

Raylı Sistemlerde Yolcu Yoğunluğunun Tespiti ve Yolcuların Yönlendirilmesi

Mehmet Cabir AKKOYUNLU¹  Volkan AZAT^{2*} 

¹ Karamanoğlu Mehmetbey Üniversitesi, Teknik Bilimler Meslek Yüksek Okulu, Makine ve Metal Teknolojileri Bölümü, Karaman, Türkiye

² Karamanoğlu Mehmetbey Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri, Karaman, Türkiye

Makale Bilgisi

ÖZET

Geliş Tarihi: 05.03.2025
Kabul Tarihi: 23.04.2025
Yayın Tarihi: 30.06.2025

Anahtar Kelimeler:

Derin öğrenme,
Raylı sistemlerde yolcu
yoğunluğunun tespiti,
İstasyonlarda yolcu
yönlendirme,
Raylı sistem işletmesi,
Havayollarında yolcu
yoğunluğunun tespiti.

Nüfusları milyonları hatta on milyonları aşan metropollerde yaşanan kalabalıklar birçok probleme sebep olmaktadır. Yaşanan problemlerinde başında trafik problemi gelmektedir. Trafik probleminin çözümü noktasında şüphesiz en önemli araç toplu taşımının etkin şekilde kullanılmasıdır. Güvenlik, konfor ve dakiklığı gibi sebepler nedeniyle raylı sistemler ve havayolları ile ulaşım toplu taşıma sistemleri içerisinde en çok tercih edilen sistemlerdir. Ancak, istasyonlarda ve alanlarda yaşanan kalabalıklar ve mimari açıdan her istasyonda yolcuların aynı noktadan giriş yapmaları neticesinde trenlerin belli noktalarında birikmelere yol açmaktadır. Bu sebepler hem yolculuk konforunun düşmesine hem de yolcuların bekleme süresinin uzamasına sebep olmaktadır. Yaşanan bu beklemler neticesinde özellikle raylı sistemlerde günlük sefer planlamaları, trenlerin sefer süreleri ve istasyonlara olan varış süreleri değişmektedir. Bu aksaklık ve değişimler yolcular kadar hafif raylı sistemlerin işletmesi açısından da sıkıntılar meydana getirmektedir. Günümüzün en popüler çalışma alanlarının başında gelen yapay zekâ başarılı uygulamaları ile her alanda adından söz ettirmektedir. Çalışmamızda da çözüm noktasında yapay zekâ'nın alt dalı olan derin öğrenme ve sayısal görüntü işleme teknikleri kullanılmaktadır. Bu teknikler ile örnek olarak hafif raylı sistemlerde vagon içerisindeki yolcuların sayılarına bağlı olarak yoğunluklarının tespit edilmesi ve gelecek istasyonlarda bekleyen yolcuların uygun vagon ve kapılara yönlendirilmesi ile hem yolcular hem de raylı sistemin işletmesi açısından daha verimli bir sistem elde edilmesi hedeflenmektedir. Havayolu taşımacılığında, özellikle yolcu ve kargo taşımacılığı sorunlarına yönelik olarak, bu yöntem uygulanabilir ve uyarlanabilir.

Determination of Passenger Density and Guidance of Passengers in Rail Systems

ArticleInfo

ABSTRACT

Received: 05.03.2025
Accepted: 23.04.2025
Published: 30.06.2025

Keywords:

Deep learning,
Detection of passenger,
Density in railway
systems,
Passenger routing.

In metropolises with populations reaching millions or even tens of millions, overcrowding leads to various problems. One of the most significant issues caused by this is traffic congestion. The most effective solution to traffic problems is undoubtedly the efficient use of public transportation. Due to factors such as safety, comfort, and punctuality, rail systems and air transportation are among the most preferred public transportation systems. However, overcrowding at stations and terminals, along with the architectural design that requires passengers to enter from the same points, leads to congestion in specific areas of trains. These issues not only reduce travel comfort but also increase passenger waiting times. As a result of these delays, especially in rail systems, daily schedules, train travel times, and station arrival times are affected. These disruptions create challenges not only for passengers but also for the operators of light rail systems. One of today's most popular fields of study, artificial intelligence, is making a name for itself with its successful applications in various domains. In our study, deep learning a subfield of artificial intelligence and digital image processing techniques are used to address this issue. These techniques aim to detect passenger density in light rail systems based on the number of passengers in each carriage. By directing waiting passengers at upcoming stations to appropriate carriages and doors, a more efficient system can be achieved, benefiting both passengers and rail system operators. This method can be applied and adapted in air transportation, particularly to address issues in passenger and cargo transportation.

