

Kablosuz manyetik sensörler kullanarak karar ağacı algoritma tabanlı araç sınıflandırmasının gerçekleştirilmesi

Implementation of the vehicle classification based-on decision tree algorithm using wireless magnetic sensors

Sercan VANÇİN^{1*}, Ebubekir ERDEM²

^{1,2}Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye.
svancin@firat.edu.tr, aberdem@firat.edu.tr

Geliş Tarihi/Received: 06.02.2017, Kabul Tarihi/Accepted: 26.04.2017
* Yazışılan yazar/Corresponding author

doi: 10.5505/pajes.2017.44452
Araştırma Makalesi/Research Article

Öz

Kablosuz sensör ağları kullanarak akıllı ulaşım sistemleri (Intelligent Transportation Systems, ITS) tasarlamak, hem maliyet hem de enerji verimliliği açısından avantajlı olup herhangi bir yolun trafiğini gözlemlemek, o yol hakkında trafik bilgisi edinmek veya sadece araçları tespit edip tipleri ve hızlarını saptamak son zamanlarda araştırmacıların ilgi odağı haline gelmiştir. Bu çalışmada sensör düğümü, manyetometre, güç kartı ve pilden oluşan ve diğer çalışmalarda kullanılan düğümlerden daha doğru ve anlaşılır veriler sunabilen bir sensör devresi kullanılmıştır. Bu sensör devreleri ile aracın tipini belirlemek için iki farklı yöntem sunulmuştur. İlk yöntemde, yoldan geçen araçlar, önerilen algoritma ve M1U (Manyetik İmza Uzunluğu) parametresine göre otomobil, minibüs, otobüs ve kamyon olarak sınıflandırılmıştır. Bu yöntemle elde edilen doğruluk payı %89 olmuştur. Diğer yöntemde ise araç sınıflandırması, makine öğrenmesi algoritması olan J48 kullanılarak yapılmış ve önerilen yöntem esas alınarak elde edilen sonuçların eniyilemesi yapılmıştır. Bir makine öğrenmesi yazılım paketi olan Weka'da uygulanan J48 sınıflandırma algoritmasını kullanır. Karar ağacı modeli, 3 eksenli HMC5983L manyetik sensöründen geçen araçlardan çıkarılan manyetik ham veri, ölçüm süresi gibi bir dizi özellikten oluşturulmuştur. Özellikler, çapraz geçerlilik temelinde değişen sınıflandırma oranları derecelerine sahip bir karar ağacı modeli üretmek için J48 eğitim algoritmasına doğru sınıflandırmalarla sağlanan niteliklerdir. Makine öğrenmesi algoritması olan J48 kullanımı araç sınıflandırmasında daha verimli ve doğru sonuçlar verdiği görülmüştür. İlk yöntemle elde edilen M1U değerleri hesaplama aşamasında zorluklar doğurmuştur. Ancak J48 algoritması kullanılarak daha belirgin ve hassas sınır ve eşik değerleri elde edilmiştir. Çalışmanın sonucu, araç sınıflandırma sisteminde önerilen algoritmanın eniyilemesiyle yaklaşık % 100 doğruluk payı ile etkili ve verimli olduğunu göstermektedir.

Anahtar kelimeler: Kablosuz sensör ağları, Manyetik sensör, Araç sınıflandırması, Makine öğrenmesi algoritması, Manyetik imza uzunluğu

Abstract

The design of Intelligent Transportation Systems (ITS) using wireless sensor networks to observe any road traffic, get road information, or just identify road vehicles has recently become an interesting and popular research topic because of its advantages in cost and energy efficiency. To perform this study, sensor circuit consisting of sensor node, magnetometer, power board and battery, is used. This sensor structure presents more accurate and intelligible results than sensor nodes used in other studies. Two different methods have been proposed to determine the type of vehicle with these sensor circuits. In the first method, vehicles passing by the road are classified as cars, minibuses, buses and trucks according to the proposed algorithm and MSL (Magnetic Signature Length) parameters. The accuracy achieved with this method was 89%. In the other method, vehicle classification was performed using machine learning algorithm J48 which is a machine learning decision tree extension and the obtained results were optimized based on the proposed method. It uses the J48 classification algorithm implemented in Weka, a machine learning software package. The Decision Tree model was built from a series of features like magnetic raw data, measurement time derived from vehicles passing through the 3-axis HMC5983L magnetic sensor. The properties are those provided by the correct classification into the J48 training algorithm to produce a decision tree model with grading ratios that vary on the basis of cross validity. The use of J48, a machine learning algorithm, has been shown to yield more efficient and accurate results in vehicle classification. The MSL values obtained by the first method have caused difficulties in the calculation process. However, by using the J48 algorithm, more specific and sensitive boundary and threshold values were obtained. The result of the study illustrates that the vehicle classification system is so effective and efficient with an accuracy rate of about 100% with optimization of the proposed system.

Keywords: Wireless sensor networks, Magnetic sensor, Vehicle classification, Machine learning algorithm, Magnetic signature length

1 Giriş

Günümüzde birçok kişi ulaşım sorunları ve trafik sıkışıklığı ile ilgili sorunlarla karşı karşıya kalmaktadır [1]. Herhangi bir yoldaki trafiği izlemek, trafikteki araçların durumu veya tipi hakkında bilgi edinmek, araçları türlerine göre sınıflandırmak ve bu trafik bilgilerini sürücülere sunmak için Akıllı Ulaşım Sistemleri (ITS) geliştirilmektedir [2]. Yapılan birçok çalışmada kablosuz sensör ağları ile araç tanıma senaryoları [3],[4] gerçekleştirilmiştir.

Anisotropik manyetik sensör (AMR) ve mikrofon sensörü kullanarak herhangi bir yolun trafik analizi yapılmıştır [5]. Bunlara ek olarak akustik sensör [6], ultrasonik sensör [7] ve

video kamera analiz sistemleri veya arial görüntüler [8] kullanarak kablosuz sensör ağ teknolojisiyle araç tespiti yapılmıştır. Diğer bir çalışmada ise AMR sensör kullanarak [9] önceden saptanan eşik değerinin üzerinde algılanan manyetik dalga verisi ölçülüp hesaplanmış ve bu sayede araç tanıma işlemleri yapılabilmektedir. Araştırılan bir çalışmada kablosuz sensör ağları kullanarak gerçek zamanlı trafik gözetim sistemi [10] geliştirilmiştir. Trafikteki araçları sınıflandırmak için optimik ayrılmış örnek bazlı sınıflandırma ve regresyon ağacı algoritması önerilmiştir [11]. Hareket mod-tabanlı araç tanıma için yapay sinir ağları metodu [12]'de önerilmiştir. Bir çalışmada ise trafik gözetim sistemi, hareketli veri sunma ve yönetim ile tümleşik bir sistem olarak

