

Metode inteligente, proactive pentru diagnosticul precoce si personalizarea tratamentului bolilor neurologice

ALAMEDA

Număr Proiect: 66 din 01/11/2021

PN-III-P3-3.6-H2020-2020-0186

Etape 2: Proiectarea și optimizarea componentelor sistemului ALAMEDA. Analiza seturilor de date existente și extinderea acestora cu date proprii

1.01.2022-30.12.2022

Cuprins

1 Obiective etapa 2.....	2
2 Rezumatul etapei.....	2
3 Descrierea științifică și tehnică (activitatea 2.1)	3
3.1 Integrarea componentelor în ALAMEDA.....	5
3.1.1 Containere	5
3.2 Branțuri inteligente	8
3.2.1 Arhitectura și fluxul de date.....	8
3.2.2 Perioada colectării datelor	8
3.2.3 Specificații tehnice (inclusiv adnotări).....	9
3.2.4 Descrierea datelor	10
3.2.5 Scenariu utilizat în ALAMEDA	11
3.2.6 Integrarea in platforma ALAMEDA	12
3.3 Brățara inteligentă	13
3.3.1 Arhitectura și fluxul de colectare date.....	13
3.3.2 Perioada colectării datelor	14
3.3.3 Specificații tehnice (inclusiv adnotări).....	14
3.3.4 Descrierea datelor	15
3.3.5 Scenariu utilizat în ALAMEDA	16
3.3.6 Integrarea în platforma ALAMEDA	17
3.4 Chatbot.....	17
3.4.1 Implementarea gestiunii dialogului	17
3.4.2 Adnotarea datelor	19
3.4.3 Scenariu utilizat în ALAMEDA	19
4 Diseminare	19
5 Bibliografie.....	19

1 Obiective etapa 2

Obiectivele prevăzute pentru etapa 2 a proiectului ALAMEDA au fost atinse prin implementarea următoarei activități în cursul anului 2022:

Activitatea 2.1: Proiectarea și optimizarea componentelor sistemului ALAMEDA. Analiza seturilor de date existente și extinderea acestora cu date proprii

Rezultat etapă: Raport de implementare pentru componentele dezvoltate, performanțele obținute, descrierea seturilor de date create

2 Rezumatul etapei

Scopul proiectului ALAMEDA este de a cerceta și prototipa următoarea generație de sisteme de asistență medicală personalizate, bazate pe inteligență artificială, având ca scop răspunsul la nevoile persoanelor cu boli și tulburări neurologice, concentrându-se în mod special pe nevoile tratamentelor de reabilitare ale pacienților și pe trei afecțiuni: Parkinson, scleroză multiplă și atac vascular cerebral.

În cadrul acestei etape au fost dezvoltate componentele frameworkului de inteligență artificială, care să fie ușor de utilizat de toate părțile interesate să utilizeze serviciile ALAMEDA, setul de instrumente fiind disponibil sub forma unei platforme web, precum și partea de colectare date necesară acestor componente (activitatea 2.1). Proiectarea componentelor bazate pe inteligență artificială este un proces pe mai multe niveluri format din: colectarea datelor, preprocesarea, adnotarea, evaluarea comparativă, antrenarea modelelor de învățare automată folosind datele adnotate colectate fiind elemente foarte importante pentru proiectarea acestui framework.

Pe baza unei evaluări generale inițiale, software-ul care va fi utilizat în studiile pilot trebuie să fie ușor de implementat la nivel de consorțiu și, de asemenea, la nivel local de către fiecare partener. Trebuie să permită instituțiilor participante să analizeze datele la nivel local fără a le încărca pe un server sau pe o infrastructură cloud. Trebuie să cuprindă un design modular ușor de extins, permițând partenerilor să adauge propriile module și să antreneze modulele existente pe seturile proprii de date.

Pentru a crea „pachete” de site stătătoare ale componentelor frameworkului de inteligență artificială care nu vor necesita instalarea de software și/sau biblioteci suplimentare s-a utilizat platforma Docker.

Componentele bazate pe inteligență artificială dezvoltate în cadrul acestei etape constau în: 1) crearea modelului de mers și 2) dezvoltarea chatbot-ului (agentul conversațional pentru completarea chestionarelor). Lipsa seturilor de date publice pentru crearea modelului de mers, a dus la necesitatea dezvoltării metodelor de achiziție a datelor în cadrul proiectului folosind branțuri inteligente și brățara inteligentă (senzori utilizați de către UPB).

Pentru branțurile inteligente sunt utilizați senzorii Novel Loadsol ce permit măsurarea mobilă a forței normale de reacție a solului pe suprafața tălpii. În cadrul colectării automate a datelor, acest dispozitiv captează date care vor putea furniza informații despre: 1) metrice referitoare la mers: de ex. numărul de pași, lungimea pasului, viteza de mers, cadența, 2) șabloane de mișcare și mers: de ex. detectarea hipokineziei (în cadrul pilotul Parkinson), detectarea executării exercițiului de recuperare fizică centrată pe picior (în cadrul studiului pilot pentru accident vascular cerebral).

Brățara GENEActiv, conține un accelerometru cu 3 axe, un senzor de temperatură și un senzor de detecție a intensității luminii. Ele sunt utilizate pe scară largă în studii clinice și observaționale care implică urmărirea mișcării și a activității.

Aplicația Chatbot este construită pe baza unui agent de conversație care este responsabil de gestionarea conversațiilor cu utilizatorii. Chatbot-ul este implementat prin intermediul unui modul de dialog, care suportă mai multe limbi. Acesta este compus din 5 componente: preprocesarea audio, recunoașterea automată a vorbirii, procesarea limbajului natural, gestiunea dialogului și sinteza text-voce. Chatbot-ul este utilizat pentru completarea și gestionarea întrebărilor din chestionar.

În cadrul acestei etape, proiectul a fost diseminat prin publicarea unui articol de conferință cu proceedings indexat ISI.

Toate obiectivele au fost realizate integral, gradul de atingere al rezultatelor fiind de 100%.

3 Descrierea științifică și tehnică (activitatea 2.1)

Scopul proiectului ALAMEDA este de a cerceta și prototipa următoarea generație de sisteme de asistență medicală personalizate, bazate pe inteligență artificială, având ca scop răspunsul la nevoile persoanelor cu boli și tulburări neurologice, concentrându-se în mod special pe nevoile tratamentelor de reabilitare ale pacienților și pe trei afecțiuni: Parkinson, scleroză multiplă și atac vascular cerebral. Inovațiile ALAMEDA sunt ancorate în integrarea datelor colectate asupra stilului de viață, precum și a fluxurilor noi de date de monitorizare a pacienților în timpul activităților zilnice, inclusiv comportamentul de somn, implementarea analizei avansate a datelor și a serviciilor de recomandare asupra stilului de viață, bazate pe inteligență artificială. Această abordare oferă personalului medical posibilitatea de a modifica intervențiile pe baza înregistrărilor de date personalizate, care pot include atât opțiuni terapeutice farmacologice, cât și non-farmacologice, cum ar fi regimurile de efort.

În cadrul acestei etape au fost dezvoltate componentele frameworkului de inteligență artificială, care sunt ușor de utilizat de toate părțile interesate să utilizeze serviciile oferite de proiectul ALAMEDA, setul de componente oferit fiind disponibil sub forma unei platforme web.

Setul de componente ale frameworkului de inteligență artificială ALAMEDA va fi utilizat inițial de aplicațiile pilot ale proiectului, care au scopul de a facilita medicilor să tragă concluzii din datele disponibile bazate pe metode de inteligență artificială pentru monitorizarea și prezicerea progresului bolilor creierului.

