



DERİN ÖĞRENME TABANLI VE PID KONTROL TABANLI SÜRÜCÜSÜZ ARAÇ SİSTEMLERİ

Koray AKI¹, Ahmet Emir DİRİK¹

¹ Bursa Uludağ Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü 16059, Nilüfer, Bursa, Türkiye

Anahtar Kelimeler

*derin öğrenme,
sürücüsüz araç,
PID,
evrimsel sinir ağları,
CNN*

Öz

İnsan müdahalesi olmadan kendi kendine hareket edebilen araçlar sürücüsüz araç olarak adlandırılmaktadır. Sürücüsüz araçlar son yirmi yılda; askeri, lojistik ve endüstriyel üretimdeki potansiyel uygulamaları ile hem akademiden, hem de endüstriden büyük ilgi görmeye başlamıştır. Sürücüsüz araçların kullanılması günümüz trafiğinin çevresel etkilerini azaltmak ve trafik kazalarını önlemek gibi birçok konuda toplumsal fayda sağlamaktadır. Sürücüsüz araçlarda navigasyon için GPS, çarpışmaları önlemek için sensör ve nesnelere tespit etmek için kamera gibi çeşitli teknolojiler kullanılmaktadır. Bu teknolojilerin hepsi ya da birkaçı kullanılarak Derin Öğrenme tabanlı ve PID kontrol ile otonom sürüş yapılabilmektedir. Bu çalışmada Derin Öğrenme Tabanlı model eğitimi ve otonom sürüş testleri sürüş simülöründe gerçekleştirilmiştir. Sürüş simülöründen aracın direksiyon açısı, hız bilgisi ve ön camına monte edilen üç kameradan (sağ, sol ve orta) görüntü bilgisi alınmıştır. Aracın otonom hareketi Derin Öğrenme tabanlı model eğitimi gerçekleştirilerek ve PID kontrol ile sağlanmıştır. Bu çalışmada Derin Öğrenme ile eğitilen modelin sürüş performansı ile PID kontrol ile gerçekleştirilen sürüş performansı sürüş simülöründe bir tam turda karşılaştırılmıştır. Aracın sürüş parkurundaki bir tam turda gerçek zamanlı olarak özerk hareketi kaydedilmiş ve başarımlar değerlendirilmiştir. Sürüş simülöründe gerçekleştirilen testler sonucunda PID kontrol tabanlı sürüşte de başarılı sonuçlar elde edilmiş olmasına rağmen, Derin Öğrenme tabanlı modelin performansının daha iyi olduğu belirlenmiştir.

DEEP LEARNING BASED AND PID CONTROL BASED AUTONOMOUS VEHICLE SYSTEMS

Keywords

*deep learning,
autonomous vehicle,
PID,
convolution neural networks,
CNN.*

Abstract

Vehicles that can move on their own without human intervention are called autonomous vehicles. Over the last two decades, autonomous vehicles have been receiving considerable interest from both academia and industry, with potential applications in military, logistics and industrial production. The development of autonomous vehicles provides social benefits in many aspects, such as reducing the number of deaths and reducing the environmental impact of today's traffic. Autonomous vehicles use various technologies such as GPS for navigation, sensors to avoid collisions, and cameras for object detection. Autonomous driving can be performed with Deep Learning and PID control. In this study, Deep Learning Based model training and autonomous driving tests were carried out in the driving simulator. Steering angle, speed information from the driving simulator and image information from three cameras (right, left and middle) mounted on the windshield were obtained. Autonomous movement of the vehicle was provided by performing Deep Learning based model training and PID control. In this study, the driving performance of the model trained with Deep Learning and the driving performance performed by PID control were compared in one full tour in the driving simulator. Autonomous movement of the vehicle was recorded in real time during one full lap on the driving track and performance evaluation was carried out. As a result of the tests carried out in the driving simulator, although successful results were obtained in PID control-based driving, it was determined that the performance of the Deep Learning based model was better.

Alıntı / Cite

Aki, K., Dirik, A. E., (2020). Derin Öğrenme Tabanlı ve PID Kontrol Tabanlı Sürücüsüz Araç Sistemleri, Mühendislik Bilimleri ve Tasarım Dergisi, 8(5), 306-316.

Yazar Kimliği / Author ID (ORCID Number)

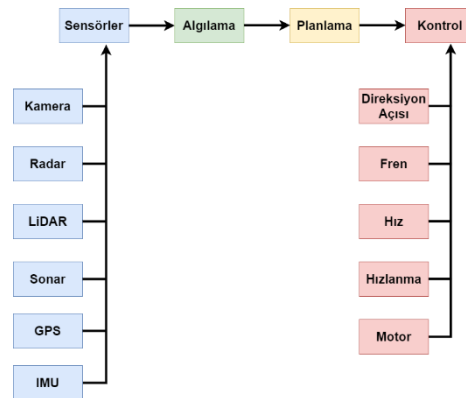
Aki, K., 0000-0002-3661-3058
Dirik, A. E., 0000-0002-9174-0367

Makale Süreci / Article Process

Başvuru Tarihi / Submission Date	26.11.2020
Revizyon Tarihi / Revision Date	27.12.2020
Kabul Tarihi / Accepted Date	28.12.2020
Yayın Tarihi / Published Date	29.12.2020

1. Giriş (Introduction)

Ülkemizde ve dünya genelinde her geçen gün araç kullanımı artmaktadır. Bugün hemen hemen her evde en az bir araç vardır. Bununla birlikte, otomobillerin yaygın kullanımı, trafik kazalarına, hava kirliliğine ve trafik sıkışıklığı gibi hayatımızı olumsuz etkileyecek durumlara yol açmaktadır. Sürücüsüz araçlar bu sorunları azaltma ve yüksek maliyetli harcamalardan tasarruf etmeyi sağlayabilmektedir. Sürücüsüz araçlar genel olarak sensörler, algılama, planlama ve kontrol olmak üzere dört modüle ayrılabilir. Şekil 1'de sürücüsüz araçlara ait sistem diyagramı gösterilmektedir. Sürücüsüz araçların kararlarını almak için kullandığı bilgiler; kamera, radar ve LiDAR gibi sensörlerden oluşur. Bu tip sensörler genellikle büyük miktarlarda veri üretir. Sensörlerden gelen bilgiler, algılama modülüne gelir. Algılama modülü sensör verilerini anlamlı bilgilerle birleştirir. Planlama modülü, algılama modülü çıktısını, davranış planlama ve hem kısa, hem de uzun menzilli yol planlaması için kullanır. Kontrol modülü, aracın planlama modülü tarafından üretilen verilerle yolu takip etmesini sağlar ve araca kontrol komutları gönderir.