Bu makaleye atıfta bulunmak için:

Akkoyunlu, M.C., & Azat, V. (2025). Raylı sistemlerde yolcu yoğunluğunun tespiti ve yolcuların yönlendirmesi. *Aerospace Research Letters (ASREL)*, 4(1), 19-35. <https://doi.org/10.56753/ASREL.2025.1.2>

* Sorumlu Yazar: Volkan Azat, volkanazat@hotmail.com



This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

GİRİŞ

Antik Yunandan itibaren tarihin her safhasında düşünebilen makinelerden bahsedildiği görülmektedir (Goodfellow, I., Bengio, Y., & Courville, A., 2018). Modern anlamda düşünebilen bir makineden söz edilen ilk çalışma Alan TURING tarafından 1950 yılında yayımlanmıştır (Nilson, N. J., 2018). Aradan geçen on yıllar içerisinde iniş çıkışlarla dolu bir tarihe sahip olan zekâ 2000’li yıllar ile yaşanan donanımsal gelişmeler ile günlük yaşamımızın her alanına girmeye başlamıştır. Yapay zekâ tarihinden bahsederken çok eski tarihlerden söz edilirken yapay zekâ’nın alt dalı olan derin öğrenme de bu tarih 1980’lerden başlamaktadır. 1990’lı yıllarda duraklama yaşasa da günümüzde yaşana donanımsal gelişmeler neticesinde yapay çok popüler bir hâl almıştır (Kızrak, M. A., & Bolat, B., 2018), (Kıymaz, Y. E., & Oguz, H. (2024)), (Hacıbeyoğlu ve ark. (2023)). Yapay zekânın ham maddesini veri oluşturmaktadır. Birçok kaynakta veri için günümüzün yeni petrolü yakıştırması yapılmaktadır. Günümüzde üretilen dijital verinin boyutu o kadar büyüktür ki Statista adlı Alman şirketi yaptığı açıklamada 2010 yılında üretilen veri miktarı 2 zettabyte olmuştur. Bu veriler 2018 yılında 33 zettabyte’a yükselmiştir ve 2025 yılında 175 zettabyte’a çıkacağı tahmin edilmektedir. Bu kadar çok verinin üretildiği bir dünyada veriyi anlamlandırmanın ve çıkarımlar yapmanın ne kadar önemli olduğu aşîkârdır.

Özellikle endüstriyel alanda çalışan mühendisler sayısal görüntü işleme teknikleri ve yapay zekâ algoritmaları ile birçok sorunun çözüme kavuşturulmaktadır. Nesnelerin sayılması, arızalı ve eksik parçaların tespiti, insanların tespiti, şüpheli hareket tanımlama bunlardan bazılarıdır. Yapay sinir ağları kullanılarak yapılan en popüler nesne tanıma uygulamalarından biri de YOLO algoritmalarıdır. Kelime anlamı olarak You Only Look Once kelimelerinin baş harflerinden oluşmaktadır. Algoritma resimler üzerinde tek aşamalı bir evrişimli sinir ağı uyguladığı için oldukça hızlı çalışmaktadır (Wu ve ark., (2021)). Dijital resimler üzerinde temel görüntü işleme algoritmaları kullanılarak resimler konumlarından okunabilmekte, gürültüler tespit edilerek temizlenebilmekte, renk uzayları değiştirilebilmekte ya da nesne tespiti gibi uygulamalar için kenarları tespit edilebilmektedir. Görüntü işleme konusunda günümüzün en popüler uygulaması da OpenCV kütüphanesidir. OpenCV ile temel görüntü işlemleri yapılabildiği gibi gelişmiş uygulamalarda yapılabilir. Çalışmamızda YOLO algoritması ve OpenCV kütüphanesi etkin bir şekilde kullanılmaktadır.

