

**SZEGEDI TUDOMÁNYEGYETEM**  
**TERMÉSZETTUDOMÁNYI ÉS INFORMATIKAI KAR**  
**MŰSZAKI INFORMATIKA TANSZÉK**

Informatika Doktori Iskola

**Új módszerek az inerciális és mágneses szenzorok  
alkalmazásában online mintafelismerési problémák  
esetén**

PhD értekezés tézisei

**Sarcevic Péter**

Témavezető

**Dr. Pletl Szilveszter**

Főiskolai tanár

SZEGED

2018



# 1 Bevezetés

A technológia fejlődésének köszönhetően a gyorsulásmérők, giroszkópok, és magnetométerek különböző alkalmazásokban való széleskörű felhasználása egyre elterjedtebbé vált.

A gyorsulásmérők mozgásérzékelők amelyek lineáris gyorsulást mérnek egy vagy több tengelyen. Egy objektum sebessége kiszámítható az objektum gyorsulásának idő szerinti integráljával. Újabb integrálással meghatározható a pozíció.

A giroszkópok forgásérzékelők amelyek szögsebesség mérésére szolgálnak, és egy vagy több (általában kettő vagy három) tengely körül érzékenyek. Az orientáció meghatározható a szögsebesség egyszeri integrálásával.

A magnetométerek passzív szenzorok amelyek a Föld mágneses terét képesek mérni egy adott pontban. Általában iránytűként használtak, tehát, képesek haladási irány becslésére [1].

A leggyakoribb felhasználása ezen szenzoroknak az inerciális navigációs rendszerek, amelyekben pozíció, orientáció, és sebesség meghatározásához szolgáltatnak információt [2]. A kis méretűeknek, illetve alacsony tömegűeknek, áruknak, és fogyasztásuknak köszönhetően mindhárom szenzor típus megtalálható számos fogyasztói elektronikákban, mint az okostelefonok, táblagépek, vagy okosórák.

Az inerciális és mágneses szenzorok széles körben használtak különböző mintafelismerési alkalmazásokban, mint az emberi mozgásfelismerés [3], gesztus felismerés [4], esések érzékelése és osztályozása [5], rezgésanalízis [6], stb. Gyakran vezeték nélküli szenzorhálózatok (WSN) formájában kerülnek felhasználásra az alkalmazásokban. A szükséges számítások ezekben a rendszerekben történhet offline vagy online. Offline esetben egy külső egység végzi a számításokat, míg az online alkalmazások esetén a felhasznált beágyazott rendszereken futnak az algoritmusok. Az online algoritmusok tervezése egy kihívást jelentő feladat, mivel ügyelni kell a megfelelő felhasználásra energia, memória, és feldolgozás terén.

Ebben a munkában az inerciális és mágneses szenzorok két mintafelismerési alkalmazásában elért eredmények vannak bemutatva. A kifejlesztett algoritmusok könnyen implementálhatóak a felhasznált mikrovezérlő alapú beágyazott rendszerekre, tehát képesek online működésre.

Az első alkalmazás gyorsulásmérőket, giroszkópokat és magnetométereket alkalmaz a kezek és a test különböző mozgásainak osztályozására. Két, az alanyok csuklóíhoz rögzített szenzorlap lett alkalmazva. A javasolt algoritmusok a szenzorok pozíció és orientáció változásainak következtében keletkezett jelekből kinyert jellemzőket használják fel.

A második alkalmazás egy magnetométert alkalmaz a járművek több osztályba történő osztályozására. Az érzékelő az úttest felületébe van szerelve, tehát stacionárius pozícióban van. A jellemzők kinyerése során a mért mágneses mezőben kialakuló disztorziók lettek felhasználva, amelyek a járművek szenzor feletti mozgása miatt jönnek létre.

## 2 Mozgásfelismerés viselhető inerciális és mágneses szenzorokkal

Az első alkalmazás emberi mozgások osztályozásával foglalkozik. Ilyen rendszerek széles körben felhasználhatóak különböző ipari, szórakoztató, egészségügyi és orvosi alkalmazásokban [7].

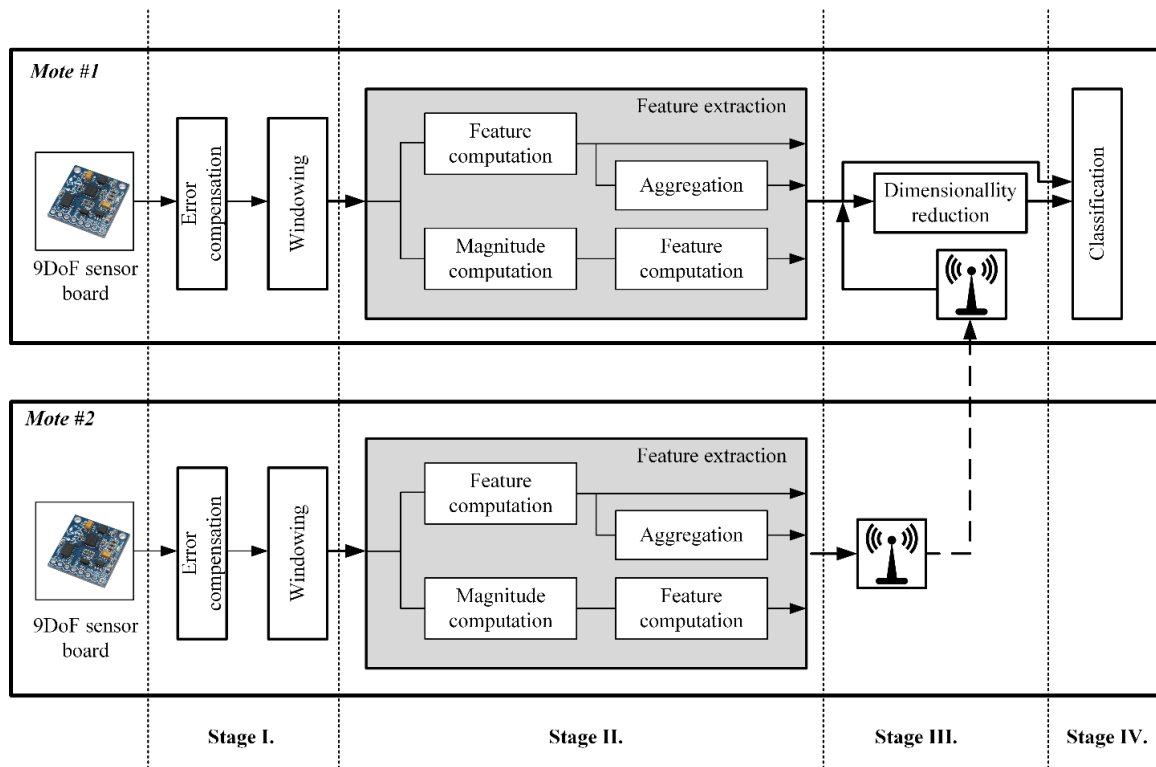
A testszenzorhálózatokban a szenzor eszközöket úgy kell megtervezni, hogy a lehető legmagasabb mobilitást biztosítsák az alanyok számára. Kicsi, könnyű és vezeték nélküli hordozható egységeknek kell lenniük.

