la senzori, măsuri ale saturației cerebrale la fiecare 5 secunde. În cadrul studiului de față s-a dorit evidențierea schimbărilor iminente de saturație cerebrală ca urmare a unei analize invazive bazate pe achiziția în tot acest timp a semnalului vocal din plâns. Durata monitorizării în acest scenariu fiind de ordinul a 2-3 minute. Date fiind aceste aspecte devine foarte importantă sincronizarea mai multor evenimente: stabilirea unei valori de referință pentru saturația cerebrală a fiecărui nou-născut analizat, evidențierea evenimentelor invazive atât pe echipamentul *INVOS* cât și în cazul plânsului provocat. Colectarea informației cu echipamentul *INVOS* se realizează pe un singur canal al acestuia.

Protocolul pentru realizarea studiului, rafinat în urma experienței dobândite pe parcursul realizării acestuia presupune urmarea unei succesiuni de pași:

1. Sincronizarea reportofonului cu aplicația Neonat prin pornire simultană și setarea în concomitent a valorii de referință (*baseline*) pentru oximetrul cerebral
  - a. Asocierea momentului de timp pentru aceste acțiuni, ștampila temporală (data, ora, minutul și secunda)
2. Marcarea recoltării
  - a. Setare eveniment prin display-ul oximetrului cerebral
  - b. Semnal acustic scurt pentru dispozitivul de achiziție a sunetului și aplicația Neonat
  - c. Asocierea momentului de timp pentru acțiuni, ștampila temporală
  - d. Reținerea tipului de recoltare (craniană, din braț sau din câlcâi)
3. Sincronizare oprire
  - a. Oprise concomitentă *INVOS*, oprirea dispozitivului de achiziție a sunetului și aplicația Neonat

## 6.5 Rezultatele studiului

În alineatele următoare se vor prezenta rezultatele studiului realizat, oferindu-se un exemplu sugestiv pentru situațiile întâlnite. Alegerea acestui nou-născut în vederea exemplificării nu este aleatorie. Cazul prezentat a suscitat interes prin prisma scăderii la o valoare sub 50% a saturației cerebrale, iar pe partea de semnal de plâns au fost sesizate valori foarte mari ale frecvenței dominante. Ulterior, cazul prezentat a fost diagnosticat cu suferință neurologică ca urmare a unor investigații suplimentare efectuate. Deși nu constituia un obiectiv al prezentului studiu, diagnosticul suferinței nefiind luat în calcul, acest rezultat deschide o direcție ulterioară de cercetare în vederea corelării suferinței neurologice cu variația parametrului de saturație cerebrală,  $rSO_2$ .

În Figura 6.11 este prezent graficul evoluției saturației oxigenului la nivel cerebral ( $rSO_2$ ) în timpul realizării unei recoltări la unul din nou-născuți. Se observă marcarea evenimentelor "Set Baseline" respective "Heel prick/Lab draw" aferente momentelor setării valorii de referință a parametrului  $rSO_2$  și momentul înțepării nou-născutului în vederea recoltării de sânge. Linia verticală de culoare roșie este



reprezentată de cursorul de baleiere a valorilor saturației, fiind poziționat la valoarea minimă a acestora pe întreaga durată a monitorizării.




Figura 6.11 Exemplu de nou-născut cu scădere a parametrului rSO2 sub limita admisibilă

În protocolul prezentat anterior s-a menționat achiziția semnalului din plâns concomitent cu colectarea informației asupra saturației. În Figura 6.12 este prezentat semnalul din plâns (achiziționat în paralel cu măsurătorile saturației ca în Figura 6.11) care debutează odată cu setarea valorii de referință în echipamentul *INVOS*. Durata înregistrării vocale nu este fixă, aceasta variind în funcție de pacient. Regula de oprire este dată de creșterea treptată a saturației către valoarea de referință, după atingerea unui minim general, sau revenirea la valoarea de referință după creșteri sau descreșteri ale valorii curente.

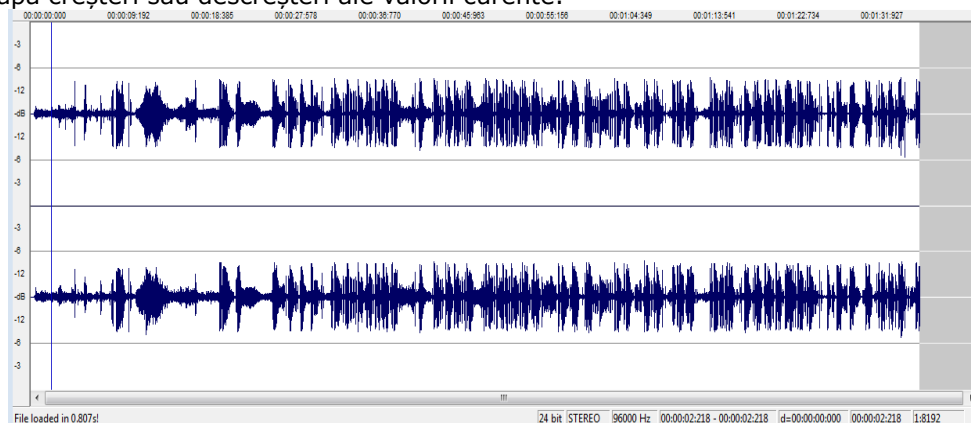




Figura 6.12 Semnalul din plâns în timpul monitorizării cu *INVOS* (Figura 6.11) la recoltarea unui nou-născut

În Figura 6.13 se redă spectrul de frecvențe al semnalului din plâns pe intervalul de interes, astfel încât să fie surprins momentul înțepării (evidențiat în spectru) și momente premergătoare și ulterioare acestuia.




**Figura 6.13** Spectrul de frecvență aferent semnalului din plâns din Figura 6.12

Având dispozitivele din acest studiu, sincronizate, s-a putut observa că odată cu apariția primului cuvânt din plâns se declanșează și scăderea saturației la nivel cerebral. Acest aspect este firesc și explicabil din punct de vedere medical, prin mecanismul producerii plânsului care presupune un inspir mai puternic decât unul obișnuit urmat de un expir mai îndelungat care poate cauza o mică insuficiență de oxigen pe o perioadă scurtă. Cu toate acestea, valori foarte scăzute ale saturației pot deveni extrem de periculoase, astfel că este de mare interes urmărirea acestuia prin parametrul  $rSO_2$ . În vederea analizării în detaliu a primului cuvânt din plâns, a fost realizată extragerea acestuia din întreg semnalul (Figura 6.14). Extragerea cuvintelor din întreg semnalul de plâns reprezintă o operațiune realizată pentru fiecare înregistrare din acest studiu, cu scopul analizării individuale a fiecărei asemenea entități constitutive ale plânsului.



**Figura 6.14** Primul cuvânt după recoltarea din braț


Spectrul de frecvențe corespunzător cuvântului din plâns din Figura 6.14 este redat în Figura 6.15. Acest spectru este sugestiv din punctul de vedere al similitudinilor pe care acesta le are cu spectrele primelor cuvinte după înțepare provenite de la alți nou-născuți, unde a fost observată o scădere mare a saturației cerebrale. Aspectul comun este reprezentat de o frecvență dominantă în jurul valorii de 1KHz și lipsa totală de energie pe frecvențe în intervalul 400Hz-600Hz, unde în secvențe de plâns neprovocat (sau nedureros) se regăsește frecvența dominantă (sau fundamentală) plânsului nou-născuților considerați în studiu.



**Figura 6.15** Spectru frecvență pe cuvânt la durere

Din punctul de vedere al evoluției parametrului de saturație rSO<sub>2</sub> s-a realizat o statistică a variației maxime a acestuia. Astfel, pentru fiecare nou-născut considerat în studiul de față și pentru care au fost respectați toți pașii din protocolul convenit, neînregistrându-se erori, s-au consemnat valorile maxime de deviație de la valoarea nominală (de *baseline*) a parametrului de saturație. În Figura 6.16 se

regăsesc aceste deviații maxime ale saturației pentru fiecare nou-născut considerat, barele roșii fiind corespunzătoare descreșterilor în saturație, iar cele albastre creșterii parametrului rSO<sub>2</sub>.



**Figura 6.16** Valorile maxime de deviație a saturației la fiecare nou-născut din studiu

Majoritatea situațiilor prezentate surprind scăderi ale valorii saturației cerebrale, unele la valori de peste 25%. Această scădere poate deveni periculoasă dacă este de durată semnificativă (peste 20 de secunde) și la valori mici, de sub 50%. Saturația nominală pentru nou-născuți se consideră în jurul valorii de 90% sau valori foarte apropiate de aceasta. La valori nominale în jurul valorii de 70%, pentru care se constată scăderi mari ale saturației, precum unele din Figura 6.16 unde sunt reale semnale de alarmă privind riscul lezionării cerebrale a nou-născutului în timpul recoltării. Există studii medicale ce vizează pericolul invaziv al recoltării mult prea îndelungate, studiul de față venind să întărească aceste îngrijorări.

