



## Otonom Araçlarda Nesne Tespiti, Şerit Tespiti, Haritalama ve Konumlandırmaya Yönelik Sensör Füzyon Tekniklerinin Uygulanması

Emre DUMAN<sup>1\*</sup> , Kemal FİDANBOYLU<sup>1</sup> 

<sup>1</sup>Bursa Uludağ Üniversitesi, Bilgisayar Mühendisliği Bölümü, Bursa, TÜRKİYE

### Özet

Trafik kazaları çoğunlukla sürücü hatalarından kaynaklanmaktadır. Otonom araçların bu kazaları önleme potansiyeli sürücünün araç ile olan bağıni kestiğinden dolayı çok yüksektir. Otonom araçlar, çevreyi gözlemlemek için çeşitli sensörler kullanırlar ve çevreyi doğru bir şekilde algılamak ve hataları azaltmak için sensör füzyon algoritmalarından yararlanırlar. Kameralar, radyo ve ışın algılama, mesafe ölçme sensörleri, eylemsizlik ölçüm birimi, küresel konumlandırma sistemi ve ultrasonik sensörler, otonom araçlarda en yaygın kullanılan sensör türleridir. Bu makalede, sensör verilerinin ve bunların füzyonuyla birlikte çeşitli filtreleme teknikleri ile iyileştirilmesi hakkında detaylı bilgi verilecektir. Buna ilaveten, otonom araçlarda nesne tespiti, konum belirleme ve haritalama gibi işlevler hakkında bilgi verilecektir. Ham verilerin Kalman filtresiyle filtrelenmesine dair bir örnek verilecektir. 3 cm hata sapması olan bir sensörden elde edilen verilerdeki hataların filtrelenmesi ile verilerin gerçek değere %98,33 oranında yakınsadığı ve sensör füzyonu ile bu gerçek değere yakınsayan verilerin %99'dan daha yüksek olduğu ve böylece daha da doğru değerler sağladığı gösterilecektir.

**Anahtar Kelimeler:** Otonom Araçlar, Otonom Sürüş, Sensörler, Sensör Füzyonu

### Application of Sensor Fusion Techniques for Object Detection, Lane Detection, Mapping and Positioning in Autonomous Vehicles

#### Abstract

Traffic accidents are mostly caused by driver errors. The potential of autonomous vehicles to prevent these accidents is very high since they disconnect the driver from the vehicle. Autonomous vehicles use various sensors to observe the environment and utilize sensor fusion algorithms to accurately perceive the environment and reduce errors. Cameras, radio and beam sensing, distance measuring sensors, inertial measurement unit, global positioning system and ultrasonic sensors are the most commonly used sensor types in autonomous vehicles. This article will provide detailed information about sensor data and its fusion along with various filtering techniques. In addition, information will be provided about functions such as object detection, location determination and mapping in autonomous vehicles. An example will be given about filtering raw data with Kalman filter. It will be shown that, as a result of filtering the errors in the data obtained from a sensor with 3 cm error deviation, the data converges to the true value by 98.33% and with sensor fusion, the data converging to this true value is higher than 99%, thus providing even more accurate values.

**Keywords:** Autonomous Vehicles, Autonomous Driving, Sensors, Sensor Fusion

#### Makale Bilgisi

Başvuru:  
27/09/2024  
Kabul:  
08/11/2024

\* İletişim e-posta: 502331030@ogr.uludag.edu.tr

## 1 Giriş

Yapılan araştırmalara göre yaşanan trafik kazalarının %94'ü ( $\pm$  %2.2) sürücülerin yaptığı hatalardan, %2'si ( $\pm$  %0.7) araçta oluşan problemlerden ve %2'si ( $\pm$  %1.3) ise ortam koşulları, yani kaygan yol ve kötü hava durumu gibi sebeplerden oluşmaktadır. Öte yandan, sürücülerin sebebiyet verdiği kazaların %41'i ( $\pm$  %2.2) iç ve dış dikkat dağınıklıklarından, %33'ü ( $\pm$  %3.7) aşırı sürattan, %11'i ( $\pm$  %2.7) virajlara süratli girmelerinden, %7'si ( $\pm$  %1.0) ise uykusuzluk gibi sebeplerden kaynaklandığı görülmektedir [1]. Ayrıca, uykusuz araç kullanmanın araçlardaki kaza oranını ciddi oranda arttırdığı görülmektedir [2]. Otonom araç teknolojisi ile %94 gibi büyük bir sürücü hatası sonucu oluşan kaza miktarını insan unsurunu araç kullanma konusunda sınırlayarak ciddi miktarda araç kazalarının sonucunda oluşan ölüm, yaralanma, maddi kayıplar önlenir. Bu teknoloji sayesinde, yaşlı insanların ulaşımı kolaylaşacak, yakıt tüketimi daha optimum olacak ve zehirli egzoz gaz salımı azalacaktır [3]. Birçok firma bu konularda çalışmalarını sürdürmektedir [4].

Otonom araçlar ile ilgili yapılan kapsamlı araştırma ve geliştirmeler [5] konum belirleme, harita oluşturma, nesne tespiti, şerit tespiti, şerit takibi, trafik işareti tespiti, rota optimizasyonu, araç kontrolü, kazalardan ve objelerden kaçınma, adaptif hız sabitleme, başka araçlarla haberleşebilme gibi konuları içermektedir. Bu makalede, otonom araçlarda kullanılan sensörler, nesne tespiti, şerit tespiti, haritalama ve konumlandırmaya yönelik sensör füzyon teknikleri hakkında bilgiler sunulacaktır.

Bu çalışmadaki motivasyon, sensör füzyonunun elde edilen ve ön işleminden geçmiş verilere olan etkisi ve bu etkilerin farklı sensör füzyonu teknikleri uygulandığında daha iyi sonuçlar elde edildiğini kanıtlamaktır. Böylece her uygulamada optimum çalışacak tekniklerin araştırılması ve denenmesi gerektiğinin anlaşılması sağlanmış olacaktır.

## 2 Literatür araştırması

Bu bölümde çeşitli problemlerin çözümlerinin öncesinde genel olarak kullanılan sensörler ve sensörlerin çalışma prensipleri genel olarak anlatılacaktır. Daha sonra, giriş kısmında bahsedilen çeşitli teknikler yani konum belirleme, harita oluşturma, nesne tespiti, şerit tespiti, şerit takibi, trafik işareti tespiti, rota optimizasyonu, araç kontrolü, kazalardan ve objelerden kaçınma, adaptif

hız sabitleme, başka araçlarla haberleşme gibi ihtiyaçların bu sensörler ile çözümleri irdelenecektir.