Az alkalmazott prototípus mérési rendszer egy IRIS WSN mote-ot és egy hozzáillesztett kilenc szabadságfokú digitális szenzorlapot tartalmaz [8]. Az IRIS mote-on található egy Atmel ATmega 1281L 8-bites mikrovezérlő és egy RF231 IEEE 802.15.4 rádió adóvevő. A csatlakoztatott kilenc szabadságfokú szenzorlap tartalmaz egy ADXL345 típusú háromtengelyű MEMS gyorsulásmérőt (ACC), egy ITG3200 háromtengelyű MEMS giroszkópot (GYR), és egy HMC5883L magnetorezisztív technológiájú magnetométert (MAG). Fejlesztve lett egy TinyOS alapú szoftver is, amely konfigurálja a szenzorokat és ciklikusan olvas belőlük mérési adatokat. Az adatokat az I2C interfészen keresztül olvassa, majd vezeték nélküli kommunikáció segítségével küldi egy BaseStation mote-nak, amely soros porton keresztül továbbítja őket a számítógépnek.

Tizenegy mozgáosztály volt definiálva annak érdekében, hogy felismerje a karok meghatározott mozgásait álló helyzetben és a test mozgása közben is: "állás a karok mozgása nélkül", "ülés a karok asztalon való pihentetésével", "sétálás", "egy helyben történő fordulás", "kocogás", "a bal kar emelése és eresztése állás közben", "a jobb kar emelése és eresztése állás közben", "mindkét kar emelése és eresztése állás közben", "a bal kar emelése és eresztése sétálás közben", "a jobb kar emelése és eresztése sétálás közben", "mindkét kar emelése és eresztése sétálás közben". Az adatgyűjtés kilenc alany segítségével történt minden mozgáshoz. A szenzorlapokkal felszerelt IRIS mote-ok az alanyok csuklóihoz lettek rögzítve. Az adatok rögzítése 20 másodperces fix hosszúságú időtartamokban történt minden mozgás esetén 125Hz mintavételezési frekvenciával, ami 2500 mérést jelent szenzoronként.

### Online mozgáosztályozási algoritmus

A javasolt algoritmusban az osztályozás négy lépésben valósul meg. A szoftver architektúra a négy lépése az 1. ábrán látható. A javasolt algoritmus feltételezi a kinyert jellemzővektor átvitelét az egyik mote-ról a másikra, majd az algoritmus maradék része a fogadó eszköz mikrovezérlőjére kellene hogy legyen implementálva [9-10].



1. ábra: Szoftver architektúra.

Az érzékelők szerkezeti hibáiból adódó nagy hibaarány miatt kompenzálni kell a nyers mérési adatokat az előfeldolgozási fázisban. A kalibrációs paraméterek egy offline, evolúciós algoritmus alapú módszerrel lettek meghatározva, amely több pozícióban végzett mérést alkalmaz a számítások során [11].

A tulajdonságok kinyerése fix szélességű ablakokban történik, amelyek állandó mérettel vannak eltolgatva.

Az alkalmazott tulajdonságok a memória használat, a számítási igény és a potenciális információmennyiség alapján lettek kiválasztva. A könnyű implementáció és az alacsony memóriaigény miatt csak időbeli analízis lett végrehajtva a jeleken. A következő jellemzők kerültek felhasználásra ebben a kutatásban: abszolút átlagérték (MAV), Willison amplitúdó (WAMP), nullátmenetek száma (NZC), változások előjelváltozása (NSSC), legnagyobb (MAX) és legisebb (MIN) érték, négyzetes közép (RMS), és jelalak hossz WL.

A bemeneti vektorok két jellemző számítási móddal lettek generálva és tesztelve: jellemzők kinyerése külön az X, Y, Z szenzortengelyek jelein (SEP), és vektor hossz alapú kinyerés, amelynél a vektorhosszban kialakuló változások felhasználásával történik a jellemzők kinyerése.

A SEP jellemzőkinyerés a szenzor három tengelyén nagy számú jellemzőt eredményezhet, amely növelheti az osztályozási algoritmus összetettségét. Ezen kívül rossz hatással lehet a felismerési arányra is, ha az alanyok nem rögzítik megfelelően az eszközöket a csuklóikhoz. Egy lehetséges megoldás lehet mindkét előző problémára a külön számított jellemzők

aggregálása (AGG). Ahogy az (1) képletben látható, ez megvalósítható az egyes tengelyeken kinyert jellemző értékek lineáris kombinációjának kiszámításával adott jellemzőtípus esetén.

$$feat_{AGG} = w_X \cdot feat_X + w_Y \cdot feat_Y + w_Z \cdot feat_Z, \quad (1)$$

ahol  $feat_{AGG}$  az aggregált jellemző érték,  $feat_X$ ,  $feat_Y$ , és  $feat_Z$  a kinyert jellemzők az egyes tengelyek esetén, és  $w_X$ ,  $w_Y$ , és  $w_Z$  a kapcsolódó súlyértékek.

A lineáris diszkriminancia-analízis (LDA) módszer lett alkalmazva a dimenziók számának csökkentésére az adathalmazokon. Ennek a módszernek az eredménye egy paraméter mátrix, amelyet szorozni kell a jellemzők vektorával, hogy megkapjuk az osztályozók bemeneteit. Az implementációja csak szorzást és összeadást igényel.