Daha önce donanımsal alanda çok büyük gelişmeler yaşandığından bahsetmiştik. İşlemcilerin çekirdek sayıları artarken paralel işlem kapasiteleri artmaktadır. Yapay zekâ algoritmaları gibi yüksek işlem gücü gerektiren çalışmalarda da grafik işlem birimi adı verilen ve yüzlerce çekirdeğe sahip donanımlar kullanılmaktadır. Ancak mühendislik uygulamalarında en önemli unsurların başında maliyet ve uygulanabilirlik gelmektedir. Laboratuvarlarda çok güçlü bilgisayarlar ve donanımlar kullanılarak gerçekleştirilen çalışmaların saha uygulamaları imkânsız hale gelmektedir. Bu noktada yardımımıza tek kart bilgisayar adı verilen ve genellikle ARM A serisi işlemcilerle sahip bilgisayarlar yetişmektedir. Bu bilgisayarlar kredi kartı boyutlarında olmalarına rağmen I2C, SPI, UART gibi haberleşme pinlerine ve GPIO adı verilen giriş çıkış pinlerine sahiptirler. Linux işletim sistemleri yüklenebilen bu sistemler çok çekirdekli merkezi işlem birimlerine de sahiptir. Çalışmamızda derin öğrenme algoritmalarının verimli bir şekilde çalıştırılabilmesi açısından NVIDIA firması tarafından geliştirilmiş olan ve üzerinde merkezi işlem birimine ilaveten grafik işlem birimi ünitesi de olan Jetson Nano ürünü kullanılmıştır. Yolcuların tanınması noktasında eğitim seti olarak COCO eğitim seti kullanılmıştır.

Globalleşen dünyada insanlar kırsal kesimlerden şehirlere doğru göç etmeye başlamışlardır. Böylece metropol adı verilen nüfusları on milyonları geçen şehirler ortaya çıkmıştır. Böylesine kalabalık şehirlerde birçok sorunun yaşanması da kaçınılmazdır. Enerji verimliliğini artırmaya yönelik çeşitli çalışmalar mevcuttur. (Akkoyunlu ve ark., (2024)). Yine bu sorunların başında şüphesiz trafik problemi gelmektedir. İnsanlar trafikte her gün saatlerini harcamakta ve bu da yaşam standartlarını olumsuz yönde

etkilemektedir. Bu sorunun çözümü her büyük şehirde olduğu gibi toplu taşımanın etkin ve verimli bir şekilde kullanılması ile olacaktır (Karakuş G., 2023). Toplu taşıma sistemleri içerisinde hafif raylı sistemler kendilerine ait yolları olmaları, konforlu yolculuk imkânı sunmaları ve dakik olmaları gibi sebepleri ile yolcular tarafından tercih edilmektedir. İşletilmesi açısından bakıldığında yolcu başına işletme maliyetinin düşük olması, kurulum maliyetinin yüksek olmasına rağmen bakım maliyetlerinin düşük olması ve çevreci olması gibi sebepler ile devlet ve belediyeler tarafından tercih edilmektedir.

Ülkemizde raylı sistemler tarihi 1856 tarihi ile başlamıştır. 1950 yılından sonra 2000’li yıllara kadar yaşanan durgunluk döneminin ardından tekrar büyük yatırımlar almaya başlayan raylı sistemler günümüzde oldukça hızlı gelişen ve büyük yatırımlar yapılan alanlar haline gelmiştir. Büyükşehirler yaşanan trafik sorunlarına kalıcı çözümler üretmek üzere yeni metro ve tramvay hatların yapımına önem vermektedir. Ülkemizde yerli olarak vagon, tramvay ve tren üreten devlet ve özel teşebbüsler bulunmaktadır.

İstasyonlara gelen yolcular mimari sebepler nedeni ile her istasyonda aynı noktalardan istasyona giriş yapmaktadır. Genel yolcu davranışları incelendiğinde ara bölgelere ilerleme yerine o bölgelerde bekleme yapıldığı gözlenmektedir. Böylece trenlerin belli noktalarından daha yoğun binişler sağlanmaktadır. Bazı yolcular hareket halindeki tren içerisinde daha az yoğun noktalara ilerlemek isterken bazı yolcular biniş noktalarında beklemeye devam etmektedir. Bu davranışlar hem vagonlar içerisinde gezen yolcular için hem de sabit bekleyen yolcular için konforsuz bir yolculuğa sebep olmaktadır. Kalabalık bölgelerde bekleyen yolcular iniş biniş esnasında rahatsız bir ortamda kalmakla beraber trenlerin istasyonlardaki bekleme sürelerinin uzamalarına sebep olmaktadır. Bu aksaklık raylı sistem işletmesinin günlük planlarının aksamasına, trenlerin daha sonraki istasyonlara geç gelmelerine ve kalabalıkların daha da artmasına sebep olmaktadır.