Figura 6.16 surprinde și situații de creștere a nivelului saturației. Dat fiind că stimulul dureros (înțeparea și recoltarea) provoacă plânsul dureros care automat duce la o desaturare la nivel cerebral, aceste situații au fost considerate ca fiind particulare, neputându-li-se atribui pentru moment o explicație din punct de vedere medical.

## 6.6 Studiul suferinței neurologice

În cadrul analizei cuvintelor din plânsul nou-născuților, au fost realizate și alte investigații în care nu a fost implicată și aparatură medicală, ca în cazul studiului precedent, ci doar plânsul provenit de la nou-născuți. Astfel, pe baza

diagnosticului medical aprioric, au fost investigate semnale de plâns aferente nou-născuților cu diferite afecțiuni printre care și suferința neurologică. Studiul suferinței neurologice, având ca suport plânsul neprovocat, va fi detaliat în cele ce urmează.

În faza inițială a acestui studiu a fost analizat plânsul provenit de la 45 de nou-născuți care a fost colectat în cadrul spitalului Clinic de Urgență pentru Copii Louis Țurcanu, Timișoara. Ulterior acestui prim lot și având la bază și o serie de rezultate preliminare, i-au fost adăugate și alte înregistrări în vederea validării rezultatelor și metodei utilizate, ajungându-se la un lot total de 120 de subiecți. Acest lot a fost compus din nou-născuți cu suferință neurologică de diverse grade, în număr de 40, în timp ce restul de 80 a fost reprezentată majoritar de nou-născuți la termen și sănătoși dar și câteva cazuri de nou-născuți prematuri sau cu alte afecțiuni, diferite însă de suferința neurologică. Scopul acestei grupări a fost în a determina particularități în plâns, exclusiv pentru suferința neurologică, comparativ cu orice alt tip de suferință sau deopotrivă, stare fizică și mentală normală.

Spitalul Clinic de Urgență pentru Copii „Louis Țurcanu” este o unitate medicală dedicată nou-născuților prematuri sau cu patologii severe care necesită spitalizare îndelungată, colectând o bună parte din cazurile grave de la alte maternități locale. Din rațiuni de mobilitate și lipsa unei zone dedicate pentru efectuarea înregistrărilor, colectarea semnalelor vocale a fost realizată exclusiv cu dispozitivul de achiziție, *Olympus LS-100*.

În cadrul acestui studiu, care a constat în investigarea unor structuri din plâns, reprezentate de cuvinte au fost trasate o serie de reguli pentru alegerea acestor cuvinte din plâns. Astfel au fost considerate:

- Cuvinte de lungime mai mare de 0.5 s – deoarece sunt structuri bine definite din plâns sesizabile și de urechea umană;
- Cuvinte vocalizate pe expir – ca urmare a detectării unor structuri vocale și pe inspir, pentru acest studiu acestea nu au fost luate în considerare;
- Stimulare nedureroasă – pentru a evita scăderi de saturație precum cele sesizate în studiul precedent și care modifică evident cuvintele de plâns.

Din cuvintele extrase după regulile prezentate mai sus au fost construite mulțimi, pentru fiecare subiect din studiu constând în cuvintele extrase dintr-o singură înregistrare dar și parametri fiziologici ai acestuia la naștere, precum și diagnosticul medical asociat.

În analiza cuvintelor din plâns au fost încercate diverse abordări în vederea determinării unor similitudini între nou-născuții diagnosticați cu suferință neurologică și restul subiecților considerați pentru studiu. În acest sens au fost extrași diferiți coeficienți din plâns și aplicate diferite metode în vederea determinării unor aspecte comune a celor din grupul nou-născuților diagnosticați cu suferință neurologică. În cele ce urmează vor fi enumerate o parte din metodele utilizate, dar care nu au oferit rezultate satisfăcătoare. Va fi considerat ca exemplu pentru fiecare din metode un cuvânt aparținând unui nou-născut cu suferință neurologică în Figura 6.17. Cuvântul este vizualizat ca înregistrare pe fiecare din cele două canale de achiziție ale dispozitivului de înregistrare, iar în alineatele următoare metodele sunt aplicate pe media celor două canale.




Figura 6.17 Cuvânt aparținând unui nou-născut cu suferință neurologică

- Coeficienții Mel cepstrali ai cuvântului din plâns (Figura 6.17) suprapuși pe forma de undă) se regăsesc în Figura 6.18. S-a încercat realizarea unei clasificări pe baza coeficienților Mel cepstrali extrași din cuvintele nou-născuților cu suferință neurologică și a restului de lot. Clasificarea a generat rezultate nesatisfăcătoare, adică o rată de clasificare corectă mai mică de 50% astfel că rezultatele și procedeele nu vor mai fi detaliate;


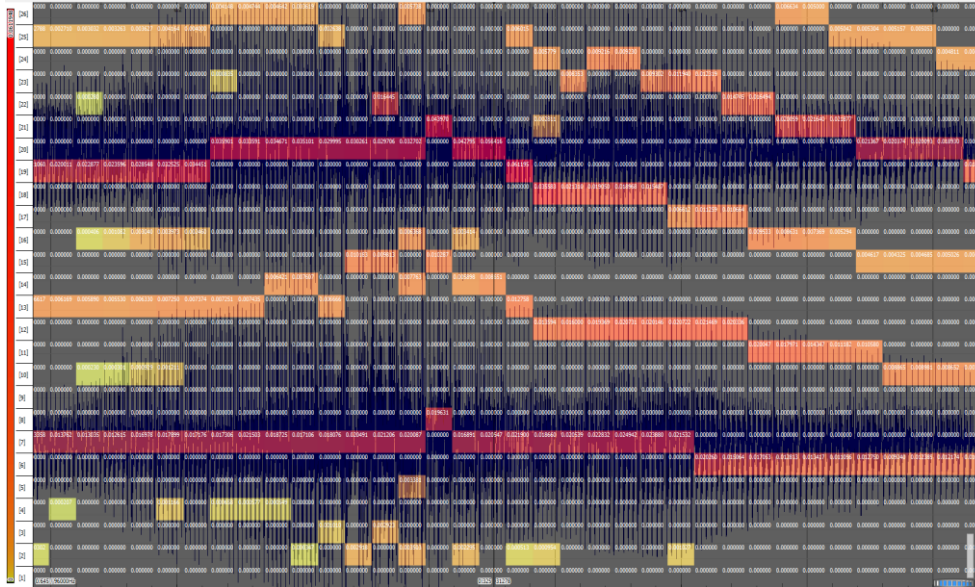


Figura 6.18 Coeficienții Mel cepstrali suprapuși peste forma de undă


- Coeficienții Bark ai cuvântului din plâns (din Figura 6.17), vizualizați și ei ca suprapunere peste forma de undă în Figura 6.19 pentru care

s-a optat deasemenea pentru realizarea clasificării, rezultatele fiind și în acest caz nesatisfăcătoare pentru a detalia metoda.




**Figura 6.19** Coeficienții Bark suprapuși peste forma de undă

- Analiza frecvenței fundamentale folosind metoda autocorelației (Figura 6.20) prin care s-a încercat, asemenea studiului precedent, determinarea unor intervale de valori în care să fie încadrați subiecții celor două mulțimi considerate. Metoda este utilă pentru o aproximare bună a frecvenței fundamentale a plânsului care prezintă utilitate în tandem cu transformata wavelet discretă.



**Figura 6.20** Funcția de autocorelația aplicată cuvântului din plâns (Figura 6.17)

- Transformata wavelet discretă reprezintă metoda care pentru studiul de față generează observațiile care servesc cel mai bine identificării suferinței neurologice din cuvinte ale nou-născutului. În Figura 6.21 se regăsesc coeficienții generați de aplicarea transformatei wavelet discrete pe cuvântul din plâns prezentat și în exemplele precedente. Detalierea metodei utilizate realizându-se în paragrafele ce urmează.



**Figura 6.21** Transformata wavelet discretă aplicată pe cuvântul din plâns din Figura 6.17

## 6.7 Analiza suferinței neurologice cu aplicarea transformatei wavelet discrete

Transformata *wavelet* reprezintă o alternativă la transformata Fourier în ceea ce înseamnă descompunerea unui semnal într-o serie de semnale constitutive mai simple. Marele aport al *wavelet*-urilor în analiza semnalelor îl reprezintă păstrarea informației temporale alături de cea de frecvență în studiul semnalelor complexe. Aspectul negativ al transformatei Fourier, care deși oferă o rezoluție foarte bună în domeniul frecvență este că îl pierde pe cel temporal [87], [88], [89], [90].

Semnalele biomedicale precum electromiograma (EMG), electrocardiograma (ECG) sau electroencefalograma (EEG) beneficiază de tehnici de analiză multirezoluție, cum este și transformata *wavelet* [88], [91]. Metoda transformatei *wavelet* este aplicată în două forme: transformata *wavelet* continuă (Continuous Wavelet Transform – CWT) și transformata *wavelet* discretă (Discrete Wavelet Transform - DWT). Alegerea în studiu a transformatei wavelet discrete se datorează utilizării acestei metode în aplicațiile în timp real cu performanțe caracterizate prin viteza sporită de obținere a coeficienților finali. În cele ce urmează se va detalia metoda aplicată, care a generat reprezentările coeficienților *wavelet* cu cel mai important impact vizual în diferențierea unor cuvinte provenite de la nou-născuți diagnosticați cu suferință neurologică, față de restul nou-născuților.

