

Asistent pentru persoane varstnice bazat pe modele de mobilitate (Mobile@Old)

Etapa 2/2015: Stabilirea cerintelor platformei

1.01.2015-31.12.2015

Coordonator: Universitatea POLITEHNICA din București (UPB)

Parteneri: P1: Centrul IT pentru Știință și Tehnologie

P2: Universitatea Babeș-Bolyai, Cluj-Napoca

P3: Universitatea Ștefan cel Mare, Suceava

Descriere proiect: Scopul principal al acestui proiect este de a dezvolta o platformă prietenoasă, adaptată nevoilor persoanelor vârstnice, pentru asistarea acestora și a-i ajuta să-și mențină un stil de viață sănătos. Platforma abordează problemele persoanelor vârstnice în corelare cu activitatea fizică desfășurată. Sistemul va analiza parametri medicali ai persoanei supravegheate (pulsul, ritmul cardiac, etc) și le recomanda exerciții fizice adaptate profilului personal. Sistemul este format din două componente: (a) VSM (Vital Sign Monitoring): analiza parametrilor vitali folosind expertiza; (b) PAT (Physical Activity Trainer): recomandarea efectuării de exerciții fizice suplimentare. Aceste exerciții vor fi efectuate în mod interactiv, sub forma unui joc adaptiv, conceput pentru persoanele vârstnice, având la bază expertiza medicală (kinetoterapeut și medic).

Rezumat Etapa 2/2015¹: Scopul etapei 2/2015 – "Specificații de implementare" constă în rafinarea arhitecturii sistemului, realizarea de experimente cu dispozitivele ce urmează a fi integrate în cele două componente ale platformei VSM și PAT și analiza datelor provenite de la acești senzori. Pentru componenta VSM a fost analizată și evaluată centura Bioharness Zephyr – achiziția de date, proiectarea bazelor de date medicale în vederea stocării datelor preluate de la senzor. De asemenea s-a evaluat modul de identificare al unui trend ascendent/descendent pentru evoluția parametrilor medicali achiziționați, trend ce va fi ulterior folosit în adaptarea exercițiilor fizice propuse utilizatorului. În plus au fost analizate o serie de dispozitive ce pot fi folosite în vederea detectării căderilor și a monitorizării nivelului de mobilitate. Pentru componenta PAT au fost realizate: achiziționarea și stocarea datelor provenite de la senzorul Kinect (folosit pentru Xbox 360), analiza acestora în vederea detectării posturilor primare și ale mișcărilor persoanei supravegheate. Pentru calculul gradului de realizare al mișcărilor fizice s-a propus metoda consensului gestual care îmbunătățește practica domeniului prin formule noi de analiză a mișcărilor gestuale ale întregului corp, precum și un test statistic pentru aprecierea diferențelor dintre preferințelor utilizatorilor. Totodată s-a analizat și detecția de privire în vederea stabilirii ulterioare a atenției utilizatorului asupra exercițiilor fizice realizate. În acest scop, în cadrul acestei etape s-a analizat acuratețea recunoașterii posturilor, respectiv mișcărilor pentru metodele propuse, identificarea direcției de privire și influența stării emoționale cu scopul îmbunătățirii interacțiunii subiecților cu sistemul în ansamblul său. Datele provenite de la senzorul Kinect au fost analizate și din perspectiva recunoașterii obiectelor din mediul înconjurător al utilizatorului urmând ca în etapa următoare (3/2016) să se construiască un mediu virtual (avatar și mediu înconjurător) prin intermediul căruia utilizatorului să-i fie propuse exercițiile fizice ce urmează a fi efectuate. Totodată au fost analizate un set de gesturi în vederea dezvoltării unei interfețe gestuale cu ajutorul căreia utilizatorul va avea acces la informații.

1. Arhitectura sistemului

Jocurile pe calculator pot fi în măsură să contribuie la întârzierea degradării cognitive - mecanismul de joc și dinamica jocului sunt în măsură să influențeze pozitiv comportamentul uman, deoarece acestea sunt concepute pentru a conduce jucătorii deasupra pragului de activare (de exemplu, partea din dreapta sus a axei aptitudine-motivație), și apoi de a le declanșa în acțiuni specifice. Cu toate acestea, aceste jocuri trebuie să fie adaptate la persoanele în vârstă, la jocul jucat, interfață și obiective. Nivelul de intensitate al exercițiilor fizice recomandate vor fi generate și adaptate în funcție de profilul utilizatorilor (în special pe baza considerentelor medicale): parametri vitali ai utilizatorului (analizate folosind expertiza medicală) și, de asemenea, pe baza comportamentului său observat. Platforma este compusă din două componente: *Vital Signs Monitoring (VSM)* și *Physical Activity Trainer (PAT)*, descrisă în (Mocanu et al., 2015). Structura generală a sistemului este prezentată Figura 1.

Componentele principale ale platformei Mobile@Old sunt:

Vital Sign Monitoring (VSM) - analizează parametri vitali folosind expertiza medicală. Frecvența cardiacă, pulsul, sau saturația de oxigen vor fi măsurate automat cu diferiți senzori, precum centura Bioharness Zephyr (Zephyr) și pulsoximetru.

¹ Raportul în format extins se găsește la adresa <http://aimas.cs.pub.ro/mobile-old/> în secțiunea Activități

Parametri vitali vor fi analizați în vederea generării de remindere, structurate în: informații despre medicația curentă (alarme pentru anunțarea momentului în care trebuie luată medicația curentă) - *Med* (Medicina), respectiv remindere legate de activitatea sa zilnică (nivelul de mișcare) - *Rem* (Memento).

Physical Activity Trainer (PAT) – realizează recomandarea efectuării de exerciții fizice suplimentare, în cazul detectării unui nivel scăzut al activității fizice. Exercițiile vor fi stabilite pe baza istoricului medical al persoanei supravegheate. Aceste exerciții fizice vor fi realizate prin joc, iar gradul de realizare va fi calculat pe baza acurateții mișcărilor realizate, ținând cont de parametri medicali, influența emoțiilor și nivelul de atenție al utilizatorului.

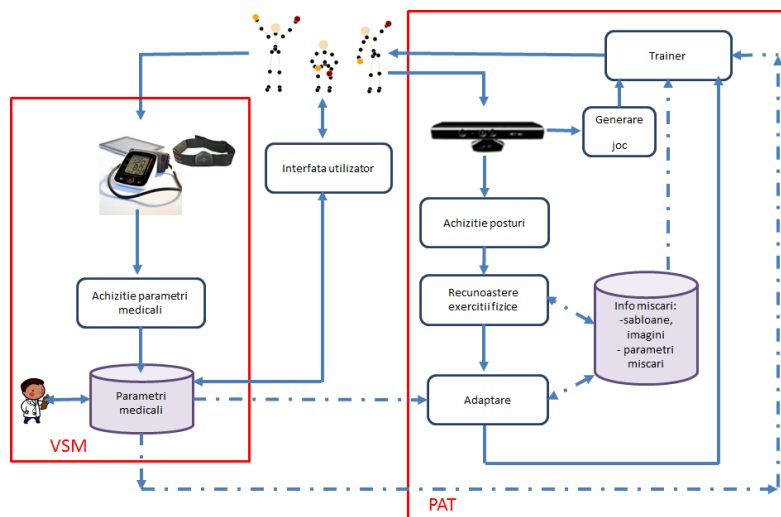


Figura 1. Arhitectura sistemului

În funcție de gradul de realizare al exercițiilor fizice acestea vor fi adaptate folosind metode de raționament bazate pe cazuri de utilizare. Exercițiile fizice vor fi prezentate utilizatorilor sub forma unui joc în care va exista un avatar personal, plasat într-un mediu ce poate simula mediul înconjurător al acestuia.

Rezultatele obținute de VSM și PAT sunt prezentate utilizatorilor (persoana supravegheată sau îngrijitorii formali/informali) prin intermediul unei interfețe în care informațiile sunt prezentate în mod diferit în funcție de tipul de utilizator. Utilizatorul va avea posibilitatea de a vizualiza și interoga aceste informații prin intermediul unei interfețe gestuale proiectată ținând cont de caracteristicile persoanelor vârstnice.

1.1 Analiza proceselor

Sistemele AAL ar putea fi considerate ca organizații de colaborare și constau în: medici, îngrijitorii formali și informali, kinetoterapeut, care poate fi asimilat cu un furnizor de servicii, ce pot ajuta persoanele în vârstă, care sunt priviți drept clienți. Din acest motiv, ne-am dezvoltat propriul sistem AAL ca o organizație – un asistent personal - care are propriul Business Process (BP). Activitatea Centrului de Îngrijire sau Activitate de Îngrijire la Domiciliu poate fi un proces de afaceri, care determină o colecție de sarcini legate de faptul că produc un serviciu sau un produs specific (pentru a servi unui anumit scop, în cazul nostru îngrijirea bătrânilor) pentru un anumit client: persoanele în vârstă (White & Miers 2008). Specificațiile BPMN 2.0 (Business Process Model and Notation) definește trei modele pentru diferite aspecte ale proceselor: Modelul de Proces, Modelul Coregrafie și Modelul Colaborare.

1.1.1 Analiza proceselor de afaceri

Există mai multe categorii de actori implicați în Platforma Mobile@Old (Rusu et al., 2015):

- **Pacientul vârstnic** – o persoană care are peste 60 de ani.
- **Îngrijitorul** - o categorie de persoane care asigură asistență minimală la domiciliu. Aceste persoane nu au voie să schimbe medicația sau să ia decizii medicale, practic efectuează doar supraveghere, eventual pansare sau alte tratamente specifice. Acestea ar putea fi implicate în introducerea datelor medicale (Tensiune Arterială, puls etc) în cazul în care vârstnicul nu se descurcă sau are probleme de sănătate (ex. oculare) care nu îi permit să facă operațiile necesare în sistem. Față de alte țări, în România nu există asistente medicale la domiciliu.
- **Medicul** – indică medicația (ora de administrare - dimineața/prânz/seara, zilele săptămânii, înainte de masă/cu cât timp înainte de masă/după masă/ la ce distanță de masă) sau schimbă medicația.
- **Kinetoterapeutul** – indică exercițiile medicale de recuperare sau de întreținere și supraveghează execuția lor, monitorizează evoluția pacientului și adaptează schema de recuperare în funcție de nevoile și de progresele înregistrate de pacient.
- **Aparținătorul** (soț/soție/ copii/alte rude/ prieteni) desemnați de vârstnic, care să poată fi alertați în condițiile în care starea de sănătate se înrăutățește sau apar noi simptome ale bolii.

Am elaborat un chestionar cu 61 de itemi, ce a fost aplicat pe persoane – subiecți cu vârsta între 60 și 87 de ani – care suferă de o boală cronică sau are afecțiuni severe, 12% din ei având și dizabilități motrice. În cadrul studiului nostru, am delimitat 3 grupuri de persoane vârstnice: (i) *Grupul A*: peste 60 ani; (ii) *Grupul B*: între 70 și 80; (iii) *Grupul C*: peste 80.

Rezultatele noastre de interes se referă la gradul de acceptare al tehnologiilor IT și condițiile de sănătate, precum și tratamentul de urgență.

Majoritatea vârstnicilor (94%) nu au smarphone, cel mult mobil (98%) și tabletă (12%) sau mai frecvent PC (54%). În funcție de profilul utilizatorului vârstnic, raportat tehnologiile IT, din chestionar am obținut următoarele rezultate:

- *Grupul A:* cunoștințe medii de IT: telefon mobil, eventual smarphone, mail, browser, motor de căutare, Skype, foarte rar (12%) cu deprinderi de utilizare a rețelelor de socializare.
- *Grupul B:* cunoștințe slabe de IT: telefon mobil, de obicei refuză utilizarea smarphone, eventual mail, browser, motor de căutare. O mică parte (10-15%) dintre aceștia folosesc Skype frecvent și majoritatea au rude în diaspora sau au cunoștințe avansate în IT.
- *Grupul C:* care raspund/ vorbesc la telefon mobil, eventual scriu un mesaj (rar, dacă folosesc ochelarii de vedere).

La nivelul de acceptabilitate al tehnologiei de către persoanele în vârstă nu există nici o diferență relevantă între aceste trei grupuri, cum ar fi:

- dispozitive AAL și aplicații (măsurarea tensiunii arteriale, monitorizare diabetică, termometru, glucometru, pulsoximetru, memento medicamente, consultanță dietă, jocuri): acceptate.
- acceptabilitate pentru a testa platforma Mobile@Old: DA (53%), NO (36%), Neutral (11%);
- senzori de tip e-textile: acceptat.
- senzori de purtat: acceptat.
- cutii mici pentru a fi transportate pe utilizator: acceptat.
- Folosirea camerelor video în casă / încăperi: nu este acceptat.
- informații și ecran de interacțiune: acceptat.
- senzori în interiorul casei: acceptat.

În ceea ce privește condițiile de sănătate și nevoile de tratament, analiza răspunsurilor legate de sănătatea persoanelor în vârstă, s-a ajuns la concluzia că cei mai mulți suferă de cel puțin o boală cronică (95%), sunt persoane în vârstă care au două boli cronice (62%), sau au 3 boli cronice (47%), indicând faptul că rolul medicului pe platformă are același nivel de importanță precum pacientul (Figurile 1 – 3). Cele mai frecvente boli cronice găsite în chestionare prelucrate sunt: boală coronariană (53%), angina (21%), hipertensiune (57%), miopie (43%), hipermetropie (47%), osteoporoză (51%), diabet (24%), obezitate (18%), tulburări tiroidiene (15%), hemipareză (23%), atac vascular (35%), Parkinson (25%), litiază renală (17%), cancer (8%) (Rusu et al., 2015).