önerilmiştir [11]. Kablosuz sensör ağları ile birden fazla türde sensörler kullanarak araç tanıma ve sınıflandırma çalışması yapılmıştır [12]. Araçlar hafif, orta ve ağır araçlar olarak sınıflandırılmıştır. Daha önceki çalışmalarda araç sınıflandırması için indükleyici (inductive) loop detector'ler kullanarak model tanıma (pattern recognition) [13] ve manyetik sensörler kullanarak vadi ve tepe (valley and hill pattern) [14] modelleri önerilmiştir. Bu çalışmada, daha önceki çalışmalardaki düğüm tasarımı zorluğunu ve gerçek zamanlı ölçüm karmaşıklığını çözebilmek için birçok amaca yönelik kullanılıp çalışabilen sensör düğümleri ve üzerine takılabilen manyetometre (HMC5983L) ile sensör devresi tasarlanmıştır. Bu sensör düğümleri, TelosB, MicaZ, Sensenode veya Imote gibi marketteki sensör düğümlerinden daha düşük masraflı olarak tasarlanabilen, Türkiyede Yeni Çağ Teknolojileri şirketinin piyasaya sunduğu düğümlerdir. Bu sensör devreleri ile aracın tipini belirlemek için iki farklı yöntem sunulmuştur. İlk olarak yoldan geçen herhangi bir aracın tipi otomobil, minibüs, otobüs ve kamyon olmak üzere sınıflandırılmıştır. Sınıflandırma sorununa yenilikçi yaklaşım sunmak için manyetik işaret uzunluğu (MIU) denklemi önerilmiştir. MIU , geliştirilen algoritmayla birlikte araç sınıflandırma problemine çözümler sunmuş ve doğru sonuçlar elde edilmesine olanak sağlamıştır. İkinci yöntemde ise bir makine öğrenme yaklaşımı olan karar ağacı makine öğrenme kullanımı ile sınıflandırma modeli üretilmiştir. Burada kullanılan J48 algoritması, Quinlan'ın ID3'ünün bir uygulamasıdır. Bu iki farklı yöntemden elde edilen sonuçlar kıyaslanmıştır. İlk yöntemle araç sınıflandırması yaparken MIU sınır değerleri birçok örnek aldıktan sonra ortalama alınmasıyla elde edilen değerlerdir. İkinci yöntemde ise söz konusu sınır değerleri karar ağacı esasına göre bulunup sisteme ve araç sınıflandırmasına daha hassas ve uygun çözümler sunmuştur. Tasarlanan sistemin az maliyetli donanım parçalarıyla gerçekleştirilebilir olması kurulan kablosuz sensör ağı kullanışlı olmasından kaynaklanmaktadır. Söz konusu kablosuz manyetik sensör ağı, kullanılan manyetik sensör ve sensör düğümünün kolayca kodlanabilir olması ve toplayıcı (collector) düğüme ilgili bilgileri aktarmasıyla avantajlı ve performanslı olduğunu yansıtmaktadır. Karmaşık ölçüm hesaplamalarından kurtulmak, daha net ve doğru veri elde etmek için sensör düğümleri ve manyetometre (manyetik sensör) seri haberleşme şartlarıyla bütünleştirilmiştir.

Makalenin diğer kısımları şöyle sunulabilir. Bölüm 2'de kablosuz sensör ağları konusu kısaca anlatılmıştır. Bölüm 3'te, kablosuz manyetometre kullanılarak araç sınıflandırma tasarımı konusu ve düşünülen senaryo açıklanarak sistem gerçekleştirimi ve önerilen algoritma ile elde edilen bulgular detaylı şekilde anlatılmaktadır. Kullanılan makine öğrenmesi algoritması, araç sınıflandırma sonuçları ve önerilen ilk yöntemin eniyilemesi bölüm 4'te anlatılmıştır. Son olarak deneysel sonuçlar ve sistem analizi bölüm 3 ve 4'teki elde edilen sonuçlarla birlikte bölüm 5'te özetlenmiştir. Bölüm 6 ise çalışma süresince yararlanılan kaynakları sunmaktadır.

2 Kablosuz sensör ağları

Kablosuz sensör ağı, bulunduğu ortamdan sahip olduğu yetenekler neticesinde veriler toplayan ve bu verileri işleyerek diğer sensör düğümleri üzerinden merkez istasyona ileten sensör düğümlerinin oluşturduğu bir dağıtık ağ yapısıdır. Kablosuz iletişimdeki gelişmelerle birlikte işlemci kalitesi, hafıza kapasitesi, düşük güç tüketimi gibi konulardaki ilerlemeler, mikro elektromekaniksel sistemlerin önemini

artırmıştır. Küçük boyuttaki cihazlarla kurulan sensör ağları az maliyetli olmuş, sensörlerin birbiriyle haberleşmesi kolaylaşmıştır. Sensör düğümleri değişik bölgelerde rastgele veya belli bir stratejiye göre yerleştirilerek çevresindeki belirlenen kriterlere göre değerleri algılama, toplama, hesaplama, yönlendirme gibi karmaşık işlemlere sahiptir. Bu şekilde ortamdaki değerleri doğru ve hassas bir şekilde elde edip çeşitli bilgiler elde edilmektedir. Bu anlamda sensörler farklı görevlere sahip olup bazıları ana sensör olarak diğer sensörlerden gelen ham verileri işleyerek belirli zamanlarda kullanılmak üzere geçici olarak dahili hafızalarında saklarlar. Kablosuz sensör ağlar, ev uygulamaları, endüstri, fiziksel çevre, askeri alan, hastane gibi hemen her yerde isteğe bağlı kullanılabilirler. Kablosuz sensör ağları çalışabilmek için markette satılan, TelosA, TelosB, mica2, micaZ, eMote, IMote2, Sensenode gibi birçok sensör düğüm çeşidi mevcuttur [13]-[15].

Kablosuz sensör düğümler Zigbee haberleşme standardını kullanır. Zigbee, az miktarda veri transferi, düşük güç kullanımı gibi parametreler bakımından wi-fi, bluetooth veya wimax gibi kablosuz iletişim standartlarından üstündür [16],[17]. Tablo 1 bu farkları açıkça göstermektedir. Ek olarak Zigbee, geniş bant yönetimi ve kullanımı, ölçeklenebilir olması, kendi kendine organizasyon kabiliyetiyle 6LoWPAN, ISA100.11a ve Wireless Hart gibi kablosuz sensör haberleşme standartlarından daha üstündür [13],[18]-[20].


Tablo 1: ZigBee ve birkaç kablosuz standartların kıyaslanması [15].

