

IONIS – NITICSplus - soluții pentru prevenirea demenței

Etapa 1: Stabilirea cerințelor platformei (2.10.2017 – 31.12.2017)

Contract: Nr. 53/2017 / AAL2017-AAL-2016-074-IONIS-2 / IONIS

Contents

1.	Scopul proiectului	1
2.	Obiective etapa 2017	1
3.	Rezumatul etapei	2
4.	Descriere activități	2
5.	Prezentare rezultate verificabile etapă.....	14
6.	Concluzii	16
7.	Diseminare	16
8.	Pagina web a proiectului – actualizata cu datele ultimei raportari.....	16
9.	Bibliografie	16

1. Scopul proiectului

Persoanele cu demență demonstrează, încă din stadiul incipient al bolii, pierderea memoriei, episoade de confuzie și dezorientarea în spațiu și timp. Acestea din urmă se întâmplă adesea în mod imprevizibil, cu consecințe care uneori pot fi foarte grave. Odată cu evoluția bolii, pierderea și rătăcirile pot deveni evenimente simptomatice și recurente. În prezent, membrii familiilor care, fără alte soluții, decurg adesea la măsuri drastice, reducând libertatea pacientului. Dacă acest lucru nu este posibil, persoanele care au grijă de un pacient cu demență trăiesc într-o stare de stres continuu. Serviciile bazate pe localizare au potențialul de a oferi, cu un cost accesibil, un ajutor util pentru persoanele care îngrijesc persoanele cu demență. Motivată de acest context, propunem dezvoltarea proiectului IONIS prin exploatarea serviciilor bazate pe localizare, monitorizarea calității somnului, servicii de comunicare pentru a oferi o gamă largă de soluții specifice demenței prin sprijinul continuu pentru persoanele cu demență atunci când sunt acasă sau în exterior. Pentru a dezvolta și a valida soluția IONIS, se va utiliza un proiect centrat pe utilizator care implică încercări ample de testare.

În cadrul proiectului UPB va contribui la proiectarea arhitecturii sistemului, dezvoltarea de metode pentru identificarea dezorientării, precum și extragerea de informații referitoare la tulburările de somn.

2. Obiective etapa 2017

Obiectivele etapei 2017 au constat în implementarea activităților din planul de realizare în vederea stabilirii cerințelor platformei. În acest context se analizează diferite soluții AAL existente, în

special cele care tratează problemele specifice demenței – în special identificarea dezorientării și se propun diferite scenarii ce vor sta la baza proiectării și implementării componentelor ce se vor integra în sistemul IONIS. Activitățile prevăzute pentru 2017 sunt următoarele:

- Activitatea I.1: Studiul metodelor și tehnologiilor existente în domeniul inteligenței ambientale
- Activitatea I.2: Elaborarea unor scenarii de utilizare a platformei și serviciilor aferente
- Activitatea I.3: Diseminare: Întâlnire deschidere proiect

3. Rezumatul etapei

Obiectivele au fost realizate integral, gradul de atingere al rezultatelor fiind de 100%. **Activitatea I.1** a avut ca scop analiza sistemelor existente care tratează problemele demenței și identificarea avantajelor și dezavantajelor acestora în vederea stabilirii principalelor caracteristici ale sistemului IONIS. În cadrul **activității I.2** au fost dezvoltate o serie de scenarii în vederea identificării componentelor sistemului IONIS, componente ce vor fi ulterior utilizate în proiectarea sistemului în etapa 2/2018. **Activitatea I.3** a avut ca scop prezentarea proiectului IONIS în cadrul conferinței: **9th Alzheimer Conference – ASK 2017: "For dementia friendly society"**, 20-21 Octombrie Spominčica – Alzheimer Slovenia. Totodată a avut loc și întâlnirea pentru deschiderea proiectului în data de 17.10.2017, Geneva, Elveția.

4. Descriere activități

Activitatea I.1: Studiul metodelor și tehnologiilor existente în domeniul inteligenței ambientale în cadrul acestei activități au fost analizate o serie de sisteme și metode ce tratează diferite probleme ale demenței. Aspectul principal analizat se referă la starea de dezorientare care apare adesea în cazul persoanelor cu demență. În continuare vor fi analizate o serie de astfel de metode, fiind descrise și diferite seturi de date ce vor putea fi utilizate în etapa următoare pentru implementarea componentelor sistemului IONIS.

În [1] este propusă o metodă ce identifică dezorientarea utilizatorilor prin analiza pozițiilor acestora achiziționate de la GPS. Metoda este evaluată prin utilizarea unui set de date GPS real obținut de la 10 persoane alese din peste 160 de persoane ale căror traiectorii au fost stocate. Setul de date utilizat a fost lansat de Microsoft Research Asia [2] [3] [4] și o parte din acesta, care constă în traiectorii și metode de transport pentru 31 de utilizatori, este publică. Algoritmul descris în articol prezintă ca date de intrare următoarele date:

- traiectorie GPS,
- o matrice de celule reprezentând un oraș
- un set de traiectorii simbolizate.

O traiectorie GPS este o secvență de puncte reprezentate de locația geografică (latitudine și longitudine). Matricea de celule este formată din celule de dimensiune egală, obținute prin împărțirea hărții orașului în celule de aceeași dimensiune. Setul de traiectorii simbolizate conține traiectorii reprezentate printr-o succesiune de simboluri după aplicarea algoritmului de simbolizare.

Ieșirea algoritmului este o etichetă care poate lua două valori, 1 sau 0. Valoarea 1 este utilizată pentru a arăta că utilizatorul ale cărui intrări au fost folosite în algoritm corespunde unui model de dezorientare, în timp ce 0 indică faptul că modelul de mișcare al utilizatorului este normal.

Lucrarea descrie metoda iBDD (metoda de detectare a dezorientării pe bază de izolare) care detectează dacă o traiectorie trebuie clasificată ca dezorientare sau nu. Acest algoritm pornește de la o traiectorie de locații GPS, pe care o simbolizează pe baza matricei celulare și apoi o analizează în vederea detectării dezorientării.

Metoda iBDD (Algoritmul 1) primește cele trei date de intrare descrise mai sus: traiectoria GPS, matricea celulelor și setul de traiectorii simbolizate. Algoritmul ia fiecare punct al traiectoriei de intrare și aplică metoda de simbolizare pe fiecare dintre ele. Dacă celula rezultată este validă, algoritmul aplică în continuare metoda de detectare pe celulă. Rezultatul este o etichetă care arată dacă traiectoria este clasificată ca normală sau ca dezorientare.

Simbolizarea traiectoriei: intrarea este un punct în traiectorie și în matricea celulară a orașului. Algoritmul verifică dacă punctul curent se află în aceeași celulă cu cel mai recent punct verificat, iar celula este ignorată dacă punctul aparține aceleiași celule. De asemenea, dacă celula este ignorată, punctul este înregistrat și numărat. Dacă punctul este față de restul punctelor, acesta va fi eliminat. Dacă celula rezultată obținută prin maparea punctului la matricea celulară este una nouă, aceasta va fi concatenată cu lista celulelor non repetitive. Dacă celula nu este aceeași cu cea precedentă, aceasta va fi marcată ca validă. Algoritmul întoarce dacă celula este validă sau nu precum și celula din matrice.

