



YATAY KURPLARDA TAŞIT STABİLİTESİNİN MAKİNE ÖĞRENMESİ İLE MODELENMESİ

*Bülent YILDIRIM¹ 

¹Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, Isparta

(Geliş/Received: 21.05.2024, Kabul/Accepted: 25.06.2024, Yayınlanma/Published: 26.06.2024)

ÖZ

Yol ekseninin doğrultusunu değiştirmek için kullanılan yatay kurplar, taşıtların ani hız ve yön değiştirmeleri gereken taşıt stabilitesi ve trafik güvenliği bakımından oldukça önemli yol kesimleridir. Bu nedenle, kurba giren araçların devrilme ve savrulma hızlarının doğru tespit edilmesi taşıt stabilitesi açısından oldukça kritiktir. Bu parametreler, taşıtın mevcut yol koşulları için güvenli olarak kurplarda hangi hızla dönebileceğini ve ne kadar enine eğimli yüzeylerde dengede kalabileceğini belirler. Bu çalışmada, deversiz yatay kurplarda farklı tür ve özelliklere sahip olan taşıtların devrilme ve savrulma hızlarını belirlemede makine öğrenmesi yöntemleri kullanılmıştır. Çalışma kapsamında, farklı araç tipleri, yol koşulları ve kurp özelliklerine göre çeşitli senaryolar içeren bir veri seti oluşturulmuştur. Bu veri seti, farklı araçların farklı koşullarda nasıl davrandığını anlamak için çeşitli senaryoları içermektedir. Bu veri seti makine öğrenmesi algoritmaları kullanılarak modellenmiş ve farklı senaryolar için geliştirilen modeller ile taşıt stabilitesi tahminleri yapılmıştır. Veri setine uygulanan makine öğrenmesi modellerinden Polinom Regresyon modeli diğer modellere göre daha iyi sonuçlar vermiştir. Bu çalışma ile makine öğrenmesi modellerinin yatay kurplardaki taşıt stabilitesini değerlendirmek için kullanılabileceği gösterilmiştir. Bu yöntem, daha güvenli bir sürüş sunmak için otonom ve sürücü destekli sistemlerde de kullanılabilir. Otonom araçlar için bu tür bir modelleme, araçların çevresel koşullara daha hızlı ve hassas bir şekilde tepki vermesine olanak tanırken, daha güvenli ve verimli bir sürüş deneyimi sunabilir. Sonuç olarak, bu çalışmada makine öğrenmesi teknikleriyle yatay kurplardaki taşıt stabilitesinin hızlı bir şekilde değerlendirilebileceği ve bu yöntemin sürücü destekli ve otonom sistemlerin geliştirilmesinde kullanılabileceği anlaşılmıştır.

Anahtar kelimeler: Taşıt Dinamiği, Makine Öğrenmesi, Kurp, Savrulma, Devrilme.

MODELLING VEHICLE STABILITY AT HORIZONTAL CURVES USING MACHINE LEARNING

ABSTRACT

Horizontal curves deflect road alignment in horizontal plane and are critical sections of the road in terms of vehicle stability and traffic safety. Therefore, accurate calculation of the rollover and skidding speeds of vehicles entering these curves is essential for maintaining vehicle stability. These parameters determine how quickly a vehicle can safely negotiate horizontal curves under current road conditions and how well it can remain in balance on transversely inclined surfaces. In this study, machine learning methods were employed to determine the rollover and skidding speeds of various types of vehicles on horizontal curves. A dataset was created containing various scenarios based on different vehicle types, road conditions, and curve characteristics. This dataset helps understand how different vehicles behave under varying conditions. Machine learning algorithms were used to model this dataset, and vehicle stability predictions were made for different scenarios. Among the machine learning models applied to the dataset, the Polynomial Regression model produced better results than the other models. This study

demonstrates that machine learning models can effectively evaluate vehicle stability on horizontal curves. This method can also be utilized in autonomous and driver-assisted systems to enhance safe driving. For autonomous vehicles, such modelling could enable quicker and more precise reactions to environmental conditions, providing a safer and more efficient driving experience. In short, the present study illustrates that machine learning techniques can rapidly evaluate vehicle stability on horizontal curves and can be instrumental in developing driver-assisted and autonomous systems.

Keywords: Vehicle Dynamics, Machine Learning, Horizontal Curves, Sliding, Rollover.

1. Giriş

Karayolu mühendisliğinde yatay kurpların tasarımında, taşıtların dinamik davranışları ve yolun fiziksel özellikleri önemlidir [1]. Taşıt hızı, dönüş yarıçapı, kurp eğimi ve yol yüzeyinin sürtünme katsayısı gibi faktörler, taşıtın kurplarda güvenli bir şekilde seyahat etmesini etkiler [2-4]. Taşıt özellikleri, yol kaplamasının özellikleri ve yatay kurbaların geometrik özellikleri taşıtların kurplarda stabilitesini sağlamak ve savrulma riskini azaltmak için dikkate alınmalıdır. Doğru bir tasarım, sürücülerin yatay kurplarda konforlu biçimde dönüş yapmasını ve trafik güvenliğini sağlar. Bu nedenle, taşıt ve yol özellikleri, güvenli yol tasarımında dikkate alınması gereken temel unsurlardır. Karayolunda seyreden taşıtların, yatay kurplarda savrulma ve devrilme hızlarını tespit etmek, güvenli yol tasarımında ve geometrik standartların belirlenmesinde kritik bir rol oynar. Karayolu tasarımcıları, yol geometrik standartlarını ve yolu kullanacak olan taşıtların özelliklerini dikkate alarak, olası kazaları minimize etmek için çeşitli mühendislik hesaplamaları yaparlar.