### 2.1 Otonom araçlarda kullanılan sensör türleri

Otonom araçlarda birçok sensör kullanılmaktadır. Bunlar arasında en yaygın olanlar aşağıda listelenmiştir:

- Kamera
- Monoküler kamera
- Stereo kamera
- Event (Nöromorfik) kamera
- Omnidirectional (Çok yönlü 360°) kamera
- Radar (Radio Detection and Ranging) (Radyo Algılama ve Mesafe Ölçme)
- LiDAR (Laser Imaging Detection and Ranging) (Işın Algılama ve Mesafe Ölçme)
- IMU (Inertial Measurement Unit) (Eylemsizlik Ölçüm Birimi)
- Ultrasonik sensör
- GPS (Global Positioning System) (Küresel Konumlandırma Sistemi)
- IPS (Indoor Positioning System) (Kapalı Alan Konumlandırma Sistemi)

#### 2.1.1 Kamera

Kamera, görüntüleri yakalayıp kaydeden bir cihazdır. Çalışma prensibi, genellikle bir lens aracılığıyla ışığın bir algılayıcıya (analog bir filmde veya dijital bir kamerada bir görüntü sensörü) odaklanması ve bu ışığın görüntü olarak işlenip saklanması esasına dayanır. Klasik analog kameralar, ışığı kimyasal bir film üzerine kaydederken, dijital kameralar ışığı elektronik veriye dönüştürür ve bu veriyi dijital formatta saklar.

Kameralar sadece aracın çevresinin tespitinde kullanılmıyor, aracın içinde insan-makine etkileşimi konusunda da kullanılmaktadır [6].

Kameralar kendi içlerinde monoküler kamera, çok yönlü 360° kamera, event (nöromorfik) kamera, stereo kamera gibi farklı görüntü algılama prensipleriyle çeşitlenmektedir.

##### 2.1.1.1 Monoküler kamera

Monoküler kamera iki boyutlu dijital görüntüler elde etmek için en ucuz ve basit sensörlerden bir tanesidir [7]. Elde edilen görüntüler üzerinde çeşitli görüntü işleme teknikleri kullanılarak şerit tespiti, trafik tabelası tanıma, yaya tespiti, kasis tespiti gibi

işlemler yapılabilir. Ancak tek başına monoküler kameralar kullanıldığı zaman tespit edilen nesnelerin derinlik hesabının yapılması zordur. Ayrıca, monoküler kameralar kötü hava koşullarından ciddi oranda etkilenmektedirler.

### 2.1.1.2 Stereo kamera

Stereo kameralar iki adet birbirine belirli bir uzaklıkta aynı yatay düzlemde bulunan monoküler kameradan oluşmaktadır. Bu sayede iki kamera arasındaki mesafe ile iki kameradan alınan görüntüdeki bir nesnenin kameralar arasındaki mesafe ve açıl hesaplamalar sayesinde tahmini derinlik ölçümü yapılabilir [8]. İnsan gözü bu kameralara doğal bir örnektir.

### 2.1.1.3 Event kamera


Event kameralar görüntü yerine piksel seviyesindeki ışık yoğunluğundaki değişiklikleri algılayan ve bu değişiklikleri gerçek zamanlı olarak kaydeden bir sensör türüdür. Her piksel bağımsız olarak çalışır ve yalnızca o pikselin görüş alanındaki ışık yoğunluğunda bir değişiklik olduğunda veri üretir. Böylece, yüksek hızda hareket eden nesnelerin takibi, yüksek dinamik aralıklı sahnelerde çalışma ve düşük ışık koşullarında bile etkili bir şekilde performans gösterme gibi durumlar için ideal kılabilir [9].

### 2.1.1.4 Omnidirectional kamera

Omnidirectional kamera, çevresindeki 360° alanı aynı anda yakalayabilen bir kamera türüdür. Bu kameralar, genellikle çoklu lens kullanarak veya özel olarak tasarlanmış bir ayna sistemi aracılığıyla etraflarındaki tam panoramik görüntüleri kaydedebilirler. Bu kameraların yakaladığı görüntüler, kullanıcının görüntüleyici üzerinde serbestçe dönmesine ve farklı açılardan sahneyi gözlemlemesine olanak tanır [5].

### 2.1.2 Radar


Radar, nesnelerin varlığını, konumunu, hızı ve benzeri özelliklerini belirlemek için radyo dalgalarını kullanarak çalışan bir algılama sistemidir ve otomotiv sektöründe yaygın olarak kullanılmaktadır [10]. Radar, bir radyo vericisi sayesinde radyo dalgalarının yayılmasını sağlar. Daha sonra, nesnelere yansıyan bu dalgalar, bir radyo alıcısı sayesinde toplanır ve analiz edilerek çevredeki nesnelere tespit edilir. Yansıyan dalgaların analizi, nesnenin konumu, hızı, yönü ve hatta şekli gibi bilgileri sağlayabilir. Şekil 1'de görselleştirilmiş radar verisi ile ortam görüntüsü görülmektedir.



Şekil 1. Radar verisi ve ortam görüntüsü [20]

### 2.1.3 LiDAR

LiDAR, nesnelerin ve yüzeylerin mesafesini, şeklini ve diğer özelliklerini belirlemek için lazer ışınları kullanarak çalışan bir uzaklık algılama cihazıdır. LiDAR sistemi, bir lazerden yayılan ışınların çevredeki nesnelere yansıtılmasını ve bu yansımaların bir alıcı tarafından toplanmasını içerir. Yayılan lazer ışınlarının, çevredeki nesnelere yansıyan ışığın alıcıya dönüş hızı hesaplanarak, nesnenin algılayıcıya olan mesafesi, yönü ve dolayısıyla konumu belirlenir. LiDAR, coğrafya, arkeoloji, jeoloji, ormancılık ve şehir planlaması gibi çeşitli alanlarda yüzey şekillerinin ve topografyanın yüksek çözünürlüklü üç boyutlu haritalarını oluşturmak için kullanılır. Ayrıca, otonom araçlar LiDAR'ı çevrelerini üç boyutlu olarak algılamak ve potansiyel engelleri veya yolları tespit etmek için kullanır. Böylece araçların güvenli bir şekilde navigasyon yapmalarını ve çevrelerindeki nesnelere etkileşimde bulunmalarını ve etrafın haritalanmasını sağlar [5]. Şekil 2, LiDAR ile oluşturulmuş üç boyutlu point-cloud (nokta bulutu) haritasını göstermektedir.