Özellik	GPRS/ GSM	Wi-Fi	Bluetooth	ZigBee
Odaklanma alanı	Geniş alan ses ve veri	Web, email, Video	Kablo yerine	İzleme ve Kontrol
Sistem Kaynağı	16 Mb+	1 Mb+	250Kb+	4-32 Kb
Pil Ömrü (gün)	1-7 Gün	0.5-5	1-7	100- 1000+
Ağ Boyutu	16 Mb+	32	7	~ Sınırsız (2 ⁶⁴)
Ağ veri genişliği (kb/sn.)	64 - 128+	11000-54000	720	100- 1000+
Kapsama Alanı (m)	1000+	1-100	1-10+	1 - 100+

3 Kablosuz manyetik sensörler kullanılarak araç sınıflandırma sisteminin tasarımı

Manyetik sensörlerin kullanılmasının esas temeli manyetik kuvveti veya alan verisini hesaplamaya dayalı değildir [21]-[23]. Araç tespiti yapmak, aracın hızlanmasını[24]-[26] saptamak veya manyetik arkin var olduğunu tespit etmek gibi çokça sebebi de vardır. Bu amaçları yerine getirebilmek için sensörlerden doğrudan ölçüm yapılamaz veya belli ölçütlerle doğru sonuca varılamaz [27]. Ancak bu bilgiler manyetik alandaki bozulmalar ya da değişiklikler yoluyla çıkarılabilir. Şekil 1'den de anlaşılacağı gibi sıcaklık, basınç, ışık ve gerilim gibi aşına olunan sensörler arzu edilen kriteri doğrudan potansiyel farka veya akıma çevirebilir [28],[29]. Ayrıca, manyetik düğümler yön, açı veya elektriksel akımları doğrudan algılayamazlar. Önce, verilen giriş ile ortaya çıkan veya farklılaşan manyetik veri oluşur [30]-[34]. Bakır kablunun bünyesindeki akım veya demir içerikli obje, yerin manyetik kuvvet veya alanındaki değişime neden olur. Manyetik sensör manyetik alan farkları tespit ettiğinde çıkış işaretinin arzu edilen argüman değerine çevrilmesi için işaretleme etabından geçmesini gerekir. Bu işlem


manyetometrenin birçok uygulama alanında kullanılmasını zorlaştıran süreçtir. Ancak bu değişim nedenlerinin iyi analiz edilmesi, doğru ve verimli sonuçlar edilmesini kolaylaştırabilir [18],[34].




Şekil 1: Geleneksel sensör ve manyetik algılama.

Şekil 2’de görülen sensör ise 3 eksende(x,y,z) ölçüm yapabilen ve veriyi seri iletişim yoluyla işlemciye aktarabilen HMC5983L manyetometredir. Bu sensör -8 ile +8 gauss aralığında manyetik alanı ölçebilme yeteneğine sahiptir. Şekil 3’te görülebilen güç kartı devresi ve güç kaynağı (AA pil) kullanılmıştır. Her 3 eksen için manyetik kuvvet, her bir X, Y ve Z veri kaydedicilerindeki 16 bitlik manyetik verinin en önemli 8 biti desimal (onluk) tabandaki değere çevrilmesiyle oluşur. Manyetik kuvvet değeri (C) denklem (1) sayesinde elde edilir [18],[31].

$$C = \sqrt{X^2 + Y^2 + Z^2} \quad (1)$$



Şekil 2: HMC5983L manyetik sensör entegresi.

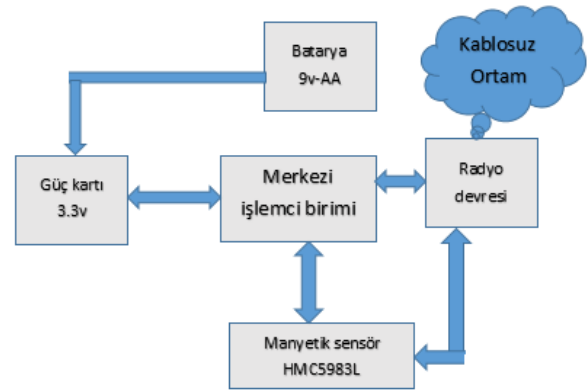


Şekil 3: Araç sınıflandırması için sensör devresi.

Elde edilen C değeri 256 değerine bölündüğünde gauss türünden manyetik kuvvet değeri elde edilmiş olunur. Örnek vermek gerekirse C değeri 290 ise o ortamın manyetik alanı yaklaşık 1.13 gauss olarak bulunabilir. HMC5983L manyetik sensör ile araç sınıflandırma yapılırken ilgili C değeri

kullanılmıştır. Herhangi bir trafikte araç yolun kenar bölümüne veya orta kısmına yerleştirilen bu sensör entegresinin yakınlarından geçtiğinde, C değeri önceden belirlenmiş eşik değerin üzerinde hesaplanır ve o zamanda yolda araç olduğu anlaşılabilir. Manyetik bileşke kuvvet değeri, farklı yerlerde değişmekle ve metal bir nesne yaklaştırıldığında sayısal değeri değişmektedir. Bu şekilde sensörün etrafındaki metal nesnelere algılanabilir.

Bu çalışmada araç sınıflandırma uygulaması için kurulan sensör devresi, güç kartı ve batarya ile bütünlük yapıyla Şekil 3’te, blok şeması ise Şekil 4’te sunulmaktadır. Sensör düğümü, Zigbee IEEE 802.15.4 standardında, 2.4 GHz ISM bandında çalışabilen, az miktarda veri alışverişi yapabilen, az maliyetli ve çok az enerji tüketen kablosuz sensör düğümüdür [18],[31].



Şekil 4: Sensör devresinin blok şeması.