Clasificarea traiectoriei drept o traiectorie normal sau o traiectorie de de dezorientare - pentru aceasta, sunt necesare trei definiții:

1. *Support, Support Set, and Support Degree*: Pentru două traiectorii $t_i \neq t_j \in T$, t_i suportă t_j (sau t_j este suportată de t_i) dacă și numai dacă t_j este sub-traiectorie a t_i . Mulțimea tuturor traiectoriilor simbolizate din T care suportă t_j poartă numele de mulțime suport pentru t_j :

$$T_{\text{supp}}^{t_j} = \{t_i \mid t_i \in T \wedge t_i \text{ suportă } t_j\}$$

și proporția $T_{\text{supp}}^{t_j}$ raportată la T poartă numele de gradul de suport pentru t_j , notat cu $\text{supp}(t_j, T)$, conform [5]:

$$\text{supp}(t_j, T) = |T_{\text{supp}}^{t_j}| \times 1/|T|$$

2. *θ -Support*: Fie o constantă $0 \leq \theta \leq 1$, o traiectorie t_j poartă numele de θ -support în raport cu T dacă gradul de suport $\text{supp}(t_j, T) \geq \theta$ [5].

3. *Outlying Point and Outlier Score*: Un "outlying point" este o celulă non- θ -support, în care traiectoria fie deviază față de traiectoria normală, fie își modifică direcția în mod repetat. Numărul de astfel de puncte determina "outlier score", pentru o traiectorie de dezorientare [1].

Conform descriilor din [1], Figura 1, prezintă o traiectorie formată din locații GPS, iar Figura 2 descrie o traiectorie simbolizată (cu eliminare de zgomete și celule repetitive).

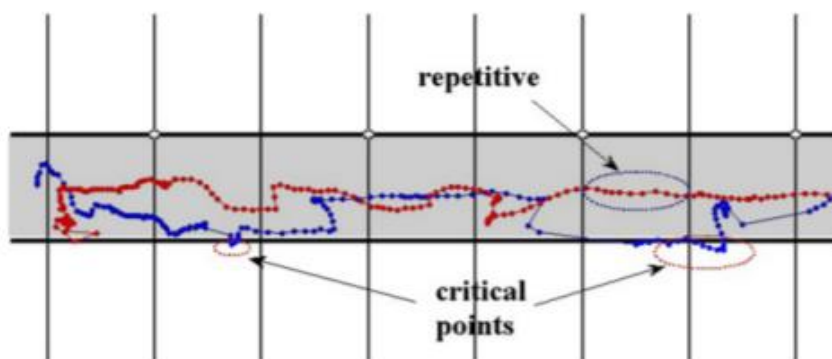


Figura 1. Traiectorie formată din locații GPS




Figura 2. Traiectorie simbolizată

Algoritmul primește ca intrări o nouă celulă și un set de traiectorii. După ce celula este atașată celulelor din traiectorie, este creat o mulțime suport pentru traiectoria curentă. Dacă gradul de suport al traiectoriei actuale este mai mic decât pragul de θ -support, atunci traiectoria este fie circulară, fie deviată. Dacă punctul este normal, mulțimea de lucru va fi actualizată cu valoarea mulțimii acceptate a traiectoriei curente. În cazul în care mai mult de trei puncte sunt deviate sau circulare, atunci eticheta de ieșire va lua valoarea 1, care reprezintă comportamentul de dezorientare.

Pentru setarea experimentală, zece seturi de date care conțin locații GPS achiziționate de la 10 persoane sunt utilizate ca seturi de date de test. Deoarece seturile de date nu sunt obținute de la persoanele în vârstă, au fost adăugate manual traiectorii pentru a simula comportamentul de dezorientare. În tabelul 1 sunt afișate statisticile pentru fiecare utilizator din setul de date de testare.

Tabel 1, conform [1].

The AUC values of iBDD with different values of cell size d when $\theta = 0.10$.

d (m)	$T - 1$	$T - 2$	$T - 3$	$T - 4$	$T - 5$	$T - 6$	$T - 7$	$T - 8$	$T - 9$	$T - 10$
80	0.8872	0.8753	0.8990	0.8999	0.8824	0.9001	0.9104	0.9200	0.9006	0.8942
120	0.9903	0.9911	0.9921	0.9933	0.9875	0.9941	0.9940	0.9954	0.9960	0.9959
150	0.9972	0.9995	0.9962	0.9968	0.9967	0.9997	0.9977	0.9974	0.9994	0.9992
180	0.9912	0.9931	0.9929	0.9927	0.9915	0.9939	0.9953	0.9955	0.9959	0.9969
220	0.9012	0.8994	0.8999	0.9100	0.8971	0.9033	0.9320	0.9297	0.9119	0.9022

Pentru a îmbunătăți eficiența metodei, în timpul căutării în mulțimea de lucru a traiectoriei, în algoritmul de detecție sunt utilizate numai ultimele trei elemente. Dacă traiectoria este θ -Support, atunci orice sub-traieorie este de asemenea θ -Support.

Traieoriile au fost etichetate în mod manual. Evaluarea s-a realizat pe baza AUC (area under the ROC curve), ce implică 4 categorii posibile de rezultate: adevărat pozitiv, fals pozitiv, fals negativ și adevărat negativ.

Evaluarea cantitativă se face pentru fiecare set de date prin calcularea valorii AUC. Rezultatele experimentale au arătat că alegerea unei dimensiuni a gridului între 120 și 180 de metri și a pragului $\theta = 0,10$, rata de detecție a fost de peste 95%, iar rata fals pozitiv este mai mică de 3%. Dacă dimensiunea celulei gridului este mai mică, rata fals pozitiv era mai mare, deoarece puncte mai apropiate vor fi mapate pe diferite celule de pe hartă. De asemenea, o valoare foarte mare pentru dimensiunea celulelor poate crea probleme în detectarea dezorientării deoarece persoana poate merge între anumite puncte în aceeași celulă, deci chiar dacă mișcarea dintre aceste puncte ar fi dezorientată, nu va fi clasificată astfel deoarece persoana rămâne în aceeași celulă. O persoană trebuie să treacă dintr-o celulă în alta pentru a putea fi detectată dezorientarea. Astfel, o celulă de 150 de metri este, de asemenea, o soluție pentru detectarea din viața reală.

Complexitatea metodei este dată de numărul de traiectorii înmulțit cu numărul de celule. Este o complexitate liniară, deci iBDD este o metodă eficientă și poate funcționa bine în scenariile din viața

reală. În Figura 3, conform [1] este afișat timpul de execuție al algoritmului dependent de numărul de puncte din setul de date.




Figura 3. Timpul de execuție al algoritmului

Există două direcții de dezvoltare viitoare pentru metoda actuală. Prima se referă la colectarea datelor de la persoanele în vârstă, astfel încât iBDD să fie adaptat pentru a fi folosit în sistemele de sănătate. A doua direcție se referă la extragerea altor informații din traiectorii, cum ar fi timpul la care s-a ajuns în acel punct.

