

# Gerçek Zamanlı Gözlem ile Sürücü Uyuşukluğunu Tespit ve Uyarı Sistemi

Furkan Terzi<sup>1</sup>, Özlem Süer<sup>2</sup> ve Gülay Çiçek<sup>3</sup>

<sup>1,2</sup>Yazılım Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi

İstanbul Beykent Üniversitesi, Sarıyer, İstanbul, Türkiye

<sup>1</sup>2203013065@student.beykent.edu.tr, <sup>2</sup>2203013064@student.beykent.edu.tr

<sup>3</sup>gulaycicek@beykent.edu.tr

**Özet**—Sürücülerin yorgunluk ve uyuşukluk durumlarını gerçek zamanlı olarak tespit etmeyi amaçlayan derin öğrenme tabanlı bir model geliştirmektedir. MRL Eye Dataset ve Yawn Dataset gibi açık erişimli veri setlerinden faydalanarak, sürücülerin göz açık/kapalı durumları ve esneme hareketleri derinlemesine analiz edilmektedir. MRL Eye Dataset, yaklaşık 85.000 görüntü ile sürücünün göz durumlarını sınıflandırırken, Yawn Dataset ise 5.000’den fazla görüntü ile esneme hareketlerini tespit etmek için kullanılmaktadır.

Bu veri setleri, modelin doğruluğunu artırmak amacıyla dengeli şekilde düzenlenmekte ve çeşitli ön işleme teknikleri ile iyileştirilmektedir. Model, CNN ile eğitilmekte ve transfer öğrenme teknikleriyle güçlendirilmekte, bu sayede modelin sınıflandırma başarısı önemli ölçüde artırılmaktadır.

Modelin elde ettiği doğruluk oranı %98, hassasiyet oranı %97,5 ve özgüllük oranı ise %98,2 gibi yüksek metriklerle başarılı sonuçlar elde edilmektedir. Bu çalışma, göz kırpması ve esneme analizlerine odaklanarak, mevcut literatürle kıyaslandığında önemli bir yenilik sunmakta ve sürücü yorgunluğunu tespit etme konusunda daha güvenilir ve etkili bir yaklaşım geliştirmektedir. Ayrıca, sentetik verilerin kullanılması, gerçek veri toplama zorluklarını aşarak daha geniş ve çeşitlendirilmiş veri setleriyle modelin eğitilmesine olanak tanımaktadır.

Gelecekte, baş hareketleri, yüz ifadeleri ve diğer biyometrik verilerin sisteme entegre edilmesi ile modelin doğruluğu daha da artırılabilir ve sürücülerin dikkat seviyelerini daha kapsamlı bir şekilde değerlendirebilir. Ayrıca, farklı kültürel ve coğrafi gruplardan elde edilen verilerle modelin genellenebilirliği sağlanarak, daha geniş bir kullanıcı kitlesine hitap edilmesi mümkün hale gelebilmektedir.

Sonuç olarak, bu çalışma, sürücü yorgunluğunu tespit etmeye yönelik geliştirilen derin öğrenme tabanlı modelin, trafik güvenliğini derinlemesine dönüştürebilecek büyük bir potansiyele sahip olduğunu ve yol güvenliğini önemli ölçüde artırabileceğini ortaya koymaktadır. Özellikle otonom araçlar ve akıllı ulaşım sistemleri gibi teknolojilerin gelişimiyle paralel olarak, bu model sürücü destek sistemlerine entegre edilerek, kazaların önlenmesine katkı sağlayabilir ve sürücülerin güvenliğini artırabilir. Bu model, trafik kazalarını önlemek ve sürücülerinin güvenliğini sağlamak adına devrim niteliğinde bir adım olarak değerlendirilebilmektedir.

**Anahtar Kelimeler:** Derin Öğrenme, Sürücü Yorgunluğu, Göz Takibi, Esneme Analizi, Trafik Güvenliği, Yapay Zeka




Fig. 1: [1].

## I. GİRİŞ

Ulaşım, insan hayatının vazgeçilmez bir parçasıdır ve ülke ekonomisinin önemli bir kısmı ulaşım sektöründen gelmektedir [2]. Sürücü uykululuk durumu ve uyuşukluğu, insan yaşamında ciddi sonuçlar doğurmakta ve büyük riskler oluşturmaktadır. Ulaşım, eğitim ve eğlence gibi çeşitli alanlara yayılan riskler, yol güvenliği bağlamında, küresel yaralanmalara ve ölümlere yol açan kazaların başlıca nedenlerindendir [3]. Pan Amerikan Sağlık Örgütü'ne göre, dünya çapında yaklaşık 1,5 milyon kişi trafik kazaları sonucu ölmekte ve milyonlarca kişi yaralanmaktadır [4].

Amerika Birleşik Devletleri'nde, AAA trafik güvenliği vakfi tarafından yapılan bir araştırma, yılda 328.000'den fazla kazanın sürücü yorgunluğundan kaynaklandığını [5], bunların 109.000'inin yaralanmayla sonuçlandığını ve yaklaşık 6.400'ünün ölümle sonuçlandığını tahmin edilmektedir [6]. Son yıllarda, teknolojinin hızla gelişmesi yaşamda güvenliği, ve rahatlığı artıran yenilikçi çözümlerin ortaya çıkmasına neden olmaktadır [7][8].

