

Sándor Zsófia – Kis Gergely: Szimultán végrehajtáson alapuló mozgásfelismerési algoritmusok fejlesztése mobiltelefonos szenzorok felhasználásával

Hivatkozás/reference:

Sándor Zsófia és Kis Gergely, „Szimultán végrehajtáson alapuló mozgásfelismerési algoritmusok fejlesztése mobiltelefonos szenzorok felhasználásával”, *Információs Társadalom*, XVI. évf. (2016) 1. szám, 57-68. old.
<http://dx.doi.org/10.22503/infars.XVI.2016.1.4>

A vezeték nélküli adatátviteli technológiákat használó szenzorhálózatok elterjedésével megnyílt a lehetőség nagymennyiségű mérési adat begyűjtésére, melyre alapulva különböző kutatócsoportok algoritmusfejlesztésekbe kezdtek a szenzoradatokban rejlő információk kinyerésére. Az egyik leggyakrabban kutatott terület a mozgásfelismerés. Cikkünkben egy olyan rendszert mutatunk be, melyben a mozgásfelismerést általános környezetben vizsgáljuk, vagyis nem a testen elhelyezett különböző szenzorok segítségével azonosítjuk a mozgásformákat, hanem a társadalom szinte bármely tagjánál fellelhető mobiltelefonos szenzorok által gyűjtött adatok felhasználásával.

Kulcsszavak: mozgásfelismerés, gépi tanulás, szenzoros adatok, idősoros mérési adatok, mintázatfelismerés

Development of motion detection algorithms based on simultaneous processing using mobile phone sensors

The growing use of sensor networks based on wireless data transfer technologies have opened up the opportunity to collect vast volumes of measurement data, enabling research teams to begin developing algorithms to gain information from sensor data. One of the most extensively researched areas is that of motion detection. The article presents a system in which motion detection is examined in a general environment, i.e. different forms of motion are not identified with the help of sensors attached to the human body but by using data gathered by mobile sensors, which is practically found on every member of society.

Keywords: motion detection, machine learning, sensory data, time series, pattern recognition

Információs Társadalom

Szűts Zoltán – Yoo Jinil:
Big Data, az információs társadalom új paradigmája

Sólyom Barbara:
Általános iskolások okostelefon-használati szokásai

Lăzăreanu Cămpian – Lázár Ede – Manuela Rozalia Gabor:
EU-tagállamok IKT fejlettségének különbségei

2016. XVI. évfolyam 1. szám

A folyóiratban közzétett művek a *Creative Commons Nevezd meg! - Ne add el! - Így add tovább! 4.0 Nemzetközi Licenc* feltételeinek megfelelően használhatók.

Sándor Zsófia – Kis Gergely

Szimultán végrehajtáson alapuló mozgásfelismerési algoritmusok fejlesztése mobiltelefonos szenzorok felhasználásával

Bevezetés

A vezeték nélküli kommunikációs technológiák, ezen belül főleg a mobiltelefonok, rendkívüli mértékben való elterjedése intézményi, társadalmi és kulturális változásokat hozott magával, ahogyan ezt George Gilderamerikai író is előre jelezte (Freeman és Louca 2012: 318-324). A technológiai újítások lehetővé teszik számunkra, hogy egyre több, megfelelő technológia ésmért adatok hiányában eddig megoldhatatlannak tűnő problémára találjunk megoldást.

A technológiai újítások között kiemelkedő mértékű fejlődés figyelhető meg a számítási költségek folyamatos csökkenésében. Ennek következtében olyan feladatok is megoldhatóvá váltak, melyek nagy mennyiségű adat feldolgozását igénylik – sokszor idézett kifejezés lett a Big Data, mely definíciószerűen konzervatív adatfeldolgozási módszerekkel és eszközökkel nem feldolgozható adathalmaz kezelését jelenti. Az ilyen nagymennyiségű adathalmaz egyik tipikus forrása a szenzoros adatok sorozata. A második releváns technológiai fejlődési irány éppen a szenzorok fejlődése – egyre kisebb méretű, pontosabb és kisebb energiafogyasztású szenzorok állnak rendelkezésünkre. A vezeték nélküli szenzorhálózatok (WSN) elterjedése lehetővé tette, hogy egy-egy szenzor által összegyűjtött adat valós időben továbbítható és feldolgozható legyen, valamint több szenzor összekötése is lehetővé válik ezen a módon.

Társadalmunk egyik kulcsfontosságú kutatási célterülete az emberi viselkedés tanulmányozása. Az emberi viselkedés megismerésével széleskörűen hasznosítható tudásra tehetünk szert, mely tudással a támogatható területek között szerepel a teljesség igénye nélkül az orvostudomány, a pszichológia, a gazdasági célú marketingtevékenység és az egészségipar. Az emberi viselkedés egyik kivételése pedig az emberi mozgás – a mozgás megfigyelésével következtethetünk az egyén viselkedésére, szokásaira.

