

# Yol Akış Yönünün Tespiti için Bir Konvolüsyonel Sinir Ağı Modeli

## A Convolutional Neural Network Model for Road Flow Direction Detection

Vedat Tümen<sup>1</sup>, Özal Yıldırım<sup>2</sup>, Burhan Ergen<sup>3</sup>

<sup>1</sup>Bilgisayar Teknolojileri Bölümü, Munzur Üniversitesi, Tunceli, Türkiye

<sup>2</sup>Bilgisayar Mühendisliği Bölümü, Munzur Üniversitesi, Tunceli, Türkiye  
{vtumen, oyildirim}@munzur.edu.tr

<sup>3</sup>Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye  
bergen@firat.edu.tr

**Özetçe**—Sürücüsüz araçlar gibi yapay zekanın etkin olarak kullanıldığı kritik alanlarda araçların hareket halinde olduğu yola ait özelliklerin gerçek zamanlı olarak tespit edilmesi önemli bir çalışma alanıdır. Bu makale çalışmasının amacı, hareket halindeki bir aracın yolun akış yönünü tespit etmesini sağlayacak bir derin öğrenme yöntemi sunmaktır. Çalışmada, Yol Akış Yönü (YAY) tespiti için derin öğrenme modellerinden Konvolüsyonel Sinir Ağları (KSA) kullanılmıştır. Akış yönünün tespiti için geliştirilen YAYKSA modeli CMU VASC görüntü veri tabanında bulunan 587 adet gerçek yol resimleri üzerinde uygulanmıştır. Hazırlanan modelin başarımlarını kıyaslamak için aynı veriler üzerinde, yaygın KSA modeli olan Cifar[1] modeli uygulanmıştır. Elde edilen sınıflandırma sonuçlarına göre, tasarlanan YAY-KSA modelinin %80.1 düzeyinde akış yönünü doğru olarak tespit ettiği görülmüştür.

**Anahtar Kelimeler**—Derin öğrenme; görüntü işleme; yol yönü tespiti; yol akışı tespiti; sınıflandırma.

**Abstract**— It is an important work area to determine realtime characteristics of roads where vehicles are in motion in critical areas where artificial intelligence is effectively used, such as driverless vehicles. The purpose of this article work is to present a deeper learning method that will allow a vehicle in motion to detect the direction of flow in the path. Convolutional Neural Networks (KSA) have been used as deep learning models for the determination of the direction of flow (YAY) in the study. The YAY-KSA model developed for flow direction detection is applied on 587 real road images in the CMU VASC image database. To compare the performances of the prepared model, Cifar [1] model which is a common KSA model was applied on the same data. According to the classification results obtained, it was seen that the designed YAY-KSA model correctly determined flow direction at 80.1% level.

**Keywords**— Deep learning; image processing; Road direction detection; road flow detection; classification.

### I. GİRİŞ

Son zamanlarda sürücüsüz araçların geliştirilmesi ve iyileştirilmesi için birçok araştırma yapılmaktadır. Sürücüsüz araçlar özellikle küresel ölçekli büyük firmaların günümüzde ve ilerleyen yıllarda odaklanacağı alanların başında gelebilecek potansiyele sahiptir. Amerika Birleşik Devletleri (ABD)'deki Nevada, Florida, Michigan ve Kaliforniya gibi bazı eyaletler, kamuya açık karayollarına otonom araçların girmesine izin veren yasaları yaptılar. Bu yasalar belli şartlar altında hazırlanan araçlar için dünyada hızla yayılmaktadır. Mevcut otonom otomobil üreticileri Google, Toyota, Nissan, BMW, Tesla gibi üreticiler, sürücüsüz araç üretme teknolojilerini aktif olarak araştırdıklarını görebiliriz [2]. Tesla ve Volvo vb. firmaların ürettiği on binlerce otomobil şu anda tüm dünya da yollarda ve her yıl sayıları hızla artmakla beraber kendilerine yeni görüş ve sürüş teknikleri geliştirmektedir. Buna ek olarak, Tesla ve Delphi ve Google gibi şirketler, ABD yollarında milyonlarca kilometre yolculuk eden tamamen sürücüsüz arabaları test etmektedir [3].

