

Egyetemi doktori (PhD) értekezés tézisei

**Emberi tevékenység felismerés viselhető
szenzorok adataiból gépi-tanulással**

Sütő József

Témavezető: Dr. Oniga István



DEBRECENI EGYETEM

Informatikai Tudományok Doktori Iskola

Debrecen, 2018

Tartalomjegyzék

1.	A doktori értekezés szakirodalmi háttere és előzményei..	1
2.	Az értekezés új tudományos eredményei	8
2.1	Adatgyűjtők optimális kombinációja és az adatleírók használatának hatékonyság vizsgálata a WARD adatbázison 8	
2.2	Adatleírók kiválasztása.....	9
2.3	Módosított gyors Fourier transzformáció	10
2.4	Sekély neurális hálózatok hatékonyság elemzése ..	11
2.5	Összetett és mély neurális hálózatok hatékonyság elemzése	12
2.6	Offline eredmények tesztelése valós környezetben	13
1.	Background and aims of the dissertation.....	15
2.	New results	20
2.1	The optimal combination of data acquisition devices and efficiency investigation of feature usage in the WARD database	20
2.2	Feature selection.....	21
2.3	Modified fast Fourier transformation	22
2.4	Efficiency investigation of shallow neural networks 23	
2.5	Efficiency investigation of complex and deep neural networks	24
2.6	Comparison of offline and real-time results	25
	Irodalomjegyzék / Bibliography.....	27

A dolgozathoz kapcsolódó kiemelt publikációk / Related main publications	31
--	----

1. A doktori értekezés szakirodalmi háttere és előzményei

A tevékenység felismerés azon a feltételezésen alapul, hogy mozgás közben az emberi test jellegzetes szenzorjelet, más szóval mintát generál, amelyek digitális jelfeldolgozás és/vagy gépi-tanulás segítségével felismerhetők. A korábbi cikkek egy részében a kutatók összetett algoritmusokat definiáltak a tevékenység felismeréshez, amelyek főként digitális jelfeldolgozási technikákon alapult [1, 2]. Ezekben az esetekben, ha újabb cselekvéseket szeretnénk bevinni a modellbe, akkor ez a modell gyökeres megváltoztatását igényli. Feltehetően ebből a megfontolásból kiindulva a kutatók többsége a felismerést valamelyik jól ismert, „sekély”, paraméteres (naiv Bayes, előrecsatolt mesterséges neurális hálózatok) és nem paraméteres (k-legközelebbi szomszéd, döntési fa, support vector machine) gépi-tanuló módszerrel végezte [3].

Annak ellenére, hogy számos cikk született már ezen a témakörön belül az egyes gépi-tanuló algoritmusok egymással szembeni hatékonysága nem volt egyértelmű. Egyes szerzők azt állították, hogy a support vector machine hatékonyabban alkalmazható tevékenység felismerésre, mint más sekély módszerek [4]. Más kutatók a neurális hálózatokat találták a leghatékonyabb módszernek erre a feladatra [5]. Ezzel szemben néhány mérési eredmény azt mutatta, hogy a neurális hálózatok gyengébben teljesítenek, mint más tanuló algoritmusok [6].

A mély tanulás megjelenése számos gépi-tanulási problémában hozott áttöréseket. Az egyre mélyebb neurális hálózatok és az új típusú rétegek használatának ötlete egyre

népszerűbbé válik a kutatók körében. Ez annak is köszönhető, hogy ezek az új tanuló módszerek automatikusan egy magasabb szintű reprezentációt képeznek a nyers adathalmazból. Ebből adódóan a mély tanulás egy általánosabb megoldást nyújt, mivel az adatleírók (*features*) kinyerését automatizálja, szemben a sekély módszerekkel, ahol az adatleíró-kinyerése statikusan történik.

A mély algoritmusok már több kutatási területen felülmúlták a korábbi leghatékonyabb sekély módszereket, mint például a szövegelemzésben, a természetes nyelv feldolgozásban, de legfőképp az objektum felismerésben [7]. Ez nagymértékben motiválta a tevékenység felismerést végző kutatókat is az összetettebb módszerek használatára, mint például a konvolúciós neurális hálózatok, amely a legáltalánosabban elterjedt, mély algoritmus lett ebben a kutatási témában. A mély tanulást támogatók köre azt állította, hogy a statikus adatleíró-kinyerés helyettesíthető a konvolúciós rétegekkel. Mivel ez a módszer nem igényli a statikus adat előfeldolgozást, ezért a használata is kényelmesebb. Ezen felül, a skálafüggetlenség és a térbeli kapcsolatok detektálása tovább növelte népszerűségüket.

Mindezek ellenére a mély algoritmusok hatékonysága a sekély módszerekkel szemben nem egyértelmű a cselekvés felismerés témakörén belül. Néhány tanulmány jól tükrözi ezt a bizonytalanságot. Egy korábbi cikkben a szerzők összehasonlították a konvolúciós háló (CNN), véletlen erdő (RF), döntési fa (DT), naiv Bayes, k-legközelebbi szomszéd (kNN) és a support vector machine (SVM) algoritmusok hatékonyságát két adatbázison és a méréseik alapján, a CNN és az RF felismerési arányai között a különbség meglehetősen csekély volt [8]. Egy másik cikk eredményei is azt mutatták, hogy a hatékonyságbeli eltérés a CNN, SVM, és a KNN között

minimális [9]. Végül egy harmadik cikk mérési eredményei alapján is a CNN (egyetlen konvolúciós réteggel) csak egy kevéssel tűnt hatékonyabbnak a sekély neurális hálózattal (ANN) szemben [10].

Annak érdekében, hogy a gépi-tanuló algoritmusokkal kapcsolatos bizonytalanságot szemléltessem, az 1. táblázatba összegyűjtöttem azokat az ismertebb cikkeket, ahol valamilyen tanuló algoritmust használnak a cselekvések felismeréséhez. Ahogy azt a táblázat is mutatja, az egyes kutatók eltérő módszerekkel próbálják meg felismerni a cselekvéseket. Szerencsére a szakirodalomban már található néhány cikk, amely leszűkíti a sekély algoritmusok körét. A [11, 12] tanulmányok eredményei alapján az ANN és a kNN bizonyult a leghatékonyabb sekély módszernek az emberi tevékenység felismerésre. Valójában az ANN esetében ez az eredmény nem is olyan meglepő, mivel elméletileg az ANN komplexebb döntési határokat képes generálni az n -dimenziós térben, mint más sekély technikák. Ez egyúttal azt a kérdést is felveti, hogy mi lehet az oka a korábbi eltérő eredményeknek?