Şekil 1. Sürücüsüz Araç Alt Sistemleri (Autonomous Vehicle Subsystems)

Derin Öğrenme (Deep Learning, DL), girdi olarak yüksek boyutlu verileri, Sinir Ağı (Neural Network, NN) olarak adlandırılan çok katmanlı bir mimari kullanan fonksiyon belirleyiciden geçirip, yüksek boyutlu verilerden ilgili özellikleri çıkarabilir. İnsanların gerçekleştirdikleri görevleri makinelerin taklit edebilmesi Yapay Zeka (Artificial Intelligence, YZ) ile sağlanmıştır. Sürücüsüz araçların geliştirilmesinde YZ teknolojilerine ihtiyaç duyulmaktadır (Chollet, 2018). Sürücüsüz araçların otonom hareketleri için direksiyon açılarının belirlenmesi ve otonom sürüş sırasında aracın hızının ayarlanması gibi karar verme veya bu değerlerin tahmin edilmesi süreci makine öğrenmesi ile gerçekleşmektedir. Bu tür çözülmesi zor ve karmaşık problemler DL yöntemleri kullanılarak çözülmektedir.

Sürücüsüz araçlarda PID kontrol önemli bir görev üstlenmektedir. Oransal kontrolde, gelen konum bilgisine göre çizginin yolun sağına kaydığı oranda sol motorun devir sayısı artacak, sağ motorun da devir sayısı azalarak çizgi istikametinde ilerlemesi sağlanacaktır. Araç virajlı yollara girdiğinde, yolum eğimi artacaktır ve türev kontrol aracın salınım oranlarını ayarlayacaktır. Viraj boyunca eğimin değişmediği durumlarda araç hızı sabit kalarak, aracın virajda salınım ve savrulma gibi olumsuz durumlarını türev kontrolü ortadan kaldırmaktadır. Sürücüsüz araç, gelen konum bilgisi ile orantılı olarak hareket ederken, integral kontrolü ile şeridin dışına her çıktığında daha hızlı bir şekilde orta noktaya ulaşmasını sağlayacaktır. İntegral kontrol değeri düzgün bir şekilde ayarlanmadığı takdirde salınım gerçekleşecektir.

Çalışmanın ikinci bölümünde sürücüsüz araç teknolojileriyle ilgili kaynak araştırması yapılmıştır. Üçüncü bölümünde ilgili çalışmada kullanılan materyal ve yöntemler yer almaktadır. Çalışmanın dördüncü bölümünde deneysel sonuçlara yer verilmiştir. Beşinci bölümde ise sonuç ve tartışma yer almıştır ve ilgili çalışmada kullanılan yöntemler karşılaştırılmıştır.

2. Kaynak Araştırması (Literature Survey)

Sürücüsüz araçların tasarımı ve geliştirilmesinde LiDAR ve kamera kullanımı ile ilgili teknolojik sorunlar vardır. Sürücüsüz araçlarda radar ve sensör özellikleri etkisiz hale getirildiğinde kar, sis ve yağmurda ne yapılacağı belirlenmesi gerekmektedir. Otonom sürüş sırasında yol kenarlarında gerçekleşen değişimlerde aracın nasıl yönlendirileceğinin bilmesi gerekmektedir. Sürücüsüz araçlarda bu sorunların üstesinden nasıl gelineceği araştırma konusudur.

Otonom araçların geliştirilmesine yönelik ilk başarılı girişim 1950'lerde başladı. İlk tamamen otonom araçlar 1984'te (Wallace vd., 1985; Kanade vd., 1986) ve 1987 yılında (Dickmanns ve Zapp, 1987) geliştirildi. DARPA (Defense Advanced Research Projects Agency's) yarışmasında, 2004 ve 2005 yıllarında Grand Challenge etkinlikleri sırasında otonom araçlar alanında önemli atılımlar yapıldı (Montemerlo vd., 2006; Thrun vd., 2006). DARPA'nın yarışmasından sonra otonom araç testleri hız kazanmıştır. Dikkat çeken örnekler arasında 2009'dan 2013 yılına kadar gerçekleşen otonom araç yarışmaları (Xin vd., 2014), 2010'da Hyundai tarafından düzenlenen otonom araç yarışması (Cerri vd., 2011), 2010'da VisLab kıtalararası otonom araç yarışması (Broggi vd., 2012), 2013'te kamuya açık alanlarda otonom araç testleri (Broggi vd., 2015) verilebilir. Bertha Benz'in otomotiv tarihindeki ilk kara yolculuğunu tamamlamasından 125 yıl sonra, aynı rota tamamen otonom olarak tamamlanmıştır (Ziegler vd., 2014). Waymo, 2009 yılında Google ile sürücüsüz araç projesi başlattı. Tesla, Tesla otopilotlarının ilk versiyonunu 2014 yılında Model S olarak piyasaya sürdü. Otomotiv sektöründe faaliyet gösteren diğer şirketlerden daha genç olsa da, Tesla bugün sürücüsüz araç pazarına liderlik ediyor. Bu günlerde caddelerde test edilen otonom araçlar olsa da, halen bazı zorluklarla karşılaşmaktadır. Bojarski vd. (2016) aracın önüne yerleştirilen tek bir kameradan alınan görüntüler ile CNN'i eğitmişlerdir. Elde edilen eğitim verileriyle sistem, şerit çizgileri olan veya olmayan yollarda ve otoyollarda trafikte sürüş yapmayı öğrenmiştir. Bojarski vd. (2017) yoldan elde edilen görüntüler ile direksiyon açılarını tahmin eden PilotNet adında sinir ağı tabanlı bir sistem geliştirmişlerdir. Cho vd. (2016) gerçek dünyada sürücüsüz araçların yollarından geçen yayaları ve araçları tespit edebilmeleri için kamera, radar ve LiDAR'ı birlikte kullanmışlardır. Ravankar vd. (2018) otonom robot ve araçların virajları daha yumuşak bir şekilde dönmeleri ve bu alanda yaşanan zorluklar üzerine bir inceleme gerçekleştirmişlerdir.