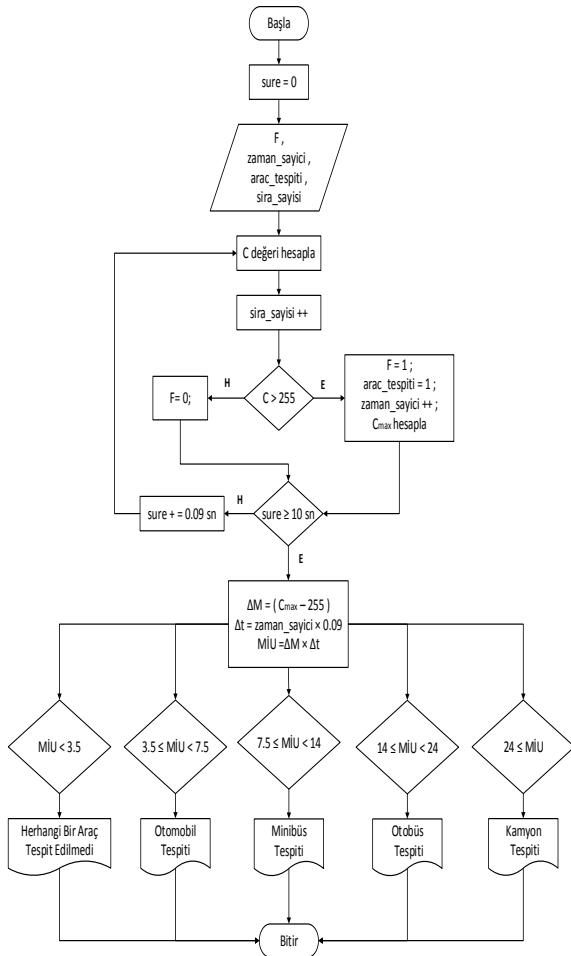
Bu bölümde, çalışma yapılan yolda geçen araçların cinsi otomobil, minibüs, otobüs ve kamyon olmak üzere 4 kategoride tespit edilmiştir. Bu tespiti yapmak amacıyla yolun ortasına 1 adet kablosuz sensör düğümü yerleştirilmiştir. Önceki bölümde kullanıldığı gibi bu çalışmada da manyetik bilgi ve manyetik bileşke kuvvet (C) değeri esas alınmıştır. Araç sınıflandırması yapabilmek için yolda araç yokken 100 adet ölçüm alınıp, elde edilen söz konusu C değerlerinin ortalaması alınmıştır. Elde edilen ortalama değer araç var olup olmadığını anlaşılması için eşik değeri olarak kullanılmıştır. Eşik değeri C_{esik} olarak adlandırılmış ve değeri 255 olarak hesaplanmıştır. Bir başka anlamda, bilindiği üzere yolda yüklü miktarda metal kütlesi bulunmadığı sürece ölçülen C_{esik} 255 olarak belirlenmiştir. Ancak yoldan geçen herhangi bir araç sensör devresine yaklaştığı anda söz konusu C değeri bu değerin dışına çıkmaktadır.

Bu çalışmada araç sınıflandırması yapmak için manyetik işaret uzunluğu (MIU) önerilmiştir. MIU , manyetik genlik farkı (ΔM) ve aracın sensörle geçen kapsama süresi (Δt) ile denklem (2)’deki şekilde hesaplanır.

$$MIU = \Delta M \times \Delta t \quad (2)$$

ΔM , hesaplanan manyetik bileşke kuvvet değeri ile önceden tespit edilen eşik değeri arasındaki farktır. Δt ise aracın sensör devresinin kapsama alanında kaldığı süredir. Bu süre, sensör programında tanımlanan zaman_sayici değeri ile 90ms’nin çarpımından oluşmaktadır. Çünkü gecikme metodu olarak ölçüm, 90 ms belirlenmiştir. MIU büyüklüğüne göre aracın türü otomobil, minibüs, otobüs ve kamyon olmak üzere sınıflanabilmektedir. Aracın boyutuna ve içerisinde veya dış bölümünde ihtiva ettiği metal miktarına göre fark etmektedir.

Sayıları eşit ancak karışık olarak otomobil, minibüs, otobüs ve kamyon olmak üzere 100 adet araç, yoldaki sensörden geçirilmiş ve elde edilen sonuçlara göre MIU değerlerinin ortalaması alınıp sınıflandırma için sınır değerleri belirlenmiştir. Bu değerlerin hesaplanmasında önemli kriterler, manyetik sensör düğümünün 0.5 ile 0.75 m arasında kapsama aralığı ve farklı türdeki araçların uzunluğunun birbirinden farklı olmasıdır [31]. Araç sınıflandırması uygulaması yapabilmek için yolun ortasına 1 adet sensör devresi yerleştirilmiştir. Manyetik sensör, sensör düğümünün I^2C portuna bağlanmıştır. Sensör düğümü bir uç düğüm olduğu dikkat edilirse edindiği manyetik alan verisini koordinatör düğüm olarak kodlanmış düğümüne iletmektedir. Uç düğüm, x, y ve z eksenlerindeki manyetik veriyi program yardımıyla manyetik bileşke kuvvete dönüştürüp bu değeri her 0.09s'de koordinatör düğümüne iletmektedir. Yani toplayıcı düğüm, seri port yazılımı olan Tera Term'e her 90 ms'de bir C değerini iletmektedir. C değeri C_{esik} 'den büyükse araç tespiti yapılmış anlamına gelmekle birlikte zaman_sayici değişkeninin değeri 1 artmaktadır. Araç tespiti yapıldığı anlamına gelen bayrak (F) değeri de "1" olarak kodlanmaktadır. Sıra_sayisi değişkeni ise kaçınıcı ölçüm yapıldığı bilgisini vermektedir. Şekil 5, araç tespiti için belirlenen algoritmanın akış diyagramını göstermektedir.



Şekil 5: Araç sınıflandırması için belirlenen algoritmanın akış diyagramı.

Araç sınıflandırması gerçekleştirmek için ilk olarak Fırat Üniversitesi Mühendislik kampüsündeki bir yolda 40 km/s sabit hızda hareket eden bir otomobil Şekil 6a'daki gibi

geçirilmiştir. Diğer araçların sensör düğümünün yakınından geçişleri minibüs, otobüs ve kamyon olmak üzere sırasıyla Şekil 6b, 6c ve 6d'de verilmiştir.



(a): Otomobil.



(b): Minibüs.



(c): Otobüs.



(d): Kamyon.

Şekil 6: Araçların sensör düğümünün yakınından geçişleri.

Bununla birlikte araçların hızı V olduğu düşünülürse manyetik işaret uzunluk değeri $MIU = \Delta M \times \Delta t \times V$ olarak hesaplanır. Buna göre araç sensörün yanından daha hızlı geçtiğinde Δt süresi kısalmış ve MIU değeri değişmez. Benzer olarak V azalırsa Δt süresi artar ve yine MIU değeri değişmez. Daha açıkça ifade etmek gerekirse $MIU = \Delta M \times \Delta t \times V$ denklemindeki $\Delta t \times V$ ifadesi, aracın sensörün kapsama alanında aldığı D_V yoludur. Yani yapılan çalışmada manyetik işaret uzunluk değeri $MIU = \Delta M \times D_V$ olarak düşünülmektedir. Bu sayede araçların

hızı değişken olduğunda bahsedildiği üzere MIU değeri değişmez. Bu çalışmada manyetik işaret uzunluk değeri $MIU = \Delta M \times \Delta t$ olarak hesaplanıp kullanılmıştır. Yani Δt değeri D_V olarak varsayılp kullanılmıştır.

HMC5983L manyometrik sensör, her 90 ms'de elde ettiği verileri koordinatör düğümüne göndermektedir. Bu periyodik sürenin kısaltılmasıyla, manyetik dalga verilerin örnekleme sayısının artacağı söylenebilir. Söz konusu veriler Tera Term logger bölümünde tutulduğu için bu veriler Matlab yazılımında veri çıkarma yöntemi ile veriler içerisinde sadece C değerleri seçilip bu değerler her 90 ms için Matlab yazılımında Şekil 7a'daki şekilde çizilmiştir. Fakat, aracın var olduğu zaman aralığı ve C verilerinin net olarak sunulabilmesi bakımından zaman ekseninde 2 ile 5. sn. aralığındaki veriler çizdirilmiştir.