Şekil 2. LiDAR ile oluşturulmuş üç boyutlu point-cloud (nokta bulutu) harita [5]

### 2.1.4 IMU

IMU, bir cihazın doğrusal ve açıl hareketlerini ölçmek için kullanılan bir sensör paketidir. Tipik olarak, üç eksenli bir ivmeölçer, üç eksenli bir jiroskop ve bazen üç eksenli bir manyetometre içerir. Bu sensörler, sırasıyla, doğrusal ivmeyi, dönme oranını ve yer çekimi ile Dünya'nın manyetik alanına göre yönelimi ölçer. IMU'lar, bu verileri toplayarak bir cihazın mekansal konumunu, yönünü, hızını ve

ivmesini anlık olarak belirleyebilir. Uzun değişimlerin ölçümü sonucunda oluşan hatalar ile IMU'lar ciddi sapmalara uğrayabilmektedir [11].

### 2.1.5 Ultrasonik sensör

Ultrasonik sensör, çevresindeki nesnelerin varlığını, mesafesini ve hızını, yüksek frekanslı ses dalgaları kullanarak tespit eden bir cihazdır. Bu sensörler, genellikle 20 KHz üzerindeki bir frekansta, insan kulağının duyamayacağı ses dalgaları yayar. Sensör, yaydığı ultrasonik dalgaların bir nesne tarafından yansıtılmasını bekler ve bu yansıyan dalgaların geri dönüş süresini ölçer. Bu süre, nesnenin sensöre olan mesafesini hesaplamak için kullanılır [12].

### 2.1.6 GPS/IPS

GPS, uydu tabanlı coğrafi konum ve saat bilgisi sağlayan küresel uydu navigasyon sistemlerinden biridir. Uydulardan gelen radyo sinyallerini yeryüzündeki GPS alıcıları sayesinde alınıp yorumlanarak konum belirlenmesi gerçekleştirir. Ancak çeşitli konum ve sinyal zayıflıkları sayesinde dağlık bölgeler gibi sinyal kesintisine uğranması olası yerlerde konum doğru olarak belirlenemeyebilir. IPS ise, kapalı alanlarda konum belirleme için kullanılan bir cihazdır. GPS'nin aksine, IPS, binaların içindeki nesnelerin veya kişilerin yerini tespit etmek amacıyla tasarlanmıştır, çünkü GPS sinyalleri bina duvarlarını geçemediğinden iç mekanlarda etkili bir şekilde çalışmaz. IPS, Wi-Fi (Wireless Fidelity) (Kablosuz Bağlantı Alanı), Bluetooth, ultrasonik sinyaller, manyetik alanlar, optik sensörler veya bu teknolojilerin bir kombinasyonunu kullanarak konum bilgisi sağlar.

## 2.2 Otonom araçlarda nesne ve şerit tespiti için kullanılan yöntemler

İnsanlar nesnelere gözleriyle görerek veya kulaklarıyla duyarak tespit ederler. Otonom araçlarda durum benzer olmakla birlikte biraz daha farklı ve daha doğru bir şekilde yapılır yani gözler ile yapılan mesafe tespitinde tamamen insan tahminine dayalı bir sonuç elde ederken sensörler de gerçek mesafeye daha doğru şekilde ölçer. Otonom araçların tespit etmesi gereken temel nesnelere aşağıda belirtilmiştir:

- Yayalar, hayvanlar
- Otomobil, bisiklet, kamyon, motor gibi araçlar
- Yol şeritleri
- Trafik tabelaları
- Trafik lambaları

Çeşitli spesifik görünümü nesnelerin tespitlerinde kameralar kullanılmaktadır. Kameralardan alınan

görseller ile çeşitli derin öğrenme, sınıflandırma, görüntü işleme teknikleriyle görüntü üzerinde Şekil 3'teki gibi yayalar [13], Şekil 4'deki gibi huniler [14], yol kenarı korumaları, trafik lambaları, trafik tabelaları [15-17], kasisler [18] gibi çeşitli nesnelerin yanı sıra askeri alanda çeşitli silah unsuru sayılabilecek nesnelere, tanklar, helikopterler gibi objelere de [19] tespit edilebilmektedir.



Şekil 3. Görüntü üzerinden yaya tespiti [13]



Şekil 4. Görüntü üzerinden huni ile şerit tespiti [14]

Monoküler kameralar ile tespit edildiğinde yayanın konumu, hareket yönü, hareket hızı gibi verilerin eksikliği yüzünden çeşitli sensörler ile veri füzyonu kullanılarak nesnelerin tam konumu tespit edilebilir. Kamera ve radar füzyonu sayesinde hem görsel hem de konumsal uzayda konum tespiti yapılabilmektedir [20]. Ayrıca, kameralar Şekil 5'te görüldüğü gibi kötü hava koşullarından ciddi oranda etkilenmesinden dolayı radar [21] veya başka sensörler kullanılarak sensör füzyonu ile bu etkinin azaltılması yönünde çalışmalar yapılmıştır.



Şekil 5. Su damlasından etkilenmiş kamera görüntüsü [21]


Bunların yanı sıra, stereo kameralar kullanılarak tespit edilen nesnenin araç ile arasındaki tahmini mesafe ölçülebilir [8]. Bunlara ek olarak, Şekil 6'da

görüldüğü gibi nöromorfik kameralar kullanılarak da nesne tespiti yapılabilmektedir ve yapılan araştırmalara göre çok hızlı çalışmakta olduğu görülmektedir [22].




Şekil 6. Nöromorfik kamera görüntü örneği [5]

LiDAR sensörleri her ne kadar çevrenin haritasını çıkarma konusunda başarılı olsalar da çevredeki nesnelere hem görülen noktalarda hem de kör noktadaki tespiti [23] konusunda ve bu tespitler sonucunda çeşitli hareketli ve hareketsiz nesnelere aracın kaçınabilmesi için optimum veri sağlayıcısı rolünü üstlenmektedir [24]. Radarlar ise her ne kadar LiDAR'lar gibi ortamın haritasını çıkartmasa da etraftaki nesnelere varlığını ve konumunu tespit etme konusunda ciddi oranda yeteneğe sahip ve kameralar gibi kötü hava şartları [25] ve kötü ortam koşullarından etkilenmemektedirler [10]. Ultrasonik sensörler de çeşitli nesnelere tespitinde kullanılabilir, ancak uzak mesafelerde ve çeşitli şekil ve nesne algulamalarında zayıf oldukları için genelde aracın yakın çevre kontrolünde, aracın arka-ön ve yanlarında park sensörleri olarak kullanılmakta [26] olup akıllı park konusunda da destek olmaktadır [27]. Şerit tespiti konusunda da her ne kadar kamera kullanımı Şekil 7 ve 8'de görüldüğü gibi optimum düzeyde çıktı veren, basit [28-32] ve bunların dışında ucuz maliyetli olsa da çeşitli haritalandırma ve konum belirleme tekniklerini kullanarak füzyon gerçekleştirme ihtiyacını ortadan kaldıramamaktadır. Şerit tespiti konusunda sadece kamera kullanılmamalıdır, çünkü zorlu hava koşullarında ve kötü ortamlarda kameraların fazla etkilenmesi sebebiyle LiDAR gibi hem çevrenin haritasını çıkartabilecek hem de ortam koşullarından etkilenmeyecek çözümler kullanılmaktadır [33]. Doğru şeritte sürüş yapmak ve şeritleri düzgün takip etmek sağlıklı bir sürüşün en temel ihtiyaçlarıdır. Bu doğru bir şekilde yapılmazsa kazalar kaçınılmazdır.