Datorită acestor boli, am obținut acordul vâstnicilor pentru a evalua nivelul de mobilitate, pe baza de examen medical și a cooperării între medici, kinoterapeut și bătrâni (**Mocanu et al., 2015**). Rezultatele pot fi relevante pentru medici și terapeuți și trebuie să fie cerințe majore în implementarea platformei Mobile@Old. În cadrul acestui sistem folosim o scară de la boala și mobilitatea (Figura 2). Dacă avem doar un singur bătrân, care are 4 boli cronice în Grupa A, și mobilitatea are valori între 9 și 3 (Figura 2), pentru Grupa B avem doar doi bătrâni cu nivel de mobilitate 8 și 9 (Figura 3). Pentru grupa C sunt două persoane cu grad de mobilitate 8 (Figura 4).

Analizând datele obținute, constatăm că mobilitatea medie scade cu vârsta și bolile suferite de vâstnic. Astfel, pentru grupul de vârstă de peste 60 de ani, media este de 6.81 și deviația standard este stabilită la 2.05; pentru media peste 70 de ani este de 5.7, iar abaterea standard este 1.98 și pentru vâstă de peste 80 de ani, media este 4.26 și deviația standard 1.2, mult mai mici decât celelalte două grupe de vârstă. Pe baza răspunsurilor vâstnicilor, elementul principal al platformei Mobile@Old se va axa pe monitorizarea sănătății.




Figura 2. Nivelul de mobilitate și a bolilor pentru persoanele cu vârstă între 60 și 70 ani




Figura 3. - Nivelul de mobilitate și al bolilor pentru persoanele cu vârstă de peste 70 de ani

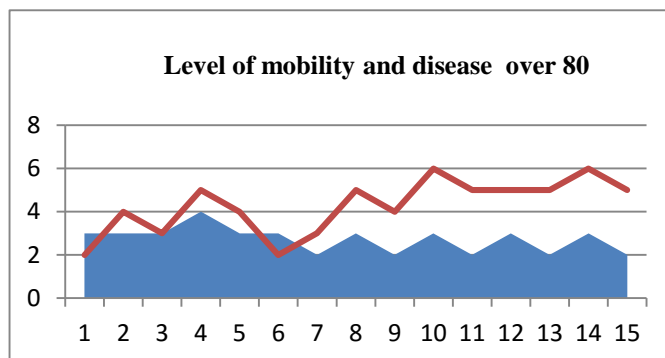


Figura 4. Nivelul de mobilitate și a bolilor de vârstă pentru persoanele cu vârsta de peste 80

1.1.2 Monitorizarea procesului de business

Platforma Mobile@Old implică trei categorii de servicii: Servicii Tratament de Urgență, Servicii de Autonomie Sportivă și Servicii Confort. Primul are caracteristici de predicție, detectare și prevenție de urgență. Mobile@Old va rezolva numai ultimele două aspecte. Pentru Serviciile de Autonomie Sportivă, în această fază vom trata și rezolva nevoile zilnice majore: gătit, mâncat, băut, îmbrăcat și asistență la curățenie în cadrul modulului *Rem*, în timp ce partea de asistență cu privire la medicație este asigurată de *Med*. Serviciile de Confort, bazate pe servicii logistice pentru găsirea lucrurilor pierdute sunt rezolvate în modul *Rem*, în timp ce serviciile de informare și divertisment sunt delegate către modulele PAT și VSM.

Două scenarii sunt prezentate - acestea implicând persoanele vârstnice, persoanele care îi îngrijesc, medici și actori-cheie și kinezioterapeuții, care trebuie să respecte restricțiile stricte impuse de bolile cronice ale vârstnicilor și parametrii medicali indicați de către medic pentru fiecare vârstnic în parte. Din acest motiv, kinezioterapeuții sunt obligați să elaboreze exerciții cu diferite grade de complexitate, în funcție de performanța și starea de sănătate a pacientului în timpul derulării. Câteva exemple de exerciții sunt prezentate în Secțiunea 3. Toată interacțiunea este bazată pe dispozitive mobile sau cu ecran (PC, laptop, notebook, tabletă, sau iPhone). Prototipul nu implică senzori video sau aparate foto. Principalele funcționalități ale platformei Mobile@Old sunt prezentate în Tabelul 1.

Tabelul 1. Mobile@old - Performanța la nivel de sistem (Rusu et al, 2015)

Performanța nivelului	Funcționalități
Utilizatori potențiali	Vârstnici cu sau fără dificultăți de mobilitate și / sau dezorientare din cauza vârstei sau bolii. Ingrijitorii, medici, kinezioterapeut
Mediu	Facilități de inteligență asistivă. Mediu structurat, cunoscut, la interior și oameni cu particularități legate de problemele de sănătate și boli.
Stabilitate psihică	Oferă îndrumare pentru exerciții fizice, prin intermediul video-urilor de preînregistrate, programe pentru îmbunătățirea funcțiilor de sănătate. Comenzi pentru utilizator și monitorizare a parametrilor de sănătate.
Monitorizarea stării de sănătate	Asigură monitorizarea continuă a sănătății pe baza unor parametri de sănătate personalizați. Oferă îndrumare pentru exerciții fizice în funcție de parametri de sănătate și performanță personală de zi cu zi.
Comunicația	Furnizarea unei comunicații bidirecționale calculator - asistent personal Oferă comunicare cu medicii și terapeuții fizici Soluție personalizată pentru integrarea în e-comunitate.

Exercițiile fizice joacă un rol foarte important în procesul de pierdere în greutate. Un program de exerciții fizice bine structurat poate conduce la o recuperare rapidă în boli severe (accident vascular cerebral, fracturi, intervenții chirurgicale) și aduce beneficii majore chiar și pentru vârstnici cu boli mai puțin severe. Scopul exercițiului fizic este de recăștiga greutatea normală, precum și reducerea comorbidității care afectează mulți pacienți obezi, cum ar fi bolile cardiovasculare, diabetul, osteoporoza.

Un program de exerciții fizice bine structurat este orice program adaptat la stilul de viață al pacientului și la capacitățile lor fizice, care include orice activitate din programul zilnic care conduce până la un ritm cardiac adecvat – ținta fiind de cel puțin 120 de bătăi pe minut (bpm). Această nivel de intensitate se recomandă pe o perioadă de 30-45 de minute. Dacă apar probleme de sănătate (transpirație, de oboseală sau de respirație) este suficient și un timp de 5-10 minute, de trei ori pe săptămână. În timp, rezistența se va construi treptat și va putea ajunge la un obiectiv de 30-45 de minute.

În continuare ne concentrăm acum asupra celor șase beneficii ale exercițiilor structurate cu activitățile cotidiene, menținând un echilibru între ele:

1. **pierderea în greutate** prin arderea unui număr de calorii pe o perioadă de timp. Recomandarea de timp este de 30 minute de exerciții pe zi, cel puțin cinci zile pe săptămână.

2. **capacitatea de a combate numeroase probleme de sănătate**, de la bolile cardiovasculare la depresie. Activitatea fizică permite sângelui să curgă viguros prin artere și vene, reducând riscul bolilor cardiovasculare, reducând riscul de a dezvolta diabet zaharat de tip 2, accident vascular cerebral, depresie și artrită.

3. **îmbunătățirea stării de spirit**. Exercițiile stimulează eliberarea de endorfine în creier care sunt cunoscute producător de "runner's high". Eliberând tensiunea și stresul prin exercițiu poate stimula stima de sine și încrederea.

4. **impuls de energie** cauzat de eficiența consumului de oxigen în întreg organismul. Cum inima și plămânii lucrează în sincronizare, permit organismului un flux fluxul de sânge bun restabilirea energiei mușchilor și țesuturilor. Exercițiile regulate cresc rezistența fizică și forța musculară, permit mușchilor și oaselor să devină mai puternice.

5. **un somn mai bun** corpul devine eliberat de stres și se permite starea de relaxare a minții. O minte relaxată va câștiga pe deplin de beneficiile somnului: funcția imunitară, memorie bună, ajută la relaxarea corpului și a mușchilor, deci organismul funcționează mai bine.

2. Componenta Vital Sign Monitoring (VSM)

Componenta VSM oferă o soluție funcțională de tip calendar al cărui scop este să amintească utilizatorului: 1. când trebuie să își ia medicația și 2. să își verifice și să comunice valorile analizelor zilnice/periodice pentru a fi analizate dacă se încadrează în limitele normale. Pentru cei care suferă de boli cronice, medicamentele luate la timp sunt cel mai important lucru, motiv pentru care considerăm că starea de sănătate poate fi îmbunătățită cu ajutorul unei medicații administrate ritmic, la indicațiile medicilor curanți.

Astfel se ghidează conduita zilnică a vârstnicului amintindu-l să își ia medicamentele, să își măsoare tensiunea, insulina, temperatura, pulsul care vor fi introduse automat sau manual (în funcție de dispozitivul folosit), apoi în funcție de decizia medicului specialist să continue tratamentul sau să îl modifice. Aplicația nu urmărește să înlocuiască medicul care diagnostichează pacientul ci să ofere o soluție flexibilă de configurare a medicației și tratamentului cu rol ambulatoriu urmat de vârstnic, după ce a fost consultat un medic specialist și a dat un diagnostic în acest sens.

Componenta va permite:

- Introducerea valorilor zilnice/periodice ale parametrilor medicali măsurați - în funcție de valorile acestora putând să se actualizeze indicațiile de tratament.
- Realizarea de analize statistice cu privire la starea de sănătate a pacienților, frecvența puseelor de boală și intensitatea lor, etc.
- Instrucțiuni de administrare (e.g. dacă trebuie luat după masă/ înainte de masă, cu jumătate de oră înainte de mâncare, etc). Medicamentele vor putea fi luate după un program sau la un anumit interval de timp precizat în setarea inițială).
- Programul de administrare: medicul va avea de ales o anumită frecvență (odată pe zi, de 2/3 ori pe zi, la 4/6/12 ore, săptămânal, sau lunar).
- Generarea de remindere legate de activitatea zilnică a utilizatorului.

2.1 Aspecte de proiectare a bazei de date Mobile@Old

Valorile parametrilor medicali măsurați vor fi salvați automat sau manual în baza de date ce conține parametri medicali, descrisă în Figura 5.

Precizările realizate în interviurile de analiză au permis modelarea EHR în funcție de actori și roluri, în următorul mod:

- un bolnav are una sau mai multe boli cronice, în consecință are asociat unul sau mai mulți medici care îl urmăresc. Fiecare are acces la fișa pacientului (EHR-Electronic Health Record) și poate accesa tabelul de tratament și boli. Aceste boli vor fi asociate la una din categoriile descrise în detaliu în specificațiile de analiză.
- un bolnav are un sau mai mulți aparținători care îl urmăresc. Limităm la 3 și alertăm în ordinea introducerii lor.
- un kinetoterapeut tratează unul sau mai mulți bolnavi. El gestionează programul de recuperare individualizat – acest aspect va fi inclus în cadrul etapei 3/2016.
- Asociem 1-1 îngrijitor-bolnav

În continuare sunt descrise tabelele de mapare. Pot exista mai mulți medici care să se ocupe pentru diverse afecțiuni ale pacientului îngrijit.

VARSTNICI (VSC) - pentru gestionarea tuturor persoanelor îngrijite. Se specifică și parametri necesari pentru funcționarea aplicației Reminder legați de configurarea alarmelor. Aceste valori se pot actualiza pe parcurs de către îngrijitor. Nu s-a setat vreo parolă din motive de accesibilitate.

MEDICAMENTE_GENERICE (MGC) - gestionează lista de medicamente generice, în funcție de substanța activă. O înregistrare în această tabelă se face pentru fiecare denumire științifică și formă de prezentare a unei astfel de denumiri. În mod normal ar trebui să separăm forma de prezentare și concentrația substanței active în toate variantele de comercializare în mai multe entități/tabele diferite, însă presupunem că nu va exista o gamă așa diversificată de produse administrate. Nu intenționăm să facem un catalog al tuturor combinațiilor posibile, ci doar a celor administrate efectiv.



Figura 5. EHR (Electronic Health record) Mobile@Old

TIPURI_OBICEI_ZILNIC (TOZ) - descrierea posibilelor obiceiuri zilnice ale unui vârstnic. Aceste informații nu sunt incluse în cadrul profilului pacientului, pentru ca anumite elemente pot diferi între persoane (unii servesc 3 mese pe zi, alții două, alții mai multe). Dintre aceste obiceiuri ne interesează în special servirea mesei, trezit, culcat.

TIPURI_AFECTIUNE (TAE) - descrierea posibilelor afecțiuni ale unui vârstnic în raport cu starea de sănătate.

TIPURI_ANALIZE_EXERCITII (TAU) - Utilizăm această tabelă pentru descrierea diferitelor tipuri de analize pe care le poate un pacient și a exercițiilor kineto. Ulterior se vor aduce îmbunătățiri pe partea de gestiune a acestor exerciții, care vor implica noi tabele.

TIPURI_ALERTE (TAA) - descrierea tipurilor de alerte și severitatea lor. Spre exemplu, la o analiză, dacă se depășește cu un anumit procent limita minimă/maximă a intervalului de normalitate a analizei, să se declanșeze o alertă. Se vor atribui sunete de alarmă specifice, pentru a fi ușor de recunoscut de către cei implicați.

ANALIZE_STANDARD (ASD) - descrierea intervalelor de normalitate ale valorilor analizelor sau a diferitelor măsurători. Anumite analize sunt influențate de vârstă și/sau sexul pacientului. Valorile normale pot fi intervale sau valori mai mici/mari decât un anumit număr. De aceea, anumite valori sunt opționale, însă nu pot rămâne necompletate ambele capete ale intervalului.

VARSTNIC_OBICEIURI (VOI) - cuprinde schița în timp obiceiurile zilnice ale vârstnicului, față de care ne ghidăm când administrăm tratamentul.

VARSTNIC_AFECTIUNI (VAE) – asociere a afecțiunilor pacienților și stadiile afecțiunilor despre care se știe că suferă. Afecțiunile pot să fi fost diagnosticate de către alți medicii, diferiți de cei activi din lista noastră.