Yatay kurplarda savrulma ve devrilme hızını belirleyen başlıca faktörler; kurp yarıçapı, kurbadaki enine eğim (dever) ve yol yüzeyindeki yanal sürtünme katsayısı olarak sıralanabilir [1]. Karayolunun sınıfına göre uygun kurp yarıçapının seçilmesi, karayolu kaplama malzemelerinin trafik ve iklim özelliklerine göre tespit edilmesi ve yatay kurplarda merkezkaç kuvvet etkisini karşılayabilmek amacıyla yola uygun biçimde dever verilmesi tasarım aşamasının adımları olarak ifade edilebilir. Örneğin, yüksek sürtünme katsayısına sahip asfalt veya beton gibi kaplama malzemeleri tercih edilerek, taşıtların kurplarda kaymaması ve güvenli bir şekilde seyahat etmesi sağlanır. Yatay kurplarda savrulma ve devrilme hızlarını tespit etmek yalnızca yol inşaatı öncesinde yapılması gereken bir süreci içermemekte, aynı zamanda mevcut yolların güvenliği için düzenli olarak yapılması gereken bir denetim ve rehabilitasyon sürecini de içermektedir. Trafik yoğunluğu, hava koşulları ve yolun fiziksel durumu gibi faktörler zamanla değişebilir, bu nedenle sürekli olarak güncellenen verilerle yol tasarımının ve güvenliğinin sürdürülebilirliği sağlanmalıdır. Otonom araçlar düşünüldüğünde, güncel yol verilerine göre hızlı ve doğru kararlar alınması sürüş güvenliği açısından oldukça kritiktir. Doğru hesaplamalar ve uygun önlemler alındığında, kazaların önlenmesine ve yol kullanıcılarının güvenliğinin artırılmasına önemli ölçüde katkı sağlanır. Çalışma, trafik güvenliği açısından kritik olan yatay kurplarda taşıt stabilitesi tahmininin makine öğrenmesi modelleri aracılığıyla ne kadar gerçek değerlere yaklaşabildiğini analiz etmektedir. Daha önce makine öğrenmesi yaklaşımının analiz edilmediği bu alanda, makine öğrenmesi modellerinin performanslarının kıyaslanması ve yorumlanması nedeniyle bu çalışma özgün ve önemlidir.

Çalışma kapsamında, öncelikle yatay kurplar ve taşıt dinamiği hakkında bilgiler verilmiş, daha sonra makine öğrenmesi yaklaşımı tanıtılmıştır. Makine öğrenmesi bölümünde, geliştirilen hız tahmin modelleri açıklanmış ve yapılan analizler anlatılmıştır. Elde edilen bulgular ise, sonuçlar bölümünde sunulmuştur.

2. Yatay Kurplar ve Taşıt Dinamiği

Yatay kurplarda seyreden taşıtlara fiziksel olarak bazı kuvvetler etki etmekte ve taşıtın stabilitesi bu kuvvetlerin etki durumuna göre değişmektedir. Bu kuvvetlerin etkisini incelemek amacıyla taşıt dinamiği denklemleri kullanılmaktadır. Taşıt dinamiği denklemleri, bir taşıtın hareketini matematiksel olarak tanımlayan denklemlerdir. Bu denklemler yardımıyla, taşıtların dinamik davranışlarını kavramak ve farklı koşullardaki durumunu tahmin etmek mümkün olmaktadır. Taşıtın hızı, ivmesi, kurptaki stabilitesi ve diğer parametreleri bu denklemler kullanılarak hesaplanabilir. Taşıt dinamiği denklemleri, inşaat mühendisliği, otomotiv tasarımı ve sürücü destek sistemleri gibi farklı alanlarda yaygın olarak kullanılmaktadır. Bu denklemler, taşıtların farklı yol koşullarında performansını değerlendirmek, trafik

güvenliğini artırmak ve taşıt tasarımını geliştirmek için kullanılır. Temel fizik ve dinamik kurallarına göre, yatay kurplarda taşıtlara etki eden kuvvetler Şekil 1’de gösterilmiştir.



Şekil 1. Yatay kurpta taşıta etkiyen kuvvetler

Burada;

F : Kurpta etkiyen merkezkaç kuvveti (N)

f_s : Kurpta etkiyen enine sürtünme kuvveti. (Yolun yüzeyi ile taşıt lastikleri arasındaki sürtünme kuvvetidir)

μ_e : Enine sürtünme katsayısı

N : Normal kuvvet

M : Taşıtın ağırlık merkezi

G : Taşıtın ağırlığı (N)

h : Taşıtın ağırlık merkezinin yoldan yüksekliği (m)

e : Taşıtın dingil mesafesi (m)

m : Taşıtın kütlesi (kg)

R : Yatay kurp yarıçapı (m)

Dönüş yarıçapının azalması veya taşıt hızının artması durumunda merkezkaç kuvveti artar. Bu da taşıtın dönüş sırasında daha fazla dış kuvvetlere maruz kalmasına ve dolayısıyla stabilitesinin azalmasına neden olabilir. Taşıtın savrulabilmesi için $F > f_s$ olmalıdır. Taşıtın dönüş yarıçapı, hızı ve kütle gibi faktörleri dikkate alarak merkezkaç kuvvetinin değeri,

$$F = m * \frac{V^2}{R} = \frac{G}{g} * \left(\frac{V}{3.6}\right)^2 \quad (1)$$

şeklinde ifade edilir. Buradaki $\frac{V^2}{R}$ değeri merkezkaç ivmesinin değeridir. Sürtünme kuvvetinin değeri,

$$f_s = \mu_e * N = \mu_e * G \quad (2)$$

eşitliği ile verilir. $F = f_s$ sınır durumu için

$$\frac{G}{g} * \left(\frac{V}{3.6}\right)^2 = \mu_e * G \quad (3)$$

eşitliğini yazarak, savrulma hızı aşağıdaki gibi elde edilir.

$$V_{sav.} = 3.6 * \sqrt{\mu_e * g * R} \quad (4)$$

Dolayısıyla taşıtın savrulma hızı

$$V_{sav.} = 11.3 * \sqrt{\mu_e * R} \quad (5)$$

şeklinde elde edilir [3].

Bu bağıntı statik stabilite faktörü olarak da anılmaktadır [2, 4].

Yatay kurplarda yukarıda açıklanan dinamik kuvvetlerin etkisiyle taşıtlar yol dışına savrulabildiği gibi, aynı zamanda devrilerek stabilitesini kaybedebilmektedir. Taşıtın devrilme formülü, taşıta etkiyen bütün kuvvetlerin, Şekil 1’de de görüldüğü gibi, dönme noktasına göre alınan moment dengesinin yazılmasıyla hesaplanmaktadır.

Şekil 1’de dikkate alınan kuvvetler ve dönme noktası için moment dengesi aşağıda tanımlanmıştır.

$$F * h = G * \frac{e}{2} \quad (6)$$

$$\frac{G}{g} * \frac{\left(\frac{v}{3.6}\right)^2}{R} * h = G * \frac{e}{2} \quad (7)$$

Bu eşitlikten hız değeri çekilirse, devrilme hızı:

$$V_{dev.} = 3.6 * \sqrt{\frac{e}{2} * \frac{1}{h} * g * R} \quad (8)$$

şeklinde hesaplanır. Taşıtın devrilme hızı bağıntısı

$$V_{dev.} = 11.3 * \sqrt{\frac{e}{2} * \frac{1}{h} * R} \quad (9)$$

şeklinde de verilebilir. Bu bağıntı devrilme eşiği olarak da anılmaktadır [5-10]. Bağıntıda görüldüğü üzere, taşıtın dingil mesafesi, ağırlık merkezinin yoldan yüksekliği ve yatay kurp yarıçapı taşıtın devrilme hızına etki etmektedir.