Şekil 7. Şerit tespiti [29]



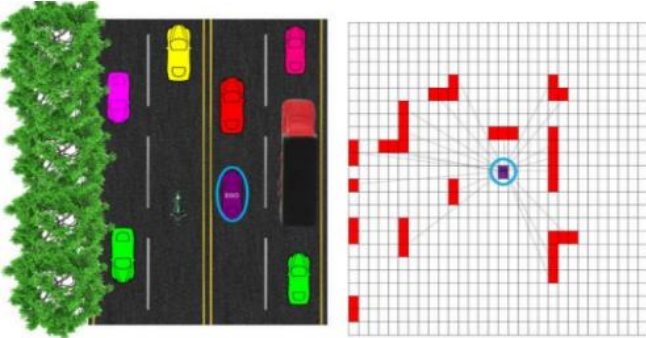
Şekil 8. Şerit tespiti yaklaşımı

### 2.3 Otonom araçlarda konum belirleme ve harita oluşturma için kullanılan yöntemler

Otonom araçlarda konum bilgisi sayesinde aracın ulaşacağı hedefe yapacağı yolculuk planı ve bu planın uygulanmasıyla, hedef konuma tam doğrulukla ulaşabilmesi sağlanmaktadır. Harita oluşturma ise anlık oluşturulmuş çevre haritası veya hazır haritalar ile aracın çevredeki oluşabilecek çukur, engel gibi statik ve yaya, diğer araçlar gibi dinamik nesnelere kaçınması ve optimum bir şekilde rotasını takip edebilmesi için esastır.[34]

Aracın anlık konumuna bağlı olarak hedefe ne kadar uzak olduğu, hedefe gidebileceği rotalar, aracın şeritler içerisindeki konumunun hesaplanmasında GPS, IPS, IMU, LiDAR ve kameralar kullanılmaktadır. Bu sensörler, gelişen teknolojiyle tek başlarına her ne kadar hata payı düşük bir şekilde çalışsalar da sensör füzyonu kullanılmadan yapılan işlemlerde hataların zamanla katlanarak problemlere yol açtığı gözlemlenmiştir.[35] Örneğin IMU kullanılarak yapılan harita üzerinde seyrüsefer hesabı (Dead Reckoning) yön, hız, mesafe, zaman ve çeşitli ihtiyaca bağlı bilgileri kullanarak harita üzerinde alınan yolu göstermek için kullanılan bir yöntemdir. Bu yöntemin en büyük problemi uzun yollarda her sensörde bulunan hata payları sayesinde ciddi bir sapma oluşturması ve haritada bulunan konumu doğru göstermediği görülmektedir [36]. Buna bağlı olarak GPS ve IMU sensörlerinin füzyonu sayesinde IMU'dan edinilen hatalı veriler GPS'den gelen veriler ile füzyonlayarak daha doğru hesaplamalar yapılabilmektedir [36-37]. GPS - IMU füzyonuna ek

olarak, görüntü ile yapılmış füzyon arařtırmalarında da ciddi oranda GPS sonucunda ortaya çıkan tüneller, dađlık bölgelerde, yüksek binaların arasında sinyallerin zayıf olmasından kaynaklı hataları [37] belli miktarda iyileřtirecek řekilde konum belirleme ve performans gözlenmiřtir [38]. Yüksek otonom seviyelerine bakıldıđında çevre araçlardan gelen konum ve yön bilgileri ile konumlandırma işlemleri de gerçekleştirilmektedir. Ortamın ızgara řeklinde haritasını çıkartma konusunda çeřitli sensörlerin füzyonu kullanılarak çözümler üretilmiřtir. Tek sensör kullanıldıđı zaman oluřan hatalardan dolayı, LiDAR, kamera, radar, ultrasonik sensörlerin çeřitli füzyonları kullanılarak daha dođru sonuçlar elde edilmektedir. Stereo kamera ve LiDAR kullanılarak Şekil 9'daki ızgara haritasında görüldüğü gibi kameradan gelen iki boyutlu veri ile LiDAR'dan gelen üç boyutlu verinin füzyonu sonucunda ciddi oranda dođru sonuçlar elde edilmiřtir [39]. Bunların yanı sıra, radar ile diđer sensörlere füzyon işlemleri de haritalandırma işlemine katkıda bulunmuřtur [40].



Şekil 9. Iızgara haritalaması örneđi [39]

LiDAR sensöründen oluřan üç boyutlu nokta-bulut (point-cloud) verilerinin karşılaştırılması ile yapılan çözümlerin diřında SLAM (Simultaneous Localization and Mapping) (Eřzamanlı Konum Belirleme ve Harita Oluřturma) kullanılarak önceden haritası çıkartılmamıř bölgelerde hızlı bir řekilde etrafın haritalanması ve duruma göre aksiyon alınması sađlanmaktadır. SLAM hesaplama hızı konusunda yavařtır ancak bu teknik haritalanmamıř, atıl rotalarda diđer tekniklere göre çok daha dođru sonuçlar elde etmektedir [5].

### 3 Kalman filtresi kullanılarak iki araç arasındaki mesafenin belirlenmesi

Kalman filtresi kullanılmasındaki amaç, sensörlerin hassasiyetlerinden kaynaklı elde edilen parazitli/hatalı verilerin filtrasyon işleminden sonra tahminleme tekniđi ile gerçek deđere daha yakın deđeri bulmaktır.

#### 3.1 Kalman filtresi

Kalman filtresi, gürültülü verilerden zamanla deđişen sistemlerin durumlarını tahmin etmek için kullanılan bir algoritmadır. 1960 yılında Rudolf E. Kálmán tarafından geliřtirilmiřtir ve özellikle kontrol sistemleri, navigasyon ve zaman serisi analizinde yaygın olarak kullanılmaktadır. Kalman filtresi, bir sistemin mevcut durumunu ve gürültü veya belirsizlik içeren ölçümleri kullanarak gelecekteki durumlarını tahmin eder.