MEDICAMENTE (MDT) - gestiunea listei de medicamente. O înregistrare în această tabelă se face pentru fiecare denumire comercială. Între nespecialiști (aparținători și pacienți) limbajul uzual nu presupune utilizarea denumirilor oficiale ale substanței active. Mai degrabă se vorbește despre Algotamin sau Algozone decât despre metamizol sodic.

PROGRAMARE_ANALIZE (PAA) - ține evidența programărilor diferitor tipuri de analize.

IST_ANALIZA_ADMIN_MED (IAT) - jurnalizează toate evenimentele: efectuare analize, administrare medicamente, prealarme.

2.2 Achiziția parametrilor medicali

În vederea achiziției parametrilor medicali s-a ales utilizarea centurii BioHarness Zephyr.

2.2.1 Descriere generală

BioHarness este cea o tehnologie portabilă avansată pentru înregistrarea parametrilor fiziologici. Prin această tehnologie se monitorizează, analizează și înregistrează un număr mare de parametri fiziologici incluzând ECG, rata respiratorie, temperatura corpului, poziția corpului și accelerația. Utilizările tehnologiei BioHarness includ aplicații medicale, aplicații ergonomice, aplicații sportive, etc. Dispozitivul BioHarness conține o bandă de prindere (în dreptul inimii) precum și o bandă opțională de fixare peste umar. Datele fiziologice sunt transmise prin protocol radio Bluetooth sau protocol standard 802.15.4 către un computer / tableta / smartphone. Componentele sistemului BioHarness sunt prezentate în Figura 6 unde se prezintă și tricouri incorporând senzorul BioHarness.

Dispozitivul BioHarness operează în două moduri:

- **Modul de monitorizare:** în care senzorul BioHarness transmite prin Bluetooth date live care pot fi vizualizate ad-hoc (Figura) sau stocate, analizate și vizualizate ulterior înregistrării lor folosind software-ul AcqKnowledge.
- **Modul de încărcare și configurare:** în care senzorul BioHarness este pus în stația de încărcare care este conectată prin USB la un calculator. Configurarea dispozitivului BioHarness se face cu ajutorul unor program software livrat împreună cu dispozitivul. Acestea citesc toate proprietățile software și hardware ale dispozitivului; afișează și configurează parametri de configurare ai transmisiilor Bluetooth; afișează și configurează transmiterea datelor și/sau modul de conectare; setează ceasul intern al dispozitivului, data și ora.




Figura 6. Componentele dispozitivului BioHarness.




Figura 7. Două instanțe ale interfeței software-ului de vizualizare a datelor.


Dispozitivul poate fi configurat să transmită date prin Bluetooth și/sau 802.15.4, și /sau să stocheze date în memoria internă. Pornirea dispozitivului va iniția fie un mod, fie ambele moduri.

2.2.2 Setarea modului de transmitere

1. Deschide Aplicația pe calculator.
2. Se face click pe butonul “Select Device” și se folosește lista existentă pentru a selecta modulul BioHarness, identificat prin numărul său de serie. Această listă va afișa în mod automat numărul de serie al oricărui dispozitiv conectat la PC.



3. Pentru a activa modulele de transmitere, se selectează meniul “User Config” din “Config Tool” și se bifează “Bluetooth Enable” și/sau “ECHO Enable”. ECHO desemnează modul de transmitere prin 802.15.4.



2.2.3 Transmiterea prin Bluetooth

Meniul Bluetooth din Configurarea centurii Zephyr permite următoarele configurări:

1. Network ID-eticheta cu care este găsit dispozitivul când este scanat. Implicit este numărul de serie al dispozitivului.
2. Bluetooth-ul este detectabil – dispozitivul este setat să fie nedetectabil dacă este necesar. Implicit este detectabil.
3. Setările perioadei Link Timeout și Lifesign. Valorile implicite pentru folosirea software-ului OmniSense a lui Zephyr sunt arătate mai sus.
4. Alte setări "Bluetooth Devices to Call" sunt pentru configurarea BioHarness pentru a se conecta la senzorii auxiliari pentru folosirea sistemului de monitorizare PSM a lui Zephyr. Acestea vor fi setate în mod automat pentru utilizare.

2.2.4 Transmiterea 802.15.4 (ECHO)

Meniul Bluetooth din Unelte de Configurare permite configurarea prezentată în figura de mai jos.

Short transceiver Address este setată pentru folosirea ca adresă de polling în conjuncție cu sistemul de pregătire PSM (Physical Status Monitoring) a centurii. Această valoare este configurată din fabrică deoarece trebuie să fie unică în sistem (0- 254). Nivelul puterii transmisiei RF este configurat din fabrică la 19 dB. Max. Repeaters: repetări maxime definește numărul maxim de unități ale receptorului ECHO care poate fi folosit într-un sistem PSM. Max. Repeats: numărul maxim de salturi de repetiție permise într-un sistem PSM este următorul parametru. Beacon Interval (ms) reprezintă intervalul de avertisment și este configurat din fabrică.

2.2.5 Indicativele de culori

Dispozitivul BioHarness folosește un cod de culori pentru a indica stările subiectului monitorizat:

- Verde – parametri fiziologici ai subiectului sunt în limitele valorilor prestabilite la configurarea dispozitivului;
- Portocaliu – unul sau mai multi parametri au depășit valoarea pragului configurat prin urmare persoana trebuie să fie monitorizată mai atent.
- Roșu – unul sau mai mulți parametri au depășit valorile pragului pentru o perioadă susținută (configurabilă). Parametri fiziologici trebuie monitorizați atent și căutată confirmarea dacă există o indicație de stres, oboseală sau traumă.

Starea subiectului este determinată analizând pulsul, rata respiratorie și valorile nivelului de activitate calculate pentru o medie de timp de peste 5 secunde. Nivelul de activitate este măsurat de către un accelerometru încorporat în dispozitivul BioHarness. Parametri sunt determinați a fi scăzuți sau mari conform pragurilor din Figura 8.

Dacă oricare din parametri din Figura 9 trec de la zona normală (verde) la valori scăzute sau mari (portocaliu sau roșu) atunci starea subiectului poate crește de la Normal la Alertă conform tabelului 2. Valorile numerice implicite ale pragurilor sunt setate în mod automat și nu trebuie schimbate pentru operațiunile normale. O stare fără Alertă timp de 5 secunde va reduce Starea de la roșu la portocaliu, sau de la portocaliu la verde.




Figura 8. Pragurile de valori și nivelurile de activitate.

Tabelul 2 – Starea subiectului

Pulsul inimii	Viteza respirației	Nivelul de Activitate	Stare
NORMAL	NORMAL	NORMAL	Fara Alerta
SCAZUT			Alerta
	SCAZUT		Alerta
MARE		SCAZUT	Alerta
	MARE	SCAZUT	Alerta

2.2.6 Interpretarea datelor

Dispozitivul BioHarness a fost dezvoltat pentru a furniza la distanță valori contextuale ale parametrilor fiziologici. El poate fi folosit ca o unealtă ajutătoare în procesul de diagnostic al unei condiții anormale. Dispozitivul poate indica faptul că valorile parametrilor fiziologici ai unui utilizator sunt în afara limitelor acceptabile. Interpretarea unor astfel de informații trebuie însă făcută contextual, luându-se în considerare următoarele:

- Informații privind condiția fizică a utilizatorului, precum condiția fizică și probleme de tensiune arterială;
- Existența unui fond de oboseală, deshidratare, infecție, traumă, etc;
- Factori de mediu precum temperatura ridicată sau umiditate;
- Orice circumstanță care poate duce la o stare de frică, panică, oboseală și care produc creșteri ale pulsului.

2.2.7 Experimente preliminare cu dispozitivul BioHarness

Centura BioHarness a fost testată inițial atât de membrii echipei CITST cât și de cei ai partenerului UPB. Au fost create trei profile de utilizatori (Figura) care au fost apoi folosite pentru testarea centurii de către utilizatori din afara organizației.

În toate testele efectuate, setarea și utilizarea centurii a fost făcută conform descrierii din secțiunea anterioară. Pentru vizualizarea datelor înregistrate s-a utilizat software-ul Zephyr Omnisense care permite conectarea a 50 centuri BioHarness cu un calculator rulând Windows. Software-ul permite înregistrarea, până la o distanță de 300 m, și analiză a parametrilor fiziologici ai utilizatorilor oferind și evaluările de trend pentru anumiți parametri.

În cele ce urmează este exemplificată o sesiune de test pentru utilizatorul CITST User-2. În Figura 10 se poate vedea etapa de conectarea a centurii BioHarness purtată de utilizatorul 2 la laptopul rulând software-ul Zephyr Omnisense. În partea dreaptă a Figurii 10 este indicat cu verde faptul că centura este conectată wireless la laptop. Concomitent începe înregistrarea bătăilor inimii (88 bpm), ratei respiratorii (18) și temperaturii corpului (37.5 grade).

Parametri de mai sus (puls, respirație și temperatură) sunt apoi măsurați live în repaus (Figura 11) și apoi în timpul unei activități fizice (Figura 12). Se poate vedea în Figura 11 că nivelul de activitate este în zona verde și marcat în general ca fiind static. În timpul mișcării, utilizatorul se înclină în dreapta ceea ce este măsurat de accelerometrul încorporat în centura BioHarness și indicat prin săgeata de jos în sus și oblic din cadranul utilizatorului 2.

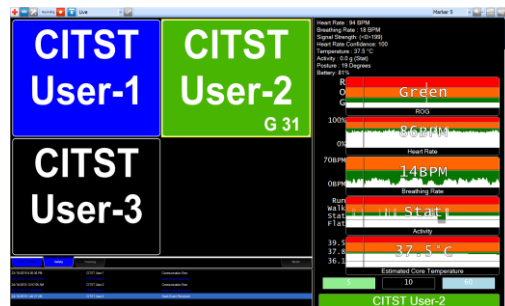


Figura 9. Trei profile de utilizatori create prin softwareul Omnisense.

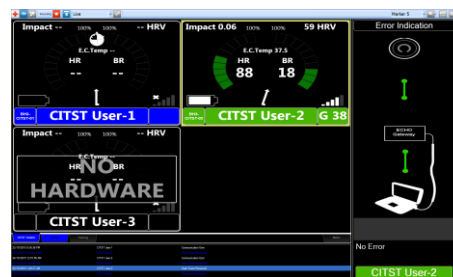


Figura 10. Conectarea wireless a centurii BioHarness purtată de utilizatorul 2 la laptopul rulând software-ul Zephyr Omnisense.



Figure 11. Înregistrarea parametrilor fiziologici (puls, respirație și temperatură).

În Figura 12 se poate vedea că utilizatorul intensifică mișcarea și ca urmare pulsul acestuia crește la 104 bpm. Acest lucru se datorează și mișcării de sărire indicată de graficul "Vertical" din dreapta Figurii 12.



Figura 12. Înregistrarea parametrilor fiziologici live în mișcare.

2.2.8 Achiziția datelor provenite de la centură

Pentru ca parametri vitali ai utilizatorului să fie atent monitorizați, dar și menținuți în sistem spre o analiză ulterioară, este necesară o arhitectura special proiectată urmând anumite principii conceptuale, respectiv: mobilitatea utilizatorului, corectitudinea datelor și asigurarea unei conexiuni sigure între device-ul de colectarea a datelor și sistemul de stocare. Spre a îndeplini aceste cerințe, a fost definitivată o arhitectură ce are în componență trei nivele: nivelul de achiziție a datelor, nivelul de comunicație și nivelul de stocare și analiză a datelor (Figura 13).

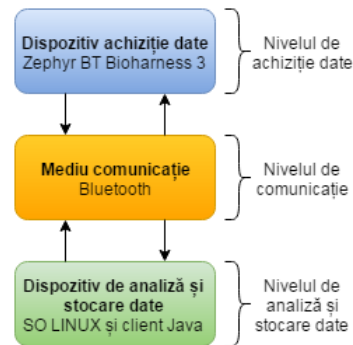


Figura 13. Descrierea modului de achiziție a datelor provenite de la centura Bioharness

Nivelul achiziție date - Primul nivel în arhitectura sistemului este cel de achiziție a datelor. Responsabilitatea acestui nivel este de a înregistra parametrii vitali ai unei persoane și de trimite datele încapsulate printr-un anumit mediu de comunicație către un nivel superior în cadrul arhitecturii aplicației. Spre a răspunde unei categorii mai largi de aplicații din domeniul IOT, a fost ales un echipament hardware specializat și acreditat pentru a efectua măsurători coerente ale parametrilor vitali ai unei persoane. Centura de monitorizare a parametrilor vitali, Zephyr Bioharness 3 a răspuns tuturor solicitărilor, fiind utilizată pe scară largă de către atleți de performanță pentru îmbunătățirea tehnicilor sportive. De asemenea pentru mobilitatea utilizatorului, centura comunica cu nivelul de analiză și stocare date prin intermediul tehnologiei Bluetooth.

Figura 14 prezintă structura pachetelor din cadrul comunicației centurii de măsurare a parametrilor vitali cu nivelul de analiză și stocare a datelor. După cum se poate observa, deasupra tehnologiei Bluetooth a fost implementat un protocol half-duplex and UART bazat pe un mecanism simplu de cerere-răspuns. Cadrul construit de dispozitivul de achiziție a datelor este încadrat între biții de STX și ETX marcând începutul și sfârșitul pachetului transmis. De asemenea fiecare mesaj are un identificator unic (Msg ID), în format binar. Mesajul de răspuns are același identificator cu cel de cerere.