Az imént ismertetett bizonytalanság motivált bennünket arra, hogy megvizsgáljunk különböző neurális hálózati architektúrák hatékonyságát eltérő rétegszámmal és bemenő adattal. Ezen felül, a korábbi tanulmányokban, ahol ANN-t használtak tanuló algoritmusként, az úgynevezett *hiperparaméterek* a szerzők tapasztalatain alapultak vagy egy szűk rácson végzett keresésből származtak [4, 6, 12, 13, 14]. Azonban ez a megközelítés a legtöbb esetben nem megbízható. Továbbá, az eddigi ismereteink azt mutatták, hogy a neurális háló együttesek (*ensemble*) és a bináris neurális hálózatok modellje nem volt kellőképpen tesztelve a cselekvés felismerésben, ezért ezeknek a módszereknek a vizsgálatát is elvégeztük.

A tevékenység felismerés kezdeti szakaszában, az egyes kutatók és kutató csoportok saját adathalmazokat gyűjtöttek össze, amelyek nyilvánosan nem elérhetőek. Ez megfigyelhető a 1. táblázat adatai alapján is. Ezekben az esetekben az eredmények összehasonlítása nagyon nehéz, mivel a kutatók eltérő adathalmazokat használtak, valamint a legtöbb esetben az elvégzett cselekvések is többé-kevésbé eltérőek voltak. Később a modern viselhető szenzorok nagymértékű elterjedésének köszönhetően egyre több nyilvános adatbázis lett elérhető a kutatók számára. Napjainkban több különböző adathalmaz is szabadon felhasználható köztük az OPPORTUNITY, PAMAP2, Skoda, WARD, stb. adathalmazok a legismertebbek [15, 16]. Ezeknek az adatbázisoknak a használata jó lehetőséget biztosít az eltérő cselekvés felismerési technikák minőségi összehasonlítására és elemzésére.

Annak érdekében, hogy az eredményeink összehasonlíthatóak legyenek mások munkáival, sok esetben mi is nyilvános adatbázisokat használtunk adatforrásként. Az általunk felhasznált adatbázisok kiválasztásakor több tényező is fontos szerepet játszott. Olyan adatbázisokon akartunk dolgozni, amelyek eltérő számú és típusú adatgyűjtő eszközzel lettek begyűjtve, többnyire hasonló cselekvéseket tartalmaznak, és elegendő referencia kapcsolódik hozzájuk. Ezek alapján munkánk tetemes része két nyilvános adatbázison folyt. Ezek közül az első a *wearable action recognition database (WARD)*¹, amelyet a Berkeley Egyetem kutatói gyűjtöttek össze, az osztályozó algoritmusok hatékonyságának tesztelése céljából. A második adatbázis az

¹ <https://people.eecs.berkeley.edu/~yang/software/WAR/>

UCI machine learning repository² egyik legtöbbet letöltött adathalmaza, amely 30 résztvevő adatait tartalmazza, akik 6 általános cselekvést végeztek (HAPT). Mindkét adatbázis jól ismert a cselekvés felismeréssel foglalkozó kutatói közösség körében és számos korábbi kutatásban használták őket adatforrásként. Éppen ezért már néhány sekély és mély tanuló algoritmust is teszteltek mindkét adathalmazon.

Annak ellenére, hogy egyre több cikk jelenik meg ebben a kutatási témakörben, néhány kérdés még nyitott volt. Ezek közül az egyik legfontosabb, hogy melyik adatleíró halmaz képes maximalizálni a tanuló algoritmus hatékonyságát? A korábbi cikkekben, az eltérő szerzők különböző adatleírókat használtak főként az idő és frekvenciatartományból, mivel egy általánosan elfogadott adatleíró halmaz nem létezik a szakirodalomban [3]. Ezzel szemben a kutatók egy kisebb csoportja a hullám transzformációt választotta adatleíró információ kinyerésre, a nyers, időtérbeli adathalmazból [17]. Ezek alapján fontosnak tartottuk egy tanulmány elvégzését, amelyben összegyűjtjük a legnépszerűbb adatleíró-kinyerési módszereket a szakirodalomból, majd ezt követően a hatékonyságukat részben adatleíró-kiválasztó (*feature selection*) algoritmusok segítségével, részben a tanuló algoritmus hatékonyságának figyelésével vizsgáljuk meg. Ezen felül, arra is kerestük a választ, hogy létezik olyan általánosan használható adatleíró halmaz, amely a megfigyelt személytől függetlenül, általánosan és hatékonyan alkalmazható?

2

<http://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones>

Végül a kutatás lezárásaként, az saját és a korábbi „*offline*” eredmények alapján elkészítettünk egy Android alapú applikációt, aminek segítségével megvizsgáltuk, hogy a speciális környezetben összegyűjtött és offline módon kiértékelte eredmények mennyire állják meg a helyüket valós környezetben.

A modern okostelefonok használhatók úgy, mint egy komplett cselekvés felismerő rendszer és már néhány kutató használt telefonokat a cselekvés felismeréshez. A többségük a telefont adatgyűjtő eszközként használta, míg az adatok kiértékelése elkülönítetten történt valamilyen jól ismert matematikai vagy adatbányász szoftverrel, mint például a Weka, Python vagy Matlab [5, 18]. Ma már a legtöbb ember rendelkezik okostelefonnal, ami elegendő számítási kapacitást és üzemidőt biztosít. Éppen ezért ezek az eszközök egy új lehetőséget nyújtanak az emberi tevékenység felismerésre. Az okos eszközök adta előnyök, mint a magas szintű programozás, különböző megjelenítési, kommunikációs és adattárolási lehetőségek, nagymértékben megkönnyítik és meggyorsítják a fejlesztés folyamatát. Ebből adódóan a valós idejű és az offline mérési eredmények összehasonlításához mi is egy okostelefont használtunk adatgyűjtőként és kiértékelőként egyaránt. Az adatbegyűjtést és kiértékelést végző applikációt, kizárólag ehhez a kutatáshoz fejlesztettük ki. Ismereteink szerint ez volt az első cikk az irodalomban, amely ilyen módon hasonlította össze az offline és a valós idejű mérési eredményeket.