În vederea obținerii coeficienților transformatei wavelet discrete se pornește cu segmentarea semnalului, adică divizarea acestuia în calupuri egale, cu excepția ultimului segment care poate avea o dimensiune mai mică, dependentă de lungimea semnalului analizat. Suprapunerea ferestrelor din algoritmul Fourier în vederea



conferirii continuității analizei semnalului de intrare se aplică și în cazul obținerii transformatei *wavelet* discrete. Aici, segmentele rezultate din prima etapă sunt extinse la stânga și respectiv dreapta cu valori nule și de dimensiune variabilă. Detaliile asupra acestor operațiuni și fundamentul matematic nu vor fi detaliate în lucrarea de față, ele fiind riguros dezbătute în articolul de referință [92] și al creatorilor transformatei *wavelet* segmentate, *SegWT*, în lucrarea [93].

Etapa clasică a transformatei *wavelet* discrete este constituită de filtrarea segmentelor create și extinse în pașii anteriori. Acestea sunt trecute concomitent printr-un filtru trece jos (FTJ) și un filtru trece sus (FTS), ilustrat în Figura 6.22.

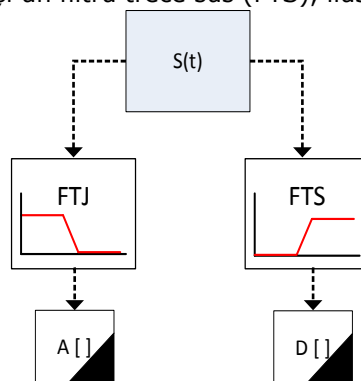


Figura 6.22 Filtrarea semnalului segmentat

Algoritmul utilizat în studiu realizează o transformare *wavelet* discretă directă (*forward DWT*) peste „cuvântul” primit la intrare. În Figura 6.23 este prezentată o schema de filtrare peste întreg semnalul de plâns, în vederea obținerii coeficienților *wavelet* care ulterior vor fi reprezentați. Utilitatea filtrelor este dată de dorința de eliminare a fluctuațiilor la frecvențe înalte, în cazul aplicării FTJ, cu scopul conservării tendințelor de modificare mai lentă. FTS elimină în schimb tendințele de modificare mai lentă, păstrând doar fluctuațiile la frecvențe înalte. Ieșirile celor două tipuri de filtre (A respective D) conferă o informație detaliată asupra semnalului de la intrare.

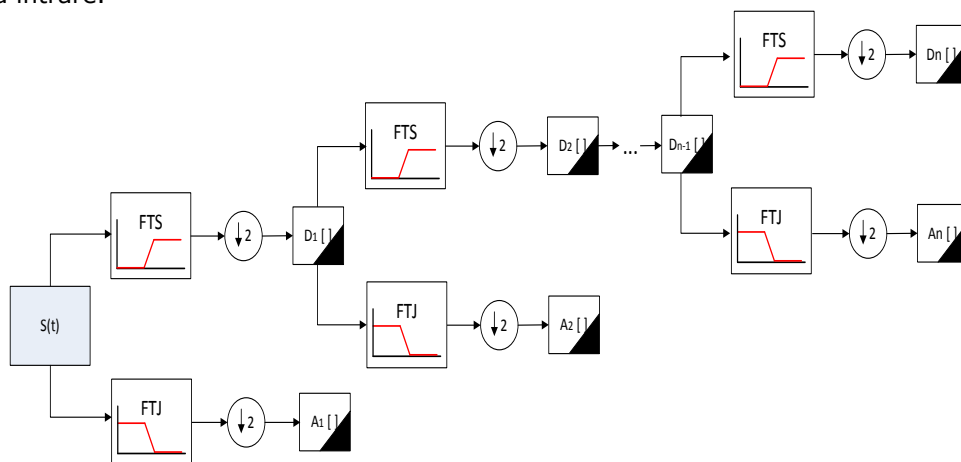
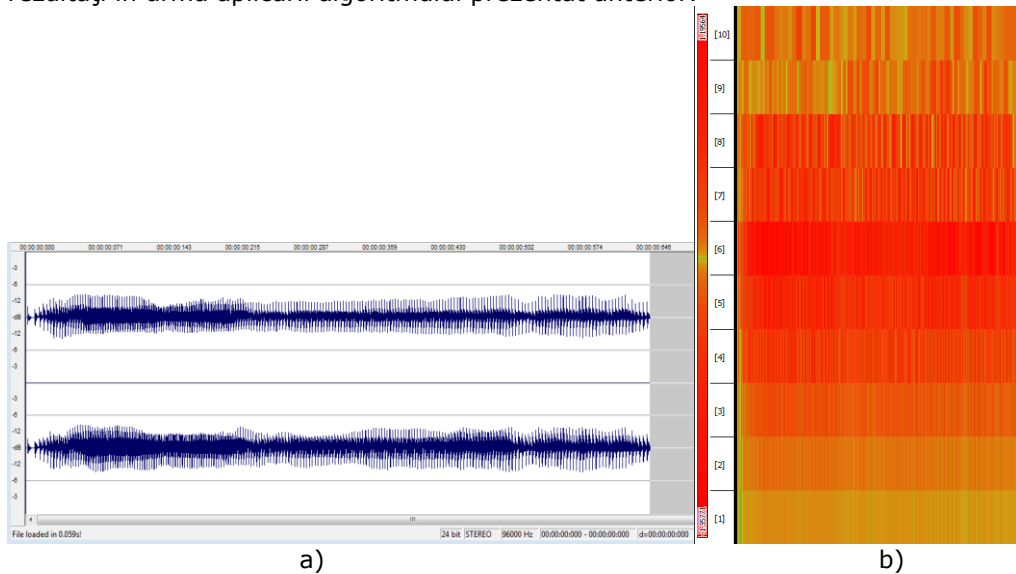


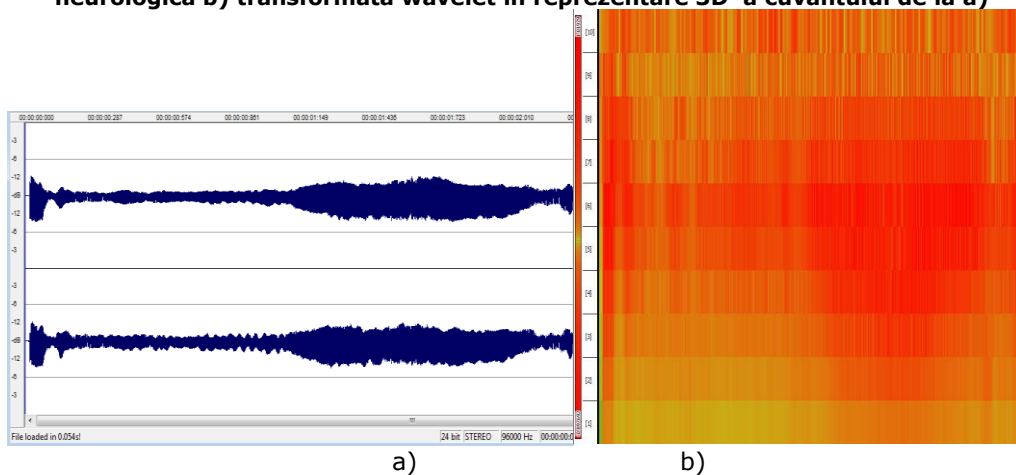
Figura 6.23 Eșantionarea diadică peste întreg cuvântul din plâns

Coeficienții wavelet sunt returnați ca vectori coloană la jumătatea frecvenței de eșantionare a semnalului analizat. Pentru simularea multi-rezoluției, în tabela de date din algoritm, coeficienții la o scară mai mare sunt copiați de mai multe ori corespunzător valorii scării (pentru o scară de 2, fiecare valoare va apărea de două ori, la o scară de trei aceștia vor apărea de patru ori în timp ce la o scară de patru aceștia vor fi multiplicați de opt ori în vederea simulării rezoluției mai slabe la scară mai mare).

În Figura 6.24 a) și Figura 6.25 a) sunt prezentate cuvinte singulare aparținând unor nou-născuți distincți, diagnosticați în prealabil cu suferință neurologică. Figura 6.24 b) și Figura 6.25 b) oferă reprezentarea coeficienților rezultați în urma aplicării algoritmului prezentat anterior.




**Figura 6.24 a) Cuvânt extras din plâns pentru nou-născut (ID\_SN\_3) cu suferință neurologică b) transformata wavelet în reprezentare 3D a cuvântului de la a)**




**Figura 6.25 a) Cuvânt extras din plâns pentru nou-născut (ID\_SN\_27) cu suferință neurologică b) transformata wavelet în reprezentare 3D a cuvântului de la a)**

În Figura 6.26 a) este oferit, în reprezentare a ambelor canale, cuvântul aparținând unui nou-născut sănătos, iar Figura 6.26 b) oferă reprezentarea coeficienților generați de algoritmul transformatei wavelet discrete, aplicat peste media celor două canale.