Sürücüsüz aracın yolda hareketi sırasında şerit takibi önemli bir konudur. Otonom sürüş sırasında aracın şeridin ortasında kalmasını sağlayacak kontrol sistemleri de araştırma konusu olmuştur. Araştırmacılar "Kamera kullanarak otoyol şeridinin ortasında sürücüsüz bir aracı tutmak için bir kontrol sistemi nasıl tasarlanabilir?" sorusuna cevap aramaktadırlar. Kontrol sistemleri; ısıtma sistemlerini düzenlemek, robotları dengelemek, barajlardaki su seviyelerini dengelemek gibi çeşitli sistemler için kullanılır (Yang vd., 2008; Khare vd., 2010; Omijeh vd., 2015; Velazquez vd., 2016; Zimit vd., 2018; Copot vd., 2019; Zhou vd., 2019). PID kontrolörler, istenen değeri hesaplamak için, mevcut ölçülen değer ile istenen değer arasındaki hataya bağlı olarak ağırlıklı oransal (Proportional, P), integral (Integral, I) ve türev (Derivative, D) bileşenlerinin bir kombinasyonunu kullanan dijital kontrol sistemleridir. Sürücüsüz araçlarda hız kontrolü, acil frenleme gibi kritik zaman kontrol sistemlerini kontrol etmek ve şerit takibi için PID kontrolörü kullanılabilir. Zhou vd. (2012) uyarlanabilir PID tabanlı kontrol sisteminde testlerini gerçekleştirecekleri 1.6 Tiggo3 SUV araca, iki tane 4 çekirdekli bilgisayar ve bir sensör seti yerleştirmişlerdir. Jigang vd. (2017) motor hız kontrolü için bulanık PID kontrol geliştirmişlerdir. Chandni vd. (2017) direksiyon açısı, fren ve aracın hızını ayarlamak için PID denetleyici geliştirmişlerdir. Geliştirilen mimari yol takibi, algılama ve kontrol modülü olmak üzere üç başlığa ayrılmıştır. Direksiyon kontrolü hem açık döngü kontrol modunda, hem de kapalı döngü PID kontrol modunda gerçekleştirilmiştir. Tekerlek kodlayıcısından gelen geri bildirim ile kapalı döngü yöntemi, merkez şeridinin sorunsuz izlenmesini sağlamıştır. Lie vd. (2014) araçlarda güvenliği arttırmak için PID kontrol tabanlı araç çarpışma önleme sistemi geliştirmişlerdir. Jiao vd. (2008), direksiyon açısını kontrol etmek için Geliştirilmiş Parçacık Sürü Optimizasyon Algoritması (Improved Particle Swarm Optimization Algorithm, IPSO) temelli kendinden uyarlamalı bir PID kontrol sistemi geliştirmişlerdir. Gerçekleştirilen kontrol sistemi, geleneksel PID kontrol yöntemine kıyasla, daha az salınım gerçekleştirmiştir. Sürücüsüz araçlar, trafik koşulları değişse bile araçları şeritte tutarak istenilen hedefe seyahat etmek üzere tasarlanmıştır. Surendharan ve Jennifer Ranjani (2016) sürücüsüz araçların ulaştırma sistemlerine entegrasyonu için bir yaklaşım geliştirmişlerdir. Geliştirdikleri yöntemde, sürücüsüz araçlar üç alt sistemden oluşmaktadır. Ortamı ve mesafe ölçümlerini algılamak için bir kamera ve ultrasonik sensör, yoldaki nesnelere ayırt etmek için duyuşal verileri analiz etme yeteneğine sahip sistem ve bilgiyi yorumlayan ve aracı istenilen yolda tutmak için uygun kararı veren bir PID kontrol ünitesi kullanılmıştır. PID kontrol cihazına dayalı sürücüsüz aracın performansı analiz edilmiştir. Gerçek mesafe ve ölçülen mesafe arasındaki fark ölçülerek, sistemin %90 başarı oranının olduğu belirtilmiştir. Nie vd. (2018), çalışmalarında sürücüsüz aracın hızı ve direksiyon açısını kontrol eden PID kontrol için radyal temelli sinir ağı geliştirmişlerdir. Geliştirilen PID kontrolünün performansı geleneksel yöntemlerden daha iyi performans göstermiştir. Emirler vd. (2014) çalışmalarında, sürücüsüz araçlarda direksiyon kontrolü için PID denetimini simülasyon ortamında gerçekleştirmişlerdir. Aracın 15 m/s hızında istenen yörüngeyi başarıyla takip ettiği belirtilmiştir. Han vd. (2017)

çalışmalarında, şerit kontrolü için direksiyon açısını belirleyen sinir ağı tabanlı PID kontrolü kullanmışlardır. Deneysel simülasyon sonuçlarında, önerilen model ve algoritmanın, şerit takibi kontrolünde gerçek zamanlı olarak ve değişen ortamlarda doğru sonuç verdiği belirtilmiştir.

3. Materyal ve Yöntem (Material and Method)


3.1. Derin Öğrenme (Deep Learning)

Makine Öğrenmesinin bir alt dalı ve verilerden öğrenebilen yeni bir yaklaşım olan Derin Öğrenme, çok katmanlı veri temsillerini öğrenmesi üzerine odaklanmıştır. Derin öğrenmenin derinliği, yaklaşımın başardığı hiçbir derinlemesine anlayışa referans olmak yerine ardışık temsil katmanları fikrini ifade eder. Modelin derinliği, veri modelindeki katman sayısı olarak adlandırılır. DL eğitim ile öğrenebilen onlarca, hatta yüzlerce ardışık katmanı içerir. DL'de her ardışık katman, giriş verisi olarak kendinden önceki katmandaki çıktıyı alır. Bu arada, makine öğrenmesine yönelik diğer yaklaşımlar, bir veya iki katmandan oluşan veri temsillerini öğrenir. Geleneksel ML algoritmalarında belirlenen özelliklerin eğitim aşaması gerçekleşmeden önce, bir insan tarafından hesaplanması gerekir. Hesaplanan bu özelliklere göre öğrenme işlemi gerçekleştirilir. Geleneksel ML algoritmaları insan bağımlı özellikler ile çalışabilirken, DL insan bağımsız özellikler ile çalışmaktadır. DL algoritmaları verinin ayırt edici özelliklerini kendi kendine öğrenmektedir. DL algoritmalarının bu yeteneği, algoritmanın başarısı açısından çok önemli etkidir. DL karmaşık veri temsillerini öğrenmek için matematiksel bir çerçevedir (Chollet, 2018).

1950'li yıllarda başlayan Yapay Sinir Ağı (YSA) çalışmaları internetin gelişimiyle ve artan veriyle birlikte sistemlerin öğrenme, karar verme, akıl yürütme gibi işlevlerin gerçekleştirilmesi için yetersiz kalmış ve beraberinde farklı bakış açıları getirmiştir. LeCun vd. (1998) tarafından çevrimiçi el yazısı tanıma için LeNet mimarisi ile Evrimsel Sinir Ağı (Convolutional Neural Network, CNN) kullanmışlardır. Geri yayılım (back propagation) algoritması ile eğitilmiş çok katmanlı sinir ağlarının, başarılı bir gradyan tabanlı öğrenme tekniği olduğu belirtilmiştir. Hinton ve Salakhutdinov (2006), çok katmanlı bir sinir ağını eğiterek düşük boyutlu kodlara dönüştürülebilir olduğunu belirtmişlerdir. Bu çalışmadan sonra DL popülerleşmiştir. 2000'li yılların başında popüler olmaya başlayan YSA, bilgisayar işlemcilerinden, daha fazla işlem gücü gerektiren yapılar için grafik işlemcilerin de kullanılmasıyla birlikte sığ alanlardan derin ağ yapılarına geçiş yapmıştır. Bu yaklaşımla birlikte görüntü işleme uygulamalarından, doğal dil işleme uygulamalarına ve medikal uygulamalar gibi karmaşık problemlerin çözülmesi için farklı alanlarda kullanılmaya başlanmıştır. Örnek bir matematiksel model ile formül gösterimi verilmiştir. Formüller ortalı olarak hizalanmalıdır. Formüllerin yerleştirilmesinde sorun yaşandığı takdirde çerçeve kalınlığı belli olmayan bir tablo içerisine yerleştirme yapılabilir.