O altă abordare a dezorientării este descrisă în lucrarea [5]. Astfel identificarea dezorientării este analizată din două perspective: detectare și evaluare. Detectarea dezorientării implică dezvoltarea de sisteme de asistență, astfel încât persoanele cu demență să poată realiza sarcinile zilnice în mai multă siguranță. Evaluarea dezorientării necesită detectarea acțiunilor pe baza cărora se poate recunoaște această stare de rătăcire precum și găsirea de noi caracteristici și modele ale acestui comportament. Pentru aceste două obiective, în cercetările actuale se aplică trei metode principale: monitorizarea evenimentelor, urmărirea și localizarea traiectoriilor combinate cu "Geofancing".

Monitorizarea evenimentelor se bazează pe colectarea datelor ce provin de la diferite evenimente, cu scopul de a detecta abaterile de la un comportament normal, cum ar fi repetarea anumitor evenimente. Un sistem propus de Doughty et al în lucrarea [6] care utilizează senzori neinvazivi pentru a detecta acțiuni cum ar fi deschiderea și închiderea unei uși și mișcările dintr-o cameră în alta, a pus în evidență pe baza experimentelor realizate o rată de detecție mai mare decât 95%. Alte sisteme au fost dezvoltate pentru a detecta contactul picioarelor cu podeaua. În momentul în care se detectează dezorientare, un mesaj de alertă va fi trimis îngrijitorului persoanei.

Metoda de urmărire a traiectoriilor este utilizată pentru a colecta date spațiale și temporale de la un utilizator și de a crea o traiectorie pe baza acestora. Un experiment realizat în lucrarea [7] a folosit etichete atașate de gleznă și un sistem de înregistrare video ce a înregistrat activitatea a 40 de persoane. Scopul sistemului a fost de a detecta patru tipuri de modele: directe, mișcări înainte-înapoi, circulare / care se suprapun, sau mișcări aleatoare. O serie de alte experimente s-au bazat pe analiza numărului de pași efectuați de utilizator. Comportamentul de dezorientare a fost detectat prin determinarea numărului de pași realizați de utilizator sau prin analizarea tiparelor de mișcare tridimensionale ale subiecților. O altă metodă utilizează locațiile obținute prin GPS identifică punctele de întoarcere într-o cale a utilizatorului pentru a detecta tipul traiectoriei: traiectorie normal sau cu întoarceri.

Lucrarea [8] propune crearea unei platforme M2M (machine to machine) care pot utiliza diferite metode în vederea identificării tiparelor și comportamentului pacienților cu boala Alzheimer. Platforma M2M este compusă din senzori, actuatori, un engine al platformei M2M, un gateway și un server. În prima fază, senzorii detectează modele comportamentale care se potrivesc simptomelor bolii, apoi platforma M2M procesează semnalele de la senzori și le transformă în valori. Gateway-ul extrage caracteristicile din datele colectate și identifică dacă comportamentul persoanei supravegheate se potrivește cu simptomele. Toate comportamentele de detecție sunt apoi trimise serverului analizând datele stocate și determină dacă persoana supravegheată prezintă simptome ale demenței sau nu. Setul de date de intrare este obținut prin achiziționarea datelor obținute de la senzori. Senzorii principali folosiți pentru colectarea datelor sunt senzorul de mișcare și cel de sunet. De exemplu, pentru a detecta dacă un individ a lăsat robinetul deschis, senzorul de mișcare va identifica dacă persoana se află încă la robinet. Apoi, folosind un microfon, sunetul va fi înregistrat și sistemul va detecta dacă este vorba de sunetul apei, utilizând recunoașterea de șabloane [9]. Pe lângă datele colectate de către senzori, se utilizează date suplimentare de comportament, asociate fiecărui utilizator.

Toate datele achiziționate sunt colectate pe serverul M2M, unde un utilizator poate selecta o metodă analitică de testare a demenței. Pe baza metodei selectate, sistemul creează o funcție care determină suspiciunea de demență pentru persoana solicitată. Există trei metode propuse pentru platforma de analiză. Platforma este dezvoltată astfel încât să poată fi ușor adăugate mai multe metode de testare. Prima metodă se bazează pe datele unei persoane în comparație cu datele colectate de la un grup de persoane, folosind metodele Multiple Logistic Regression și Discriminant Analysis.

În cea de-a doua metodă, comportamentul unui individ este analizat în comparație cu comportamentul său anterior. Metoda utilizată pentru a determina suspiciunea bolii Alzheimer se bazează de asemenea pe metoda Multiple Logistic Regression. Ultima metodă se bazează, de asemenea, pe comportamentul persoanei și pe attribute suplimentare ale comportamentului, astfel încât sunt furnizate caracteristici de comportament suplimentare care ar fi greu de obținut folosind numai datele achiziționate de la senzori.

Pentru evaluare au fost utilizate diferite scenarii (conform Figura 4) [10], pentru care acuratețea variază între 80% și 100%, cu excepția scenariului de uitare la închiderea televizorului, pentru care rata de detecție a fost cuprinsă între 30% și 40%.

Symptoms	Content of the Scenario
Memory loss (High motivation of life)	Forgetting to closing faucet, Forgetting to turn off the TV, Vacuum the floor
Memory loss (Low motivation of life)	Forgetting to turn off the TV, Forgetting to take a shower, Going to the rest room many times
Sleep disorders	Get a nap, Can hardly sleeping , Wandering at middle of the night
Wandering	Wander inside the house, Wandering at middle of the night

Figura 4. Corespondență simptome - scenarii, conform [10]

Lucrarea [11] descrie o modalitate de detecție a comportamentului anormal pe baza recunoașterii activităților. Astfel au fost considerate 3 seturi de date [12]. În tabelul 3, conform [12] sunt descrise datele din seturile de date care au fost analizate.

Tabel 2. Descriere date analizate, conform [12]

	House A	House B	House C
Age	26	28	57
Gender	Male	Male	Male
Setting	Apartment	Apartment	House
Rooms	3	2	6
Duration	25 days	14 days	19 days
Sensors	14	23	21
Activities	10	13	16
Annotation	Bluetooth	Diary	Bluetooth

Setul de date nu era obținut de la persoane cu demență, astfel au fost necesare modificări manuale asupra datelor pentru a simula comportamentul unei persoane cu demență. O deviere a comportamentului se referă la uitare și repetarea acțiunilor și a activităților. Acesta este unul dintre simptomele cele mai comune pentru persoanele care suferă de diferite forme de demență. Acest tip de comportament a fost adăugat în setul de date prin repetarea unei activități normale sau a unei secvențe de activități normale. A doua abatere constă în tulburări de somn și deshidratare. Tulburările de somn și dezorientarea în timpul nopții sunt de asemenea simptome ale demenței. Pentru a simula aceste activități au fost adăugate activități normale zilnice între activitatea de dormit a persoanelor.