1. táblázat. Leggyakrabban használt tanuló algoritmusok és felismerési arányaik

Tanuló algoritmus	Referencia	Adatforrás	Adatgyűjtésben résztvevő önkéntesek száma	Felismerési arány
kNN	[20]	nem nyilvános	5	98.0%
	[19]	nem nyilvános	20	97.0%
	[11]	nem nyilvános	8	99.7%
DT	[45]	nem nyilvános	10	97.3%
	[5]	nem nyilvános	6	92.8%
SVM	[23]	nyilvános	20	98.5%
	[24]	nyilvános	30	96.0%
	[4]	nem nyilvános	12	90.2%
ANN	[14]	nem nyilvános	6	97.9%
	[13]	nem nyilvános	7	95.0%
	[12]	nem nyilvános	8	96.8%
CNN	[25]	nyilvános	20	95.9%
	[26]	nyilvános	30	95.2%
	[27]	nyilvános	30	95.8%

2. Az értekezés új tudományos eredményei

2.1 Adatgyűjtők optimális kombinációja és az adatleírók használatának hatékonyság vizsgálata a WARD adatbázison

A [J1] munkánknak több célkitűzése is volt. Az egyik az, hogy megvizsgáljuk különböző szenzor kombinációk hatékonyságát a WARD adatbázis 13 cselekvésének felismerésére. A második, az adatleírók nélküli és az adatleírókkal kibővített normalizált nyers adatok hatékonyság elemzése. Összesen 31 szenzor konfigurációt vizsgáltunk meg, ahol kétrétegű előrecsatolt mesterséges neurális hálózatot használtunk a cselekvések osztályozására. A neurális hálót Matlabban hoztuk létre az alapbeállítások használatával. A köztes rétegen *szigmoid* aktivációs függvényt használtunk, míg a kimeneti rétegen három különböző függvényt teszteltünk: lineáris, versengő és küszöb (0.5 küszöbértékkel). Mind a 31 konfiguráció esetén a neurális hálót három különböző bemeneti adathalmazzal teszteltük, ahol az első esetben csak a normalizált nyers adatot használtuk, míg a második és harmadik esetben a nyers adathoz hozzávettünk egy, majd két adatleírót (jel nagyságterület és szórásnégyzet). Az így kapott eredmények a [J1] cikkben találhatóak és ennek alapján jött létre az 1. tézispont.

1. tézis: *A WARD adatbázis adatainak felhasználásával, méréseink során megmutattuk, hogy már két adatleíró felhasználásával a neurális háló felismerési aránya egyértelműen növelhető. Egy, két és öt adatgyűjtővel a legjobb felismerési arányok 87.88%, 95.51% és 99.18% voltak és*

ezekben az esetekben, az adatleírók bevonása 15.65%, 9% és 1.11%-os javulást hozott. Ennek alapján azt állapítottuk meg, hogy kevés adatgyűjtő eszköz használatakor az adatleírók alkalmazása jelentősen növeli a felismerési arányt, viszont az adatgyűjtők számának növelésével, az adatleírók pozitív hatása a felismerési arányra, egyre inkább csökken.

2.2 Adatleírók kiválasztása

Néha az adatleírók száma túl sok lehet, amelyek közül néhány szükségtelen. Az adatleíró kiválasztás során megpróbáljuk meghatározni a kiinduló adatleírók halmazának azt a részhalmazát, amely nem tartalmaz redundanciát és irreleváns adatleírókat. A kiválasztás folyamata a legtöbb esetben az adatleíró halmazok eloszlásán vagy korrelációs kapcsolataik alapján zajlik. Annak ellenére, hogy elég sok tanulmány született a tevékenység felismerésben, azoknak a tanulmányoknak a száma, ahol kiválasztó algoritmussal vizsgálták az adatleírók hasznosságát, meglehetősen kevés. Ez volt a motivációja a [J2]-es munkánknak, amelyben 8 szűrő és egy keretező algoritmussal választottunk ki adatleírókat, egy általunk összegyűjtött adatleíró halmazból. Az így kapott adatleírók részhalmazának a hatékonyságát, 3 tanuló algoritmuson teszteltük, a WARD adatbázis adatainak a felhasználásával. Mivel a szakirodalomban nincs általánosan elfogadott adatleíró halmaz, ezért ennek a tanulmánynak az elvégzése előtt összegyűjtöttük a mások által használt adatleíró-kinyerési módszereket a korábbi cikkekből. Ez a munkánk eredményezte a 2. tézispontot.

2. tézis: *A 8 szűrő és egy keretező algoritmussal végzett adatleíró kiválasztás eredményei, amit a WARD adatbázison kaptunk, azt mutatták, hogy nincs egy általánosan elfogadható adatleíró halmaz, amely az egyes személyektől függetlenül,*

hatékonyan alkalmazható lenne, mivel az egyes módszerek csak részben átfedő adateleíró részhalmazokat választottak ki a különböző személyekhez.

2.3 Módosított gyors Fourier transzformáció

Néhány adateleíró-kinyerése a frekvenciatartományban történik. Nyilvánvalóan ehhez az első lépés a frekvenciatartományba való áttérés, amit a gyors Fourier transzformáció (FFT) segítségével tehetünk meg. A radix-2 FFT és a transzformáció szorzófaktorainak vizsgálatakor észrevettük, hogy a szorzófaktorok közötti kapcsolatok felhasználásával, elegendő összesen az első $N/8 + 1$ szorzófaktor kiszámítása és tárolása. A [J3] cikkünkben ismertettük a fent bemutatott három összefüggést a szorzófaktorok között és itt világítottunk rá arra, hogy ezek egyszerűen beépíthetők egy radix-2 algoritmusba. Ezt felhasználva készítettünk egy függvényt a radix-2 FFT-hez, amely elvégzi a letárolt szorzófaktorok felhasználásával a további szorzófaktorok származtatását. Tehát, az általunk létrehozott módosítás azt jelenti, hogy kevesebb konstans szorzófaktor tárolására van szükség az FFT futtatása előtt, mivel ezek egymásból származtathatók. Viszont a transzformáció futtatásakor, a műveletek száma ez által nem csökken. Ennek alapján született meg a 3. tézispont.

3. tézis: *Létrehoztunk egy kiegészítő függvényt a radix-2-es gyors Fourier transzformáció algoritmushoz, aminek segítségével kihasználható a szorzófaktorok közötti mindhárom összefüggés. Ennek felhasználásával elegendő az első $N/8 + 1$ szorzófaktor kiszámítani és letárolni a transzformáció futtatása előtt, mert a többi szorzófaktor ebből származtatható. Ez gyakorlatilag azt jelenti, hogy kevesebb*

memóriaterületet kell lefoglalnunk az előre kiszámított szorzófaktoroknak.