3.2. PID Kontrol (PID Control)

PID, Oransal (Proportional), İntegral (Integral), Türev (Derivative) için kullanılan bir kısaltmadır. Bu terimler hataya uygulanan üç temel matematiksel fonksiyonu açıklamaktadır. PID kontrolörün ana görevi hatayı en aza indirmektir. PID, bir girdiyi alır, amaçlanan davranış sapmasını hesaplar ve amaçlanan davranış sapmasının minimum ve daha yüksek doğruluk elde etmek için çıkışı ayarlar. Sürücüsüz araç yoldaki şeritleri takip ederken çizgiyi tam olarak yakalayabilir.



Şekil 2. PID Kontrolör Yapısı (PID Controller)

PID kontrolü kullanıldığında, araç yolun tam orta noktasından ilerlerken istikrarlı bir şekilde ve ivedilikle yolun orta noktasına kendisini sabitleyebilmesi gerekmektedir. Sürücüsüz araç yolda hareket halindeyken kontrolünü kaybetmemesi ve yolda çeşitli ışık seviyelerine sahip ortamlardan geçerken, bunlardan etkilenmemesi gerekmektedir. Bu gibi problemlerin üstesinden gelmek için PID kontrolü kullanmak gerekmektedir. Şekil 2'de hedef konum $r(t)$ ile gösterilmiş, ölçülen konum ise $y(t)$ ile gösterilmiştir. Zamana bağlı değişim oranı $r(t)$ ile $y(t)$ 'nin farkı alınarak hesaplanır. Sisteme kullanıcı tarafından oluşturulan hata değeri eklenir. Her bir kontrolör için hata (error) değeri ile değişim oranı çarpılır.


$$u(t) = K_p e(t) + K_i \int_0^t e(t') dt' + K_d \frac{de(t)}{dt} \quad (1)$$

Her bir kontrolörden çıkan sonuç toplanarak kontrolör çıkışı hesaplanır. Denklem 1’de PID kontrolörün çıkış değerinin hesaplanması gösterilmiştir. Burada $e(t)$ zamana bağlı hata değerini, K_P oransal kontrolörün hata değerini, K_D türev kontrolörün hata değerini K_I integral kontrolörün hata değerini göstermektedir.

3.3. Önerilen Yöntem (Proposed Method)

Sürücüsüz araçların yolda hareket ederken direksiyon açılarının belirlenmesi için simülasyon ortamında gerçekleştirilen DL tabanlı ve PID kontrolü olan yöntemler kullanılabilir. Sürücüsüz araçların hareketi sırasında bazı sorunlarla karşılaşmaktadır. Yoldaki şerit çizgilerini tam olarak yakalayamayabilir ya da şerit olmayan yollarda nasıl davranacağına karar vermeyebilir. Sürücüsüz aracın hızı arttığında kontrolünü kaybedebilir ya da farklı yol koşullarında çevresel faktörlerden (farklı ışık seviyeleri, kar yağmur vb. ortamlar) etkilenebilmektedir. Belirtilen sorunları çözmek çok karmaşık görünse de, belirtilen problemlerin çözümü için DL tabanlı sistemler ve PID kontrolü sistemler kullanılmaktadır. Fiziksel hasarı önlemek için sürücüsüz araçlar ilk önce simülasyon ortamında eğitilmekte ve test edilmektedir.


Son yıllarda sürücüsüz araçların geliştirilmesine yönelik yarış muazzam bir şekilde hızlanmıştır. Pek çok bileşen sürücüsüz bir araç oluşturur ve en önemlilerinden bazıları ona güç veren sensörler ve DL yazılımıdır. Bu çalışmada, direksiyon açısını tahmin etmek ve sürücüsüz aracın simülasyon ortamında kendi kendine hareket etmesi DL modeli oluşturularak ve PID kontrol ile sağlanmıştır. PID kontrol hem aracın hızını kontrol etmek hem de şerit üzerinde otonom bir şekilde hareket etmesi için kullanılmıştır. DL ile oluşturulan modelde Tensorflow tabanlı Keras kütüphanesi kullanılmıştır. Oluşturulan modele kameralardan elde edilen görüntüler verilerle aracın direksiyon açısı tahmin edilmiştir. Şekil 3’de kameradan gelen görüntülerin sinir ağına eğitiminin şeması gösterilmiştir.



Şekil 3. Derin Öğrenme Eğitim Modeli (Deep Learning Training Model)

CNN modelinde elu aktivasyon fonksiyonu kullanılmıştır. Giriş görüntüleri üzerinde ilk önce normalize işlemleri uygulanmıştır ve sonra normalize görüntüler CNN’ye giriş olarak verilmiştir. CNN’in ilk evrişim katmanında 5×5 ’lik 24 tane filtre bulunmaktadır. Evrişim katmanında görüntülerin farklı özellikleri çıkartılmıştır. Oluşturulan CNN modeli mimarisinde beş tane evrişim katmanı ile bir tane düzeltme katmanı ve dört tane de tam bağlı katman bulunmaktadır. İkinci erişim katmanında 5×5 boyutunda 36 tane filtre, üçüncü evrişim katmanında 5×5 boyutunda 48 tane filtre, dördüncü evrişim katmanında 3×3 boyutunda 64 tane filtre ve en son evrişim katmanında 3×3 boyutunda 64 tane filtre kullanılmıştır. Evrişim katmanlarından sonra aşırı uyumu engellemek için 0,5 seyreltme uygulanmış ve sonrasında matris düzeltme katmanında tek boyutlu bir vektöre dönüştürülmüştür. Düzeltme katmandaki tüm düğümlerin tek bir çıktıyla birleştirildiği, direksiyon açısı değerlerini öngören, bütün bağlantılı katman uygulanmıştır. Düzeltme katmanından sonra 0,5 seyreltme uygulanarak bütün bağlı katmanlar kullanılmıştır. DL modelinin eğitimi için kullanılacak verilerin toplanması işleminde elde edilen veriler, kamera görüntüleri ve her karedeki direksiyon açısı değerleridir. Görüntüler özellik seti ve direksiyon açıları etiket seti olarak kullanılmış ve sadelik nedeniyle aracın hızı PID kontrolör kullanılarak sabitlenmiştir. Bu yaklaşım kullanılarak toplanan veriler, daha fazla insan etkileşimi olmadan, yalnızca girdi verilerine dayanarak sürüş yapmayı öğrenecek sinir ağını eğitmek için kullanılmıştır. Eğitim verileri toplandıktan sonra, otonom sürüş için sinir ağı, direksiyon açısını tahmin etmek için bu veri seti üzerinde eğitilmiştir. Son olarak, eğitilmiş model, aynı simülasyon ortamında gerçek zamanlı bir özerk sürüş olan çıkarım için kullanılmıştır. Sürücüsüz aracın insan etkileşimi olmadan, kendi kendine hareketi sırasındaki başarı ölçütü, sürüş simülasyonunda her zaman yolda kalması ve yolun ortasından hareket etmesi olarak değerlendirilmiştir.