Proiectarea componentelor bazate pe inteligență artificială este un proces pe mai multe niveluri care începe cu colectarea datelor și se termină cu integrarea diferitelor modele de învățare automată și de învățare profundă. Colectarea datelor, preprocesarea, adnotarea, evaluarea comparativă, antrenarea modelelor de învățare automată și de învățare profundă folosind datele adnotate colectate sunt elemente foarte importante pentru proiectarea modulelor acestui framework (Figura 1).

Lipsa seturilor de date publice pentru crearea modelului de mers, a dus la necesitatea dezvoltării metodelor de achiziție a datelor în cadrul proiectului.

Nivelul 1 - Colectarea datelor: datele colectate în mod corespunzător îmbunătățesc eficacitatea și acuratețea modelelor de învățare automată. Astfel, colectarea datelor are un rol principal în dezvoltarea unor astfel de aplicații. Datele colectate trebuie să includă toate tipurile și secvențele necesare pentru predicție și diagnosticare. Prin urmare, trebuie adoptate următoarele principii în vederea atingerii obiectivului proiectului: număr adecvat de eșantioane

per clasă/variabilă predictivă, colectarea de date a experimentelor cu mai multe serii cronologice cu un grad de frecvență diferit, adnotarea și compararea corectă a datelor colectate.

Nivelul 2 - Adnotarea datelor și preprocesarea: Acuratețea modelelor de învățare automată depinde de adnotarea datelor: cu cât este mai precisă adnotarea datelor, cu atât sunt mai precise predicțiile modelului. În plus, prin adnotarea adecvată, preprocesarea datelor adnotate mărește performanța algoritmilor. Astfel, este foarte important să ne asigurăm că adnotarea a fost efectuată ținând cont de obiectivele de predicție și diagnosticare stabilite de partenerii medicali.



Figura 1. Componentele frameworkului de inteligență artificială ALAMEDA.

Nivelul 3 - Analiza datelor folosind învățarea automată și învățarea profundă: în această etapă, diferite modele de învățare automată și de învățare profundă sunt antrenate pe baza datelor adnotate în etapa anterioară. Modelele pot fi antrenate folosind date diferite: de la senzori, imagini/videouri, voce pentru a diagnostica și a prezice condițiile pacientului conform predicției definite de personalul medical. Diverse concepte de învățare automată și de învățare profundă, cum ar fi rețelele neuronale convoluționale (CNN), învățarea prin transfer bazată pe CNN, rețelele generative adversariale (GAN-uri), învățarea prin recompensă pot fi încorporate pentru a atinge obiectivele legate de diagnosticarea timpurie și tratament.

Nivelul 4 - Integrarea modelelor antrenate cu frameworkul de inteligență artificială: Toate componentele trebuie să fie integrate în frameworkul de inteligență artificială pentru a

funcționa colectiv și eficient. Rolul acestui nivel este de a asigura compatibilitatea și coeziunea între diferitele componente.

3.1 Integrarea componentelor în ALAMEDA

În ceea ce privește integrarea și documentarea componentelor frameworkului de inteligență artificială, se adopta următoarele abordări (descrise în cele ce urmează).

3.1.1 Containere

Pentru a crea „pachete” de site stătătoare ale componentelor frameworkului de inteligență artificială care nu vor necesita instalarea de software și/sau biblioteci suplimentare s-a utilizat platforma Docker. Un container Docker este un mediu de rulare virtualizat utilizat în dezvoltarea de aplicații pentru a crea, rula și implementa aplicații care sunt izolate de hardware-ul de bază. Imaginile Docker sunt punctul de plecare, acționând ca un set de instrucțiuni asemănător unui șablon pentru a construi un container Docker. O imagine are tot ce este necesar pentru a rula o astfel de aplicație, inclusiv cod, dependențe, fișiere de configurare, variabile de mediu, biblioteci și runtime.

Imaginile Docker sunt - cel mai frecvent - create prin metoda Dockerfile. Un Dockerfile cu text simplu încorporează specificațiile pentru crearea unei imagini folosind un set amănunțit de instrucțiuni la care se poate face referire pe site-ul Dockerⁱ. De asemenea, utilizatorul poate configura un fișier *.dockerignore* pentru a exclude orice fișiere care nu sunt necesare pentru construcția finală. Apoi, comanda Docker *build* este folosită pentru a crea o imagine Docker și sunt setate un nume și o etichetă pentru imagine.

Odată ce o imagine a fost definită, aceasta poate fi salvată într-un registru Docker, care este un sistem de stocare și distribuție pentru imaginile Docker. Un registru Docker este organizat în depozite Docker, unde un depozit deține toate versiunile unei anumite imagini. Registrul permite utilizatorilor Docker să extragă imagini local, precum și să salveze imagini noi în registru (cu ajutorul permisiunilor de acces adecvate). În acest scop în ALAMEDA, va fi implementat un registru privat pentru a găzdui și a partaja toate imaginile relevante, încorporând mecanisme de autentificare adecvate, cum ar fi credențiale pre-partajate.

Pe lângă acestea, vor fi exploatate capacitățile Docker Compose - un instrument pentru definirea și rularea aplicațiilor Docker cu mai multe containere. Folosind Compose, utilizatorul creează un fișier Yet Another Markup Language (YAML) pentru a configura serviciile aplicației folosind imagini (potențial dintr-un registru). Apoi, cu o singură comandă, sunt pornite toate serviciile din configurare.

Pe scurt, procesul de containerizare a aplicațiilor ALAMEDA este rezumat în următorii trei pași:

1. definirea imaginilor aplicației cu fișierele Dockerfile corespunzătoare, astfel încât acestea să poată fi reproduse oriunde.
2. înregistrarea imaginilor în registrul privat Docker stabilit.
3. definiția Docker Compose fișiere YAML care assemblează serviciile (imaginile) unei aplicații de sistem, astfel încât acestea să poată fi rulate împreună într-un mediu izolat.

Pentru documentația componentelor din frameworkul de inteligență artificială se va utiliza specificația OpenAPIⁱⁱ v3.1.0. OpenAPI este în prezent standardul de facto al industriei pentru descrierea, producerea, consumarea și vizualizarea serviciilor web RESTful.

O specificație OpenAPI are forma unui fișier YAML sau JavaScript Object Notation (JSON) și permite descrierea unui API, incluzând:

- endpoints disponibile și operații pentru fiecare endpoint.

- parametri de funcționare, intrare și ieșire pentru fiecare operație.
- metode de autentificare.
- informații de contact, licență, termeni de utilizare și alte informații.

Pe lângă adoptarea specificației OpenAPI, se vor utiliza și următoarele instrumente open-source construite în jurul specificației OpenAPI:

- **Swagger Editor:** un editor în browser pentru scrierea specificațiilor OpenAPI, care va fi folosit pentru a transforma informațiile primite prin șabloanele de mai sus în specificații compatibile cu OpenAPI.
- **Swagger User Interface:** redă specificațiile OpenAPI ca documentație interactivă, permițând utilizatorilor să testeze apelurile API direct în browser.
- **Swagger Codegen:** pentru generarea de stub-uri de server și biblioteci client din specificațiile OpenAPI.

Pe baza unei evaluări generale inițiale, software-ul care va fi utilizat în studiile pilot trebuie să fie ușor de implementat la nivel de consorțiu și, de asemenea, la nivel local de către fiecare partener. Trebuie să permită instituțiilor participante să analizeze datele la nivel local fără a le încărca pe un server sau pe o infrastructură cloud, asigurând astfel conformitatea cu GDPR și cu reglementările UE privind confidențialitatea datelor. Trebuie să includă analize vizuale integrate și rapoarte automate care să permită o mai bună înțelegere și diseminare a rezultatelor cercetării. Trebuie să cuprindă un design modular ușor de extins, permițând partenerilor să adauge propriile module și să antreneze modulele existente pe seturile proprii de date. De asemenea, modulele și seturile de date anonimizate trebuie să poată fi partajate cu întregul consorțiu.