2.4 Sekély neurális hálózatok hatékonyság elemzése

A tevékenység felismerés témakörében a neurális hálókkal kapcsolatos bizonytalanság, amit a bevezetőben ismertettem, arra ösztönzött minket, hogy egy átfogó tanulmány keretében megvizsgáljuk a különböző neurális hálózat alapú stratégiák hatékonyságát a mi problémakörünkön. A témakör aktuális állása alapján tipikusan három költség (vagy hiba) függvényt használnak eltérő aktivációs függvényekkel a köztes és a kimeneti szinteken. Ennek alapján a [J5]-ös cikkünkben három, azonos szinttel és neuronszámmal, viszont eltérő aktivációs és hibafüggvénnyel rendelkező neurális háló architektúrát teszteltünk véletlenszerűen kiválasztott hiperparaméterekkel és eltérő bemeneti adatokkal. A tanulmányban megvizsgáltuk a három eltérő architektúrával rendelkező neurális hálózat hatékonyságát kizárólag normalizált nyers adattal, a 4 leggyakoribb adatleíróval és végül az általunk összegyűjtött adatleíró halmazzal. A hálózatok legjobb eredményét 100 kísérlet elvégzése után választottuk ki, amelynek során a hálózatok kezdeti tanulási aránya, a tanulási arányt csökkentő faktor és a súlyok normalizálásának erőssége véletlenszerűen volt kiválasztva. Az itt kapott eredmények alapján fogalmazódott meg a 4. és 5. tézisponthoz.

4. tézis: *A három neurális háló architektúrával végzett méréseink alapján az egyes hálók legjobb felismerési arányai a WARD adatbázison 99.4%, 99.2% és 99.1% volt, míg a HAPT adatbázison 97%, 96.5% és 96.6%. Ennek alapján azt állapítottuk meg, hogy a három neurális háló architektúra teljesítménye csak minimálisan különbözik egymástól. Ezzel szemben a hálók hiper-paramétereinek kombinációja*

lényegesen befolyásolja a háló teljesítményét, mivel ugyan az a neurális háló egy helyesen és helytelenül kiválasztott paraméter kombinációval több, mint 80%-os felismerési arány eltérést is produkálhat.

5. tézis: *A két réteggel rendelkező sekély neurális hálókkal végzett kísérleteink során, amikor az általunk összegyűjtött összes adatleíróit felhasználtuk a neurális hálózat bemeneteként, a legmagasabb felismerési arányok a WARD és a HAPT adatbázisokon 99.4% és 97% volt. Ezek az eredmények, a WARD esetében 0.9%-kal, míg a HAPT esetében 0.6%-al jobb, mint a korábban mért legmagasabb felismerési arányok a két adatbázison. Ez azt mutatja, hogy a hiper-paraméter kereséssel és az általunk összegyűjtött, különböző idő és frekvenciaterületi adatleírók alkalmazásával egy kétszintes, sekély neurális háló használata optimális választás emberi tevékenység felismerésre.*

2.5 Összetett és mély neurális hálózatok hatékonyság elemzése

A sekély, kétrétegű neurális hálózatok után, a [J6]-os munkánkban megvizsgáltuk egy kibővített, sekély neurális hálózatnak, sekély neurális hálók együttesének, bináris neurális hálózatoknak és két konvolúciós hálónak a hatékonyságát a WARD és HAPT adatbázisokon. Az így kapott felismerési arányokat és tanítási időigényeket összehasonlítottuk a sekély neurális hálóval mért értékekkel és ennek az összehasonlításnak az eredmény adta a 6. tézispontot.

6. tézis: *Méréseink azt mutatták, hogy az általunk vizsgált két adatbázison a neurális háló együttesek, bináris neurális hálózatok és a konvolúciós hálók használata nem előnyösebb a sekély, kétszintű neurális hálózattal szemben, mivel ezeknek a*

komplexebb tanuló algoritmusoknak az alkalmazása vagy nem hozott felismerési arány növekedést, vagy csak 0.2%-os javulást eredményezett. Ezzel szemben a tanítási időigényük a sekély neurális hálózat többszöröse.

2.6 Offline eredmények tesztelése valós környezetben

A kutatásunk lezárásaként, az általunk és mások által kapott offline eredmények megbízhatóságát vizsgáltuk meg valós környezetben. Erre azért volt szükség, mivel az emberi cselekvés felismerés témakörében született eredmények túlnyomó többsége offline módon, valamilyen nyilvános adatbázison vagy saját készítésű adathalmazokon történt, ahol az adatok begyűjtése speciális környezetben zajlott. Ezek alapján nem rendelkezünk semmilyen információval arról, hogy a korábbi eredmények mennyire állják meg a helyüket valós környezetben. Ez motiválta a [J7]-es munkánkat, ahol 7 alapvető cselekvés felismerését végeztük valós-időben. Adatgyűjtőként egy okostelefont használtunk, mivel ez az eszköz magas szintű programozási környezetet, nagy számítási kapacitást, különböző megjelenítési, adattárolási és kommunikációs lehetőségeket biztosított számunkra. Az adatkiértékelés szintén a telefonon futott, amit egy általunk készített Android alapú applikáció végzett. Az applikációt és a tesztkörnyezet kialakítását (adatgyűjtő elhelyezése, mintavételi sebesség, ablakméret, stb.) a szakirodalom útmutatásai alapján végeztük. Az applikációban a felismerési arányokat két tanuló algoritmussal vizsgáltuk – k-legközelebbi szomszéd és sekély neurális hálózat. Az így kapott mérési eredményeinket összehasonlítva a korábbi offline eredményekkel született meg a 7. tézispont.

7. tézis: *Miután összehasonlítottuk az általunk kapott valós-idejű mérési eredményeket a korábbi offline mérési*

eredményekkel, azt tapasztaltuk, hogy a valós-idejű mérések során kisebb felismerési arányokat kaptunk. Erre két indokot találtunk. Egyrészt a valós-idejű adatoknak nagyobb a szórása, mint a speciális környezetben összegyűjtött adatoké. A korábban használt adathalmazok speciális környezetben lettek begyűjtve, ami homogénebb adathalmazt eredményezett, és ez nem fedi le a hétköznapi élet lehetséges élethelyzeteit. Másrészt függetlenül attól, hogy hol helyezzük el az adatgyűjtőnket, egyetlen adatgyűjtő használata esetén, az egyes elemi cselekvésekhez rögzített adathalmazok között átfedések keletkezhetnek, mivel az adatgyűjtőben lévő inerciális szenzorok, az eltérő cselekvéseknél, ugyan abban vagy hasonló pozícióban is lehetnek.

1. Background and aims of the dissertation

Human activity recognition (HAR) is based on the assumption that body movements generate characteristic sensor signal patterns which can be recognised with digital signal processing techniques or with machine learning (ML) algorithms. In the early stage of HAR, some researchers developed own activity recogniser algorithms which are based on digital processing techniques [1, 2]. Unfortunately the extension of these models requires significant modifications. Due to this drawback most scientists used well-known shallow techniques to the classification such as naïve Bayesian (NB), k-nearest neighbours (KNN), decision tree (DT), support vector machines (SVM) and artificial neural networks (ANN) [3].