Yol akışının temel sistem gereksinimi, değişen koşullara uyum sağlama yeteneğidir; çünkü aracın çevresi, çevresel koşullara ve aracın bulunduğu yolun türüne bağlı olarak değişebilir [4]. Model tabanlı yol takip sistemlerinin çoğu çok sınırlı alanlarda çalışmaktadır. Yol genişliği ve aydınlatma koşulları gibi çevresel değişkenler değiştiğinde dışsal gürültü varlığında parçalanma eğilimi gösterir [5]. Otonom araçlar için otomatikleştirilmiş bir direksiyon sağlama temel rolü dışında, yol yönü tanımlama algoritmaları, potansiyel olarak tehlikeli durumların, nesnelerin tespiti için etkin bir emniyet sistemi olarak düşünülmektedir [6]. Yol yönü tahmini sürücüsüz araçların yolda daha rahat bir sürüş ve oluşabilecek kazaları önlemek için oldukça yararlı olduğu

düşünülmektedir. Yolun ileri, sol ve sağ şeklinde akışı bulunmaktadır. Sürücüsüz araçların gelişiminde yol yönü tespiti en önemli aşama olarak görülmektedir. Tüm araçların güvenliğini sağlamak için yol yönünün önceden tespit edilmesi gerekmekte ve bu tespiti göre yönlendirme yapılmalıdır.

Günümüzde yapılan çalışmalara bakıldığında genelde asfalt bölünmüş şeritli yolda çalışmaların yapıldığı görülmektedir. Bu şekilde yoldaki şeritler incelenerek kenar çıkarımı yapılarak bölünmüş yolun kenarları ve orta kısmı tespit edilebilir. Fakat günümüzde özellikle gelişmekte olan ülkelerde bulunan kara yollarında bölünmüş yollar azdır ve yollarda boyalı şeritler bulunmamaktadır. Yol akışının tespiti ile ilgili yapılan çalışmalara bakıldığında genellikle yoldaki işaretlerin belirlenerek aracın yönlendirildiği görülmektedir.

## II. İLGİLİ ÇALIŞMALAR

Yol akış yönü ile ilgili birçok çalışma bulunmaktadır. İlk çalışma 1989 yılında yapılmış olan ALVINN (Yapay Sinir Ağı tabanlı bir Otonom Arazi Aracı) [7]. Bu çalışmada, yol izlemesi için tasarlanmış 3 katmanlı bir geri yayımlı yapay sinir ağı modeli kullanılmıştır. ALVINN sisteminde, bir kamera ve bir lazer mesafe bulucusunun elde ettiği görüntüler girdi olarak alınmakta ve çıkış olarak aracın hareket etmesi gereken yön üretilmeye çalışılmaktadır. Sistemin eğitimi, benzetimi yapılmış yol görüntüleri kullanılarak gerçekleştirilmiştir. ALVINN birçok farklı türde yol üzerinde güvenle bir aracı kullanabileceğini kanıtlamıştır. 1999 yılında yapılan çalışmada [5] ise geliştirilmiş Radial Basis Function (RBF) sinir ağı kullanılarak otonom bir aracın yol yönünün görsel olarak tanımlanması yapılmıştır. Doğru yolu bulmak için yapılan bu çalışmada başarımlar yüksek çıkmıştır. 2012 yılında Maria Schmiterlöv yapmış olduğu yüksek lisans çalışmasında [8] yapay yol görüntülerini hazırlamış olduğu bir konvolüsyonel sinir ağı modeli ile birçok kez eğitilmiş ve imgelerin 1/3'ünü doğrulama için kullanmıştır. Yaptığı bu çalışmada birçok yöntem kullanmasına rağmen yüksek oranda bir başarımlar elde edemediği görülmüştür. Benzer şekilde [9]'de yapılan bir çalışmada ise çeşitli sınıflandırıcı algoritmaları ile CMU VASC görüntü veri tabanındaki imgelerin sınıflandırılması gerçekleştirmiştir. Bu amaçla öncelikle görüntülere ait özellikler çeşitli kenar çıkarma ve dönüştürme yöntemleri ile elde edilmiştir. Elde edilen özellik vektörleri üzerinde Concurrent Self-Organizing Maps (CSOM) sınıflandırıcısı kullanılmıştır. Yapılan bu yöntem eğitim verilerini artırarak ve test verilerini azaltarak % 100 başarı elde etmiştir.