A kutatók rendelkezésére áll tehát egy megfogható problémakör, valamint az az eszköztár, melynek segítségével a problémakörre adott válasz megtalálható. Éppen ezért ma széleskörűen kutatják a szenzorok által gyűjtött adatok felhasználhatóságát mozgásdetektálásra. A kutatások legtöbbször laborkörülmények között folyik, testre erősített szenzorok segítségével.

Jelen cikk célja, hogy egy olyan rendszert mutasson be, mely a mozgásdetektálás kapcsán a laborkörülmények közül kilépve, a mindennapi élet során keletkező adatok feldolgozására épül. A problémafelvetést követően az adatgyűjtő és továbbító rendszert, majd a feldolgozó algoritmusok egymásra épülését mutatjuk be, végül összefoglaljuk a tanulságokat.

Problémafelvetés

Megelőző kutatások

Az okostelefonokba épített és egyéb viselhető szenzorok felhasználási területei sokrétűek. A lépésfelismeréstől mint elemi cselekvéstől kezdve az egészséges életmódra motiváláson át a komplex cselekvések felismeréséig gyakorlatilag minden mozgásforma detektálására alkalmasak lehetnek a megfelelő módszer felhasználásával. A nemzetközi irodalomban is visszaköszön ez a sokrétűség, mely a módszerekre és a felhasználási területre egyaránt vonatkozik.

Egyes kutatások szűk célterületekre irányulnak, mint például a lépésszámlálás kapcsán a lehető legpontosabb megoldás keresése (Naqvi et al. 2012: 675–681), melynek során az akcelerométert (gyorsulásmérőt) felhasználva sikerült mindössze néhány lépésnyi hibát elérni a valójában megtett lépésekhez képest. E megoldás egyik továbbfejlesztett változata, amikor már a sebesség tényezőt is figyelembe vehetjük (Murray, Abhayasinghe és Jayalath 2013). A sebességet is figyelembe vevő kutatásban a lassú és gyors séta, lejtős vagy emelkedős területeken való séta, valamint a lépcsőzés esetében történt meg a lépésszámlálás. A kutatók mindehhez a giroszkópot használták fel, mert arra a következtetésre jutottak, hogy a lassú séta esetén az akcelerométer nem ad pontos értéket a lépésszámláláskor. Eredményeik biztatók: a lassú séta sík terepen 96% feletti, lejtőn és emelkedőn 95% feletti, míg lépcsőzés esetén 90% feletti pontosságot hozott a lépésszámlálás során.

Több kutatócsoport is vizsgálta az alapcselekvéseket, mint a séta, futás, lépcsőzés, ülés, állás, liftezés, ugrás. Közöttük egyesek a Random Forest módszer segítségével 99.97%-os pontosságot értek el a cselekvések felismerésében (Mendes-Moreira, Cruz-Silva és Menezes 2013), míg a legközelebbi szomszéd algoritmust felhasználva 93%-ban sikerült eltalálni a cselekvést (Das et al. 2010). Megszorításokkal dolgozott (Cruz-Silva, Mendes-Moreira és Menezes 2013) egyetlen készüléktípussal és csak nadrágzsebben történő elhelyezkedéssel, míg egy másik esetben (Das et al. 2010) ugyancsak egy készüléktípus, és két pozícióban történő elhelyezéssel jelentették a vizsgálatok fókuszát.

A nyugalmi helyzetek – vagyis az állás, ülés, fekvés detektálása – nagy pontossággal megtehető (Cerqueira da Silva 2013). Ezen kutatás során a felsoroltakon kívül a sétát és a lépcsőzést mint tevékenységeket vizsgálták, így a döntési fa felhasználásával 86%-os pontosságot értek el. Mások ennél is tovább léptek és már az autózvezetést is detektálni tudták a séta, futás, biciklizés, ülés és állás mellett (Siirtola és Röning 2012: 38-45). A vizsgálat során online és offline módban is tesztelték a QDA (Quadratic Discriminant Analysis) és a k-legközelebbi szomszéd algoritmusok hatékonyságát. Online módban a QDA 95,8%, a k-nn 93,9%, míg offline módban a QDA 95,4%, a k-nn pedig 94,5%-os pontosságot adott. Ezekben az esetekben is rögzítve volt a telefonok elhelyezése, Siirtola és Röning esetében emellett az elhelyezés iránya is (2012: 38-45).

A Khan és szerzőtársai (2010) esetében már törekedtek arra, hogy a telefonok pozíciójától függetlenül legyenek képesek cselekvéseket elkülöníteni, ám ebben az esetben is csak az alapcselekvések kerültek megkülönböztetésére.