One part of researches reached good results with ANN. For example, the authors of [5] are applied feed-forward ANNs for the classification and outperformed previous results on public datasets. However, Chernbumroong et al. claimed that the SVM is a better choice for activity classification than ANN [4]. Moreover in the work of Ponce et al. the ANN produced almost the worst performance [6].

The appearance of deep learning caused a great breakthrough in ML. The idea of using deep networks with new types of layers was very interesting to researchers because these techniques can automatically build high-level representations of the raw data. Thus deep learning offers a more generic solution because the feature construction process can be fully automated. The deeper techniques have been successfully applied to many different research fields and already

outperformed lots of state of the art shallow ML solutions in document analysis, natural language processing, and mainly in object recognition [7]. It motivated the HAR community to the usage of deep architectures such as convolutional neural networks (CNNs). CNN supporters claimed that the feature extraction property of the convolutional layers can substitute the hand-crafted feature extraction stage from shallow methods. Since CNN does not require feature extraction thus its usage is more convenient. In addition the scale invariance and the local dependency exploitation properties of those techniques further increased their popularity.

However, the efficiency of deep neural networks over simple ANNs in the HAR problem is not clear. The authors of [8] compared a CNN with random forest (RF), DT, NB, KNN and SVM on two databases and the recognition accuracy between RF and CNN was very small. In the article of Yang et al. the accuracy between CNN, SVM, and KNN was also small on two public datasets [9]. The results of [10] also showed that the recognition rate difference between the most effective CNN (with one convolutional layer) and ANN is not significant.

In order to illustrate the uncertainty in HAR, we collected several well-known reference works from the literature where machine learning algorithm was the classifier. Table 1 contains the list of collected papers. As Table 1 demonstrates, different authors used different shallow and deep ML algorithms for activity recognition. Fortunately some studies have shown that ANN and kNN are more efficient shallow methods than others for this purpose. A good comparison between shallow techniques can be found in [11, 12]. Actually in the case of ANN this result is not surprising because theoretically an ANN can generate more complex decision

boundaries in the n -dimensional feature space than other shallow techniques. It raises the question: What can be the reason for different results?

The above described uncertainties motivated us to investigate the efficiency of different ANN architectures with different hyper-parameters, number of layers, and input data. In previous studies where ANN was the classifier, the hyper-parameters are based on the author's experiences or came from a partial or narrow grid search [4, 6, 12, 13, 14]. However it is an unreliable choice. In addition, to the best of our knowledge more complex ANN models such as ANN ensembles and binary ANN classifiers have been poorly tested in the HAR problem.

At the beginning of HAR research, researchers tested ML algorithms on own datasets which are not public. Later, the widespread distribution of modern wearable sensors caused an impressive growth in the amount of publicly available, physical activity databases. Nowadays numerous public datasets are available for scientific HAR purposes, including the OPPORTUNITY, PAMAP2, Skoda, WARD, etc. datasets [15, 16]. The usage of such databases gives a good opportunity for qualitative comparison of classifier models. In order to our results can be verifiable we similarly used public databases in our works. We wanted to use different datasets which were acquired with different types and number of data collector devices, ensure different representations of data, contain similar and different activities, and exist enough previous works on theme. According to those criteria, two databases were used as data sources.

The first is the wearable action recognition database (WARD)³. It is a benchmark data set to the HAR research which has been collected at University of California, Berkeley. The second database has been downloaded from the UCI machine learning repository⁴ (HAPT). It was carried out by 30 volunteers who performed six daily activities. Both databases are well-known inside the HAR community and numerous researchers worked on them. Already the efficiency of several shallow and deep techniques was examined on both databases.

Although many articles have been presented in this topic, some questions are unanswered yet. In previous papers, different authors extracted different features especially from the time and frequency domains because a well-established feature group does not exist [3]. A small part of scientists used the wavelet transformation for feature extraction instead of time and frequency domains' features [17]. Therefore, we collected the most relevant feature extraction techniques from the literature and examined their efficiency with feature selection methods (8 filter and 1 wrapper algorithms) and according to the classifier performance. We tried to find an answer for the following question: Is there a general feature combination which similarly efficient independently of the person?

³ <https://people.eecs.berkeley.edu/~yang/software/WAR/>

⁴ <http://archive.ics.uci.edu/ml/datasets/Human+Activity+Recognition+Using+Smartphones>

Table 1
Previous recognition rates with machine learning methods in HAR

Classifier	References	Data source	Number of subjects	Recognition rate
kNN	[20]	not public	5	98.0%
	[19]	not public	20	97.0%
	[11]	not public	8	99.7%
DT	[45]	not public	10	97.3%
	[5]	not public	6	92.8%
SVM	[23]	public	20	98.5%
	[24]	public	30	96.0%
	[4]	not public	12	90.2%
ANN	[14]	not public	6	97.9%
	[13]	not public	7	95.0%
	[12]	not public	8	96.8%
CNN	[25]	public	20	95.9%
	[26]	public	30	95.2%
	[27]	public	30	95.8%

The current state of the art proposes numerous ML solutions to HAR but we do not have any useful information about their usability in a real-time application. Therefore, at the end of our work we investigated the efficiency and reliability of previous, promising offline results in real environment with a self-developed, Android-based application. Today's smartphones also can be used as a complete HAR system without any additional hardware components. Already several researchers

used phones for HAR. Most of them used the phone as a data acquisition device and the evaluation happened offline by mathematical or data mining tools such as Weka, Python and Matlab [5, 18]. Smartphones have some advantages unlike special purpose data acquisition devices. For instance, they provide high level programming environment with different visualization, data storage and communication capabilities. According to the previous reasons, in our study a smartphone acted in the sensor role and a self-developed, Android-based application performed the complete classification process which has been designed especially to this study according to the latest theoretical results. To the best of our knowledge, it was the first work which compares offline and online results in this manner.

2. New results

2.1 The optimal combination of data acquisition devices and efficiency investigation of feature usage in the WARD database

Our [J1] work had more goals. One of them is the efficiency investigation of different sensor combinations for the recognition of 13 activities in the WARD database. In addition we also investigated the influence of the usage of normalized raw data with and without features. Totally 31 combinations have been tested where the classifier algorithm was a two layers, feed-forward artificial neural network. The network has been created in Matlab with the default setup. In the hidden layer the activation function was sigmoid while on the output layer we tested three functions: linear, competitive and threshold (0.5 threshold value). The network has been tested with three different data sets in all configurations. At first the

normalized data has been used as the network input and then it has been extended with the signal magnitude area and later with the variance features. The results of this work give the 1st thesis point.