Çalışmalar, trafik kazalarından kaynaklanan ölümlerin ve yaralanmaların, dikkat dağınıklığı ve uyuşukluk gibi, sürücü yorgunluğuyla ilişkili insan faktörlerinden kaynaklandığını göstermektedir [9]. Çoğu durumda, uykulu sürüş kazaları kırsal yollarda ve otoyollarda meydana gelmektedir [10]. Yolcuların ve yayaların güvenliği ve emniyeti, sürücü uykululuğu nedeniyle tehlikeye girmektedir. Bu nedenle, ulaşımında güvenliği artırmak için uykulu sürüşü tanımlama ve tahmin etme teknikleri önemlidir [11].

### Özgül Model ile Sürücü uyuşukluğunu tespit etmek için öne çıkan 4 başlık:

- **Göz Kırpma:** Göz kırpmalar, sürücünün uyanıklık düzeyinin iyi bir göstergesidir. Sürücünün uyuşukluk durumu göz kırpmalarının sıklığı ve düzenindeki değişikliklere bağlıdır. Bu yöntemin uygulanması, kaza sayısını azaltarak yol güvenliğini önemli ölçüde iyileştirmektedir [1].

Örneğin, Romoser ve Fisher, iki farklı koşulda kavşaklardaki dönüşler sırasında katılımcıların bakış noktalarını belirlemek için bir göz izleyici kullandılar. Bao ve Boyle, sürücülerin kavşaklarda sağa ve sola dönüşler ve düz sürüş manevraları yaparken baş hareketlerini izlemek için araç içi kameraları kullanarak sürücülerin görsel tarama davranışlarını değerlendirdiler [12].

- **Esne Sıklığı:** Sürüş sırasında esneme, yorgunluk ve uykululuğun önemli bir belirtisi olup, sürüş güvenliğini tehlikeye atmaktadır. Sürücülerin esneme refleksi, dikkat dağılmasına yol açarak kazalara sebebiyet vermektedir. Bu nedenle, esnemenin sürücüler üzerindeki etkilerini anlamak ve kontrol yöntemleri geliştirmek, yol güvenliğini artırmak için kritik bir adımdır [13].
- **Sentetik Veri:** Gerçek dünyadan alınan verilerin taklit edilerek, gerçek veri olmadan model eğitmek veya test etmek için kullanılmaktadır. Gerçek dünyada veri toplamak zor, pahalı veya etik açıdan problemli olabilir. Sentetik veri, bu eksikliği giderir ve gerçek olan verileri taklit ederek veriler üretmektedir. Sentetik veriler, özellikle göz ve hareketlerini incelemek için gereksinim duyduğumuz verileri oluşturmanın yanı sıra, gerçek verilerin toplama zorluklarıyla karşılaşmadan modelimizi daha geniş ve çeşitlendirilmiş bir veri setiyle eğitmemizi sağlamaktadır.
- **Çevrimdışı Veri:** Toplandıktan sonra işlenen ve analiz edilen veridir. Bu veriler, önceden kaydedilir ve model eğitiminde veya analizde kullanılmak üzere daha sonra işlenmektedir. Offline veri, büyük veri kümelemeleri için uygun olup, geçmişteki verilerle yapılan analizlerde kullanılır. Offline veriler ise, büyük miktarda verinin toplanıp işlenmesinin ardından derinlemesine analiz yapılabilmesine olanak tanıyarak, modelin doğruluğunu artırmaktadır. Bu süreçte, göz, esneme hareketleri gibi dikkat dağıtıcı faktörleri incelemek, sürücü uyuşukluğu tespiti için önemli bir rol oynamaktadır.

Literatüre göre uyuşukluk tespit sistemleri, görüntü tabanlı yaklaşımlar kullanılmaktadır. Bu sistemler, sürücülerin göz hareketleri, ağız yüz ifadeleri, kaşlar veya solunum gibi parametreleri izleyerek uyuşukluğu tespit etmektedir. [14].

Derin öğrenme algoritmaları, modelleri çok sayıda katmandan oluşturulmuş sinir ağlarının kullanımıyla, özellik çıkarma sürecini otomatikleştirme yeteneğine sahiptirler [15]. Derin öğrenme algoritmaları arasında, CNN adı verilen belirli bir derin sinir ağı vardır; bunlar, görüntüler arasında desenler bulma ve özellikleri tanıma yetenekleri nedeniyle bilgisayar görüşünde oldukça doğru sonuçlar üretirler [16].




Fig. 2: ( a ) Gözler açık. ( b ) Gözler kapalı [4].