Şekil 7a'dan da görülebileceği üzere Δt süresince araç tespiti 6 adet örnek ile tespit edilmiştir. Aslında zaman_sayici değişkeninin değeri 6 olmuştur. Her 0.09 sn.'de bir örnekleme alındığı için Şekil 6'daki algoritmaya göre; $\Delta t = 0.09 \times 6 = 0.54$ sn. olduğu bulunur. Ayrıca, otomobil sensör düğümünün yakınından geçerken en yüksek C değeri 262 ve C_{esik} 'de 255 olduğu bilindiğine göre; $\Delta M = 262 - 255 = 7$ olarak bulunur. Bu bilgilere göre bu otomobil için saptanan manyetik işaret uzunluğu (MIU) denklem (2)'e göre; 3.78 olarak elde edilmiştir. Hesaplanan MIU değerinin birimsel değeri önemli değildir. Ayrıca, bu değer minibüs veya otobüs için artmaktadır.

İkinci uygulama olarak minibüs için ölçüm yapılmıştır. Dikkat edilirse otomobil ve minibüs arasında araç uzunluğu açısından fazla fark olmadığı için araçların sensör devresinden geçerken oluşan meşgulliyet süreleri benzer olmuştur. Ancak, minibüs daha fazla metal malzemesinden oluştuğu düşünülürse

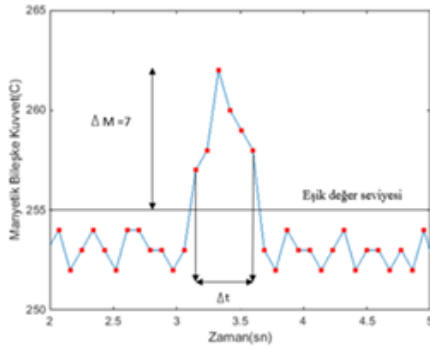
manyetik genlik farkının otomobile nispeten daha yüksek olduğu sebebi anlaşılabilir. Minibüs, otobüs ve kamyon içinde aynı uygulama gerçekleştirilmiştir. Otobüs tiplerinin uzunluğu 7-9 m arasında değiştiği düşünülürse elde edilen meşgulliyet süresinin otomobil veya minibüse göre daha yüksek olmasının nedeni anlaşılabilir.

Kamyon sınıflandırması yapıldığında elde edilen en önemli sonuç, kamyon ile otobüs ölçümlerindeki manyetik genlik farkının benzer ancak meşgulliyet sürelerinin farklı oluşudur.

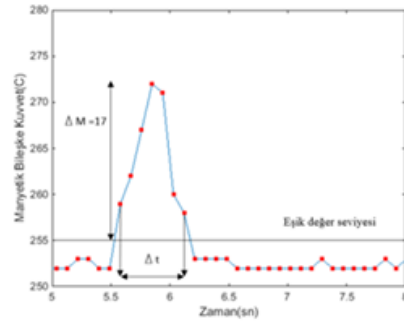
Ölçüm yapılan kamyonun uzunluğu otobüsten daha uzun olduğu için aracın sensör düğümü kapsama alanındaki meşgulliyet süresi kamyon için daha fazla olmuştur.

Tablo 2 farklı tipte 100 adet araç için sınıflandırma ve tanımanın önerilen sınıflandırma algoritması için doğruluk oranlarını göstermektedir. Tablo 2'ye göre, en yüksek doğruluk kamyonlarda en düşük doğruluk ise minibüste olmak üzere sırasıyla %96 ve %84 olarak elde edilmiştir. Tablo 2'den de görüldüğü üzere sadece 1 kamyon tespit edilemeyerek yanlış sonuç alınmıştır. Yapılan çalışmada, kamyon gibi hem boyutça büyük hem de metal bakımından zengin araçlarda daha belirgin, hassas ve doğru sonuçlar edinilmiştir. Ayrıca, tüm araçlar göz önünde bulundurulduğunda ortalama olarak %89 gibi yüksek bir doğruluk oranıyla karşılaştırıldığı söylenebilir.


Tüm araç tiplerine ait elde edilen veriler Tablo 3'te özetlenmiştir. Bu veriler her araç tipine ait elde edilen MIU değerleridir. Bu değerler esas olarak her bir araç tipi için 25 örnek değerlendirilmiş ve toplam 100 örnek için ölçülen ve hesaplanan ortalama MIU değerleri Tablo 4'te verilmiştir. Bu değerler göz önünde bulundurularak araç sınıflandırması yapılmış ve Tablo 2'deki sonuçlar ortaya çıkmıştır.




(a): Otomobil.



(b): Minibüs.



(c): Otobüs.



(d): Kamyon.

Şekil 7: Araç türlerine göre elde edilen manyetik bileşke kuvvet-zaman grafiği.

Tablo 2: Önerilen araç sınıflandırma algoritmasına göre doğruluk sonuçları.

Araç Tipi	Geçen Araç Sayısı	TESPİT EDİLEN ARAÇ SAYISI				ÖNERİLEN ALGORİTMANIN DOĞRULUĞU
		Otomobil	Minibüs	Otobüs	Kamyon	
Otomobil	25	22	3	0	0	%88
Minibüs	25	1	21	3	0	%84
Otobüs	25	0	1	22	2	%88
Kamyon	25	0	0	1	24	%96
Toplam araç sayısı	100	22	21	22	24	%89

89

Tablo 3: Araç tiplerine ait elde edilen sonuçlar.

Araç Tipi	ΔM	$\Delta t(\text{sn})$	MIU
Otomobil	7	0.54	3.78
Minibüs	17	0.63	10.71
Otobüs	23	0.81	18.63
Kamyon	25	1.26	31.5

Tablo 4: Araç tiplerine ait ortalama MIU değerleri.