Pentru a stabili metodele ce trebuie dezvoltate, s-a pornit de la analiza variabilelor de predicție identificate de partenerii medicali în ALAMEDA:

1. Tabelul cu predictorii și variabile deduse: conține lista completă de variabile, atât generate de pacient (predictori), cât și rezultate din testele clinice (deduse). Descrierea fiecărei variabile permite stabilirea dacă este o valoare numerică liberă sau una discretă. Partenerii medicali au definit nevoile de predicție pentru fiecare dintre variabilele necesare fiecărui test pilot. Scopul este de a folosi istoricul variabilelor predictoare (în ultimele 3, 6, 12 luni) pentru a încerca să se prezică rezultatul unui test clinic viitor. În cadrul variabilelor predictoare există un subset de variabile, care vor fi rezultatul unei clasificări din datele preluate de la senzori:
 - a. Modelul de mers: clasificare folosind intrările de la brățara inteligentă, brățuri inteligente, ceas inteligent și centura inteligentă. UPB a dezvoltat achiziția datelor provenite de la brățara inteligentă și brățurile inteligente.
 - b. Analiza expresiei faciale: clasificare a imaginii utilizând intrarea de la camera smartphone-ului.
 - c. Analiza sentimentelor din mesaje text: clasificare a sentimentelor aplicată conținutului conversației pe care un utilizator o are cu Chatbot-ul ALAMEDA.
 - d. UPB va dezvolta în cadrul proiectului ALAMEDA, modelul de mers precum și dezvoltarea Chatbot-ului.
2. Lista țintelor de predicție a progresului/regresului intra-pacient: definește seturi de condiții cumulative, care indică o înrăutățire sau o îmbunătățire a situației unui pacient. Aceste criterii vor fi folosite pentru a eticheta un subset al datelor pacientului pe o anumită perioadă de timp, reprezentând un progres sau un regres în situația lor. Acest lucru este definit în prezent pentru studiul pilot accident vascular cerebral, deoarece este mai ușor de definit astfel de criterii pentru această afecțiune.

Având în vedere cele de mai sus, este propus următorul set de instrumente pentru studiile pilot:

1. Vizualizare: mijloace de a vizualiza mai multe date din seria temporală cu un grad diferit de frecvență pentru intrările individuale ale seriei temporale. Vizualizarea este esențială pentru căutare. Un instrument bun de vizualizare poate oferi perspectivă și inspirație, evidențiind eventualele anomalii sau modele.
2. Adnotare: sunt necesare instrumente relevante pentru a adnota subseturi de intrare din una sau mai multe serii temporale ce reprezintă o situație de progres sau regres. Astfel de instrumente pot funcționa:
 - a. într-o manieră vizuală - se selectează manual intervalul temporal, seria temporală variabilă și etichetați intervalul ca progres sau regres
 - b. într-o manieră bazată pe reguli - se creează reguli cu operatori temporali al căror rezultat este etichetarea unui interval de serie temporală ca o situație de progres sau regresie
3. Analiză focalizată
 - a. instrumente de analiză a mersului: module bazate pe rețele neuronale care pot fi antrenate pe serii de timp numerice multivariate (adică intrările sensorului de la brățara inteligentă, brățuri, ceas și centură)
 - b. utilizarea arhitecturii Perceiver IOⁱⁱⁱ pentru intrări multimodală ar putea fi de ajutor
 - c. instrumente de recunoaștere a emoțiilor faciale: bazat pe rețele neuronale care pot fi antrenate pe imagini cu fețele pacienților achiziționate de la smartphone-uri
 - d. instrumente de analiză a sentimentelor din conversații: module bazate pe rețele neuronale pentru a clasifica sentimentele în text din interacțiunile cu un agent conversațional (chatbotul). Astfel de instrumente sunt potențial utile pentru toate cazurile medicale care necesită analiză de text pentru a descoperi sentimentele (de exemplu, probleme psihologice, de sănătate mintală), unde sunt definite două moduri de funcționalitate:
 - e. clasificarea sentimentelor din enunțuri individuale
 - f. clasificarea sentimentele într-o conversație (2 sau mai multe enunțuri ale utilizatorului; utilizand contextul unui istoric de conversație)
4. Instrumente de clasificare a seriilor temporale cu variabile predictive: acesta este cel mai important set de instrumente de inteligență artificială pentru partenerii medicali ALAMEDA, precum și pentru mulți medici din domenii similare, deoarece are legătură directă cu interesul de a analiza posibilitatea de predicție a datelor achiziționate de la senzorii utilizați de pacienți dar și chestionarele raportate de pacient în performanța viitoare a pacientului într-un test medical. Cel mai provocator aspect al acestor instrumente este acela de a putea integra în analiză atât variabilele cu valori discrete, cât și cele continue. Un alt aspect important este extragerea caracteristicilor relevante și selectarea celor mai potrivite pentru a antrena un set de modele. Setul de instrumente ar trebui să includă:
 - a. o metodă clasică de analiză - de ex. care implică modele cunoscute (de exemplu, Autoregressive Integrated Moving Average-ARIMA) și biblioteci disponibile pentru clasificarea seriilor temporale (de exemplu, sktime^{iv}, pyts^v)
 - b. modele bazate pe rețele neuronale - implicând mai multe abordări: rețele convoluționale 1D (convnets), modele bazate pe atenție, memorie convoluțională de lungă durată (conv-lstm), modele RNN cu unități recurente gated (GRU)

- c. caracteristici de detectare a valorilor anormale: codificatoare automate, detectarea valorilor anormale a seriei temporale (TODS^{vi}), detecția anomaliilor nesupravegheate în seria temporală^{vii}, CNN-uri^{viii}
- d. o caracteristică importantă o constituie capacitatea de a selecta dintre intrările utilizate pentru clasificare, adică din toate datele înregistrate, de a antrena modelele folosind doar subseturi din toate intrările colectate la un moment dat și de a putea adăugați apoi noi intrări la model.

UPB va dezvolta în cadrul proiectului ALAMEDA, modelul de mers (folosind datele achiziționate de la brățara inteligentă și brățurile inteligente) precum și dezvoltarea Chatbot-ului (agentul conversațional pentru completarea chestionarelor).

3.2 Branțuri inteligente

Senzorii Novel Loadsol^{ix} permit măsurarea mobilă a forței normale de reacție a solului pe suprafața tălpii. Sistemul poate fi folosit atât pentru măsurători statice cât și dinamice, pentru a cuantifica cu acuratețe forțele generate între picior (talpa piciorului) și pantof.

În cadrul colectării automate a datelor, acest dispozitiv captează date care vor putea furniza informații despre:

- metrici referitoare la mers: de ex. numărul de pași, lungimea pasului, viteza de mers, cadența
- șabloane de mișcare și mers: de ex. detectarea hipokineziei (în cadrul studiului pilot Parkinson), detectarea executării exercițiului de recuperare fizică centrat pe picior (în cadrul studiului pilot pentru accident vascular cerebral).

3.2.1 Arhitectura și fluxul de date

Fluxul de date pentru serviciul de colectare a datelor de la brățurile inteligente este prezentat în Figura 2. Două tipuri de utilizatori vor interacționa cu acest serviciu: supervizorul studiului pilot (acest rol va fi jucat de partenerii medicali și/sau tehnici din proiect) și utilizatorul din studiul pilot (pacienții efectivi).

Înainte de utilizare, fiecare brăț trebuie configurat (pasul 1) și adaptat pacientului care-l va purta (de exemplu, greutatea pacientului trebuie configurată pentru a asigura valorile normale ale forței). De fiecare dată când se efectuează o măsurătoare, datele sunt sincronizate cu aplicația Android Loadsol-S care rulează pe smartphone-ul pacientului (pasul 2). După o perioadă în care aceste brățuri au fost purtate, datele de pe smartphone sunt preluate de supervizorul studiului pilot (pasul 3) și stocate în forma în care au fost achiziționate în cloud-ul ALAMEDA (pasul 4).