Bilgisayar görüşü, makinelerin görsel verileri analiz ederek anlamlandırmasını sağlayan bir teknolojidir. Özellikle Evrişimli Sinir Ağları gibi derin öğrenme mimarileri, görseldeki karmaşıklığı modelleyebilmektedir. Bu modeller, görsellerdeki karmaşık desenleri tanıyabilme ve analiz edebilme yeteneğine sahip olup, yüz tanıma, nesne tanıma gibi alanlarda yüksek doğruluk oranları sağlamaktadır [17]. Diğer yöntemlerle karşılaştırıldığında, CNN daha az ön işleme gerektirmektedir. Bu nedenle, bir CNN resim özneteliklerini kavramak için en etkili öğrenme algoritmasıdır [18]. Microsoft, Google, ATT, NEC ve Facebook, CNN mimarisinin geliştirilmesi ve iletilmesiyle ilgilenen şirketler arasındadır [19]. CNN, düzenli sinir ağlarını yeniden bir araya getirir, öğrenilebilir nöronlardan oluşmaktadır. CNN birçok değişikliğe uğrayan ileri beslemeli bir mimaridir. Evrişimin birincil amacı, ilişkili veri kaynaklarından anlamlı özellikler çıkarmaktır [20]. Evrişimsel mimarinin çıktısı daha sonra aktivasyon fonksiyonuna gönderilir. Her gönderilen çıktı için farklı aktivasyon fonksiyonları üretir ve bu da öğrenmeyi kolaylaştırmaktadır [21].

*Transfer öğrenmesi*, CNN'lerle ilgili önemli bir kavramdır. Bu kavram, benzer alanda farklı bir problemi çözmek için daha önce eğitilmiş modelden, yeni modeller oluşturur [22]. Önceden eğitilmiş model tarafından edinilen bilgi, yeni model için bir başlangıç noktası görevi görür [23]. Bu teknik, özellikle az miktarda veriyle doğru modeller üretmek için yararlıdır [24]. CNN'ler genellikle sınıflandırma ve basit görevler için kullanılırken, R-CNN'ler daha karmaşık görevler için kullanılmaktadır [25]. R-CNN mimarileri küçük nesneleri tespit etmek için tek aşamalı yöntemlerden daha iyi performans göstermektedir [26].

*Faster R-CNN*, R-CNN yönteminin geliştirilmiş bir versiyonudur. Faster R-CNN, zorlukları aşmak için Region Proposal Network (RPN) kullanır. RPN, bölge öneri aşamasını tamamen derin öğrenme tabanlı bir ağ ile sağlamaktadır. Bu, önerilen bölgeleri doğrudan öğrenmeyi hızlandırır [27]. Faster R-CNN algoritması hedef tespiti ve tanıma alanında mükemmel sonuçlar elde etmekte ve derin öğrenmenin performansını büyük ölçüde iyileştirmektedir [28]. Ayrıca GPU işlemi kullanabildiği için hızlı hesaplama yapabilmektedir [29]. Kapalı durumdaki ağız, hem gündüz hem de gece rutinlerini ve uykulu durumları temsil eden bazı örnek görüntülerle birlikte Şekil 2'de gösterilmektedir.

TABLE III: Literature Taraması Sonuçları

| Makale Yazarlar (Yıl)                   | Veri Seti                               | Örnek Sayıları                            | Yöntemler                                                    | Sonuçlar       | Eksiklikler                                                                                        | Gelecek Katkıları                                                                                                                 |
|-----------------------------------------|-----------------------------------------|-------------------------------------------|--------------------------------------------------------------|----------------|----------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|
| Leiyu Chen ve ekibi (2021) [19]         | Belirtilmemiş                           | Belirtilmemiş                             | CNN                                                          | Doğruluk:%97   | Veri seti büyüklüğü belirtilmemiştir. Diğer algoritmalarla karşılaştırma yapılmamıştır             | Farklı veri setleriyle test edilmesi önerilmiştir. Derin öğrenme algoritmalarının daha fazla araştırılması gerekiyor.             |
| Jia Hou ve ekibi (2023) [20]            | CIFAR-10, LSVH verileri                 | CIFAR-10 60.000 örnek, LSVH belirtilmemiş | POSS-CNN                                                     | Doğruluk:%86.4 | LSVH'de diğer modellerle karşılaştırma sınırlıdır.                                                 | Modelin hız ve verimliliği artırılmalıdır.                                                                                        |
| Guoming Li ve ekibi (2021) [21]         | Belirtilmemiş                           | Belirtilmemiş                             | CNN                                                          | Doğruluk:%99   | Veri seti büyüklüğü belirtilmemiştir. Diğer yöntemlerle karşılaştırma yapılmamıştır.               | Farklı veri setleri üzerinde test edilmesi gerekmektedir. Çalışmaların çiftlik yönetimine katkısı artırılmalıdır.                 |
| Fiaz Majed ve ekibi (2022) [22]         | CIFAR-10, LSVH                          | 7200 Örnek                                | CNN                                                          | Doğruluk:%98   | Büyük veri seti ihtiyacı vardır.                                                                   | Veri artırma yöntemleri kullanılmalıdır.                                                                                          |
| Saieshan Reddy ve ekibi (2024) [23]     | Vehicle Detection Dataset               | 1492 Örnek                                | Faster R-CNN, YOLO v3, SSD                                   | Doğruluk:%99   | Veri seti büyüklüğü açıklanmamış. Algoritmalarla karşılaştırma eksik.                              | Farklı veri setleriyle test edilmesi önerilmiş. Hız ve doğruluk optimizasyonu yapılmalıdır.                                       |
| Dulari Bhatt ve ekibi (2021) [24]       | ImageNet, CIFAR-10, MNIST verileri      | 7 Görüntü                                 | CNN, LeNet, AlexNet, ResNet                                  | Doğruluk:%96.4 | Büyük veri ve yüksek hesaplama gücü gerektirir. Derin ağlarda kaybolan gradyan sorunu yaşanabilir. | Toplu öğrenme ile performans artırılabilir. Küçük veri setleri ile eğitime odaklanılmalı. Donanım hızlandırıcılar geliştirilmeli. |
| Ming Zhou ve ekibi (2022) [25]          | Infrared images of insulators verileri  | 2304 Görüntü                              | Mask RCNN, ResNet101, Attention Mechanism, Genetic Algorithm | Doğruluk:%98   | Diğer yöntemlerle karşılaştırma yapılmamıştır.                                                     | Farklı veri setlerinde test edilmesi gerekmektedir.                                                                               |
| Justin Butler, Henry Leung, (2024) [26] | Vehicle-Detection, Aerial-Cars verileri | 14372 Görüntü                             | CR-CNN, Mask R-CNN, IoU inflation method                     | Doğruluk:%98   | Algoritmalarla karşılaştırma sınırlıdır.                                                           | Modelin hız ve verimliliği artırılmalıdır                                                                                         |
| Danilo Avola ve ekibi (2021) [27]       | UMCD, UAVDT, UAV20L, UAV123 verileri    | 1670 Görüntü                              | MS-Faster R-CNN, Deep SORT                                   | Doğruluk:%97   | Genel model değerlendirmesi eksiktir.                                                              | Daha geniş ve farklı veri setlerinde test edilmesi önerilmektedir.                                                                |
| Tong Bai ve ekibi (2020) [28]           | UMCD, UAVDT, UAV123, UAV20L verileri    | 2800 Görüntü                              | Faster R-CNN, DRNet, RoI Align                               | Doğruluk:%82.1 | Düşük çözünürlüklü görüntülerde daha düşük performans gösterdiği belirtilmektedir.                 | Hız ve doğruluk açısından iyileştirmeler yapılmalıdır.                                                                            |