Yapılan çalışmaların çoğu genellikle yapay veriler üzerinde gerçekleştirilmiştir. Sadece çalışma [9]'da CMU-VASC veri tabanındaki gerçek görüntüler üzerinde kenar çıkarımı ve bazı dönüşüm yöntemleri uygulandıktan sonra

klasik sinir ağı yöntemleri ile tespit işlemi gerçekleştirilmiştir. Bu makale çalışmasında ise gerçek görüntüler üzerinde bir çalışma gerçekleştirilmiştir. Bunun yanı sıra sık-yapılı öğrenme yöntemlerinin yerine hem özellik çıkarımı hem de sınıflandırma süreçlerini bir arada barındıran bir derin öğrenme yöntemi kullanılmıştır.

## III. DERİN ÖĞRENME

Derin öğrenme, çok katmanlı ileri beslemeli sinir ağlarının eğitime süreçlerinden oluşmaktadır. Derin öğrenme modelleri çok sayıda farklı nitelikte gizli katman ile oluşturulduğundan bu ismi almıştır. Derin öğrenme; görüntü sınıflandırma, imge işleme, video analizi ve sınıflama, ses tanıma ve işleme ve doğal dil öğrenme süreci gibi daha birçok alanda kullanılmaktadır. Derin öğrenme özellikle, büyük miktarlarda, etiketlenmemiş eğitim verilerinden öznelilik çıkarım yöntemleri ile özelliklerin saptamasını yapabilen sistemler oluşturmak için ileri teknoloji, çok seviyeli sinir ağların kullanılması ile oluşmaktadır.

Günümüzde makine öğrenmesinde ve örüntü tanıma alanları gibi yapay zeka alanında popüler bir yöntem haline gelmiştir. Derin öğrenmeye ihtiyaç duymamızın sebeplerinin başında, yapay sinir ağlarının tek başına bazı problemleri çözmede yetersiz kalması veya geç cevap vermesidir. Günümüzde artan teknoloji ile sürekli verilerin büyümesine paralel olarak gelişen teknoloji sayesinde işlemcilerde özellikle grafik tabanlı işlemcilerin gücünün artması ile istenen veriye daha hızlı ulaşma imkânı sağlamıştır. Bu imkanı kullanmak için derin öğrenme yaklaşımları kullanılarak büyük verilerden hızlı ve istenen bilgilere ulaşmamız sağlanmıştır.

Derin öğrenme mimarisi giriş olarak verilen bir sayısal materyalin ilk aşamada; çizgi, kenarlar, renk, doku gibi ana hatlarını analiz eder. Bu işlemde sonra ortaya çıkan sonuçları kombine ederek nesne modellemesi yapar [10]. Derin öğrenmenin en sık kullanılan algoritmaları, Derin Sinir Ağları (DSA), Otomatik Kodlayıcılar (OK) ve Boltzmann Makinelerinin türevleri olan Kısıtlı Boltzmann Makineleridir [11]. Son zamanlarda derin öğrenme alanında özellikle görüntü işlemede görüntüyü bütün olarak işleyen ve verinin özneliliklerinin elde edilmesi ile sınıflara veya özelliklerine ayıran, başarımları yüksek olan konvolüsyon sinir ağları yöntemi kullanılmaktadır.

Bu çalışmada da yol akış yönü tespitinde derin öğrenme yöntemlerinden olan KSA mimarisi kullanılmıştır.

### A. Konvolüsyonel Sinir Ağları

Yann LeCun tarafından 1990 yılında yapılan çalışma ile geliştirilen ve günümüzde artan bir şekilde kullanılan KSA'lar, çok katmanlı sinir ağlarının ileri yayılım algoritmasının özel bir türüdür [12]. KSA, en düşük

sayıda önişlem ile piksel görüntülerin işlenmesi ve doğrudan görsel kalıplar çıkarmak için geliştirilmiştir. Aşırı değişkenliğe sahip desenler ve basit geometrik dönüşümlere karşı oldukça başarılıdırlar. KSA'ların, diğer sınıflandırma algoritmalarından daha iyi bir performans göstermesinin nedenlerinden birisi öznitelik çoğaltma ve özetleme katmanlarına sahip olmasıdır. Bu özellikler yardımıyla mevcut veriyi daha iyi sınıflandırmakta ve tanımaktadır. KSA katmanları gelişmekle birlikte temel olarak dört katmandan oluşmaktadır. Bu katmanlar; konvolüsyon katmanı, aktivasyon katmanı, alt-örnekleme (pooling) katmanı ve tam bağlı katmandır.