##### 3.1.1 Tahmin aşaması

Kalman filtresi iki ana bileřenden, tahmin ve güncellemeden oluřmaktadır. Bu iki bileřen, sistemin durumunu en iyi řekilde tahmin etmek için sürekli olarak birbirini izler.

**Durum Tahmini:** Bu aşamada, bir önceki duruma ve kontrol girdilerine dayanarak, sistemin bir sonraki durumu tahmin edilir.

$$\hat{x}_{n|n-1} = F_n \hat{x}_{n-1|n-1} \quad (1.1)$$

Burada,  $F_n$  durum geçiř matrisidir ve  $x_{n-1|n-1}$  önceki zaman adımındaki durum tahminidir.

**Hata Kovaryansı Tahmini:** Bu aşamada, tahmin hatasının nasıl yayılacađı belirlenir.

$$P_{n|n-1} = F_n P_{n-1|n-1} F_n^T + Q_n \quad (1.2)$$

Burada,  $Q_n$  süreç gürültüsü kovaryans matrisidir.

##### 3.1.2 Güncelleme aşaması

**Kalman Kazancı:** Ölçümden elde edilen bilgiyi, tahmin edilen durumu düzeltmek için kullanılır.

$$K_n = P_{n|n-1} G_n^T (G_n P_{n|n-1} G_n^T + R_n)^{-1} \quad (1.3)$$

Burada,  $G_n$  ölçüm matrisi ve  $R_n$  ölçüm gürültüsü kovaryans matrisidir.

**Durum Güncellemesi:** Bu aşamada, ölçüm verilerine dayalı olarak durum tahmini güncellenir.

$$\hat{x}_{n|n} = \hat{x}_{n|n-1} + K_n (y_n - G_n \hat{x}_{n|n-1}) \quad (1.4)$$

Burada,  $y_n$  mevcut ölçümdür ve  $G_n \hat{x}_{n|n-1}$  tahmin edilen ölçümdür.

**Hata Kovaryansı Güncellemesi:** Bu aşamada, güncellenmiř duruma göre hata kovaryansı hesaplanır.

$$P_{n|n} = P_{n|n-1} - K_n (G_n P_{n|n-1} G_n^T + R_n) K_n^T \quad (1.5)$$

##### 3.1.3 Uygulama alanları

Kalman filtresi, birçok alanda kullanılmaktadır.

- Navigasyon ve Konum Belirleme: GPS verilerinin dođruluđunun arttırılması ve araçların konumunun hassas bir řekilde belirlenmesi.

- Robotik: Robotların hareketlerinin ve konumlarının izlenmesi.
- Ekonomi: Zaman serisi verilerinde tahmin yapılması.
- Görüntü İşleme: Nesne takibi ve görüntü stabilizasyonu yapılması.

### 3.1.4 Avantajlar ve sınırlamalar

#### Avantajları:

- Optimal Tahmin: Gürültülü verilerden en iyi tahmini sağlar.
- Gerçek Zamanlı İşlem: Anlık olarak çalışabilir ve hızlı hesaplama gerektirir.
- Matematiksel Temel: Sağlam bir matematiksel temele dayanır.

#### Sınırlamaları:

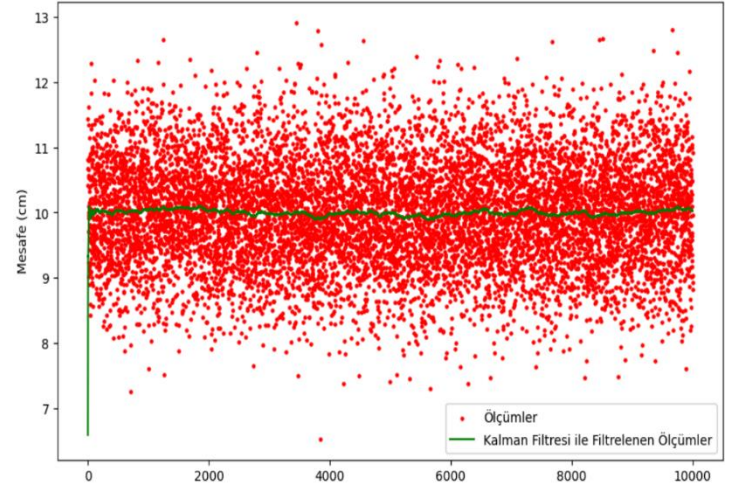
- Doğrusal Sistemler: Temel Kalman filtresi doğrusal sistemler için geçerlidir. Doğrusal olmayan sistemler için genişletilmiş Kalman filtresi (EKF) veya parçacık filtresi gibi genişletmeler gerektirir.
- Gürültü Varsayımları: Sistem ve ölçüm gürültüsünün normal dağılıma sahip olduğu varsayımı, pratikte her zaman geçerli olmayabilir.

Kalman filtresi, sensör verilerinin doğruluğunu artırmak ve güvenilir tahminler yapmak için güçlü bir araçtır. Özellikle gerçek zamanlı sistemlerde, güvenilir ve hassas sonuçlar elde etmek için yaygın olarak kullanılır [41].

### 3.2 Kalman filtresi ile ham verilerin filtrelenmesi örneği

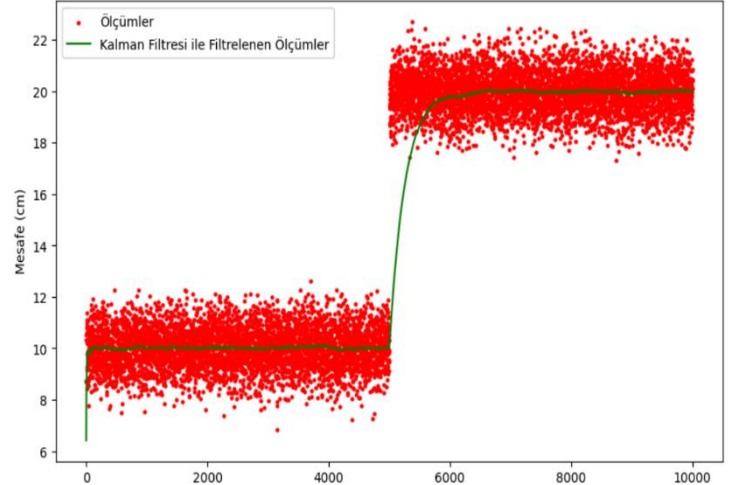
Bu bölümde Python programlama dili kullanılarak hata payı  $\pm 3$  cm olacak şekilde rastgele oluşturulmuş verilere ultrasonik sensör verisi adı altında filtreleme işlemi yapılacaktır. Oluşturulan bu veriler, matplotlib kütüphanesi kullanılarak grafikler halinde görselleştirilmiştir.