În timpul perioadei de purtare, pacientul are opțiunea de a utiliza ALAMEDA Digital Companion pentru a efectua adnotări (tip și orele de începere/terminare) a activităților specifice efectuate în perioada de monitorizare intensivă (pasul 5). Platforma ALAMEDA combină datele brute cu adnotările (pasul 6), care pot fi apoi exploatate de algoritmi care fac parte din ALAMEDA Gait Analysis Toolkit (pasul 7).

3.2.2 Perioada colectării datelor

Branțurile inteligente fac parte din setul de dispozitive purtate de pacienți în perioadele intensive (speciale) de monitorizare care sunt programate la etape specifice pentru fiecare studiu pilot, după cum urmează:

- studiul pilot Parkinson: purtare zilnică continuă timp de maximum 8 ore/zi, pe durata unei săptămâni înaintea fiecărei vizite clinice la fiecare 3 luni.

- studiul pilot accident vascular cerebral: purtare zilnică continuă timp de maximum 8 ore/zi, pe o durată de două-trei săptămâni înainte de fiecare vizita la clinica la fiecare 6 luni.
- studiu pilot scleroză multiplă: purtare zilnică continuă timp de maximum 8 ore/zi, pe durata a două-trei săptămâni înainte de fiecare vizită la clinică la fiecare 6 luni.

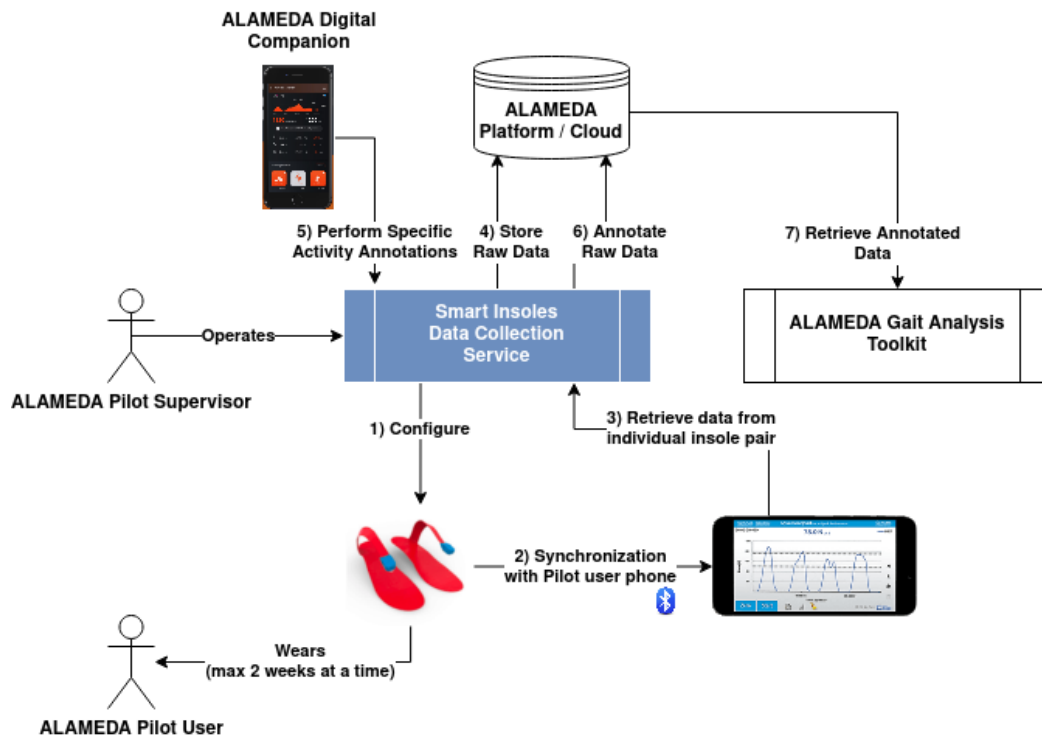


Figura 2. Colectarea datelor pentru branșurile inteligente.

3.2.3 Specificații tehnice (inclusiv adnotări)

Configurarea branșurilor inteligente Loadsol se realizează folosind aplicația Loadsol-S disponibilă în AppStore și Google Play Store. Figura 3 prezintă două capturi de ecran ale interfeței de configurare.

Există trei setări de configurare importante, care sunt evidențiate cu verde: (i) trebuie setată greutatea pacientului (deoarece aceasta va informa valorile așteptate ale forței normale), (ii) ID-ul pacientului este folosit ca numele pacientului și (iii) activare mod pacient, ce trebuie activat după configurarea inițială, astfel încât pacientul să nu mai poată modifica din neatenție setările.

Toate celelalte configurații pot fi lăsate cu valorile implicite care sunt adaptate pentru capturarea mersului normal (nu se anticipează utilizarea de către pacienții care pot alerga sau se pot antrena în sporturi de mare intensitate, care ar necesita creșterea intervalului de valori normale ale forței).

Senzorii branșului se conectează prin Bluetooth la smartphone. Trebuie activată o procedură de scanare a senzorului (după inserarea bateriilor). În timpul configurării senzorului, este important să se aleagă în mod corect branșul asociat fiecărui picior. Pentru a face acest lucru, procedura concepută este să porniți fiecare branș dintr-o pereche la un moment dat.

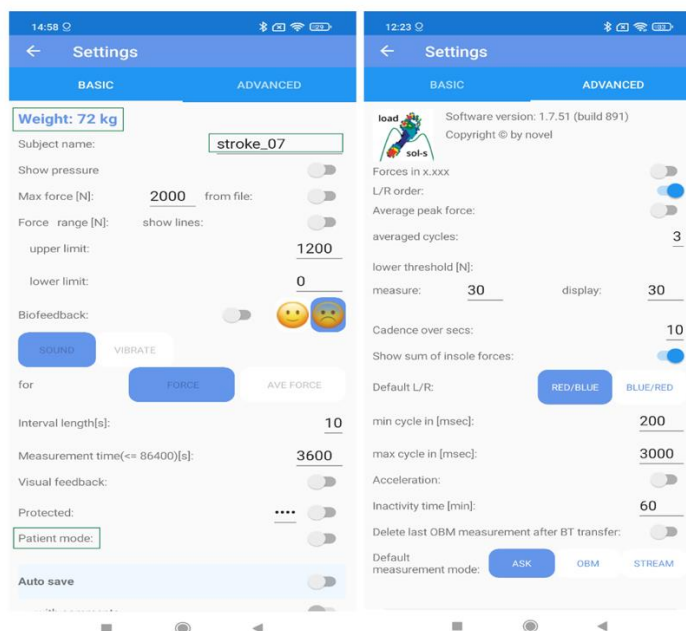


Figura 3. Interfața de configurare a aplicației Loadsol-S.

Aplicația Loadsol-S va identifica automat poziția corectă a senzorului pe picior (piciorul stâng sau drept) și va semnaliza acest lucru (-L (stânga) sau -R (dreapta)), așa cum se arată în Figura 4). Așa cum se poate observa în Figura 4 branțul piciorului drept a fost inițial activat și conectat, iar branțul stâng este în curs de conectare.




Figura 4. Exemplu configurare în aplicația Loadsol-S. (-R) și (-L) specifică piciorul pe care trebuie purtat.

3.2.4 Descrierea datelor

Branțurile inteligente captează date legate de forța de reacție a solului (forța cu care solul împinge înapoi pe piciorul unei persoane în timpul mersului) măsurată în Newton (N).