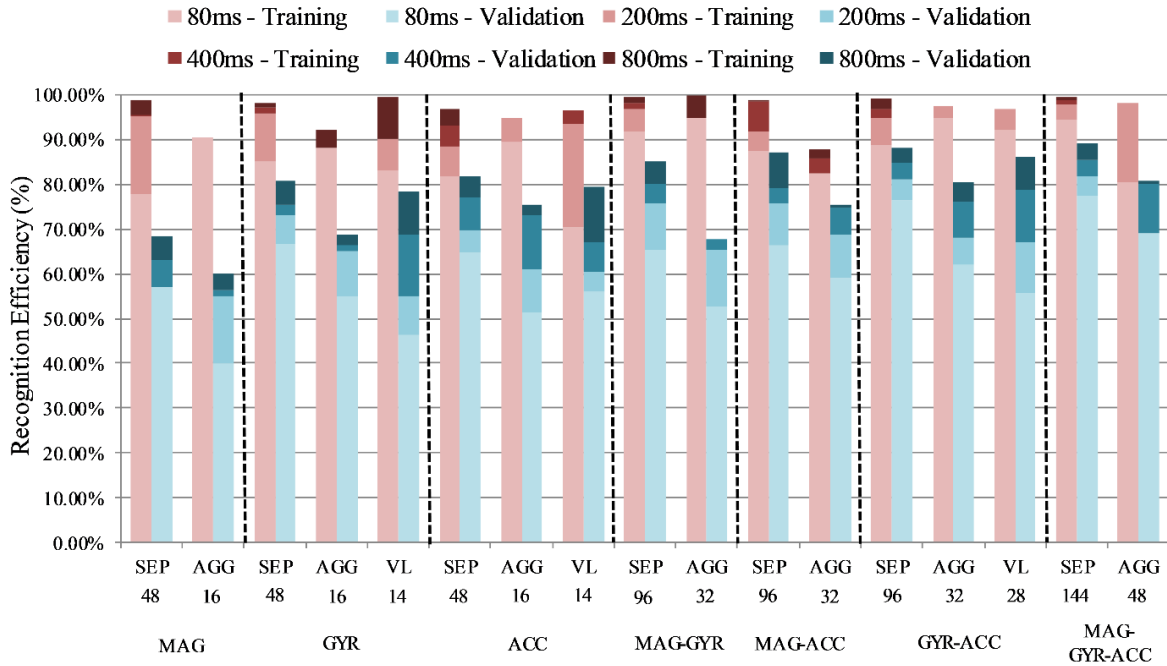
Hét lehetséges osztályozási módszer lett választva és tesztelve: legközelebbi centroid osztályozó (NCC), többrétegű perceptron (MLP), naiv Bayes módszer (NBC), "egy az egy ellen" (OvO) és "egy mindenki ellen" (OvA) szupport vektor gépek (SVM), k-legközelebbi szomszéd módszer (k-NN), osztályozási fák (CT).

Összesen 340 adathalmaz lett létrehozva az alkalmazott szenzor típusok, időtartománybeli jellemző (TDF) számítási módok, ablakok mérete, és mintavételezési frekvenciák alapján. Minden alkalmazott ablakméret milliszekundum tartományú volt. A következő ablakszélesség és eltolás párok voltak alkalmazva: 80ms szélesség és 40ms eltolás; 200ms szélesség és 40ms eltolás; 400ms szélesség és 80ms eltolás; 800ms szélesség és 80ms eltolás. Az érzékelők felismerési hatékonyságra gyakorolt hatásának vizsgálata, valamint a memória és a hardver erőforrások felesleges használatának megelőzése érdekében a három szenzor típus külön-külön, párokban és együtt is lett tesztelve. Az adathalmazok öt különböző mintavételezési frekvencia használatával lettek generálva: 25Hz, 50Hz, 75Hz, 100Hz, és 125Hz. Az adatok a négy alacsonyabb frekvenciához a 125Hz mintavételezési frekvenciával gyűjtött adatok alulmintavételezésével lettek meghatározva.

Az osztályozók tanítása öt alany adataival történt a kilencből, míg a maradék négy alany adatai az osztályozók validálására voltak használva ismeretlen bemenetekként.

Mind a hét klasszifikációs módszer tesztelve lett minden adathalmazon dimenzió redukció alkalmazásával és anélkül, hogy megvizsgálásra kerüljön annak hatása a felismerési hatékonyságra, memória használatra, és tanítási időre. Nem sikerült eredményeket elérni az NBC használatával LDA nélkül, mivel valamely osztályok nulla varianciájú jellemzőket tartalmaznak. Az eredmények megmutatták, hogy a legmagasabb hatékonyság az MLP-vel érhető el, de az LDA-MLP is elfogadható a kicsit alacsonyabb hatékonyság, alacsonyabb memóriaigény és nagy számú tulajdonság esetén szignifikánsan alacsonyabb tanítási idő miatt. A CT hatékonyan osztályozza a tanítási adatokat, viszont a teljesítménye sokkal alacsonyabb ismeretlen mintákon. A nagyon népszerű k-NN és SVM alapú módszerek használhatatlannak bizonyultak az applikációban, az alacsony hatékonyságuk és magas hardver igényük miatt.

A legjobb eredmények a 17 különböző kombinációra a négy különböző ablakszélesség esetén a 2. ábrán láthatóak.



2. ábra: Elért klasszifikációs hatékonyságok tanítási és validálási adatokon különböző ablakméretek alkalmazásával. A vízszintes tengelyen az első sorban a kinyerési módok, a szükséges jellemzők száma a második sorban, a harmadik sorban pedig a használt szenzortípusok láthatóak.

Az eredményekből megállapítható, hogy a mintavételezési frekvenciák nincsenek nagy hatással az elért felismerési arányokra, csak kis javulások érzékelhetők a mintavételezési frekvencia növelésével. A felhasznált milliszekundum tartományú ablakok használhatónak bizonyulnak, mivel 77% feletti hatékonyság érhető el ismeretlen adatokon a legkisebb, 80ms-os, ablakok használatával, míg majdnem 90% érhető el a legnagyobb 800ms-os mérettel. Az elért felismerési arányokból megállapítható, hogy a különböző alanyok mozgásában magas korreláció látható, mivel a tanítási és validálási adathalmazok más alanyok adataival lettek létrehozva. A klasszifikációs arányok a tanítási adatokon elérhetik majdnem a 100%-ot, ami szintén egy fontos tényező ha az applikáció egy személyre lenne tanítva és felhasználva.

A mágneses szenzor maga nagyon alacsony, 40-67%, felismerési arányokat szolgáltat, viszont szignifikánsan javíthatja a giroszkópok és gyorsulásmérők teljesítményét ha együtt vannak használva. A két inerciális szenzor egyedül 80% körüli felismerést biztosít a legnagyobb ablakméret esetén. A legmagasabb hatékonyságok a három szenzor típus együttes alkalmazásával lettek elérve, viszont a mágneses szenzor hatása nagyon kicsi, mivel csak 1-2%-kal növeli a felismerési arányokat, miközben nagy mértékben növeli a rendszer árát és fogyasztását, illetve a szükséges jellemzők számát. Néhány adathalmaz esetén a magnetométer adataival kinyert jellemzők hozzáadásával csökkent a klasszifikációs hatékonyság.