**Figura 6.26** Cuvânt extras din plâns pentru nou-născut (ID\_N\_3) fără afecțiune b) transformata wavelet în reprezentare 3D a cuvântului de la a)

În Figura 6.27 și Figura 6.28 sunt evidențiate frecvențele dominante din spectrul de frecvență a cuvintelor din Figura 6.24 a) și Figura 6.25 b). Deși cuvintele provin de la doi născuți distincți, însă amândoi diagnosticați cu suferință neurologică, valorile frecvențelor dominante se situează ambele în jurul valorii de 1320Hz care reprezintă o valoare extremă în contextul unui plâns neprovocat, a cărui plajă de valori este considerată în intervalul [400Hz-600Hz] cu eventuale abateri la limita superioară a acestui interval de 100Hz, 200Hz.




**Figura 6.27** Spectru de frecvență a întregului cuvând din Figura 6.24



**Figura 6.28** Spectru de frecvență a întregului cuvânt din Figura 6.25

Analiza sunetelor prin aplicarea transformatei wavelet discrete, fiind o metodă de tip multi-rezoluție, simulată și în cadrul algoritmului aplicat, permite păstrarea componentei temporale la generarea vizualizărilor. Devine astfel posibilă o reprezentare precum cea din Figura 6.29, în care cuvântul din plâns este suprapus peste reprezentarea coeficienților transformatei, evidențiindu-se maparea între valorile coeficienților rezultați și forma de undă a semnalului din cuvântul din plâns.



**Figura 6.29** Cuvântul din plâns peste reprezentarea transformatei wavelet discrete a cuvântului (nou-născutul diagnosticat cu suferință neurologică ID\_SN\_11)

## 6.8 Concluzii parțiale

În cadrul acestui capitol au fost realizate analize asupra unor formațiuni extrase din plâns, denumite „cuvinte”. Au fost realizate două tipuri de studii care s-au concentrat fiecare pe analiza cuvintelor provenite din plâns:

- Studiul variației saturației cerebrale cu echipamentul INVOS și achiziția plânsului cu dispozitivul Olympus, precumși monitorizarea în timp real a caracteristicilor de plâns cu aplicația Neonat, la recoltarea de sânge de la nou-născut, obținându-se:
  - Un protocol pentru efectuarea corectă a achiziției tuturor parametrilor de interes: saturația rSO<sub>2</sub>, valoarea frecvenței dominante în jurul evenimentului de înțepare și recoltare și

- valorile în timp real ale intensităților vocale și spectrogramele din aplicația Neonat;
- Observarea de valori foarte ridicate ale frecvenței dominante din semnalul de plâns pe durata recoltării sangvine, când valoarea parametrului de saturație este la cea mai scăzută valoare (majoritatea cazurilor);
- Realizarea unei înregistrări a unui nou născut cu valoarea parametrului de saturație sub 50% pe perioada recoltării și cu frecvența dominant peste 1kHz, diagnosticat ulterior cu suferință neurologică.
- Studiul suferinței neurologice la nou-născuții diagnosticați cu rezultate prin:
  - Aplicarea transformatei wavelet discrete peste „cuvinte” provenite din semnalul din plâns atât pentru nou-născuți diagnosticați cu suferință neurologică cât și pentru cei sănătoși, observându-se o diferențiere la reprezentarea coeficienților rezultați în urma aplicării TWD pe cuvinte provenite din semnalele de plâns ale celor două categorii menționate.

Rezultate analizelor cu echipamentul INVOS pentru fiecare nou-născut studiat sunt prezentate în extensie în cadrul Anexei 1. În cadrul Anexei 2 sunt prezentate o parte din cuvintele extrase și vizualizarea coeficienților wavelet pentru nou-născuții considerați în cadrul acestui studiu.

## 7. Concluzii, contribuții personale și direcții viitoare de cercetare

### 7.1 Concluzii și contribuții personale

Lucrarea de față a avut ca obiectiv principal analiza plânsului nou-născuților în vederea determinării de metode necesare interpretării acestuia, pentru sprijinirea diagnosticului medical obiectiv și rapid. Plânsul nou-născutului, ca semnal vocal, a necesitat transformarea în semnal electric prin intermediul unui microfon de achiziție și apoi în semnal digital stocabil printr-un proces de digitizare.

Activitatea de cercetare se concretizează prin următoarele:

1. Abordarea sistemică a asistării diagnosticului medical, în cazul nou-născuților, integrând logic aspectele ingineresti, de natură științifică și cele procedurale, mergând pe următoarele direcții:
  - a. Clasificarea semnalelor de plâns prin utilizarea tehnicilor de Data Mining aplicate pe date preluate cu un instrument conceput și destinat exclusiv achiziției și procesării semnalului din plâns. Clasificarea având ca scop indentificarea de semnalmente comune în plânsul nou-născuților cu patologii similare;
  - b. Corelarea informației furnizate de aparatura medicală specializată cu informația extrasă din semnalul din plâns. Scopul direcției este acela de a găsi indicatori în semnalul din plâns, care să constituie argumente decizionale pentru echipa de medici, similare celor oferite de aparatura medicală.
2. Contribuții pe parte de documentare asupra stadiului actual al cercetării în domeniul temei alese. În această etapă s-a realizat o sinteză amplă a rezultatelor obținute până în prezent de mai multe grupuri de cercetători, precum și a metodelor utilizate de acestea în vederea asistării personalului medical.
3. Dezvoltarea unui software dedicat achiziției semnalului de plâns, aplicația Neonat, care reprezintă în totalitate o contribuție personală valorificată științific în [94], [95]. Această aplicație (utilizată de 2 ani în mediul spitalicesc de către personalul medical) permite:
  - a. configurarea parametrilor de achiziție a semnalului de plâns (de exemplu ordinul FFT, intervalul de reprezentare al amplitudinii semnalului sau numărul de canale);
  - b. achiziția propriu-zisă;
  - c. stocarea datelor nou-născutului într-o bază de date externă, relaționată;
  - d. extragerea și stocarea parametrilor de intensitate vocală cu instrumentele emulate VU Meter și PP Meter;
  - e. generarea spectrogramei semnalului pe cadre configurabile din plâns și vizualizarea reprezentării spectrogramei cascadă în timp real pe întreaga durată a achiziției

- f. crearea automată de fișiere *.arff* cu parametri extrași din semnalul de plâns și încărcarea acestora în mediu Weka în vederea realizării de studii de *Data Mining*
4. Contribuții în etapa de analiză a înregistrărilor de plâns prin aplicarea de tehnici de *Data Mining* în vederea realizării de clasificări între un grup de nou-născuți sănătoși și loturi constituite din nou-născuți cu afecțiuni și caracteristici similare. Rezultatele studiului au fost validate științific prin prezentare publică și publicare în [96]
- Rezultatele cele mai concludente au fost obținute pentru lotul de nou-născuți prematur, lotul de nou-născuți cu strangulație de CO la naștere și lotul de nou-născuți cu patologii severe (suferință neurologică majoră, prematuritate în jurul a 30 de săptămâni sau indice Apgar sub 5).
  - Clasificarea a fost evaluată pe bază de indicatori statistici, oferind rezultate foarte bune pentru cele trei loturi menționate.
    - Pentru încadrea corectă în grupul de proveniență a nou-născuților cu strangulație de CO la naștere s-a obținut un procent favorabil de 97%-98%, cu ambele instrumente de măsură emulate, prin folosirea arborilor de decizie (algoritmul *Random Tree*) – având o eroare medie relativă de 0.06.
    - La clasificarea nou-născuților prematuri s-a obținut o clasificare corectă a instanțelor de 98% (de asemenea cu ambele instrumente de măsură și cu ajutorul aceleiași familii a arborilor de decizie), de această dată folosind algoritmul *Random Forest*.
    - Clasificarea lotului de nou-născuți cu patologii severe prin utilizarea *VU Meter*, s-a realizat cu o acuratețe de 98%.
  - Rezultatele ce s-au obținut confirmă existența unor diferențiatori în plânsul nou-născuților considerați și capabilitatea unui model de învățare de a realiza această discriminare.
5. Analiza „cuvintelor” din plâns în care s-a utilizat tehnică profesională de achiziție prin dispozitivul de înregistrare Olympus PCM. Metodele propuse pentru testarea și calibrarea acestei aparaturi de achiziție, în contextul utilizării ei în studiul primului plâns după naștere, reprezintă o contribuție personală, primind recunoaștere științifică în [97]. În cadrul acestei etape au fost realizate studii proprii pentru:
- Corelarea evoluției parametrului de saturație al oxigenării la nivel cerebral (rSO<sub>2</sub>- în timpul recoltării de sânge de la nou-născut) cu modificări ale frecvenței dominante a semnalului din plâns.
    - S-a utilizat în studiu aparatură medicală nouă, reprezentată de pulsoximetrul cerebral, INVOS, în vederea colectării valorilor parametrului de saturație cerebrală, rSO<sub>2</sub>;
    - S-a creat un sistem de achiziție compus din oximetrul cerebral, dispozitivul de înregistrare și aplicația Neonat, care pe baza unui protocol de lucru nou creat a făcut posibilă sincronizarea echipamentelor și realizarea studiului. Rezultatul acestuia, constând în evidențierea unei frecvențe dominante cu valoare de peste 1kHz pe durata scăderii masive a saturației pentru majoritatea lotului de nou-