Sürücüsüz araç hareket halindeyken aracın üç kamerasından toplanan görüntüler rastgele kaydırılır ve döndürülür ve ardından sinir ağı beslenir. Bu girdilere dayanarak, sinir ağı tek bir değer, direksiyon açısını üretir. Temel olarak, giriş görüntülerine dayanarak, sinir ağı aracın hangi açıdan yönlendirilmesi gerektiğine karar verir. Bu çıktı değeri, sinir ağının kararındaki hatayı hesaplamak için insan sürüşünden toplanan direksiyon verileriyle karşılaştırılır. Model, bu hatayı azaltmak için ağırlıkları geriye yayılım algoritmasını kullanarak günceller. Eğitim sisteminin bir blok şeması Şekil 4’de gösterilmektedir.




Şekil 4. Sürücüsüz Araç için CNN Eğitimi (CNN Training for Autonomous Vehicle)

Bu çalışmada farklı model ve farklı veri kümeleri kullanılarak DL tabanlı sürücüsüz araç eğitimi gerçekleştirilmiştir. Modelin eğitimi, Intel(R) Core(TM) i7 2600@3.40 GHz işlemci, 16 GB ram ve NVIDIA GeForce GTX 1080 grafik kartı olan bilgisayarda gerçekleştirilmiştir. CNN modelinde *elu* aktivasyon fonksiyonu kullanılmıştır. Giriş görüntüleri üzerinde ilk önce normalize işlemleri uygulanmıştır ve sonra normalize görüntüler CNN'e giriş olarak verilmiştir. CNN'in ilk evrişim katmanında 5×5 'lik 24 tane filtre bulunmaktadır. Evrişim katmanında görüntülerin farklı özellikleri çıkartılmıştır. Oluşturulan CNN modeli mimarisinde beş tane evrişim katmanı ile bir tane düzeltme katmanı ve dört tane de tam bağlı katman bulunmaktadır. İkinci erişim katmanında 5×5 boyutunda 36 tane filtre, üçüncü evrişim katmanında 5×5 boyutunda 48 tane filtre, dördüncü evrişim katmanında 3×3 boyutunda 64 tane filtre ve en son evrişim katmanında 3×3 boyutunda 64 tane filtre kullanılmıştır. Evrişim katmanlarından sonra aşırı uyumu engellemek için 0,5 seyreltme uygulanmış ve sonrasında matris düzeltme katmanında tek boyutlu bir vektöre dönüştürülmüştür. Düzeltme katmandaki tüm düğümlerin tek bir çıktıyla birleştirildiği, direksiyon açısı değerlerini öngören, bütün bağlantılı katman uygulanmıştır. Düzeltme katmanından sonra 0,5 seyreltme uygulanarak bütün bağlı katmanlar kullanılmıştır. Tablo 1'de CNN katman modelleri ve kullanılan parametreler gösterilmiştir. Sürücüsüz aracın yolun orta kısmında kalması ve yol şeridinin kenarlarına değmeden veya yol şeridinin dışına çıkmadan yumuşak sol ve sağ dönüşler yapması için PID kontrolör kullanılmıştır.

Tablo 1. CNN Katman Modelleri ve Parametreler (CNN Layer Models and Parameters)

KATMAN	ÇIKIŞ MODELİ	PARAMETRE
Evrişim 1	$31 \times 98 \times 24$	1824
Evrişim 2	$14 \times 47 \times 36$	21.636
Evrişim 3	$5 \times 22 \times 48$	43.248
Evrişim 4	$3 \times 20 \times 64$	27.712
Evrişim 5	$1 \times 18 \times 64$	36.928
Seyreltme 1	$1 \times 18 \times 64$	0
Düzeltilme	1 152	0
Bütün Bağlı 1	100	115.300
Seyreltme 2	100	0
Bütün Bağlı 2	50	5.050
Seyreltme 3	50	0
Bütün Bağlı 3	10	0
Seyreltme 4	10	0
Bütün Bağlı 4	1	11

Sürüş simülöründe gerçekleştirilen otonom sürüş sırasında, aracın yanal konumu ile şeridin merkezi arasındaki çapraz yol hatası (Cross Track Error, CTE) ölçmüştür. PID kontrolün amacı sistemdeki toplam hatanın en aza indirilmesi veya sistemdeki toplam kazancın maksimize edilmesidir. Simülörde, CTE değeri simülör tarafından gönderilen veri mesajından okunur ve PID kontrol hata değerlerini günceller ve toplam hataya dayanarak direksiyon açısını tahmin eder. Şekil 5'de PID kontrol işlem akışı verilmiştir. P veya "orantılı" bileşen, sürücüsüz araç davranışı üzerinde doğrudan gözlemlenebilir etkiye sahiptir. Sürücüsüz aracın, şerit merkezinden uzaklığı ile orantılı bir şekilde yönlendirmesini sağlar. Eğer araç çok fazla sağa doğru giderse, hafifçe sola, tam tersi durumda da aracı hafifçe sağa doğru yönlendirir. Oransal kontrol tek başına kullanıldığında sürekli bir salınım gerçekleşir.



Şekil 5. PID Sistem Mimarisi (PID System Architecture)

Oransal kontrol, hedef değere ulaşmada yardımcı olur, ancak hedef değer etrafındaki hata salınımı (küçük de olsa) hedef değere ulaşmak için azaltılmalıdır. İntegral kontrolün devreye girdiği yer burasıdır. İntegral kontrolü, zaman içindeki hataların toplamıdır. Böylece hata küçük olduğunda, integral bileşen hedef değere nispeten kısa bir sürede ulaşmaya yardımcı olur çünkü integral zamanın değişim hızının üstündedir. PI kontrol ile bir değişkenin kontrol edilmesi sağlanabilir, ancak hatayı tahmin etmek ve bunu geribildirim sistemine dahil etmek sabit bir denetleyiciye sahip olmanın çok önemli bileşenidir. Türev kontrolü tam da bunu yapar, önceki hatayı temel alarak gelecekteki hatayı hesaplar ve sisteme dahil eder. Denetleyicinin çıktısında salınım olasılığı varsa, türev kontrolü salınım kontrolüne yardımcı olacaktır. Bütün kontrolörler birlikte kullanıldığında zamana bağlı hata oranı düşecektir ve salınım azalacaktır. PID, direksiyon açısını hesapladıktan sonra, bir gaz değeri elde edilir ve simülatöre geri gönderilir. Yeni bir mesaj alındığında, güncelleme ve tahmin işlemini tekrar başlatmak için yeni CTE değeri kullanılır. Salınımları gidermek için PID parametrelerinin çok hassas bir şekilde ayarlanması gerekmektedir. Bu çalışmada PID parametreleri manuel olarak ayarlanmıştır. PID değerleri farklı koşullara göre değişebilmektedir, bu yüzden sürücüsüz aracı dengede tutacak değerlerin seçilmesi önemlidir. Parametre değerlerinden herhangi birinin hatalı olması durumunda, daha fazla salınım ve sürüş pistindeki yoldan sapmalar görülmektedir. PID kontrolü istenen konumda ilerlerken bazen araç salınımlar gerçekleştirilmektedir. Sürücüsüz araç istenen değere (yolun ortasına) ulaşmak istemektedir.