3. Model ve Analizler

Günümüzde çok boyutlu veri analizi yaklaşımı artmış ve veri çeşitliliği arttıkça analizler zorlaşmaya başlamıştır. Karmaşık veriler üzerinden tahminleme yapılması gereken alanlarda başvurulan yöntemlerin başında makine öğrenmesi gelir. Makine öğrenmesi modelleri veriler arasındaki önemli ilişkileri ortaya çıkararak tahminleme yapmayı öğrenen modellerdir.

Makine öğrenmesi modellerinin performansı, üzerinde öğrenim yapmış olduğu veri kümesinin karmaşıklığına göre değişiklik gösterebilir. İlişki çıkarması basit olan veri kümelerinde basit modeller tercih edilebilirken, ilişki çıkarması zor olan veri kümelerinde modelin karmaşıklığının artırılması gerekir. Verilerdeki ilişkilerin karmaşıklığı yalnızca veri boyutuyla ilişkili değildir ve veri dağılımı da ilişki karmaşıklığı üzerinde büyük bir rol oynamaktadır. Bu sebeple hangi makine öğrenmesi modelinin kullanılan veri seti üzerinde daha iyi performans göstereceğine yalnızca verilere bakılarak karar vermek zordur çünkü verilerin boyutu arttıkça veri dağılımını algılamak zorlaşır. Makine öğrenmesi algoritmalarından hangisinin eldeki veriler üzerinde daha iyi performans gösterdiğini ölçmek için kullanılan genel yöntem, verileri eğitim, validasyon ve test seti olmak üzere üç farklı sete bölmektir.

Modeller eğitim setinde eğitilerek veriler üzerinden tahmin yapmayı öğrenir. Makine öğrenmesi modellerinin farklı hiper parametreleri olduğundan dolayı en iyi hiper parametreyi seçmek için bu parametrelerin farklı kombinasyonları denir ve validasyon seti üzerinden öğrenilen tahmin

yönteminin eğitimde kullanılmamış verilerde ne kadar gerçeğe yaklaştığı hesaplanır. Validasyon setinde en iyi tahmini yapmayı sağlayan hiper parametreleri kullanan model en iyi model olarak seçilir. Son olarak farklı makine öğrenme algoritmaları içinde seçilen en iyi modellerin eğitim ve hiperparametre seçim sürecine dahil edilmemiş olan test seti üzerindeki tahminlerinin gerçek değerlere ne kadar yaklaştığı hesaplanır. Algoritmaların test seti üzerindeki performansları kıyaslanarak en iyi makine öğrenmesi modeli seçilir.

Makine öğrenmesi modelleri, günümüzde, otonom araçların yazılımlarında, şerit algılama [11], obje tespit etme [12], karar verme mekanizmaları [13] gibi çeşitli amaçlarla kullanılmaktadır. Bu çalışmada makine öğrenmesinin otonom araç teknolojilerinde analizini görselleştirerek yorumlayabilmek adına görece basit olan yatay kurplarda taşıtların savrulma ve devrilme hızlarının tahmini üzerine modeller eğitilmiş ve bu modellerin performansları analiz edilmiştir. Analizlerin detaylarının anlatıldığı bu bölüm veri seti üretimi, makine öğrenmesi algoritmaları ve model analizleri olmak üzere üç alt başlıktan oluşmaktadır.

3.1 Veri Seti Üretimi

Bu çalışmada incelenen savrulma ve devrilme hızları Bölüm 1’de ele alınmış olan formüller üzerinden hesaplanabilmektedir. Savrulma hızı, kurp yarıçapı (R) ve enine sürtünme katsayısı (μ_e) değişkenleri yardımıyla hesaplanırken; devrilme hızı, kurp yarıçapı (R), taşıtın dingil mesafesi (e) ve taşıtın ağırlık merkezinin yoldan yüksekliği (h) değişkenleri kullanılarak hesaplanır. Analizlerde bu değerler girdi değerleri, savrulma ve devrilme hızları ise çıktı değerleri olarak tanımlanmıştır. Savrulma ve devrilme hız tahminleri iki farklı analiz olarak ele alınmış olup, belirtilen girdi ve çıktı değerleri ile iki farklı veri seti oluşturulmuştur.

Savrulma hızı tahmini için kurp yarıçapı (R) değerleri $\{30, 60, 90, 120, 200, 300, 400, 500\}$ ve enine sürtünme katsayısı (μ_e) değerleri $\{0.4, 0.38, 0.36, 0.34, 0.32, 0.3, 0.28, 0.26, 0.24, 0.22, 0.2, 0.18, 0.16, 0.14, 0.12, 0.1, 0.08, 0.06, 0.04\}$ kümelerinden seçilmiş olup, bu değerlerin kombinasyonu üzerinden savrulma hızları hesaplanmıştır. Bu değerler gerçek hayatta görülebilecek olası değerlerden seçilmiştir. Veri setinde toplamda 152 adet örnek bulunmaktadır.

Devrilme hızı tahmini için ise savrulma hızı veri seti oluşturulmasından farklı bir yol izlenmiştir. Kurp yarıçapı R değerleri $\{30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180, 190, 200, 225, 250, 275, 300, 325, 350, 375, 400, 425, 450, 475, 500\}$ kümesinden seçilmiştir. Taşıt dingil mesafesi (e) için otomobil, minibüs, ağır kamyon ve otobüs olmak üzere 4 farklı araç türü seçilmiştir. Taşıtların dingil mesafesi (e) her bir kategori için sırasıyla 1.736, 2.059, 2.482 ve 2.200 olarak belirlenmiştir. Bu değerler gerçek hayattan alınan taşıt örnekleri üzerinden hesaplanmıştır. Taşıtların ağırlık merkezinin yoldan yüksekliği h ise otobüs kategorisi haricindeki kategorilerde gerçek hayattan toplanan veriler üzerinden minimum ve maksimum değerler olarak belirlenmiştir. Sırasıyla otomobil, minibüs ve ağır kamyon kategorileri için bu değerler $[0.508, 0.5842]$, $[0.762, 1.016]$ ve $[1.524, 2.159]$ olarak bulunmuştur. Otobüs için ise tek bir yaklaşık değer olarak 1.302 kullanılmıştır. Savrulma hızı veri setinde olduğu gibi bu değerlerin kombinasyonu alınarak veri seti oluşturulmuştur. Savrulma hızı veri setinden farklı olarak minimum ve maksimum değer aralığı olan kategoriler için 10 farklı h değeri basit rastgele örnekleme yöntemiyle oluşturulmuştur. Böylece h aralığı olan her bir kategori için 300, otobüs kategorisi için 30 farklı girdi verileri üzerinden devrilme hızı hesaplanarak toplamda 930 örnek içeren bir veri seti oluşturulmuştur.