Scopul constă în testarea rețelelor neuronale recurente (RNN) pentru a identifica dacă sunt fezabile în contextul detectării anomaliilor într-un model. Este important să se țină cont de informațiile temporale și spațiale despre o activitate, precum și de ordinea în care se desfășoară mai multe activități. Pentru a prezice dacă o activitate este normală sau se abate de la comportamentul standard al subiectului, seturile de date împreună cu etichetele activităților sunt utilizate pentru antrenarea RNN. Rețeaua este testată pe o secvență de activități care va trebui etichetă ca o activitate normală sau nu. În lucrare sunt prezentate trei tipuri de arhitecturi pentru rețele neurale recurente: Vanilla RNN, Long Short Term Memory RNN și Gated Recurrent Unit RNN. Pentru experimente au fost folosite implementările RNN din biblioteca Keras [13] și Theano [14]. Evaluarea s-a realizat pe baza celor patru metrici: recall, precision, acuratețe și F-measure pe cele 3 seturi de date: A, B și C. Comparatia între metodele analizate este prezentată din punct de vedere al algoritmilor, dar și al senzorilor utilizați este prezentată în Tabelul 3.

Pe baza modelelor analizate au fost analizate și seturi de date existente (în afara celor folosite în articolele descrise anterior).

Un prim set de date este cel descris în [15], set de date făcut public în septembrie 2015. Setul de date conține 270 de exemple pentru antrenament și 11 exemple de test. Datele au fost achiziționate pe un hol, o dată la fiecare 0,1 secunde. Setul de date conține valori preluate de la diferiți senzori: magnetometru, accelerometru și senzor de orientare. Cele două date finale folosite pentru a reprezenta un eșantion sunt două stări ale unei traiectorii, starea inițială și starea finală. Traiectoria poate fi "normală" atunci când utilizatorul se deplasează de jos în sus sau de la stânga la dreapta sau "invers", atunci când utilizatorul se mișcă de sus în jos sau de la dreapta la stânga.

Formatul fișierelor este următorul:

```
ts_1  mx_1  my_1  mz_1  ax_1  ay_1  az_1  ox_1  oy_1  oz_1
...
ts_n  mx_n  my_n  mz_n  ax_n  ay_n  az_n  ox_n  oy_n  oz_n
```

lat_1 lon_1 lat_2 lon_2 FS_1 LS_1
 ...
 lat_m lon_m lat_{m+1} lon_{m+1} FS_m LS_m

O altă bază de date ce poate fi utilizată în vederea identificării dezorientării este cea descrisă în [16]. Această bază de date achiziționează semnale wireless dintr-o clădire, localizarea făcându-se în funcție de puterea semnalului recepționat de la punctele de acces din clădire. La fel ca în poziționarea bazată pe câmpul magnetic, baza de date conține date colectate de pe cele 8 coridoare principale din laboratorul GEOTECH. Coridoarele au fost cartografiate în două direcții. Eșantionarea a fost efectuată la mai multe puncte de referință, iar din acestea au rezultat 680 de eșantioane discrete ca set de antrenament. După aceasta, coridoarele au fost cartografiate din nou, folosind diferite puncte de referință, iar rezultatul constă în 480 de eșantioane discrete utilizate ca set de testare.

Tabel 3. Comparație algoritmi

	Caracteristici	Referință	Performanțe
Senzori	1. GPS trajectory tracking – set de date public de la Microsoft Research Asia – conține traiectorii GPS preluate de la peste 160 de indivizi.	[2], [3]. [4]	
	2. O colecție de senzori, de exemplu: mișcare, sunet, presiune, au fost utilizați pentru detecția simptomelor de demență ușoară. Toți acești senzori au fost conectați la o platformă IoT care are posibilitatea de a adăuga și alte metode de monitorizare a persoanelor.	[8]	
	3. Senzori wireless au fost utilizați pentru a identifica șabloane de mobilitate a utilizatorilor. A fost utilizat RFM DM 1810 datorită unui API bine documentat, consum redus de energie și rată bună de transfer.	[12]	
Algoritmi	IBDD – primește o traiectorie formată din multiple puncte, o matrice de mapare a hărții prin care se reprezintă spațiul exterior, o mulțime de traiectorii simbolizate și etichete asociate traiectoriile, care le clasifică în traiectorii normale sau nu.	[1]	Rata de detecție a algoritmului IBDD este 95%. Rezultatele fals pozitive sunt sub 3%. Complexitatea algoritmului este $O(nm)$, unde n reprezintă numărul de celule ale traiectoriei, iar m numărul de traiectorii.

	<p>Trei tipuri (Vanilla, LSTM, GRU) de rețele neurale recurente utilizate pentru crearea de modele pe baza informațiilor existente în seturile de date de antrenare. Aceste modele sunt folosite pentru a prezice și detecta comportamente anormale și deviații de la activitățile de bază.</p> <p>Sunt considerate 3 seturi de date, achiziționate din diferite locații.</p>	[11]	<p>Fiecare set de date este analizat independent de celelalte. Pentru primul set de date metoda LSTM furnizează cele mai bune rezultate, în ceea ce privește precizia, depășind metode precum SVM și Naïve Bayes.</p> <p>Pentru al doilea set de date, rețelele neurale recurente oferă o acuratețe ridicată, dar rezultatele se situează sub cele obținute de SVM.</p> <p>Pentru al treilea set de date, rețelele neurale recurente depășesc în performanță celelalte metode.</p> <p>În ansamblu, modelele bazate pe rețele neurale recurente se ap-au apropiat de cele mai performante modele de ultimă oră și chiar mai bune pentru primul set de date care folosește o reprezentare specifică a caracteristicilor.</p>
--	---	------	--

Activitatea I:2: Elaborarea unor scenarii de utilizare a platformei și serviciilor aferente: în cadrul acestei activități au fost propuse 5 scenarii ce vor fi utilizați în etapa II pentru identificarea componentelor sistemului IONIS și proiectarea arhitecturală a acestuia.

Scenariul 1:

Domnul X merge să facă o plimbare în parcul din apropierea casei. În momentul în care vrea să se întoarcă acasă el nu mai reușește să-și amintească drumul spre casă. IONIS va detecta faptul că Domnul X este confuz (stă pentru o perioadă mai lungă în același loc, merge dintr-un loc în altul, în mod repetat, nu-și respect agenda) și îi sugerează să se întoarcă acasă consultându-și agenda (de ex. preferințele sale după o plimbare în parc). Sistemul îi va arăta pe telefonul mobil, direcția pe care trebuie să o urmeze pentru a ajunge acasă (pas cu pas) fiind însoțită de mesaje vocale și textuale. De asemenea un mesaj de alertă este trimis către persoana care are grijă de dl. X (sau către un membru al familiei acestuia) pentru a-l informa că domnul X și-a terminat plimbarea, dar că acesta este confuz referitor la drumul de înapoiere și că sistemul îi ajută să ajungă acasă, asigurând urmărind poziția acestuia pas cu pas, afișând în permanență poziția acestuia în sistemul de (WebSite care va afișa poziția permanentă a domnului X și drumul sugerat care ar trebui să-l urmeze). În cazul în care dl X nu va urma recomandările sistemului, IONIS va trimite un nou mesaj către persoana care-l are în grijă. Pașii componenți ai scenariului sunt (Figura 5):

- Modulul de localizare detectează continuu poziția actuală a domnului X.
- Modulul de comportament detectează starea "ajutor necesar".
- Modulul de comportament necesită intervenția modulului de suport.
- Modulul de suport verifică agenda utilizatorului.
- Modulul de suport necesită poziția furnizată de modulul de localizare pentru a-l ghida pe domnul X către casă.