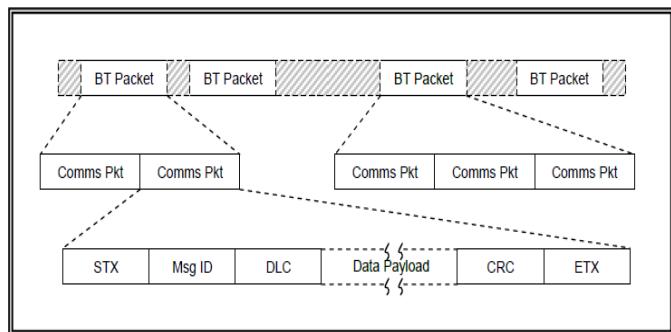


Figura 14. Structura pachetelor

În componența cadrului, este prezentă și dimensiunea datelor disponibile (DLC) care poate avea valori între 0 și 128. Câmpul de date disponibile (Data Payload) reprezintă datele propriu-zise care circulă prin intermediul tehnologiei Bluetooth. Dimensiunea acestui câmp este dictată de câte câmpul DLC. Spre a se asigura că datele ce circulă între nivelul de stocare și analiză și nivelul de achiziție sunt corecte și nealterate de către mediul de transmisie, a fost inclus în cadrul pachetului și un câmp dedicat calculului unei sume de control (CRC). Suma de control este calculată de către expeditor și verificată ulterior de către destinatar. În cazul în care verificarea eșuează, pachetul este respins. După cum se observă în Figura 14, într-un pachet Bluetooth, pot fi incluse mai multe pachete de măsurători, astfel soft-ul utilizat pentru interpretarea pachetelor va trebui să permită extragerea unui singur sau a mai multor pachete dintr-un singur pachet Bluetooth (Figura 15).

În acest fel, orice dispozitiv, apt de a comunica prin intermediul tehnologiei Bluetooth și care implementează protocolul descris mai sus, poate achiziționa date de la centura Zephyr BioHarness 3, rezultând o mare compatibilitate și o mai ușoară integrare în orice aplicație a acestui dispozitiv de achiziție a datelor.

Nivelul de comunicație - Abstractizarea sistemului a condus la apariția unui nivel teoretic și anume, nivelul de comunicație. În practică, dispozitivul ales pentru achiziția datelor poate implementa și funcționalitatea de comunicare astfel fuzionând cele două niveluri. În contextul aplicației curente, comunicația se realizează prin

tehnologia Bluetooth, entitățile comunicante, având module emițător-receptor Bluetooth. Consumul redus de energie al tehnologiei Bluetooth a condus la alegerea acesteia în detrimentul tehnologiei Wi-Fi.

```

public byte [] getSetSerialNumberMessage(boolean activate) {
    byte[] message = new byte[] {0x02, 0x0B, 0x01, 0x00, 0x00, 0x03};

    if (activate == true)
        message[3] = 0x01;
    byte[] crcCalc = new byte[1];
    System.arraycopy(message, 3, crcCalc, 0, 1);
    message[4] = _crc8.Calculate(crcCalc);

    return message;
}

```

Figura 15. Exemplu funcție construcție pachet de request Serial Number

Nivelul de analiză și stocare date - Ultimul nivel în cadrul arhitecturii generale a sistemului este reprezentat de nivelul de analiză și stocare date. Acestui nivel îi revine datoria de a se conecta la dispozitivul de achiziție, de a iniția transmisia datelor, de a asigura permanenta conexiune și de a stoca ulterior datele achiziționate. Implementarea protocolului de comunicație a fost realizată în limbajul Java, urmărind o portabilitate oferită de acest limbaj spre a fi posibilă schimbarea o eventuală schimbare a sistemului de operare în cazul în care o serie de noi cerințe arhitecturale o vor cere. Sistemul de operare ales este de tipul UNIX, deoarece oferă posibilitatea unui control mai mare asupra comunicației și proceselor din sistem. Programul în Java, utilizează pentru comunicație un stream de date ce trebuie expus de către sistemul de operare. Pentru a deschide și expune un stream de date în sistemul de operare UNIX, spre a comunica cu un dispozitiv prin tehnologia Bluetooth, a fost utilizat utilitarul RFCOMM (Figura 16).

Nivelul de analiză și stocare date - Ultimul nivel în cadrul arhitecturii generale a sistemului este reprezentat de nivelul de analiză și stocare date. Acestui nivel îi revine datoria de a se conecta la dispozitivul de achiziție, de a iniția transmisia datelor, de a asigura permanenta conexiune și de a stoca ulterior datele achiziționate. Implementarea protocolului de comunicație a fost realizată în limbajul Java, urmărind o portabilitate oferită de acest limbaj spre a fi posibilă schimbarea o eventuală schimbare a sistemului de operare în cazul în care o serie de noi cerințe arhitecturale o vor cere.

Sistemul de operare ales este de tipul UNIX, deoarece oferă posibilitatea unui control mai mare asupra comunicației și proceselor din sistem. Programul în Java, utilizează pentru comunicație un stream de date ce trebuie expus de către sistemul de operare. Pentru a deschide și expune un stream de date în sistemul de operare UNIX, spre a comunica cu un dispozitiv prin tehnologia Bluetooth, a fost utilizat utilitarul RFCOMM (Figura 16).

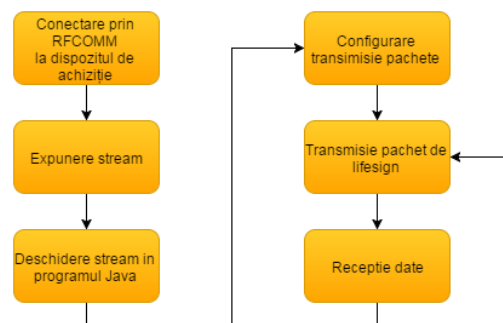


Figura 16. Etape transmisie și recepție date

Conectarea la dispozitivul Bluetooth de achiziție a datelor, se realizează prin intermediul utilitarului RFCOMM. Printre opțiunile sale se numără: găsirea dispozitivelor Bluetooth din proximitate, pairing cu un dispozitiv din lista celor găsite anterior și în final expunere stream în sistemul de fișiere /etc/RFCOMM0. Managementul conexiunii este asigurat de către acest utilitar ce are implementată toată stiva aferentă tehnologiei Bluetooth. După ce stream-ul a fost expus în sistemul de fișiere, trebuie acordate permisiuni de scriere și citire, necesare pentru ca programul în Java să poată deschide, ulterior efectuând operații de citire și scriere (Figura 17).

Programul Java conține întreaga implementare a protocolului half-duplex UART ce este utilizat de centura Zephyr BioHarness 3 pentru comunicare. Toate pachetele din documentația producătorului au fost implementate pentru a oferi un control absolut asupra funcționalităților. De asemenea, au fost implementate funcții destinate construirii și parsării pachetelor. În cadrul procedurii de inițializare a sistemului, după ce utilitarul RFCOMM a expus un stream în sistemul de fișiere, programul Java va deschide acel stream și va menține în această stare până în momentul în care utilizatorul decide deconectarea de la dispozitivul de achiziție. Un prim pas în inițierea transmisiei de date este configurarea pachetelor ce vor fi transmise de către dispozitivul de achiziție. Configurarea se realizează prin modelul cerere-răspuns: se trimite un pachet de configurare cu un anumit identificator și se așteaptă recepția unui pachet de răspuns cu același identificator având bitul de răspuns setat pe ACK pentru succes sau NAK pentru eșec. În continuare pentru a semnala dispozitivului de achiziție pornirea măsurătorilor, se trimite un pachet special de lifesign. După ce acest pachet a fost recepționat, centura Zephyr BioHarness 3 va trimite măsurători la un anumit interval de timp. Pachetul special de lifesign trebuie trimis permanent pentru ca dispozitivul de achiziție să nu închidă linia de comunicație.

```

echo "INFO: Start scanning..."
hcitool scan > $TEMP_RESULT_FILE
cat $TEMP_RESULT_FILE | tail -n +2

DEVICE_MAC=$(cat scan_result.dat | grep "$DEVICE_NAME" | cut -f2 -s)
echo "INFO: Found device $DEVICE_MAC"

echo "INFO: Register device code: [PIN: $DEVICE_PIN]"
bluetooth-agent "$DEVICE_PIN" &

echo "INFO: Create link to [$RFCOMM_NR] [MAC: $DEVICE_MAC]"
sudo rfcomm connect "$RFCOMM_NR" "$DEVICE_MAC" &

sleep 6

echo "INFO: Add read/write permissions to [$PATH_TO_RFCOMM/$RFCOMM_NR]"
sudo chmod 777 "$PATH_TO_RFCOMM/$RFCOMM_NR"

```

Figura 17. Script conectare RFCOMM și expunere stream

O dată ce un pachet cu măsurători ajunge la nivelul de analiză și stocare a datelor, acesta este parsat, informația fiind ulterior stocată într-o bază de date pentru o eventuală analiză amănunțită a parametrilor vitali măsurați (Figura 18).

```

new Thread() {
public void run() {
try {
Thread.sleep(800);
} catch (InterruptedException e) {
e.printStackTrace();
}
GetSerialNumber(true);
SetGeneralPacket(_ZephyrRequestedPacketTypes.GP_ENABLE);
SetECGPacket(_ZephyrRequestedPacketTypes.ECG_ENABLE);
SetBreathingPacket(_ZephyrRequestedPacketTypes.BREATHING_ENABLE);
SetRtoRPacket(_ZephyrRequestedPacketTypes.RtoR_ENABLE);
SetAccelerometerPacket(_ZephyrRequestedPacketTypes.ACCELEROMETER_ENABLE);
SetSummaryDataPacket(_ZephyrRequestedPacketTypes.SUMMARY_ENABLE);
SetEventPacket(_ZephyrRequestedPacketTypes.EVENT_ENABLE);
SetLoggingDataPacket(_ZephyrRequestedPacketTypes.LOGGING_ENABLE);
SendLifeSign();
}
}

```

Figura 18. Exemplu funcție configurare recepție pachete

2.3 Analiza dispozitivelor necesare determinării căderilor și a nivelului de mobilitate

Căderile sunt o problema majoră pentru vârstnici reprezentând una din principalele cauze de accidentări și spitalizări. De asemenea, mobilitatea este un bun indicator al stării de sănătate al persoanelor vârstnice la care schimbări în tiparele de mobilitate pot semnaliza stadiul incipient al unor probleme neurodegenerative. De exemplu, deplasarea repetitivă între aceleași două puncte în interiorul locuinței poate fi asociată cu probleme de memorie iar rămânerea în aceeași poziție pentru perioade lungi de timp poate indica stări depresive.

În contextul importanței recunoscute al detectării căderilor și mobilității la interior s-au dezvoltat o serie de tehnologii cu utilitate în aceste doua domenii. În (Lohan et al., 2015) s-au analizat aceste tehnologii din punct de vedere al avantajelor și dezavantajelor pe care le oferă precum și din punctul de vedere al percepției utilizatorilor. Percepția utilizatorilor a fost evaluată în România pe baza unui sondaj de opinie efectuat în cadrul actualului proiect. Informațiile obținute în baza sondajului au fost corelate cu informații obținute de la utilizatori din alte patru țări europene precum și cu informațiile experților privind tehnologiile în cadrul unui proces de analiză analitică ierarhică (Analytic Hierarchy Process - AHP) pentru a evalua cea mai adecvată tehnologie pentru persoanele vârstnice care să semnaleze căderile și modificările în mobilitate. Tabelul 3 prezintă informații asupra utilizatorilor participanți la sondajele de opinie efectuate.

Analiza tehnologiilor din punct de vedere al avantajelor și dezavantajelor acestora a inclus tehnologii wearable (utilizatorul poartă un mic dispozitiv/senzor care comunică cu senzori instalați în locuința acestuia) precum și tehnologii fără dispozitiv purtat de utilizator. Acestea din urmă au avantajul ca se evita situația în care utilizatorul uită să poarte dispozitivul sau senzorul de detecție. Din ambele categorii au fost prezentate și analizate tehnologii bazate pe RFID (radio frecvență), BLE (Bluetooth), WiFi și UWB (banda ultra largă).

Datele aferente analizei se pot descărca de la următorul link: <http://goo.gl/GuklMB>. În urma analizei efectuate s-a obținut clasificarea din Tabelul 4. În acest tabel tehnologiile sunt ordonate începând cu cea mai adecvată (locul 1) și terminând cu cea mai puțin adecvată (locul 10) din punct de vedere al utilizatorilor vârstnici precum și pe baza

a cinci criterii multi-dimensionale de optimizare. Tehnologia care s-a clasat pe primul loc este cea bazată pe BLE (cu sau fara dispozitiv purtat de utilizator) fiind urmat de de tehnologiile WiFi. Cea mai puțin acceptată este tehnologia bazată pe RFID din cauza costului ei ridicat, acurateții scăzute și lipsei de confort atunci când este instalată în interiorul locuinței (este necesară montarea unui număr foarte mare de senzori).

Tabelul 3. Informații asupra respondenților la sondajele de opinie.

Tara de origine	RO	CH	FR	PL	SL	Total
Numărul	61	6	10	44	32	153
Numărul mediu de	3.2	6.7	3.8	3.1	5.2	4.4
Vârsta medie [ani]	73.1	74.3	81.7	74.0	70.3	74.7
Vârsta cea mai	65	72	86	65	66	65
% persoane care	27.9	50	60	27.3	25	38.0
% femei	60.6	50	60	45.4	75	58.2
% având o condiție	78.7	66.7	80	59.1	53.1	67.5

Tabelul 4. Clasificarea tehnologiilor pe baza metodei de analiză AHP.