- născuți analizați, a fost trimis pentru evaluare științifică spre publicare [98]
  - b. Stabilirea unei metode pentru evidențierea din plâns a suferinței neurologice
    - Analizarea fără rezultate concludente cu metode utilizate în aplicații de recunoaștere a vorbirii, precum metodele analizei coeficienților Bark sau a coeficienților Mel cepstrali;
    - Aplicarea în premieră pentru analiza multirezoluție pe „cuvintele” din plâns a Transformatei Wavelet Discrete care a generat reprezentări vizuale concludente prin care se pot distinge cuvintele aparținând nou-născuților cu suferință neurologică de cele ale nou-născuților sănătoși.
6. Efectuarea a peste 500 de înregistrări de plâns ale nou-născuților prin care, în urma experienței dobândite, au putut fi definite protocoale de lucru pentru diferitele studii întreprinse pentru diminuarea efectului perturbațiilor și asigurarea de condiții cât mai apropiate tuturor subiecților participanți la studiu.
- a. La efectuarea de achiziții de semnale de plâns utilizând aplicația Neonat au fost trasate reguli privind instrumentația de achiziție utilizată și utilizarea ei, numărul persoanelor care efectuează la un moment dat înregistrări, poziționarea nou-născutului la momentul efectuării achiziției de semnal sau tipul stimulului admis în cazul lipsei plânsului spontan;
  - b. În cadrul studiului evoluției parametrului de saturație cerebrală la recoltare, a fost imperativă definirea aceluși set de reguli astfel încât datele achiziționate să poată fi interpretate. Prin utilizarea în studiu a celor trei dispozitive reprezentate de:
    - aplicația Neonat (pentru urmărirea semnalului de plâns în timp real)
    - dispozitivul Olympus PCM (pentru o achiziție precisă în vederea analizei ulterioare)
    - echipamentul medical INVOS (pentru colectarea valorii parametrului de saturație)
 a fost necesară sincronizarea acestora cu procedeul medical de recoltare și a constituit obiectivul principal al protocolului creat.

Desfășurarea unei activități de cercetare în mediul de spital (terapie intensivă) atrage după sine depășirea unei serii de probleme. Rolul protocoalelor de lucru mai sus menționate este de a asigura, printre altele, un climat guvernat de reguli în care achizițiile de semnal efectuate să aibă o cât mai bună acuratețe. Detalierea problemelor întâmpinate în studiul semnalului de plâns provenit de la nou-născuți și modul de combatere al acestora a constituit rezultatul principal al respectivei etape, fiind valorificat în cadrul unei lucrări admise într-un jurnal de profil medical [99]. Printre principalii factori perturbatori ai studiului ingineresc într-un mediu de spital se numără:

- Disponibilitatea aparaturii;
- Lipsa unor protocoale/proceduri și metodologii de lucru;
- Zgomotul ambiental;
- Personal nefamiliarizat cu metodologii ingineresti;
- Prioritatea sănătății pacientului în fața oricărei alte activități de cercetare.



## 7.2 Direcții viitoare de cercetare

Rezultatele obținute în cadrul prezentei lucrări pune bazele și încurajează ideea aprofundării cercetării asupra plânsului la nou-născuți. Scopul acestei activități, pentru viitor, îl constituie găsirea de noi metode și tehnici pentru identificarea din timp a unor semnalmente de patologii, în mod neinvaziv, utilizând semnalul din plâns. Dezideratul demersurilor întreprinse până acum rămâne realizarea unui dispozitiv de *screening* postnatal care, pe baza interpretării semnalului din plâns să faciliteze decizia medicală, mai precis, mai rapid, să ghideze echipa medicală spre investigarea mai amănunțită pe anumite suferințe. Un astfel de dispozitiv ar avea, de asemenea, marele avantaj al eliminării multiplelor teste invazive care sunt realizate asupra nou-născutului în momentul de față.

## Bibliografie

- [1] M. F. Collen, "Origins of Medical Informatics," *Medica informatics (Special Issue)*, vol. West J Med, 1986, Dec.
- [2] P. A. Reynolds, J. Harper, A. M. Jenner and S. Dunne, "Better informed: an overview of health informatics," *British Dental Journal*, pp. 259 - 264, 2008.
- [3] I. Passarani, "Patient access to Electronic Health Records - Report of the eHealth Stakeholder Group," 2013.
- [4] Comisia Europeana, "'Digital Agenda for Europe'," [Online]. Available: <http://ec.europa.eu/digital-agenda/en/news/ehealth-stakeholder-group-members>. [Accessed 31 Martie 2015].
- [5] Enciclopedia Britanica, "Site-ul oficial al enciclopediei Britanica," [Online]. Available: <http://www.britannica.com/technology/MYCIN>. [Accessed 3 Mai 2015].
- [6] MedLive, "Site cu articole si blog-uri medicale," [Online]. Available: <http://medlive.hotnews.ro/ce-este-implantul-cohlear-si-cum-functioneaza-povestea-unor-copii-afectati-de-lipsa-auzului-pentru-care-implantul-cohlear-inseamna-o-viata-cu-sunete-si-cuvinte.html>. [Accessed 31 Martie 2015].
- [7] American Speech-Language-Hearing Association, "Site-ul oficial al asociației americane pentru vorbire, limbaj și auz," [Online]. Available: <http://www.asha.org/public/hearing/Cochlear-Implant/>. [Accessed 31 martie 2015].
- [8] EuroMedic, "Site-ul lanțului de clinici particulare EuroMedic parte a grupului Euromedic International," [Online]. Available: <http://euromedic.ro/servicii/imagistica/rmn.aspx>. [Accessed 31 Martie 2015].
- [9] Intuitive Surgical, "Pagina oficială a firmei dezvoltatoare a sistemului da Vinci," [Online]. Available: <http://www.davincisurgery.com/>. [Accessed 31 Martie 2015].
- [10] M. Cucerea, Aportul ecografiei transfontanelare în depistarea și urmărirea unor afecțiuni cerebrale la nou-născuții și sugarii cu suferință neurologică centală perinatală. Corelații clinico-ecografice (teză de doctorat), Tg Mureș: UMF Tg. Mureș, 2003.
- [11] RoMedic, "Site-ul oficial RoMedic," [Online]. Available: <http://www.romedic.ro/asfixia-perinatale>. [Accessed 17 Mai 2015].
- [12] O. Mărginean and a. et, *Pediatrie - note de curs -*, Târgu-Mures, România, 2013.
- [13] C. Ilie, C. Angelescu and I. Enătescu, *Note de curs*, 2015.
- [14] O. Wasz-Hockert, J. Lind, V. Vuorenkoski, T. Partanen and E. Valanne, "The Infant Cry: A Spectmgraphic and Auditory Analysis," *Spastics International Medical Publications*, 1968.
- [15] J. Orozco and C. A. R. García, "Detecting Pathologies from Infant Cry Applying Scaled Conjugate Gradient Neural Networks," in *ESANN'2003 proceedings - European Symposium on Artificial Neural Networks*, Bruges, Belgia, 2003.
- [16] M. Jam and H. Sadjedi, "A System for Detecting of Infants with Pain from Normal Infants Based on Multi-Band Spectral Entropy by Infant's Cry Analysis," in *Second International Conference on Computer and Electrical*