3.2 Makine öğrenmesi algoritmaları

Savrulma ve devrilme hızları sürekli değişken oldukları için analizlerde üç farklı regresyon modeli kullanılmıştır. Bu modeller *(i)* doğrusal regresyon, *(ii)* polinom regresyon ve *(iii)* çok katmanlı algılayıcılardır. Savrulma ve devrilme hızlarının gerçek değerleri oluşturulan veri setinde bulunduğu için seçilen modeller denetimli öğrenme yaklaşımı ile eğitilmiştir.

3.2.1 Doğrusal regresyon

Doğrusal regresyon, girdi ve çıktı arasında bir doğrusal ilişki olduğu varsayımını yapan bir makine öğrenmesi algoritmasıdır. Bulunan doğrusal ilişki bir hiper düzlem formülü ile ifade edilir. Doğrusal

regresyon algoritmasında her bir girdi değerine birer katsayı β_{1-n} atanır ve ek olarak bir de eğilim değeri β_0 bulunmaktadır. Bu katsayılar hiper düzlemin oryantasyonunu belirlerken β_0 değeri ise hiper düzlemin sıfır noktasına göre uzaydaki yer değişikliğini belirler. Modelin formülü aşağıdaki gibidir:

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n \quad (10)$$

Bu formülde x_{1-n} terimleri girdi değerlerini temsil ederken y değeri tahmin değerini temsil eder. Katsayılar ve eğilim değeri β_{0-n} doğrusal regresyon modelindeki öğrenilebilir parametrelerdir. Bu parametreler üretilen tahmin değerlerinin veri setindeki gerçek değerler ile arasındaki hatayı en düşük seviyeye getirecek şekilde hesaplanır. Bu işlem sırasında genelde en küçük kareler yöntemi kullanılmaktadır.

3.2.2 Polinom Regresyon

Polinom regresyonun eğitim yöntemi doğrusal regresyon ile birebir aynı olsa da tahmin yöntemi doğrusal regresyondan farklıdır. Polinom regresyon doğrusal olmayan ilişkileri öğrenebilmek için girdi değerlerinin 1'den k 'ye kadar derecelerini kullanarak tahmin üretir. Bu sebeple polinom regresyon doğrusal regresyona göre daha karmaşık ilişkileri modelleyebilmektedir. Örneğin, iki girdi değeri x_1 ve x_2 için üçüncü dereceden ($k=3$) bir polinom regresyon modeli aşağıdaki gibidir:

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_1^2 + \beta_4x_2^2 + \beta_5x_1x_2 + \beta_6x_1^3 + \beta_7x_2^3 + \beta_8x_1^2x_2 + \beta_9x_1x_2^2 \quad (11)$$

k değeri bir hiper parametre olup, validasyon seti kullanılarak veri setindeki veri dağılımını en iyi modelleyen k değeri bulunmalıdır.

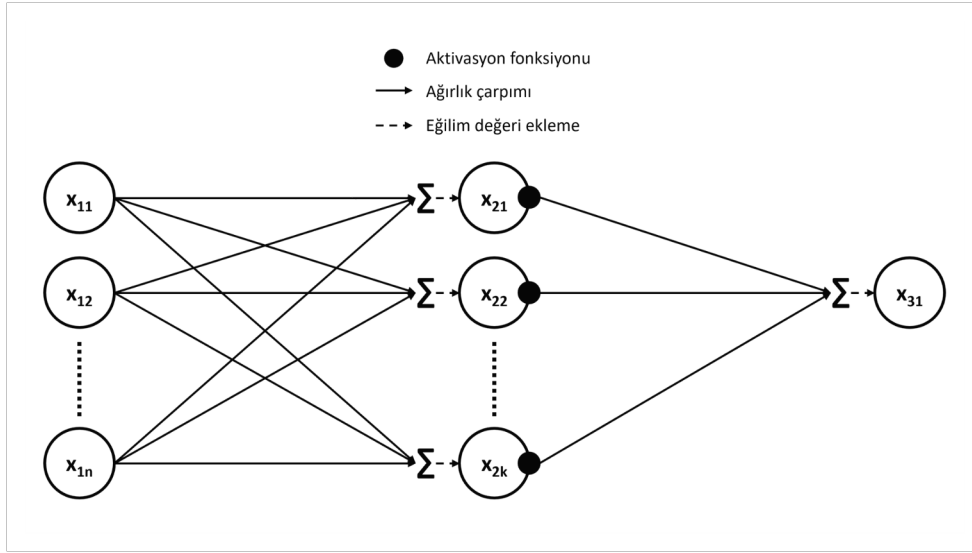
3.2.3 Çok katmanlı algılayıcı

Yapay sinir ağları makine öğrenmesinin bir alt dalıdır. Tek katmanlı ya da çok katmanlı olarak tanımlanabilir. Yapay sinir ağlarının çok katmanlı olan versiyonları çok katmanlı algılayıcılar olarak isimlendirilmiştir. Bu modeller aynı zamanda literatürde evrensel yaklaşımıcılar olarak da tanımlanmaktadır [14]. Katman sayısındaki farklılıklara ek olarak yapay sinir ağlarının her bir katmanında bir veya birden fazla nöron bulunabilmektedir. Bu nöronlar bir önceki katmandan gelen değerleri işleyerek bir sonraki katmana iletir. Bu işlem aşağıdaki gibi formüle edilmiştir:

$$a_j = g\left(\sum_{i=1}^n w_{ij}x_i + b_j\right) \quad (12)$$

Yukarıdaki denklemde a_j katmandaki j . nöronun bir sonraki katmana ilettiği değeri belirtir. Bu değer belirlenirken bir önceki katmandaki n nöron bağlantılarından gelen her bir değer öğrenilebilir parametreler olan w ağırlıklarıyla çarpılır ve eğilim değeri b bu sonuca eklenir. Bu sonuçlar toplanır ve aktivasyon fonksiyonu olarak belirlenen g fonksiyonundan geçirilir. g fonksiyonu (aktivasyon fonksiyonu) işlenen değerler arasında bulunan doğrusal ilişkiyi doğrusal olmayan ilişkiye dönüştürmek için kullanılan bir fonksiyondur. Böylece model daha karmaşık fonksiyonları öğrenebilmektedir.

Girdi değerlerinin ilk katmandan başlayarak her bir nöron tarafından kolektif olarak işlenmesine ve son olarak çıktı değerine ulaşılmasına kadar geçen veri işleme sürecine ileri yayılım algoritması denmektedir. İleri yayılım algoritması sonucunda model bir tahminde bulunmuş olur. Çok katmanlı algılayıcılar için örnek bir mimari Şekil 2'de gösterilmektedir.