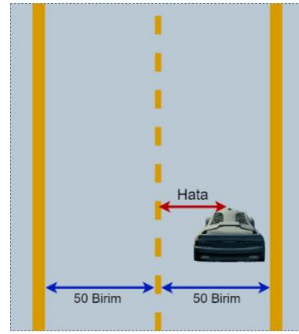
4. Deneysel Sonuçlar (Experimental Results)

Sürüş simülatöründe oluşturulan DL tabanlı modellerin ve PID tabanlı modelin, sürüş pistindeki şeritlerin tam ortasından ilerlemesi istenmektedir. Araç sürüş pistinde otonom olarak ilerlerken şeritlerin merkezinden sapmalar yaşanmaktadır. Otonom sürüşün test edilebilmesi için araç sürüş pistinde ilerlerken, aracın şeritlerin orta noktasından sol ve sağ şeride olan mesafesinin ölçülmesi gerekmektedir. Aracın her şeritten ne kadar uzakta olduğunu hesaplamanın birkaç yolu vardır. Simülatör ortamında araca yerleştirilen kameralardan yararlanıp ya da sürüş kaydı yapıp görüntü işleme yöntemleri kullanılabilir. Görüntü işleme yöntemleriyle sürüş pistindeki şeritler bulunup işaretlenebilir ya da şeritleri bulmak için derin öğrenme yöntemleri de kullanılabilir. DL yöntemleri kullanılacaksa, LiDAR gibi diğer sensörlerden gelen konumları kullanabilir ve sinir ağı sensörlerden gelen bilgiler kullanılarak eğitilebilir (Gurghian vd., 2016).




Şekil 6. Sürücüsüz Araç Pisti (Autonomous Vehicle Track)

Bu çalışmada otonom sürüş sırasında, aracın hareketi kayıt altına alınmıştır. Bu video kaydı performans değerlendirilmesinde kullanılmıştır. Sürücüsüz araç test edilirken, sürüş pistindeki bir tam turdaki performansı değerlendirilmiştir. Sürücüsüz aracın hızı 10 mph olarak belirlenmiş ve aracın şeridin orta noktasından ne kadar sapma yaptığı ölçülmüştür. Sürüş pistindeki iki şeridin arasında kalan mesafe Şekil 6'da gösterildiği gibi 100 birim olarak değerlendirilmiştir. Hata değeri ölçülürken şeritlerin tam ortası 0 olarak kabul edilmiştir. Şekil 7'de kesikli çizgilerle gösterilen çizgi aracın sürekli hareket etmesi istenen konumdur. İstenen notadan sola doğru sapmalar 0 ile -50 arasında ve sağa doğru sapmalar ise 0 ile 50 arasında değerlendirilmiştir. DL tabanlı sürüş testlerinde modeller, Adam en iyileme yöntemi kullanılarak eğitilmiştir ve öğrenme oranı 0,001 olarak ayarlanmıştır. CNN modelleri farklı yığın değerleriyle eğitildiğinde örnek sayısının az olmasından kaynaklı başarımlar arasında büyük farklar oluşmuştur.



Şekil 7. Sürücüsüz Aracın Orta Çizgiden Sapması (Deviation of the Autonomous Vehicle from the Middle Line)

En başarılı sonuçlarda yığın değeri 100 olarak ayarlanmıştır. DL tabanlı yöntemlerin performans değerlendirmesinin objektif olarak bir yapılması için tüm yöntemler birbirleriyle karşılaştırılmıştır. Başarılı otonom sürüşün testleri, sürüş simülatoründeki pistte gerçekleştirilmiştir. Özerk sürüş modu sırasında, araca monte edilmiş merkezi kameradan gelen sinyal sürekli olarak alınmış ve eğitilen modele girildi olarak gönderilmiştir. Model kendisine gelen sinyallere karşılık direksiyon açısı tahmin etmiş ve aracın yörüngede kalmasını sağlamıştır. 81 adımda eğitimini tamamlayan DL tabanlı modelin sürüş pistinde bir tam turu kayıt altına alınmıştır (Aki, 2019a). Sürücüsüz araç yol boyunca yörünge merkezinde kalmayı başarmıştır. Eğitim sürüşü sırasında toplanan verilerden kaynaklı bazen yörünge merkezinden sapmalar gerçekleşmiştir.



Şekil 8. Yörünge Merkezinden Sapma - DL (Deviation from Orbit Center - DL)


Kaydedilen görüntüye ait yörüngeden sapma grafiği Şekil 8’de verilmiştir. İki şerit arasında kalan nokta yörünge merkezi olarak kabul edilmiştir. Sürücüsüz araç otonom sürüş sırasında, yörünge merkezinden sola ve sağa doğru sapmalar gerçekleştirmiştir. Sağa ve sola doğru yörüngeden sapma değerleri normalize edilmiş ve sola sapma negatif (-), sağa sapma pozitif (+) olarak gösterilmiştir.

Tablo 2. PID Kazanç Değerleri

SİMGE	KAZANÇ DEĞERİ
K_P	0,75
K_I	0,0001
K_D	1

PID kontrol testleri de aynı sürüş simülatoründe gerçekleştirilmiştir. Sürüş pistinde aracın bir tam turda performans değerlendirilmesi yapılmıştır. Otomobilin nasıl tepki vereceğini ve farklı parametre değerlerinin sürüş performansını nasıl etkilediği görmek için PID parametreleri empirik olarak Tablo 2’de gösterildiği gibi ayarlanmıştır.

Aracın bir tam turu kayıt altına alınmıştır (Aki, 2019b). Araç hareket halindeyken kaydedilen videodaki görüntülerden, yoldaki şeritler tespit edilmiştir. İki şeridin tam ortası yörünge merkezi olarak kabul edilmiştir. Sürücüsüz aracın yoldaki konumu tespit edildikten sonra, her görüntü karesinde sürücüsüz aracın merkeze olan uzaklığı ölçülmüştür. Bu ölçüm hata olarak kabul edilmiştir. Sürücüsüz aracın bir tam turdaki salınımı grafiksel olarak Şekil 9’da gösterilmiştir. Sürücüsüz aracın yörünge merkezinden sola doğru sapması negatif olarak ve sağa sapması pozitif olarak değerlendirilmektedir.