Loc în clasament	Tipul de tehnologie	Grad de adecvare conform AHP
1	BLE tag + rx instalată în locuință	14.41%
2	tag accelerometru + rx în locuință	12.71%
3	tag WiFi + rs în locuință	12.64%
4	tag UWB + receptor în locuință	11.27%
5	sistem de captat imagini / camere video	9.40%
6	sistem montat în locuință de UWB	8.93%
7	tag RFID + cititoare în locuință	8.70%
8	WiFi în locuință	8.22%
9	sistem BLE în locuință	7.84%
10	sistem RFID în locuință	5.84%

2.4 Analiza stării de sănătate pe baza parametrilor medicali achiziționați

În cadrul etapei curente au fost realizate două modalități de analiză a datelor medicale. Prima abordare folosește analiza datelor conceptuale aplicată pe un set de date medicale, folosind o matematizare a noțiunii clasice de concept, ce are la bază paradigma procesare a cunoștințelor formale (Conceptual Knowledge Processing). Pornind de la această premisă, s-a propus o metodă mai naturală, utilizabilă de către factorul uman pentru a putea investiga, reprezenta, procesa și dobândi cunoștințe de la o bază de date medicală (**Taut et al., 2015**). Întregul proces medical devine acum un suport rațional, care deschide posibilitatea de a descoperi noi conexiuni, sau pentru a oferi unele sugestii pentru clinicieni. Acest studiu a fost efectuat cu scopul de a pune în aplicare un sistem de vizualizare pentru comportamentul cunoștințelor în setul de date cardiovasculare fundamentat pe paradigma Conceptual Knowledge Processing (procesarea conceptuală a cunoștințelor). Cea de a doua abordare se referă la folosirea metodelor de inteligență artificială în vederea detectării unui trend ascendent/descendent al parametrilor medicali achiziționați (s-au folosit tensiunea sistolică, diastolică și pulsul stocate de la o singură persoană pe durata a patru luni de zile. Ceea ce ne interesează este detectarea unui trend ascendent sau descendent ce va fi folosit ulterior (în cadrul etapei 3/2016) în vederea adaptării exercițiilor fizice ce urmează a fi indicate utilizatorului spre a fi executate. Pentru analiza datelor medicale s-au folosit metodele: linear regression, generalized linear models (Ridge Regression, Lasso). Pe baza erorilor calculate, eroarea minimă în identificarea trendului a fost obținută folosind metoda Linear Regression în care s-a identificat trendul ascendent al evoluției parametrilor medicali (trend ce corespunde cu realitatea) – cum este exemplificat în Figura 19 (graficul albastru reprezintă evoluția prezisă, iar cel verde evoluția reală).



Tensiunea sistolică



Tensiunea diastolică



Pulsul

Figura 19. Evoluția parametrilor medicali

3. Physical Activity Trainer

3.1 Experimente preliminare cu senzorul Kinect

Tehnologia de achiziție a gesturilor efectuate cu întreg corpul (*en.*: whole-body gestures) aleasă în vederea implementării aplicației Physical Activity Trainer (PAT) este reprezentată de către senzorul Microsoft Kinect (Kinect, 2015a).

3.1.1 Descrierea senzorului Kinect (pentru Xbox 360)

Senzorul Kinect se bazează pe tehnologia de detectare în adâncime (depth sensing technology) prin care este capabil să detecteze localizarea și mișcarea oamenilor și a vocilor lor. Senzorul Kinect încorporează tehnologii hardware avansate pentru detectare (sensing). Dintre acestea, de menționat sunt un senzor de adâncime, o cameră color și un ansamblu de patru microfoane care asigură captarea 3D a mișcării întregului corp 3D și recunoașterea trăsăturilor faciale. De asemenea, aceste tehnologii oferă capacități pentru recunoașterea vocii.

Senzorul Kinect furnizează trei tipuri de fluxuri de date:

- (1) Fluxul video *color* cu rezoluții disponibile ale imaginilor de 640×480 pixeli (VGA), respectiv 1280×960 pixeli (UVGA sau SXGA-), furnizate la viteze de 15, respectiv 30 de cadre pe secundă în formatele de culoare RGB și YUV.
- (2) Fluxul video în domeniul *infraroșu* furnizat la o rezoluție de 640×480 pixeli (VGA) și o viteză a cadrelor de 30 fps.
- (3) Fluxul video de *adâncime* cu rezoluții disponibile de 80×60, 320×240, respectiv 640×480 pixeli, 30 fps, care furnizează date privind adâncimea scenei și a obiectelor prezente în raza de acțiune a senzorului cu valori exprimate în unități fizice (mm).
- (4) Fluxul de date de tip *schelet* oferă coordonatele 3-D ale unor puncte cheie localizate pe corpul utilizatorului, puncte urmărite de la cadru la cadru cu o frecvență măsurată de aproximativ 30 fps (care poate varia în funcție de gradul de încărcare a procesorului CPU). În cadrul acestui flux de date, fiecare persoană detectată și urmărită de către senzorul Kinect în zona sa de acțiune (*i.e.*, între 80 cm și 4 m față de senzor) este reprezentată sub forma unei mulțimi alcătuită dintr-un număr fix de 20 de puncte distribuite uniform pe suprafața corpului, a se vedea (Kinect, 2015b) pentru localizarea precisă a acestor puncte.

Aceste date sunt specifice versiunii hardware 1.0 a senzorului Kinect, respectiv versiunii 1.8 a bibliotecii de dezvoltare a aplicațiilor (Kinect, 2015d). Datele oferite de către senzor sunt preluate pe portul USB prin intermediul tipurilor de date, funcțiilor și evenimentelor din clasele și obiectele predefinite în cadrul librăriei Microsoft Kinect SDK, librărie dezvoltată pentru platforma .NET (a se vedea specificațiile de dezvoltare pentru Windows la adresa www.kinectforwindows.org).

3.1.2 Achiziția datelor

În urma analizei tipurilor de date furnizate de către senzorul Microsoft Kinect, am selectat *fluxul video de adâncime*, respectiv *fluxul de date de tip schelet* ca fiind relevante și importante pentru atingerea scopurilor propuse pentru aplicația Physical Activity Trainer. În această etapă de realizare a experimentelor cu ajutorul senzorului Kinect nu a fost considerat fluxul video color. Acest lucru a fost eliminat din implementare datorită faptului că utilizarea sa ar putea fi percepută drept o invadare a spațiului personal, respectiv intimității utilizatorului în timpul realizării exercițiilor de antrenament fizic, acest lucru reprezentând o problemă des amintită și discutată în comunitate; a se vedea, de exemplu, (Kinect, 2015c). Imaginile color pot fi folosite pentru construcția unui joc prin care utilizatorul să realizeze exercițiile fizice recomandate – joc format dintr-un avatar și obiectele aflate în mediul înconjurător real al utilizatorului. În acest sens s-a folosit senzorul Kinect pentru a testa recunoașterea obiectelor din jurul persoanei supravegheate. A fost propus un algoritm de recunoaștere a obiectelor (**Petroniu et al., 2015**), care constă în o rețea poligonală 3D asociată obiectului (prin achiziția datelor de la Kinect), urmând ca apoi recunoașterea să se facă folosind metoda "geometric hashing", prin identificarea părților principale ale obiectelor. Construcția jocului pentru realizarea exercițiilor fizice folosind modelarea 3D va fi realizată în etapa următoare. În prezent este folosit fluxul video de adâncime și scheletul, care permit o captură a mișcărilor utilizatorului care este reprezentat sub forma unei siluete impersonale (vezi Figura 20) cu o cantitate de informație vizuală suficientă pentru a înțelege specificul mișcării și care atenuează totodată detaliile ce particularizează în mod obișnuit utilizatorul (*e.g.*, fața, hainele, mediul înconjurător, etc.). În același timp, fluxul de date de tip schelet permite o identificare precisă a fiecărei părți a corpului aflate în mișcare, permițând o reprezentare a mișcărilor de antrenament fizic sub forma de serii de timp multi-dimensionale (în cazul versiunii 1.8 a senzorului este vorba despre 20×3=60 dimensiuni de captură a datelor de mișcare). Cele două tipuri de fluxuri de date au fost evaluate și apreciate ca fiind corespunzătoare pentru adresarea celor două deziderate principale ale aplicației Physical Activity Trainer în cadrul proiectului Mobile@Old, și anume:

- (1) *Oferirea de exemple de exerciții de antrenament utilizatorului pentru ghidarea activităților acestuia*. Până acum, literatura domeniului a considerat diverse modalități de a furniza exemple de mișcări gestuale care au luat

forma înregistrării video (Gillies *et al.*, 2015), a mișcărilor generate automat de către modele 3D de tip avatar (Ebert *et al.*, 2015; Norris *et al.*, 2014; Zhang *et al.*, 2013), respectiv mișcări schițate prin utilizarea de reprezentări minimaliste ale utilizatorilor prin puncte și linii (Gillies *et al.*, 2015). Întrucât toate aceste abordări suferă limitări (e.g., afectarea intimității percepute de către utilizator prin înregistrare video, respectiv potențiale probleme de relaționare cu un avatar), am decis folosirea în cadrul aplicației Physical Activity Trainer a exemplarelor de exerciții de mișcare redată de siluete ale utilizatorilor, aspect pentru care fluxul de adâncime al senzorului Microsoft Kinect oferă, atât cantitativ cât și calitativ, datele necesare.

- (2) *Recunoașterea mișcărilor efectuate în timpul antrenamentului fizic* folosind algoritmi care operează direct asupra mulțimii de puncte de interes, puncte urmărite în timp real pe corpul utilizatorului și raportate de Kinect prin intermediul fluxului de date de tip schelet.

3.2 Înregistrarea datelor de mișcare

Pentru înregistrarea datelor de mișcare, a fost implementată o interfață experimentală care capturează, adnotează și salvează silueta utilizatorului, respectiv secvența de puncte urmărite pe corpul acestuia în fișiere video AVI, respectiv fișiere de date XML. Figura 20 ilustrează o captură ecran a interfaței dezvoltate pentru înregistrarea mișcărilor, Figura 21 prezintă secvențe ale siluetei utilizatorului capturate într-un fișier video, iar în Figura 22 este ilustrată o porțiune a unui fișier XML descriind mișcarea din Figura 21 sub forma unei serii de timp multi-dimensionale (i.e., fiecare postură din seria de timp cuprinde 20 de puncte localizate pe corpul utilizatorului, fiecare punct fiind caracterizat prin cele 3 coordonate x, y, z).

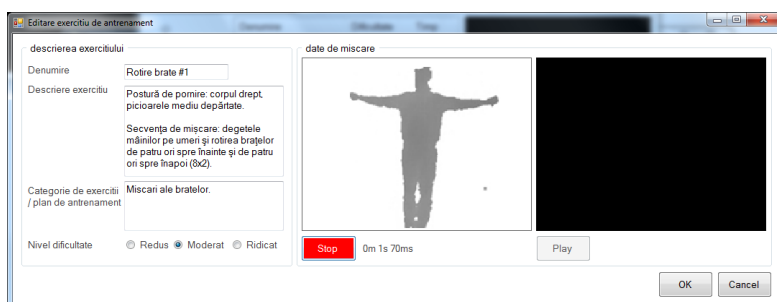


Figura 20. Interfața experimentală pentru înregistrarea și adnotarea datelor de mișcare.



Figura 21. Silueta unui utilizator efectuând un exercițiu de antrenament constând în întinderi și reveniri repetate ale brațelor. Mișcarea siluetei este înregistrată sub forma de fișiere video AVI comprimate folosind standardul MPEG4.

```
<BodyGesture Name="Rotire brate #1" Postures="298" Description="Postură de pornire: corpul drept, picioarele mediu depărtate. Degetele mâinilor pe umeri și rotirea brațelor de patru ori spre înainte și de patru ori spre înapoi (8x2). TrainingPlan="" Difficulty="0">
  <BodyPosture Time="41392461.0" Joints="28">
    <Joint Type="HipCenter" X="-0.579870462417683" Y="0.179364048493965" Z="2.54841375359952" />
    <Joint Type="Spine" X="-0.59168048511322" Y="0.249500751495361" Z="2.53586649894714" />
    <Joint Type="ShoulderCenter" X="-0.64988374718080" Y="0.602559404277802" Z="2.44931186193821" />
    <Joint Type="Head" X="-0.713977694511414" Y="0.798318684181105" Z="2.46820974349976" />
    <Joint Type="ShoulderLeft" X="-0.793828473854065" Y="0.59092925441742" Z="2.61805210876465" />
    <Joint Type="ElbowLeft" X="-0.567433536852704" Y="0.407060205936432" Z="2.66228079795837" />
    <Joint Type="WristLeft" X="-0.44672030210495" Y="0.214401483535767" Z="2.72805285453796" />
    <Joint Type="HandLeft" X="-0.495065301656723" Y="0.165149673819542" Z="2.68901170654297" />
    <Joint Type="ShoulderRight" X="-0.557556748390198" Y="0.455957919358207" Z="2.42809617218018" />
    <Joint Type="ElbowRight" X="-0.628937602043152" Y="0.181400181706537" Z="2.3134572743235" />
    <Joint Type="WristRight" X="-0.743561685885297" Y="0.0341404157910347" Z="2.22595524787903" />
    <Joint Type="HandRight" X="-0.8073515259598236" Y="0.0926263183355331" Z="2.21506190299988" />
    <Joint Type="HipLeft" X="-0.620499789714813" Y="0.18798092931509" Z="2.59225040704346" />
    <Joint Type="KneeLeft" X="-0.496491312980652" Y="0.406424768818481" Z="2.75840878486633" />
    <Joint Type="AnkleLeft" X="-0.594210591316223" Y="0.799908936023712" Z="2.75839185714722" />
    <Joint Type="FootLeft" X="-0.544692039489740" Y="0.831302344799042" Z="2.65108942855353" />
    <Joint Type="HipRight" X="-0.515786349773407" Y="0.117523662745953" Z="2.51907730102539" />
    <Joint Type="KneeRight" X="-0.540735960006714" Y="0.401440799236298" Z="2.51784873008728" />
    <Joint Type="AnkleRight" X="-0.562907040119171" Y="0.814998507499695" Z="2.53432488441467" />
    <Joint Type="FootRight" X="-0.620376884937286" Y="0.876709222793579" Z="2.50956892967224" />
  </BodyPosture>
  <BodyPosture Time="41392493" Joints="28">...</BodyPosture>
  <BodyPosture Time="41392524.2" Joints="28">...</BodyPosture>
</BodyGesture>
```

Figura 22. Reprezentarea mișcărilor sub forma unei secvențe de posturi consecutive în timp capturate de senzorul Microsoft Kinect. Secvența de posturi este înregistrată într-un fișier XML.