- Engineering*, 2009.
- [17] M. M. Jam and H. Sadjedi, "Identification of Hearing Disorder by Multi-Band Entropy Cepstrum Extraction from Infant's Cry," in *Biomedical and Pharmaceutical Engineering, ICBPE'09. International Conference on. IEEE*, 2009.
  - [18] M. A. Ruíz, L. C. Altamirano, C. Reyes and O. Herrera, "Automatic Identification Of Qualitatives Characteristics in Infant Cry," in *Spoken Language Technology Workshop (SLT), IEEE*, 2010.
  - [19] S. F. Molaezadeh and M. H. M. M. Salarian, "Type-2 Fuzzy Pattern Matching for Classifying Hunger and Pain Cries of Healthy Full-term Infants," in *The 16th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP 2012)*, 2012.
  - [20] O. F. Reyes-Galaviz, S. D. Cano-Ortiz and C. A.Reyes-Garcia, "Validation of the Cry Unit As Primary Element for Cry Analysis Using an Evolutionary-Neural Approach," in *Mexican International Conference on Computer Science*, Baja California, 2008.
  - [21] K. Kuo, "Feature Extraction and Recognition of Infant Cries," in *Electro/Information Technology (EIT), IEEE International Conference on*, Normal, IL, USA, 2010.
  - [22] V. Tocchioni, C. Manfredi and L. Bocchi, "A Robust Tool for Newborn Infant Cry Analysis," in *Proceedings of the 28th IEEE EMBS Annual International Conference*, New York City, USA, 2006.
  - [23] S. Orlandi, C. Manfredi, L. Bocchi and M. Scattoni, "Automatic Newborn Cry Analysis: a Non-Invasive Tool to Help Autism Early Diagnosis," in *34th Annual International Conference of the IEEE EMBS*, San Diego, California, USA, 2012.
  - [24] X. Wei, Y.-X. Li, L. Zhong and J.-B. Liang, "Distinguishing Infant Cry from Adult Voice Based on Spectrum Analysis," in *Audio, Language and Image Processing (ICALIP), International Conference on*, Shanghai, 2012.
  - [25] R. Sahak, W. Mansor, K. Lee, A. Yassin and A. Zabidi, "Orthogonal least square based support vector machine for the classification of infant cry with asphyxia," in *Proceedings of the 3rd International Conference on Biomedical Engineering and Informatics (BMEI'10) (Vol. 3, pp. 986-990)*, 2010.
  - [26] C. Manfredi, L. Bocchi, S. Orlandi, M. Calisti, L. Spaccaterra and G. Donzelli, "Non-Invasive Distress Evaluation in Preterm Newborn Infants," in *30th Annual International IEEE EMBS Conference*, Vancouver, British Columbia, Canada, 2008.
  - [27] H. Baeck and M. N. Souza, "Study of Acoustic Features of Newborn Cries that Correlate with the Context," in *2001 Proceedings of the 23rd Annual EMBS International Conference*, Istanbul, Turcia, 2001.
  - [28] R. Sahak, W. Mansor, L. Khuan, A. Zabid and A. I. M. Yassin, "Detection of asphyxia from infant cry using support vector machine and multilayer perceptron integrated with Orthogonal Least Square," in *Biomedical and Health Informatics (BHI), 2012 IEEE-EMBS International Conference on (pp. 906-909). IEEE*, Hong Kong & Shenzhen, 2012, 2-7 January.
  - [29] R. Sahak, W. Mansor, L. Y. Khuan, A. Ihsan, M. Yassin and A. Zabidi, "An orthogonal least square approach to select features of infant cry with asphyxia," in *Signal Processing and Its Applications (CSPA), 6th International*

*Colloquium on. IEEE*, 2010, May.

- [30] R. Sahak, W. Mansor, L. Y. Khuan, A. Zabidi and A. I. M. Yassin, "Detection of Asphyxia from Infant Cry Using Support Vector," *Proceedings of the IEEE-EMBS International Conference on Biomedical and Health Informatics - BHI*, 2012.
- [31] Y. Abdulaziz and S. M. S. Ahmad, "Infant cry recognition system: A comparison of system performance based on mel frequency and linear prediction cepstral coefficients," in *Information Retrieval & Knowledge Management, (CAMP), International Conference on*, Shah Alam, Selangor, 2010.
- [32] R. Sahak, Y. Lee, W. Mansor, A. Yassin and A. Zabidi, "Optimized Support Vector Machine for classifying infant cries with asphyxia using Orthogonal Least Square," in *Computer Applications and Industrial Electronics (ICCAIE), 2010 International Conference on* (pp. 692-696). *IEEE*, 2010.
- [33] J. Saraswath, M. Hariharan, S. Yaacob and W. Khairunizam, "Automatic Classification of Infant Cry: A Review," in *International Conference on Biomedical Engineering (ICoBE)*, Penang, 27-28 February 2012.
- [34] A. Zabidi, L. K. W. Mansor, R. Sahak and F. Y. A. Rahman, "Mel-Frequency Cepstrum Coefficient Analysis of Infant Cry with Hypothyroidism," in *5th International Colloquium on Signal Processing & Its Applications (CSPA)*, Kuala Lumpur, Malaysia, 2009.
- [35] M. Z. M. Ali, W. Mansor, Y. K. Lee and A. Zabidi, "Asphyxiated Infant Cry Classification Using Simulink Model," in *IEEE 8th International Colloquium on Signal Processing and its Applications*, Malacca, Malaysia, 2012.
- [36] M. Z. M. Ali, W. Mansor, L. Y. Khuan and A. Zabidi, "Simulink Model of Mel Frequency Cepstral Coefficient Analysis for Extracting Asphyxiated Infant Cry Features," in *2012 International Conference on Biomedical Engineering (ICoBE)*, Penang, Malaysia, 2012.
- [37] A. Patil, "Infant Identification from Their Cry," *Seventh International Conference on Advances in Pattern Recognition*, pp. 107-110, 2009.
- [38] I. Jolliffe, *Principal component analysis*, John Wiley & Sons, Ltd, 2002.
- [39] R. Sahak, W. Mansor, L. Khuan, A. Zabidi and F. Yasmin, "An Investigation into Infant Cry and Apgar Score Using Principle Component Analysis," in *5th International Colloquium on Signal Processing & Its Applications (CSPA)*, Kuala Lumpur, Malaysia, 2009.
- [40] R. Sahak, W. Mansor, Y. K. Lee, A. I. M. Yassin and A. Zabidi, "Performance of Combined Support Vector Machine and Principal Component Analysis in Recognizing Infant Cry with Asphyxia," in *32nd Annual International Conference of the IEEE EMBS*, Buenos Aires, Argentina, 2010.
- [41] A. Zabidi and e. al., "Classification of infant cries with hypothyroidism using Multilayer Perceptron neural network," in *Signal and Image Processing Applications (ICSIPA), IEEE International Conference on*, 2009.
- [42] M. Petroni and e. al, "Identification of pain from infant cry vocalizations using artificial neural networks (ANNs)," Vols. 729-738, 1995.
- [43] R. Schoenweiler and a. et, "Neuronal networks and self-organizing maps: new computer techniques in the acoustic evaluation of the infant cry. *International journal of pediatric otorhinolaryngology*," vol. 38, no. 1, pp. 1-11, 1996.

- [44] A. Zabidi, L. Khuan, W. Mansor, I. M. Yassin and R. Sahak, "Classification of Infant Cries with Asphyxia Using Multilayer Perceptron Neural," in *Second International Conference on Computer Engineering and Applications*, Bali Island, Indonesia, 2010.
- [45] O. Bogdanovici, "Anatomia vocala - Fonația," [Online]. Available: <http://www.scribd.com/doc/245370770/Anatomia-vocala-Fonatie#scribd>.
- [46] M. Giurgiu and L. Peev, "Sinteza din text a semnalului vocal, vol.1 Modelare acustică și fonologică," Cluj-Napoca, Editura RISOPRINT, 2006.
- [47] Reliable Software, "Pagina oficială a companiei Reliable Software," [Online]. Available: <http://www.relisoft.com/science/Physics/sampling.html>. [Accessed 21 Octombrie 2013].
- [48] E. Lupu and P. Pop, *Prelucrarea numerica a semnalului vocal, vol.1 Elemente de analiza si recunoastere*, Cluj-Napoca: Editura RISOPRINT, 2004.
- [49] "Site-ul de prezentare al aplicației WaveIO," [Online]. Available: <http://g.netit.ro/soft/waveio/tech-3.html>. [Accessed 5 Mai 2009].
- [50] B. Porat, *A Course in Digital Signal Processing*, John Wiley and Sons, 1997.
- [51] WaveIO, "Pagina de descriere a aplicației WaveIO," [Online]. Available: <http://g.netit.ro/soft/waveio/tech-1.html>. [Accessed 7 Decembrie 2011].
- [52] Wikipedia, "Pagina oficială dedicată mediului Visual Studio," [Online]. Available: [http://en.wikipedia.org/wiki/Microsoft\\_Visual\\_Studio](http://en.wikipedia.org/wiki/Microsoft_Visual_Studio). [Accessed 12 Decembrie 2014].
- [53] Mitov Software, "Pagina oficială a dezvoltatorului de software," [Online]. Available: <http://www.mitov.com/>. [Accessed 22 Ianuarie 2015].
- [54] Microsoft Corporation, "Pagina oficială a companiei Microsoft," [Online]. Available: [http://www.microsoft.com/romania/serve/sql/overview\\_1.msp](http://www.microsoft.com/romania/serve/sql/overview_1.msp). [Accessed 9 Ianuarie 2015].
- [55] Wikipedia, "Pagina oficială SQL Server," [Online]. Available: [http://en.wikipedia.org/wiki/SQL\\_Server\\_2005](http://en.wikipedia.org/wiki/SQL_Server_2005). [Accessed 5 Iunie 2013].
- [56] I. H. Wittien and E. Frank, *Data Mining: Practical machine learning tools and techniques*, 2nd Edition, San Francisco: Morgan Kaufmann, 2005.
- [57] Wikipedia, "Pagina oficială destinată mediului Weka," [Online]. Available: [http://en.wikipedia.org/wiki/Weka\\_\(machine\\_learning\)](http://en.wikipedia.org/wiki/Weka_(machine_learning)). [Accessed 20 Martie 2015].
- [58] C. Nastase, *Manualul inginerului de sunet*, 2013.
- [59] L. Andreescu, *Contribuții la studiul propagării și limitării zgomotului în instalații - teză de doctorat*, București: Universitatea Tehnică de Construcții București, 2010.
- [60] Media College, "Pagina oficială Media College," [Online]. Available: <http://www.mediacollege.com/audio/monitoring/ppm.html>. [Accessed 21 Ianuarie 2015].
- [61] "Site official Media College," [Online]. Available: <http://www.mediacollege.com/audio/monitoring/vu.html>. [Accessed 3 Februarie 2015].
- [62] D. Hand, H. Mannila and P. Smyth, *Principles of Data Mining*, Cambridge, MA, USA: MIT Press, 2001.
- [63] J. D. Larose, *Data Mining methods and models*, New Jersey: ohn Wiley &