Şekil 9. Yörünge Merkezinden Sapma – PID (Deviation from Orbit Center - PID)

5. Sonuç ve Tartışma (Result and Discussion)

Sürüş simülatörü kullanılarak sürücüsüz araç testleri yapılırken, orta kamera görüntüleri kullanılmaktadır. Orta kameradan alınan görüntülerle aracın direksiyon açısı kontrol edilmeye çalışılmaktadır. DL tabanlı ve PID tabanlı sürücüsüz aracın otonom sürüşü için, bir tam turda yörünge merkezinden sapma değerlerinin hesaplanması yapılmıştır. PID tabanlı sürücüsüz aracın virajlarda çok fazla salınım yaptığı gözlenmiştir. Özellikle de köprüden sonraki keskin virajda çok fazla salınım gerçekleştirmiştir. Bazı virajlarda sürücüsüz aracı yörünge merkezinde tutmak için küçük salınımlar gerçekleştirmiştir. PID tabanlı sürücüsüz araç, yörünge merkezinde kalabilmek için çok fazla salınım gerçekleştirdiğinden gerçek hayat için uygun olmadığı görülmüştür. DL tabanlı sürücüsüz araç daha stabil bir sürüş sergilemiştir. DL modeli yolun farklı desen ve farklı parlaklık değerlerini öğrenmiştir. Köprüden sonraki ilk keskin dönüşte sol şeride doğru bir sapma gerçekleştirmesine rağmen, sonrasında yörünge merkezinde gitmeyi başarmıştır. Burada belirtilen keskin viraj hariç yolun geri kalan kısmında DL tabanlı sürücüsüz araç daha iyi performans göstermiştir. PID tabanlı sürücüsüz araç performansı ile DL tabanlı sürücüsüz araç performansı Tablo 3’de karşılaştırılmıştır.

Tablo 3. Performans Değerlerinin Karşılaştırılması (Comparison of Performance Values)

MODEL	ORTALAMA MUTLAK HATA (%)	STANDART SAPMA	ORTALAMA
DL Tabanlı Sürüş	9,191	11,285	6,25e-14
PID Tabanlı Sürüş	9,520	12,217	3,09e-14

Sürüş pistindeki bir tam turda yörünge merkezinden sapma değerleri ölçüldükten sonra, anlaşılabilirliği artırmak için normalizasyon uygulanmıştır. Normalizasyon uygulandıktan sonra DL tabanlı sürücüsüz aracın ortalama mutlak hata değeri 9,191 ve PID tabanlı sürücüsüz aracın ortalama mutlak hata değeri 9,52 olarak ölçülmüştür. DL tabanlı sürücüsüz aracın sürüş pistinde bir tam turda standart sapması 11,285 olarak ölçülürken, PID tabanlı sürücüsüz aracın standart sapma değeri 12,217 olarak ölçülmüştür. DL Tabanlı sistemin şerit çizgilerini takip etmedeki ortalama performansı 6,25e-14 olarak ölçülmüş ve PID Tabanlı sistemin performansı da 3,09e-14 olarak ölçülmüştür. Her iki sistemde saniyedeki görüntü karesi sayısı 30fps olarak ölçülmüştür. Genel olarak performans değerleri karşılaştırıldığında DL tabanlı sistemin daha başarılı sonuçlar sergilediği görülmüştür.

DL tabanlı farklı model kullanılarak eğitim gerçekleştirilmiş ve başarılı sonuç üreten modellerin sürüş simülatöründe gerçek zamanlı otonom olarak testleri gerçekleştirilmiştir. Aynı zamanda PID kontrol parametreleri de düzgün bir şekilde ayarlanarak sürücüsüz aracın sürüş pistinde otonom hareketi sağlanmıştır. Testler sonunda PID kontrol ile de başarılı sonuçlar elde edilse de, en başarılı test sonucu DL tabanlı model ile gerçekleşmiştir. PID kontrol ile otonom sürüş sırasında bazen salınımlar gerçekleşmiştir. DL tabanlı sistemde fazla salınım gerçekleşmemiştir.

Bu çalışmada aşağıdaki gibi bazı sonuçlar elde edilmiştir.

- Sürücüsüz aracın eğitim sürüşü sırasında, farklı yol koşulları ve farklı hava şartlarında veri toplanması eğitimin başarısını yüksek tutacaktır.
- Yolun eğimi tek bir yöne doğru olduğunda model o yönde öğrenme gerçekleştireceği için, elde edilen verilerde belli bir eşik değerine göre kırpmaya gerçekleştirilmiştir. Bu tarz problemlerle karşılaşmamak için eğitim sürüşünün gerçekleştirileceği yolun eğiminin dengeli olması gerekmektedir.
- Eğitim verileri toplandıktan sonra eğitim için gerekli olmayan görsellerin kırpmaya yöntemiyle

temizlenmesi modelin başarısını artıracaktır.

- Modele verilecek girişlerin her biri için aynı değer aralığına sahip olması için toplanan verilerde normalizasyon yapılmalıdır. Normalizasyon işlemi eksik öğrenme ve aşırı öğrenmeyi engelleyecektir.
- Modelin önyargısı ve aşırı öğrenmeyi engellemek için seyreltme işlemi kullanılmalıdır.
- Evrişim katmanları özellik çıkarımlarından sorumlu olduğundan daha fazla evrişim katmanı kullanılabilir.

Bu çalışma Doç Dr. Ahmet Emir DİRİK danışmanlığında, Koray AKİ tarafından hazırlanan “Derin Öğrenme Tabanlı Sürücüsüz Araç Sistemleri” başlıklı tezden alınmıştır.

Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

Kaynaklar (References)