A legmagasabb hatékonyságok a szenzor tengelyein kinyert jellemzők felhasználásával lettek elérve, viszont ezek háromszor több jellemzőt használnak mint az aggregáció és a vektor

hossz alapú adathalmazok. Az inerciális szenzorok 86,17%-os felismerési arányt szolgáltatnak a VL alapú kinyeréssel, viszont az alacsonyabb ablakméretek esetén a javasolt aggregáció alapú jellemző kinyerés magasabb felismerési arányokat szolgáltat.

### **Hierarchikus-elosztott mozgásosztályozási algoritmus**

Mivel az előző osztályozási algoritmus együtt használja a két eszközön kinyert adatokat az osztályozási fázisban, az implementációja magas fogyasztású rádiókommunikációt igényel a mote-ok közötti adatátvitelhez. Ésszerű az algoritmust szétosztani egy hierarchikus megközelítésben, hogy egy elosztott hálózatot kapjunk, amelyben az eszközök meghatározzák a saját mozgásosztályukat [12-13]. Az előző algoritmushoz képest különbség csak az előfeldolgozási rész után észlelhető, mivel a hiba kompenzáció, ablakozás és jellemzőkinyerés azonos módon történnek. Az osztályozás a kinyert jellemzővektor alapján történik mindkét mote-on. Az osztályozás mindkét mote-on történik a kinyert jellemzővektor alapján. A javasolt hierarchikus-elosztott technika felhasználásával csak a meghatározott mozgásosztály átvitele szükséges periodikusan az egyik mote-ról a másikra az ablak eltolás értéke alapján. Az egész test és karok mozgásának meghatározása a két meghatározott osztály kombinálásával történik. Amellett, hogy a javasolt algoritmusban kevesebb vezeték nélküli adatátvitel szükséges, az osztályozóknak kevesebb bemeneti jellemzője és kimenete van, tehát, energiahatékonyabb és könnyebben implementálható az algoritmus a mote-okra. Új eszközök hozzáadása a rendszerhez szintén könnyebb lenne ennek a módszernek az alkalmazásával, mivel csak az osztályok kombinálásának folyamatát a fogadó eszközön kell módosítani, a jellemzők vektora pedig szintén túl nagyra válna a nem elosztott módszer esetén.

Az elosztott módszer esetén néhány osztály összevonható a kar szerepe alapján az adott mozgásban. Így az osztályok száma hétre csökkenthető egy eszköz esetén. Két különböző módszer lett tesztelve a mozgáshierarchiákban. Az elsőben az osztályok egy szinten vannak szétosztva. A második módszerben a mozgások három szintre vannak szétosztva. Az osztályozó algoritmus öt elosztást használ, hogy eldöntse a hierarchia mely eleme felel meg a tényleges mozgásnak.

Az osztályozáshoz MLP neurális hálózatok lettek használva. Az osztályok kombinálása azon az eszközön történik amely fogadja a másik osztályát. A kombináció egy osztályt szolgáltat kimenetnek, de ismeretlen osztályt ad ha az osztályok nem képeznek érvényes párt.

Összesen 68 adathalmaz lett összeállítva a különböző ablakméretek hatásának megvizsgálására. A jellemzők kinyerése a 125Hz-es mintavételezési frekvencia alkalmazásával rögzített jelek segítségével történt.

Az elért eredmények alapján látható, hogy a két hierarchikus módszer hasonló eredményeket szolgáltat, de a nem elosztott algoritmus sokkal magasabb eredményeket ad. Az átlagos különbség körülbelül 25% mindkét hierarchikus módszerhez viszonyítva mind a tanítási, mind a validálási adatokon. A legmagasabb hatékonyságok validálási adatokon,



75,76% az első és 72,05% a második hierarchia felhasználásával, a három szenzor típus együttes alkalmazásával érhető el.

### **Idő- és frekvenciatartomány alapú analízis összehasonlítása**

Mivel a javasolt algoritmusok csak alacsony memória- és számításigényű TDF-eket alkalmaznak, fontos a két jellemzőkinyerési mód képességeinek összehasonlítása a mérési adatokon [14]. A szórás hozzá lett adva az előzőleg alkalmazott időbeli tulajdonságokhoz. A frekvenciatartománybeli jellemzők kiszámítása az rögzített jelek amplitúdó spektruma alapján történik, tehát, transzformációt igényelnek frekvenciatartományba. A transzformáció gyors Fourier transzformáció (FFT) segítségével történt. Az alkalmazott FDF-ek a következők voltak: spektrális energia, medián frekvencia, átlagos frekvencia, átlagos teljesítmény, csúcs magnitúdója, csúcs frekvenciája, és a középfrekvencia varianciája. Három különböző ablakszélesség lett alkalmazva: 64, 128, és 256 mérés. Az alkalmazott 125Hz-es mintavételezési frekvencia alapján ez 0.5s, 1s, és 2s.

Az elért eredményekből látható, hogy a TDF-ek magasabb felismerési arányt szolgáltatnak a legtöbb adathalmaz esetén. A legmagasabb felismerési arányok mindhárom ablakméret esetén a giroszkóp és a gyorsulásmérő nyers adataival lettek elérve. A legmagasabb klasszifikációs hatékonyságokat a legszélesebb ablakok szolgáltatták, 91,74%-ot TDF-ek, és 88,51%-ot FDF-ek felhasználásával.

### **3 Valós idejű járműosztályozás egy magnetométer felhasználásával**

Az automatikus járműérzékelési technológiák fontos szerepet játszanak az intelligens közlekedési rendszerekben. Ezek a rendszerek adatokat biztosítanak a járművek számáról és osztályáról, amelyek nagyon fontos bemeneti szempontjai a forgalom modellezésnek, az útburkolat kialakításának, a közlekedéstervezésnek, a szennyezés becslésének és a forgalomirányításnak. A leggyakrabban alkalmazott technológiák az induktív hurkok és a képfeldolgozó detektorok, viszont a mágneses szenzor alapú járműérzékelőknek számos előnyük van ezekkel a technológiákkal szemben.

A járműosztályozás megvalósítható két szenzor alkalmazásával, amely lehetővé teszi a jármű sebességének és hosszának meghatározását, vagy csak egy eszköz felhasználásával, viszont ezek a rendszerek csak a jelalakokra hagyatkozhatnak a klasszifikálási folyamat során [15].

