



## ARIMA YAPAY ZEKA YÖNTEMİ KULLANILARAK ISPARTA İLİNDEKİ ÖRNEK BİR KAVŞAK İÇİN ARAÇ SAYISI VE ARAÇ GEÇİŞ SÜRELERİNİN TESPİTİ

Gökhan KADİROĞULLARI<sup>1\*</sup>, Bekir AKSOY<sup>1</sup>, Hamdi SAYIN<sup>1</sup>, Melek ÖMÜR<sup>1</sup>

<sup>1</sup> Isparta Uygulamalı Bilimler University, Technology Faculty, Department of Mechatronik Engineering, Isparta, Türkiye

### Anahtar Kelimeler

Görüntü işleme,  
Derin öğrenme,  
ARIMA.

### Öz

Günümüzde teknolojinin hızla ilerlemesi ile birlikte yapay zeka hayatımızın vazgeçilmez bir parçası haline gelmiştir. Yapay zeka, bilgisayar ya da bilgisayar ile kontrol edilen faaliyetlerin insan ya da zeki canlılar gibi tahmin edebilme yöntemi olarak tanımlanabilmektedir. Yapay zeka, sağlık, eğitim, güvenlik, robotic gibi birçok uygulama alanında sıklıkla kullanılmaktadır. Yapay zekanın önemli kullanım alanlarından birisi de araçların kontrollü ve güvenli bir biçimde geçişleri için kullanılan trafik sinyalizasyon sistemleridir. Trafik sinyalizasyonu genellikle trafiğin yoğun olduğu kavşaklarda trafiğin yoğunluğuna bakmaksızın sabit süre bazlı çalışmaktadır. Bu nedenle sabit süreli trafik sinyalizasyon sistemleri günümüzde çok tercih edilmemektedir. Akıllı trafik sinyalizasyon sistemlerinde bekleme süresi ise araç sayısı ve araçların geçiş sürelerine bağlıdır. Çalışmada Isparta ilinde bulunan Ulaştırma ve Trafik Hizmetleri Müdürlüğü'nden özellikle trafiğin yoğun olduğu kavşaklardan birisi olan Otogar kavşağındaki araçlara ait video görüntüleri alınmıştır. Alınan görüntüler üzerinde görüntü işleme ve ARIMA derin öğrenme yöntemi uygulanmıştır. ARIMA derin öğrenme yöntemi ile zamana bağlı araç sayısı ve araç geçiş süreleri R<sup>2</sup> performans değerlendirme ölçütüne göre değerlendirilerek %82 ve %89 doğruluk oranı elde edilmiştir.

## DETERMINATION OF VEHICLE NUMBER AND VEHICLE TRANSIT TIME FOR A SAMPLE INTERSECTION IN ISPARTA PROVINCE USING ARIMA ARTIFICIAL INTELLIGENCE

### Keywords

Image Processing,  
Deep Learning,  
ARIMA

### Abstract

Today, with the rapid advancement of technology, artificial intelligence has become an indispensable part of our lives. Artificial intelligence can be described as a method of predicting computer or computer-controlled activities like human or intelligent creatures. Artificial intelligence are frequently used in many application areas such as health, education, security and robotics. One of the important uses of artificial intelligence is traffic signaling systems used for the controlled and safe passage of vehicles. Traffic signaling generally works on fixed time basis at intersections with heavy traffic, regardless of the traffic density. Thus, fixed time traffic signaling systems are not preferred much today. The waiting time in smart-traffic signaling systems depends on the number of vehicles and the transit time of the vehicles. The study, video footage of the vehicles at the Otogar intersection, which is one of the intersections with heavy traffic, was taken from the Directorate of Transport and Traffic Services in Isparta. Image processing and ARIMA deep-learning method were applied on the captured images. With the ARIMA deep-learning method, the number of time-dependent vehicles and the R<sup>2</sup> of vehicle transit times were evaluated according to the performance evaluation criteria and accuracy rate of 82% and 89% was obtained.

### Alıntı / Cite

Kadiroğulları, G., Aksoy, B., Sayın H., Ömür M., (2020). Determination of Vehicle Number and Vehicle Transit Time for a Sample Intersection in Isparta Province Using ARIMA Artificial Intelligence, Journal of Engineering Sciences and Design, 8(5), 11-24.

\* İlgili yazar / Corresponding author: yl1930654003@stud.sdu.edu.tr

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process	
G. Kadiroğulları, 0000-0002-8849-1363	<b>Başvuru Tarihi / Submission Date</b>	14.11.2020
B. Aksoy, 0000-0001-8052-9411	<b>Revizyon Tarihi / Revision Date</b>	03.12.2020
H. Sayın, 0000-0002-0826-8517	<b>Kabul Tarihi / Accepted Date</b>	09.12.2020
M. Ömür, 0000-0002-0831-1036	<b>Yayın Tarihi / Published Date</b>	29.12.2020

## 1. Giriş (Introduction)

Günümüzde hızla büyüyen kent nüfusu beraberinde trafik sorunlarını getirmektedir (Çakır vd., 2009). Bu sorunlar ekonomik ve sosyal hayatı olumsuz yönde etkilemektedir. İnsanların hayattaki en kıymetli değerleri zamanlarıdır. Örneğin yapılan bir araştırmada İstanbul gibi büyük şehirlerde yaşayanların kaybettikleri zamanın büyük bir kısmı da trafikte harcamaktadırlar. Bu nedenle trafik sinyalizasyon sistemlerinin önemi gitgide artmaktadır. Sinyalizasyon sistemlerinin doğru bir şekilde çalışmaması hem çevre kirliliğine hem de doğal kaynakların israfına neden olmaktadır (Kös, 2015). Yerel yönetimler bu olumsuzlukların önüne geçmek için daha geniş yollar veya alternatif yollar yapsalar da kavşaklarda yine de trafik yoğunluğu oluşmaktadır (Gençosman, 2017). Bu nedenle trafik sinyalizasyon sistemleri ile trafik akışının kontrolü sağlanmaya çalışılmıştır. Trafik sinyalizasyonu, ulaşımın düzenlenmesinde on dokuzuncu yüzyıldan itibaren kullanılmaya başlanmıştır (Başkan, 2004). Sinyalizasyon, yollar üzerinde ve özellikle kavşaklarda trafiğin düzenli ve güvenli bir şekilde sağlanması için belirli zamanlarda periyodik olarak trafik akışını düzenlemektedir (Şimsir vd., 2013). Sinyalizasyon sistemlerinde zaman dağılımları yayaların ve taşıtların güvenliği için oldukça önemlidir (Utku, 2008). Trafik akışını kontrol etmede kullanılan sinyalizasyon sistemleri koordine ve izole sinyalizasyon sistemler olmak üzere iki ana gruba ayrılmaktadır (Gençosman, 2017).

Son yıllarda sinyal sürelerinin en ideal hale getirmesinde yapay zekâ algoritmaları kullanılmaktadır. Yapay zekâ makine öğrenmesi ve makine öğrenmesinin bir alt dalı derin öğrenme kavramları içermektedir (İpek vd., 2020). Makine öğrenmesinin bir alt dalı olan derin öğrenme, yöntemindeki algoritmalar insan beynindeki nöronlar gibi çalışmaktadır. Derin öğrenmeyi makine öğrenmesinden ayıran özellik öğrenme kurallarını kendisi oluşturmasıdır (Aydın vd., 2017). Derin öğrenmede verinin temsillerini öğrenebilmek için çoklu işleme katmanlarından oluşmaktadır (Şeker vd., 2017). Derin öğrenme yüksek seviyedeki ses ve görüntü verilerinde sınıflandırma ve kümeleme gibi işlemleri insan yeteneklerine yakın derece yapabilmektedir (Amato vd., 2017). Derin öğrenmede, veri ön işleme aşaması olmadığından dolayı veriden özellik çıkarımı yaparak öğrenmeyi sağlamaktadır (Barbedo, 2018).