**Değerlendirme metrikleri:** Bir modelin performans haritasını çizen kılavuzlardır. Metrikler modelin güçlü ve zayıf yönlerini titizlikle incelemektedir. Sadece "başarı" veya "başarısızlık" olarak sınırlanmaz; her adımda modelin nerede öne çıktığını ve nerede aksadığını ortaya çıkarmaktadır. Duyarlılık, Özgüllük, Doğruluk ve F-Ölçütü gibi koşullar, modelin performansını detaylıca analiz etmektedir. Karmaşıklık matrisi, sınıflandırma modelinin performansını değerlendirmekte ve doğru-yanlış sınıflandırma sayısını gösteren bir tablodur. Karmaşıklık matrisi genellikle dört bölüme ayrılmaktadır;

- **TP (True Positive):** Model, gerçekten yorgun olan bir sürücüyü doğru bir şekilde "yorgun" olarak işaretlediğinde.
- **FP (False Positive):** Model, uyandırılmaya gerek olmayan bir sürücüyü yanlış bir şekilde "tehlikeli" olarak etiketlediğinde.
- **TN (True Negative):** Model, uyandırılmaya gerek olmayan bir sürücüyü doğru bir şekilde normal olarak değerlendirdiğinde.
- **FN (False Negative):** Model, tehlikeli bir durumu gözden kaçırarak bir sürücüyü yanlış bir şekilde normal olarak değerlendirdiğinde.

**Doğruluk (Accuracy):** Modelin genel başarısını gösteren bir kriter olup, doğru sınıflandırılmış örneklerin toplam örneklere oranı olarak hesaplanmaktadır. Yani, doğru pozitif (TP) ve doğru negatif (TN) sonuçlarının toplamı, tüm sınıflandırmaların (doğru ve yanlış) toplamına bölünerek elde edilmektedir:

*Doğruluk :*

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

**Hata Oranı:** Modelin yanlış sınıflandırma oranını göstermektedir.

$$Error Rate = 1 - Accuracy = \frac{FP + FN}{TP + TN + FP + FN} \quad (8)$$

**Duyarlılık (Sensitivity):** Modelin gerçek pozitif örnekleri doğru bir şekilde tanıma oranını ölçen bir değerlendirme kriteridir. Duyarlılık, özellikle sınıflandırma problemlerinde, modeli olumlu sınıfını doğru tahmin etme başarısını yansıtmaktadır.

*Duyarlılık:*

$$Sensitivity = \frac{TP}{TP + FN} \quad (9)$$

**Hata Oranı:** Modelin yanlış pozitif veya yanlış negatif sınıflandırmalarını anlamamıza yardımcı olan bir ölçüdür.

$$False Negative Rate = 1 - Sensitivity = \frac{FN}{TP + FN} \quad (10)$$

**Özgüllük (Specificity):** Modelin negatif sınıflarını doğru şekilde tanıyıp tanımadığını ölçen bir değerlendirme kriteridir. Özgüllük, modelin gerçek negatifleri doğru bir şekilde tespit etme oranını göstermektedir. Bu kriter genellikle yanlış pozitiflerin tespitiyle ilişkilendirilmekte ve genellikle "doğru negatif oranı" olarak da adlandırılmaktadır.