Branțurile au două zone sensibile la forță, una pentru antepicior și una pentru călcâi. Folosind acești senzori pot fi extrase următoarele date brute și agregate:

Modelul datelor – branțuri inteligente	
Forța picior stâng / drept (N)	Forța de reacție cu solul măsurată pentru întregul picior în timpul unui ciclu de pas

	Domeniu (20 N – 2000 N)
Forța călcâi stâng / drept (N)	Forța de reacție cu solul măsurată pentru călcâi în timpul unui ciclu de pas Domeniu (20 N – 2000 N)
Forța antepicior față stâng / drept (N)	Forța de reacție cu solul măsurată pentru antepicior în timpul unui ciclu de pas Domeniu (20 N – 2000 N)
Rata de încărcare (N/s)	Viteza cu care se aplică forța normală asupra corpului Domeniu 0 – 50.000
Forța integrată în timp (Ns)	Valori cumulate ale forței normale acumulate pe o perioadă de timp (de obicei, durata maximă a unui ciclu de pas) Domeniu (60 - 6000)
Cadența (număr pași / min)	Numărul total de pași compleți (piciorul stâng plus drept) executați într-un minut Domeniu 0 - 200

3.2.5 Scenariu utilizat în ALAMEDA

Odată ce senzorii au fost configurați, pot fi efectuate măsurători. Înainte de fiecare măsurătoare, pacientul trebuie să efectueze o procedură de calibrare, așa cum se arată în Figura 5. Procedura implică ridicarea piciorului stâng și drept în această succesiune, astfel încât să ofere aplicației informația forței normale cu greutatea 0, care ar putea fi diferită de o valoare reală 0 din cauza încălțămintei prea strânse.

După procedura de calibrare, butonul Start devine activ în interfața de măsurare. O dată apăsat, branțurile continuă să măsoare până când acesta se oprește sau bateria se va descărca.

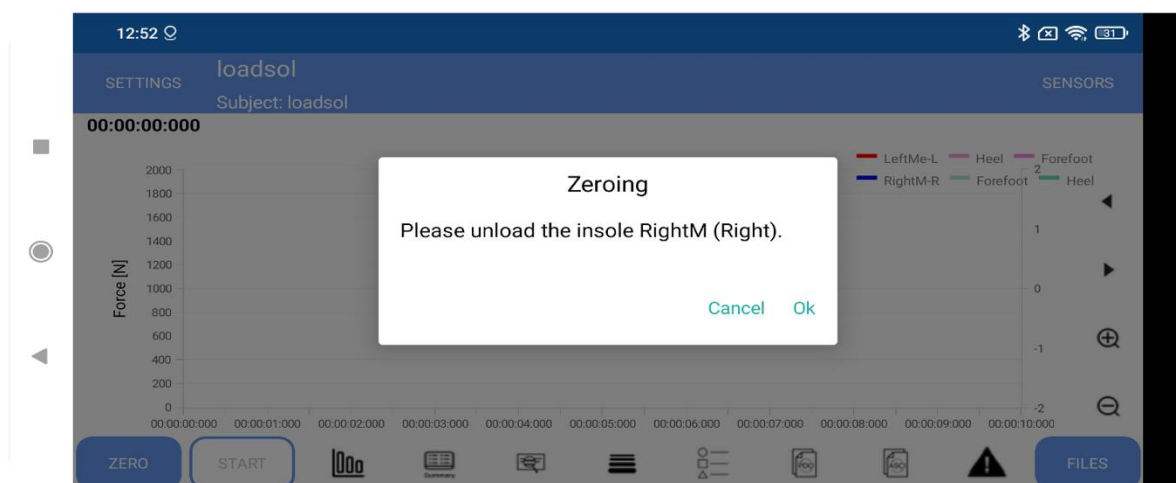


Figura 5. Interfața aplicației Loadsol-S pentru calibrare greutate 0 înainte de a începe sesiunile de înregistrare a datelor.

Branțurile sunt utilizate în timpul perioadelor de monitorizare intense în care are loc colectarea datelor.

Scenariul de utilizare de bază este cel al purtării branțurilor introduse în pantofii purtați zilnic, maxim 8 ore pe zi. În timpul perioadei de monitorizare intensă, pacienții vor primi zilnic dimineața mementouri prin care vor putea vizualiza tutoriale de utilizare a acestor branțuri.

Pe lângă scenariul de utilizare de bază, pacienții care vor fi implicați în diferite activități specifice în timpul perioadei intense de monitorizare vor fi încurajați să folosească funcționalitatea de adnotare disponibilă în ALAMEDA, pentru a marca începutul și sfârșitul unei activități. Mai exact, pacienții pot marca ora de începere, ora de încheiere și tipul unei activități speciale (de exemplu, exerciții fizice, 30 de minute de mers în aer liber, apariția unui simptom motor, administrarea de medicamente).

Următoarele activități vor beneficia de funcționalitățile de adnotare:

- studiul pilot accident vascular cerebral:
 - executarea exercițiilor de recuperare pentru picioare;
- studiul pilot Parkinson:
 - executare mers 30 min;
 - marcarea apariției simptomelor de tremur, diskenizie sau hipokinezie
- studiul pilot scleroza multiplă:
 - marcarea apariției episoadelor de rigiditate a mișcării.

Adnotările vor fi stocate ca metadata în ALAMEDA Semantic Knowledge Graph. Acestea vor fi ulterior utilizate de frameworkul de analiză a mersului pentru a antrena/valida algoritmi pentru detectarea exercițiilor fizice de recuperare și a problemelor de mobilitate.

3.2.6 Integrarea în platforma ALAMEDA

Toate măsurătorile realizate sunt automat stocate pe smartphone. Acestea pot fi vizualizate pe smartphone (vezi Figura 6), iar aplicația Loadsol-S permite stocarea într-un fișier binar care poate fi convertit ulterior în format CSV folosind aplicația software Loadpad Analysis pentru PC.

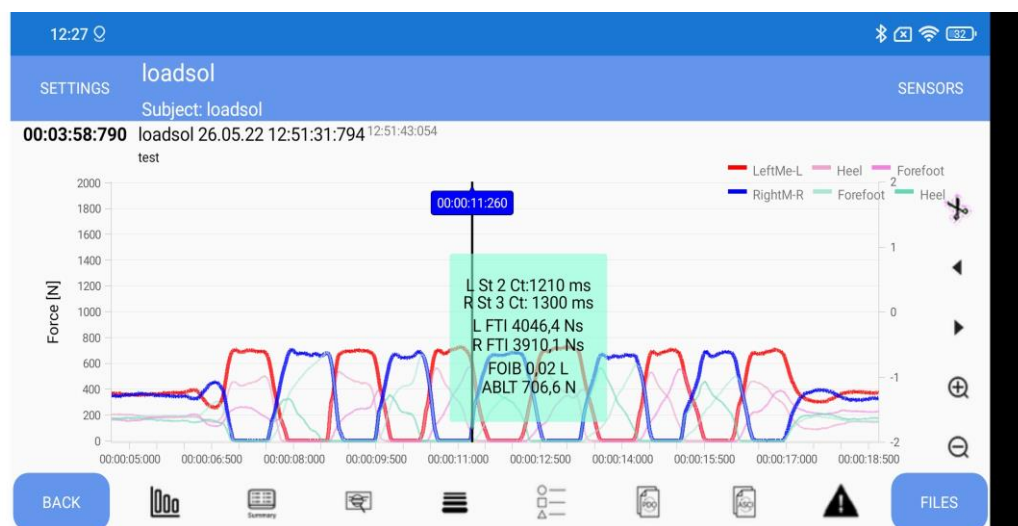


Figura 6. Vizualizarea unei înregistrări în aplicația Loadsol-S. Curbele prezintă valorile forțelor (în N) pentru întreg piciorul stâng (rosu) și drept (albastru), analog pentru călcâi și antepicior.

Fișierele CSV extrase sunt încărcate în formă brută în cloud-ul ALAMEDA folosind o conexiune SSH cu securizare bazată pe chei. Fișierele sunt organizate pe ID-ul pacientului și zile individuale de înregistrare pe perioada respectivă de monitorizare intensă. Valorile brute ale forței normale sunt necesare ca intrare în algoritmi din ALAMEDA Gait Analysis Toolkit, care coroborează informații din mai multe surse (brățară inteligentă, brânțuri și centură) pentru

a efectua detectarea exercițiilor efectuate, detectarea șabloanelor de mers și a perioadelor de mobilitate redusă, precum și extragerea de metrici pentru mers.