Araç Tipi	Araç Sayısı	Ortalama MIU
Otomobil	25	4.57
Minibüs	25	9.85
Otobüs	25	21.24
Kamyon	25	30.25

4 J48 Makine öğrenmesi algoritması ile önerilen yöntemin eniyilemesi

Bu çalışmadaki ikinci yöntem ise, makine öğrenme algoritması kullanarak ilk önerilen yöntemin sonuçlarının eniyilenmesidir. Bir çalışma yapılırken kullanılacak en uygun makine öğrenme algoritmasının seçilmesi çok önemlidir. Bu seçimi yaparken kontrollü makine öğrenme sınıflandırma probleminin çözümüyle uğraşmıştır. Farklı otomobiller için dört farklı sınıf oluşturulmuştur. Algoritma seçimi için birçok seçenek var olmasına rağmen karar ağacı seçilmiştir. Bir karar ağacı tabanlı makine öğrenme algoritması kullanılmasının nedeni, uygulanması ve hesaplama verimliliği açısından basit olmasıdır. Bir karar ağacı kodu iç içe geçmiş if-döngüler kullanarak kolayca uygulanabilir ve sınıflandırma için nispeten hızlı olur. Kullanılan özelliklere bağlı olarak, hesaplama zamanının çoğu, karar ağacında kullanılan özelliklerine göre ağacınkinden daha fazla olabilir. Karar ağacı algoritması için kaba kuvvet yöntemini kullanarak en iyi özellikler hesaplandı. Sınıflandırma algoritması için Weka kütüphanesini kullanıldı. Sınıflandırma algoritması için J48 karar ağacı yöntemi kullanılmıştır. J48, kendi içinde ID3 karar ağacı algoritmasının bir uzantısı olan Quinlan'ın C4.5 algoritmasının açık kaynaklı bir Java uygulamasıdır. ID3 ve C4.5 en uygun ağacı belirlemek için iki kavram kullanır. Birincisi entropi, ikincisi bilgi kazancıdır. İlk entropi denklemi, bilgi kazanımı hesaplamasının iki ayrı seviyesinde kullanılan özyinelemeli bir denklem olan denklem (3)'te açıklanmaktadır. Bu ilk durumda, $|C|$ sınıfların sayısı, $|S|$ toplam eğitim örneği sayısıdır ve son olarak $|C_i|$ belirli sınıftaki eğitim örneklerinin sayısıdır [33].

$$H(S) = - \sum_{i=1}^{|C|} \frac{|C_i|}{|S|} \log_2 \left(\frac{|C_i|}{|S|} \right) \quad (3)$$

Daha sonra, ikinci bir entropi hesaplaması, denklem (4)'te tarif edildiği gibi gerçekleştirilmelidir. T_i belirli bir özelliğin elemanlarının sayısı terimi ve son olarak $|T|$ tüm örneklerin veya alt kümedeki toplam özneliklerin sayısıdır. Buna ek olarak, bu ikinci entropi denklem (3)'teki birinci entropi

hesaplamasını gerektirir. Bu ikinci durumda, $|C|$ belirli bir özelliğin içinde olabileceği durumların sayısıdır ki biri durum özneliği var olduğunda veya olmadığına olmak üzere genelde 2'dir. $|S|$, T_i 'ye eşittir ve $|C_i|$ belirli bir özellik ve duruma ilişkin ölçütleri karşılayan örnek sayısına eşittir.

$$H_a(S) = \sum_{i=1}^{|C|} \frac{|T_i|}{|T|} \text{info}(T_i) \quad (4)$$

Son olarak, denklem (3) ile denklem (4) çıkarılarak, bilgi kazanımını sınıflara ve denklem (5) 'te gösterilen tek bir özneliğe göre üretebilir.

$$IG(S) = H(S) - H_a(S) \quad (5)$$

Denklem 5'in çok önemli olmasının nedeni her nitelik için en yüksek bilgi kazanımı hesaplamak hangi özneliğin karar ağacında en iyi çataları sağlayacağını söylemesidir. Her bir çatalda, bilgi kazanımı, ağacın o dalında kalan örneklerle yeniden hesaplanmalıdır. Örneğin, 100 örnekle başlarsak, en yüksek bilgi kazanımı, örnekleri 40 ve 60 gruplarına bölerek, ancak bir grup birden fazla fazla olası sınıf içerdiğinde, bilgi kazanımı yeniden hesaplanması gereken yerlerde başka bir çatal oluşturulur. Ağaç, her bir dal mümkün olan tek bir sınıfa ulaşana kadar, karar çemberi modelin tamamlandığı noktada, her çatalı için bilgi kazancı hesaplamaya devam eder. Sayısal değerler söz konusu olduğunda, sayıların tümü en azından en büyük sıraya göre sıralanır ve iki gruba ayrılır. Bilgi kazancı, sıralı 25 setinin bölme noktasında belirlenen potansiyel eşik değeri ile sayıların iki grubu arasında hesaplanır. Bölünme noktası, iki grup arasında herhangi bir sayıda seçilebilir. Bu nedenle, öznelik kümesi n tekrarlanmayan sayısal öğeler içeriyorsa, n-1 bilgi kazanç hesaplamaları tamamlanmalıdır. En büyük bilgi kazanımına sahip eşik değeri, o çatalda koşullu olacak şekilde seçilir. Eşik değerden büyük olan tüm rakamlar bir şube alır, aksi halde diğerini alır [33],[34].

Bu yöntem kullanılarak, otomobil, minibüs, otobüs ve kamyon sınıfı olmak üzere 4 adet sınıf oluşturulmuştur. Ayrıca "class" adlı bir sınıf ise elde edilen örneklerin saptanan eşik değeriyle kıyaslanarak doğru sınıfa ait olup olmadığını göstermesi için kullanılmıştır. Weka'da her bir sınıf için 25 adet ölçüm sonuçları örnekleme olarak seçilmiş ve toplamda 100 örnek kullanılmıştır. Yani $|C|$ 5, $|S|$ ise toplamda 100 örnek değerine sahip olmuştur. Şekil 8 Weka'da oluşturulan sınıflama örneklerini göstermektedir. Şekil 8'den de görüleceği üzere J48 algoritmasına göre karar ağacı çalıştırılmıştır.

Ayrıca, Weka Explorer'da "Classify" menüsünden karar ağacı çalıştırıldığında Şekil 9'daki görüntü elde edilmektedir. Şekil 9'da açıkça görülmektedir ki belirlenen eşik değere göre doğru bir şekilde sınıflandırma %96 olarak tespit edilmiştir. Ayrıca ortalama mutlak hata ise 0.0792 olarak bulunmuştur. Makine öğrenmesi algoritmasına göre minimum, maksimum, ortalama (mean) ve standart sapma (StdDev) değerleri olmak üzere araç türlerine ait sınır değerleri Tablo 5'te verilmiştir.

```

=== Run information ===

Scheme:          weka.classifiers.trees.J48 -C 0.25 -M 2
Relation:        weka.datagenerators.classifiers.classification.RDGI-S_1_
Instances:       25
Attributes:      5
                class
                otomobil
                minibus
                otobus
                kamyon
Test mode:       evaluate on training data

=== Classifier model (full training set) ===

J48 pruned tree
-----
: c1 (25.0/1.0)

Number of Leaves :    1

Size of the tree :    1

Şekil 8: Araç türlerinin sınıflandırılması.

Test mode:         10-fold cross-validation

=== Classifier model (full training set) ===

J48 pruned tree
-----
: c1 (25.0/1.0)

Number of Leaves :    1

Size of the tree :    1

Time taken to build model: 0.02 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      24   96 %
Kappa statistic                     0
Mean absolute error                 0.0792
Root mean squared error             0.2043
    
```

Şekil 9: Araç sınıflandırılmasının doğruluk gösterimi.