Şekil 2. Örnek çok katmanlı algılayıcı mimarisi

Verilen örnek mimarideki ilk katman girdi katmanı, aradaki katman gizli katman ve son katman da çıktı katmanı olarak isimlendirilmektedir. Girdi katmanında n değer girdi olarak verilirken, gizli katmanda k tane nöron bulunmaktadır. k değeri modelin hiper parametrelerinden biridir. Analizlerde tek bir tahmin çıktısı bulunduğu için, analizlerle uyumlu olması adına şekildeki çıktı katmanında yalnızca bir nöron gösterilmiştir. Birden fazla değeri tahmin etmek gerektiği durumlarda bu sayı artırılabilir. Bunun yanı sıra gizli katman sayısı da çoğaltılabilmektedir. Gizli katman ve nöron sayılarının artırılması modelin daha karmaşık fonksiyonları öğrenebilme kapasitesini artırır.

Model eğitimi sürecinde ileri yayılım algoritması sonrasında geri yayılım algoritması kullanılarak modeldeki öğrenilebilir parametreler güncellenir [14]. Bu güncelleme probleme göre tanımlanmış olan hata fonksiyonu göz önünde bulundurularak yapılır [15]. Hatanın parametrelere göre türevi alınarak parametreler hatayı minimize edecek şekilde güncellenir. Regresyon modeli eğitimi için hata fonksiyonu olarak genelde en küçük kareler yöntemi kullanılmaktadır.

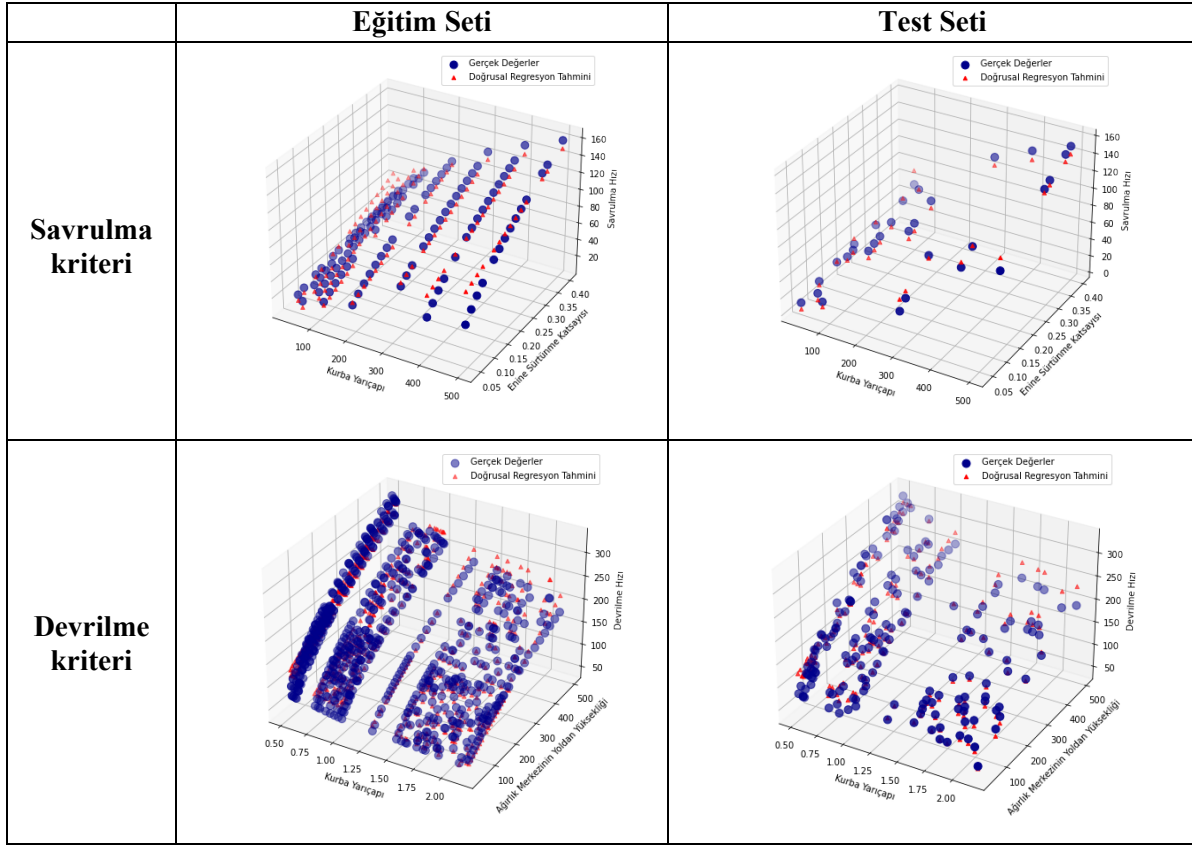
3.3 Model Analizleri

Bölüm 2.2’de açıklanmış olan modeller analiz için oluşturulan veri seti üzerinde scikit-learn [16] ve PyTorch [17] kütüphaneleri yardımıyla eğitilmiştir ve modellerin tahminleri Matplotlib kütüphanesi [18] desteğiyle üç boyutlu olarak görselleştirilmiştir. Kullanılan veri seti, eğitim, validasyon ve test seti olmak üzere üç farklı sete bölünmüştür. Bu veri setleri sırasıyla verilerin %64, %16 ve %20’sinden oluşmaktadır. Veri seti bölünmeden önce veriler karıştırılarak seçim sırasında rastgelelik sağlanmıştır. Modeller eğitim seti üzerinde en küçük kareler yöntemi ile eğitilmiştir ve eğitim sırasında farklı hiper parametreler ile validasyon seti üzerinden değerlendirilerek en iyi performans gösteren model seçilmiştir. Eğitim sırasında girdi ve çıktı değerleri $[0,1]$ aralığında normalize edilmiştir. Validasyon seti üzerindeki tahmin hataları normalize edilmiş değerler üzerinden raporlanmış olup, algoritma bazında seçilmiş en iyi modeller kıyaslanırken test seti üzerinde hem normalize edilmiş hem de edilmemiş tahmin hataları raporlanmıştır.

Doğrusal regresyon modelinde hiper parametre bulunmadığı için tek bir model eğitilmiştir. Modelin gerçek veriler üzerinde almış olduğu hata değerleri Tablo 1’de verilirken, eğitim ve test setlerinde tahmin değerlerinin gerçek değerlerine yakınlığı üç boyutlu uzayda Şekil 3’te gösterilmiştir.