Görüntü işleme alanında çalışan kuruluşlar çoğunlukla KSA tabanlı çalışmalar ve türevlerine yoğunlaşmıştır. LeNet [13], AlexNet [14], GoogLeNet [15], VGGNet [16] ve ResNet [17] gibi organizasyonlar KSA tabanlı uygulamalar geliştirerek görüntü işleme, sınıflama alanında büyük başarımlar elde etmektedir. Bu çalışmada incelenen Cifar modeli de AlexNet tarafında geliştirilen KSA tabanlı bir modeldir.

1) Konvolüsyon katmanı: Bu katman temel olarak filtreler ve özellik haritalarından oluşmaktadır. Filtreler, konvolüsyon katmanında bu katmanın nöronlarını temsil eder. Rastgele sayılar üretilerek ağırlıklar oluşturulur. Bu ağırlıklar ile imgenin belirtilen değerleri konvolüsyon işlemine tabi tutularak çıktı değer elde edilir. Bu işlemler, belirli aralıklarla adım adım ilerler ve tüm görüntü taranana kadar devam eder.

2) Alt-örnekleme (Pooling) katmanı: Konvolüsyon katmanı kullandıktan sonra elde edilen özellikler üzerinde farklı işlemler uygulanarak daha derin özelliklerin elde edilmesi istenmektedir [18]. Alt-örnekleme katmanı bu amaçla kullanılan bir katman olmasının yanında, giriş verisini daha düşük boyutlu temsillerine indirmek için kullanılmaktadır. Bunun için çeşitli teknikler kullanılmaktadır. Örneğin maksimum ve ortalama teknikleri yaygın olarak kullanılan alt-örnekleme teknikleridir.

3) Aktivasyon katmanı: Aktivasyon işlemi, bir özellik haritasının her bileşenine uygulanan doğrusal olmayan bir aktivasyon fonksiyonuyla doğrusal bir filtre izlenerek elde edilir. KSA modellerinde kullanılan en yaygın yöntem sifra eşikleme olarak bilinen ReLU dur. Bu yöntem, sigmoid ve tanjant fonksiyonu ile karşılaştırıldığında daha hızlı sonuç üretmektedir. Bu durum özellikle işlem kapasitesi bakımından kısıtlı olan bilgisayarlar için belirgin bir hız artışına olanak sağlamaktadır [15]. ReLU yönteminin yanı sıra birçok aktivasyon fonksiyonu bulunmaktadır. Bunlardan başlıcaları;

- Maksimum ve ortalama aktivasyon fonksiyonları;  

$$f(x) = \max(0; x)$$

$$f(x) = \text{avg}(0; x)$$
(1)

- Sigmoid aktivasyon fonksiyonu;

$$f(x) = (1 + e^{-x})^{-1} \quad (2)$$


- Hiperbolik tanjant aktivasyon fonksiyonu;

$$f(x) = \tanh(x) \quad (3)$$

4) Softmax sınıflandırıcı: Çok sınıflı verilerin sınıflandırılması için kullanılan başarılı bir sınıflandırma yöntemidir. Özellikle yüksek sayıda sınıf verileri için kullanılır. Normal bir sınıflandırıcıda sınıf sayısı oldukça düşük olmasına karşın Softmax,  $y(i) \in \{1, \dots, K\}$  kadar sınıf üzerinde sınıflandırma işlemi yapabilmektedir.