Daha verimli bir raylı sistem işletme yönetimi ve tercih edilen, konforlu, dakik bir yolculuk sağlamak amacıyla Raylı Sistemlerde Yolcu Yoğunluğunun Tespiti ve Yolcuların Yönlendirmesi adlı çalışmamız ile vagonlardaki yolcuların tespiti yapılarak gelecek istasyonlarda bekleyen yolcuların uygun diğer kapılara yönlendirilmesi önerilmektedir. Sistemin yoğun olduğu saatlerde yaşanmakta olan problemler yolcuların doğru yönlendirilerek olumsuzlukların önüne geçilmesi ve işletme adına planlamada kullanılacak önemli verilerin elde edilmesi hedeflenmektedir.

Konu ile ilgili yapılan akademik çalışmalar incelendiğinde önemli bir kısmı insan ve kalabalıkların alışveriş merkezlerindeki dükkân ziyaretleri, hava alanları gibi önemli alanlarda şüpheli hareket davranışlarını analizi gibi konulara yoğunlaştığı görülmektedir. Toplu taşımaya yönelik yapılan çalışmalar ve geliştirilen ürünler incelendiğinde yoğunlukla otobüsler ile ilgili çalışma ve ürünler olduğu görülmektedir. Bu çalışmalarda kapı üstlerinde bulunan kameralardan alınan görüntüler ile yolcu sayma işlemi gerçekleştirilmektedir. Yolcuların içerideki dağılımları ya da yönlendirilmesi mümkün olamamaktadır. Özellikle hafif raylı sistemler gibi yolcuların içeride dağılımı değiştirebileceği durumlarda sadece işletmenin yolcu sayıları ile ilgili çalışmalarına veri sağlayacak sistemler ve çalışmalar bulunmaktadır.


YÖNTEM

Sayısal görüntü işleme giriş ve çıkışlarını sayısal görüntülerin oluşturduğu bir süreçtir. Bu süreçler üç ana başlık altında toplanmaktadır. Alçak seviyeli süreçlerde, resimler üzerindeki gürültünün azaltılması, zıtlık zenginleştirme, görüntü zenginleştirme gibi işlemler gerçekleştirilmektedir. Orta seviyeli işlemlerde, görüntünün bölütlenmesi, kenar bilgileri ve öznitelik verilerinin elde edilmesi gibi işlemler gerçekleştirilerek tanımlanması sağlanmaktadır. Yüksek seviyeli süreçler ise tanımlanan görüntüye anlam verme süreci ile ilgilenmektedir (Gonzalez, R. C., & Woods, R. E., 2002). Sayısal görüntü, pozitif tamsayı değerlerinden oluşmuş iki boyutlu matris yapısındadır. Sayısal görüntüyü temsil

eden matrisin her bir elemanlarına piksel adı verilmektedir. Piksel, görüntüyü oluşturan en küçük parçadır. Pikselin değeri ilgili görüntü elemanının parlaklık şiddetini belirtir (Kızılkaya, A., 2008). Siyah beyaz resimler tek bir matris ile gösterilirken renkli resimlerde piksellerin değerleri kırmızı, yeşil ve mavi bileşenleri ifade eden üç matris ile gösterilmektedir. Aşağıdaki iki resimde siyah beyaz ve renkli resimlere ait küçük birer parçanın piksel değerleri görülmektedir. The table number and text should be placed above the table in bold. A period should not be placed at the end of the table number. The title of the table should be italicized and capitalized and should be placed on a separate line below the table number. The table should have no vertical lines and as few horizontal lines as possible.


Şekil 1

Renkli Resimlere İçin Piksel Değerleri



Şekil 2

Siyah-Beyaz Resimlere İçin Piksel Değerleri



Görüntü işlemenin temelleri piksellerin renk değerlerine dayanmaktadır. Histogram eşitleme, Kenar bulma ve morfolojik işlemler gibi fonksiyonları kullanırken bu değerleri kullanmaktayız.

Görüntü işleme alanında OpenCV kütüphanesi oldukça popülerdir. Kütüphanenin içeriğinde görüntü işleme algoritmalarından oluşan 2500'den fazla algoritma bulunmaktadır. C++, Python ve Java programlama dilleri ile çalışlabilmektedir (Hakkında:OpenCV., 2022).