- Sons, Inc., 2006.
- [64] M. Andronie and D. Crișan, "Commercially Available Data Mining Tools used in the Economic," *Database Systems Journal*, vol. I, no. 2, pp. 45-54, 2010.
- [65] P. Chen, "Data Mining in Macroeconomic Data Sets - Proiect academic KDD," Universitatea Carnegie Mellon, Pittsburgh, SUA, dupa anul 2003 (conform ultimei referințe bibliografice).
- [66] M. Brameie and W. Banzhaf, "A comparison of linear genetic programming and neural networks in medical data mining.," *Evolutionary Computation, IEEE Transactions on*, vol. 5, no. 1, pp. 17-26, 2001.
- [67] K. J. Cios and G. W. Moore, "Uniqueness of medical data mining," *Artificial intelligence in medicine*, vol. 26, no. 1, pp. 1-24, 2002.
- [68] F. Gorunescu, *Data Mining, concepte, modele și tehnic*, Cluj-Napoca: Editura Albastra, 2006.
- [69] N. Ball and R. Brunner, "Data mining and machine learning in astronomy," *International Journal of Modern Physics*, vol. 19, no. 7, pp. 1049-1106, 2010.
- [70] B. Chen and a. et., "Chem2Bio2RDF: a semantic framework for linking and data mining chemogenomic and systems chemical biology data," *BMC bioinformatics*, vol. 11, no. 1, 2010.
- [71] "Site-ul oficial al conferinței "4th Workshop on Data Mining for Medicine and Healthcare"," [Online]. Available: <http://www.dmmh.org/>. [Accessed 2 Mai 2015].
- [72] L. Zhu, B. Wu and C. Cao, "Introduction to medical data mining," *Sheng Wu Yi Xue Gong Cheng Xue Za Zhi*, vol. 20, no. 3, pp. 559-562, 2003.
- [73] Autoritatea Națională pentru Cercetare Științifică, "Pagină a Autorității Naționale pentru Cercetare Științifică," [Online]. Available: <http://www.roinno.ro/index.php?module=ca&page=rez&action=viewfisa&id=415>. [Accessed 10 Aprilie 2015].
- [74] D. Garrett and e. al, "Comparison of linear, nonlinear, and feature selection methods for EEG signal classification," *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 11, no. 2, pp. 141-144, 2003.
- [75] C. Perez-Iratxeta, Bork and M. A. A. Peer, "Association of genes to genetically inherited diseases using data mining," *Nature genetics*, vol. 31, no. 3, pp. 316-319, 2002.
- [76] K. Sudhir, K. Tamura and M. Nei, "MEGA3: integrated software for molecular evolutionary genetics analysis and sequence alignment," *Briefings in bioinformatics*, vol. 5, no. 2, pp. 150-163, 2004.
- [77] S. Paul, N. Guatam and R. Balint, *Preparing and Mining Data with Microsoft SQL Server 2000 and Analysis Services*, Microsoft SQL Server Series, Online Books, 2002.
- [78] U. WAIKATO, "Pagina oficială a mediului Weka," 2015. [Online]. Available: <http://www.cs.waikato.ac.nz/ml/weka/>. [Accessed 23 Ianuarie 2015].
- [79] P. Cichosz, *Data Mining Algorithms: Explained using R*, Wiley, 2015.
- [80] Gizmag, "Site oficial al revistei tehnice GizMag," [Online]. Available: <http://www.gizmag.com/olympus-ls100-multi-track-linear-pcm-recorder/24397/>. [Accessed 12 Mai 2015].
- [81] C. Inc., "Brosura oficiala Oximetrie cu INVOS in neonatologie," [Online].

- Available: <http://www.covidien.com/rms/products/cerebral-somatic-oximetry/ivos-5100c-cerebral-somatic-oximeter>.
- [82] E. Frost, "Cerebral Oximetry - Emerging Applications for an Established Technology," Aprilie 2012.
- [83] H. E. Elser, D. Holditch-Davis and D. H. Brandon, "Cerebral Oxygenation Monitoring A Strategy to Detect Intraventricular Hemorrhage and Periventricular Leukomalacia D," in *Medscape*, 2011.
- [84] "Site-ul Copilul.ro cu informații de la specialiști cu privire la nou-născuți și copii," [Online]. Available: <http://www.copilul.ro/bebelusi/sanatate/Testul-de-sange-din-calcaiul-bebelusului-a9672.html>. [Accessed 3 Mai 2015].
- [85] "Site-ul DespreCopii care oferă opinii din partea specialiștilor cu privire la nou-născuți și copii," [Online]. Available: <http://www.desprecopii.com/info-id-1164-nm-Testul-cu-sange-din-calcaiul-bebelusului.htm>. [Accessed 3 Martie 2015].
- [86] L. Bocchi, L. Spaccaterra, F. Acciai, S. Orlandi, F. Favilli, E. Atrei, C. Manfredi and G. P. Donzelli, "Non Invasive Distress Monitoring in Children Hospital Intensive Care Unit," 2008.
- [87] "Site-ul grupului de cercetare din Cluj-Napoca, "Multimedia Technologies and Telecommunications Research Centre"," [Online]. Available: [http://ctmtc.utcluj.ro:8080/sites/pni/SACCD/AV/Curs/Curs07\\_saccdmm.pdf](http://ctmtc.utcluj.ro:8080/sites/pni/SACCD/AV/Curs/Curs07_saccdmm.pdf). [Accessed 3 Mai 2015].
- [88] A. Phinyomark, A. Nuidod, P. Phukpattaranont and C. Limsakul, "Feature Extraction and Reduction of Wavelet Transform Coefficients," *ELECTRONICS AND ELECTRICAL ENGINEERING*, vol. 6, no. 122, pp. 27-32, 2012.
- [89] C. Valens, *A Really Friendly Guide to Wavelets*, 1999.
- [90] M. Misiti, Y. Misiti, G. Oppenheim and J. Poggi, *Wavelet Toolbox*, 1996.
- [91] I. B. Ciocoiu, "Analiza de tip wavelet," in *Curs Digital Signal Processing*.
- [92] S. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1989.
- [93] P. Rajmic and J. Vlach, "Real-Time Audio Processing via Segmented Wavelet Transform," in *Digital Audio Effects (DAFx-07)*, Bordeaux, Franța, 2007, Septembrie 10-15.
- [94] C. Ilie, I. Enătescu, F. F. R. Ilie, V. Enătescu and A. Nyiredi, "Analiza spectrografică a plânsului provocat de durere la nou-născut utilizând tehnici de Data Mining," *Aspecte etice în Neonatologie-Durerea la nou-născut*, pp. 184-188, 2011.
- [95] R. Robu, F. Feier, V. Stoicu-Tivadar, C. Ilie and I. Enătescu, "The analysis of the new-borns' cry using NEONAT and data mining techniques," in *Proceedings of the 15th IEEE International Conference on Intelligent Engineering Systems (INES)*, Poprad, 2011.
- [96] F. Feier, I. Enătescu, C. Ilie and I. Silea, "Newborns' cry analysis classification using signal processing and data mining," in *Optimization of Electrical and Electronic Equipment (OPTIM)*, International Conference on, Cheile Grădiștei, Brașov, 2014.
- [97] F. Feier and I. Silea, "A novel approach on the newborns' cry analysis using


- professional recording and feature extraction from the "first cry" with LabVIEW," in *Soft Computing Applications - Proceedings of the 6th International Workshop Soft Computing Applications*, Timisoara, 2014.
- [98] F. Feier, C. Angelescu, I. I. S. Silea and M. A. Moisescu, "Sound Analysis System of Newborn Cry during Blood Draw with Cerebral Oximetry Monitoring," *Journal of Control Engineering and Applied Informatics (CEAI)*, 2015.
- [99] F. Feier, C. Angelescu, C. Ilie and I. Silea, "Disturbance factors in conducting engineering studies on the newborns' cry, in a hospital environment," *Jurnalul Pediatriei*, 2015.
- [100] Wikipedia, "Pagina dedicată funcțiilor de ferestruire," [Online]. Available: [http://en.wikipedia.org/wiki/Window\\_function](http://en.wikipedia.org/wiki/Window_function). [Accessed 21 Iunie 2015].