- Aki., K. 2019a. Sürüş Simülöründe Derin Öğrenme Tabanlı Sürücüsüz Araç Testi <https://www.youtube.com/watch?v=01kLVx6xMQQ>-(Erişim tarihi: 07.02.2020).
- Aki., K. 2019b. Sürüş Simülöründe PID Tabanlı Sürücüsüz Araç Testi, <https://www.youtube.com/watch?v=QtRFsFQRv3g>-(Erişim tarihi: 01.02.2020).
- Anonim, 2019. PID Kontrol, https://en.wikipedia.org/wiki/PID_controller-(Erişim tarihi: 01.02.2020).
- Bojarski, M., Del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., Jackel, L., Monfort, M., Muller, U., Zhang, J. 2016. End to End Learning for Self-Driving Cars. <https://arxiv.org/pdf/1604.07316.pdf>-(Erişim tarihi: 06.02.2020).
- Bojarski, M., Yeres, P., Choromanska, A., Choromanski, K., Firner, B., Jackel, L., Muller, U. 2017. Explaining How a Deep Neural Network Trained with End-to-End Learning Steers a Car. <https://arxiv.org/pdf/1704.07911.pdf>-(Erişim tarihi: 06.02.2020).
- Broggi, A., Cerri, P., Felisa, M., Laghi, M. C., Mazzei, L., Porta, P. P. 2012. The Vislab Intercontinental Autonomous Challenge: An Extensive Test for a Platoon of Intelligent Vehicles. *International Journal of Vehicle Autonomous System*, 10: 147-164.
- Brooggi, A., Cerri, P., Debattisti, S., Laghi, M. C., Medici, P., Molinari, D., Panciroli, M., Prioletti, A. 2015. Proud-Public Road Urban Driverless-Car Test. *Intelligent Transportation Systems*, 16(6): 3508-3519.
- Cerri, P., Soprani, G., Zani, P., Choi, J., Lee, J., Kim, D., Yi, K., Broggi, A. 2011. Computer Vision at the Hyundai Autonomous Challenge. *International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 5-7 Oct. 2011, Washington, DC, USA.
- Chandni, C.K., Sajith Variyar, V.V., Guruvayurappan, K. 2017. Vision Based Closed Loop PID Controller Design and Implementation for Autonomous Car. *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. 13-16 September 2017, Udupi, India.
- Cho, H., Seo, Y., Vijaya Kumar, B.V.K., Rajkumar, R.R. 2014. A Multi-Sensor Fusion System for Moving Object Detection and Tracking in Urban Driving Environments. *Proceedings of the 2014 IEEE International Conference on Robotics and Automation (ICRA)*, 31 May–7 June 2014, Hong Kong, China.
- Chollet, F. 2018. *Deep Learning with Python*, Ed: Arritola, T., Gaines, J., Taylor, T., NY, USA, pp: 4-23.
- Chowdhary, P., Gupta, V., Gupta, D., Jadhav, A., Mishra, V. 2018. Design of Two Wheel Self Balancing Robot Using PID Controller. *International Journal of Engineering Research & Technology*, 5(1): 1-3
- Copot, D., Ghita, M., Ionescu, C. M. 2019. Simple Alternatives to PID-Type Control for Processes with Variable Time-Delay. *Processes*, 7(3): 1-16.
- Dickmanns, E.D., Zapp, A. 1987. Autonomous High Speed Road Vehicle Guidance by Computer Vision. *IFAC Proceedings Volumes*, 20(5): 221-226.
- Emirler, M. T., Uygan, İ. M. C., Güvenç, B. A., Güvenç, L. 2014. Robust PID Steering Control in Parameter Space for Highly Automated Driving. *International Journal of Vehicular Technology*, 2014(3): 1-8.
- Gurghian, A., Koduri, T., Bailur, S. V., Carey, K. J., Murali, V. N. 2016. DeepLanes: End-To-End Lane Position Estimation Using Deep Neural Networks. *2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 26 June-1 July 2016, Las Vegas, NV, USA.
- Han, G., Fu, W., Wang, W., Wu, Z. 2017. The Lateral Tracking Control for the Intelligent Vehicle Based on Adaptive PID Neural Network. *Journal of Sensors*, 17(6): 1244.
- Hinton, G. E., Salakhutdinov, R. R., 2006. Reducing the Dimensionality of Data with Neural Networks, *Computer Science. New Life for Neural Networks*, 313: 504-507.
- Jigang, H., Jie, W., Hui, F. 2017. An Anti-Windup Self-Tuning Fuzzy PID Controller for Speed Control of Brushless DC Motor. *Journal for Control, Measurement, Electronics, Computing and Communications*, 58(3): 321-335.
- Jiao, J., Chen, W. W., Shao-Wen, L.L., Wang, J. X. 2008. Self-adaptive PID Control for Intelligent Vehicle Steering System Based on IPSO. *Journal of Anhui University*, 29:1325-1327.
- Kanade, T., Thorpe, C., Whittaker, W. 1986. Autonomous land vehicle project at CMU. *Proceedings of the 1986 ACM Fourteenth Annual Conference on Computer Science*; 4-6 February 1986, OH, USA.
- Khare, Y. B., Yaduvir, S. 2010. PID Control of Heat Exchanger System. *International Journal of Computer Applications*, 8(6): 22-27.
- Lie, G., Zejian, R., Pingshu, Ge., Jing, C. 2014. Advanced Emergency Braking Controller Design for Pedestrian Protection Oriented Automotive Collision Avoidance System. *The Scientific World Journal*, 2014: 1-11.
- Montemerlo, M., Thrun, S., Dahlkamp, H., Stavens, D., Strohband, S. 2006. Winning the DARPA Grand Challenge with an AI Robot. *Proceedings of the 21st National Conference on Artificial Intelligence*, 16-20 July 2006, MA, USA.

- Nie, L., Guan, J., Lu, C., Zheng, H., Yin, Z. 2018. Longitudinal Speed Control of Autonomous Vehicle Based on a Self-Adaptive PID of Radial Basis Function Neural Network. *IET Intelligent Transport Systems*, 12(6): 485-494.
- Omijeh, B. O., Ehikhamenle, M., Promise, E. 2015. Simulated Design of Water Level Control System. *Computer Engineering and Intelligent Systems*. 6(1): 30-40.
- Ravankar, A., Ravankar, A.A., Kobayashi, Y., Hoshino, Y., Peng, C.-C. Path Smoothing Techniques in Robot Navigation: State-of-the-Art, Current and Future Challenges. *Journal of Sensors*, 18(9): 3170.
- Surendharan, S., Jennifer Ranjani, J. 2016. Environment Conscious Automated Vehicle Navigation System using PID Controller. *Indian Journal of Science and Technology*, 9(48): 1-5.
- Thrun, S., Montemerlo, M., Dahlkamp, H., Stavens, D., Aron, A., Diebel, J., Fong, P., Gale, J., Halpenny, M., Hoffmann, G. 2006. Stanley: The Robot That Won the DARPA Grand Challenge. *Journal of Field Robot*, 23(9): 661-692.
- Velazquez, M., Cruz, D., Garcia, S. 2016. Velocity and Motion Control of a Self-Balancing Vehicle Based on a Cascade Control Strategy. *International Journal of Advanced Robotic Systems*, 13(3): 1-11.
- Wallace, R., Stentz, A., Thorpe, C., Moravec, H., Whittaker, W., Kanade, T. 1985. First results in robot road-following, *Proceedings of the 9th International Joint Conference on Artificial Intelligence*, 18-23 August 1985, CA, USA.
- Xin, J., Wang, C., Zhang, Z., Zheng, N. 2014. China Future Challenge: Beyond the Intelligent Vehicle, *IEEE Intelligent Transportation Systems*. 16(2): 8-10.
- Yang, Q., Li, G., Kang, X. 2008. Application of Fuzzy PID Control in The Heating System. 2008 Chinese Control and Decision Conference, 2-4 July 2008, Yantai, Shandong, China.
- Zhao, P., Chen, Y., Song, Y., Tao, X., Xu, T., Mei, T. 2012. Design of a Control System for an Autonomous Vehicle Based on Adaptive-PID. *International Journal of Advanced Robotic Systems*, 9(44): 1-11.
- Zhou, X., Gao, H., Jia, Y., Li, L., Zhao, L., Yu R. 2019. Parameter Optimization on FNN/PID Compound Controller for a Three-Axis Inertially Stabilized Platform for Aerial Remote Sensing Applications. *Journal of Sensors*, 2019(2):1-15.
- Ziegler, J. ve ark. 2014. Making Bertha Drive an Autonomous Journey on a Historic Route. *Intelligent Transportation Systems Magazine*, 6(2): 8-20.
- Zimit, A. Y., Yap, H. J., Hamza, M. F. Siradjuddin, I. 2018. Modelling and Experimental Analysis Two-Wheeled Self Balance Robot Using PID Controller. *International Conference on Computational Science and Its Applications*, 2-5 July 2018, Melbourne, VIC, Australia.