Egyes publikációk (Tomlein et al. 2012, Shin et al. 2010, Kwapisz, Weiss és Moore, 2010) esetében az egészséges életmód és a mozgásfelismerés összekapcsolásának bemutatása volt a cél. Az egyik esetben (Tomlein et al. 2012) a vizsgálatot végzők lépésszámlálót fejlesztettek ki akcelerométer adatok és neurális háló segítségével úgy, hogy a lépésszám-

lálók általános hibáját, vagyis a hamis lépések detektálását tűzték ki célul, és ezzel az egészségmegőrzési rendszer megbízhatóságát fejlesztették. Egy másik kutatás során emelkedőn felfelé- és lefelé séta, sík területen séta, lefelé és felfelé lépcsőzés, valamint a futás cselekvések felismerésére fejlesztettek algoritmust ismét egészségmegőrzési céllal (Shin et al. 2010). A cselekvések felismerésének pontossága rendre 93,2%, 97,4%, 97,6%, 98,8%, 92,2%, 90,8% voltak. Nem minden elemzés irányult kizárólag az egészségüggyel kapcsolatos adatok feldolgozására, piaci szemlélettel egy kényelmi funkció fejlesztése is cél lett, melyben a telefon üzemmód változtatása volt a fókuszban egyes tevékenységek, például futás során (Kwapisz, Weiss és Moore 2010).

Az alapcselekvések mellett összetett cselekvések felismerésével is foglalkoztak, mint például a kézmosás, takarítás, főzés, stb. (Dernbach, Das és Krishnan 2012). Ebben a kutatásban módszerek széles skáláját alkalmazták, melyek közül a NaiveBayes módszert kivéve 90% feletti pontossággal tudták megmondani az alapcselekvéseket. Ezzel szemben a komplex cselekvések esetén a legjobb pontosság mindössze 50% volt.

A legtöbb esetben viselhető szenzorok segítségével adnak jó becsléseket a felhasználó által végzett cselekvésekre, ami a fix elhelyezkedésből adódik (Yang és Hsu 2009, Karantonis et al. 2006, Ozdemir és Barshan 2014).

Az eddigiek alapján a komplexitás több dimenziója felé mozdulunk el, azzal a céllal, hogy a lehető legtöbb cselekvést el tudjuk különíteni a közepes komplexitású cselekvések közül (amiben a buszon utazás például benne van, de a mosogatás mint tevékenység már nincs). Mindezt okostelefonok felhasználásával a széleskörű felhasználási lehetőségek érdekében, lehetőleg a telefon típusától, és elhelyezkedésétől függetlenül.

A kihívás

Az általunk bemutatásra kerülő rendszer célja, hogy a mozgást egyrészt természetes közegben, másrészt külön eszközigény nélkül is képes legyen pontosan felismerni. A széleskörben történő elterjedést megakadályozhatja, ha a felhasználó számára kényelmetlenséggel jár az eszköz használata. Amennyiben szükség van egy bokapánt és egy karperec együttes viselésére, ez kellemetlen lehet a felhasználó számára, így olyan megoldást kerestünk, mellyel a felhasználónak nem szükséges a mindennapi szokásait megváltoztatnia. Így esett a választás a mobiltelefonokba beépített szenzorok használatára. A mobiltelefonokat a felhasználók a nap aktív részének jelentős hányadában maguknál tartják, így a mobiltelefon mozgása a legtöbb esetben a felhasználó mozgásával egyezik.

A mobiltelefonok használatához az algoritmusfejlesztésen túl egyéb kihívások is kapcsolódnak. Az első kihívás éppen a fent említett kényelmetlenségek kiküszöböléséhez köthető. Csak akkor igaz, hogy a mobiltelefon használata nem okoz kényelmetlenséget a felhasználónak, ha a rendszer képes olyan alapelvárásokat teljesíteni, mint az alacsony energiafogyasztás, az adatforgalom alacsonyan tartása és a telefon erőforrásainak (például memória) optimalizált felhasználása. Ezt tehát mindenképp teljesíteni kell a használhatóság érdekében.

A második kihíváscsoport a különbözőségekből adódik, értve ezt a felhasználók közötti és a készülékek közötti különbségekre egyaránt. A mozgások azonosítása azért lehet nehézkes, mert a különböző egyének eltérnek testalkatban, habitusban, mozgási szokásokban

– egyéneként eltérnek ugyanazok a végzett cselekvések, amennyiben a szenzoros idősoros adatokat vizsgáljuk. Emellett a mobiltelefonok közötti különbségek is kiküszöbölendők. A beépített szenzorok közötti minőségbeli, pontosságbeli, és akár mértékegységbeli különbségekkel meg kell tudni birkózni ahhoz, hogy a széleskörű elterjedést biztosítani lehessen.

A harmadik kihívás a megfelelő válaszidő biztosítása megfelelő pontosság mellett. Mivel nem laborkörülmények között marad a rendszer, ezért – a nemzetközi irodalmak alapján – arra sem lehet számítani, hogy a modellek pontossága ugyanolyan lesz, mint a fent említett laborkörülmények között, figyelembe véve azt is, hogy a megkülönböztetni kívánt cselekvések egy része egymáshoz hasonló.

Technikai megoldási koncepció

A megoldási koncepció felvázolása előtt fontos megemlíteni, hogy a kutatók jelenleg az adat-továbbítás és feldolgozás technikai megoldása tekintetében két út közül választhatnak. Mindkét út rendelkezik előnyökkel és hátrányokkal is, ezeket ebben a szakaszban ki is fejtjük.