Derin öğrenmenin tıp (Nasip vd., 2018; Toraman vd., 2020; Yıldız, 2019) ve sağlık (Türkçetin vd., 2019; Keleş, 2018; Kaya vd., 2019) gibi birçok alanda sıklıkla kullanılmaktadır. Derin öğrenmenin önemli kullanım alanlarından birisi de trafik sinyalizasyon sistemleridir. Özellikle trafik akışını hızlandırma ve yönlendirmede yapay zeka yöntemleri kullanılmaktadır. Çalışmada Isparta ilinin trafik yoğunluğu fazla olduğu kavşaklardan birisi olan Otogar kavşağındaki Mobil Elektronik Sistem Entegrasyonu (Mobese) görüntüleri Isparta Ulaştırma ve Trafik Hizmetleri Müdürlüğü'nden alınarak veri seti oluşturulmuştur. Elde edilen görüntüler üzerinde ARIMA derin öğrenme yöntemi kullanılarak zamana bağlı araç sayısı ve araç geçiş süreleri korelasyon katsayısı (ing. Squared  $R^2$ ) performans değerlendirme ölçütüne göre %82 ve %89 doğruluk oranında tespit edilmiştir.

## 2. Kaynak Araştırması (Literature Survey)

Sönmez vd. (2005) yapmış oldukları çalışmada video görüntülerinden yararlanarak sinyalize bir kavşakta trafik akışının başlangıçta durma yoğunluğunda bulunan ve duran taşıtların kavşaktan ayrılmasıyla azalmaya başlayan trafik yoğunluğunun, yol ve zaman boyunca değişimini veren matematiksel model geliştirmişlerdir.

Öztürk (2006) yapmış oldukları uygulamada bir birinin alternatifi olan iki yolun sensörler yardımıyla araç yoğunluğunu mikro denetleyici yardımıyla değerlendirerek sürücülerini trafiğin az olduğu yola yönlendiren bir model geliştirmişlerdir. İstanbul boğaz köprülerinde buna benzer bir sistem kullanılmaktadır.

Erdem'in (2007) yapmış olduğu bu çalışmada önceden tahmin edilemeyen trafik yoğunluğunun yaşandığı kavşaklar için gerçek zamanlı olarak trafik akışının denetlenmesine yönelik bir çalışmadır. Bulanık mantık yöntemiyle yapılan bu çalışmada, sabit zaman aralıklı kesin kural tabanlı sistemlere göre değişken trafik yoğunluklarının olduğu kavşaklarda daha iyi sonuç alınmıştır. Kavşaklarda yaptıkları ölçüm sonuçlarında çıkış değerleri çok esnek alınmasına rağmen %26-36 arasında kırmızı ve yeşil ışık için uygun yanma zaman süreleri oluşmuştur. Bu değerlerde çalışma ile gerçekleştirilen yöntemin klasik yöntemlere göre daha başarılı olduğunu tespit etmiştir.

Çakır vd.(2009) yapmış oldukları çalışmada ise PLC tabanlı bir trafik sinyalizasyon sistemi gerçekleştirmişlerdir.

Çalışmalarında kavşaklara yerleştirilen sensörlerden alınan veriler doğrultusunda PLC’de geliştirilmiş olan algoritmayla trafik akış yoğunluğuna göre sinyalizasyon sisteminin süreleri düzenlenmiştir. Ayrıca araç sensörlerden alınan bilgiler doğrultusunda taşıtların kavşağa giriş ve çıkış hızları da tespit edilmektedir. Gerçekleştirdikleri bu sistemle trafik lambalarının yanma sürelerini trafik yoğunluğu doğrultusunda dinamik olarak ayarlayabilmişlerdir. Böylelikle yoğun trafiklerde araç geçişlerinin kesintiye uğraması engellenmiş ve trafik akışını hızlandırmışlardır. Trafik yoğunluğunun az olduğu bölgelerde ise gereksiz beklemleri azaltmışlardır.

Gençosman (2017) yılında yapmış olduğu çalışmada kavşaklardaki şeritlere yerleştirdiği manyetik sensörler yardımıyla bir veri tabanı oluşturmuştur. Oluşturduğu bu veri tabanı ile yapay sinir ağları modellerinden olan Radyal Tabanlı Fonksiyon ağlarını kullanarak uyarlanabilir sinyal kontrol sistemindeki yeşil sinyal sürelerin tahmin edilmesinde başarılı bir yöntem olduğunu tespit etmiştir. Radyal Tabanlı Fonksiyon ağının performans testlerinde 0 saniye tolerans ile uyarlanabilir yeşil süreleri %72.5 oranında 1 saniye tolerans ile %97.25 oranında başarı elde etmiştir.

Javaid vd. (2018) yapmış oldukları çalışmada nesnelerin internetini kullanan akıllı trafik yönetim sistemi geliştirmişlerdir. Çalışmada nesnelerin internetini kullanarak akıllı bir trafik yönetim sistemi ve trafik akışını optimize etmek için merkezi olmayan bir yaklaşım geliştirmişlerdir. Geliştirdikleri sistemde Mobese görüntüleri üzerinde görüntü işleme yöntemleriyle trafik yoğunluğunu tespit etmişlerdir. Tespit edilen yoğunluk değeri eşik değerini geçiyor ise eşik değerinin altına düşene kadar yeşil ışığı sürekli yanmakta, eşik değerinin altında ise sinyalizasyon sistemleri normal çalışmaktadır.

Mohammad Albatish ve Abu-Naser’in (2019) yapmış oldukları çalışmada kural tabanlı sistem kullanarak akıllı trafik ışığı sisteminin modellenmesi ve kontrol edilmesi çalışmasını gerçekleştirmişlerdir. Çalışmada trafik sıkışıklığını çözmek için kural tabanlı yapay zekâ yöntemi kullanmışlardır. Çalışma trafik ışığı uzman sistemi (TLES) ve donanım tasarımı olmak üzere iki bölümünden oluşmaktadır. Sistemin donanımı için Arduino geliştirme kartı ve IR sensörler kullanılmıştır. Önerdikleri bu yöntem ile kavşaklardan geçen araç sayısını artırarak şeritlerde sürücülerin bekleme sürelerini azaltan dinamik bir uygulama için prototip sistem tasarlamışlardır. Prototipini hazırladıkları sistemin bir grup uzmana test ettirmişlerdir. Uzmanlardan sistemin değerlendirmesi için bir anket doldurarak geri bildirimde bulunmaları istenmiştir. Anket sonuçlarına göre önerilen çalışmanın doğruluğu %90 ve uygulanabilirliği %88 olarak tespit etmişlerdir.

Yiğit (2019) tarafından yapılan diğer bir çalışmada ise Denizli ilinin Mimar Sinan kavşağından toplanan veriler ile kavşaktaki bekleme sürelerini optimize edilmiştir. Kavşaktaki bekleme sürelerini optimize etmek için yapay sinir ağını ve oto-regresif entegre hareketli ortalama yöntemlerini kullanarak kısa zamanlı trafik tahmini gerçekleştirmiştir. İki yöntemden de elde edilen sonuçları performans testlerine tabi tutmuş ve sonuçlar karşılaştırmıştır. Tahminleme sonuçları doğrultusunda ARIMA yönteminde gecikme iyileştirmeleri %20 ile %40 arasında iken, YSA (Yapay Sinir Ağı) modeli gecikme iyileştirmelerinde başarısız sonuçlar gösterdiğini tespit etmişlerdir.