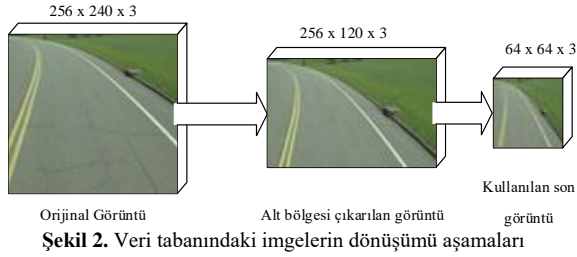
#### IV. ÖNERİLEN YAY-KSA MODELİ

Sürücüsüz araçların bir yolda ilerlerken yönünün belirlenmesi sağlıklı bir sürüş için oldukça önemlidir. Sürüşün başarılı bir şekilde devam etmesi için aracın sürekli anlık olarak ve önceden belirlenen doğrultuda ilerlemesi kumanda edilmelidir. Araçlarda bir erken uyarı sistemi geliştirerek bu tür araçların yönlendirilmesi başarılı bir şekilde yapılır. Şeritle ayrılmış çizgili yollarda kullanılan araçlar için geliştirilmiş sistemler asfaltın doğal renginden farklı olan belirgin şerit rengini temel alarak aracın yönünü belirlenmektedir. Fakat bazı yollarda belirgin şerit çizgileri bulunmamakta ya da görünür olmamaktadır. Bazı durumlarda ise yolun tek şeritli olması veya yol işaretlerinin olmaması durumunda tespitin zor olmasıdır. Bu çalışmamızda CMU-VASC veri tabanında bulunan 587 adet rastgele seçilmiş içerisinden kara yolu bulunan ve sayı olarak farklı olan 3 tip yol imgesi kullanılmıştır. Bu tipler yön olarak; ileri devam eden yol, sola dönen yol ve sağa dönen yol şeklinde ifade edilebilir. Bu tiplere ait çeşitli görüntüler Şekil 1'de verilmiştir.



Şekil 1. Veri tabanından örnek imgeler

Veri tabanındaki imgelerin boyutu genişlik ve yükseklik farklı olduklarında işlenmek için tümü aynı boyut olarak ölçeklendirilmesi gerekmektedir. Ölçeklendirme öncesinde imgelerin alt kısmında kalan yarısı kesme işlemine tabi tutularak atılmıştır. Üst kısmı yeniden boyutlandırılarak Şekil 2’de görüldüğü gibi 64x64x3 boyutlarında sınıflanacak imgeler elde edilmiştir.



Şekil 2. Veri tabanındaki imgelerin dönüşümü aşamaları

587 adet RGB kanallı imgenin Tablo I’de görüldüğü gibi 325 tanesi ileri devam eden yol, 149 tanesi sola dönen yol ve 113 tanesi de sağa dönen yol olduğu tespit edilmiştir.

Yol Tipi	İmge Sayısı	Veri tabanındaki oranı
İleri devam eden yol	325	0.5537
Sola devam eden yol	149	0.2538
Sağa devam eden yol	113	0.1925
<b>Toplam</b>	<b>587</b>	<b>1</b>

Tablo I. Veri tabanındaki imgelerin türe göre dağılımları

CMU-VASC veri tabanında kullandığımız imgeleri incelediğimizde, farklı zaman aralıklarında ve farklı yol tiplerinde görüntüleme işlemlerinin yapıldığı tespit edilmiştir. Bu imgelerin hepsi belirlenen veri tabanından rastgele seçilmiştir.

Bu çalışma için geliştirilen YAY-KSA modeli Tablo II’de görüldüğü gibi 5 konvolüsyon 3 pooling ve 5 aktivasyon (ReLU) ve softmax katmanı ile birlikte toplamda 14 katmandan meydana gelmektedir.


Katman	Katman Adı	Kernel Boyutu	Katman Tipi	[Pad, Stride]
1	Convolution	12x12@32	-	[2, 3]
2	Pooling	5x5	Max	[01, 3]
3	Activation	-	ReLU	
4	Convolution	3x3@32	-	[2, 1]
5	Activation	-	ReLU	
6	Pooling	3x3	Max	[01, 2]
7	Convolution	5x5@32	-	[2, 1]
8	Activation	-	ReLU	
9	Pooling	3x3	Max	[01, 2]
10	Activation	-	ReLU	
11	Convolution	2x2@64	-	[0, 1]
12	Activation	-	ReLU	
13	Convolution	1x1@64	-	[0, 1]
14	Fully Connect		SoftMax	

Tablo II. Hazırlanan modelin parametreleri

Tablo II’de YAY-KSA modeli ve parametreleri detaylı bir şekilde verilmiştir. Tablo II’yi incelediğimizde ilk katman 12x12 boyutunda konvolüsyon katmanı olup 32 bit derinlikte veriler konvüle edilerek işlenmekte ve 3 stride ile tüm imge dolaşmaktadır. 2. katman olan pooling ile bir önceki katmandan elde edilen değerlerin yine stride ölçüsü ile dolaşarak maksimum olanı alınır. 3. Katmanda ise aktivasyon katmanı bulunmaktadır. Bu katmanda ise bir önceki katmandan elde edilen sonuçları ReLU aktivasyon fonksiyonu geçirilerek hesaplanır. Bu işlemler Tablo II’de belirtilen katmanlar ve özellikleri çerçevesinde softmax katmanına ulaşınca kadar her imge için devam eder.