A probléma alapja, hogy a szenzoradatok a mobiltelefonban vagy a szenzoros eszközben elérhetőek, ezért vagy továbbítani kell ezeket egy feldolgozó szerver felé, vagy a feldolgozást kell a szenzoros eszközön végezni. Amennyiben az adatokat egy szerveren szeretnénk feldolgozni, a megoldandó probléma a magas generált adatforgalom. A nagymennyiségű adat továbbítása a felhasználó számára kellemetlen lehet, amennyiben az mobilinterneten keresztül történik. Lévé ez az adatintenzívebb megoldás, ezért a szervernek is a megfelelő kapacitásokkal kell rendelkeznie. További előny szemben az eszközön történő feldolgozással, hogy ebben az esetben nincs információvesztés.

Az eszközön történő feldolgozás mellett voksolók legfőbb érve az, hogy nincs szükség minden adatra, hanem az eszközön futó algoritmusok segítségével kinyerhető a lényegi információ, és elegendő ezt továbbítani a szerver felé. Ez nagy előnye ennek a módszernek, mert így erőforrást takarít meg mind az eszköz, mind a szerver tekintetében, azonban az információvesztés mellett a feldolgozó algoritmusok futásának magasabb memóriaigénye van, mely ismét csak kellemetlen lehet a felhasználó számára. Az 1. táblázat mutatja összefoglalva a két módszer előnyeit és hátrányait.

	Adatfeldolgozás szerveren	Adatfeldolgozás az eszközön
Generált adatforgalom	Magas	Alacsony
Helyi memóriaigény	Alacsony	Magas
Szerver tárhely igény	Magas	Alacsony
Információ-vesztés	Nincs	Van

1. táblázat: Az adatfeldolgozás módjainak értékelése (saját szerkesztés)

Fejlesztésünk során a szerveren való adatfeldolgozást választottuk, legfőképpen azért, mert a kutatás során minden információ megtartására törekedünk. A fenti problémakör megoldásaként az 1. ábrán bemutatottan megfelelően egy olyan rendszert hoztunk létre, mely az említett kihívásokat tartja szem előtt.



1. ábra: Az adatfeldolgozás folyamata (saját szerkesztés)

Mivel a mobiltelefonok szenzorjaiból kinyerhető adatokat gyűjtjük, ezért egy mobilalkalmazás az egyik központi eleme a felépített rendszernek. Ez az alkalmazás az üzenetküldő szertvertől kapott utasításoknak megfelelően gyűjti az adatokat, ezeket fájlba írja, tömöríti, és a kapott utasításoknak megfelelően továbbítja az adat-szerver felé. Az adat-szerver feladata a nagy mennyiségben kapott adat feldolgozása és megfelelő formában való továbbítása a feldolgozó szerverek számára. A feldolgozó szerverek futtatják a kidolgozott algoritmusokat, majd meghozzák becslésüket azzal kapcsolatban, hogy mely tevékenység végezheti a felhasználó. A végső döntést e rész-döntések alapján hozzuk meg.

Mérés – adatgyűjtés

A megfelelő adatgyűjtési módszertan meghatározása esszenciális mind a modellezéshez, mind a későbbi működőképesség fenntartásához. Mivel a felhasználók számára rendkívül fontos a testreszabottság és a könnyű, valamint kényelmes használat, ezért nem csak az adatok legjobb minőségben való gyűjtését és továbbítását, hanem az erőforrások optimális kihasználását is célként tűztük ki.


A fejlesztett mobilalkalmazás működése során egy beépített algoritmus segítségével észleli a kis aktivitású időszakokat, és ekkor nem gyűjti az adatokat. Természetesen ez az

úgynevezett alvó üzemmód paraméterezhető, így az üzenetküldő szerverről konfiguráció segítségével bármikor állítható, hogy a mérés mikor fusson és álljon le. Az alvó üzemmód nemcsak az adatforgalmat, hanem az akkumulátorhasználatot is csökkenti.

A szenzoros adatok kinyerése a szenzor API-n (ApplicationProgrammingInterface) keresztül történik meg, majd oly módon kerül eltárolásra, amely a keretek között elérhető legkisebb méretet eredményezi. Ez a méretcsökkentés két részből áll, egyrészt az állomány méretre optimalizált átalakításából és kódolásából, másrészt a tömörítésből. A kapott állomány eredeti méretéhez képest nagyságrendileg 12%-ra sikerült a továbbítani kívánt állomány méretét csökkenteni. Ezen a csökkentési arányon felül az aktivitási aránytól függően még nagymértékben csökkenti a méretet az alvó üzemmód jelenléte. A mérni kívánt szenzorok köre szintén beállítható konfiguráció segítségével, az algoritmusfejlesztés során viszont leginkább az akcelerométer, GPS és giroszkóp került fókuszba.

A gyűjtött adatok adatszerver felé való továbbítása így megtörténhet, és a felhasználót a lehető legkisebb mértékben zavarjuk az adatküldéssel. A rendszer további szakaszai függetlenek a felhasználótól, ígyműködésével nem befolyásoljuk őt.