Egy mérési eszköz lett telepítve adatgyűjtéshez. A detektor az úttest felszínébe lett szerelve a sáv közepén. Az alkalmazott hardver egy HMC5843 alapú egység, amelyet a Selma Kft, Szabadka, Szerbia fejlesztett. A hardver szintén rendelkezik egy 8-bites mikrovezérlővel (Silicon Labs C8051F930), amely képes külső eszközökkel is kommunikálni. A kifejlesztett járműérzékelő algoritmus implementálva lett a telepített eszközre. Az alkalmazott mintavételezési frekvencia 50Hz volt. Az eszközön levő szoftver elküldte a mérési adatokat és a detekciós flag értékét a szervernek. A detekciók validálása és az egyes minták osztályának meghatározása érdekében egy kamera is fel lett szerelve az út szélére. Az adatgyűjtő szoftver képeket mentett a detekciós flag minden lefutó élénél. Az adatgyűjtés több hónapon keresztül történt különböző időjárás körülmények közt, és összesen több mint 30000 minta lett összegyűjtve.

#### **Szenzor kalibráció és a járműérzékelő algoritmus**

A járműérzékelés nagyon fontos részét képezi a klasszifikációs folyamatnak, mivel követnie kellene a környezeti változásokat [16] és ugyanúgy viselkedni különböző járművek esetén. A kifejlesztett detekciós algoritmus főleg járműosztályozási feladatokhoz lett tervezve, és adaptív küszöbök alkalmaz ezeknek a változásoknak a követésére [17]. Először egy kalibrációs folyamat fut le, amely megtalálja pillanatnyi eltolás értékeket minden tengelyen. A folyamat egy kalibrációs tartományt alkalmaz, amelynek mérete kicsit nagyobb kell hogy legyen a csúcstól csúcsig mért zajszinttől. A kalibráció során a legmagasabb és legalacsonyabb értékek lettek megfigyelve minden tengelynél egy mérési ablakban. Ha a kalibráció sikeres, akkor a felső és alsó kalibrációs és detekciós küszöbök kerülnek meghatározásra minden tengelynél. Ez a legmagasabb és legalacsonyabb értékek által meghatározott tartomány egyenletes szétnyújtásával történik adott szélességekre. Jármű jelenlétét akkor állapítja meg az

algoritmus ha a mérési értékek meghaladják a detekciós küszöböt az X és a Z tengelyeknél. Az észlelési flag akkor törlődik ha a mérések mind az X mind a Z tengelyeknél a kalibrációs küszöbök által meghatározott tartományban vannak egy előre definiált mérési szám során. Az algoritmusnak képesnek kellene lennie megfelelően érzékelni az utánfutós járműveket, tehát a mérési számot a járművek potenciális sebessége és a jármű és az utánfutó közötti lehetséges távolság alapján kell kiszámolni. Amikor nincs észlelés az algoritmus folyamatosan próbál újrakalibrálni, így követni tudja a környezeti változásokat.

Az algoritmus hatékonyságának tesztelésére egy egy órás teszt lett végezve. Az detekciós algoritmus hatékonysága 94,15% [18]. Az algoritmus érzékeli az összes felette áthaladó járművet, egyedül motorkerékpárok okozhatnak hibákat ha nem haladnak elég közel a szenzorhoz. A többi hibát a fals érzékelések okozzák. Ezek a szomszédos sávban elhaladó magas fémtartalmú járművek hatására alakulnak ki.

### **Járműosztályozó algoritmus**

Az alkalmazott járműosztályozó algoritmus három fő részből áll: járműérzékelő algoritmus, jellemző kinyerés, osztályozás [19]. Valós idejű és online járműosztályozáshoz minden résznek könnyen implementálhatónak kell lennie a használt hardver mikrovezérlőjébe.

A jellemzők a detekciós ablakban lettek kinyerve. A választott tulajdonságok csak időtartománybeli analízisen alapszanak, mivel kevés számítás igényelnek, és nem szükséges hozzájuk az összes mérési érték tárolása a detekciós ablakban. A jellemzők kiválasztása a potenciális képességük alapján történt, hogy tudják-e érzékelni a járművek tengelyeit és a fémtartalmukat. Szintén fontos, hogy immunisnak kell lenniük a sebességváltozásokra. Az alkalmazott jellemzőtípusok a következők voltak: MAX, MIN, MAX és MIN helye, tartományváltások, lokális maximumok és minimumok száma, MAV, átlagérték (MV), NSSC, NZC, átlagos jelalakhossz (AWL), RMS, WAMP.

Különböző kinyerési módok lettek tesztelve amelyek megnövelhetik a hatékonyságot és/vagy csökkenthetik a szükséges jellemzők számát. A jellemzők kinyerése a nyers szenzor adatokon és aggregált adatokon történik, amelyek nyers adatokból számíthatóak ki. A következő kinyerési módok lettek alkalmazva: mérési tengelyek, abszolút értékek, origótól számított vektor hosszak, szögek, kalibrációs ponttól számított vektor hosszak.

Figyelembe véve a mágneses szenzorok képességeit, kilenc osztály lett definiálva: motorkerékpár, autó, kisteherautó vagy minibusz, teherautó, teherautó utánfutóval, nyergesvontató, busz, csuklós busz.

A javasolt algoritmusban háromrétegű MLP neurális hálózatok lettek alkalmazva az osztályozásra, és osztályonként 130 minta lett használva.

A különböző jellemző kinyerési módok és alkalmazott szenzor tengelyek kombinációi alapján különböző adathalmazok lettek tesztelve annak érdekében, hogy minimalizálva legyenek a jellemzők számai és a rendszer lehetséges ára. Összesen 18 különböző kombináció lett definiálva. A detekció hosszának hatása a jellemzővektorban is meg lett vizsgálva.

A szükséges jellemzők száma, és az átlagos felismerési arány a tanítási és validálási adatokon a 36 adathalmaz esetén az 1. táblázatban vannak összefoglalva.

1. táblázat: Szükséges jellemzők száma, és átlagos felismerési arány a tanítási és validálási adatokon különböző adathalmazok esetén.