NVIDIA tarafından yapılan açıklamada OpenCV kütüphanesinin CUDA yazılımına uyarlandığını ve GPU üzerinde çalıştırıldığında 5 kat ile 100 kat arasında daha hızlı çalışabildiği bildirilmektedir (NVIDIA Developer., 2022).

Şekil 3

Yapay Zekâ ve Alt Dalları




Yapay zekânın bir araştırma konusu olarak ortaya çıkışması sürecinde üç toplantı önemli bir yer teşkil eder. Bunlar, 1955 yılında gerçekleştirilen “Öğrenen Makineler Oturumu”, 1956 yılında “Yapay Zekâ Yaz Araştırma Projesi” ve 1958 yılında gerçekleştirilen “Düşünce Süreçlerinin Mekanikleşmesi” toplantılarıdır (Nilson, N. J., 2018). Ortaya çıkışının ardından yapay zekâ tarihi inişli çıkışlı dönemler geçirmiştir. Yapay zekâ 1974 ile 1980 yılları arasında yapay zekâ kışı olarak bilinen döneme girmiş ve eleştirilere maruz kaldığı birçok rapor yayımlanmıştır. Bu dönemde yapay zekâ alanına destek ve ilgi azalmıştır. Bu dönem 1980’lerde İngiliz hükümetinin Japonlarla yarışmak için tekrar yatırımlara başlaması ile sona ermiştir (Öztürk, K., & Şahin, M. E., 2018). Donanımsal gelişmelere paralel olarak yaşanan gelişmeler sayesinde 1990’lı yıllarda yapay zekânın adı daha çok duyulmaya başladı. Bu yıllarda IBM’in geliştirdiği Deep Blue adlı bilgisayarın meşhur satranç şampiyonu Garry KASPAROV’u yenmesi ile yapay zekâ insanların dikkatini çekti. Sonraki süreçte yapay zekâ ürettiğimiz büyük veriler sayesinde daha fazlasını öğrenmeye ve gelişmeye devam etti.

Yapay Sinir ağları biyolojik sinir ağlarının çalışmasından esinlenerek tasarlanmaktadır. Bu ağlarda öğrenme işlemi ilk olarak belirlenen ağırlık işlemlerinin geri besleme ile güncellenmesi ile gerçekleştirilmektedir. Her nöron arasında birbirleri ile bağlantı kuracak bağlantılar bulunmaktadır. Ağda bulunan noktalar arasındaki etkileşim ağırlıklar ile belirlenmekte ve nörona giren çıkan verilere göre bunların eğitilmesi ile çıktıların katkı oranları hesaplanmaktadır (Şen, Z., 2004).

Şekil 4

Nöronun Matematiksel Modeli




Derin öğrenme makine öğrenmesinin bir alt dalıdır. Derin öğrenmenin tam olarak anlaşılabilmesi için makine öğrenmesinin tam olarak anlaşılması gerekmektedir (Goodfellow, I., Bengio, Y., & Courville, A., 2018). Derin öğrenmede birbirini takip eden derin katmanlar bulunmaktadır. Derin öğrenmenin ifade ettiği derin tanımlı bu katmanların oluşturduğu derinliktir. Bu derinlik çok sayıda katmandan oluşabilir. Bu katmanlar makine öğrenmesinde bir veya iki katmandan oluşmaktadır. Derin öğrenmede nörobijolojiden bahsedilse de insan beyninden esinlenilmiş değildir (Chollet, F., 2019).

Derin öğrenmenin en büyük çıkışı AlexNet evrimsel sinir ağı mimarisinin kazandığı büyük başarı sağlanmıştır (İnik, Ö., & Ülker, E., 2017). Aşağıdaki şekilde evrimsel sinir ağı yapısı görülmektedir.