A kapott adatokat az adatszerver előfeldolgozó modulja kapja meg, mely az adatok feldolgozható formába hozatalát végzi. Ez magában foglalja a kitömörítést, a dekódolást, és olyan eljárások futtatását, melyek a később futó algoritmusok számára szükségesek. Ilyen az adatsorok összefüggővé tétele, dimenziócsökkentés vagy az interpoláció, mellyel a szenzor API pontatlanságait (adott frekvenciájú mintavételezésben fellelhető apróbb eltéréseket) kiküszöbölhetjük. A mobiltelefonos adatgyűjtés egyik legproblémásabb pontja az, hogy az egyes mobiltelefon-gyártók más minőségű és gyártmányú szenzorokat építenek be telefonjaikba, melyek más skálán mérhetnek, de pontosságuk szinte biztosan eltér egymástól. A 2. ábrán a pontosságbeli különbségeket szemléltetjük.



2. ábra: Mobiltelefonokba épített szenzorok működésének összehasonlítása (saját szerkesztés)

A 2. ábrán a tesztelésbe bevont mobiltelefonok akcelerométer, vagyis gyorsulásmérő szenzorának időszora szerepel. Minden telefon nyugalmi helyzetben van, de láthatóan középértékben és szórásban is eltérnek egymástól. Ezeket az eltéréseket az algoritmusoknak tudniuk kell kezelni. A 2. ábrán csak Android operációs rendszerű készülékek által szolgáltatott adatok szerepelnek, az iOS operációs rendszerrel mért eredmények ettől nagymértékben eltérnek a különböző mértékegységben történő adatrögzítés miatt. Az Android operációs rendszerrel rendelkező telefonok ugyanis m/s^2 mértékegységet használnak, az iOS pedig a gravitáció egységében, g-ben rögzít, vagyis ebben az esetben az 1g jelenti a $9.81 m/s^2$ -et. A mérési skálák egyesítése emiatt fontos részfeladat az előfeldolgozás során.

Algoritmusfejlesztés

Cselekvések

Az algoritmusok fejlesztésének első lépése annak kitűzése, hogy mely cselekvések kerüljenek megkülönböztetésre. A szakirodalomban rengeteg különböző esetet vizsgáltak, az előzőekben már hivatkozott módokon, melyek között pusztán a lépésszámlálástól kezdve az eszköz elhelyezkedését is megkülönböztetni kívánó esetek megtalálhatóak. Saját kutatásunkban azt tűztük ki célul, hogy a telefon elhelyezkedésétől függetlenül próbáljuk meghatározni a cselekvést, vagyis azokat a mintázatokat keressük, melyek közösek az összes elhelyezkedés tekintetében. Példaként vegyünk a nadrágzsebben és a táskában elhelyezett készüléket. Vannak eltérések a két eset között, mivel az első esetben a testhez szorítva, a második esetben pedig részben a testtől függetlenül mozog a készülék. Viszont a mozgás alapmintázatának mindkét esetben meg kell egyeznie, és ezt a mintát keressük algoritmusainkkal, figyelmen kívül hagyva a zajt, mely az elhelyezkedésből adódik.

A kutatás során a referencia adatok gyűjtése a lehető legnagyobb bontásban történt, azonban a cselekvések közötti hasonlóságok miatt a cselekvések egy része összevonásra került. A következő cselekvéslistáról készültek referencia-mérések:

- Eszköz nélküli mozgás
 - nyugalmi helyzet (asztalon és a felhasználónál)
 - séta
 - futás
 - lépcsőzés (lefelé és felfelé irányban)
 - telefon használat (telefonálás és képernyőhasználat)
- Járműveken utazás
 - busz
 - metró
 - villamos
 - trolibusz
 - vonat
 - hév
- Egyéb
 - lift (lefelé és felfelé irányban)
 - mozgólépcső (lefelé és felfelé irányban)

Szimultán futó algoritmusok

Az előfeldolgozás után a rendszer több ágra bomlik, mely ágakon a fejlesztett algoritmusok párhuzamosan futnak, azzal a céllal, hogy a legjobb eredményt kaphassuk végeredményként. Minden algoritmusnak vannak erősségei és gyengeségei, melyek azt okoznák, hogy egyenként nem lennének elegendőek, viszont egymást támogatva-javítva robosztus rendszert kaphatunk.

Példaként említve egy algoritmusunk a GPS felhasználására épül, mely nagymértékben képes javítani a többi algoritmus eredményét, viszont egyrészt a felhasználónak be

kell kapcsolnia a helymeghatározást a telefonján, másrészt beltérben még bekapcsolt állapotban sem elérhetőek az adatok. Ezért ezt az algoritmust csak kiegészítésként használhatjuk, algoritmusaink alapja leginkább az akcelerométer.