#### A. Deneyisel Sonuçlar

Veri tabanında bulunan 587 adet RGB kanallı imgeler gerekli ön işlem aşamalarından geçirildikten sonra hazırlanan YAY-KSA modeline verilmiştir. Yapılan çalışma sonunda Şekil 3’deki gibi bir sınıflandırma başarımları gözlemlenmiştir. Şekil 3’ü incelediğimizde 170. Epoch’ta eğitim sıfıra inmekte ve eğitim aşaması tamamlanmış olmaktadır. Doğrulama için 170. Epoch’taki başarımları 80,1% olduğu görülmektedir.




Şekil 3. YAY-KSA modelinin görüntüler üzerinde eğitim ve doğrulama sonuçları

Yapılan bu çalışmanın literatür taramasında tespit edilen benzer çalışmalardaki başarımlarına bakıldığında, ön işleme tabi tutulmadan ve özellik çıkarımı yapılmadan test işleminde oldukça yüksek bir başarımlar elde edildiği tespit edilmiştir. Tablo III’te yapılan çalışmaların başarımlarının karşılaştırması görülmektedir.

Çalışma Adı	İmge Sayısı	Başarımlar Oranı(%)	İmge Türü
[2]	1200	90	Yapay
[3]	15087	74,016	Yapay
[4]	70	100	Doğal
Cifar[1]	587	70	Doğal
<b>Önerilen YAY-KSA Modeli</b>	<b>587</b>	<b>80,1</b>	<b>Doğal</b>

Tablo III. Bazı çalışmaların başarı oranlarının karşılaştırılması

Tablo III'te yapılan çalışmaların başarımları incelendiğinde yapay veri ve gerçek veri olarak farklı veri tipleri olduğu görülmektedir. Gerçek veriler üzerinde yapılan [4] çalışması eşit olarak dağılmış ve aynı tür ve zamanda çekilmiş 70 imge üzerinde çalışma yapıldığı ve eğitim verisi yüksek tutularak 100% başarı elde edildiği görülmüştür. [3] çalışmasında birçok farklı data set kullanmıştır. Kendi geliştirmiş olduğu sistemden elde ettiği yapay verileri bir KSA yöntemine göre sınıflandırmış ve başarımları en yüksek 74,016% olarak tespit etmiştir. [2] çalışması ise yapay sinir ağı yöntemi kendi elde ettiği yapay görüntü verileri ile araç navigasyon sistemi test edilmiştir ve bunu başarımları da 90% olarak ölçülmüştür. Yapılan çalışmalar genelde yapay parkurda çekilen anlık görüntüler üzerinde olmuştur, buna rağmen çok yüksek bir başarımları elde edilmemiştir. [4] çalışmasında ise özel olarak seçilen sadece 70 adet resim üzerinde çalışma yapılmıştır ve bu imgeler birçok önışlemeden geçirildiğinde dolayı sınıflandırıldığında başarımları oranı yüksek çıkmıştır. Bizim önerdiğimiz sistemde geliştirilen modele ve Cifar[1] modeline veriler sunularak başarımları test edilmiştir. 587 adet imgenin hiçbirisi özel olarak seçilmemiş ve bir önışlemeden geçirilmemiştir. Geliştirmiş olduğumuz model ile Cifar[1] modelinin 200 epoch'a kadarki sonuçları Şekil 4 te görüldüğü gibidir.



Şekil 4. Modellerin sonuçları (a) YAY-KSA modeli, b) Cifar modeli)

Şekil 4 (a) incelendiğinde modelimizin 170. Epoch'ta eğitim basamağının sifıra ulaştığı ve başarımları oranının da 80.1% olduğu görülmektedir. 170. Epoch'ta Şekil 4(b) Cifar modeli ise eğitim basamağı sifıra ulaşmamıştır ve eğitim basamağı tamamlanmadığından doğrulama oranı yaklaşık %70 civarında olmuştur. Bu sonuç önerdiğimiz modelin, Cifar modeline göre başarımlarının oldukça iyi olduğunu göstermiştir.