- Modulul de localizare îl ghidează pe domnul X către casă.
- Modulul de suport activează modulul de apel în vederea contactării persoanei care-l îngrijește.

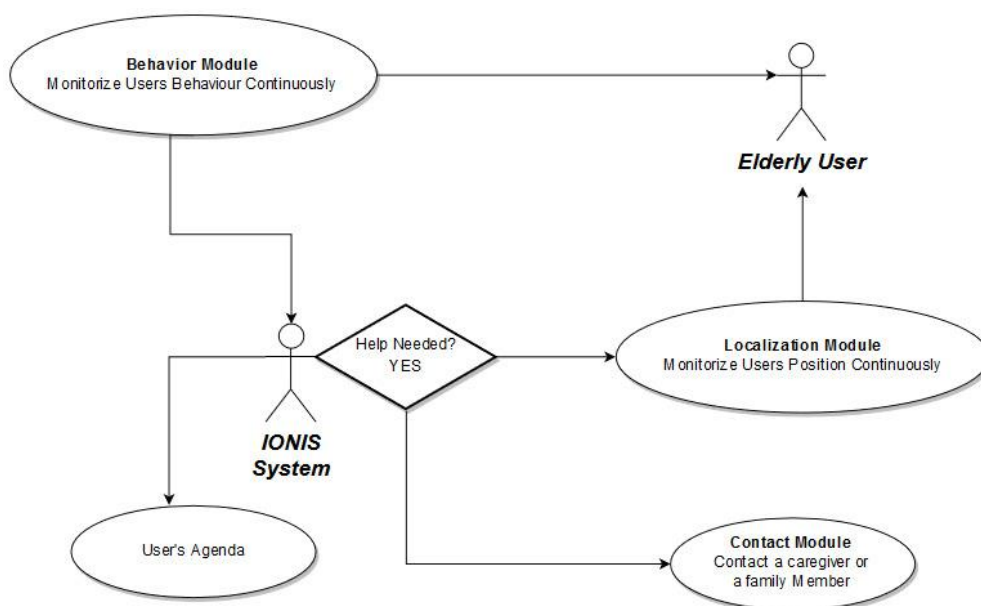


Figura 5. Scenariul 1

Scenariul 2:

Dl. X este singur acasă și doarme. IONIS detectează că domnul X s-a trezit de multe ori în ultima noapte și că de fiecare dată a avut probleme să adoarmă. IONIS consultă lista de activități pentru ziua curentă și constată că nu este nimic urgent, prin urmare IONIS îi sugerează domnului X să-și reprogrameze întâlnirile într-o altă zi și să facă niște activități în interiorul casei, astfel încât să nu depună eforturi excesive, deoarece este deja obosit ca rezultat al faptului că a dormit prost în noaptea anterioară. Pașii componenți ai scenariului sunt (Figura 6):

- Modulul de monitorizare a somnului îl urmărește continuu pe domnul X în timpul perioadei de somn.
- De fiecare dată când somnul este întrerupt, modulul de monitorizare a somnului informează modulul de sănătate.
- Modulul de sănătate urmărește continuu parametrii de sănătate ai domnului X (de exemplu, puls și număr de pași efectuați). Dimineața constată că valorile parametrilor medicali nu sunt în limite normale (de ex. Puls sau tensiune mai mare ca de obicei) sau că el este oboist (a efectuat un număr mare de pași pe perioada nopții) și informează modulul de decizie că este mai bine pentru domnul X să rămână acasă.
- Modulul de decizie verifică agenda dlui X (activitățile curente pentru ziua în curs) și timpul adecvat în care domnul X poate muta activitățile și întâlnirile amânate (cu modulul agendei).
- Modul de decizie sugerează domnului X să amâne activitățile programate pentru ziua curentă.
- Modulul de decizie sugerează o nouă planificare pentru aceste activități.
- Modul de decizie verifică în permanență starea de sănătate a domnului X (prin interacțiunea cu modulul de sănătate).

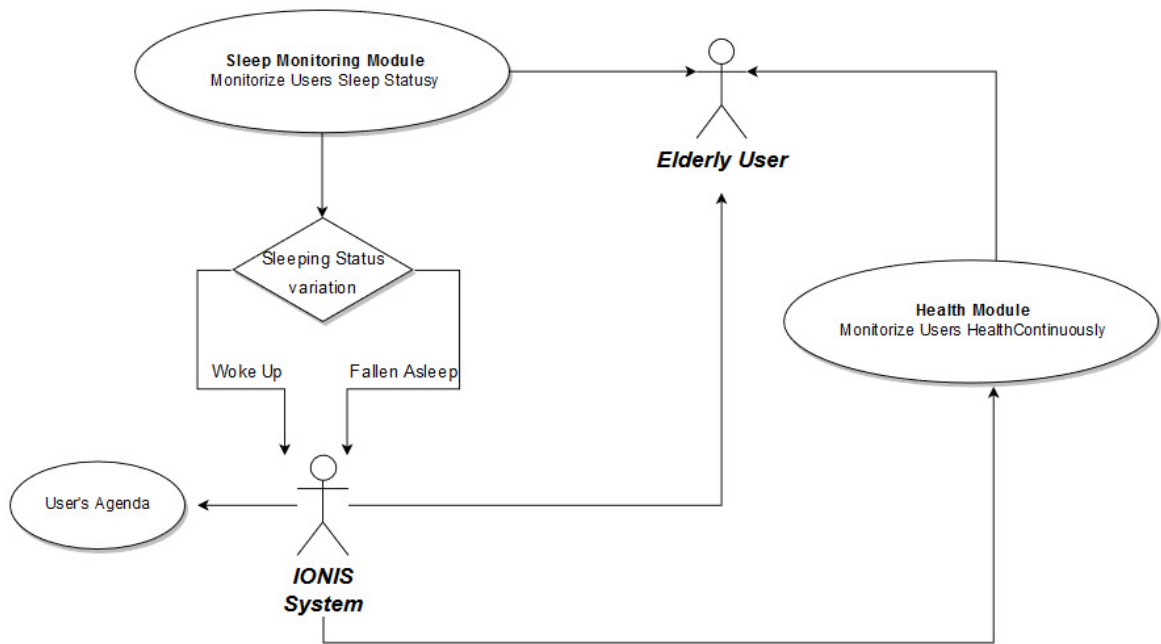


Figura 6. Scenariul 2

Scenariul 3:

Dl. X se află acasă și se uită la TV. IONIS detectează că dl. X a petrecut prea mult timp în fața televizorului, fără să desfășoare nicio activitate fizică. IONIS îi sugerează dlui X să facă o altă activitate. Pașii componenți ai scenariului sunt (Figura 7):

- Modulul de monitorizare a activității urmărește continuu activitatea domnului X.
- Modulul de monitorizare a activității detectează faptul că domnul X a petrecut prea mult timp făcând aceeași activitate.
- Modulul de monitorizare a activității informează modulul de decizie.
- Modulul de decizie verifică starea de sănătate a domnului X prin interacțiune cu modulul de sănătate.
- Modulul de decizie verifică agenda domnului X.
- Modulul de decizie îl informează pe domnul X că a petrecut mult timp făcând același lucru și sugerează o activitate adecvată cu starea sa de sănătate și în conformitate cu agenda sa.