Felhasznált tengelyek											
Jellemzők száma											
Hatékonyság tanítási adatokon (%)						Hatékonyság validálási adatokon (%)					
X, Y, Z		X, Y, Z, DL		X		X, DL		Z		Z, DL	
42		43		14		15		14		15	
82.11	67.69	81.50	66.58	78.83	71.33	80.11	72.22	77.92	71.24	81.36	72.36
X, Z		X, Z, DL		$X_{abs}, Y_{abs}, Z_{abs}$		$X_{abs}, Y_{abs}, Z_{abs}, DL$		$X_{abs}$		$X_{abs}, DL$	
28		29		27		28		9		10	
81.61	70.13	81.97	71.64	81.00	71.20	81.81	69.73	73.86	68.18	76.14	70.04
$Z_{abs}$		$Z_{abs}, DL$		$X_{abs}, Z_{abs}$		$X_{abs}, Z_{abs}, DL$		$XY_o, XZ_o, YZ_o, XYZ_o$		$XY_o, XZ_o, YZ_o, XYZ_o, DL$	
9		10		18		19		56		57	
74.31	69.07	75.56	69.82	78.97	69.96	80.08	71.38	82.20	70.18	82.81	68.18
$XZ_o$		$XZ_o, DL$		$XY_o, XZ_o, YZ_o$		$XY_o, XZ_o, YZ_o, DL$		$XYZ_o$		$XYZ_o, DL$	
14		15		42		43		14		15	
80.75	73.73	80.14	74.44	81.03	69.82	84.06	71.51	77.97	72.76	81.39	74.67
$XY_A, XZ_A, YZ_A$		$XY_A, XZ_A, YZ_A, DL$		$XZ_A$		$XZ_A, DL$		$XY_C, XZ_C, YZ_C, XYZ_C$		$XY_C, XZ_C, YZ_C, XYZ_C, DL$	
42		43		14		15		36		37	
79.00	66.53	79.97	65.78	80.92	71.20	79.69	71.87	79.08	66.36	81.75	69.11
$XZ_C$		$XZ_C, DL$		$XY_C, XZ_C, YZ_C$		$XY_C, XZ_C, YZ_C, DL$		$XYZ_C$		$XYZ_C, DL$	
9		10		27		28		9		10	
72.78	68.49	76.53	70.53	80.83	68.36	79.28	68.27	73.61	68.93	75.69	71.38

Az elért eredményekből látható, hogy az aggregált adatok használata szögek és vektor hosszak formájában akár a klasszifikációs hatékonyságot is megnövelheti a jellemzők számának csökkentése mellett. A legmagasabb felismerési arányok a validációs adatokon az origótól számított vektor hosszakkal lettek elérve az XY-síkban, 74,67% a detekció hosszának használatával, és 73,73% anélkül. Csak az X vagy a Z tengely használata 71-72%-ot ad, ami mutatja, hogy még egy egytengelyű szenzor is képes hatékonyan osztályozni a járműveket több osztályba. A detekció hossza átlagosan 1,28%  $\pm$ 1,63%-al növeli meg az osztályozási hatékonyságot tanítási adatokon, és 0.80%  $\pm$ 1.37%-al ismeretlen adatok esetén. Ez mutatja, hogy a felhasznált jellemzők képesek az információ hatékony kinyerésére a jelalakokból. A szükséges jellemzők száma a legjobb adathalmazok esetén 14-15, míg konvergencia ismeretlen adatokon 10-15 neuron esetén észlelhető.

## Szabályalapú fals detekció szűrő algoritmus

A fals detekciók nagyban kihatnak a klasszifikációs algoritmus hatékonyságára, így fontos ezek minimalizálása. A javasolt fals detekció szűrő módszer szabályokon alapszik, amelyek különböző adattípusok és relációk használatának segítségével lettek összeállítva [18, 20].

Az optimális paraméterek és relációk keresése különböző adattípusokkal volt tesztelve. A szenzorok tengelyein mért értékek mellett aggregált adatok is tesztelve lettek. A szomszédos sáv felé mutató tengely kellene hogy a legtöbb információt hordozza a fals detekciók szűréséhez, de a többi is figyelembe lett véve. A következő adattípusok voltak felhasználva: mérési tengelyek, az origótól számított vektor hosszak és szögek.

A következő értéktípusok voltak meghatározva a detekciós ablakban az összes adattípus esetén: legmagasabb érték, legalacsonyabb érték, és legnagyobb érték a mérési adatok abszolút értéke esetén.

Mivel a szomszédos sávban haladó magas fémtartalmú járművek nagyobb különbségeket generálhatnak a jelekben mint a szenzor felett haladó alacsonyabb fémtartalmú járművek, indokolt különböző adattípusok arányainak tesztelése. Az arányok az adat- és értéktípusok minden kombinációja esetén meg lettek határozva.

A paraméter értékek optimalizálására genetikus algoritmusok lettek alkalmazva. Tévedések a jó detekciók esetében megengedettek, de mind a jó érzékelések helyes meghatározása, mind a fals detektálásoké fel lett használva a fitness függvényekben. Az arányok súlyozva vannak mivel kevésbé fontos a fals detekciók felismerése mint a jók elvesztése. A felhasznált fitness függvény a következő:

$$fitval = w_c - w_c \cdot n_c / N_c + w_f - w_f \cdot n_f / N_f \quad (2)$$

ahol  $fitval$  a fitness érték,  $n_c$  a megtalált helyes detektálások száma,  $N_c$  a jó detektálások száma,  $n_f$  a megtalált fals detektálások száma,  $N_f$  a fals detektálások száma,  $w_c$  a jó detektálások esetén használt súly, és  $w_f$  a fals érzékeléseknél alkalmazott súly.

Azon paraméterek megtalálása érdekében amelyek hatékonyan használhatók a fals detekciók szűrésére, először az összes adat- és értéktípus minden kombinációja külön tesztelve lett. A leghasználhatóbb paraméterek megtalálása után még pontosabb eredményekért fontos kombinálni ezeket a paramétereket összetettebb szabályokban. A legjobban felhasználható paraméterek megtalálása után még pontosabb eredményekért fontos kombinálni ezeket a paramétereket összetettebb szabályokban. A szabályok két módon lettek kombinálva, mivel az "ÉS" és "VAGY" logikai operátorok egyaránt tesztelve lettek a különálló szabályok között.

Az elért eredményekből látható, hogy 97%-a a fals detekcióknak szűrhető a jó érzékelések csak 0,3%-os elvesztésével. A legmagasabb eredmények vektor hosszak használatával érhetőek el, míg kicsit alacsonyabb arányokat szolgáltatnak a mérések a szenzor tengelyein. Egy szimpla paraméter elegendő lehet a fals detekciók szűrésére. Szintén észrevehető, hogy annak ellenére, hogy a szomszédos sáv felé mutató tengely kellene hogy a legtöbb információt hordozza a fals detekciók szűréséhez, a másik két tengely jobb eredményeket biztosít.