Frank vd. (2019) yapmış olduğu çalışmalarında görüntü işleme yönteminin kullanarak nesnelerin interneti tabanlı akıllı trafik yoğunluğu kontrolü çalışmasını önermişlerdir. Önerilen bu yöntem ile gerçek trafik yoğunluğunun ölçümü, gerçek zamanlı bir video ve görüntü işleme tekniği kullanarak elde edilmiştir. Elde edilen gerçek zamanlı görüntülerden trafik yoğunluğunun hesaplanması için sunucuda önceden ayarlanmış görüntüler ile çapraz doğrulama yapılmıştır. Yoğunluğa bağlı olarak da kavşaklardaki trafik hareketlerini düzenleyerek trafik yoğunluğunun azalmasını sağlamışlardır.

Çakıcı (2020) yılında yapmış olduğu doktora tezinde sinyalizasyon kavşaklarının performansını ve hizmet düzeylerini artırmak amacıyla kavşaklardaki gecikmeleri azaltmak için sinyal ve faz planı optimizasyonu tabanlı denetim modeli geliştirmiştir. Geliştirdiği modelde Diferansiyel Gelişim Algoritmasını kullanarak sinyal sürelerini ve faz planını optimize etmiştir.

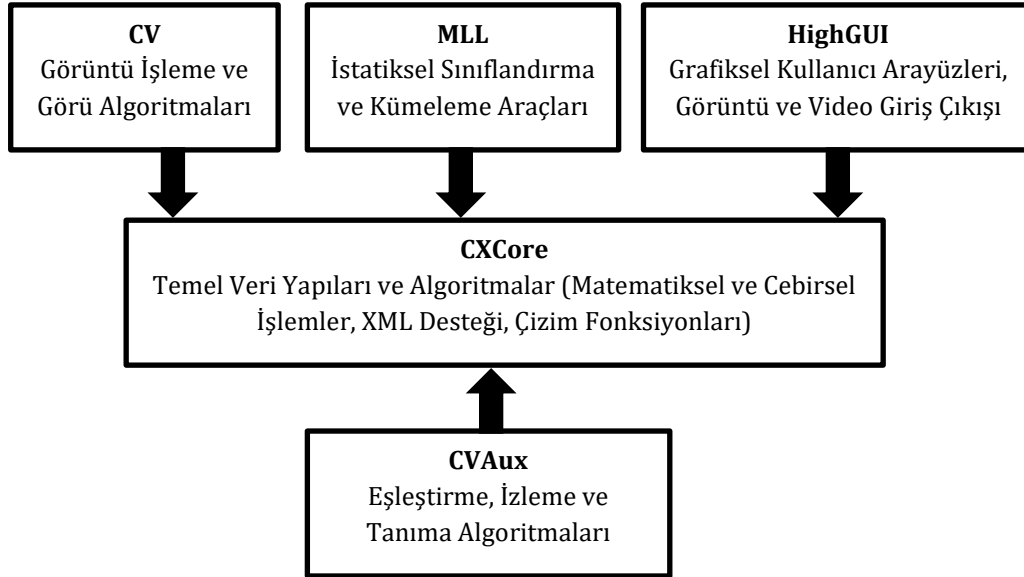
### **3. Materyal ve Yöntem (Material and Method)**

#### **3.1. Materyal(Material)**

Çalışmada, Isparta Ulaştırma ve Trafik Hizmetlerinin mobese görüntülerinden faydalanılarak Isparta’nın en yoğun kavşaklarından biri olan otogar kavşağındaki 45 saatlik video görüntüsü alınmıştır. Bu görüntüler üzerinde 27.01.2020 tarihindeki trafiğin yoğun olduğu sabah 08:00 ile akşam 19:00 saatleri arasındaki görüntüler kullanılmıştır. Python programlama dilinde OpenCv Kütüphanesi ve ARIMA derin öğrenme modeli kullanılarak araç geçiş süreleri ve sayılarının tahminlenmesi gerçekleştirilmiştir. OpenCV, ARIMA ve performans değerlendirme ölçütleri hakkında detaylı bilgiler aşağıda verilmiştir.

### 3.1.1. OpenCv kütüphanesi (OpenCv Library)

OpenCv 1999 yıllarında ilk sürümü Intel firması tarafından geliştirilen görüntü işleme kütüphanesidir (Wang vd., 2010). Görüntüler içerisinde anlamlı bilgilerin çıkarılması için Intel firması tarafından C ve C++ dilleri kullanılarak geliştirilmiş olup açık kaynaklı bir kütüphanedir (Doğan vd., 2013). OpenCV kütüphanesini içerisindeki görüntü işleme ve bilgisayarlı görme algoritmalarıyla hareket tespiti, yüz tanıma gibi pek çok uygulamada kullanılmaktadır. OpenCV kütüphanesi, gerçek zamanlı uygulamaları hedef alınarak geliştirilmiştir (Tenekeci vd., 2014). OpenCV'nin bir alt kütüphanesinde görüntü tanıma ve kümeleme gibi görüntü işlemede sıklıkla kullanılan makine öğrenmesi fonksiyonları da mevcuttur (Özcan vd., 2013). Temel olarak OpenCV kütüphanesi beş bileşenden oluşmaktadır. Şekil 1'de OpenCV kütüphanesinin temel bileşenleri görülmektedir.



Şekil 1. OpenCV Temel Bileşenleri (Doğan vd., 2013). (OpenCV Basic Components)

### 3.1.2. Arka Plan Çıkarımı (Background Extraction)

Görüntülerde hareketli nesnelerin tespitinde ve takip edilmesinde arka plan çıkarımı sıklıkla kullanılan bir yöntemdir (Karaköse vd., 2016). Arka plan çıkarımı genellikle sabit bir zemin üzerinde hareketli nesnelerin takibi ya da tespiti için kullanılmaktadır (Karasulu vd., 2016). Arka plan çıkarımı yönteminde temel mantık sabit olan yüzey ya da zemin üzerindeki değişikliklerden faydalanarak nesnelerin takip edilmesini ve belirlenmesini sağlamaktadır (Güner vd., 2016). Arka plan çıkarımı yönteminin matematiksel ifadesi eşitlik (1)'de verilmiştir. Eşitlik (1)'deki  $\psi_e$ ,  $e$  anındaki hareket etiketi olarak tanımlanmaktadır. Eşitlikteki  $V_{m,e}$  video içerisindeki  $m$  pikseli ile arka plana ait  $m$  pikseli arasındaki mesafe ise  $u$  ile gösterilmektedir.  $T_\lambda$  terimi ise eşik değerini ifade etmektedir (Karaköse vd., 2016).

$$\psi_e(m) = \begin{cases} 1, & \text{eğer } u(V_{m,e}, B_m) > T_\lambda \\ 0, & \text{diğer} \end{cases} \quad (1)$$

### 3.1.3. Gaussian Filtresi (Gaussian Filter)

Gaussian filtreleme yöntemi görüntülerdeki ayrıntıları veya gürültüleri kaldırmak için kullanılan iki boyutlu filtreleme yöntemidir (Okumuş vd., 2015). Bu filtreleme yönteminin önemli avantajlarından birisi de filtreleme işlemleri yatayda ve dikeyde gerçekleştirilmesidir (Tanyıldızı vd., 2016). Gaussian filtrelemenin genel matematiksel ifadesi eşitlik (2)'de verilmiştir.

$$G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}} \quad (2)$$

Eşitlikteki  $G(x)$  gaussian filtre değerini,  $x$  satır,  $y$  sütunları ve  $\sigma$  (sigma) ise gaussian dağılımın standart sapmasını temsil etmektedir[30].