3.2 Modelul experimental al componente de recunoaștere a activităților fizice

Dezvoltarea modelului experimental pentru recunoașterea activităților realizate de către utilizatorii potențiali ai aplicației Physical Activity Trainer a fost realizată parcurgând următorii pași:

- (1) *Discuții cu un profesionist kinoterapeut* au condus la colectarea unui set de mișcări ale întregului corp reprezentând activități standard în ceea ce privește exercițiile de antrenament fizic (vezi exemple în Tabelul 5). Aceste mișcări pun în evidență importanța diverselor părți ale corpului uman în exercițiile de efectuat de

către persoanele în vârstă, precum și importanța capturii precise a părților corpului implicate în mișcările desfășurate.

- (2) *Structurarea modelului experimental* în componente specializate aferente proceselor de achiziție, recunoaștere și evaluare a mișcărilor utilizatorului, precum și considerarea unui modul de ghidare a acestuia în timpul efectuării exercițiilor de antrenare.
- (3) *Implementarea unui algoritm de recunoaștere a mișcărilor* de antrenament fizic.
- (4) *Identificarea unei metodologii de evaluare a mișcărilor* executate de către utilizatori relativ la exemplele de mișcări efectuate de către experți (i.e., analiza acurateții clasificatorului de mișcare) cât și relativ unele la celelalte (i.e., analiza de consens gestual inter-utilizatori).

Tabelul 5. Exemple de modele de exerciții de antrenament fizic.




Postură de pornire: corpul drept, picioarele mediu depărtate.

Secvența de mișcare: degetele mâinilor pe umeri și rotirea brațelor de patru ori spre înainte și de patru ori înapoi (8x2).



Postură de pornire: corpul drept, picioarele mediu depărtate.

Secvența de mișcare: brațul stâng sus iar cel drept jos, extensii ale brațelor trăgând spre spate, identic cu brațele schimbate (4x4).



Postură de pornire: fața spre scaun, corpul drept, picioarele apropiate, mâinile pe spătar.

Secvența de mișcare: extensia ușoară a trunchiului cu ducerea accentuată a capului înapoi și revenire, șoldurile înainte (x8).

Recunoașterea exercițiilor fizice poate fi realizată în două etape: recunoașterea posturilor (static) și recunoașterea mișcărilor.

3.2.1 Recunoașterea posturilor corpului uman

Pentru recunoașterea posturilor s-a propus o abordare ierarhică (Mocanu & Mocanu, 2015), folosind o metodă de învățare supervizată, ce folosește o clasificare ierarhică a posturilor împărțită în (i) posturi majore - în picioare, așezat, culcat și stând pe vine respectiv (ii) posturi minore – rafinarea posturilor în funcție de poziția brațelor: sus, jos, lateral, frontal. Posturile vor fi descrise prin analiza scheletului preluat cu ajutorul unui senzor Kinect (Xbox 360). Pornind de la punctele de articulație furnizate de schelet, sunt calculate caracteristicile ce descriu fiecare tip de postură: majoră și minoră. Caracteristicile calculate sunt reprezentate prin unghiuri calculate între părțile componente ale scheletului – nu se folosesc unghiuri față de planul xoz sau față de axele ox, oy, oz – astfel caracteristicile extrase nu depind de poziția și orientarea Kinectului.

Pentru postura majoră, caracteristicile folosite sunt: (i) unghiul dintre partea superioară și inferioară a piciorului; (ii) unghiul dintre partea superioară a piciorului și planul trunchiului; (iii) unghiul dintre partea inferioară a piciorului și planul trunchiului; (iv) unghiul dintre partea superioară a piciorului și linia șold-umăr, respectiv unghiul dintre glezna stângă, coloana vertebrală și glezna dreaptă. Postura minoră este descrisă prin: (i) unghiul dintre brațul superior și cel inferior; (ii) unghiul dintre bațul inferior și planul trunchiului; (iii) unghiul dintre bațul superior și linia umerilor; (iv) unghiul dintre brațul superior și linia umăr-șold. Pornind de la aceste unghiuri, postura majoră, respectiv cea minoră sunt descrise pe baza higramelor normalizate.

Clasificarea este realizată în doi pași, corespunzător celor două categorii de posturi, folosind o metodă de votare în doi pași – se realizează votarea pornind de la poziția fiecărui picior, urmând ca apoi informațiile obținute să fie combinate. Fie $no_features$ numărul total de caracteristici corespunzător posturii majore, respectiv minore și $no_postures$ numărul de clase posibile de posturi ce pot fi recunoscute. Pe baza higramelor calculate în procesul de învățare, fiecare caracteristică furnizează o valoare de votare corespunzătoare fiecărei posturi. Fie f - caracteristică, v - valoarea caracteristicii f , p - postura ce va avea asociată valoarea de votare $vote_p^f$ și $histo_p^f$ - histograma corespunzătoare caracteristicii f obținută din datele de antrenare corespunzătoare posturii p . Valoarea de votare asociată caracteristicii f este: $vote_p^f = histo_p^f[no_bin_f]$, în care no_bin_f reprezintă numărul de bin-uri din histogramă:

$$no_bin_f = \frac{180 + v}{bin_width} + 1$$

în care bin_width este dimensiunea intervalului.

Fiecare postură are asociate $no_features$ valori de votare. Valoarea finală de votare este obținută prin:

$$vote_p^{final} = \sum_{i=1}^{no_features} vote_p^{f_i} * w_{f_i}$$

unde w_{fi} reprezintă ponderea caracteristicii f_i .

Fie $vote_{left}$, $vote_{right}$ și $vote_{both}$ valorile de votare pentru piciorul stâng, drept, respectiv valoarea combinată. Pentru a elimina din valorile ce dau rezultate foarte diferite, construim noi vectori $vote_{left_podium}$, $vote_{right_podium}$ care conțin valoarea 0 pentru posturile care nu sunt clasificate în primele 3:

$$vote_{left_podium} = \begin{cases} vote_{left}(i), & \text{if } vote_{left}(i) \text{ in top 3 biggest values in the array} \\ 0, & \text{otherwise} \end{cases}$$

De asemenea sunt eliminate toate posturile care sunt considerate a fi imposibile pentru ambele picioare – se creează o mască ce conține valoarea 0 – posturi imposibile, respectiv 1 – posturi posibile:

$$mask(i) = \begin{cases} 1, & \text{if } vote_{both}(i) > 0 \\ 0, & \text{otherwise} \end{cases}$$

Valoarea finală de votare va fi:

$$vote_{final}(i) = vote_{left_podium}(i) * mask(i) + vote_{right_podium}(i) * mask(i) + vote_{both}(i)$$

Valorile ponderilor au fost alese pe baza experimentelor. Astfel ponderea cu valoarea 1 a fost setată pentru partea superioară a piciorului, pondere a cu valoarea 2 pentru unghiul dintre patrea superioară a piciorului și planul trunchiului, pondere a cu valoarea 3 pentru unghiul dintre glezna stângă, coloana vertebrală și glezna dreaptă. Pentru acest caz matricea de confuzie este redată în Figura 23, acuratețea medie obținută fiind de 82,6%.

Predicted/Actual	Crouching	Sitting on a chair	Sitting on the floor	Standing	Standing left leg frontal	Standing left leg side	Standing right leg frontal	Standing right leg side
Crouching	100	0	0	0	0	0	0	0
Sitting on a chair	2.44	96.48	0	0	0	0	0.81	0.27
Sitting on the floor	14.14	3.03	82.83	0	0	0	0	0
Standing	0.21	2.59	0	82.60	0.76	2.27	0.54	11.03
Standing left leg frontal	0	0	0	0	90.24	9.76	0	0
Standing left leg side	0	0	0	0	0	100	0	0
Standing right leg frontal	0	0	0	0	0	0	100	0
Standing right leg side	0	0	0	0	0	0	0	100

Figura 23. Matricea de confuzie pentru recunoașterea posturilor

3.2.2 Recunoașterea și evaluarea exercițiilor fizice: Algoritmul de recunoaștere a mișcărilor efectuate cu întreg corpul

Pentru recunoașterea și evaluarea mișcărilor efectuate de un utilizator în timpul antrenamentului fizic, am folosit o abordare specifică învățării supravegheate a formelor în cadrul căreia o mulțime de exemple de antrenare servește drept model pentru cum ar trebui să arate mișcările în timpul antrenamentului. Fie T mulțimea de antrenare alcătuită dintr-un număr de $|T|$ exemple de mișcări care au fost realizate în prealabil de către un expert și apoi evaluate și adnotate de către persoana responsabilă de programul de pregătire fizică al unui utilizator al aplicației Physical Activity Trainer. Fiecare exemplu din mulțimea de antrenare reprezintă o secvență de mișcare a întregului corp codificată sub forma unei mulțimi de posturi capturate de către senzorul Microsoft Kinect la momente consecutive de timp, astfel:

$$T = \{T_1, T_2, \dots, T_{|T|}\}$$

$$T_i = \{P_1^i, P_2^i, \dots, P_{|T_i|}^i\}$$

$$P_j^i = \{p_1, p_2, \dots, p_{20} | p_k = (x_k, y_k, z_k) \in R^3, k = 1..20\}$$

unde P_j^i reprezintă postura corpului uman capturată de către senzorul Kinect la momentul j pentru exemplul de antrenare i , postură alcătuită dintr-un număr de 20 de puncte 3-D.

Procesul de clasificare presupune compararea unei mișcări candidat executată de utilizator în timpul antrenamentului fizic (al cărei tip se dorește a fi determinat, cum ar fi secvențele de mișcare din Tabelul 1) cu exemplele din mulțimea de antrenare. Comparația este implementată prin intermediul folosirii unei distanțe d care calculează gradul de disimilaritate dintre geometria și cinematica mișcării candidat și dimensiunile corespunzătoare ale fiecărui exemplu de antrenare. Întrucât mișcărilor de antrenare, respectiv mișcarea candidat, vor fi alcătuite dintr-un număr inegal de posturi (ceea ce împiedică realizarea de comparații 1-la-1 între posturile ce constituie fiecare mișcare), metrica folosită trebuie să țină cont de variabilitatea producerii mișcărilor gestuale în domeniul timp, variabilitate des raportată în literatură pentru execuțiile gestuale de orice natură (Rekik *et al.*, 2013). Drept urmare, soluția aleasă pentru implementare a fost cea corespunzătoare tehnicii Dynamic Time Warping – DTW (Myers, 1981; Keogh și Ratanamahatana, 2005; Salvador și Chan, 2007). Tehnica DTW realizează o aliniere a mulțimilor posturilor celor două mișcări supuse comparației, aliniere ce se dorește a fi optimă din perspectiva costului total de transformare geometrică a unei mulțimi de posturi în cealaltă. Costul DTW este calculat folosind principiile programării dinamice care constau în rezolvarea din punct de vedere optim a unor subprobleme de dimensiuni mici (implicit, mai ușoare) și integrarea soluțiilor acestora în vederea obținerii soluției optime a problemei inițiale. În continuare, fie A și B cele două mișcări supuse comparației. Concret, tehnica DTW este implementată calculând o matrice a costurilor de aliniere dintre posturile aparținând celor două mulțimi supuse comparației, matrice definită astfel:

$$cost_{i,j} = \begin{cases} \|A_0 - B_0\| & i = 0 \text{ și } j = 0 \\ cost_{i-1,j} + \|A_i - B_0\| \text{ sau } cost_{i,j-1} + \|A_0 - B_j\| & j = 0 \text{ sau } i = 0 \\ \min(cost_{i-1,j-1}, cost_{i-1,j}, cost_{i,j-1}) + \|A_i - B_j\| & i > 0 \text{ și } j > 0 \end{cases}$$

Rezultatul DTW al comparării celor două mulțimi de posturi A și B se regăsește în colțul din dreapta-jos al matricii, respectiv $cost_{|A|-1,|B|-1}$. Pentru claritate, o implementare în limbajul de programare C# este furnizată în Figura 24. Pentru a obține tipul mișcării candidat, vor fi executate comparații repetate între candidat și fiecare exemplu din mulțimea de antrenare pe baza următoarei reguli de clasificare corespunzătoare vecinului celui mai apropiat (Webb și Copsey, 2011): mișcarea candidat C este de tipul exemplului T_j dacă distanța DTW dintre C și T_j este cea mai mică considerând toate rezultatele comparațiilor candidatului C cu exemple din mulțimea T . Această tehnică de clasificare a fost confirmată din punct de vedere al eficacității și acurateței de recunoaștere în literatura domeniului (Ahmed *et al.*, 2015; Su *et al.*, 2014; Vatavu, 2012b).

```

/// <summary>
/// Calculeaza distanta DTW dintre doua gesturi de miscare
/// a intregului corp.
/// </summary>
public static double Sqr_DTW_AllJoints(BodyGesture gesture1, BodyGesture gesture2)
{
    int n = gesture1.BodyPostures.Count;
    int m = gesture2.BodyPostures.Count;

    double[,] cost = new double[n, m];
    cost[0, 0] = BodyPosture.SqrEuclideanDistance(gesture1.BodyPostures[0], gesture2.BodyPostures[0]);
    for (int j = 1; j < m; j++)
        cost[0, j] = cost[0, j - 1] + BodyPosture.SqrEuclideanDistance(gesture1.BodyPostures[0], gesture2.BodyPostures[j]);
    for (int i = 1; i < n; i++)
        cost[i, 0] = cost[i - 1, 0] + BodyPosture.SqrEuclideanDistance(gesture1.BodyPostures[i], gesture2.BodyPostures[0]);
    for (int i = 1; i < n; i++)
        for (int j = 1; j < m; j++)
        {
            double min = Math.Min(cost[i - 1, j - 1], Math.Min(cost[i - 1, j], cost[i, j - 1]));
            cost[i, j] = min + BodyPosture.SqrEuclideanDistance(gesture1.BodyPostures[i], gesture2.BodyPostures[j]);
        }

    return cost[n - 1, m - 1];
}

```

Figura 24. Algoritmul DTW, implementat în limbajul C#.NET pentru compararea a două mișcări capturate de către senzorul Microsoft Kinect și reprezentate sub forma de serii de posturi. DTW folosește principiile programării dinamice pentru a alinia optim cele două mișcări.