Cselekvések hasonlóságai

A 2. táblázatban, illetve a 3. táblázatban látható egy-egy algoritmus számítási módszere, amelyek alapján megfigyelhető, hogy a kiválasztott alapcselekvések között mekkora hasonlóság van a főbb cselekvések esetében.

	busz	lépcső	lift	metró	nyugalom	séta	telefonhasználat	villamos	vonat
busz	0,91	0,67	0,25	0,70	0,31	0,66	0,71	0,54	0,65
lépcső	0,67	0,95	0,36	0,46	0,51	0,95	0,43	0,39	0,46
lift	0,25	0,36	0,89	0,45	0,77	0,40	0,06	0,62	0,43
metró	0,70	0,46	0,45	0,77	0,44	0,47	0,58	0,66	0,70
nyugalom	0,31	0,51	0,77	0,44	0,82	0,55	0,12	0,56	0,43
séta	0,66	0,95	0,40	0,47	0,55	0,97	0,43	0,41	0,48
telefonhasználat	0,71	0,43	0,06	0,58	0,12	0,43	0,80	0,38	0,59
villamos	0,54	0,39	0,62	0,66	0,56	0,41	0,38	0,70	0,63
vonat	0,65	0,46	0,43	0,70	0,43	0,48	0,59	0,63	0,82

2. táblázat: Alapcselekvések hasonlóságai a szenzoradatok alapján (saját szerkesztés)

A 2. táblázat hasonlósági mérőszámokat tartalmaz, az értékek elméleti minimuma -1 , elméleti maximuma pedig teljes hasonlóság esetén 1 . A főatlóban látható az egyes azonos cselekvések közötti átlagos távolság, míg a mátrix többi értéke a cselekvések közötti távolságot reprezentálja. Érdeemes megfigyelni a séta és lépcsőzés közötti nagyon erős hasonlóságot, ami abból adódik, hogy a lépcsőzés is lépésekből áll. Érdekes, hogy az egyes felhasználók közötti mozgásbeli különbségek akkorák, hogy a két cselekvés szinte egybemosódik. Egyedül a nagyobb amplitúdó különbözteti meg ezt a két cselekvést, melyet ez az algoritmus kevésbé mutat ki. Felfigyelhetünk a lift és a nyugalom hasonlóságára is, mely abból adódik, hogy a lift a kezdeti gyorsulást és a záró lassulást kivéve alapvetően egyenes vonalú egyenletes mozgást végez, mely a gyorsulásmérő adataiban teljesen egyezik a teljes nyugalmi helyzettel. A nyugalmi helyzetben és az egyenes vonalú egyenletes mozgás esetében is zérus a gyorsulás értéke.

	nyugalom	séta	lépcső le	lépcső fel	busz	metró	villamos	lift le	mozgó- lépcső fel	vonat
nyugalom	0,00	4,42	4,22	4,49	0,39	0,49	0,60	0,38	0,25	0,22
séta	4,42	0,00	2,46	2,80	4,10	4,02	4,43	4,18	4,28	4,23
lépcső le	4,22	2,46	0,00	2,50	3,94	3,82	3,88	3,97	4,07	4,05
lépcső fel	4,49	2,80	2,50	0,00	4,20	4,10	4,40	4,28	4,63	4,32
busz	0,39	4,10	3,94	4,20	0,00	0,27	0,35	0,33	0,24	0,24
metró	0,49	4,02	3,82	4,10	0,27	0,00	0,38	0,32	0,33	0,32
villamos	0,60	4,43	3,88	4,40	0,35	0,38	0,00	0,47	0,45	0,44
lift le	0,38	4,18	3,97	4,28	0,33	0,32	0,47	0,00	0,30	0,30
mozgó- lépcső fel	0,25	4,28	4,07	4,63	0,24	0,33	0,45	0,30	0,00	0,15
vonat	0,22	4,23	4,05	4,32	0,24	0,32	0,44	0,30	0,15	0,00

3. táblázat: Alapcselekvések távolságai egy-egy referencia cselekvés között (saját szerkesztés)

A 3. táblázat már nem hasonlóságokat mutat, hanem távolságokat egy-egy referencia cselekvés között, ezért láthatóak a főatlóban a zérus értékek – itt is azt figyelhetjük meg, hogy vannak erősebb hasonlósági csoportok a cselekvések között, illetve ismét a séta lépcsőzéssel vett hasonlósága, valamint a járműveken mért adatok közötti hasonlóságok láthatók. Ez az algoritmus viszont az előzőhöz képest láthatóan erősebben meg tudja különböztetni a liftezést a nyugalomtól, ezért fontos az algoritmusok kombinációja.

A robosztusság elérése érdekében nagymintás adatgyűjtéssel is támogattuk a fejlesztést, melyben a felhasználók közötti különbségek feltérképezése volt a cél, valamint az, hogy a modellillesztéseknél gyakran elkövetett hiba, a túltanítás ne következhesen be. Ebben a modellezési esetben kifejezetten nagy gond lehet, ha az algoritmus rátanul egyetlen felhasználó mozgására, és ebből próbál meg következtetni mások mozgására, akik lassabban sétálnak. Vagy éppen más tömegközlekedési eszközökkel járnak, melyek mintázatai az első felhasználónál nem találhatók meg, és ezért nem lennének képesek felismerni ezeket. Mivel rendszerünkben nem az a cél, hogy két cselekvésformát laborkörülmények között megkülönböztessünk egymástól, ezért alkalmaztuk két hullámban 80-100 felhasználó bevonását a kutatásba mindennapi körülmények között.