Şekil 10'da 10.000 adet ultrasonik sensör ölçüm verisi (kırmızı renk) ve bu verilerin Kalman filtresi ile filtrelenmiş hali (yeşil renk) gözlemlenmektedir.



Şekil 10. Kalman filtresi ile filtrelenmiş ultrasonik sensör ölçümleri

Bu şekilden görüldüğü gibi, ultrasonik sensör 10 cm uzaklıktan belirli bir nesneye karşı uzaklık verisi elde etmektedir. Herhangi bir filtre uygulanmamış olan kırmızı noktalarda 3 cm boyutunda belirli sapmalar gözlenmektedir. Kalman filtresi uygulandığında ise bu sapmanın başlangıç değerleri hariç en fazla 0.3 cm olduğu görülmektedir. Bu teste ek olarak 10 cm uzaklıktan 20 cm uzaklığa çekilen bir ultrasonik sensör örneği Şekil 11'de gösterilmektedir.



Şekil 11. İki farklı mesafe verisinin Kalman filtresi ile filtrelenmiş ultrasonik sensör ölçümleri

## 4 Sensör füzyonu kullanılarak filtrelenmiş verilerin işlenmesi

Sensör füzyonu, farklı sensörlerden elde edilen verilerin çeşitli teknikler kullanılarak birleştirilmesi ile daha doğru verilerin elde edilmesini sağlayan bir yöntemdir.

Literatürde bu teknik üç farklı seviyede değerlendirilmektedir [42-43]:

- Düşük seviye füzyon (Low-Level Fusion)


- Özellik seviyesinde füzyon (Feature-Level Fusion)
- Yüksek seviye füzyon (High-Level Fusion)

Düşük seviye füzyon tekniğinde, sensörden gelen ham veriler herhangi bir ön işlemden geçmeden füzyonlanır.

Özellik seviyesinde füzyon yönteminde sensörden gelen ham verinin bir ön işleme tabi tutulduktan sonra füzyonlanması sağlanır.

Yüksek seviye füzyon tekniğine örnek olarak Şekil 9'da gösterilen ızgara haritalaması uygulaması verilebilir [39]. Bu uygulamada, kameradan gelen renk, yoğunluk ve kenar bilgisi içeren 2 boyutlu yüksek kalitedeki veriler ile birlikte LiDAR'dan gelen nokta bulutu verisinin füzyonlanması ile ızgara haritası oluşturulmuştur.

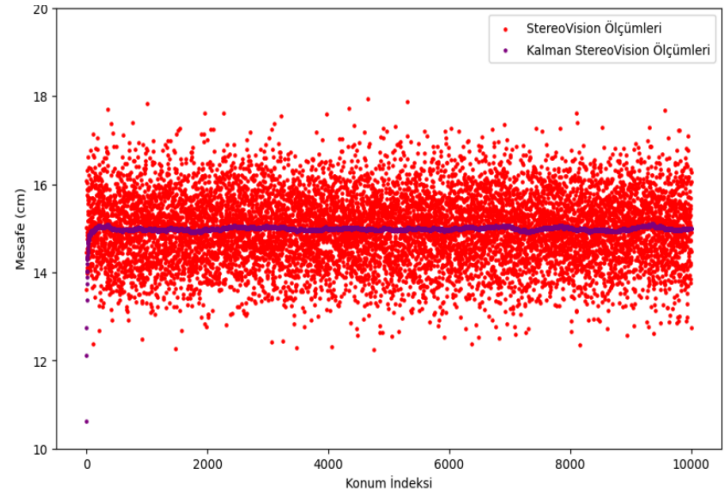
Bu bölümde iki farklı hassasiyetlere sahip ve aynı tipte veriyi toplayan sensörlerden elde edilen verilerin simülasyonu yapıldı. Bu verilere Kalman filtresi ile filtreleme işlemi yapılarak özellik seviyesinde füzyon mimarisi gerçekleştirildi. Bunun neticesinde iki benzer füzyonlama tekniği ile daha doğru sonuçlar elde edildi. 15 cm mesafeden ölçüm yapılacak şekilde simüle edilen deneyde radar sensörü ölçümlerinin hata sapması  $\pm 0.5$  cm olarak belirlendi. Stereo Vision ölçümlerinin hata sapması  $\pm 3$  cm olacak şekilde tekrar Python programlama dili kullanılarak rastgele bir şekilde oluşturuldu. Matplotlib kütüphanesi ile oluşturulan 10.000 adet veri Şekil 12'de gösterilmektedir.




Şekil 12. Stereo vision ve radar ölçümleri

Şekil 13'de Kalman filtresi ile stereo vision ölçümü ve ham stereo vision ölçümü karşılaştırması gösterilmektedir. Bu şekilden, Kalman filtresi ile daha doğru sonuçlar elde edildiği ve mor renkli noktaların 15 cm olan gerçek değere yakınsadığı gözlemlenmektedir. Şekil 14'te de radar sensöründen gelen verilerin Kalman filtresi ile hatalarının bir

kısımının giderilmiş versiyonlarını gözlemlenmektedir.




Şekil 13. Kalman filtresi ile stereo vision ölçümü ve ham stereo vision ölçümü karşılaştırılması



Şekil 14. Kalman filtresi ile radar ve ham radar ölçümleri

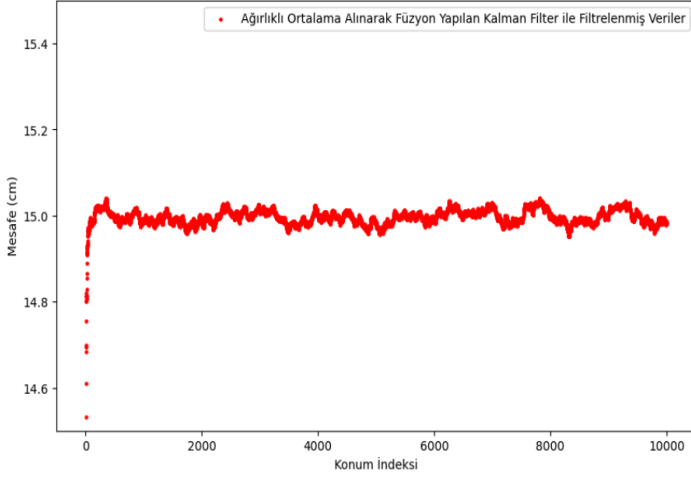
Bu filtreleme işlemlerine ek olarak bu iki sensörün mesafe ölçümlerinin füzyonu iki farklı algoritma ile test edilmiştir. Şekil 15'te, Kalman filtresi ile ölçülen stereo vision ve radar verilerinin ortalaması alınarak füzyonu gösterilmektedir.