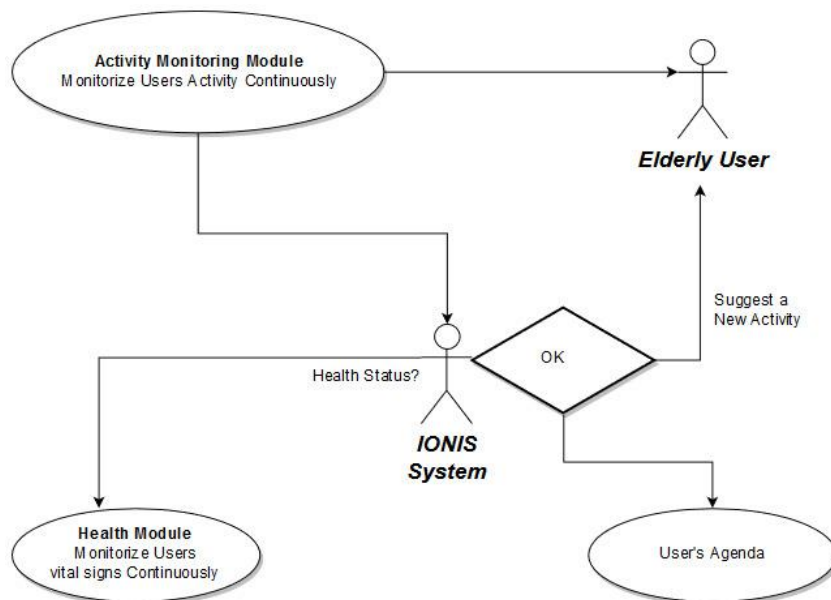


Figura 7. Scenariul 3

Scenariul 4:

Dl. X adoarme cu luminile aprinse. IONIS detectează acest lucru și în mod automat vaș tinge luminile. În cazul în care dl. X se trezește în mijlocul nopții și va începe să meargă prin casă, IONIS în mod automat va porni luminile. Pașii componenți ai scenariului sunt (Figura 8):

- Modulul de monitorizare a somnului detectează că domnul X a dormit.
- Modulul de monitorizare a somnului informează modulul de decizie că domnul X a adormit.
- Modulul de decizie verifică starea luminilor și informează modulul de iluminare să le stingă.
- Modulul de monitorizare a somnului detectează faptul că domnul X s-a trezit.
- Modulul de monitorizare a somnului informează modulul de decizie că domnul X s-a trezit.
- Modulul de decizie verifică starea luminilor din casă și transmite modulul de iluminare să le aprindă în cazul în care este nevoie (dacă lumina naturală nu este suficientă la acea oră).

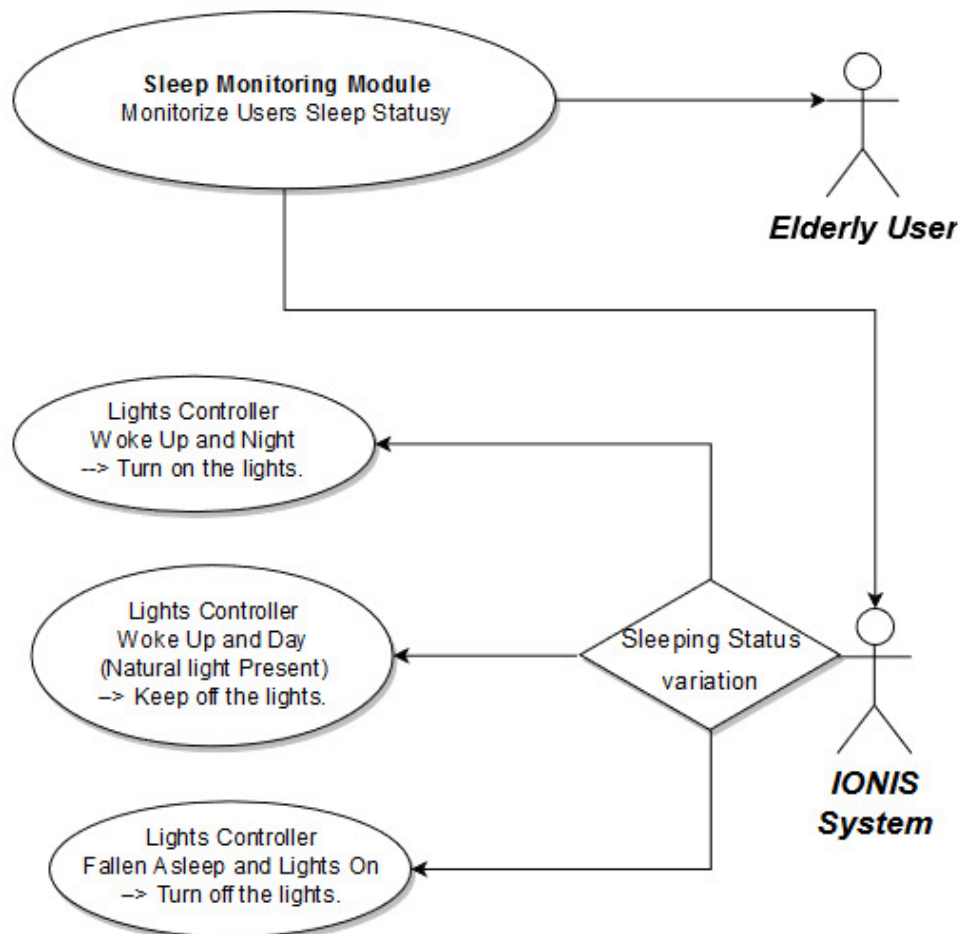


Figura 8. Scenariul 4

Scenariul 5:

Dl. X urmărește un program TV care îl agită (de exemplu un meci de fotbal, în care echipa sa favorite pierde). IONIS sugerează să schimbe canalul sau să efectueze o altă activitate. În cazul în care situația persistă sau se înrăutățește, IONIS va contacta persoana care are grijă de el sau pe un membru al familiei. Pașii componenți ai scenariului sunt (Figura 9):

- Modulul de comportament detectează starea de agitație.
- Modulul de comportament necesită intervenția modulului de decizie.
- Modulul de decizie verifică activitatea reală a dl. X cu modulul de monitorizare a activității și verifică istoricul domnului X referitor la acea activitate.
- Modulul de decizie verifică starea de sănătate a domnului X prin interacțiune cu modulul de sănătate.
- Modulul de decizie constată că activitatea desfășurată îi provoacă agitație.
- Modulul de decizie sugerează domnului X să schimbe canalul TV sau să realizeze o altă activitate.
- Dacă situația persistă sau se înrăutățește, modulul de decizie va cere modulului de asistență va informa un membru al familiei.