3.3 Brățara inteligentă

Brățara GENEActiv (prezentată în Figura 7) dezvoltată de compania britanică ActivInsights, conține un accelerometru cu 3 axe, un senzor de temperatură și un senzor de detecție a intensității luminii. Ele sunt utilizate pe scară largă în studii clinice și observaționale care implică urmărirea mișcării și a activității.



Figura 7. Brățara GENEActiv.

În cadrul ALAMEDA și, în special, în colectarea datelor pacientului, acest dispozitiv achiziționează date din care pot fi obținute următoarele informații:

- metrici despre mers: de exemplu: numărul de pași, lungimea pasului, viteza de mers, cadența;
- metrici despre activitate: duratele zilnice ale activității (sedentare, scăzute, medii și active);
- șabloane pentru mișcare și mers: detectarea tremorului, detectarea hipokenziei (pentru studiul pilot Parkinson), detecția realizării exercițiului de recuperare fizică (pentru studiul pilot accident vascular cerebral);
- metrici despre somn: timpul petrecut în pat, timpul petrecut dormind, timpul de trezire, timpul de adormire.

Potrivit modalității de colectare de date în ALAMEDA, brățara GENEActiv face parte din setul de dispozitive purtate de pacienți în perioadele intensive (speciale) de monitorizare care sunt programate la etape specifice pentru fiecare studiu pilot.

3.3.1 Arhitectura și fluxul de colectare date

Fluxul de colectare de date de la brățara inteligentă este prezentat în Figura 8 și este similar cu procesul descris pentru branșurile inteligente. Aceleași tipuri de utilizatori interacționează cu dispozitivul: supervizorul studiului pilot (rolul jucat de partenerii medicali și/sau tehnici ai proiectului) și utilizatorul studiului pilot (pacienții efectivi).

Brățările trebuie configurate pentru frecvența de măsurare (de exemplu, 50 Hz) și locația de purtare a corpului (pasul 1). La sfârșitul unei perioade de purtare, datele de pe brățară sunt preluate de supervizorul studiului pilot (pasul 2) și stocate în formă brută în cloudul ALAMEDA (pasul 3). Adnotările făcute de pacient (de exemplu, exercițiile fizice efectuate) sunt, de asemenea, stocate în cloudul ALAMEDA (pasul 5) și utilizate pentru a caracteriza datele brute (pasul 6). În afară de datele brute, zilnic sunt extrase statistici privind activitatea zilnică și somnul (pasul 4). Datele brute adnotate pot fi apoi exploatate de algoritmi care fac parte din frameworkul de analiză a mersului din ALAMEDA (pasul 7).

3.3.2 Perioada colectării datelor

Brățara inteligentă de asemenea face parte din setul de dispozitive purtate de pacienți în perioadele intensive (speciale) de monitorizare care sunt programate la etape specifice pentru fiecare studiu pilot, după cum urmează:

- studiul pilot Parkinson: purtarea zilnică continuă la încheietura mâinii și purtarea nocturnă la gleznă (pentru a detecta efectele sindromului picioarelor neliniștite) pe durata unei săptămâni înainte fiecărei vizite la clinică la interval de 3 luni;
- studiul pilot accident vascular cerebral: purtarea zilnică continuă la încheietura mâinii și purtarea nocturnă la gleznă (pentru a detecta efectele sindromului picioarelor neliniștite) pentru o durată de două săptămâni înainte de fiecare vizită la clinică la interval de 6 luni;
- studiul pilot scleroza multiplă: purtare zilnică continuă la încheietura mâinii pe durata a două-trei săptămâni înainte de fiecare vizită la clinică la interval de 6 luni.

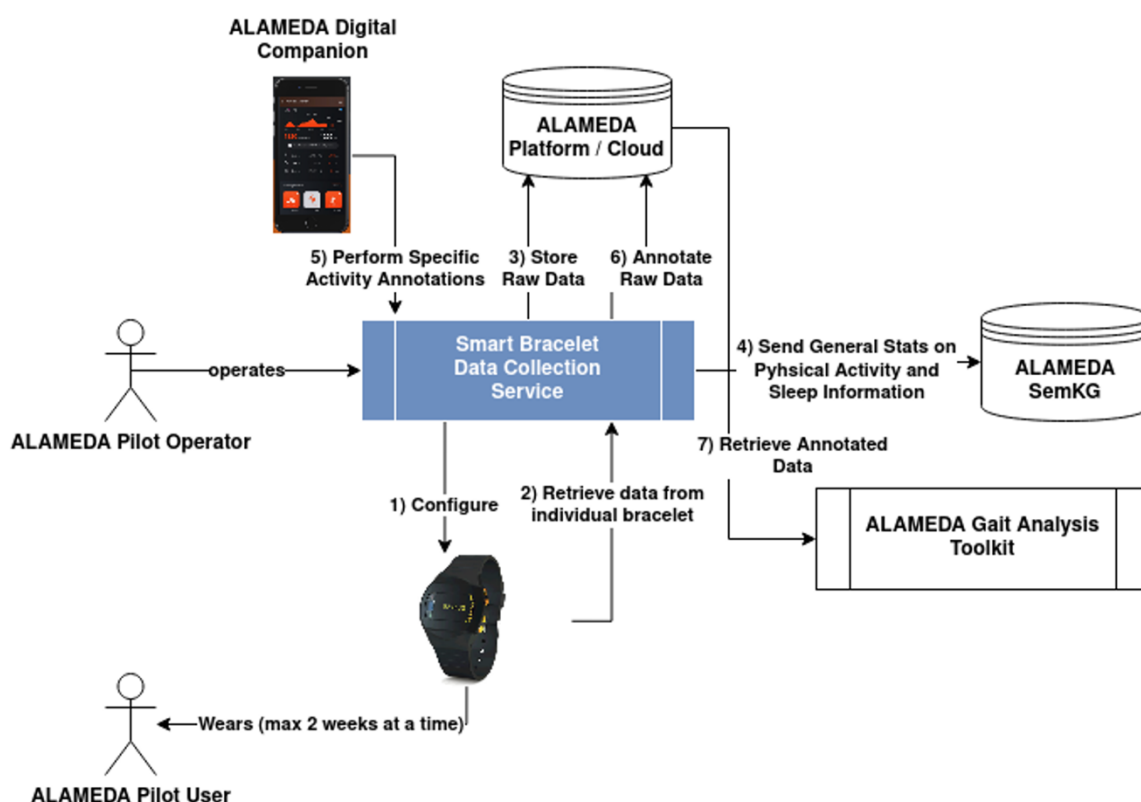


Figura 8. Fluxul colectării datelor de la brățara inteligentă.

3.3.3 Specificații tehnice (inclusiv adnotări)

Înainte de începerea unei perioade de purtare, brățara este configurată de către partenerii medicali prin specificarea următoarelor metadate importante:

- ID-ul pacientului, utilizat pentru a identifica utilizatorul de la care au fost colectate datele. ID-ul pacientului este unic pentru fiecare pacient înregistrat în studiile pilot ALAMEDA.
- poziția de purtare în timpul zilei: încheietura mâinii stângi sau drepte

- frecvența de eșantionare: 50 Hz pentru un timp de purtare de cel mult două săptămâni, 20 Hz pentru o durată de trei săptămâni (poate fi cazul pentru unii pacienți cu scleroză multiplă)

Configurarea și încărcarea se realizează folosind cablu USB. După configurare, pacientul nu este obligat să interacționeze cu dispozitivul în niciun fel (nu este necesară reîncărcarea), în afară de purtarea acestuia conform instrucțiunilor personalului medical.