Tablo 1. Doğrusal regresyon modelinin savrulma ve devrilme hızı tahmininde en küçük kareler yöntemi ile almış olduğu hata değerleri

| Tahmin Değeri | Validasyon (N) | Test (N) | Test |
|------------------|----------------|----------|----------|
| Savrulma kriteri | 0.0051 | 0.0029 | 60.8161 |
| Devrilme kriteri | 0.0024 | 0.0029 | 235.0927 |



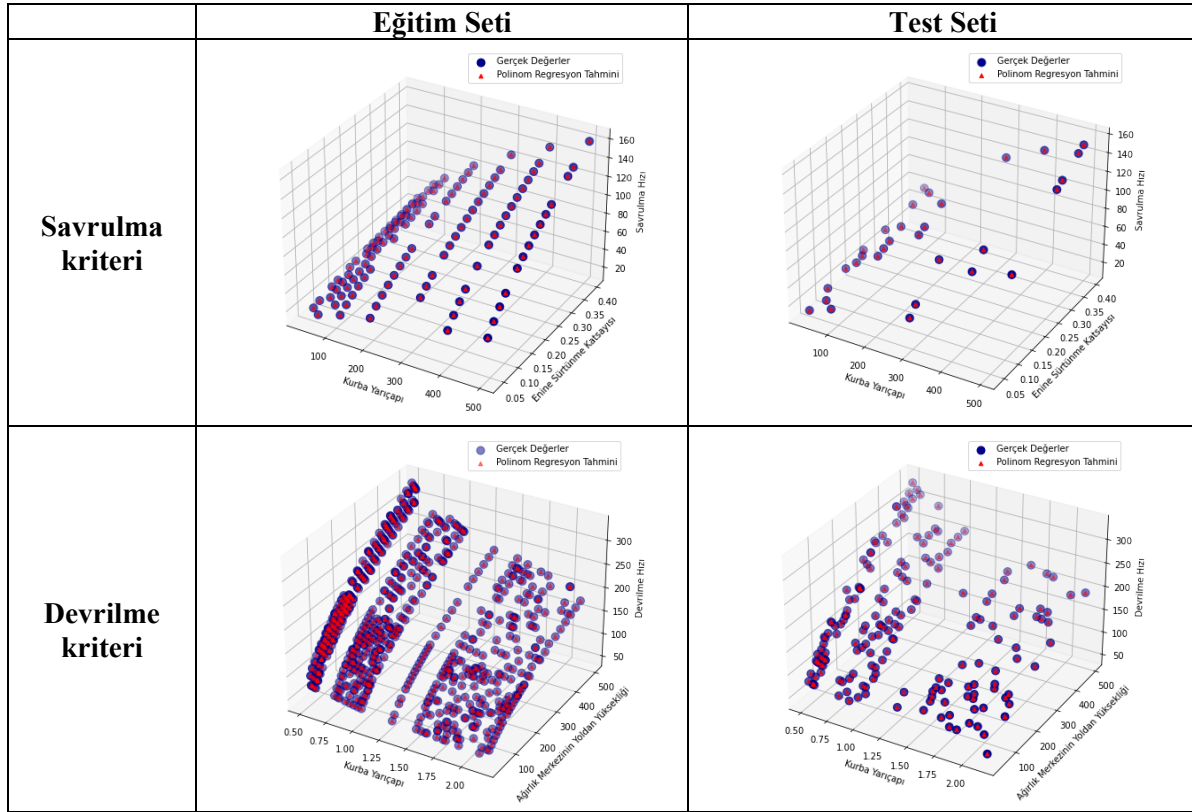
Şekil 3. Doğrusal regresyon modelinin savrulma ve devrilme hızı tahmininde göstermiş olduğu performans

Polinom regresyon modeli eğitilirken hiper parametre olarak farklı polinom dereceleri denenmiştir. Modelin bu denemeler sırasında gerçek veriler üzerinde almış olduğu hata değerleri Tablo 2’de verilirken, eğitim ve test setlerinde tahmin değerlerinin gerçek değerlerine yakınlığı üç boyutlu uzayda Şekil 4’te gösterilmiştir.

Tablo 2. Polinom regresyon modelinin savrulma ve devrilme hızı tahmininde en küçük kareler yöntemi ile almış olduğu hata değerleri

| Tahmin Değeri | Polinom Derecesi (k) | Validasyon (N) | Test (N) | Test |
|------------------|----------------------|----------------|-----------------|----------------|
| Savrulma kriteri | 1 | 5.15e-3 | - | - |
| | 2 | 3.27e-4 | - | - |
| | 3 | 5.67e-5 | - | - |
| | 4 | 9.35e-6 | - | - |
| | 5 | 2.88e-6 | - | - |
| | 6 | 9.50e-7 | - | - |
| | 7 | 4.51e-7 | - | - |
| | 8 | 8.70e-8 | - | - |
| | 9 | 1.69e-7 | - | - |
| | 10 | 1.34e-7 | - | - |
| | 11 | 4.25e-9 | 2.40e-10 | 5.01e-6 |
| | 12 | 8.96e-7 | - | - |
| Devrilme kriteri | 1 | 2.45e-3 | - | - |
| | 2 | 1.44e-4 | - | - |
| | 3 | 3.55e-5 | - | - |
| | 4 | 4.19e-6 | - | - |
| | 5 | 9.64e-7 | - | - |
| | 6 | 2.60e-7 | - | - |
| | 7 | 8.68e-8 | - | - |
| | 8 | 3.82e-8 | - | - |
| | 9 | 1.73e-8 | - | - |
| | 10 | 2.61e-9 | 9.22e-9 | 7.37e-4 |
| | 11 | 1.64e-8 | - | - |
| | 12 | 6.59e-8 | - | - |

Tabloda, (N) ile gösterilen değerler normalize edilmiş değerlerdir. Validasyon seti üzerinde en iyi performansı gösteren modeller en iyi model olarak seçilmiş olup test seti üzerindeki performansları hesaplanmıştır. Tabloda görüldüğü üzere savrulma hızı tahmininde en iyi performans gösteren model 11. dereceden polinom ($k=11$) kullanırken, devrilme için en iyi k değeri 10 olarak bulunmuştur.