Eşitlik (2)'deki matematiksel ifadenin iki boyutlu görüntüler için matematiksel ifadesi eşitlik (3)'de verilen matematiksel ifade ile elde edilmektedir (Doğan vd., 2014).

$$G(x, y) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3)$$

### 3.1.4. Morfolojik Filtreleme (Morphological Filtering)

Morfolojik filtreleme görüntülerdeki nesnelerin geometrik şekillerine dayalı kümeler teorisi ile oluşturulmuş görüntü işleme yöntemidir (Topaloğlu, 2004). Görüntülere morfolojik filtreleme uygulandığında görüntü içerisindeki istenilen nesnenin belirlenmesi için nesnelere ayırt edilmesini, görüntülerdeki gürültülerin azalması ve bölütleme gibi işlemlerin uygulanmasını sağlamaktadır (Karhan vd., 2011).

### 3.1.5. ARIMA Modeli (ARIMA Model)

ARIMA modelinin ilk olarak 1951 yılında Peter Whittle tarafından bulunmuş ve 1971 yılında bir kitap haline geldikten sonra popüler hale gelmiştir (Moralı, 2011). ARIMA modelinin bir diğer ismi de Box-Jenkins olarak da bilinmektedir (Vergil ve Özkan, 2007). Literatür incelendiğinde ARIMA modeli ulaştırma sektöründe oldukça fazla tercih edilmektedir. Trafik akışının analizinde ve modellenmesinde de yoğun olarak ARIMA modelleri kullanılmaktadır (Tortum vd., 2014). ARIMA üç temel parametreden oluşan bir tahmin modelidir. ARIMA modeli  $p$ ,  $q$  ve  $d$  parametrelerinden oluşmaktadır (Solak vd., 2013).  $p$  değeri otoregresif modeli (AR) derecesini,  $d$  parametresi durağanlık için alınan fark derecesini ve son olarak  $q$  parametresi ise hareketli ortalamanın (MA) derecesini göstermektedir. ARIMA modeli durağan olmayan süreçlerde kullanılırken modeli oluşturan AR( $p$ ), MA( $q$ ) ve bunların birleşimi olan ARMA( $p, q$ ) durağan süreçlerde kullanılmaktadır (Duru, 2007). Oluşturulan ARIMA modelinin seçiminde Akaike ve Schwarz bilgi kriterleri kullanılmıştır.

#### 3.1.5.1. Akaike Bilgi Kriteri (Akaike Information Criteria)

Akaike bilgi kriteri bir veri seti için istatistiksel göreceli model ölçüsüdür. Akaike bilgi kriteri modelleri birbirlerine göre kalitesini göreceli olarak tahmin etmektedir. Dolayısıyla model seçimleri için bu bilgi kriteri kullanılmaktadır (Ucal, 2006). Akaike bilgi kriterinin matematiksel ifadesi Eşitlik (4)'de verilmiştir. Eşitlikte  $k$  değeri sabit terimler dahil parametre sayısını, ve  $L$  değeri ise benzerliği vermektedir. Model seçiminde ise AIC bilgi kriteri küçük olmalıdır (Atalay, 2012).

$$AIC = -2 \log(L) + 2k \quad (4)$$

#### 3.1.5.2. Schwarz Bilgi Kriteri (Schwarz Information Criteria)

Schwarz bilgi kriteri, Gideon Schwarz tarafında 1978 yılında sunulmuştur (Bahadır ve Saraçlı, 2010). Model seçiminde Schwarz değerinin düşük olanın seçilmesi gerekmektedir (Atalay, 2012). Schwarz bilgi kriteri, Akaike bilgi kriterine göre modele eklenecek yeni değişkenler için ortaya çıkacak durumlar için daha dikkatli düzenlenmiştir (Ucal, 2006). Schwarz bilgi kriterinin logaritmik formu eşitlik (5)'de verilmiştir. Eşitlikte RSS değeri kalıntı kareler toplamını,  $n$  gözlem sayısını ve  $k$  ise sabit terim dahil olmak üzere parametre sayısını temsil etmektedir (Ucal, 2006).

$$\ln SIC = \frac{k}{n} \ln(n) + \ln \left( \frac{RSS}{n} \right) \quad (5)$$

### 3.1.6. Performans Değerlendirme Ölçütleri (Performance Evaluation Criteria)

Çalışmada ARIMA modelinden elde edilen sonuçlar Ortalama Kare Hata (İng. Mean Square Error (MSE)), Ortalama Mutlak Hata Yüzdesi (İng. Mean Absolute Percentage Error(MAPE)) ve  $R^2$  performans değerlendirme ölçütleri kullanılarak değerlendirilmiştir.

#### 3.1.6.1. Ortalama Kare Hata (MSE-Mean Square Error)

MSE, regresyon eğrisinin bir dizi noktaya ne kadar yakın olduğunu ifade etmektedir. Bu yöntemde ortalama kare hatanın değeri sıfıra ne kadar yakın olursa modelin performansı o kadar yüksektir (Yavuz ve Deveci, 2012). Ortalama kare hata değerini hesaplamada eşitlik (6)'da verilen matematiksel ifade kullanılmaktadır (Calp, 2019). Eşitlikte  $y_t$  gerçek değerleri,  $\hat{y}_t$  tahmin değerlerini ve son olarak  $T$  ise tahmin sayısını ifade etmektedir.

$$MSE = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2 \quad (6)$$

### 3.1.6.2. Ortalama Mutlak Hata Yüzdesi (MAPE-Mean Absolute Percentage Error)

MAPE, zaman serileri ve regresyon modellerinin doğruluklarının ölçümünde sıklıkla kullanılan performans değerlendirme ölçütlerinden birisidir. MAPE performans değerlendirme ölçütünün matematiksel ifadesi eşitlik (7)'de verilmiştir (Takma vd., 2012). Eşitlik (7)'de  $y_t$  gerçek değerleri,  $\hat{y}_t$  tahmin değerlerini ve son olarak  $T$  ise tahmin sayısını ifade etmektedir.

$$MAPE = 100 - \frac{1}{T} \sum \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (7)$$