3.3.4 Descrierea datelor

Figura 8 prezintă modul în care pot fi extrase din brățara GENEActiv. Datele brute referitoare următoarele semnale pot fi preluate cu frecvența specificată în faza de configurare:

- valorile accelerației pentru axele X, Y și Z măsurate în unități de accelerație gravitațională (g). Interval -8g – +8g
- temperatura (grade Celsius). Interval -25°C - +40°C
- intensitatea luminii (lux). Interval 0 – 3000
- apăsare buton (număr de apăsări).

Pe lângă stocarea datelor brute, există un serviciu care conține un set de scripturi ce adaptează și extind scripturile R și Python open-source existente care calculează rezumate pe zi ale valorilor de activitate și somn. Deoarece există mai multe biblioteci care sunt utilizate pentru a efectua extragerea de metrici, rezultatele finale sunt asociate cu informații despre metadate care indică proveniența acestora.

Ieșirea scripturilor de rezumare a valorilor de activitate și somn este generată sub forma unui JSON (Listing 1 și Listing 2).

Rezumatul activității include în prezent valorile:

- numărul pașilor
- perioada în care nu a fost purtată
- activitate sedentară / ușoară / durata perioadei moderate / intensă

```
"activity_summary": [
  {
    "provenance": "Activinsights",
    "data": [
      {
        "day_start": "2022-01-23 03:00:00.+0200",
        "day_start_ts": 1642899600.0,
        "day_end": "2022-01-24 03:00:00.+0200",
        "day_end_ts": 1642986000.0,
        "steps": 581,
        "non_wear": 0,
        "sedentary": 22522,
        "sedentary_percent": 0.26,
        "light_activity": 0,
        "light_activity_percent": 0.0,
        "moderate_activity": 905,
        "moderate_activity_percent": 0.01,
        "vigorous_activity": 0,
        "vigorous_activity_percent": 0.0
      }
    ]
  }
],
```

Listing 1 Exemplu rezultat sumar activitate obținut din datele colectate într-o zi de la brățara GENEActiv.

Rezumatul somnului include în prezent valori de:

- debutul somnului
- timpul de ridicare din pat
- timpul total petrecut în pat și timpul total de somn/eficiența somnului
- durata de timp până la prima trezire după debutul somnului

```
"sleep_summary": [  
  {  
    "provenance": "Activinsights",  
    "data": [  
      {  
        "night_start": "2022-01-23 15:00:00.+0200",  
        "night_start_ts": 1642942800.0,  
        "night_end": "2022-01-24 15:00:00.+0200",  
        "sleep_onset": "2022-01-24 01:45:02.+0200",  
        "rise": "2022-01-24 09:41:52.+0200",  
        "total_bed_time": 28285,  
        "total_sleep_time": 18383,  
        "waso": 9902,  
        "first_waso": 6758,  
        "sleep_efficiency": 65.0  
      },  
    ],  
  }  
]
```

Listing 2. Exemplu rezumat somn obținut din datele colectate într-o zi de la brățara GENEActiv.

3.3.5 Scenariu utilizat în ALAMEDA

După cum s-a menționat, brățara GENEActiv este un dispozitiv purtat de pacient în perioadele intense de monitorizare definite în partea de colectare a datelor.

Scenariul de bază de utilizare este cel al purtării simple a dispozitivului la încheietura mâinii în timpul zilei și a gleznei (acolo unde este necesar) în timpul nopții. Obiectivul în scenariul de utilizare de bază este de a capta rezumatele activității la o granularitate mai mare. În timpul perioadei de monitorizare intensă, pacienții vor primi zilnic mementouri dimineața și seara care îi vor instrui unde și cum să-și atașeze dispozitivul.

Ca și în cazul branșurilor inteligente, pacienții care se angajează în activități specifice în timpul perioadei intense de monitorizare se poate folosi funcționalitatea de adnotare din ALAMEDA Digital Companion.

Datele brățării inteligente beneficiază de adnotarea următoarelor activități speciale:

- studiul pilot accident vascular cerebral:
 - executarea exercițiilor de recuperare fizică a membrului superior
- studiul pilot Parkinson:
 - executarea mersului timp de 30 min
 - marcarea apariției simptomelor de tremur, diskenizie sau hipokenizie

- studiul pilot scleroză multiplă:
 - marcarea apariției episoadelor de rigiditate a mișcării

3.3.6 Integrarea în platforma ALAMEDA

După o perioadă de colectare, datele sunt salvate de pe dispozitiv utilizând suportul de docking USB precum și aplicația furnizată de GENEActiv care rulează pe sistemul de operare Windows. Datele sunt extrase în format binar care poate fi citit folosind un număr de biblioteci open source (de exemplu, GENEActiv în R, pygeneactivxi în Python).

Datele extrase din brățara GENEActiv urmează două căi de procesare și integrare în platforma ALAMEDA (vezi și Figura 8):

- 1 Stocarea datelor brute: fișierul binar este încărcat printr-o conexiune SSH securizată în cloud-ul ALAMEDA, unde este indexat după ID-ul pacientului și marcajele de timp de început și de sfârșit ale perioadei de purtare. Valorile brute ale accelerometrului sunt necesare ca intrare în algoritmi din frameworkul ALAMEDA Gait Analysis Toolkit, care coroborează informații din mai multe surse (brățară inteligentă, brățuri și centură).
- 2 Rezumatul valorilor de activitate și somn: datele sunt procesate de scripturi dezvoltate intern care adaptează și extind scripturile R și Python open-source existente care calculează valorile de activitate și de somn. După extragere, rezumatele sunt inserate în ALAMEDA Semantic Knowledge Graph (SemKG) folosind API-ul furnizat de setul de instrumente.

3.4 Chatbot

Aplicația Chatbot este construită pe baza unui agent de conversație care este responsabil de gestionarea conversațiilor cu utilizatorii. Chatbot-ul este implementat prin intermediul unui modul de dialog, care suportă mai multe limbi. Acesta este compus din 5 componente: preprocesarea audio, recunoașterea automată a vorbirii (ASR – Automatic Speech Recognition), procesarea limbajului natural (NLU – Natural Language Understanding), gestiunea dialogului (DM – Dialog Management) și sinteza text-voce (TTS – Text to Speech):

- Preprocesarea audio: stochează informații utile care sunt legate de modulul de dialog, cum ar fi limba dialogului curent, număr biți / eșantion, frecvența adecvată a sunetului, numărul de canale audio, codificarea audio. Prezența acestei componente optimizează rezultatul componentei ASR.
- Recunoașterea automată a vorbirii: convertește, în timp real, cuvintele rostite de utilizator (voce) într-un fișier text.
- Procesarea limbajului natural: convertește orice fișier text într-un format reprezentat prin intenție și a entității/entităților din text. Acest lucru permite înțelegerea a ceea ce a spus utilizatorul.
- Gestiunea dialogului: decide care trebuie să fie răspunsul sistemului cu privire la comanda utilizatorului. Acesta este responsabil de starea și fluxul conversației, precum și de păstrarea istoricului interacțiunilor pentru sesiunea curentă.
- Sinteza text-voce: convertește orice text într-un fișier audio care conține textul rostit folosind vorbirea umană artificială.

3.4.1 Implementarea gestiunii dialogului

Procesare audio: Extrage din profilul utilizatorului limba pe care utilizatorul o folosește pentru a interacționa cu sistemul. Extrage din setările sistemului număr biți / eșantion, frecvența

corespunzătoare a sunetului, numărul de canale audio, codificarea audio. Datele extrase sunt furnizate celorlalte componente ale chatbotului.

Recunoașterea automată a vorbirii: primește comanda vocală a utilizatorului într-un fișier audio și trimite fișierul audio către serviciul de recunoaștere automată a vorbirii^{xii} furnizat de Google cloud (pentru ambele limbi). În cloud, comanda vocală este convertită în text. Textul este trimis către gestiunea dialogului sub forma unui fișier JSON care conține pe lângă textul recunoscut și alte informații utile, cum ar fi scorul de încredere al recunoașterii.