Şekil 4. Polinom regresyon modelinin savrulma ve devrilme hızı tahmininde göstermiş olduğu performans

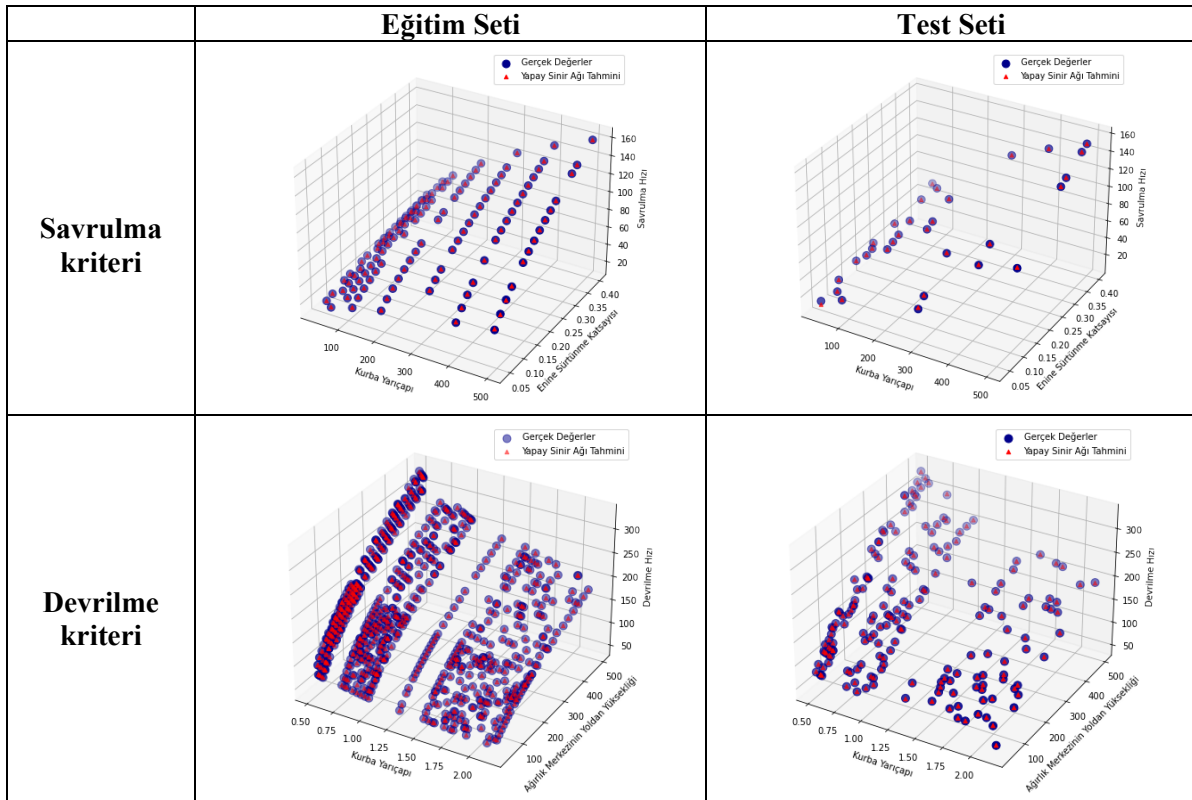
Çok katmanlı algılayıcı modellerinde eğitimde kullanılan dönem sayısı 10,000 olarak sabit tutulmuş olup hiper parametre olarak gizli katmandaki nöron sayısı ve öğrenme hızı hiper parametreleri için farklı kombinasyonlar denenmiştir. Öğrenim hızı için bu değerler {0.05, 0.01, 0.005, 0.001} kümesinden seçilirken gizli katmandaki nöron sayısı {4, 8, 16, 32, 64, 128, 256} kümesinden seçilmiştir. Aktivasyon fonksiyonu olarak ReLU kullanılmıştır.

Dönem sayısı, eğitim sırasında veriler üzerinden kaç defa geri yayılım yapılacağını belirlerken öğrenme hızı geri yayılımda hesaplanan türevlerin ağırlıklara ne kadar etkileyeceğini belirler. Eğitimde yalnızca tek bir gizli katman kullanılmıştır ve bu katmandaki nöron sayıları değiştirilerek modelin kompleksliğinin tahmin performansına etkisi gözlemlenmiştir. Buna ek olarak farklı öğrenme hızları da denenerek içlerinden en iyi performans gösteren model seçilmiştir.

Denenmiş olan modeller içinden validasyon seti üzerinde en iyi performans gösteren modellerin hiper parametreleri ve gerçek veriler üzerinde almış olduğu hata değerleri Tablo 3'te verilirken, eğitim ve test setlerinde tahmin değerlerinin gerçek değerlerine yakınlığı üç boyutlu uzayda Şekil 5'te gösterilmiştir.

Tablo 3. Çok katmanlı algılayıcı modelinin savrulma ve devrilme hızı tahmininde en küçük kareler yöntemi ile almış olduğu hata değerleri

| Tahmin Değeri | Gizli Katmandaki Nöron Sayısı | Öğrenme Hızı | Validasyon (N) | Test (N) | Test |
|------------------|-------------------------------|--------------|----------------|----------|---------|
| Savrulma kriteri | 128 | 0.05 | 3.82e-6 | 2.96e-5 | 6.19e-1 |
| Devrilme kriteri | 256 | 0.01 | 1.11e-6 | 1.18e-6 | 9.42e-2 |



Şekil 5. Çok katmanlı algılayıcı savrulma ve devrilme hızı tahmininde göstermiş olduğu performans

Tablo 4. Validasyon seti üzerinde en iyi performans gösteren makine öğrenmesi modellerinin test seti üzerindeki performans karşılaştırması

| Tahmin Türü | Değerlendirme Ölçütü | Doğrusal Regresyon | Polinom Regresyon | Çok Katmanlı Algılayıcı |
|---------------|----------------------|--------------------|-------------------|-------------------------|
| Savrulma hızı | En küçük kareler | 60.8161 | 5.01e-6 | 6.19e-1 |
| | R ² | 0.96315 | 1.00000 | 0.99957 |
| Devrilme hızı | En küçük kareler | 235.0927 | 7.37e-4 | 9.42e-2 |
| | R ² | 0.94720 | 1.00000 | 0.99997 |

Validasyon seti üzerinde en iyi performans gösteren modellerin test seti üzerindeki tahmin performansları Tablo 4’te karşılaştırılmıştır. Bu karşılaştırmada en küçük kareler yöntemine ek olarak, regresyon modellerinin performans analizinde sıkça kullanılan R² ölçütü de raporlanmıştır. Karşılaştırmada, polinom regresyon modelinin diğer modellere göre her iki değerlendirme ölçütü üzerinde de daha iyi performans gösterdiği gözlemlenmiştir.

Tablo 5. Polinom regresyon modelinin test seti üzerindeki devrilme hızı tahmininin ve gerçek değerlerin araç türleri ve kırba yarıçapı (R) değerleri üzerinden karşılaştırması

| Araç Türü | Kırp Yarıçapı, R (m) | Tahmin Edilen Devrilme Hızı (km/sa) | Gerçek Devrilme Hızı (km/sa) |
|-------------|----------------------|-------------------------------------|------------------------------|
| Ağır Kamyon | 100 | 101.91 | 101.91 |
| Ağır Kamyon | 350 | 190.75 | 190.77 |
| Minibüs | 100 | 117.09 | 117.10 |
| Minibüs | 200 | 161.84 | 161.84 |
| Otobüs | 50 | 73.45 | 73.44 |
| Otobüs | 350 | 194.30 | 194.31 |
| Otomobil | 450 | 300.36 | 300.36 |
| Otomobil | 50 | 97.54 | 97.53 |

Tablo 5’te verilen bazı örnek bulgulardan görüleceği üzere, polinom regresyon modeli ile teorik değerlere oldukça yakın sonuçlar elde edilmiştir. Ayrıca elde edilen sonuçlar taşıt dinamiği açısından

değerlendirildiğinde, farklı araç türlerinin aynı kurp yarıçapı için devrilme hızlarının değiştiği, bu değişimin araç boyutu (gabarisisi) ile doğrudan ilişkili olduğu anlaşılmıştır.