*Özgüllük:*

$$Specificity = \frac{TN}{TN + FP} \quad (11)$$

**Hata Oranı:** Hata oranı, yanlış pozitif ve yanlış negatif sınıflandırmalarının toplamını ölçerken, özgüllük, sadece yanlış pozitifleri ele almaktadır.

$$False Positive Rate = 1 - Specificity = \frac{FP}{TN + FP} \quad (12)$$

**F-ölçütü (F-Measure):** Modelin kesinlik ve duyarlılık değerlerinin entegrasyonunun bir ölçüsüdür ve genellikle sınıflandırma problemlerinde dengenin önemli olduğu durumlarda kullanılmaktadır.

*F-Ölçütü:*

$$F-Measure = 2 \cdot \frac{Precision \cdot Sensitivity}{Precision + Sensitivity} \quad (13)$$

**Hata Oranı:** Modelin hatalarını ve başarılarını dengeli bir şekilde anlamamıza yardımcı olmaktadır. Hata oranı, yanlış sınıflandırmaların tüm oranını ölçerken, F-ölçütü doğru pozitiflerin oranına odaklanarak modelin başarısını daha kapsamlı şekilde değerlendirmektedir.

$$F-Error Rate = 1 - F-Measure \quad (14)$$

**AUC - ROC (Area Under the Curve - Receiver Operating Characteristic):** Sınıflandırma modelinin performansını değerlendirmek için kullanılan önemli bir metriktir olup AUC, ROC eğrisinin altındaki alanı ifade ederek modelin doğru sınıflandırma kapasitesini özetlemektedir.

**ROC Eğrisi:** Modelin doğru pozitif oranı ve yanlış pozitif oranı arasındaki ilişkiyi görselleştirmektedir.

**TPR,** duyarlılık olarak da bilinmektedir.

$$TPR = \frac{TP}{TP + FN}$$

**FPR,** yanlış pozitiflerin oranıdır.

$$FPR = \frac{FP}{FP + TN}$$

**AUC:** ROC eğrisinin altındaki alanı temsil etmektedir. Modelin sınıflandırma doğruluğunu ölçü olarak göstermektedir. AUC değeri 0 ile 1 arasında değişmektedir.

AUC = 1: Model mükemmel sınıflandırma yapmaktadır.

AUC = 0.5: Model tamamen rastgele tahminler yapmaktadır.

AUC < 0.5: Model, tamamen tersine çalışıyor ve tahminlerinin çoğu yanlışır.

#### IV. DENEYSEL SONUÇLAR

Bu aşamada, sürücülerin dikkat seviyelerini belirlemek amacıyla geliştirilen yapay zeka tabanlı sınıflandırma yöntemlerinin performansları değerlendirilmektedir. Ele alınan problem, göz hareketlerinin analizi yoluyla sürücü yorgunluğunu tespit etmeyi hedeflemektedir. Geliştirilen modelin amacı, özellikle trafik kazalarını önlemek ve sürücülerin güvenliğini artırmaktır. Bu bağlamda, yorgunluk tespiti için kullanılan MRL Eye Dataset ve Yawn Dataset veri kümeleri çalışmamızın temelini oluşturmaktadır. Veri setlerimizdeki örnekler, gözlerin açık ya da kapalı durumu ve esneme gibi fiziksel belirtiler üzerine odaklanmaktadır.

Veri setlerimize, öncelikle eksik ve hatalı verilerin temizlenmesi, görüntülerin gri tonlamaya dönüştürülmesi ve tüm örneklerin sabit boyutlara ölçeklendirilmesi gibi bir dizi veri ön işleme yöntemi uygulanmaktadır. Ayrıca, veri boyutlarını optimize etmek ve modellerin hızlı öğrenmesini sağlamak amacıyla Min-Max Normalizasyonu yöntemi tercih edilmektedir. Daha sonra, CNN ile özellik çıkarımı gerçekleştirilmektedir. Özellik çıkarımı sonrasında, en etkili özelliklerin belirlenmesi için PCA ve diğer seçme algoritmalarından faydalanılmaktadır.

Bu çalışmada, derin öğrenme tekniklerinden CNN ve özgün olarak sentetik veri, çevrimdışı veri kullanarak bir sınıflandırma algoritması elde edilmektedir. Deneysel bölümde, bu algoritmaların doğruluk, hatırlama, F1 skoru gibi performans metrikleri ile değerlendirilen sonuçları detaylı bir şekilde analiz edilmektedir.