Thesis 1: *On the WARD database we showed that the usage of only two features can significantly increase the recognition rate of an artificial neural network. The highest recognition rates were 87.88%, 95.51% and 99.18% with one, two and five data acquisition devices respectively. In those cases the usage of features caused 15.65%, 9% and 1.11% improvements. This result shows that, with less number of sensors the usage of features has high effect on the recognition rate but increasing the number of data acquisition devices this positive effect is decreasing.*

2.2 Feature selection

In some cases, the number of features is rather huge and some features can be useless. Feature selection is the process of choosing a subset from the original features set according to the distribution of feature vectors or relations (e.g. correlation) between them. It is a frequently used dimensionality reduction technique. Essentially, the goal of all feature selection algorithms independently of their types is to find an appropriate hyperplane in the feature space where the class distributions are distinct. Although many articles have been presented in this topic, the number of articles which utilize feature selection algorithm in activity recognition is very small. It was the motivation of our [J2] study where we tried to select the most efficient features from an extended feature group with 8 filter and one wrapper feature selection algorithms. The efficiency of a selected feature set was

measured with 3 machine learning methods on the WARD database.

Thesis 2: *Our feature selection has been performed with 8 filter and 1 wrapper algorithms on the WARD database. According to its result we concluded that a generally applicable feature subset which can be efficient independently of the person does not exist because feature selection algorithms selected different or just partially overlapping feature subsets for different persons.*

2.3 Modified fast Fourier transformation

Some feature extraction happen in the frequency domain. In this case the first step is the conversion from time to frequency domain with the well-known fast Fourier transformation (FFT). During the investigation of FFT techniques and the relations between phase (twiddle) factors we observed that the conventional radix-2 FFT does not utilize all relations between phase factors. By the usage of each relation, it is enough to calculate and store the first $N/8 + 1$ factors. We created a function which performs the derivation and it was embedded into the radix-2 FFT. This observation has been presented in our [J3] article. To sum up, our modification means that less memory are necessary to the storage of phase factors because they can be derived from each other. However this modification does not reduce the number of operations in the transformation. It is the base of the 3rd thesis point.

Thesis 3: *We developed a supplementary function to the radix-2 fast Fourier transformation algorithm which derives the phase factors from each other. In this case it is enough to calculate and store the first $N/8 + 1$ phase factors because other factors can be derived from them. It means that less*

memory is necessary to the phase factor storage. However this modification does not reduce the number of operations in the transformation.

2.4 Efficiency investigation of shallow neural networks

The above described uncertainties motivated us to investigate the efficiency of different ANN architectures on both databases with different *hyper-parameters*, number of layers and input data. In spite of the relatively simple structure of a shallow ANN, more possible constructions exist in the literature. The state of the art proposes three cost (error) functions with different activation function combinations on the hidden and output layers. According to this three ANNs have been defined and tested with two layers, random hyper-parameters and different input data in our [J5] work. In the first step the classifier input was the normalized raw data. Thereafter the 4 most popular features have been used as the network input and finally an extended feature set has been applied. In each case 100 experiments have been performed on all ANN architectures. The results of this study give the 4th and 5th thesis points.

Thesis 4: *The highest recognition rates of the three artificial neural network architectures were 99.4%, 99.2% and 99.1% on the WARD database and 97%, 96.5% and 96.6% on the HAPT database. This shows that the performance of the three architectures is just slightly different. However the hyper-parameters in a neural network have more significant influence on the network performance than the architecture because the same network with good and bad parameter*

combinations can produce more than 80% recognition rate difference.

Thesis 5: *We measured 99.4% and 97% recognition rates on the WARD and HAPT databases with a shallow, two layers artificial neural network where the input was an extended feature set. Those results are 0.9% better in the case of WARD and 0.6% better in the case of HAPT than the previous best results on the two databases. It demonstrates that a shallow artificial neural network with random hyper-parameters and an extended feature set can be an optimal choice for human activity classification.*

2.5 Efficiency investigation of complex and deep neural networks

After the investigation of shallow neural networks with two layers we also examined the efficiency of an extended shallow network (with one additional layer), some neural network ensembles, binary neural network classifier groups and two convolutional networks on the WARD and HAPT databases in our [J6] study. Thereafter their performance has been compared with the shallow network's results and this comparison gives the 6th thesis point.

Thesis 6: *Our measurements on the two public databases showed that the usage of neural network ensembles, binary neural network groups or convolutional neural networks is not more advantageous than shallow neural networks because the more complex structure did not yield recognition rate growth or it caused only 0.2% improvement. However their training and decision times were much longer than in the case of shallow networks.*

2.6 Comparison of offline and real-time results

The current state of the art proposes numerous machine learning solutions to activity recognition but we do not have any useful information about their usability in a real-time application. Therefore, we investigated the efficiency and reliability of previous, promising offline results in real environment in our [J7] work. We tried to recognize 7 daily activities from one data acquisition device's signal. According to the advantages of modern smartphones (high level programming, high computational capacity, different visualization and communication possibilities), in our study a smartphone acted in the sensor role and an Android-base, self-developed application performed the complete classification process which has been designed especially to this study according to the latest theoretical results (sampling frequency, window size, etc.). In the application two learning algorithms have been implemented and used: k-nearest neighbour and artificial neural network. After the real-time tests, the comparison between our measurements and previous offline results gave the 7th thesis point.

Thesis 7: *After the comparison of our real-time and previous offline results we observed recognition rate difference between the real-time and offline approaches. We found two possible reasons for the difference. At first, the dispersion of feature vectors in real life situations is higher than in the data set which has been collected in special environment, under supervision. In the real-time case some feature vectors can be out of the decision boundary of their real class. In addition, with one data acquisition device, the inertial sensors can generate the same data to the elementary activities because*

they can be in similar positions independently of the sensor arrangement.

Irodalomjegyzék / Bibliography

- [1] Godfrey A, Bourke AK, O'laighin GM, Van de Ven P, Nelson J (2011) Activity classification using a single chest mounted tri-axial accelerometer, *Med. Eng. Phys.*, 33:1127-1135.
- [2] Lugade V, Fortune E, Morrow M, Kaufman K (2014) Validity of using tri-axial accelerometers to measure human movement – part I: posture and movement detection, *Med. Eng. Phys.*, 36:169-176.
- [3] Lara OD, Labrador MA (2013) A survey on human activity recognition using wearable sensors, *IEEE Commun. Surv. Tut.*, 15:1192-1209.
- [4] Chernbumroong S, Cang S, Atkins A, Yu H (2013) Elderly activities recognition and classification for applications in assisted living, *Expert Syst. Appl.*, 40:1662-1674.
- [5] Kilinc O, Dalzell A, Uluturk I, Uysal I (2015) Inertial based recognition of daily activities with ANNs and spectrotemporal features. In: *Proc. of the IEEE 14th International Conference on Machine Learning and Applications*, Miami, pp. 733-738.
- [6] Ponce H, Villasenor MLM, Pechuan LM (2016) A novel wearable sensor-based human activity recognition approach using artificial hydrocarbon networks, *Sensors*, 16:1-28.
- [7] Krizhevsky A, Sutskever I, Hinton GE (2012) ImageNet classification with deep convolutional neural networks. In: *Proc. of the Neural Information Processing Systems*, Nevada, pp. 1-9.
- [8] Gjoreski H, Bizjak J, Gjoreski M, Gams M. (2016) Comparing deep a classical machine learning methods for