## 4 A tézispontok összefoglalása

A tézisek és a hozzájuk kapcsolódó publikációk kapcsolata a 2. táblázatban látható.

2. táblázat: Tézisek és a hozzájuk kapcsolódó publikációk.

Publikáció	Tézis							Típus
	1.1	1.2	1.3	2.1	2.2	2.3	2.4	
[8]	•	•						konferencia cikk
[9]		•						konferencia cikk
[10]		•						folyóirat cikk
[12]			•					konferencia cikk
[13]			•					folyóirat cikk
[14]		•						konferencia cikk
[17]				•	•			könyvfejezet
[18]					•	•	•	konferencia cikk
[19]						•		folyóirat cikk
[20]							•	konferencia cikk

Az eredmények a következő tézisekbe foglalhatók össze:

**1. Téziscsoport** Újszerű online algoritmusokat fejlesztettem emberi test és karok mozgásának osztályozásához csuklóra szerelt gyorsulásmérők, giroszkópok, és magnetométerek felhasználásával. Az algoritmusok implementálhatóak korlátos erőforrásokkal rendelkező beágyazott rendszerekre.

**1.1. Tézis** Kifejlesztettem egy prototípus mérési rendszert emberi mozgások rögzítésére, és mérési adatokat gyűjtöttem az osztályozók tanításához és validálásához. Két WSN mote-okra szerelt kilenc szabadságfokú szenzorlapot alkalmaztam, melyek az alanyok csuklóihoz voltak rögzítve.

**1.2. Tézis** Kifejlesztettem egy új online mozgásosztályozó algoritmust amely a különböző egységeken kinyert jellemzőket együtt használja fel az osztályozási fázisban.

Megmutattam, hogy kizárólag alacsony memóriaigényű időtartománybeli jellemzők alkalmazása elegendő magas klasszifikálási hatékonyság eléréséhez inerciális és mágneses szenzorokat alkalmazó mozgásosztályozó rendszerekben.

Megmutattam, hogy különböző alanyok mozgásaiban magas a korreláció, mivel az osztályozók magas felismerési arányokat szolgáltattak olyan alanyok adatai esetén amelyek nem voltak alkalmazva tanítás során.

Megmutattam, hogy milliszekundum tartományú ablakszélességek elegendőek az emberi test és karok mozgásainak hatékony felismeréséhez.

Javaslatot tettem egy aggregáció alapú módszerre, amellyel több tengelyű szenzorok esetén csökkenthető a jellemzők száma. A módszer alkalmazása háromszor kevesebb jellemzőt

eredményez annál az esetnél, amikor a szenzor egyes tengelyein kinyert jellemzők kerülnek az osztályozók bemeneteire. Az aggregáció az egyes tengelyeken kinyert jellemző értékek lineáris kombinációjának kiszámításával történik adott jellemzőtípus esetén. Az aggregációs módszer alkalmazható osztályozási hatékonyságokat biztosít. Ez a redukciós módszer segíthet a rendszernek abban is, hogy kevésbé legyen érzékeny a szenzorok kisebb orientációbeli eltérésére.

Megmutattam, hogy új szenzortípus hozzáadása a rendszerhez egyes esetekben csak kis mértékben javítja vagy akár csökkenti a rendszer felismerő képességét. A lehetséges szenzortípusok különböző kombinációkban történő tesztelésével egy optimális konfiguráció található, amely csökkentheti a rendszer árát és fogyasztását.

Megmutattam, hogy hasonló alkalmazások esetén a többrétegű perceptron neurális hálózatok a legalkalmasabb osztályozók online algoritmusok megvalósításához, illetve, hogy néhány népszerű módszer (szupport vektor gépek, k-legközelebbi szomszéd módszer) nem alkalmas online felhasználásra korlátos erőforrású beágyazott rendszerek esetén.

Megmutattam, hogy a lineáris diszkriminancia-analízis alapú dimenziócsökkentés alkalmazása a jellemzőket tartalmazó vektoron javíthatja különböző osztályozók felismerési hatékonyságát, tanítási idejét, és az implementáláshoz szükséges memóriaigényüket.

Megmutattam, hogy csak egyszerű időtartománybeli jellemzők alkalmazásával egyes adathalmazok esetén magasabb klasszifikációs arány érhető el mint csak frekvenciatartomány alapú analízis esetén kinyert jellemzők felhasználásával.

Megmutattam, hogy a javasolt aggregáció alapú csökkentése a jellemzők számának frekvenciatartománybeli jellemzők esetén is hatékonyan alkalmazható.

**1.3. Tézis** Kifejlesztettem egy hierarchikus-elosztott algoritmust emberi mozgások online osztályozására, amelyben a több felhasznált eszköz meghatározza a saját mozgásoztályát, majd egy eszköz ezen osztályokat kombinálva meghatározza a teljes test mozgásoztályát. Ez az algoritmus kevesebb számítást igényel az osztályozók kisebb mérete miatt, illetve kevesebb vezeték nélküli kommunikációt igényel, amely az energiahatékonyság szempontjából jelentős. Ez a módszer alkalmazása leegyszerűsíti az új egységek rendszerhez való hozzáadását is. Két különböző mozgáshierarchiát alkalmaztam, amelyek hasonló hatékonyságokat eredményeztek.

**2. Téziscsoport** Kifejlesztettem egy valós idejű járműosztályozó rendszert, amely egy darab úttestbe szerelt mágneses szenzort alkalmaz.

**2.1. Tézis** Kifejlesztettem egy prototípus mérési rendszert, amelyben egy magnetométer alapú egység lett szerelve az úttest felszínébe. Az érzékelések validációja és az egyes minták osztályának megállapítása érdekében egy kamerát is alkalmaztam, amely az út szélére lett telepítve. A mérési rendszer segítségével nagyon nagy adatbázist alkottam az összegyűjtött mintákból.

**2.2. Tézis** Kifejlesztettem egy adaptív küszöbökkel alkalmazó járműérzékelési algoritmust. Az algoritmus kezelni tudja a környezeti változásokat, és főleg járműosztályozási alkalmazásokhoz lett tervezve. Az algoritmus egy kalibrációs módszert alkalmaz bekapcsolás után, amely segítségével becsli az eltolásokat az egyes szenzortengelyeken, majd állandó újrakalibrációval követi a környezetben fellépő változásokat. Az algoritmus alkalmas utánfutós járművek detektálására is.

**2.3. Tézis** Kifejlesztettem egy új online járműosztályozó algoritmust, amely többrétegű neurális hálózatok használatával képes a járműveket kilenc osztályba besorolni. Az algoritmus időtartománybeli jellemzőket alkalmaz, amelyek potenciálisan érzékelni tudják a járművek fémtartalmát és tengelyeinek számát, immunisak a sebességváltozásokra, és alacsony a memóriahasználatuk.