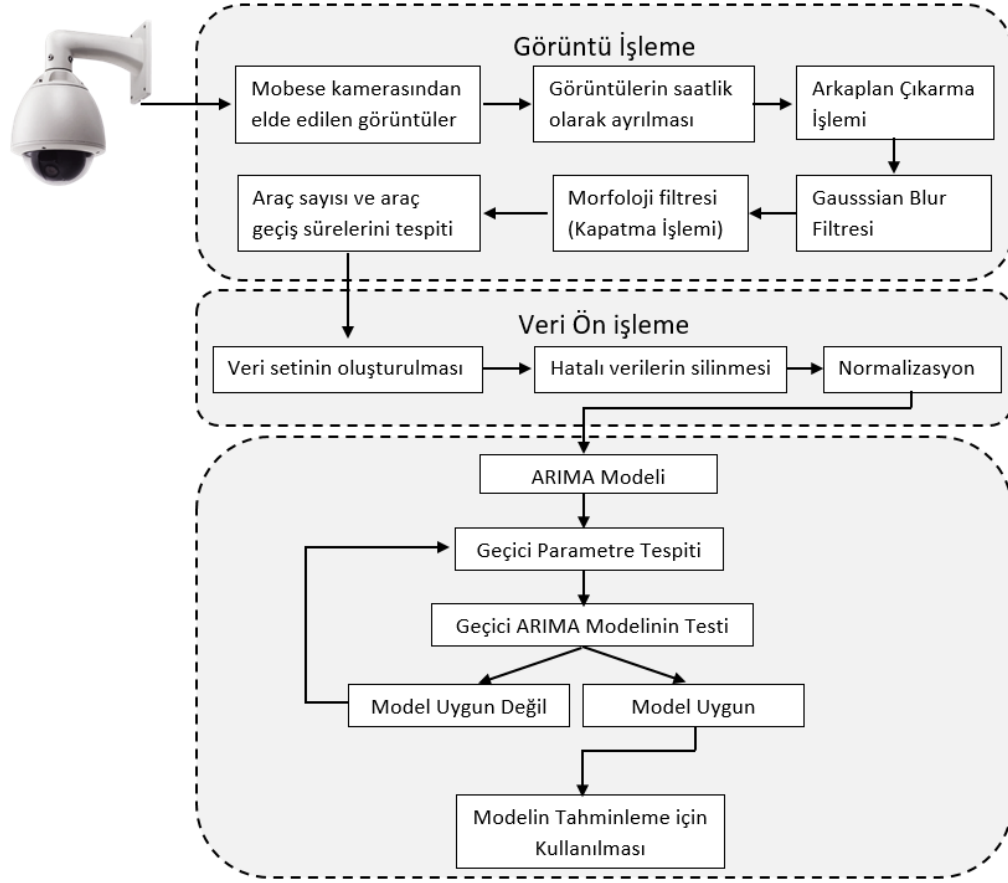
### 3.1.6.3. R<sup>2</sup> Değerlendirme Ölçütü (R<sup>2</sup> Performance Evaluation Criteria)

R<sup>2</sup>, modellerin tahmin ettiği değerler için tahminlerdeki doğruluk ya da isabet derecesini belirtmektedir. R<sup>2</sup> performans değerlendirme ölçütünün matematiksel ifadesi eşitlik (8)'de verilmiştir (Keskin, 2018). Eşitlikte  $y_i$  deneysel olarak saptanmış değerleri,  $\hat{y}$  regresyon eşitliğinden hesaplanmış değerleri ve  $\bar{y}$  ise deneysel verilerin ortalamasını ifade etmektedir.


$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (8)$$

## 3.2. Metot (Method)

Çalışmanın iş akış diyagramı şekil 2'de verilmiştir. Şekilde de görüldüğü gibi ilk olarak Isparta Ulaştırma ve Trafik Hizmetlerinin mobese görüntülerinden elde edilen görüntüler üzerinde görüntü işleme yöntemleri kullanılarak taşıt sayımı gerçekleştirilmiştir. Taşıt sayımı şekil 3'de görülen otogar kavşağındaki Isparta merkezinden üniversite yönüne doğru olan yoldaki araçların sayımı ve geçiş süreleri ölçülmüştür. Mobese görüntülerinden araç sayımı ve geçiş süreleri ölçümleri yapılmadan önce gaussian ve morfoloji gibi filtrelemelerden geçirilerek yumuşatma işlemi gerçekleştirilmiştir. Filtreleme işlemleri ile görüntüler üzerinde iyileştirmeler yapılmıştır. Elde edilen toplam 169 adet verilerden hatalı veriler ayıklanmış ve normalizasyon işlemine tabi tutulmuştur. Son olarak araç sayısı ve araç geçiş süreleri için ARIMA derin öğrenme modeli ile modellenmiştir.



Şekil 2. İş Akış Diyagramı (Work Flow Diagram)



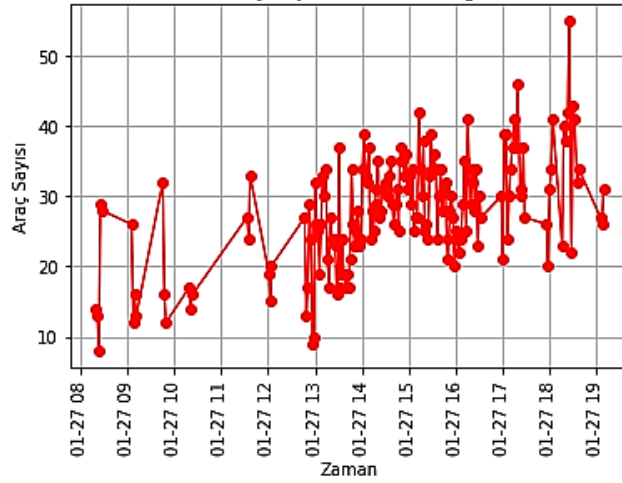
Şekil 3. Otogar Kavşağı (Bus terminal intersection)

#### 4. Araştırma Bulguları (Research Findings)


Çalışmada Isparta ilinin otogar kavşağındaki mobese görüntülerinden yararlanılarak kavşaktan geçen araç sayısı ve bu araçların geçiş süresi verileri kullanılarak zaman serileri analizi yöntemi ile zamansal analiz yapılmıştır. Belirlenen kavşaktaki araç sayısı ve araç geçiş süreleri Box-Jenkins yöntemi kullanılarak modellenmiştir. Zaman serileri analizi için uygulamada Python programlama dili kullanılmıştır.

Trafik sinyalizasyon sisteminin modellenmesinde ilk olarak şekil 4'de ve şekil 5'de gösterildiği gibi araç sayısı ve geçiş süresi grafikleri çizdirilmiştir. Elde edilen grafikler incelendiğinde araç sayısı ve geçiş süresi verilerinde bir durağanlığın olmadığı görülmektedir. Şekil 6'da verilerin durağan olmadığını test etmek için oto korelasyon eğrisi çizdirilmiştir. Şekil 6'daki araç sayısı serisinin oto korelasyonu incelendiğinde ilk 9 verinin gecikme sınırını aştığı


görülmektedir. Şekil 7'de ise araçların geçiş sürelerinin oto korelasyonuna bakıldığında da ilk 6 verinin gecikme süresini geçtiği görülmektedir. Şekil 6 ve şekil 7'deki sonuçlar her iki verinin durağan olmadığını göstermektedir.



Şekil 4. Araç Sayısı Zaman Grafiği (Vehicle Count-Time Chart)

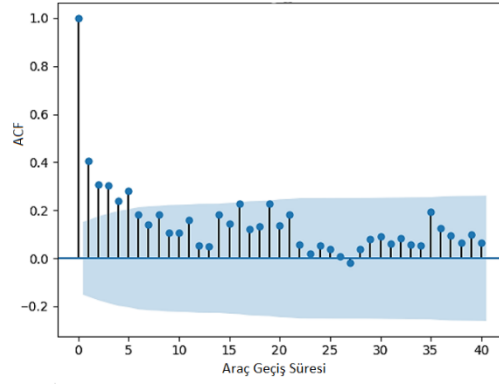


Şekil 5. Araç Geçiş Süresi Zaman Grafiği (Vehicle Transit Time-Time Graph)




Şekil 6. Araç Sayısı Serisinin Oto korelasyonu (Autocorrelation of Vehicle Count Series)






Şekil 7. Araç Geçiş Süresi Serisinin Oto korelasyonu (Autocorrelation of Vehicle Transition Time Series)

Bu iki veri setinin ARIMA modelinde tahminlenmesi için ilk olarak veri setinin doğal logaritması alınıp veri değişim aralığı küçültülerek normalizasyon işlemi gerçekleştirilmiştir. Şekil 8’de normalize işlemi yapılmış serilere ait grafikler verilmiştir. Normalize edilmiş veriler birinci dereceden fark alınarak serilerin oto korelasyonları incelenmiştir.