TABLE IV: Sınıflandırma Yöntemlerinin Performans Sonuçları - MRL Eye Veri Seti

| Model              | Veri İşleme | Doğruluk (%) | Duyarlılık (%) | Özgüllük (%) | Kesinlik (%) | F1 Skoru (%) | AUC (%) |
|--------------------|-------------|--------------|----------------|--------------|--------------|--------------|---------|
| Lojistik Regresyon | PCA Kapalı  | 95.99        | 93.35          | 98.19        | 97.72        | 95.49        | 98.81   |
|                    | PCA Açık    | 95.87        | 93.16          | 98.13        | 97.65        | 95.35        | 98.77   |
|                    | LDA Açık    | 95.87        | 93.16          | 98.13        | 97.65        | 95.35        | 98.77   |
| SVM                | PCA Kapalı  | 98.28        | 96.92          | 99.41        | 99.27        | 98.08        | 99.81   |
|                    | PCA Açık    | 98.28        | 96.92          | 99.41        | 99.27        | 98.08        | 99.81   |
|                    | LDA Açık    | 98.28        | 96.92          | 99.41        | 99.27        | 98.08        | 99.81   |
| Rastgele Orman     | PCA Kapalı  | 99.27        | 98.81          | 99.65        | 99.57        | 99.19        | 99.97   |
|                    | PCA Açık    | 99.11        | 98.44          | 99.67        | 99.60        | 99.02        | 99.96   |
|                    | LDA Açık    | 99.12        | 98.44          | 99.68        | 99.61        | 99.02        | 99.96   |
| Naive Bayes        | PCA Kapalı  | 82.76        | 70.42          | 93.02        | 89.37        | 78.77        | 89.00   |
|                    | PCA Açık    | 76.84        | 67.33          | 84.75        | 78.59        | 72.53        | 86.02   |
|                    | LDA Açık    | 76.84        | 67.33          | 84.75        | 78.59        | 72.53        | 86.02   |
| KNN                | PCA Kapalı  | 99.62        | 99.27          | 99.91        | 99.89        | 99.58        | 99.83   |
|                    | PCA Açık    | 99.63        | 99.32          | 99.89        | 99.86        | 99.59        | 99.80   |
|                    | LDA Açık    | 99.63        | 99.32          | 99.89        | 99.86        | 99.59        | 99.80   |
| CNN                | PCA Kapalı  | 98.54        | 97.87          | 99.10        | 98.91        | 98.38        | 99.85   |
|                    | PCA Açık    | 99.01        | 98.45          | 99.46        | 99.35        | 98.89        | 99.95   |
|                    | LDA Açık    | 99.10        | 98.48          | 99.61        | 99.53        | 99.00        | 99.95   |
| YSA                | PCA Kapalı  | 95.90        | 93.21          | 98.13        | 97.68        | 95.38        | 99.13   |
|                    | PCA Açık    | 96.05        | 95.47          | 96.54        | 95.91        | 95.65        | 99.19   |
|                    | LDA Açık    | 96.80        | 95.62          | 97.78        | 97.29        | 96.45        | 99.32   |
| RNN                | PCA Kapalı  | 98.27        | 97.99          | 98.50        | 98.19        | 98.08        | 99.82   |
|                    | PCA Açık    | 98.89        | 98.62          | 99.12        | 98.95        | 98.78        | 99.94   |
|                    | LDA Açık    | 98.63        | 98.14          | 99.04        | 98.84        | 98.49        | 99.90   |
| LSTM               | PCA Kapalı  | 95.66        | 92.71          | 98.12        | 97.73        | 94.96        | 99.50   |
|                    | PCA Açık    | 97.07        | 97.67          | 96.57        | 96.06        | 96.84        | 99.62   |
|                    | LDA Açık    | 98.07        | 97.78          | 98.32        | 97.98        | 97.87        | 99.79   |
| GRU                | PCA Kapalı  | 97.33        | 96.85          | 97.73        | 97.32        | 97.06        | 99.70   |
|                    | PCA Açık    | 98.63        | 98.07          | 99.10        | 98.91        | 98.48        | 99.91   |
|                    | LDA Açık    | 98.42        | 98.73          | 98.17        | 97.87        | 98.28        | 99.90   |
| <b>Özgün Model</b> | PCA Kapalı  | 88.00        | 78.00          | 99.00        | 99.00        | 87.00        | 99.00   |
|                    | PCA Açık    | 90.00        | 91.00          | 99.00        | 99.00        | 94.00        | 98.00   |
|                    | LDA Açık    | 92.00        | 97.00          | 99.00        | 98.00        | 96.00        | 92.00   |

*PCA'nın kullanılması*, modelin daha anlamlı özelliklere odaklanmasını sağlayarak verilerdeki gürültü ve fazla boyutluluk problemini azaltmaktadır. Bu, modelin genelleme yeteneği artırabilir ve eğitim süresini kısaltarak daha hızlı ve daha iyi performans göstermesini sağlayabilmektedir.

Özellikle yüksek boyutlu veri setlerinde, PCA kullanımı doğruluk, duyarlılık, özgüllük gibi performans ölçütlerinde iyileşmelere yol açabilmektedir. Bu nedenle, PCA'nın projenin genel model performansını olumlu yönde etkileyebileceği söylenebilmektedir.

*LDA kullanılmadığında model*, yüksek boyutlu ve gereksiz bilgileri içeren verilerle çalışır, bu da genelleştirme yeteneğini sınırlayabilmekte ve overfitting riskini artırabilmektedir. Özelliklerin fazla olması, modelin daha karmaşık hale gelmip performansın azalmasına neden olabilmektedir.

LDA kullanıldığında veri setindeki fazla boyutlu özellikler, en anlamlı ve ayırtıcı olanlara uyarlanır. Bu, modelin genelleştirme yeteneğini artırarak test verileri üzerinde daha iyi performans göstermesini kolaylaştırır. Sonuç olarak, LDA kullanımı doğruluk, duyarlılık, özgüllük ve F1-skoru gibi performans ölçütlerinde iyileşmelere yol açabilmektedir.