A rendszer a végső tippeket az adatfájlok beérkezésétől számítva 2–4 perc alatt képes megadni, és skálázható a felhasználók számától függően. A tippek pontossága a visszamérés alapján (mely egy másfél órás városi közlekedés és cselekvés-sorozat kis mintán történő elvégzését tartalmazta) 67%-os pontosságú volt.

Az adatgyűjtés tapasztalatai

A nagymintás adatgyűjtés során egy kutatási panelből kerültek kiválasztásra és meghívásra a paneltagok. A válaszadási arány az első adatgyűjtés alatt, mely még kizárólag Android operációs rendszerrel rendelkező felhasználók között történt a kutatás jellege miatt rendkívül alacsony volt. 5309 meghívó került kiküldésre, melyből 657 fő kezdte meg a szűrőkérdőív kitöltését, és 82 felhasználó regisztrált egy alkalmazás letöltésével a kutatásba. Ez azt jelenti, hogy minden 8. ember foglalkozott a témával, közülük pedig ugyancsak minden 8. ember volt alkalmas a kutatásra. Az alkalmasság szűrése legnagyobb részben az alapján történt, hogy hajlandó-e a felhasználó vállalni a kutatás feltételeit. A telefon mozgás-adatainak gyűjtése ugyanis zavarhat néhány felhasználót, kiemelten fontosnak tartottuk, hogy ne okozzunk ilyen jellegű problémát, és a kutatásban részt vevők teljesen tisztában legyenek azzal, hogy miként tervezzük adataikat felhasználni. Nem meglepő az ilyen jellegű kutatásokkal szembeni bizalmatlanság, a személyes információk védelme és „Nagy Testvér” elől való elrejtőzés igénye miatt. Szerencsére az igénybe vett kutatási panel tagok között él egy olyan attitűd is, mely arra ösztönzi az egyéneket, hogy segítsék a kutatókat, előrébb mozdítsák ezzel világunk megismerését, és a véleményüket is szeretnék elmondani a tudományos eredmények előremozdítása érdekében. A kutatás során folytatott kommunikáció alapján is ez látszódott, többen érdeklődtek a kutatás sikere iránt, és kívántak sok sikert, vagy olyan információkat közöltek, mellyel a rendszer működésének gyenge pontjait igyekeztek feltérképezni.

Érdekesség rejlik a kutatásban részt vevők arányának, és a kutatás időpontjának összefüggésében is. A fent említett első hullám 2015. augusztus hónapban folyt, míg a második hullám 2016. februárban. Ez a hullám kissé más volt, megtörtént az előző hullám résztvevőinek meghívása is, ahol 50%-os volt a részvételi arány. Ezen felül viszont csak 1858 meghívó került a többi felhasználó között kiküldésre, melyből 316-an kezdtek el a szűrőkérdőívet, és 94-en regisztráltak is, melyből 52-en az új felhasználók közül. Látszik, hogy az újonnan meghívottak közül már minden 6. felhasználó kitöltötte a kérdőívet, ami sokkal jobb arányt jelent. Emellett a regisztrációs arány a kitöltők között 16,5% volt februárban, szemben az előző hullám 12%-ával. Ez a második arány részben az új iOS platform bevezetéséből is adódik, de az operációs rendszer penetráció önmagában nem kellene ekkora változást okozzon.

Konklúzió

Cikkünkben egy olyan rendszert mutattunk be, mely a mozgásfelismerést a lehető legtermészetesebb formájában és a lehető legegyszerűbben elérhető eszközökkel képes véghezvinni. A kutatás során arra jutottunk, hogy érdemes több egymást támogató algoritmust kialakítani, mellyel a cselekvésfelismerés erősebbé válhat. Azonban az is igaz, hogy a laborkörülményekhez, és az egyszerűbb, néhány cselekvést egymástól megkülönböztetni kívánó modellekhez képest a statisztikai teljesítmény természetesen csökken. Ahogyan a rendszerben egyre nagyobb rugalmasságot engedélyezünk, úgy csökken a pontosság, ám azt sem szabad elfelejteni, hogy a cselekvések összevonásával vagy a rugalmasság csökkentésével ez a rendszer is pontosabbá válik.

A kutatás során a cikk elején említett kihívásokra sikeresen válaszoltunk, megteremtettük az egyensúlyt az univerzalitásra való törekvés és a pontosság között, és egy olyan rendszert hoztunk létre, mely egyszerűen, bárki számára használható és megfelelően gyors válaszidővel rendelkezik. A további finomhangolás folyamatban van.