## V.SONUÇ

Bu çalışmada yol akış yönü tespiti için YAY-KSA isimli bir derin öğrenme modeli geliştirilmiştir. Geliştirilen modelin yol akış yönünü iyi bir şekilde tespit edebildiği görülmüştür. Ayrıca önerilen YAY-KSA modeli ile KSA alanında oldukça popüler olan Cifar modeli kıyaslandığında aynı veriler üzerinde YAY-KSA modelinin oldukça avantaj sağladığı görülmüştür. Elde edilen sonuçlar ışığında, YAY-KSA modelinin yeterli derecede eğitim ve parametre düzenlemesinden sonra otonom sistemler için elde edilen anlık görüntülerin hızlı ve gerçek zamanlı işlenerek erken uyarı sistemlerinin geliştirilmesine temel oluşturabileceği söylenebilir. Bu model ile araç hareket halinde iken yapılan görüntü işleme ile araç için yolun akış yönü rahatlıkla tespit edilebilir. Önerilen model, görüntüleri önışlemeden geçirmeden doğrudan işlemesi hem zaman hemde maliyet açısından incelenen diğer modellerden daha iyi olduğu tespit edilmiştir. Gelecek dönemde modelin biraz daha geliştirilerek başarımlarının artırılması hedeflenmektedir.

## KAYNAKÇA

- [1] A. Krizhevsky, Hinton, "Convolutional Deep Belief Networks On Cifar-10." Unpublished Manuscript, 40, 2010.
- [2] R. Dale, A. Stedmon. "To Delegate or not to Delegate: A Review of Control Frameworks for Autonomous Cars." Applied ergonomics 53 383-388. 2016.
- [3] B. Brown, "The Social Life of Autonomous Cars." Computer 50.2: 92-96. 2017.
- [4] N. Victor, C. Tudoran. "Road Following for Autonomous Vehicle Navigation Using a Concurrent Neural Classifier." Automation Congress, WAC 2008. World. IEEE, 2008.
- [5] N. Victor, M. Valcu, B. Sabac. "A Neural Approach for Detection of Road Direction in Autonomous Navigation." Computational Intelligence p: 324-333, 1999.
- [6] U. Ozguner, C. Stiller, K. Redmill. "Systems for Safety and Autonomous Behavior in Cars: The DARPA Grand Challenge Experience." Proceedings of the IEEE p: 397-412. 2007
- [7] A. Pomerleau Dean, "Alvin: An Autonomous Land Vehicle in a Neural Network.", Advances in Neural Information Processing Systems. p. 305-313, 1989.
- [8] M. Schmiterlöv, "Autonomous path following using convolutional networks.", Master Tez, The Institute of Technology, Linköping University 2012.
- [9] Victor-Emil Neagoe, Cristian-Tudor Tudoran. "A Neural Machine Vision Model for Road Detection in Autonomous Navigation." University Politehnica of Bucharest Scientific Bulletin, Series C: Electrical Engineering 73.2, 167-178, 2011
- [10] V. Tümen, B. Ergen, "İçerik Tabanlı Görüntü Erişiminde Derin Öğrenme Yöntemlerinin Kullanımı.", International Artificial Intelligence and Data Processing Symposium'16, 2016.
- [11] Ian J. Goodfellow, D. Erhan, P. Luc Carrier, A. Courville, M. Mirza, Ben Hamner, W. Cukierski, Y. Tang, D. Thaler, D. Hyun Lee. "Challenges in representation learning: A report on three machine learning contests." Neural Networks, 64:117-124, 2014.

- [12] J. Gehring, Y. Miao, F. Metze, "Extracting Deep Bottleneck Features Using Stacked Auto-Encoders", Acoustics, Speech and Signal Processing (ICASSP), 2013 IEEE International Conference on May 2013.
- [13] Y. LeCun, "LeNet-5, convolutional neural networks," 2013
- [14] A. Krizhevsky, I. Sutskever, E. Geoffrey Hinton, "Imagenet Classification With Deep Convolutional Neural Networks", Advances in Neural Information Processing Systems, pp. 1097-1105, 2012.
- [15] S. Christian, "Going Deeper With Convolutions." Proceedings Of The IEEE Conference on Computer Vision and Pattern Recognition, P. 1-9, 2015.
- [16] İnternet Erişimi: [http://www.robots.ox.ac.uk/~vgg/research/very\\_deep/](http://www.robots.ox.ac.uk/~vgg/research/very_deep/)
- [17] He, Kaiming, "Deep Residual Learning for Image Recognition." Proceedings of the IEEE conference on computer vision and pattern recognition., p. 770-778, 2016.
- [18] İnternet Erişimi: <http://ufldl.stanford.edu/tutorial/supervised/Pooling/>