Procesarea limbajului natural: primește fișierul text și extrage intenția și entitatea/entitățile din textul primit. Datele extrase sunt salvate într-un fișier JSON (împreună cu informații utile). Fișierul JSON este trimis către componenta de gestiune a dialogului. Pentru a permite extragerea intenției și a entității/entităților s-a utilizat Rasa-X^{xiii}. Pentru fiecare limbă au fost create intenții și pentru fiecare intenție au fost asociate diferite entități. Apoi a fost antrenat Rasa-X pentru fiecare limbă.

Gestiunea dialogului: primește fișierul JSON generat de NLP și decide care ar trebui să fie răspunsul sistemului. A fost utilizată Rasa-X ca soluție. În Rasa-X, au fost create diferite povești. Odată ce gestiunea dialogului primește fișierul JSON, compară intenția extrasă și entitatea/entitățile cu poveștile sale, având întotdeauna în vedere poziția interacțiunii curente în dialog; apoi decide răspunsul sistemului. Testul răspunsului este afișat pe ecran și este trimis către componenta sinteză text-voce.

Sinteza text-voce: primește răspunsul în format text și îl trimite către ResponsiveVoiceJS^{xiv} (pentru ambele limbi), în care fișierul text este convertit într-un fișier audio care conține textul rostit prin utilizarea vorbirii umane artificiale. ResponsiveVoiceJS trimite înapoi fișierul audio către gestiunea dialogului și fișierul audio va fi auzit prin ieșirea audio a sistemului.

Elaborarea chestionarelor s-a realizat folosind o caracteristică oferită de RASA numită „form”. Form-urile sunt o modalitate convenabilă de a solicita informații de la utilizatori într-un mod structurat. În plus, form-urile prin construcție nu permit abateri de la forma activă în prezent. Adică, în cazul în care un anumit form este activ, nu este posibil să se schimbe subiectul conversației până când toate informațiile necesare nu au fost obținute. Cu toate acestea, RASA permite definirea implicită a scenariilor în care un form poate fi dezactivat înainte de completare. În general, utilizarea mecanismului de form-uri asigură că nu pot exista distrageri în timpul răspunsului la o întrebare și nu influențează răspunsurile utilizatorilor, fără a afecta calitatea generală a colectării datelor.

Chatbot-ul este capabil să gestioneze întrebările care acceptă răspunsuri în una dintre următoarele forme:

- întrebări cu răspunsuri liber ca text
- întrebări cu un singur răspuns ales dintr-o selecție de opțiuni predefinite
- întrebări în care răspunsurile multiple sunt acceptabile dintr-o selecție de opțiuni predefinite
- întrebări condiționate: întrebări care depind de răspunsurile la întrebările anterioare

Prin intermediul agentului conversațional și al form-urilor RASA se oferă opțiunea de a întrerupe un chestionar și de a-l continua ulterior, fără a pierde progresul, adică răspunsurile la întrebările anterioare. Această opțiune de a putea opri răspunsul la chestionare, permite utilizatorilor să-și îndeplinească sarcinile în propriul ritm. Cu toate acestea, din cauza naturii medicale a întrebărilor și a frecvenței acestora în cadrul studiului, sondajele trebuie finalizate într-un interval de timp specific pentru a oferi informații utile. Astfel, partenerii medicali din ALAMEDA au convenit ca toate chestionarele să fie completate după o perioadă de 1 sau 2

zile din momentul în care au devenit disponibile prima dată și după o perioadă de 1 zi pentru întrebările relevante. După această perioadă, chestionarele devin inaccesibile utilizatorului. În cazul în care utilizatorii nu completează sau au completat parțial un anumit chestionar, atunci acel chestionar este considerat incomplet și rămâne la latitudinea personalului medical dacă îl include în evaluarea pacientului.

3.4.2 Adnotarea datelor

Pentru a interacționa cu agentul, utilizatorii trebuie să aibă un ID de utilizator unic care îi va permite agentului să urmeze o cale de conversație diferită pentru fiecare utilizator. ID-ul utilizatorului este folosit pentru a prelua conversațiile anterioare, precum și starea actuală a chestionarelor pentru acel utilizator, pentru a continua de la ultima întrebare la care a răspuns. Datele text sunt adnotate automat de către agent în timp real, folosind identificatorul unic al fiecărui utilizator împreună cu ora asociată fiecărui mesaj.

Toate elementele conversației, inclusiv mesajele utilizatorului și cele ale agentului, sunt stocate într-o bază de date SQL în timp real. Odată completate toate răspunsurile la chestionar împreună cu întrebările respective (plus informațiile stocate în baza de date) sunt grupate în format .json și sunt puse la dispoziția personalului medical prin intermediul.

3.4.3 Scenariu utilizat în ALAMEDA

Considerăm studiul pilot accident vascular cerebral în care fiecare pacient, vinerea, acesta va trebuie să completeze chestionarul asociat. În momentul în care chestionarul este disponibil, pacientul va primi o notificare pe telefon. Pacientul va avea două opțiuni, fie selectează notificarea, fie o ignoră. Dacă pacientul decide să selecteze notificarea, atunci va fi redirecționat către Chatbot și chestionarul va fi deschis. În cazul în care ignoră notificarea, utilizatorul poate accesa chestionarul solicitând chatbot-ului chestionarele disponibile în prezent într-o etapă ulterioară (maxim în următoarele 2 zile). În timpul furnizării răspunsurilor, pacientul va avea opțiunea de a opri procesul. La finalizarea completării chestionarului, răspunsurile pacientului vor fi transmise personalului medical.

4 Diseminare

În cadrul acestei etape, proiectul a fost diseminat prin publicarea unui articol de conferință cu proceedings indexat ISI:

Alexandru Sorici, Lidia Bajenaru, Irina Mocanu, Adina Magda Florea - Health Monitoring of Adults with Brain Diseases Using Shoe Pressure Sensors, *40th IBIMA Conference*, acceptat, în curs de publicare (ISI Proceedings, în curs de indexare WOS), <https://ibima.org/accepted-paper/health-monitoring-of-adults-with-brain-diseases-using-shoe-pressure-sensors/>.

5 Bibliografie

ⁱ Dockerfile reference: <https://docs.docker.com/engine/reference/builder/>

ⁱⁱ Openapis: <https://www.openapis.org/>

ⁱⁱⁱ Perceiver IO: A General Architecture for Structured Inputs & Outputs, <https://paperswithcode.com/paper/perceiver-io-a-general-architecture-for>

^{iv} Sktime - A unified framework for machine learning with time series, <https://www.sktime.org/en/stable/>

^vPyts - A Python package for time series classification, <https://pythonrepo.com/repo/johannfaouzi-pyts-python-machine-learning>

^{vi}TODS: Automated Time-series Outlier Detection System , <https://github.com/datamllab/tods>

^{vii} Munir, S. A. Siddiqui, A. Dengel and S. Ahmed, "DeepAnT: A Deep Learning Approach for Unsupervised Anomaly Detection in Time Series," in *IEEE Access*, vol. 7, pp. 1991-2005, 2019, doi: 10.1109/ACCESS.2018.2886457.

^{viii} Time Series Anomaly Detection Using Convolutional Neural Networks and Transfer Learning, <https://arxiv.org/abs/1905.13628>

^{ix} Loadsol: <https://www.novel.de/products/loadsol/>

^x GENEaread: <https://cran.r-project.org/web/packages/GENEaread/index.html>

^{xi} Pygeneactiv: <https://github.com/harvard-nrg/pygeneactiv>

^{xii} Google Cloud: <https://cloud.google.com/speech-to-text>

^{xiii} Rasa-X: <https://rasa.com/>

^{xiv} ResponsiveVoice.JS: <https://responsivevoice.org>