Şekil 5

AlexNet Evrimsel Sinir Ağı Yapısı



İlk YOLO algoritması Joseph Redmon tarafından 2015 tarihinde yayınlanmıştır. YOLO algoritması gerçek zamanlı olarak nesnelerin tespiti için kullanılmaktadır. YOLO algoritması ileri yayılma yöntemi ile resimlerdeki nesneleri kutu şeklinde belirlemektedir. YOLO algoritmasında veri setinin test ve eğitim işlemlerinin yapıldığı aşamalarda tüm resme ait veriler kodlanmaktadır. Bu işlem sayesinde diğer tanımlama yöntemlerinden daha iyi performans elde edilmektedir (Nasrullah, M., & Diker, A., 2021). YOLO “You Only Look Once” sadece bir kez bak cümlesinin baş harflerinden oluşmaktadır. İlk dört sürümde CPU ve GPU üzerinde işlem yapılabilmesini sağlayan Darknet sinir ağları kullanılmaktaydı. Projemiz kapsamında YOLOv5 sürümü kullanılmıştır. Bu sürüm PyTorch frame work üzerinde çalışmaktadır. PyTorch, GPU ve CPU'ları kullanarak derin öğrenme için optimize edilmiş bir tensör işlem kitaplığıdır. NVIDIA tarafından geliştirilen ve model eğitimi gibi geleneksel olarak yavaş süreçleri hızlandırmaya izin veren GPU ile CPU'yu birbirine bağlayan bir API olan CUDA'yı dâhili olarak kullanır. YOLOv5 çok sayıda önceden eğitilmiş modele sahiptir. Bunların aralarındaki fark, modelin boyutu ile çıkarım süresi arasındaki dengedir. En hafif model olan YOLOv5s sürümü sadece 14MB iken en büyük modele olan YOLOv5x 168MB büyüklüğündedir.

Jetson Nano görüntü sınıflandırma, nesne algılama gibi uygulamaları çalıştırmanıza imkân tanıyan küçük, güçlü bir tek kart bilgisayardır (Nvidia web sayfası., 2022). Jetson Nano ile modern yapay zekâ uygulamalarını kolaylıkla çalıştırılabilmekteyiz.

Projemizde 2GB RAM belleğe sahip Jetson Nano bilgisayar modeli kullanılmıştır. Kartımızın üzerinde monitör bağlantısına imkân sağlayan HDMI konektörü bulunmaktadır. İnternet bağlantısı Ethernet üzerinden ya da harici bağlanabilen Wifi üzerinden sağlanabilmektedir.

Şekil 6

Jetson Nano Bilgisayar



Jetson Nano bir bilgisayar olmasına karşın üzerinde 40 adet GPIO pininin bulunmaktadır. Bu pinler Raspberry Pi ile uyumluluk göstermektedir. Jetson Nano bilgisayarımız 2 GB 64-bit LPDDR4 25.6 GB/s RAM, hafıza birimi 128 GB 100 MB/sn'ye kadar aktarım yapabilen class 10 hafıza kartı, CPU 1.43 GHz hızında ARM A57 Quad Core CPU ve en önemlisi 128 çekirdekli NVIDIA Maxwell GPU ünitelerine sahiptir. Bu GPU 472 GFLOP işlem gücüne sahiptir.

Şekil 7

NVIDIA Maxwell GPU Kart



Şehir içi hafif raylı sistemler klasik tramvayların modernleştirilmiş şeklidir. Hafif raylı sistemlerde araçlar trafikten ayrılmış kendine ait özel bir yolu kullanan elektrikli ulaşım sistemleridir. Hafif raylı sistemler bir makinist tarafından kullanılmaktadır ve duraklar arası mesafeleri yaklaşık 600 ila 1000 metre arasındadır. Şehir içi ulaşımında kullanılan bu araçların ulaşabilecekleri hız en yüksek 60-80 km/s'dir (Şenlik, İ., (2013).

Ülkemizde raylı sistemler İstanbul, Eskişehir, İzmir, Ankara, Bursa, Kocaeli, Samsun, Gaziantep, Konya, Antalya, Adana ve Kayseri illerinde kullanılmaktadır (Railway Turkey., 2021).

İstanbul'da bulunan raylı sistemler incelendiğinde, Ulaştırma Bakanlığının açıkladığı projelerde tamamladığında bakanlık bünyesindeki raylı sistem uzunluğu 183,3 km'ye ulaşacaktır (RailTurkey web sayfası., 2022). Metro İstanbul tarafından işletilen raylı sistem uzunluğu 262,15 km uzunluğundadır. 2029 yılı sonunda tüm sistemin planlanan uzunluğu 625,70 km olacaktır. İstanbul'da raylı sistemlerin toplu taşımada kullanım oranı yaklaşık olarak %20 ve günlük taşınan yolcu sayısı da 1.610.000 civarındadır (İETT., (2021).