- human activity recognition using wrist accelerometer. In: Proc. of the 25th International Joint Conference on Artificial Intelligence, New York, pp. 1-7.
- [9] Yang JB, Nguyen MN, San PP, Li XL, Krishnaswamy S (2015) Deep convolutional neural networks on multichannel time series for human activity recognition. In: Proc. of the 24th International Joint Conference on Artificial Intelligence, Buenos Aires, pp. 3995-4001.
- [10] Saez Y, Baldominos A, Isasi P (2016) A comparison study of classifier algorithms for cross-person physical activity recognition, *Sensors*, 17:66-92.
- [11] Rahman HA, Ge D, Faucheur AL, Prioux J, Carrault G (2017) Advanced classification of ambulatory activities using spectral density distances and heart rates. *Biomed. Signal Poces.*, 34:9-15.
- [12] Gao L, Bourke AK., Nelson J (2014) Evaluation of accelerometer based multi-sensor versus single sensor activity recognition systems, *Med. Eng. Phys.*, 36:779-785.
- [13] Yang JY, Wang JS, Chen YP (2008) Using acceleration measurements for activity recognition: an effective learning algorithm for constructing neural classifiers, *Pattern Recogn. Lett.*, 29:2213-2220.
- [14] Khan AM, Lee YK, Lee SY, Kim TS (2010) A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer, *IEEE T. Inf. Technol. B.*, 14:1166-1172.
- [15] Hammerla NY, Halloran S, Plots T (2016) Deep, convolutional, and recurrent models for human activity recognition using wearables. In: Proc. of the 25th International Joint Conference on Artificial Intelligence, New York, pp. 1533-1540.

- [16] Zheng M, Nguyen LT, Yu B, Mengshoel OJ, Zhu J, Wu P, Zhang J (2014) Convolutional neural networks for human activity recognition using mobile sensors. In: Proc. of the 6th International Conference on Mobile Computing, Applications and Services, Austin, pp. 197-205.
- [17] Ayachi FS, Nguyen HP, Pelletier CL, Goubault E, Boissy P, Duval C (2016) Wavelet-based algorithm for auto detection of daily living activities of older adults captured by multiple inertial measurement units (IMUs), *Physiol. Meas.*, 37:442-461.
- [18] Ayu MA, Ismail SA, Matin AFA, Montoro T (2012) A comparison study of classifier algorithms for mobile-phone's accelerometer based activity recognition. *Engineering Procedia*, 41:224-229.
- [19] Preece JS, Goulermas JY, Kenney LPJ, Howard D (2009) A comparison of feature extraction methods for classification of dynamic activities from accelerometer data. *IEEE T Bio-Med Eng.* 56:871-879.
- [20] Duarte F, Lourenco A, Abrantes A (2014) Classification of physical activities using a smart phone: evaluation study using multiple users *Procedia Technology* 17:239-247.
- [21] Kouris I, Koutsouis D (2013) Application of data mining techniques to efficiently monitor chronic diseases using wireless body area networks and smartphones. *Universal Journal of Biomedical Engineering* 1: 23-31
- [22] Maurer U, Smailagic A, Siewiorek DP, Deisher M (2006) Activity recognition and monitoring using multiple sensors on different body positions. In Proc. of the International Workshop on wearable and Implementable Body Sensor Networks. Cambridge, pp. 112-116.

- [23] Su B, Tang Q, Wang G, Sheng M (2016) The recognition of human daily activities with wearable motion sensor systems. In: *Transaction on Edutainment, XII*, Springer Berlin Heidelberg, pp 68-77.
- [24] Anguita D, Ghio A, Oneto L, Parra X, Reyes-Ortiz L (2013) A public domain dataset for human activity recognition using smartphones. In: *Proc. of 21th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*. Bruges, pp 437-442.
- [25] Sheng M, Jiang J, Su B, Tang Q, Yahya AA, Wang G (2016) Short-time activity recognition with wearable sensors using convolutional neural networks. In: *Proc. of the 15th ACM SIGGRAPH Conference on Virtual-Reality Continuum and Its Applications in Industry*, Zhuhai, pp. 413-416.
- [26] Jiang W, Yin Z (2015) Human activity recognition using wearable sensors by deep convolutional neural networks. In: *Proc. of the 23th ACM International Conference on Multimedia*, Brisbane, pp. 1307-1310.
- [27] Ronao CA, Cho SB (2016) Human activity recognition with smartphone sensors using deep learning neural networks, *Expert Syst. Appl.*, 59:235-244.

A dolgozathoz kapcsolódó kiemelt publikációk / Related main publications

- [J1] Oniga S, Suto J (2015) Optimal recognition method of human activities using artificial neural networks, Meas. Sci. Rev., 15:323-327. **IF.: 0.969.**
- [J2] Suto J, Oniga S, Pop-Sitar P (2017) Feature analysis to human activity recognition, Int. J. Comp. Commun., 12:116-130. **IF.: 1.374** (2016).
- [J3] Suto J, Oniga S (2015) A new relation between “twiddle factors” in the fast Fourier transformation. Elektron. Elektrotech., 21:56-59. **IF.: 0.389.**
- [J4] Oniga S, Suto J (2016) Activity recognition in adaptive assistive systems using artificial neural networks, Elektron. Elektrotech., 22:68-72. **IF.: 0.859.**
- [J5] Suto J, Oniga S (2017) Efficiency investigation of artificial neural networks in human activity recognition. J. Amb. Intel. Hum. Comp. <https://doi.org/10.1007/s12652-017-0513-5>. **IF.: 1.588** (2016).
- [J6] Suto J, Oniga S (2018) Efficiency investigation from shallow to deep neural network techniques in human activity recognition. Cogn. Syst. Res. Elbírálás alatt.
- [J7] Suto J, Oniga S, Lung C, Ioan O (2018) Comparison of offline and real-time human activity recognition results using machine learning techniques, Neural. Comput. Appl. <https://doi.org/10.1007/s00521-018-3437-x>. **IF.: 2.505** (2016).