Tablo 5: Makine öğrenmesi algoritmasına göre araç türlerine ait sınır değerleri.

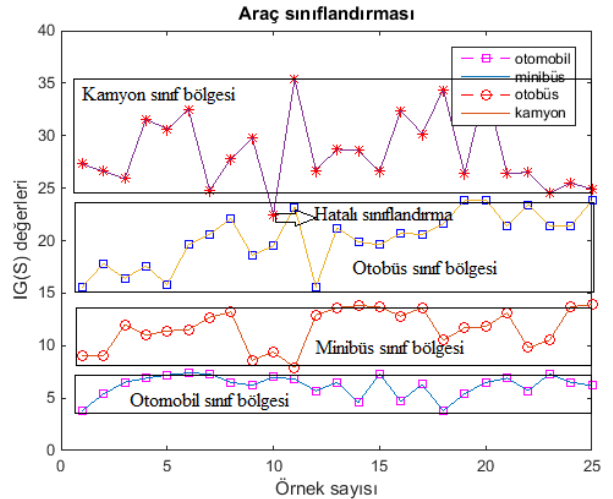
Parametreler	Araç Tiplerine Ait Sınır $IG(S)$ Değerleri			
	Otomobil	Minibüs	Otobüs	Kamyon
Minimum	3.8	7.9	15.6	24.5
Maksimum	7.4	13.9	23.9	35.4
Ortalama	6.175	11.644	20.204	28.612
Standart sapma	1.053	1.864	2.605	3.279

Bu yöntemle daha optimum eşik değer ve limit değerleri elde edilmiştir. Tüm örnekler incelendiğinde kamyon sınıfına ait bir ölçüm değeri (örnek değeri) hatalı tespit edilmiştir. Bu değere (22.5) sahip araç otobüs sınıfına dahil olması gerekirken kamyon sınıfında görülmektedir. "Class" sınıfında bu örnek değeri "c0" olarak kaydedilmiştir. Bu değer "false" değerini geri döndürmektedir. Şekil 10 bu hatalı tespiti sarı renkle izah ederek göstermektedir. Kamyon sınıfının minimum değeri 24.5 olmasına karşın 22.5 değeri tespit edilmiştir.

No.	1: class Nominal	2: otomobil Numeric	3: minibus Numeric	4: otobus Numeric	5: kamyon Numeric	
2	c1		5.4	9.0	17.8	26.6
3	c1		6.5	12.0	16.4	25.9
4	c1		6.9	11.0	17.6	31.6
5	c1		7.2	11.4	15.8	30.6
6	c1		7.4	11.5	19.6	32.5
7	c1		7.3	12.7	20.6	24.8
8	c1		6.5	13.2	22.1	27.8
9	c1		6.2	8.6	18.6	29.8
10	c0		7.0	9.4	19.5	22.5
11	c1		6.8	7.9	23.2	35.4
12	c1		5.7	12.9	15.6	26.7
13	c1		6.5	13.6	21.2	28.7
14	c1		4.6	13.8	19.9	28.6
15	c1		7.3	13.7	19.6	26.6
16	c1		4.7	12.8	20.7	32.4
17	c1		6.3	13.6	20.6	30.2
18	c1		3.8	10.5	21.6	34.4
19	c1		5.4	11.7	23.8	26.4
20	c1		6.5	11.8	23.9	34.7
21	c1		6.9	13.1	21.4	26.4
22	c1		5.7	9.8	23.4	26.5
23	c1		7.3	10.5	21.4	24.5
24	c1		6.5	13.7	21.4	25.5
25	c1		6.2	13.9	23.8	24.9

Şekil 10: Araç sınıflandırılmasının sonucu.

Şekil 11 ise araç sınıflandırmasında 25 örnek için elde edilen sınıf bölgelerini ve $IG(S)$ değerlerini grafiksel olarak sunmaktadır. Şekil 11'den de açıkça görüldüğü üzere 4 adet sınıflandırma bölgesi oluşturulmuştur. Ancak kamyon sınıfına ait olması gereken bir değer otobüs sınıfına dahil olmuştur. Makine öğrenmesiyle yapılan araç sınıflandırmasında otomobil, minibüs ve otobüs için %100 doğruluk olmasına karşın kamyon için %96 doğruluk payı elde edilmiştir. Sonuç olarak ortalama %99 gibi doğruluk payı göz önünde bulundurulduğunda; daha önceki bölümde anlatılan yöntem kullanılarak araç sınıflandırması uygulamasında elde edilen doğruluk oranından (%89) oldukça yüksek olduğu anlaşılmaktadır.



Şekil 11: Sınıflama bölgeleri.

5 Sonuçlar

Bu çalışmada, trafikte hareket eden araçlar otomobil, minibüs, otobüs ve kamyon olmak üzere 4 seviyede kategorize edilmiştir. Bu şekilde sınıflandırma işlemi yapılırken MIU parametresi önerilmiş ve kullanılmıştır. Bu yöntemde belirlenen sınıflandırma için sınır değerleri, tüm ölçümlerde elde edilen değerlerin ortalaması olduğu için hesaplama zorluğu ortaya çıkmaktadır. Oysaki makine öğrenmesi algoritmalarından olan J48 algoritması ile karar ağacı modelini

oluşturmak için yeterli eğitim örnekleri verildiğinde araç sınıflandırmanın eniyilemesiyle %100'e yakın son derece yüksek oranlara erişebildiği görülmüştür. Saptanan sınır ve eşik değerler, sınıflandırma için daha doğru sonuçlar doğurmuştur. Çalışmanın sonuçları değerlendirildiğinde, makine öğrenmesi algoritması kullanılarak araç sınıflandırması yapmanın daha doğru ve verimli kararlar doğuracağı anlaşılmaktadır. Yolda uygulama yapılırken çokça araç kullanılarak örnekler alınmış ve önerilen algoritmanın önceki çalışmalara göre daha verimli ve doğru sonuçlar doğurduğu tespit edilmiştir. Bu çalışmanın en değerli özellikleri, araç sınıflandırma sistem tasarımının basit, önceki çalışmalara göre daha dinamik içerikli olması ve önerilen metod ve algoritmaların doğru çıktılar oluşturmasıdır. Gelecek çalışmalarda, araç sınıflandırması yapabilmek veya aracın diğer özelliklerini belirleyebilmek için hem makine öğrenmesi hem de yapay zekâ teknikleriyle bütünlüklü algoritmalar önerilmesi düşünülmektedir.