3.3 Recunoașterea și evaluarea exercițiilor fizice: O nouă metodologie pentru analiza consensului privind execuția mișcărilor gestuale ale întregului corp

În vederea realizării unei analize riguroase a mișcărilor preferate de către participanți în timpul efectuării antrenamentelor fizice, am adresat problematica analizei similarității mișcărilor gestuale ale întregului corp dintr-o perspectivă nouă, complementară față de cea a recunoașterii mișcărilor, și anume analiza consensului (*en.*: gesture agreement).

În afara acestui mod de evaluare sunt considerate și următoarele două aspecte, ce urmează a fi integrate în modalitatea finală de evaluare (realizată în etapa 3/2016):

- oferirea suportului afectiv necesar în asemenea activități și anume gestionarea automată a emoțiilor cu scopul îmbunătățirii interacțiunii subiecților cu sistemul în ansamblul său, (Schipor & Schipor, 2015).
- detecția direcției de privire pornind de la analiza imaginilor video în vederea detectării nivelului de atenție al utilizatorului asupra exercițiilor fizice ce trebuie executate (Carapencea & Mocanu, 2015). Astfel se folosește modelul "active shape", în vederea urmării feței, se calculează linia ochiului (ce unește colțurile ochiului) și se detectează pupila în vederea detecției direcției de privire.

Elaborarea unei noi metodologii privind analiza consensului a fost determinată de interesul crescut manifestat în ultima vreme în literatura domeniului pentru înțelegerea consensului dintre participanți cu privire la mișcărilor gestuale preferate pentru executarea de sarcini în cadrul aplicațiilor care beneficiază de o interfață gestuală. Metodologia analizei consensului a fost introdusă de către (Wobbrock *et al.*, 2005) pentru maximizarea intuitivității introducerii de simboluri în interfețele om-calculator și a fost aplicată apoi de (Wobbrock *et al.*, 2009) și (Morris *et al.*, 2010) în cadrul primului studiu privind consensul utilizatorilor asupra gesturilor touch efectuate pe suprafețe sensibile la atingere, e.g., mese interactive. De atunci, metodologia a fost aplicată cu succes pentru analiza preferințelor utilizatorilor în ce privește mișcărilor gestuale, aceștia manifestându-și propriile opțiuni privind mișcări potrivite cu sarcinile de efectuat, ușor de executat și de reamintit ulterior. Relevante pentru tematica proiectului Mobile@Old sunt studiile legate de mișcărilor gestuale efectuate cu întreg corpul, care au arătat preferințele de mișcare ale utilizatorilor puși în situația interacțiunii cu un sistem expunând o interfață gestuală care capturează mișcarea întregului corp, e.g., interfețele dezvoltate folosind senzorul Microsoft Kinect. De exemplu, (Vatavu, 2012a) reprezintă primul studiu din literatura domeniului privind consensul participanților legat de mișcarea

întregului corp capturată folosind senzorul Kinect, pentru care a fost raportată o rată medie de consens de 0.415. Un studiu cuprinzător efectuat ulterior (Vatavu, 2013) a confirmat rezultatele pentru participanți de diverse categorii de vârstă și studii (cu caracter tehnic sau nu). Analiza mișcărilor gestuale a fost abordată în studii specifice pentru persoane în vârstă, de exemplu în (Bobeth *et al.*, 2012).

Pentru o înțelegere mai bună a similarității dintre mișcărilor gestuale ale participanților, am introdus o metodologie nouă privind analiza consensului gestual (Vatavu *et al.*, 2015). Metodologia constă într-o nouă formulă de evaluare a consensului inter-utilizator, precum și într-un nou test statistic util pentru aprecierea semnificației diferențelor dintre valorile consensului gestual obținut pentru diverse categorii de mișcări gestuale. Descriem metodologia pe scurt în continuare.

Fie n utilizatori de la care au fost preluate mișcări gestuale în relație cu o anumită sarcină de efectuat r , de exemplu mișcări realizate cu întregul corp capturate de către senzorul Microsoft Kinect. Fie P mulțimea tuturor propunerilor de mișcări, iar P_i submulțimi de mișcări identice. Rata de consens (*en.*: agreement rate) pentru cei n utilizatori cu privire la sarcina r este obținută prin evaluarea următoarei expresii:

$$R(r) = \frac{\sum_{P_i \in P} \frac{1}{2} |P_i| (|P_i| - 1)}{\frac{1}{2} |P| (|P| - 1)}$$

unde $|P|$ reprezintă cardinalul mulțimii P . De exemplu, dacă un număr de $n = 20$ de utilizatori au executat un număr de $|P| = 20$ mișcări gestuale, dintre care 15 sunt de același tip ($|P_1| = 15$) iar restul de 5 de un tip diferit ($|P_2| = 5$), atunci rata de consens dintre acești utilizatori va fi reprezentată de valoarea $(15 \times 14/2 + 5 \times 4/2) / (20 \times 19/2) = 0.605$. Cu alte cuvinte, formula consensului ne informează în acest caz că 60.5% dintre perechile de utilizatori au fost în consens privind mișcărilor efectuate. A se observa natura aparte a informației furnizată de către rata de consens, complementară celei oferite de rata de recunoaștere a gesturilor și care, împreună, au capacitatea de a furniza o înțelegere mai bună a mișcărilor efectuate de către utilizatori. Ecuația (3) poate fi rescrisă din perspectiva raportului fiecărei categorii de mișcări relativ la numărul total de mișcări efectuate ($|P_i|/|P|$), după cum urmează:

$$AR(r) = \frac{|P|}{|P| - 1} \sum_{P_i \in P} \left(\frac{|P_i|}{|P|} \right)^2 - \frac{|1|}{|P| - 1}$$

Ecuația (4) este în strânsă legătură cu formula consensului propusă inițial de către (Wobbrock *et al.*, 2005), cu diferența constând în aplicarea a doi factori corectori ($\frac{|P|}{|P|-1}$ și $\frac{|1|}{|P|-1}$) care sunt legați de numărul de grade de libertate disponibile pentru calculul consensului (Vatavu *et al.*, 2015).

Similar ratei de consens, pot fi definite rata de dezacord dintre participanți (*en.*: disagreement rate, $DR(r)$), respectiv rata de consens generalizată pentru mai multe sarcini r_1, r_2, \dots, r_k (*en.*: coagreement rate, $CR(r_1, r_2, \dots, r_k)$), după cum urmează:

$$DR(r) = \frac{\sum_{P_i \in P} \frac{1}{2} |P_i| (|P| - |P_i|)}{\frac{1}{2} |P| (|P| - 1)}$$

$$CR(r_1, r_2, \dots, r_k) = \frac{1}{\frac{1}{2} |P| (|P| - 1)} \sum_{i=1}^{\frac{1}{2} |P| (|P| - 1)} \prod_{j=1}^k \delta_{i,j}$$

unde $\delta_{i,j}$ reprezintă notația lui Kronecker (James, 1992) [240] aplicată pentru mișcărilor efectuate de perechea de utilizatori i pentru sarcina j , și anume $\delta_{i,j}$ ia valoarea 1 dacă utilizatorii din perechea i sunt în consens, respectiv 0 în caz contrar. Rata de dezacord pentru exemplul anterior (15/20 de mișcări gestuale similare și alte 5/20 diferite) este $(15 \times 5/2 + 5 \times 15/2) / (20 \times 19/2) = 0.395$ reprezentând complementul față de 1.000 al ratei de consens obținută anterior, 0.605.

Distribuția de probabilitate pentru rata de consens este ilustrată în Figura 25 în funcție de numărul de utilizatori care au executat mișcări gestuale, $|P| = 10, 20, 30, 40, 50$. Se observă o valoare cumulată a probabilității de 90% pentru rate de consens sub 0.374, respectiv 99% probabilitate pentru ca rata de consens obținută experimental să fie sub 0.636 (valori valabile pentru $|P| = 20$ utilizatori). În medie, valoarea așteptată pentru rata de consens este 0.136.

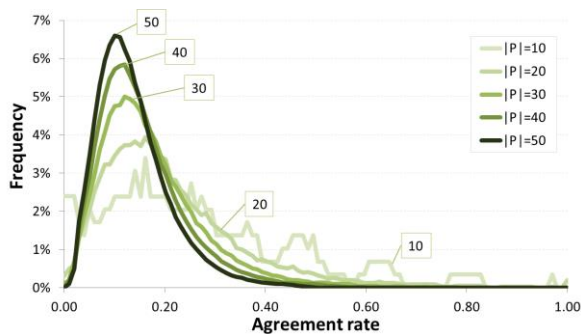


Figura 25. Distribuția de probabilitate pentru rata de consens (en.: agreement rate) în funcție de numărul de utilizatori care au executat mișcări gestuale, $|P| = 10, 20, 30, 40, 50$.

Pe lângă raportarea consensului gestual între participanți, aprecierea diferenței de consens în ce privește semnificația statistică reprezintă un punct forte al noii metodologii de analiză a gesturilor propuse în cadrul acestei etape (Vatavu *et al.*, 2015). Testul statistic pe care l-am propus a fost inspirat de testul Q a lui Cochran (Cochran, 1950) aplicat astăzi pentru analiza datelor provenite din design-uri experimentale pentru care variabila dependentă este una binară care codifică succesul sau eșecul unei observații sub aplicarea unui anumit tratament. Analogia pe care am abordat-o a fost informată de faptul că rezultatul consensului unei perechi de utilizatori poate fi evaluat ca fiind DA sau NU, ceea ce înseamnă că variabila dependentă este una binară. În continuare, prezentăm formula derivată din testul Q al lui Cochran pentru analiza diferențelor dintre ratele de consens calculate pentru diverse sarcini de efectuat, formulă exprimată strict în funcție de ratele de consens pentru sarcinile considerate în cadrul analizei:

$$V_{rd} = (k - 1) \frac{1}{2} |P| (|P| - 1) \frac{\sum_{j=1}^k AR(r_j)^2 - \frac{1}{k} (\sum_{j=1}^k AR(r_j))^2}{\sum_{j=1}^k AR(r_j) - \frac{1}{k} \sum_{t=1}^k \sum_{s=1}^k CR(r_t, r_s)}$$

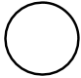

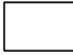
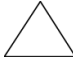


Metodologia consensului mișcărilor gestuale propusă și implementată în cadrul acestei etape va fi evaluată experimental în etapa următoare a proiectului Mobile@Old, "Experimente în laborator pe modelele experimentale ale componentelor: VSM, PAT. Achiziția de date în condiții de laborator. Analiza și interpretarea datelor", pentru care estimăm obținerea de date noi privind consensul mișcărilor gestuale ale întregului corp pentru persoane în vârstă, rezultate ce vor fi publicate în conferințele sau revistele relevante din literatura domeniului.

4. Interfața utilizator

Utilizatorul va avea acces la informațiile referitoare la istoricul medical al unei persoane, precum și cele referitoare la nivelul de exerciții fizice realizate prin intermediul unei interfețe gestuale. În acest scop a fost propusă o metodă de recunoaștere a unui set de gesturi (touch-based gestures) ce vor fi folosite în dezvoltarea interfeței utilizator, accesibilă de pe un smart-phone (interfață ce va fi implementată în etapa 3/2016).

Metoda de recunoaștere a gesturilor touch-based este descrisă în lucrarea (Nicolaescu & Mocanu, 2015). Pornind de la setul de gesturi analizate în lucrare (Nicolaescu, 2015), vor fi păstrate și folosite în interfața utilizator numai acelea pentru care acuratețea va fi ridicată. Conturul corespunzător fiecărui gest este descris pe baza descriptorilor Fourier, care reprezintă o metodă de caracterizare a formelor. Aceștia se bazează pe transformata Fourier, care folosește coordonatele complexe ale punctelor pentru a obține coeficienții Fourier, ce descriu forma în domeniul frecvenței. Astfel frecvențele joase reprezintă caracteristici generale, iar cele înalte conțin informații despre detalii. Datorită acestui fapt se poate renunța la coeficienții corespunzători frecvențelor foarte înalte, dimensiunea descriptorului reducându-se semnificativ. Un avantaj foarte mare este dat de posibilitatea de normalizare, prin care se obține invarianță la translație, scalare, rotație și punctul de start al conturului. Descriptorii Fourier reprezintă o metodă foarte populară, fiind des folosită pentru a caracteriza și a recunoaște forme. Etapa de antrenare s-a realizat folosind următoarele metode de învățare automată: (i) Rețea neurală de tip backpropagation; (ii) Arbore de decizie; (iii) Naive Bayes; (iv) Set de clasificatori de tip Analiză Discriminantă Liniară. S-au folosit gesturile din Tabelul 6 pentru a testa mai multe metode de recunoaștere. S-au ales astfel încât acestea să aibe elemente comune, dar și diferite, pentru a se testa cât contează asemănarea. Gesturile sunt executate în sensul acelor de ceasornic și în cel trigonometric, astfel obținându-se invarianță la sensul de parcurgere a conturului.