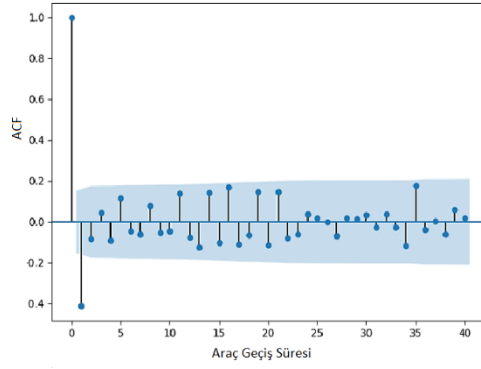


Şekil 8. Normalize Edilmiş Veriler (Normalized Data)

Şekil 9 ve şekil 10’daki oto korelasyona bakıldığında serinin durağanlaştığı görülmektedir. Veri setlerimizi durağan hale getirdikten sonra en iyi ARIMA derin öğrenme modelinin seçimine geçilmiştir. Veri setini birinci dereceden fark alma işlemi yapıldığında durağan hale geldiği için ARIMA modelindeki  $d$  fark alma değeri 1 olarak seçilip diğer değerler üzerinde farklı modeller test edilerek en doğru sonucu veren model tespit edilmiştir.



Şekil 9. Araç Sayısı Birinci Dereceden Durağanlaştırma İşleminin Otokorelasyonu (Autocorrelation of First Order Stabilization Process for Number of Vehicle)



**Şekil 10.** Geçiş Süresi Birinci Dereceden Durağanlaştırma İşleminin Otokorelasyonu (Autocorrelation of Vehicle Transition Time First Order Stabilization Process)

Tablo 1 ve tablo 2’de her iki veri seti için en iyi modelin belirlenmesinde kullanılan parametreler verilmiştir.

**Tablo 1.** Araç Sayısı Serisi İçin Oluşturulan Alternatif Model Tahmin Sonuçları (Alternative Model Estimation Results for Vehicle Number Series)

Modeller	Olabilirlik Oranı (Log Likelihood)	Akaike Bilgi Kriteri (AIC)	Schwarz Bilgi Kriteri (SIC)
ARIMA(1,1,0)	-38.557	83.115	92.451
ARIMA(1,1,1)	-11.451	30.902	43.350
ARIMA(2,1,1)	-10.315	30.631	46.191
ARIMA(1,1,2)	-10.838	31.675	47.235
ARIMA(2,1,2)	-11.451	34.903	53.574
ARIMA(3,1,1)	-10.172	32.344	51.016
ARIMA(4,1,2)	-9.581	35.161	60.057
ARIMA(4,1,1)	-9.655	33.310	55.094

**Tablo 2.** Araç Geçiş Süresi Serisi İçin Oluşturulan Alternatif Model Tahmin Sonuçları (Alternative Model Estimation Results for Vehicle Transit Time Series)

Modeller	Olabilirlik Oranı (Log Likelihood)	Akaike Bilgi Kriteri (AIC)	Schwarz Bilgi Kriteri (SIC)
ARIMA(1,1,0)	-14.974	35.947	45.283
ARIMA(1,1,1)	7.417	-6.834	5.614
ARIMA(2,1,1)	7.442	-4.883	10.677
ARIMA(1,1,2)	7.639	-5.278	10.282
ARIMA(2,1,2)	7.491	-2.981	15.691
ARIMA(3,1,1)	Model tarafından hesaplanamamıştır.		
ARIMA(4,1,2)	7.730	0.540	25.436
ARIMA(4,1,1)	Model tarafından hesaplanamamıştır.		

Tablo 1 ve tablo 2’de verilen parametrelere göre en doğru tahmini verecek modeli belirlemede aşağıda verilen kriterler göz önünde bulundurulmuştur.

- İlk olarak tahmin edilen parametrelerin anlamlı olmalıdır.
- İkinci aşamada ise yüksek bir belirleme katsayısına (veya düzeltilmiş belirleme katsayısına) sahip olmalıdır.
- AIC ve SIC bilgi kriterleri küçük olmalıdır..

- Olabilirlik oranı mümkün olduğunca yüksek olmalıdır.

Tablo 1 ve tablo 2 incelendiğinde olabilirlik oranı değeri en yüksek olan, Akaike ve Schwarz bilgi kriteri en az olan model ARIMA(2,1,1) ve ARIMA (1,1,1) olduğu görülmektedir. Bu nedenle Araç sayısının tahminlenmesinde ARIMA (2,1,1) modeli araç geçiş süresinin tahminlenmesinde ise ARIMA (1,1,1) modeli kullanılmıştır. Bu modellere ait MSE, MAPE ve R<sup>2</sup> performans değerlendirme sonuçları tablo 3’de verilmiştir.

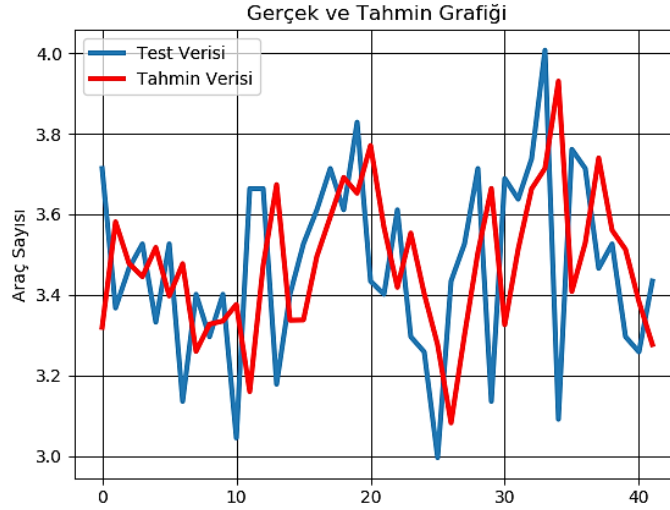
<b>Tablo 3. Performans Değerlendirmesi (Performance Evaluation)</b>	
Araç Sayısı Tahmini için kullanılan model ARIMA (2,1,1)	
<b>MSE</b>	0.063
<b>MAPE</b>	93.99
<b>R<sup>2</sup></b>	82.13
Araç Geçiş Süresi Tahmini için kullanılan model ARIMA (1,1,1)	
<b>MSE</b>	0.054
<b>MAPE</b>	94.61
<b>R<sup>2</sup></b>	89.7831

Tablo 4’de ARIMA(2,1,1) ve ARIMA (1,1,1) modelleri için katsayı değerleri verilmiştir.