6 Kaynaklar

- [1] Haoui A, Kavalier R, Varaiya P. "Wireless magnetic sensors for traffic surveillance". *Transportation Research Part C: Emerging Technologies*, 16(3), 294-306 2008.
- [2] Lei Z, Wang R, Cui L. "Real-time traffic monitoring with magnetic sensor networks". *Journal of information science and engineering*, 27(4), 1473-1486 2011.
- [3] Gil Jimenez VP, Fernandez JM. "Simple design of wireless sensor networks for traffic jams avoidance". *Journal of Sensors*, 2015(1), 1-7 2015.
- [4] Nooralahiyan AY, Kirby HR, McKeown D. "Vehicle classification by acoustic signature". *Mathematical and Computer Modelling*, 27(9), 205-214 1998.
- [5] Jo Y, Jung I. "Analysis of vehicle detection with wsn-based ultrasonic sensors". *Sensors*, 14(8), 14050-14069 2014.
- [6] Leitloff J, Rosenbaum D, Kurz F, Meynberg O, Reinartz P. "An operational system for estimating road traffic information from aerial images". *Remote Sensing*, 6(11), 11315-11341 2014.
- [7] Barbagli B, Manes G, Facchini R, Manes A. "Acoustic sensor network for vehicle traffic monitoring". *1st International Conference on Advances in Vehicular Systems, Technologies and Applications*, Venice, Italy, 24-29 June 2012.
- [8] Chen W, Chen L. "A Realtime dynamic traffic control system based on wireless sensor network". *In Proceedings of the 2005 International Conference on Parallel Processing Workshops (ICPPW'05)*, Oslo, Norway, 14-17 June 2005.
- [9] Nadeem T, Dashtinezhad S, Liao C, Iftode L, "TrafficView: a scalable traffic monitoring system". *IEEE International Conference on Mobile Data Management (MDM'04)*, Berkeley, USA, 19-22 January 2004.
- [10] Ng EH, Tan SL, Guzman JG. "Road traffic monitoring using a wireless vehicle sensor network". *International Symposium on Intelligent Signal Processing and Communication System*, Bangkok, Thailand, 8-11 December, 2008.
- [11] Haijian L, Honghui D., Limin J. Moyu R. "Vehicle classification with single multi-functional magnetic sensor and optimal MNS-based CART". *Measurement*, 55(2), 142-152 2014.
- [12] Lifu W, Nong Z, Haiping D. "Real-time identification of vehicle motion-modes using neural networks". *Mechanical Systems and Signal Processing*, 51, 632-645 2015.
- [13] Dogan R, Erdem E. "Temperature and humidity control of the tunnels in the dam using wireless sensor networks". *19th International Conference on Intelligent Engineering Systems*, Bratislava, Slovakia, 3-5 September 2015.
- [14] Cheung SY, Coleri S, Dundar B, Ganesh S, Tan CW, Varaiya P. "Traffic Measurement and Vehicle Classification with a Single Magnetic Sensor". California PATH Research Report UCB-ITS-PWP-2004-7 2004.
- [15] Vancin S, Erdem E. "Design and simulation of wireless sensor network topologies using zigbee standard". *International Computer Networks and Applications*, 2(3), 135-143 2015.
- [16] Mihajlov B, Bogdanoski M. "Overview and analysis of the performances of Zigbee based wireless sensor networks". *International Journal of Computer Applications*, 29(12), 28-35 2011.
- [17] Wang X, Zhang S. "Comparison of several sensor deployments in wireless sensor networks". *International Conference on E-Health Networking, Digital Ecosystems and Technologies*, Shenzhen, China, 2010.
- [18] Vancin S, Erdem E. "Kablosuz manyetik sensör ağlarında adaptif eşik değer algoritmasıyla araç tespitinin gerçekleştirilmesi". *International Artificial Intelligence and Data Mining Symposium*, Inonu University, Malatya, Turkey, 17-18 September 2016.
- [19] Gans JS, King SP, Wright J. *Wireless communications*. ISBN:0444514236, Handbook of Telecommunications Economics, 2005.
- [20] Chang K. *RF and Microwave wireless systems*. ISBNs: 0-471-35199-7, John Wiley & Sons, Ltd 2000.
- [21] Karasulu B, Tokel L, Korukoğlu S. "ZigBee - IEEE 802.15.4 Standard based wireless sensor networks". *Int. Conf., Information Univ., İstanbul, Turkey* 2009.
- [22] Markevicius V, Navikas D, Daubaras A, Cepenas, ZMM, Andriukaitis D. "Vehicle influence on the earth's magnetic field changes". *Elektronika IR, Elektrotehnika*, 20(4), 43-48 2014.
- [23] Ciureanu P, Middelhoeck S. *Thin Film Resistive Sensors*. 1st ed. New York, USA, CRC Press, 1992.
- [24] Jonasson C, Erlandsson M, Johansson C. "Magnetic Sensors for Traffic Detection". IMEGO, Technical Report, Sweden 2006.
- [25] Jo Y, Jung I. "Analysis of vehicle detection with wsn-based ultrasonic sensors". *Sensors*, 14(8), 14050-14069, 2014.
- [26] Michael JC, Withanawasam LS. "Vehicle detection and compass applications using AMR magnetic sensors". Honeywell, SSEC, 12001 State Highway 55, Plymouth. MN USA 55441 1999.
- [27] Piecha J. "Digital camera as a data source of its solution in traffic control and management". *Transport Problems*. 7(4), 57-70 2012.
- [28] Bottero M, Dalla CB, Deflorio FP. "Wireless sensor networks for traffic monitoring in a logistic centre". *Transportation Research Part C: Emerging Technologies*. 26, 99-124 2013.
- [29] Sifuentes E, Casas O, Pallas-Areny R. "Wireless magnetic sensor node for vehicle detection with optical wake-up". *IEEE Sensors Journal*, 11(8), 1669-1676 2011.

- [31] Zhou JC, Chen LP, Chen L. "A small-scale traffic monitoring system in urban wireless sensor networks". *IEEE International Conference on Systems, Man, and Cybernetics (SMC '13)*, Manchester, United Kingdom, 13-16 October 2013.
- [32] Vancin S. Trafik İzleme Sistemlerinin Kablosuz Manyetik Sensörler Kullanılarak Gerçekleştirilmesi. Yüksek Lisans Tezi, Fırat Üniversitesi, Elazığ, Türkiye, 2016.
- [33] Fernández J, Calavia L, Baladrón C. "An intelligent surveillance platform for large metropolitan areas with dense sensor deployment". *Sensors*, 13(6), 7414–7442 2013.
- [34] Ying K, Ameri A, Trivedi A, Ravindra D, Patel D, Mozumdar M. "Decision tree-based machine learning algorithm for in-node vehicle classification". Department of Electrical Engineering, California State University, Long Beach 2015.
- [35] Al-Nasser FA, Mahmoud MS. "Wireless sensors network application: a decentralized approach for traffic control and management in wireless sensor networks". *Technology and Applications*, 16, 347–374 2012.