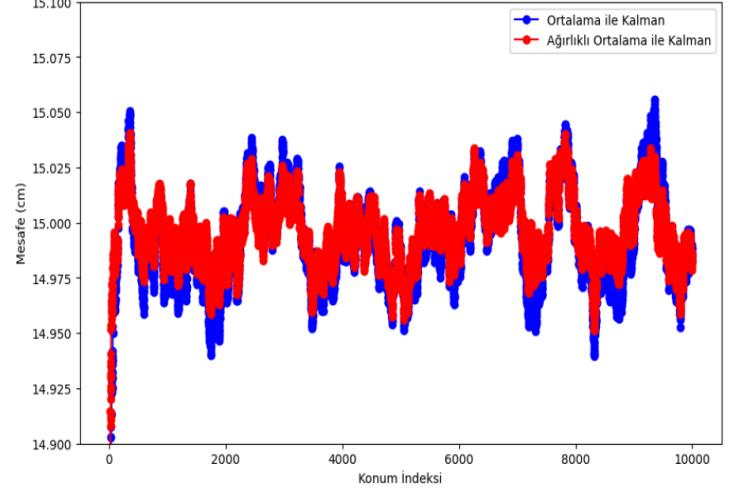
Şekil 15. Kalman filtresi ile ölçülen stereo vision ve radar verilerinin ortalama alınarak füzyonu

Şekil 16'da ise Kalman filtresi ile ölçülen stereo vision ve radar verilerinin ağırlıklı ortalaması alınarak füzyonu gösterilmektedir.



Şekil 16. Kalman filtresi ile ölçülen stereo vision ve radar verilerinin ağırlıklı ortalaması alınarak füzyonu

Şekil 17'de ise Kalman filtresi ile ağırlıklı ortalama ve normal ortalama füzyonu karşılaştırması gözlemlenmektedir.



Şekil 17. Kalman filtresi ile ağırlıklı ortalama ve normal ortalama füzyonu karşılaştırması

Burada, ağırlıklı ortalama alınarak yapılan iki farklı sensörden elde edilen verinin füzyonlanması ile 15 cm'ye daha çok yakınsadığı görülmektedir. Ayrıca, daha hassas ölçümler içeren radar sensör verisinin ağırlığı artırılarak yapılan ağırlıklı ortalama füzyon tekniğinde gerçek değere yaklaşık %50 daha çok yakınsadığı gözlemlenmektedir.

## 5 Sonuçlar

Sonuç olarak sensörlerden toplanan verilerin gerçek veriye olan sapmasından dolayı oluşan hataların Kalman filtresi ile filtrelenmesiyle, verilerin gerçek değere %98,33 oranda yaklaştığı gözlemlenmiştir. Bununla birlikte çeşitli sensör füzyonu teknikleri ile bu değerin %99'a yükseldiği görülmektedir.

Kullanılan iki füzyon tekniği karşılaştırıldığı zaman, genel sonuca oransal olarak çok fazla bir etki oluşturmadığı gibi gözükse de kendi aralarında %50 civarında doğru veriye yakınsama farkı gözlemlenmektedir. Bundan dolayı, farklı metotlar ile füzyon yaklaşımının daha doğru veya daha yanlış sonuçlar üretebileceği anlaşılmaktadır.

Elde edilen sonuçlar doğrultusunda, Kalman filtresi ile filtreleme işleminin isterlere göre yetersiz sonuç üretmesi durumunda sensör füzyonunun tamamlayıcı bir rol üstlenerek gerçek değere olan yakınsamayı arttırdığı gözlemlenmiştir.

Otonom araçların buldukları konumu, çevreyi, ortam koşullarını, çevredeki dinamik ve statik nesnelere algılaması zorunludur. Bu algılama konusunda geliştirilen teknikler ve algılamanın doğruluğu baz alınarak yapılan füzyonlar sonucu otonom araçların güvenliği ve sağlıklı bir şekilde çalışması konusunda ciddi ilerlemeler kaydedilmiştir. Günümüzde tam otonom sürüşe ulaşılması gerçeklik dışıdır. Belirli bölgelerde

otonom sürüş prensiplerini içeren araçlar kullanılmaktadır ancak tam otonom durumu her koşulda ve her konumda otonom sürüşün sağlanmasını gerektirdiği için yasal ve fiziksel problemler aşamadığı sürece tam otonom sürüş gerçeklik dışı kalmaya devam edecektir.

Öte yandan, otonom araçların etraftan topladıkları verilerin doğru hesaplanabilmesi için gerçekleştirilen filtreleme ve füzyonlama tekniklerinin ne kadar önemli olduğu elde edilen sonuçlardan da anlaşılmaktadır.

Gelecek çalışmalarda daha farklı filtreleme ve sensör füzyonu tekniklerinin kullanılmasıyla elde edilen sonuçların karşılaştırılması yapılabilir. Böylelikle en optimum füzyonlama tekniği daha kapsamlı bir şekilde belirlenebilir.