**Tablo 4.** ARIMA(2,1,1) ve ARIMA(1,1,1) modellerinin katsayıları (Coefficients of ARIMA (2,1,1) and ARIMA (1,1,1) models)

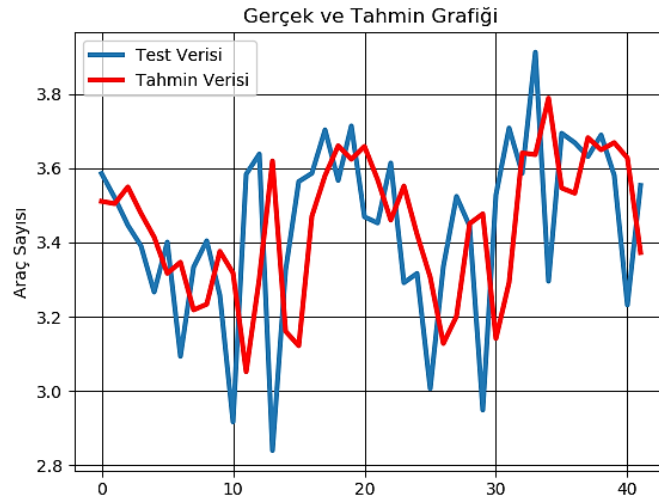
Araç Sayısı Tahmini için kullanılan model ARIMA (2,1,1)				
Değişkenler	Katsayı	Std. Hata	t-İstatistiği	Önem
C	0.0043	0.002	2.250	0.024
AR(1)	0.1726	0.083	2.071	0.038
AR(2)	-0.1246	0.082	-1.519	0.129
MA(1)	-0.9159	0.037	-24.889	0.000
Araç Geçiş Süresi Tahmini için kullanılan model ARIMA (1,1,1)				
Değişkenler	Katsayı	Std. Hata	t-İstatistiği	Önem
C	0.0030	0.001	2.510	0.012
AR(1)	0.2028	0.089	2.283	0.022
MA(1)	-0.9568	0.038	-25.208	0.000

Şekil 11’de ARIMA (2,1,1) modelinden elde edilen araç sayıları ile gerçek araç sayılarının grafiği verilmiştir. Grafik incelendiğinde ARIMA(2,1,1) modelinden elde edilen sonuçların gerçek değerleri oldukça yakın olduğu görülmektedir.



**Şekil 11.** Araç Sayısının Tahmin Değerleri Ve Gerçek Değerler (Estimated Values and Actual Values of Vehicle Count)

Şekil 12’da ise ARIMA(1,1,1) modelinden elde edilen araç geçiş süresi değerleri ile gerçek değerler aynı grafik üzerinde gösterilmiştir. Kullanılan modelin gerçek değerlere yakın sonuçlar verdiği şekilde görülmektedir.



**Şekil 12.** Araç Geçiş Süresinin Tahmin Değerleri Ve Gerçek Değerleri (Estimated Values and Actual Values of Vehicle Transit Time)

## 5.Sonuç(Result)

Bilgi ve teknoloji çağının hızla geliştiği dünyamızda yapay zeka yöntemleri de oldukça hızlı bir şekilde gelişmektedir. Yapay zeka yöntemleri hemen hemen tüm alanlarda sıklıkla kullanılmaktadır. Yapay zekanın önemli kullanım alanlarından birisi de trafik akışını hızlandırma da oldukça önemli olan trafik sinyalizasyon sistemleridir.

Çalışmada Isparta ilindeki en yoğun yaya ve taşıt kavşaklarından olan otogar kavşağından elde edilen mobese görüntüleri için ARIMA modelinden faydalanılarak araçların belirli saatlerdeki geçiş süreleri ve sayılarının tahminlenmesi açısından değerlendirilmiştir. Elde edilen sonuçlar aşağıda maddeler halinde verilmiştir.

- İlk olarak Python programlama dilinde OpenCv kütüphanesi kullanılarak görüntü işleme yöntemiyle araçların geçiş süreleri ve sayıları gerçekleştirilerek veri seti oluşturulmuştur.
- İkinci olarak oluşturulan araç sayısı ve geçiş süreleri için en ideal ARIMA derin öğrenme modelinin seçimi için AIC ve SIC bilgi kriterlerinden yararlanılmıştır. Bu bilgi kriterleri

doğrultusunda oluşturulan modeller içerisinde en iyi sonucu veren model seçilmiştir. Araç geçiş süreleri için en iyi modelin ARIMA (1,1,1) ve araçların sayısı için ARIMA(2,1,1) modelinin en uygun modeller olduğu tespit edilmiştir.

Seçilen en uygun modeller üzerinde MSE,  $R^2$  ve MEAN performans değerlendirme kriterlerine göre başarı oranları incelenmiştir. Değerlendirme sonucunda ARIMA (2,1,1) modelinin MAPE değerinde %93.99 ve  $R^2$  %82.13 doğruluk değeri ile başarılı tahmin gerçekleştirdiği belirlenmiştir. ARIMA (1,1,1) modelinde ise MAPE değerinde %94.61 ve  $R^2$  %89.78 doğruluk değeri ile başarılı tahmin gerçekleştirdiği belirlenmiştir. Daha sonraki akademik çalışmalarda veri seti üzerinde farklı yapay zekâ algoritmaları kullanılarak elde edilen doğruluk değerinin artırılması düşünülmektedir.

### Teşekkür (Acknowledgement)

Araştırmanın yapılmış olduğu veri setini sağlayan Isparta Ulaştırma ve Trafik Hizmetleri Müdürlüğü'ne teşekkür ederiz.

### Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

### Kaynaklar (References)

- Amato, G., Carrara, F., Falchi, F., Gennaro, C., Meghini, C., & Vairo, C., 2017. Deep learning for decentralized parking lot occupancy detection. *Expert Systems with Applications*, 72, 327–334. <https://doi.org/10.1016/j.eswa.2016.10.055>
- Albatish, I. M., Abu-Naser, S. S., 2019. Modeling and Controlling Smart Traffic Light System Using a Rule Based System. In 2019 International Conference on Promising Electronic Technologies (ICPET) (pp. 55-60). IEEE.
- Atalay, A., Tortum, A., Gökdağ, M., 2012. Türkiye'de 1977-2006 Yılları Arasında Meydana Gelen Aylık Trafik Kazalarının Zamansal Analizi. *Pamukkale University Journal of Engineering Sciences*, 18(3).
- Aydin, E., & Yüksel, S. E., 2017. Buried target detection with ground penetrating radar using deep learning method. In 2017 25th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- Bahadır, M., & Saraçlı, S., 2010. Isparta'da Arıma Modeline Göre Sentetik İklim Verilerinin Analizi. *Nature Sciences*, 5(3), 163-177.
- Barbedo, J. G. A., 2018. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. *Computers and electronics in agriculture*, 153, 46-53.
- Başkan, Ö., 2004. İzole sinyalizasyon kavşaklardaki ortalama taşıt gecikmelerinin yapay sinir ağları ile modellenmesi (Master's thesis, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü).
- Çakıcı, Z. 2020. Sinyalizasyon kavşakları için optimizasyon tabanlı trafik yönetim modeli.
- Çakır, A., Çalış, H., Dandil, E., 2009. PLC Tabanlı Dinamik Trafik Sinyalizasyon ve Araç Hız Ölçüm Sistemi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(1), 101-107.
- Calp, M. H., 2019. İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi. *Politeknik dergisi*, 22(3), 675-686.
- Doğan, T., Sert, E., Taşkın, D., 2013. Araç Destek Sistemleri İçin Kuş Bakışı Görüntü Dönüşümü.
- Doğan, Y., Ataç, M., Özdemir, C., 2014. Izgara Tabanlı Görüntü Dosyalarının Çizilmesi İçin Yeni Bir Yaklaşım.
- Duru, Ö., 2007. Zaman Serileri Analizinde Arıma Modelleri Ve Bir Uygulama. *İstanbul Üniversitesi / Sosyal Bilimler Enstitüsü / Ekonomi Bölümü / Ekonometri Anabilim Dalı / Ekonomi-Maliye Bilim Dalı*
- Erdem, O. A., 2007. Kavşak Trafik Sinyalizasyon Sistemi İçin Bulanık Mantık Tabanlı Gerçek Zamanlı Denetleyici Tasarımı ve Uygulanması. *Engineering Sciences*, 2(4), 241-255.
- Frank, A., Al Aamri, Y. S. K., Zayegh, A. 2019. IoT based smart traffic density control using image processing. In 2019 4th MEC International Conference on Big Data and Smart City (ICBDSC) (pp. 1-4). IEEE.
- Gençosman, B. Ç., 2017. *Journal of Current Researches on Engineering, Science and Technology (JoCREST)*. Science and Technology, 3.
- Güner, E., 2016. Lazer ışını ile işaretlenen hareketli cisimleri hedefe kitlenerek izleyen sistem (Master's thesis, Başkent Üniversitesi Fen Bilimleri Enstitüsü).
- İpek, S. U. C. U., Ataman, E., 2020. Dijital Evrenin Yeni Dünyası Olarak Yapay Zeka Ve Her Filmi Üzerine Bir Çalışma. *Yeni Medya Elektronik Dergisi*, 4(1), 40-52.
- Javaid, S., Sufian, A., Pervaiz, S., Tanveer, M. 2018. Smart traffic management system using Internet of Things. In 2018 20th International Conference on Advanced Communication Technology (ICACT) (pp. 393-398). IEEE.]
- Karaköse, M., Baygın, M., Aydın, İ., Sarımaden, A., Erhan, A., 2016. Endüstriyel Sistemlerde Arkaplan Çıkarımı Tabanlı Hareketli Nesne Tespiti ve Sayılması İçin Yeni Bir Yaklaşım. *Muş Alparslan Üniversitesi Fen Bilimleri Dergisi*, 4(2), 373-381.
- Karasulu, B., 2013. Videolardaki Hareketli Nesnelerin Tespit Ve Takibi İçin Uyarlanabilir Arkaplan Çıkarımı Yaklaşımı Tabanlı Bir Sistem. *Uludağ University Journal of The Faculty of Engineering*, 18(1), 93-110.
- Karhan, M., Oktay, M. O., Karhan, Z., Demir, H., 2011. Morfolojik görüntü işleme yöntemleri ile kayıslarda yaprak delen (çil) hastalığı sonucu oluşan lekelerin tespiti. In 6th International Advanced Technologies Symposium (IATS'11), Elazığ, Türkiye (pp. 172-176).