Irodalom

- Cruz-Silva, Nuno, João Mendes-Moreira, Paulo Menezes, „Features Selection for Human Activity Recognition with iPhone Inertial Sensors”, *Portuguese Conference on Artificial Intelligence*, 2013. <https://repositorio-aberto.up.pt/handle/10216/76074>
- Das, Sauvik, LaToya Green, Beatrice Perez, Michael Murphy, „Detecting User Activities using the Accelerometer on Android Smartphones”, 2010. https://www.truststc.org/reu/10/Reports/Das-GreenPerezMurphy_Paper.pdf
- Dernbach, Stefan, Barnan Das, Narayanan C. Krishnan, „Simple and Complex Activity Recognition Through Smart Phones”, *Proceedings of the Eighth International Conference on Intelligent Environments*, IEEE Computer Society, Washington DC, 2012, pp. 214-221. <http://dx.doi.org/10.1109/IE.2012.39>
- Freeman, Chris, Francisco Louca „The Emergence of a New Techno-Economic Paradigm: The Age of Information and Communication Technology (ICT)”, in *As Time Goes By – From the Industrial Revolutions to the Information Revolution*, Oxford University Press, 2002, pp. 318-324. <http://dx.doi.org/10.1093/0199251053.003.0009>
- Jayalath, Sampath, NimsiriAbhayasinghe, Iain Murray, „A Gyroscope Based Accurate Pedometer Algorithm”, in *Proceedings of the 4th international Conference on Indoor Positioning and Indoor Navigation*, 2013, pp. 510-513. http://espace.library.curtin.edu.au/R?func=dbin-jump-full&local_base=gen01-era02&object_id=195204
- Khan, Asjad M., Young Kwan Lee, Sung-young Lee, Thomas S. Kim, „Human Activity Recognition via An Accelerometer-Enabled-Smartphone Using Kernel Discriminant Analysis”, *5th International Conference on Future Information Technology (FutureTech)*, 2010. <http://dx.doi.org/10.1109/FUTURETECH.2010.5482729>
- Kwapisz, Jennifer R., Gary M. Weiss, Samuel A. Moore, „Activity Recognition using Cell Phone Accelerometers”, *ACM SIGKDD Explorations Newsletter*, 12 (2), 2010, pp. 74-82. <http://dx.doi.org/10.1145/1964897.1964918>
- Naqvi, NajmeZehra, Dr.Ashwani Kumar, Aanchal Chauhan, KritkaSahni, „Step Counting Using Smartphone-Based Accelerometer”, *International Journal on Computer Science and Engineering*, 4(3), 2012, pp. 675–681. <http://www.enggjournals.com/ijcse/doc/IJCSE12-04-05-266.pdf>
- Shin, Jaewan, Dongkyoo Shin, Dongil Shin, Sungmin Her, Soohan Kim, Myungsoo Lee, „Human Movement Detection Algorithm Using 3-Axis Accelerometer Sensor Based on Low-Power Management Scheme for Mobile Health Care System”, in *GPC'10 Proceedings of the 5th international conference on Advances in Grid and Pervasive Computing*, 2010, pp. 81-90. http://dx.doi.org/10.1007/978-3-642-13067-0_12
- Siirtola, Pekka, JuhaRöning, „Recognizing Human Activities Userindependently on Smartphones Based on Accelerometer Data”, in *International Journal of Interactive Multimedia and Artificial Intelligence*, 1(5), 2012, pp. 38–45. <http://dx.doi.org/10.9781/ijimai.2012.155>
- da Silva, Joana Raquel Cerqueira, „*Smartphone Based Human Activity Prediction*”, M.S. thesis, Faculdade de Engenharia, Universidade do Porto, Porto, 2013. <https://repositorio-aberto.up.pt/handle/10216/67649>

- Tomlein, Michal, PavolBielik, Peter Krátky, Stefan Mitrík, Michal Barla, MáriaBieliková. „Advanced Pedometer for Smartphone-based Activity Tracking”, in *Proceedings of the International Conference on Health Informatics*, 2012, pp. 401-404. <http://dx.doi.org/10.5220/0003786704010404>
- Yang, Che-Chang, Yeh-Liang Hsu „Development of a wearable motion detector for telemonitoring and real-time identification of physical activity”, *Telemed. J. E. Health*, 2009,15, pp. 62-72. <http://dx.doi.org/10.1089/tmj.2008.0060>

Sándor Zsófia 2009-ben a Corvinus Egyetem Gazdaságmatematikai elemző közgazdász szakának matematikai közgazdaságtan szakirányán szerzett diplomát. 2007-ben kezdte karrierjét adatbányász-ként a gyógyszeriparból kiindulva, majd a telekommunikációs és pénzügyi szektorban, végül a Kutatás Fejlesztési terület felé is nyitva. Szakmáját tekintve egész pályafutása során az adatbányászat témakörére koncentrált, kutatási területei közé tartoznak az adatbányászat új felhasználási lehetőségei.

Kis Gergely a Budapesti Corvinus Egyetem adjunktusa, az eNET Internetkutató és tanácsadó Kft. partnere, a Hírközlési és Informatikai Tudományos Egyesület (HTE) gazdasági bizottságának elnöke, az Infotér elnökségi tagja. Az infokommunikációs világon belül elektronikus hírközléssel, e-kereskedelemmel és IKT-hoz kötődő projektekkel foglalkozik. Kutatási érdeklődése kiterjed a piackutatási, elemzési módszertanokra, valamint az adatbányászatra is.