Şekil 8


Yıllara Göre İstanbul'daki Raylı Sistemleri Kullanan Yolcu Sayıları



Çalışmamız esnasında yapılan testler T1 Bağcılar Kabataş hattında yapılmıştır ve kullanılan görüntüler bu hattaki bir trene aittir. Hattın sahip olduğu toplam uzunluk 19,3 kilometredir. Hatta 31 adet istasyon bulunmaktadır ve 92 adet tramvay ile yolcu taşımacılığı yapılmaktadır. Hattın kontrol ve idaresi Zeytinburnu istasyonda bulunan Kumanda Merkezi adı verilen bir birim tarafından gerçekleştirilmektedir. Tramvayların konumu ve tramvaylara ait bilgiler tramvayların tümünde bulunan Takip Sistemi ismindeki bir sistem tarafından toplanmaktadır. Sistem Gaye Bilişim şirketinde çalıştığım süreçte tarafımda tasarlanmış ve gerçekleştirilmiştir. Sistem tarafından tramvayların anlık konumları, kapı durumları, makinist bilgileri gibi anlık verilerini toplanmakta ve ardından GSM hattı aracılığıyla merkezi veritabanına gönderilmektedir. Bu veriler sayesinde tramvaylar kumanda merkezinin duvarındaki büyük ekrandan takip edilebilmektedir. Projemizde Jetson nano ile elde ettiğimiz yoğunluk verileri de takip sistemimiz aracılığı ile merkezdeki veri tabanına iletilmektedir.

Şekil 11

Kumanda Merkezi Takip Ekranı



Raylı sistemlerin sefer planlaması aşamasında öncelikli olarak sefer aralıklarının belirlenmesi işlemi gerçekleştirilir. Burada, yaşanan yolcu yoğunluklarının hangi günlerde, hangi zaman aralıklarında ve ne kadar sıklıkta olacağı belirlenmektedir. Örneğin, okula yakın olan istasyonlarda okul giriş çıkış saatlerinde yoğunluk yaşanması yahut semt pazarlarının kurulduğu bölgelerdeki istasyonlarda o günlerde yaşanan yoğunluklar gibi bilgiler planlama esnasında değer kazanmaktadır.

Planlama aşamasında bu bilgilere dayanarak yolcu kapasitelerine göre değişik tiplerde tramvaylar tercih edilmektedir. Ayrıca sefer sürelerinin ne kadar olacağı bilgisi trafikte yaşanabilecek gecikmeler ve yolcuların iniş ve binişleri sürecinde yaşanan zaman kayıplarının da dikkate alınmasıyla hesaplanmaktadır.


Vagonların içerisindeki yolcu yoğunluğunun günlere ve günün belirli saatlerine göre nasıl değişim gösterdiğinin veri olarak elde edilmesi ile bu verilere dayanarak sefer planlamalarının yapılması sonucunda çok daha sağlıklı bir planlama gerçekleştirilecektir. Yolcuların istasyonlarda beklemeleri ve iniş binişleri sırasında daha planlı bir süreç yaşanacak ve raylı sistemlerin ten önemli avantajı olan konforlu bir yolculuk yapmaları sağlanacaktır. Yönlendirme sayesinde kaybedilen sürelerin azalması ile sefer süreleri daha doğru hesaplanabilecek ve tam olarak belirlenen sefer aralıklarında hizmet sunulacaktır. İstasyonlarda yaşanan fazladan beklemelerin yerine kazanılan zaman sayesinde yoğun saatlerde fazladan sefer yapılabilmesi de sağlanabilecektir. Sefer sürelerinin belirlenen sürelerden daha fazla sürmesi ile elektrik ile çalışan raylı sistemlerin güç tüketimi artış gösterecek ve işletme maliyeti de yükselecektir. Yolcu sayılarının tespit edilebilmesi ile kilometre başına maliyet gibi ekonomik performans göstergelerinin de hesaplanması daha kolay olacaktır. İstasyonlarda yaşanan bekleme sürelerinin rapor edilmesi ile yönlendirme haricinde fiziksel aksaklıklardan dolayı yaşanmakta olan tramvayların istasyonlarda bekleme süresinin artışları söz konusu ise bunlarda tespit edilebilecektir.

Projemiz kapsamında vagon içerisindeki yolcuların yoğunluğu tespit edilmekte ve elde edilen bu bilgiler tramvay takip sistemine iletilerek buradan merkez veritabanı sistemine iletilmesi sağlanmaktadır. Bu bilgiler sonraki istasyonlarda tramvay kapılarının geleceği yerlere konumlandırılacak yönlendirme tabelaları ile yolcuların vagon yoğunluğunun az olduğu noktalara

yönlendirilmesini sağlanacaktır.