- Kaya, U., Yılmaz, A., Dikmen, Y., 2019. Sağlık Alanında Kullanılan Derin Öğrenme Yöntemleri. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 792-808.
- Keleş, A., 2018. Derin Öğrenme Ve Sağlık Alanındaki Uygulamaları. *Electronic Turkish Studies*, 13(21).
- Keskin, S., 2018. Yalancı (Pseudo) R-Kare Ölçülerine Genel Bakış, *Sağlık Bilimlerinde Güncel Akademik Çalışmalar*, 11, 3-9.
- Kös, M., 2015. Kentiçi Ulaşım Problemlerine Alternatif Entegre Bisiklet Ulaşımı Planlaması (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Moralı, T., 2011. İMKB 100 endeksinin yapay sinir ağları ve Newton nümerik arama modelleri ile tahmini ve sonuçların karşılaştırılması (Master's thesis).
- Nasip, Ö. F., & Zengin, K., 2018. Deep Learning Based Bacteria Classification. In 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT) (pp. 1-5). IEEE.
- Okumuş, F., Kocamaz, A. F., Özgür, M. E., 2015. Detection and counting of *Oncorhynchus Mykiss* spermatozoa. In 2015 23rd Signal Processing and Communications Applications Conference (SIU) (pp. 1805-1808). IEEE.
- Özcan, M. O., Sert, E., Taşkın, D., & Taşkın, C., 2013. OpenCV ile Stereo Görüntülerden Derinlik Kestirimi. *AkademikBilişim 2013*.
- Öztürk, N. B., 2006. Akıllı trafik sistemleri, Doctoral dissertation, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Şeker, A., Diri, B., Balık, H. H., 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 3(3), 47-64.
- Şimşir, F., Özkaynak, E., Ekmekçi, D., 2013. Kavşaklarda Trafik Sinyalizasyon Sisteminin Modellemesi ve Benzetimi. *Akademik Bilişim*.
- Solak, A. O., 2013. Türkiye'nin toplam petrol talebi ve ulaştırma sektörü petrol talebinin arıma modeli ile tahmin edilmesi. *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences*, 18(3).
- Sönmez, C., 2005. Sinyalize kavşaklarda trafik akımının modellenmesi. Doctoral dissertation, Fen Bilimleri Enstitüsü.
- Takma, Ç., Atıl, H., Aksakal, V., 2012. Çoklu doğrusal regresyon ve yapay sinir ağı modellerinin laktasyon süt verimlerine uyum yeteneklerinin karşılaştırılması. *Kafkas Üniversitesi, Veterinerlik Fakültesi Dergisi*, 18(6), 941-944.
- Tanyıldızı, E., Okur, S., 2016. Retina Görüntülerindeki Kan Damarlarının Belirlenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 28(2).
- Tenekeci, M. E., Gümüşçü, A., Aslan, E., 2014. Görüntüden OpenCV ile Duygu Analizi. *Akademik Bilişim*, 5-7.
- Topaloğlu, M., 2004. Matematiksel morfoloji ile imge bölütleme (Doctoral dissertation, Karadeniz Teknik Üniversitesi/Fen Bilimleri Enstitüsü).
- Toraman, Ç., Koşan, A. M. A., 2020. Yurdal, M. O. Tıp Fakültesi Öğrencilerinin Bilişsel Esneklik Düzeyleri, Öğrenme Yaklaşımları ve Kullandıkları Öğrenme Stratejileri. *Tıp Eğitimi Dünyası*, 19(57), 76-97.
- Tortum, A., Gözcü, O., Çodur, M. Y. 2014. Türkiye'de Hava Ulaşım Talebinin Arıma Modelleri ile Tahmin Edilmesi. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 4(2), 39-54.
- Türkçetin, A. Ö. Ü., Bayrakçı, H. C., Aksoy, B., 2019. Akciğer kanserinin tespit edilmesinde derin öğrenme algoritmalarının kullanılması. *Isparta Uygulamalı Bilimler Üniversitesi / Lisansüstü Eğitim Enstitüsü / Mekatronik Mühendisliği Anabilim Dalı*.
- Ucal, M. Ş., 2006. Ekonometrik Model Seçim Kriterleri Üzerine Kısa Bir İnceleme. *C.Ü. İktisadi ve İdari Bilimler Dergisi*, 7(2), 41-57.
- Utku, S. B., 2008. Sinyalize kavşaklarda yaya hareketliliğinin ve güvenliğinin irdelenmesi (Doctoral dissertation, DEÜ Fen Bilimleri Enstitüsü).
- Vergil, H., Özkan, F., 2007. Döviz Kurları Öngörüsünde Parasal Model ve Arıma Modelleri: Türkiye Örneği.
- Wang, Y.M., Li Y., Zheng, J.B., 2010. "A Camera Calibration Technique Based On OpenCV", *Information Sciences and Interaction Sciences (ICIS)*, 3rd International Conference, China, 403-406
- Yavuz, S., Devci, M., 2012. İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Yiğit, R. N., 2019. Kısa zamanlı trafik tahmini ile devre süresi optimizasyonu ve gecikme analizi. Master's thesis, Pamukkale Üniversitesi Fen Bilimleri Enstitüsü.
- Yıldız, O., 2019. 'Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(4), 2241-2260.