LDA (Linear Discriminant Analysis) kullanımının eğitim süresi üzerindeki etkileri genellikle sınıflandırma problemlerine yönelik olur. Ancak CNN ve LDA'yı birlikte kullanmak yerine sadece CNN kullanmak, eğitim süresinin ve modelin doğruluğunun daha verimli olmasını sağlar.

CNN, LDA gibi geleneksel yöntemlere göre daha hızlı ve etkili bir şekilde sınıflandırma yapabilir. LDA, verilerin sınıf ayrımını optimize etmeye çalışırken, CNN kendiliğinden bu ayrımları öğrenebilir. Bu nedenle, LDA kullanımı genellikle CNN'den daha yavaş olabilir.




Fig. 10: Açık ve Kapalı Göz - Test Sonucu

**Hiperparametreler**, derin öğrenme modellerinin eğitimi sırasında performansı önemli ölçüde etkileyen parametrelerdir. Bu parametrelerin doğru şekilde ayarlanması, modelin genelleme yeteneği, eğitim süresi ve sonuçlarının doğruluğu üzerinde doğrudan etkiye sahiptir.




Fig. 11: Batch Size'in Doğruluk Üzerindeki Etkisi

**Batch size**, bir modelin eğitim verilerini küçük gruplar halinde kullanarak model parametrelerini güncelleme sıklığını ifade etmektedir. Eğitim sırasında, model verileri görmeden belirli bir grup veri kullanılarak parametre güncellenir. Projede, batch size 64 olarak seçilmiştir. Küçük bir batch size kullanıldığında, model daha sık parametre güncellemeleri yapar ve bu, eğitim sürecinin daha hızlı ilerlemesini sağlamaktadır. Daha sık güncellenen model, fazla geri bildirim alır ve genelleştirilebilir performans

sağlayabilmektedir. Ancak, küçük batch size kullanıldığında, eğitim süresi artabilir ve modelin daha fazla gürültülü davranma riski bulunmaktadır.

Büyük batch size kullanıldığında hesaplama maliyetleri artmaktadır. Büyük batch size kararlı bir optimizasyon sağlamaktadır. Kullanıldığında model, yerel minimumlara takılma riskiyle karşı karşıya kalabilmektedir. Çalışmada batch size 64 tercih etmemizin nedeni, hesaplama maliyetlerini dengelemek ve modelin daha hızlı eğitilmesini sağlamaktır. Küçük veri kümelerinde daha fazla çeşitlilik ve genelleştirme yeteneği sunarken, daha düşük hesaplama maliyetleri ile daha kararlı performans elde edilebilmektedir. Bu nedenle, batch size 64 projemizde optimal bir tercih olmaktadır.




Fig. 12: Epoch Sayısının Doğruluk Üzerindeki Etkisi

**Epoch sayısı**, eğitim veri kümesinin tamamının model üzerinde bir kez işlenmesini ifade eder. Yeterli sayıda epoch, modelin verileri öğrenmesini sağlar. Ancak fazla epoch sayısı aşırı öğrenmeye (overfitting) yol açabilir. Bu çalışmada 15 epoch seçilmiştir, çünkü bu, modelin verileri yeterince öğrenmesine olanak tanırken aşırı öğrenmeden kaçınmayı sağlayan bir değerdir.




Fig. 13: Öğrenme Oranının Doğruluk Üzerindeki Etkisi

**Learning rate (öğrenme oranı)**, modelin her adımda öğrenme hızını belirler. Düşük öğrenme oranları daha yavaş ama kararlı öğrenmeye neden olurken, yüksek öğrenme oranları ise daha hızlı ancak dengesiz öğrenmeye yol açabilir. Bu çalışmada, öğrenme oranı olarak 0.001 seçilmiştir. Bu değer, modelin etkili bir şekilde eğitilmesini sağlar ve aşırı hızlı ya da çok yavaş güncelleme yapmasını engeller.




Fig. 17: PCA'nın Metrik Değerlerine Etki Grafiği

Adam, öğrenme oranını her parametre için ayrı ayrı uyarlayarak, ağırlık güncellemelerinin daha verimli olmasını sağlar. Bu algoritma, hem moment (ilk moment) hem de hızlanmış moment (ikinci moment) tahminleri kullanarak, modelin daha hızlı ve doğru bir şekilde eğitilmesine olanak tanır. Modelde Adam kullanmak, genellikle daha iyi performans ve hızlı yakınsama sağladığı için mantıklı bir tercih olmaktadır. Özellikle büyük veri setlerinde ve karmaşık modellerde Adam, öğrenme oranı ayarlamalarını otomatikleştirerek eğitim sürecini iyileştirmektedir.

## V. TARTIŞMA

Bu çalışmada, sürücülerin göz hareketleri ve esneme sıklıklarını analiz ederek yorgunluk durumlarını tespit eden bir sistem geliştirilmektedir. Derin öğrenme tabanlı CNN mimarisi kullanılarak oluşturulan model, özellikle MRL Eye ve Yawn veri setlerinde yüksek doğruluk oranlarına ulaşmaktadır.