Megmutattam, hogy egy egyetlen magnetométeren alapuló rendszer is elegendő a járművek kilenc osztályba sorolásához.

Megmutattam, hogy vektor hosszak és szögek formájában aggregált adatok segítségével akár a felismerési arány is növelhető a bemenetek számának csökkentése mellett.

Megmutattam, hogy a detekció hosszának, amely egy sebességfüggő jellemző, hozzáadása a jellemzőkből álló vektorhoz csak kis mértékben növeli az osztályozási hatékonyságot. Ez mutatja, hogy a felhasznált jellemzők képesek az információ hatékony kinyerésére a jelalakokból.

**2.4. Tézis** Kifejlesztettem egy szabályalapú algoritmust a szomszédos sávban elhaladó nagy fémtartalmú járművek által okozott fals detekciók szűrésére. Ennek az alkalmazása tovább növelheti a javasolt járműosztályozó rendszer általános hatékonyságát.

Megmutattam, hogy megfelelő szabályok alkalmazásával nagy százalékban kiszűrhetőek a fals érzékelések csupán néhány helyes detekció elvesztésével.

Megmutattam, hogy annak ellenére, hogy a szomszédos sáv felé mutató tengely kellene, hogy a legtöbb információt hordozza a fals érzékelések szűréséhez, a másik két tengely sokkal megbízhatóbb paramétereket biztosít.

Megmutattam, hogy a vektor hosszak alakjában aggregált adatok sokkal magasabb szűrés hatékonyságot biztosító paramétereket szolgáltatnak mint az érzékelő tengelyeinek jelein kinyert paraméterek.



## Hivatkozások

- [1] W. Li, and J. Wang, Magnetic sensors for navigation applications: an overview. *The Journal of Navigation* 67(2): 263-275, 2014.
- [2] H. Zhao, and Z. Wang, Motion measurement using inertial sensors, ultrasonic sensors, and magnetometers with extended Kalman filter for data fusion. *IEEE Sensors Journal* 12(5): 943-953, 2012.
- [3] K. Altun, B. Barshan, and O. Tuncel, Comparative study on classifying human activities with miniature inertial and magnetic sensors. *Pattern Recognition* 43(10): 3605-3620, 2010.
- [4] K. Liu, C. Chen, R. Jafari, and N. Kehtarnavaz, Fusion of inertial and depth sensor data for robust hand gesture recognition. *IEEE Sensors Journal* 14(6): 1898-1903, 2014.
- [5] P. Tsinganos, and A. Skodras, On the comparison of wearable sensor data fusion to a single sensor machine learning technique in fall detection, *Sensors* 18(2): 592, 2018.
- [6] C. A. Brooks, and K. Iagnemma, Vibration-based terrain classification for planetary exploration rovers. *IEEE Transactions on Robotics* 21(6): 1185-1191, 2005.
- [7] M. Cornacchia, K. Ozcan, Y. Zheng, and S. Velipasalar, A survey on activity detection and classification using wearable sensors. *IEEE Sensors Journal* 17(2): 386-403, 2017.
- [8] P. Sarcevic, Z. Kincses, and S. Pletl, Wireless sensor network based movement classification using wrist-mounted 9DOF sensor boards. In: *Proc. of IEEE International Symposium on Computational Intelligence and Informatics (CINTI)*, Budapest, Hungary, pp. 85-90, 2014.
- [9] P. Sarcevic, Z. Kincses, and S. Pletl, Comparison of different classifiers in movement recognition using WSN-based wrist-mounted sensors. In: *Proc. of IEEE Sensors Applications Symposium (SAS)*, Zadar, Croatia, pp. 446-451, 2015.
- [10] P. Sarcevic, Z. Kincses, and S. Pletl, Online human movement classification using wrist-worn wireless sensors. *Journal of Ambient Intelligence and Humanized Computing*, 2017. <https://doi.org/10.1007/s12652-017-0606-1>
- [11] P. Sarcevic, S. Pletl, and Z. Kincses, Evolutionary algorithm based 9DOF sensor board calibration. In: *Proc. of IEEE International Symposium on Intelligent Systems and Informatics (SISY)*, Subotica, Serbia, pp. 187-192, 2014.
- [12] P. Sarcevic, Z. Kincses, S. Pletl, and L. Schaffer, Distributed movement recognition algorithm based on wrist-mounted wireless sensor motes. In: *Proc. of European*

- Wireless (EW)*, Budapest, Hungary, pp. 130-135, 2015.
- [13] P. Sarcevic, L. Schaffer, Z. Kincses, and S. Pletl, Hierarchical-distributed approach to movement classification using wrist-mounted wireless inertial and magnetic sensors. *Infocommunications Journal* 7(3): 33-41, 2015.
  - [14] P. Sarcevic, Z. Kincses, and S. Pletl, Comparison of time- and frequency-domain features for movement classification using data from wrist-worn sensors. In: *Proc. of IEEE International Symposium on Intelligent Systems and Informatics (SISY)*, Subotica, Serbia, pp. 261-265, 2017.
  - [15] H. Tafish, W. Balid, and H. Refai, Cost effective vehicle classification using a single wireless magnetometer. In: *Proc. of International Wireless Communications and Mobile Computing Conference (IWCMC)*, Paphos, Cyprus, pp. 194-199, 2016.
  - [16] S. Cheung, and P. Varaiya, *Traffic surveillance by wireless sensor networks: Final report*. University of California, Berkeley, 2007.
  - [17] P. Sarcevic, Vehicle classification using neural networks with a single magnetic detector. *Issues and Challenges of Intelligent Systems and Computational Intelligence, Studies in Computational Intelligence*, vol. 530, pp. 103-115, 2014.
  - [18] P. Sarcevic, and S. Pletl, Vehicle classification and false detection filtering using a single magnetic detector based intelligent sensor. In: *Proc. of International Conference on Information Society and Technology (ICIST)*, Kopaonik, Serbia, pp. 144-149, 2014.
  - [19] P. Sarcevic, and S. Pletl, Real-time vehicle classification system using a single magnetometer. *Acta Polytechnica Hungarica* (submitted).
  - [20] P. Sarcevic, and S. Pletl, False detection filtering method for magnetic sensor-based vehicle detection systems. In: *Proc. of IEEE International Symposium on Intelligent Systems and Informatics (SISY)*, Subotica, Serbia, pp. 277-281, 2018.