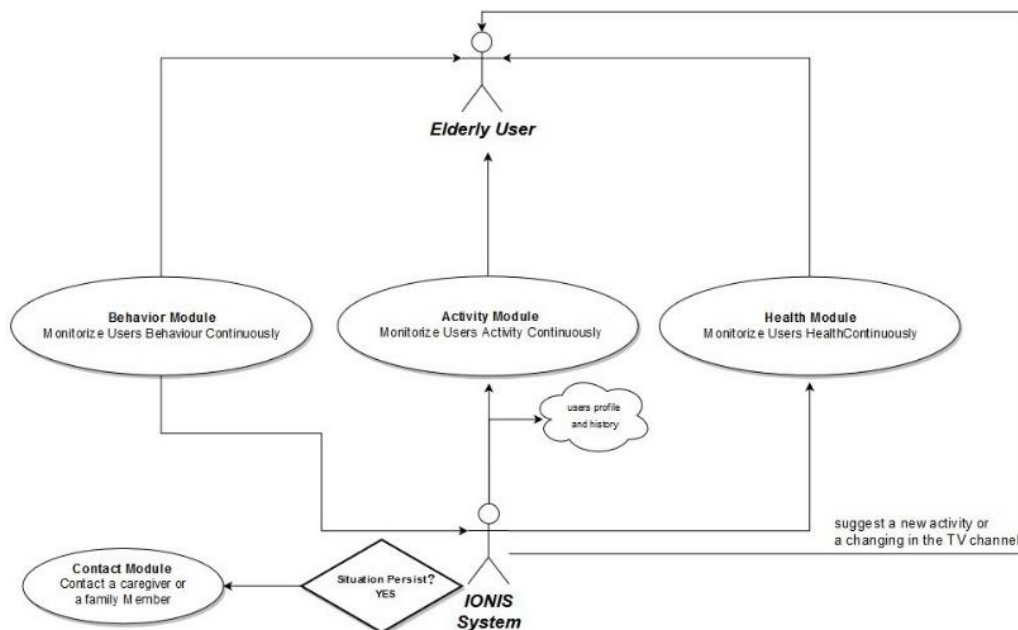


Figura 9. scenariul 5

Activitatea I:3: Diseminare: Întâlnire deschidere proiect:

5. Prezentare rezultate verificabile etapă

Activitatea I.1: Studiul metodelor și tehnologiilor existente în domeniul inteligenței ambientale

Activitatea I:2: Elaborarea unor scenarii de utilizare a platformei și serviciilor aferente

Activitatea I:3: Diseminare: Întâlnire deschidere proiect

- Elaborarea unui articol submis la revista International Journal of Computers Communications & Control, indexată ISI (FI: 1.374) – articol în evaluare:

I. Mocanu, G. Scarlat, L. Rusu, D. Benta, B. Cramariuc – Indoor Localisation through Probabilistic Ontologies, International Journal of Computers Communications & Control (ISI Journal, FI: 1.374), în evaluare

- Întâlnirea de deschidere a proiectului – 17 Octombrie 2017, Geneva, Elveția unde s-au discutat principalele aspecte în vederea proiectării și implementării principalelor componente din sistemul IONIS.
- Prezentare poster în cadrul conferinței: **9th Alzheimer Conference – ASK 2017**: "For dementia friendly society", 20-21 Octombrie Spominčica – Alzheimer Slovenia.


IONIS Indoor and outdoor NITICSplus solution for dementia challenges

1.10.2017-31.03.2020

IONIS brings together technologies and services to build a user-centered modular ICT-based platform that offers a wide range of specific solutions to problems and difficulties that people with dementia are confronting. The IONIS solution can compensate in an adaptive way for mild to moderate dementia associated deficiencies such as memory problems and cognitive decline. The integrate technologies and services will offer support to both caretakers and caregivers.

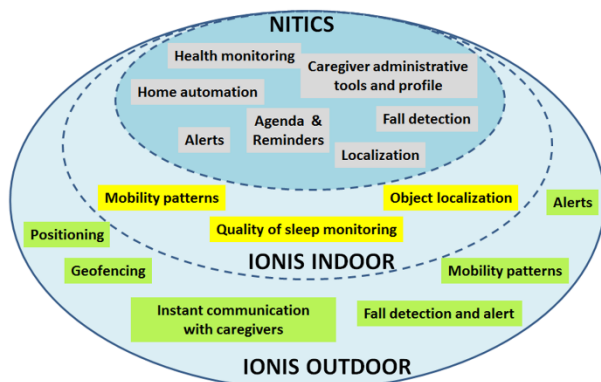
Participant organization name	Organization type	Country
ECLEXYs Sagl	SME	CH
Centrul IT pentru Stiinta si Tehnologie	End-user/SME	RO
University POLITEHNICA of Bucharest	R&D	RO
IZRIIS Institute for research, intergenerational relations, gerontology and ICT	End-user	SI
Alzheimer Slovenia - Spominčica	NGO	SI
Warsaw University of Technology	R&D	PL
Department of Geriatrics Warsaw	End-user	PL
Bay Zoltán Nonprofit Ltd. for Applied Research	End-user	HU
Órszi Napsugár Otthon	End-user	HU
Softic Ltd.	SME	HU

Effort distribution

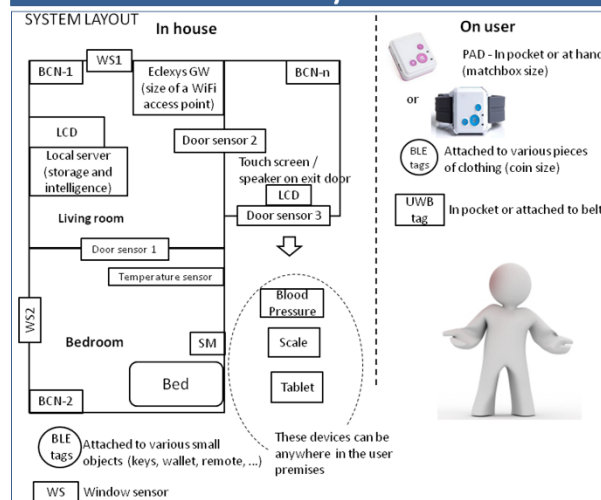


IONIS design and motivation

IONIS is building on the results of a previous AAL project, NITICS (Networked InfrasTructure for Innovative home Care Solutions), selected as one of the AAL success stories. The NITICS platform will be enhanced with new functionalities such as to offer both indoor and outdoor services.