Makalede, makine öğrenimi (ML) ve derin öğrenme (DL) algoritmalarını karşılaştırmalı bir yaklaşımla ele alınmaktadır. Derin öğrenme tekniklerinden CNN algoritması, görsel tabanlı sınıflandırma görevlerinde yüksek performans göstermektedir. Literatürdeki çalışmalar CNN modellerinin yüzde 96 ile yüzde 99 arasında doğruluk oranlarına ulaştığını ortaya koymaktadır. Bu, CNN'in otomatik özellik değerlendirmeyi yapabilmesini ve karmaşık verilerdeki desenleri tanıma yeteneğinden kaynaklanmaktadır. Makine öğrenim yöntemleri daha düşük işlem gücü gerektirmekte ve küçük veri kümelerinde etkili olmaktadır. Ancak, ML algoritmaları genellikle öz niteliklerin el ile seçilmesine dayanır ve derin öğrenme kadar yüksek doğruluk sağlayamayabilmektedir. Makalede sunulan özgün model, mevcut literatürdeki eksiklikleri gidererek, göz kırpması ve esneme gibi sürücü davranışlarını birleştirerek sürücü dikkatini daha doğru bir şekilde değerlendirmeyi hedeflemektedir.

Modelde, kullanılan veri setleri literatürdeki diğer yöntemlere göre daha güvenilir sonuçlar sunmaktadır. Bu durum, hem DL hem de ML algoritmalarının avantajlarını birleştirerek kapsamlı bir yaklaşım sunulduğunu göstermektedir.

Model, güçlü yönler açısından özgün modelin sentetik ve çevrimdışı verilerin dengeli kullanımı ve gerçek dünya koşullarını modelleyen geniş bir veri seti üzerinde eğitilmektedir. Bu, veri çeşitliliğini artırarak genel performansı iyileştirmektedir. CNN tabanlı yapısı, görsel analizde yüksek doğruluk sağlayarak, literatürde belirtilen düşük ışık koşulları veya veri dengesizliği gibi problemlerin üstesinden gelmektedir. Mevcut DL ve ML yöntemlerinin bazıları, daha hızlı sonuçlar üretebilirken, gerçek zamanlı testlerde yeterince etkili olamayabiliyor. Model, hem esneme hem de göz hareketlerini uyarlayarak, daha kapsamlı bir çözüm sunmakta ve çevresel değişkenlere karşı dayanıklılık sergilemektedir.

Çalışmada kullanılan veri kümeleri, algoritmaların doğruluğunu ve genel performansını doğrudan etkileyen önemli bir unsurdur. Veri setlerinin öznitelik çeşitliliği ve örnek sayısı, modelin genel yetkinliğini artırırken, dengeli dağılıma sahip olmaları, sınıflandırma doğruluğunu olumlu yönde etkilemektedir. MRL Eye Dataset'teki açık ve kapalı göz durumlarının eşit şekilde dağıtılması, algoritmaların yanlışlık riskini azaltarak tutarlı sonuçlar üretmesini sağlamaktadır. Veri setlerinin kalite ve çeşitliliği, modelin genelleme kapasitesini artırarak farklı çevresel koşullarda yüksek doğrulukla çalışmasını sağlamaktadır.

Veri kümesine uygulanan ön işleme adımları ve öznitelik seçimi yöntemleri performansı artırmada önemli bir rol oynamaktadır. Veri temizleme, normalizasyon ve uygun öznitelik seçimi, gereksiz hesaplamaları azaltmaktadır. Bu süreç, derin öğrenme algoritmalarının daha hızlı eğitilmesine ve daha yüksek performans göstermesine olanak tanımaktadır. Veri kümesi seçimi ve ön işleme adımları, çalışmada model başarısını belirleyen önemli unsurlardan biridir. Makale kapsamındaki analizlere göre, kullanılan derin öğrenme algoritmaları, özellikle CNN, görüntü tabanlı verilerin işlenmesinde yüksek doğruluk oranlarıyla öne çıkmaktadır. CNN'nin, düşük ön işleme gereksinimi ve görsel özellikleri otomatik olarak çıkarma yeteneği, özellikle göz kırpması ve esneme tespiti gibi hareketlerin analizinde zaman tasarrufu sağlamaktadır.

Makine Öğrenimi algoritmaları, düşük veri senaryolarında daha az kaynak tüketse de, doğruluk açısından genellikle geride kalmaktadır. Özellikle, CNN'in MRL Eye ve Yawn veri setleri üzerinde sağladığı yüzde 95 üzeri doğruluk oranı, derin öğrenmenin bu tür sistemler için daha etkili bir çözüm sunduğunu göstermektedir. Ancak, DL algoritmalarının yüksek hesaplama maliyetleri ve geniş veri seti ihtiyaçları, zaman ve kaynak açısından iyileştirilmesi gerektiğini vurgulamaktadır.

Modelin performans değerlendirilmesinde kullanılan metriklerin seçiminde, ilgili çalışmanın hedefleri ve kullanılan veri türü önemli bir rol oynamaktadır. Çalışmada, hassasiyet, doğruluk ve geri çağırma gibi metrikler tercih edilmektedir. Bu metriklerin seçim nedeni, sürücü uykusu halinin tespitinde yanlış negatif ve yanlış pozitif sonuçların minimuma indirilmesidir.