### Kaynaklar

- [1] Singh S. "Critical reasons for crashes investigated in the national motor vehicle crash causation survey". *Technical Report*, 2015.
- [2] Tefft BC. "Acute Sleep Deprivation and Risk of Motor Vehicle Crash Involvement". *Technical Report, Washington, D.C., Foundation for Traffic Safety*, 2016.
- [3] Crayton T], Meier BM. "Autonomous vehicles: Developing a public health research agenda to frame the future of transportation policy". *Journal of Transport & Health*, 6, 245-252, 2017.
- [4] Waymo L. "On the road to fully self-driving". *Waymo Safety Report*, 1-43, 2017.
- [5] Yurtsever E et al. "A survey of autonomous driving: Common practices and emerging technologies". *IEEE Access*, 8, 58443-58469, 2020.
- [6] Fridman L, "Human-Centered Autonomous Vehicle Systems: Principles of Effective Shared Autonomy". *arXiv:1810.01835*, 2018.
- [7] Yamazato T, Takai I, Okada H, Fujii T, Yendo T, Arai S, Andoh M, Harada T, Yasutomi K, Kagawa K, Kawahito S. "Image-Sensor-Based Visible Light Communication for Automotive Applications". *IEEE Communications Magazine vol. 52 no. 7*, 88-97, 2014.
- [8] Neves R, Matos AC. "Raspberry PI based stereo vision for small size ASVs". *IEEE OCEANS, San Diego*, 1-6, 2013.
- [9] Maqueda AI, Loquercio A, Gallego G, Garcia N, Scaramuzza D, "Event-based vision meets deep learning on steering prediction for self-driving cars". *IEEE Computer Vision and Pattern Recognition (CVPR)*, 5419-5427, 2018.
- [10] Steinbaeck J, Steger C, Holweg G, Druml N, "Next Generation Radar Sensors in Automotive Sensor Fusion Systems". *2017 IEEE Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, 2017.
- [11] Borodacz K, Cezary S, Stanislaw P, "Review and selection of commercially available IMU for a short time inertial navigation". *Aircraft Engineering and Aerospace Technology 94.1*, 45-59, 2022.
- [12] Zhmud V A, Kondratiev N O, Kuznetson K A, Trubin V G, Dimitrov L V, "Application of ultrasonic sensor for measuring distances in robotics." *Journal of Physics: Conference Series*, 1015, 3, 2018.
- [13] Day, C et al. "Pedestrian recognition and obstacle avoidance for autonomous vehicles using raspberry Pi". *Intelligent Systems Conference (IntelliSys)*, 2, 51-69, 2020.
- [14] Kalms L et al. "Robust lane recognition for autonomous driving". *IEEE Conference on Design and Architectures for Signal and Image Processing (DASIP)*, 1-6, 2017.
- [15] Swaminathan, V et al. "Autonomous driving system with road sign recognition using convolutional neural networks". *IEEE International Conference on Computational Intelligence in Data Science (ICCIDS)*, 1-4, 2019.
- [16] Hwang K, Jung IH, Lee JM. "Implementation of autonomous driving on RC-CAR with Raspberry PI and AI server". *Webology*, 19, 4444-4458, 2022.
- [17] Burleigh N, King J, Bräunl T. "Deep learning for autonomous driving". *IEEE Digital Image Computing: Techniques and Applications (DICTA)*, 1-8, 2019.
- [18] Dewangan DK, Sahu SP. "Deep learning-based speed bump detection model for intelligent vehicle system using raspberry pi". *IEEE Sensors Journal*, 21(3), 3570-3578, 2020.
- [19] Ozkan Z et al. "Object detection and recognition of unmanned aerial vehicles using Raspberry Pi platform". *Fifth IEEE International symposium on multidisciplinary studies and innovative technologies (ISMSIT)*, 467-472, 2021.
- [20] Kim J, Han DS, Senouci B. "Radar and vision sensor fusion for object detection in autonomous vehicle surroundings". *Tenth IEEE International conference on ubiquitous and future networks (ICUFN)*, 76-78, 2018.
- [21] Nobis F et al. "A deep learning-based radar and camera sensor fusion architecture for object detection". *IEEE Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, 1-7, 2019.
- [22] Lichtsteiner P, Posch C, Delbruck T. "A 128x128 120 db 15µs latency asynchronous temporal contrast vision sensor". *IEEE Journal SolidState Circuits*, 43(2), 566-576, 2008.
- [23] Thakur R "Scanning LIDAR in Advanced Driver Assistance Systems and Beyond: Building a road map for next-generation LIDAR technology". *IEEE Consumer Electronics Magazine*, 5(3), 48-54, 2016.
- [24] Baras N et al. "Autonomous obstacle avoidance vehicle using LIDAR and an embedded system". *Eighth IEEE International Conference on Modern Circuits and Systems Technologies (MOCASIT)*, 1-4. 2019.
- [25] Kutilla M et al. "Automotive LIDAR sensor development scenarios for harsh weather conditions". *IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*. 265-270, 2016.

- [26] Jeong SH, Choi CG, Oh JN et al. "Low cost design of parallel parking assist system based on an ultrasonic sensor". *Int. J. Automot. Technol.*, 11, 409-416, 2010.
- [27] Paidi V et al. "Smart parking sensors, technologies and applications for open parking lots: a review". *IET Intelligent Transport Systems*, 12(8) 735-741, 2018.
- [28] Rossi A et al. "Real-time lane detection and motion planning in raspberry pi and arduino for an autonomous vehicle prototype". *arXiv:2009.09391*, 2020.
- [29] Thadeshwar H et al. "Artificial intelligence based self-driving car". *Fourth IEEE International Conference on Computer, Communication and Signal Processing (ICCCSP)*, 1-5, 2020.
- [30] Sainath V et al. "Deep learning for autonomous driving system". *Second IEEE International Conference on Electronics and Sustainable Communication Systems (ICESC)*, 1744-1749, 2021.
- [31] Jain AK. "Working model of self-driving car using convolutional neural network, Raspberry Pi and Arduino". *Second IEEE International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, 1630-1635, 2018.
- [32] Kayaduman A et al. "Development and application of sensor network for autonomous vehicles". *IEEE International Conference on Artificial Intelligence and Data Processing (IDAP)*, 1-5, 2018.
- [33] Hata A, Wolf D. "Road marking detection using LIDAR reflective intensity data and its application to vehicle localization". *17th IEEE International Conference on Intelligent Transportation Systems (ITSC)*, 584-589, 2014.
- [34] Kuutti S et al. "A survey of the state-of-the-art localization techniques and their potentials for autonomous vehicle applications". *IEEE Internet of Things Journal*, 5(2), 829-846, 2018.
- [35] Kocic J, Jovicic N, Drndarevic V, "Sensors and Sensor Fusion in Autonomous Vehicles". *Telecommunications forum (TELFOR)*, 20-21, 2018.
- [36] Yang Q, Sun J. "Location system of autonomous vehicle based on data fusion". *IEEE International Conference on Vehicular Electronics and Safety*, 314-318, 2006.
- [37] Zhang F et al. "A sensor fusion approach for localization with cumulative error elimination". *IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, 1-6, 2012.
- [38] Suhr JK et al. "Sensor fusion-based low-cost vehicle localization system for complex urban environments". *IEEE Transactions on Intelligent Transportation Systems*, 18(5), 1078-1086, 2016.
- [39] Oh SI, Kang HB. "Fast occupancy grid filtering using grid cell clusters from LIDAR and stereo vision sensor data". *IEEE Sensors Journal*, 16(19), 7258-7266, 2016.
- [40] Alqaderi H, Schulz R, "Enhancement of LIDAR Data Association and Fusion Using Imaging Radar Grid-Maps for Advanced Automotive Environment Perception". *IEEE Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, 1-6, 2018.
- [41] Li Q, Li R, Ji K, Dai W, "Kalman filter and its application." *8th IEEE International Conference on Intelligent Networks and Intelligent Systems (ICINIS)*, 2015.
- [42] Aeberhard M, Kaempchen N, "High-Level Sensor Data Fusion Architecture for Vehicle Surround Environment Perception". *Proc. 8th Int. Workshop Intell*, 2011
- [43] Jeong DY, Velasco-Hernandez G, Barry J, Walsh J, "Sensor and Sensor Fusion Technology in Autonomous Vehicles: A Review". *State-of-the-Art Sensors Technologies*, 2021.