# ANEXA 1 – Experimente cu echipamentul INVOS




Anexa 1 1 Evoluție parametru saturație ID\_1




Anexa 1 2 Spectrul de frecvențe pe perioada monitorizării cu INVOS ID\_1




Anexa 1 3 Cuvânt 1 după prima înțepare ID\_1




Anexa 1 4 Cuvânt 1 după a 2-a înțep. ID\_1




Anexa 1 5 Cuvânt 2 după a 2-a înțepare ID\_1




Anexa 1 6 Evoluție parametru saturație ID\_2




Anexa 1 7 Spectrul de frecvențe pe perioada monitorizării cu INVOS ID\_2




Anexa 1 8 Cuvânt 1 după înțepareID\_2




Anexa 1 9 Evoluție parametru saturație ID\_3




Anexa 1 10 Spectrul de frecvențe pe perioada monitorizării cu INVOS ID\_3




Anexa 1 11 Cuvânt 1 după înțepareID\_3



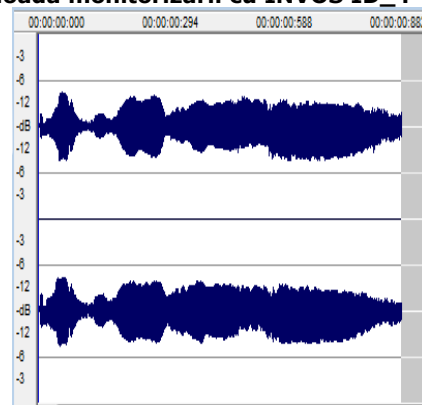
**Anexa 1 12 Evoluție parametru saturatie ID\_4**



**Anexa 1 13 Spectrul de frecvențe pe perioada monitorizării cu INVOS ID\_4**




**Anexa 1 14 Cuvânt 1 după înțep 2 ID\_4**




**Anexa 1 15 Cuvânt 1 după înțep 1 ID\_1**


## ANEXA 2 – Analiza suferinței neurologice




Anexa 2 1 Formă undă cuvânt 1 ID\_SN1




Anexa 2 2 Cuvânt 1 DWT ID\_SN1



Anexa 2 3 Formă undă cuvânt 2 ID\_SN1




Anexa 2 4 Cuvânt 2 DWT ID\_SN1




Anexa 2 5 Formă undă cuvânt 3 ID\_SN1

Anexa 2 6 Cuvânt 3DWT ID\_SN1




Anexa 2 7 Formă undă cuvânt 1 ID\_SN1

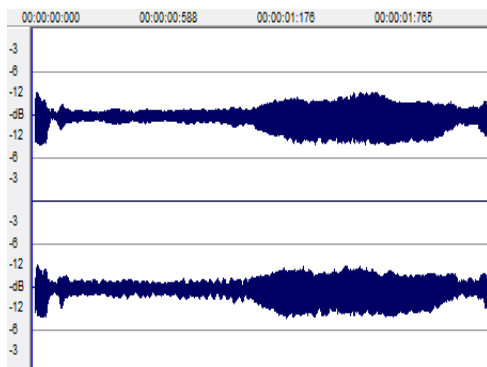
Anexa 2 8 Cuvânt 4DWT ID\_SN1




Anexa 2 9 Formă undă cuvânt 1 ID\_SN2




Anexa 2 10 Cuvânt 1 DWT ID\_SN2




Anexa 2 11 Formă undă cuvânt 3 ID\_SN2




Anexa 2 12 Cuvânt 3 DWT ID\_SN2




Anexa 2 13 Formă undă cuvânt 6 ID\_SN2



Anexa 2 14 Cuvânt 6 DWT ID\_SN2




Anexa 2 15 Formă undă cuvânt 1 lung ID\_SN3

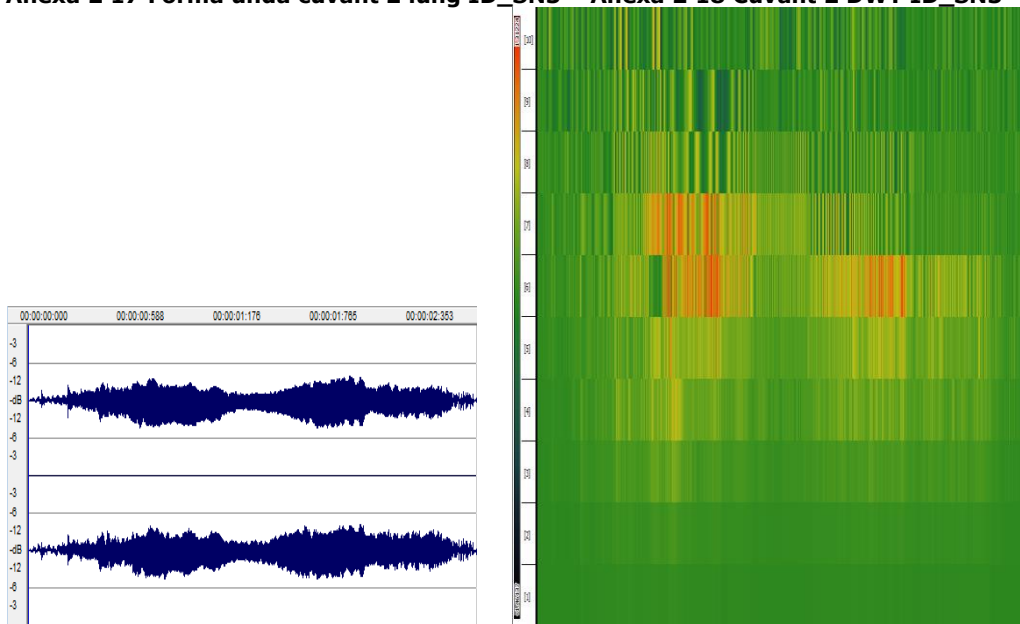


Anexa 2 16 Cuvânt 1 DWT ID\_SN3







**Anexa 2 17 Formă undă cuvânt 2 lung ID\_SN3    Anexa 2 18 Cuvânt 2 DWT ID\_SN3**




**Anexa 2 19 Formă undă cuvânt 1 lung ID\_SN4    Anexa 2 20 Cuvânt 1 DWT ID\_SN4**




Anexa 2 21 Formă undă cuvânt 2 ID\_SN4



Anexa 2 22 Cuvânt 2 DWT ID\_SN4



Anexa 2 23 Formă undă cuvânt 4 ID\_SN4



Anexa 2 24 Cuvânt 4 DWT ID4

## **Lista de lucrări publicate în domeniul temei de cercetare**

### **A. Lucrări științifice publicate în reviste indexate Web of Science-WoS (ISI)**

1. **F. Feier**, I. Silea, C. Angelescu, I. Ș. Sacală, M. A. Moiescu, „Sound Analysis System of New-born Cry during Blood Draw with Cerebral Oximetry Monitoring” - în curs de publicare în „Journal Of Control Engineering and Applied Informatics”

### **B. Lucrări științifice publicate în volumele unor manifestări științifice (Proceedings) indexate Web of Science-WoS (ISI) Proceedings**

2. **F. Feier**, I. Silea, „A novel approach on the newborns’ cry analysis using professional recording and feature extraction from the “first cry” with LabVIEW”, Soft Computing Applications - Proceedings of the 6th International Workshop Soft Computing Applications (SOFA 2014) – în curs de indexare ISI (SOFA 2012 indexată ISI)
3. **F. Feier**; I. Enătescu,; C. Ilie; I. Silea, "Newborns' cry analysis classification using signal processing and data mining", Optimization of Electrical and Electronic Equipment (OPTIM), 2014 International Conference on, On page(s): 880 – 885

### **C. Lucrări științifice publicate în reviste de specialitate indexate BDI**

4. **F. Feier**, C. Angelescu, C. Ilie, I. Silea, „Disturbance factors in conducting engineering studies on the newborns’ cry, in a hospital environment”, Jurnalul Pediatriei – Year XVIII, Vol. XVIII, Nr. 69-70, January-june 2015, ISSN 2360 – 4557, p. 3 - 9

### **D. Lucrări științifice publicate în volumele unor manifestări științifice (Proceedings) indexate BDI**

5. R. Robu, **F. Feier**, V. Stoicu-Tivadar, C. Ilie, I. Enătescu, „The analysis of the new-borns' cry using NEONAT and data mining techniques”, Proceedings of the 15th IEEE International Conference on Intelligent Engineering Systems (INES), Pages 235-238, Poprad, Slovakia, 2011

### **E. Lucrări științifice publicate în volumele unor manifestări științifice**

6. C. Ilie, I. Enătescu, **F. Feier**, R. Ilie, V.R. Enătescu, A. Nyiredi, M. Roșu „Analiza spectrografică a plânsului provocat de durere la nou-născut utilizând tehnici de data maning”, Al II-lea Congres Național de Neonatologie, Iași 15-18 septembrie 2011, publicat în volumul de lucrări inextenso “Aspecte etice în Neonatologie-Durerea la nou-născut”, Editura “Gr. T. Popa”, U.M.F. Iași, ISBN 978-606-544-072-2, pg.184-188