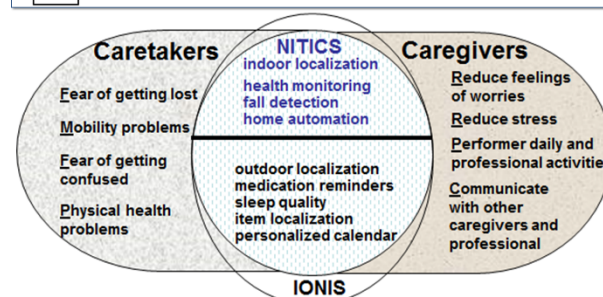


IONIS layout




IONIS end-users and objectives

❖ Primary end-users: are people, not necessarily elderly, with cognitive impairment or in early to moderate stages of dementia who are still capable of performing many of the regular indoor and outdoor activities despite declining memory and cognitive functions.
 ❖ Secondary end-users: caregivers, both informal and formal. Main target are informal caregivers who are also impacted physically, psychologically and economically.



Acknowledgements

Under the Call AAL-2016-074, this work was supported within the Active and Assist Living Programme (AAL) by a grant of the:
 > Hungarian National Research, Development and Innovation Office, NKFIH
 > Polish National Centre For Research And Development, NCBIR
 > Romanian Executive Agency for Scientific Research and Innovation, CCCDI-UEFISCDI
 > Slovenian Ministry of Education, Science and Sport, MIZS
 > Swiss Federal Officer for Professional Education and Technology, OPET



6. Concluzii

Obiectivele au fost realizate integral, gradul de atingere al rezultatelor fiind de 100%. În cadrul **activității I.1** a fost realizată o analiză a sistemelor existente care tratează detecția simptomelor de demență, în special identificarea dezorientării pe baza analizei comportamentului uman (obținut din traiectoriile de deplasare sau activitățile realizate). Totodată au fost analizate o serie de seturi de date disponibile, care vor putea fi utilizate în etapa 2/2018 în vederea implementării unei metode de detecție a dezorientării. În cadrul **activității I.2** au fost elaborate 5 scenarii ce vor ajuta la identificarea componentelor sistemului IONIS precum și proiectarea acestuia. Activitatea I.3 a avut ca scop diseminarea proiectului. Întâlnirea de deschidere a proiectului s-a desfășurat pe 17 Octombrie 2017, la Geneva. Proiectul a fost prezentat în cadrul conferinței: 9th Alzheimer Conference – ASK 2017: "For dementia friendly society", 20-21 Octombrie Spominčica – Alzheimer Slovenia. Totodată a fost elaborat un articol, trimis la revista International Journal of Computers Communications & Control, indexată ISI (FI: 1.374), aflat în evaluare – în care se propune o metodă de localizare în interiorul casei bazată pe recunoașterea de obiecte combinată cu identificarea contextului pe baza unei ontologii.

7. Diseminare

- Elaborarea unui articol submitat la revista International Journal of Computers Communications & Control, indexată ISI (FI: 1.374) – articol în evaluare:

I. Mocanu, G. Scarlat, L. Rusu, D. Benta, B. Cramariuc – Indoor Localisation through Probabilistic Ontologies, International Journal of Computers Communications & Control (ISI Journal, FI: 1.374), în evaluare

- Întâlnirea de deschidere a proiectului – 17 Octombrie 2017, Geneva, Elveția unde s-au discutat principalele aspecte în vederea proiectării și implementării principalelor componente din sistemul IONIS.
- Prezentare poster în cadrul conferinței: **9th Alzheimer Conference – ASK 2017**: "For dementia friendly society", 20-21 Octombrie Spominčica – Alzheimer Slovenia.

8. Pagina web a proiectului – actualizata cu datele ultimei raportari.

Pagina proiectului este: aimas.cs.pub.ro/ionis/

9. Bibliografie

1. Qiang Lin, Daqing Zhang, Kay Connelly, Hongbo Ni, Zhiwen Yu, Xingshe Zhou: Disorientation detection by mining GPS trajectories for cognitively-impaired elders. Pervasive and Mobile Computing 19: 71-85 (2015)
2. Yu Zheng, Like Liu, Longhao Wang, Xing Xie. Learning Transportation Modes from Raw GPS Data for Geographic Application on the Web, In Proceedings of International conference on World Wild Web (WWW 2008), Beijing, China. ACM Press: 247-256
3. Yu Zheng, Quannan Li, Yukun Chen, Xing Xie. Understanding Mobility Based on GPS Data. In Proceedings of ACM conference on Ubiquitous Computing (UbiComp 2008), Seoul, Korea. ACM Press: 312–321.

4. Yu Zheng, Yukun Chen, Quannan Li, Xing Xie, Wei-Ying Ma. Understanding transportation modes based on GPS data for Web applications. *ACM Transaction on the Web*. Volume 4, Issue 1, January, 2010. pp. 1-36.
5. Qiang Lin, Daqing Zhang, Liming Chen, Hongbo Ni, Xingshe Zhou: Managing Elders' Wandering Behavior Using Sensors-based Solutions : A Survey
6. K. Doughtyt, G. Williams, P.J. King, *et al.* DIANA - A telecare system for supporting dementia sufferers in the community, *Proc EMBC 1998* (1998), pp. 1980-1983
7. David Martino-Saltzman, PhD, Bruce B. Blasch, PhD, Robin D. Morris, PhD, Lisa Wynn McNeal, MSE; Travel Behavior of Nursing Home Residents Perceived as Wanderers and Nonwanderers, *The Gerontologist*, Volume 31, Issue 5, 1 October 1991,
8. Haruka Ishii, Keisuke Kimino, Maher Aljehani, Nobuhiro Ohe, Masahiro Inoue - An Early Detection System for Dementia using the M2M/IoT Platform, Volume 96, 2016, Pages 1332-1340
9. Hiroyuki Nishi, Kin Kin, Yoshimasa Kimura and Toshio Kakinoki, "Life sound discrimination algorithm using Neural network," *IEICE Tech. Rep.*, vol. 114, no. 390, ICM2014-43, LOIS2014-50, pp. 61-65, Jan. 2015(in Japanese).
10. Ishii, Haruka & Kimino, Keisuke & Aljehani, Maher & Ohe, Nobuhiro & Inoue, Masahiro. (2016). Early Detection System for Dementia using M2M/IoT Platform. *Procedia Computer Science*. 96. 1332-1340. 10.1016/j.procs.2016.08.178.
11. Damla Arifoglu, Abdelhamid Bouchachia - Activity Recognition and Abnormal Behaviour Detection with Recurrent Neural Networks
12. T. Van Kasteren, G. Englebienne, and B. J. A. Krose. Human activity recognition from wireless sensor network data: Benchmark and software. *Activity Recognition in Pervasive Intelligent Environments*, pages 165–186, 2011.
13. Francois. Keras. <https://github.com/fchollet/keras>, 2015.
14. Theano Development Team. Theano: A Python framework for fast computation of mathematical expressions. *arXiv e-prints*, abs/1605.02688, may 2016.
15. Joaqu n Torres-Sospedra, David Rambla, Raul Montoliu, Oscar Belmonte, and Joaqu n Huerta. UJIIndoorLoc-Mag: A New Database for Magnetic Field-Based Localization Problems, *Proceedings of the Sixth International Conference on Indoor Positioning and Indoor Navigation (IPIN 2015)*, 13-16 October 2015, Banff, Alberta, Canada
16. <https://archive.ics.uci.edu/ml/machine-learning-databases/00310/>, accesat decembrie 2017