Tabel 6 - Setul de gesturi

Cerc	V	Dreptunghi	Triunghi	Alfa	8
					

Evaluarea aplicației s-a făcut folosind setul de gesturi, descris în Tabelul 7 și s-au folosit pentru fiecare gest, următoarele ordine de mărime: (i) 200 de exemple pentru antrenare; (ii) 100 de exemple pentru testare; (iii) 30 de exemple pentru validare. După cum se poate observa cele mai bune rezultate au fost obținute folosind Rețeaua neurală.	Tabel 7 - Precizie recunoaștere				
	Gest/Methodă	Rețea neurală	Arbore de decizie	Naive Bayes	Set de clasificatori
Cerc	94%	74%	68%	68%	
V	99%	85%	88%	93%	
Dreptunghi	98%	91%	88%	65%	
Triunghi	89%	94%	85%	34%	
Alfa	94%	70%	90%	74%	
8	98%	80%	74%	81%	
Medie	95.3%	82.3%	82.2%	69.2%	
În tabelul 8 sunt comparați clasificatorii după mai multe criterii. Timpul de procesare al unui gest este de aproximativ 18.92 ms, acesta reprezentând diferența dintre timpul de rulare al clasificatorului și timpul total de recunoaștere.	Tabel 8 - Comparație clasificatori				
	Criteriu/Methodă	Rețea neurală	Arbore de decizie	Naive Bayes	Set de clasificatori
	Precizie	95.3%	82.3%	82.2%	69.2%
	Timp clasificator	15.82 ms	3.54 ms	4.96 ms	145.17 ms
	Timp total recunoaștere	34.74 ms	22.46 ms	23.88 ms	164.09 ms
	Timp antrenare	7.11 s	1.59 s	1.37 s	1.93 s
	Dimensiune pe disc	36 KB	5 KB	7 KB	890 KB

Se poate observa că rezultatele obținute pentru gesturile complete sunt comparabile cu cele ale lucrărilor din domeniu prezentate în capitolul cu metode existente. Astfel o precizie ridicată și un timp de clasificare scăzut sunt favorabile pentru recunoașterea online.

5. Obiective îndeplinite

Obiectivele corespunzătoare Etapei 2/2015, au fost îndeplinite cu succes, în proporție de 100%. În continuare enumerăm principalele realizări ale proiectului în cadrul etapei curente:

- Crearea de experimente necesare dezvoltării celor două componente VSM și PAT.
- Întâlniri de lucru între membri echipei de proiect în vederea rafinării arhitecturii platformei, creării bazei de date medicale, proiectării, implementării și realizării celor două componente VSM și PAT.
- Achiziția senzorilor Kinect pentru Xbox One în vederea îmbunătățirii modulului de recunoaștere a activităților fizice, crearea jocului cu avatar și mediu simulat utilizând Kinectul împreună cu biblioteca Unity 3D.
- Achiziția de unelte software pentru captarea mișcărilor efectuate în fața Kinectului; echipament de dezvoltare și integrare hardware, dispozitive auxiliare privind interacțiunea om-mașină.

Diseminarea rezultatelor - Participarea la conferințe și publicare de articole în jurnale indexate în baze de date

- **2 articole publicate în jurnale indexate în BDI: Index Copernicus**
 - [Carapencea & Mocanu, 2015] Constantin Carapencea, Irina Mocanu, Real-Time Gaze Tracking with a Single Camera, Journal of Information Systems & Operations Management, Vol. 9, Nr. 1, pp 37-49, 2015, jurnal indexat în BDI: Index Copernicus
 - [Mocanu & Mocanu, 2015] Catalina Mocanu, Irina Mocanu - Human Body Posture Recognition using a Kinect sensor - Journal of Information Systems & Operations Management, in curs de publicare, jurnal indexat în BDI: Index Copernicus
- **5 articole prezentate la conferințe cu proceedings ce urmează a fi indexate ISI Proceedings**
 - [Lohan et al., 2015] Lohan, Simona, Cramariuc, Oana, Malicki, Lukasz, Brencic, Neja Samar, Cramariuc, Bogdan - Analytic Hierarchy Process for assessing e-health technologies for elderly indoor mobility analysis, 5th EAI International Conference on Wireless Mobile Communication and Healthcare- "Transforming healthcare through innovations in mobile and wireless technologies", Londra, Septembrie 2015, in curs de indexare ISI, in curs de publicare
 - [Mocanu et al., 2015] Irina Mocanu, Lucia Rusu, Dan Andrei Sitar Taut, Business Process Analysis for MOBILE@OLD, 9th International Conference on Intelligent Systems and Agents (ISA 2015) "Full Paper" Las Palmas de Gran Canaria, Spain, 22-24 July 2015, in curs de indexare ISI, în curs de publicare
 - [Nicolaescu & Mocanu, 2015] Alexandru Nicolaescu, Irina Mocanu, Touch-Based Gesture Recognition for Human-Based Interfaces, Proceedings of AgTAmI 2015, the International Workshop on Agent Technology for Ambient Intelligence, the 20th International Conference on Control Systems and Computer Science, Ioan Dumitrache, Adina Magda Florea, Florin Pop, Alexandru Dumitrascu (Eds.), May 27-29, Bucharest, Romania, pp 743 - 748, 2015, in curs de indexare ISI
 - [Petroniu et al., 2015] Andrei Mihai Petroniu, Mihai Trascau, Irina Mocanu, Object Recognition with Kinect Sensor, 20th International Conference on Control Systems and Computer Science (CSCS), 2015, Ioan Dumitrache, Adina Magda Florea, Florin Pop, Alexandru Dumitrascu (Eds.), May 27-29, Bucharest, Romania, pp 385 - 392, 2015, in curs de indexare ISI

- [Schipor și Schipor, 2015] Schipor Maria-Doina, and Schipor Ovidiu Andrei. 2015. Building E-PET - Could Emotions Personal Trainer Become a Reality? The 11th ELSE Conference (Aprilie 2015), in curs de indexare ISI, în curs de publicare
 - **3 articole prezentate la conferințe cu proceedings indexate în BDI: ACM, Springer, IEEE**
- [Vatavu et al., 2015] Radu-Daniel Vatavu, Jacob O. Wobbrock. 2015. Formalizing Agreement Analysis for Elicitation Studies: New Measures, Significance Test, and Toolkit. In Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems (CHI '15). ACM, New York, NY, USA, 1325-1334. DOI: <http://dx.doi.org/10.1145/2702123.2702223> , indexata în BDI: ACM DL, DBPL, conferinta de rang A în clasamentul ARC (Australian Research Council); Rata de acceptare a articolelor a fost de 23% (495 articole acceptate din 2150 trimise).
- [Rusu et al., 2015] Lucia Rusu, Sergiu Jecan, Dan Sitar, Mobile@Old an ADL Solution, 18th International Conference on Business Information Systems, 3rd Workshop on Formal Semantics for the Future Enterprise (FSFE 2015), Poznań, Poland, 24-26 June 2015, indexata BDI: Springer, în curs de publicare
- [Taut et al., 2015] Dan Andrei SITAR TĂUT, Christian SĂCĂREA, Adela Viviana SITAR TĂUT - Knowledge Visualization for Supporting Communication in Cardiovascular Risk Assessment Hypotheses, The 23rd Conference on Software, Telecommunications and Computer Networks (SoftCOM 2015), Bol (Island of Brac), September 16-18, IEEE Catalog Number CFP1587A-USB, ISBN 978-953-290-055-2, www.fesb.hr/SoftCOM, Conferință Categoria B din Domeniul Informatică, indexata în BDI: IEEE, în curs de publicare

Bibliografie

- [Ahmed et al., 2015] Faisal Ahmed, Padma Polash Paul, and Marina L. Gavrilova. 2015. DTW-based kernel and rank-level fusion for 3D gait recognition using Kinect. *Vis. Comput.* 31, 6-8 (June 2015), 915-924.
- [Bobeth et al., 2012] Jan Bobeth, Susanne Schmehl, Ernst Kruijff, Stephanie Deutsch, and Manfred Tscheligi. 2012. Evaluating performance and acceptance of older adults using freehand gestures for TV menu control. In Proceedings of the 10th European conference on Interactive tv and video (EuroITV '12). ACM, New York, NY, USA, 35-44.
- [Cochran, 1950] Cochran, W.G. 1950. The comparison of percentages in matched samples. *Biometrika* 37, 3/4 (1950), 256-266.
- [Ebert et al., 2015] Dylan Ebert, Vangelis Metsis, and Fillia Makedon. 2015. Development and evaluation of a unity-based, kinect-controlled avatar for physical rehabilitation. In Proceedings of the 8th ACM International Conference on PErvasive Technologies Related to Assistive Environments (PETRA '15). ACM, New York, NY, USA, , Article 88 , 2 pages.
- [Gillies et al., 2015] Marco Gillies, Harry Brenton, Matthew Yee-King, Andreu Grimalt-Reynés, and Mark d'Inverno. 2015. Sketches vs skeletons: video annotation can capture what motion capture cannot. In Proceedings of the 2nd International Workshop on Movement and Computing (MOCO '15). ACM, New York, NY, USA, 104-111.
- [James, 1992] James, R.C. *The Mathematics Dictionary*, 5thEd. Chapman & Hall, New York, 1992
- [Keogh și Ratanamahatana, 2005] Keogh, E., Ratanamahatana, C.A. 2005. Exact indexing of dynamic time warping. *Knowledge and Information Systems* 7 (3): 358-386.
- [Kinect, 2015a] Kinect-Windows app development, <http://kinectforwindows.org/> Accesat 11/2015
- [Kinect, 2015b] Tracking Users with Kinect Skeletal Tracking, <https://msdn.microsoft.com/en-us/library/jj131025.aspx> Accesat 11/2015
- [Kinect, 2015c] Kinect Privacy and Online Safety FAQ. <http://www.xbox.com/en-US/legal/privacyandonlinesafety> Accesat 11/2015
- [Kinect, 2015d] Kinect for Windows SDK 1.8. <https://msdn.microsoft.com/en-us/library/hh855347.aspx> Accesat 11/2015
- [Morris et al., 2010] Meredith Ringel Morris, Jacob O. Wobbrock, and Andrew D. Wilson. 2010. Understanding users' preferences for surface gestures. In *Proceedings of Graphics Interface 2010* (GI '10). Canadian Information Processing Society, Toronto, Ont., Canada, Canada, 261-268.
- [Myers, 1981] Myers, C.S., Rabiner, L.R. 1981. A comparative study of several dynamic time-warping algorithms for connected word recognition. *The Bell System Technical Journal*, 60(7):1389-1409, September 1981.
- [Norris et al., 2014] Norris, A. E., Weger, H., Bullinger, C., Bowers, A. 2014. Quantifying engagement: Measuring player involvement in human-avatar interactions. *Computers in Human Behavior* 34 (2014) 1-11.
- [Rekik et al., 2013] Yosra Rekik, Laurent Grisoni, Nicolas Roussel. 2013. Towards Many Gestures to One Command: A User Study for Tabletops. Proceedings of the 14th IFIP TC 13 International Conference INTERACT (2) 2013: 246-263.
- [Salvador și Chan, 2007] Stan Salvador and Philip Chan. 2007. Toward accurate dynamic time warping in linear time and space. *Intell. Data Anal.* 11, 5 (October 2007), 561-580
- [Su et al., 2014] Chuan-Jun Su, Chang-Yu Chiang, and Jing-Yan Huang. 2014. Kinect-enabled home-based rehabilitation system using Dynamic Time Warping and fuzzy logic. *Appl. Soft Comput.* 22 (September 2014), 652-666. [Shotton, 2011] J. Shotton et al. Real-Time Human Pose Recognition in Parts from a Single Depth Image, *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, IEEE CS Press, 2011, 1297-1304.
- [Vatavu, 2012a] Radu-Daniel Vatavu. 2012. User-defined gestures for free-hand TV control. In Proceedings of the 10th European conference on Interactive tv and video (EuroITV '12). ACM, New York, NY, USA, 45-48.
- [Vatavu, 2012b] Radu-Daniel Vatavu. 2012. Nomadic Gestures: A Technique for Reusing Gesture Commands for Frequent Ambient Interactions. *Journal of Ambient Intelligence and Smart Environments*, 4(2). IOS Press, 79-93.
- [Vatavu, 2013] Radu-Daniel Vatavu. 2013. A Comparative Study of User-Defined Handheld vs. Freehand Gestures for Home Entertainment Environments. *Journal of Ambient Intelligence and Smart Environments*, 5(2). IOS Press, 187-211.
- [Webb și Copsey, 2011] Andrew R. Webb, Keith D. Copsey. 2011. *Statistical Pattern Recognition*, 3rd Edition, October 2011. Wiley <http://eu.wiley.com/WileyCDA/WileyTitle/productCd-0470682272.html>
- [White & Miers, 2008] White, S.A.; Miers, D., 2008. *BPMN Modeling and Reference Guide: Understanding and Using BPMN*, Future Strategies Inc., *Lighthouse Point*, Florida, USA.
- [Wobbrock et al., 2005] Jacob O. Wobbrock, Htet Htet Aung, Brandon Rothrock, and Brad A. Myers. 2005. Maximizing the guessability of symbolic input. In CHI '05 Extended Abstracts on Human Factors in Computing Systems (CHI EA '05). ACM, New York, NY, USA, 1869-1872.
- [Wobbrock et al., 2009] Jacob O. Wobbrock, Meredith Ringel Morris, and Andrew D. Wilson. 2009. User-defined gestures for surface computing. In Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '09). ACM, New York, NY, USA, 1083-1092.
- [Zhang et al., 2013] Yupeng Zhang, Teng Han, Zhimin Ren, Nobuyuki Umetani, Xin Tong, Yang Liu, Takaaki Shiratori, and Xiang Cao. 2013. BodyAvatar: creating freeform 3D avatars using first-person body gestures. In Proceedings of the 26th annual ACM symposium on User interface software and technology (UIST '13). ACM, New York, NY, USA, 387-396.
- [Zephyr] Bioharness Zephyr www.BioHarness, accesat noiembrie 2015