Nyilvántartási szám: DEENK/91/2018.PL
Tárgy: PhD Publikációs Lista

Jelölt: Sütő József
Neptun kód: OD030V
Doktori Iskola: Informatikai Tudományok Doktori Iskola
MTMT azonosító: 10040166

A PhD értekezés alapjául szolgáló közlemények

Idegen nyelvű, külföldi könyvrészletek (4)

1. **Sütő, J.**, Oniga, I. L., Sitar, P. P.: Comparison of wrapper and filter feature selection algorithms on human activity recognition.
In: 2016 6th International Conference on Computers Communications & Control (ICCCC) : This edition of conference is dedicated to the 110th anniversary of Grigore C. Moisil (1906-1973) Romanian Mathematician, Computer Pioneer Award of IEEE Computer Society (1996 - posthumously). Eds.: I. Dzitac, F.G. Filip, M.J. Manolescu, IEEE, Piscataway, 124-129, 2016. ISBN: 9781509017355
2. **Sütő, J.**, Oniga, I. L., Hegyesi, G.: A simple fast Fourier transformation algorithm to microcontrollers and mini computers.
In: 18th International Conference on Intelligent Engineering Systems (INES), 2014 : proceedings. Ed.: A. Szakal, IEEE, [Piscataway], 61-65, 2014. ISBN: 9781479946150
3. Oniga, I. L., **Sütő, J.**: Human activity recognition using neural networks.
In: Proceedings of the 2014 15th International Carpathian Control Conference (ICCC). Ed.: Ivo Petrás, Igor Podlubny, Ján Kacur, Radim Farana, IEEE, Piscataway, 403-406, 2014. ISBN: 9781479935284
4. **Sütő, J.**, Oniga, I. L., Orha, I.: Microcontroller based health monitoring system.
In: Proceedings of the 2013 IEEE 19th International Symposium for Design and Technology in Electronic Packaging, IEEE, [Piscataway], 24-27, 2013. ISBN: 9781479915552

Idegen nyelvű tudományos közlemények hazai folyóiratban (1)

5. **Sütő, J.**, Oniga, I. L., Buchman, A.: Real time human activity monitoring.
Ann. Math. et Inf. 44, 187-196, 2015. ISSN: 1787-5021.





Idegen nyelvű tudományos közlemények külföldi folyóiratban (7)

6. **Sütő, J.**, Oniga, I. L., Lung, C., Orha, I.: Comparison of offline and real-time human activity recognition results using machine learning techniques.
Neural Comput. Appl. [Epub ahead of print], [1-14], 2018. ISSN: 0941-0643.
DOI: <http://dx.doi.org/10.1007/s00521-018-3437-x>
IF: 2.505 (2016)
7. **Sütő, J.**, Oniga, I. L.: Efficiency investigation of artificial neural networks in human activity recognition.
J. Ambient Intell. Humaniz. Comput. [Epub ahead of print], 1-12, 2017. ISSN: 1868-5137.
DOI: <http://dx.doi.org/10.1007/s12652-017-0513-5>
IF: 1.588 (2016)
8. **Sütő, J.**, Oniga, I. L., Pop-Sitar, P.: Feature analysis to human activity recognition.
Int. J. Comput. Commun. Control. 12 (1), 116-130, 2017. ISSN: 1841-9836.
IF: 1.374 (2016)
9. Oniga, I. L., **Sütő, J.**: Activity recognition in adaptive assistive systems using artificial neural networks.
Elektron. Elektrotech. 22 (1), 68-72, 2016. ISSN: 1392-1215.
DOI: <http://dx.doi.org/10.5755/j01.eee.22.1.14112>
IF: 0.859
10. **Sütő, J.**, Oniga, I. L.: A new relation between "Twiddle Factors" in the fast Fourier transformation.
Elektron. Elektrotech. 21 (4), 56-59, 2015. ISSN: 1392-1215.
DOI: <http://dx.doi.org/10.5755/j01.eee.21.4.12784>
IF: 0.389
11. Oniga, I. L., **Sütő, J.**: Optimal recognition method of human activities using artificial neural networks.
Meas. Sci. Rev. 15 (6), 323-327, 2015. ISSN: 1335-8871.
DOI: <http://dx.doi.org/10.1515/msr-2015-0044>
IF: 0.969
12. **Sütő, J.**, Oniga, I. L.: A new C++ implemented feed forward neural network simulator.
Carpathian J. Electr. Comp. Eng. 6 (2), 3-6, 2013. ISSN: 1844-9689.





További közlemények

Idegen nyelvű, külföldi könyvrészletek (3)

13. **Sütő, J., Oniga, I. L., Lung, C., Orha, I.:** Recognition rate difference between real-time and offline human activity recognition.
In: Internet of Things for the Global Community : Proceedings : July 10-12, 2017, Madeira-Portugal / Fernando Morgado-Dias, IEEE, Danvers, 13-18, 2017. ISBN: 9781538620649
14. **Sütő, J., Oniga, I. L.:** FPGA implemented reduced Ethernet MAC.
In: 4th IEEE International Conference on Cognitive Infocommunications CogInfoCom 2013 : Proceedings, December 2-5, 2013 Budapest, Hungary. Ed.: Péter Baranyi, IEEE, Danvers, 29-32, 2013. ISBN: 9781479915466
15. **Sütő, J., Máté, Á., Végh, J., Oniga, I. L.:** Developing a general purpose data collector framework for robots.
In: Carpathian Control Conference (ICCC), 2012 13th International, IEEE, Piscataway, 690-693, 2012.

Idegen nyelvű tudományos közlemények külföldi folyóiratban (2)

16. **Sütő, J., Oniga, I. L.:** Testing artificial neural network for hand gesture recognition.
Creat. Math. Inform. 22 (2), 223-228, 2013. ISSN: 1584-286X.
17. **Sütő, J., Oniga, I. L.:** Remote controlled data collector robot.
Carpathian J. Electr. Comp. Eng. 5 (1), 117-120, 2012. ISSN: 1844-9689.

Idegen nyelvű absztrakt kiadványok (1)

18. **Sütő, J., Oniga, I. L.:** Testing artificial neural network for gesture recognition.
In: Abstracts and Pre-Proceedings 9th International Conference on Applied Mathematics, Editura BiblioPhil, Baia Mare, 21-22, 2013. ISBN: 9786069309483

A közlő folyóiratok összesített impakt faktora: 7,684

A közlő folyóiratok összesített impakt faktora (az értekezés alapjául szolgáló közleményekre): 7,684

A DEENK a Jelölt által az IDEa Tudóstérbe feltöltött adatok bibliográfiai és tudományos mérései ellenőrzését a tudományos adatbázisok és a Journal Citation Reports Impact Factor lista alapján elvégezte.

Debrecen, 2018.04.18.