4. Sonuç

Bu çalışmada, makine öğrenmesi yaklaşımı ile yatay kurplarda seyreden taşıtların stabilitesi incelenmiştir. Yatay kurplarda trafik güvenliği önem arz etmekte ve pek çok faktörden etkilenmektedir. Bu faktörlerden, yol geometrisi, kaplama özellikleri ve farklı taşıt türleri çalışma kapsamında dikkate alınmıştır. Buna göre, farklı kurp yarıçapları, enine sürtünme katsayısı değerleri ve araç özellikleri için araçların savrulma hızları ve devrilme hızları tahmin edilmiştir.

Çalışma kapsamında, makine öğrenmesi yaklaşımlarından, doğrusal regresyon, polinom regresyon ve çok katmanlı algılayıcı yöntemleri kullanılmıştır. Çalışmada kullanılan veri setleri, eğitim, validasyon ve test seti biçiminde üç farklı oranda dikkate alınmıştır. Yapılan analizlerde, modellerin test seti üzerindeki hata değerleri ve tahmin grafikleri kıyaslandığında; doğrusal regresyon modelinin kapasitesinin ilişkileri öğrenmekte yeterli olmadığı, bunun yanı sıra polinom regresyon ve çok katmanlı algılayıcı modellerinin kapasitesinin gerçek dağılımı tahmin etme üzerinde başarılı olduğu gözlemlenmiştir. Polinom regresyon modelindeki polinom derecesi artırıldıkça modelin tahmin kapasitesi artırılmış ve bir noktaya kadar performans artışı da gözlemlenmiştir. Polinom regresyon modelleri içinden seçilen en iyi modeller çok katmanlı algılayıcı modellerinden daha iyi performans göstermişlerdir.

Çalışmada yapılan analizler sonucunda, özellikle küçük yarıçaplı kurbalarda hız sınırlarına uyulmasının trafik güvenliği açısından faydalı olacağı ve kurp yarıçapının 250 m ve üzerinde olması durumunda daha güvenli seyir sağlanabileceği tespit edilmiştir.

Yapılan çalışma kapsamında kullanılan makine öğrenmesi algoritmalarının aynı zamanda otonom araç teknolojileri ile kullanılması trafik güvenliği açısından faydalı olacaktır. Otonom araçlar, çevrelerindeki koşulları anlamak ve güvenli bir şekilde hareket etmek için gerçek zamanlı verilere ihtiyaç duymaktadır. Makine öğrenmesi algoritmaları, bu verileri analiz ederek yatay kurbalardaki riskleri önceden tahmin edebilir ve araçların güvenli bir şekilde dönüş yapmasını sağlayabilir. Bu nedenle, çalışma kapsamında makine öğrenmesiyle yapılan hesaplamaların otonom araç teknolojileri için kritik bir öneme sahip olduğu söylenebilir.

Sonuç olarak, makine öğrenmesiyle taşıtların yatay kurplarda savrulma ve devrilme hızlarının kolayca hesaplanması, sürüş güvenliğini artırmak ve kazaları önlemek için etkili bir yaklaşım sağlayabilir.

Kaynaklar

- [1] N. Yayla, Karayolu Mühendisliği, Birsen Yayınevi, İstanbul, (2009).
- [2] B. Gunay, Sliding and Rollover on Highways - Subtleties to Note, The Turkish Chamber of Civil Engineers (Teknik Dergi), 33 (4) (2022) 12329-12334.
- [3] Y.S. Murat, Ulaştırma-1 Ders Notları, Pamukkale Üniversitesi, Denizli, (2020).
- [4] R. Lamm, B. Psarianos, T. Mailaende, Highway Design and Traffic Safety Engineering Handbook, NY: McGraw-Hill, New York, 848p, (1999).
- [5] M. Rogers, Highway Engineering, Oxford, UK, Blackwell Science, (2003).
- [6] P.A. Tipler, G. Mosca, Physics for Scientists and Engineers, 6th ed. W.H. Freeman and Company, New York, (2007).
- [7] J.L. Meriam, L.G. Kraige, Engineering Mechanics: Dynamics. 6th ed. John Wiley & Sons, Hoboken, (2007).
- [8] C.A. O'Flaherty, Highways. Traffic Planning and Engineering. 3rd ed. Edward Arnold, London, UK, (1986).
- [9] T.D. Gillespie, Fundamentals of Vehicle Dynamics. Society of Automotive Engineers, Warrendale, PA, (1992).

- [10] Z. Jin, B. Li, J. Li, *Dynamic Stability and Control of Tripped and Untripped Vehicle Rollover*. Synthesis Lectures on Mechanical Engineering. Morgan & Claypool Publishers, San Rafael, CA, (2019).
- [11] Q. Zou, H. Jiang, Q. Dai, Y. Yue, L. Chen, Q. Wang, Robust lane detection from continuous driving scenes using deep neural networks. *IEEE Transactions on Vehicular Technology*, 69 (1) (2020) 41–54.
- [12] A. Balasubramaniam, S. Pasricha, *Object Detection in Autonomous Vehicles, Status and Open Challenges*, (2022).
- [13] Q. Liu, X. Li, S. Yuan, Z. Li, *Decision-Making Technology for Autonomous Vehicles: Learning-Based Methods, Applications and Future Outlook*. In 2021 IEEE International Intelligent Transportation Systems Conference (ITSC), IEEE Press, (2021) 30–37.
- [14] K. Hornik, M. Stinchcombe, H. White, Multilayer feedforward networks are universal approximators. *Neural Networks*, 2 (5) (1989) 359–366.
- [15] Y.S. Murat, Comparison of Fuzzy Logic and Artificial Neural Networks Approaches in Vehicle Delay Modeling. *Transportation Research Part C-Emerging Technologies*, 14 (1) (2006) 316–334.
- [16] F. Pedregosa et al, Scikit-learn: Machine learning in Python, *Journal of Machine Learning Research*, 12 (Oct) (2011) 2825–2830.
- [17] A. Paszke et al, PyTorch: An Imperative Style, High-Performance Deep Learning Library. In *Advances in Neural Information Processing Systems*, Curran Associates Inc, 32 (2019) 8024–8035.
- [18] J. Hunter, Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9 (3) (2007) 90-95.