Şekil 12

Yolcu Yoğunluğunun Belirlenmesi ve Yönlendirme Sistem Şeması



Tasarlanan sistemin iki aşaması bulunmaktadır. İlk aşamada tramvay kapılarının kapanmasının ardından tramvayların içerisinde bulunan güvenlik kameralarından belirli aralıklarla resim kareleri alınmaktadır. Güvenlik kameralarını kullanımı montaj aşamasındaki sorunları ortadan kaldırdığı gibi ekonomik olarak da oldukça uygun bir çözümdür. Resimler kameralar tarafından kullanılan kayıt cihazından belirli aralıklarla OpenCV Kütüphanesi kullanılarak frame olarak okunmaktadır. Ardından, kameradan kaynaklanan tuz biber gürültülerinin temizlenmesi için gauss filtresi ile bir ön işleme uygulanmaktadır. Yolcuların belirlenmesi için Jetson Nano bilgisayarımız üzerindeki GPU'da koşturulan YOLOv5 Algoritması ve COCO veri seti ile yolcuları, yolculara ait çanta ve bagajları tanımlayarak içerideki yoğunluğu belirlenmektedir.

Aşağıda gerçek bir seferden alınmış resimler bulunmaktadır. Vagonda yaşanan ışık değişimleri, yolcuların ve diğer nesnelerin kameranın açısına tam olarak girememeleri, tramvay parçalarının görüşü engellemesi ve yolcu hareketleri gibi durumlar bazı yolcuların bir resimde tespit edilmesine ancak başka bir resimde tespit edilememesine sebep olabilmektedir. Bu nedenle kısa aralıklar ile on adet resim olarak tespit işlemi gerçekleştirilmiştir.

Şekil 13

Vagon İçerisindeki Tespit Sonuçları 1



Şekil 14*Vagon İçerisindeki Tespit Sonuçları 2***Şekil 15***Vagon İçerisindeki Tespit Sonuçları 3***Şekil 16***Vagon İçerisindeki Tespit Sonuçları 4***Şekil 17***Vagon İçerisindeki Tespit Sonuçları 5***Şekil 18***Vagon İçerisindeki Tespit Sonuçları 6*

Şekil 19

Vagon İçerisindeki Tespit Sonuçları 7



Şekil 20

Vagon İçerisindeki Tespit Sonuçları 8



Şekil 21

Vagon İçerisindeki Tespit Sonuçları 9



Şekil 22

Vagon İçerisindeki Tespit Sonuçları 10



Algoritma çalıştırıldığında ilk resimde 7 yolcu, ikinci resimde 11 yolcu, üçüncü resimde 9 yolcu, dördüncü resimde 8 yolcu, beşinci resimde 8 yolcu, altıncı resimde 9 yolcu, yedinci resimde 12 yolcu, sekizinci resimde 7 yolcu, dokuzuncu resimde 13 yolcu ve son resimde 11 yolcu tespit etmiştir. Alınan ardışık resimlerden elde edilen sonuçlara dayanarak taranan alandaki yolcu sayısının 13 olduğu sonucuna ulaşılmıştır. Burada %81 oranında bir başarı oranı ile tespit işlemi gerçekleştirilmiştir.

Görüntülenen alan tek bir Bombardier marka tramvayın ilk çeyrek görüntüsüdür ve yaklaşık olarak 35 kişilik yolcu kapasitesine sahiptir. Yoğunluk belirleme dağılımı şöyle belirlenmiştir.

- 0-10 Yolcu Az Yoğun
- 11-20 Yolcu Normal
- 21-35 Yolcu Çok Yoğun

İkinci aşamada, belirlenen yoğunluk değerlerine göre istasyonlarda bulunan yönlendirme tabelaları ile yolcuların en uygun noktalara yönlendirilmeleri sağlanmaktadır. Bu yönlendirmede, yeşil renk az yoğun, sarı renk normal ve kırmızı renk çok yoğun olduğunu belirtmektedir.

Şekil 23

Yönlendirme Tabelaları



TARTIŞMA

Konu ile ilgili yapılan araştırmalar ve çalışmalarda toplu taşıma ile yolcu yoğunluğunu hesaplanması konusunda otobüslere yönelik olarak kapı üzerinden sensörler veya kameralar ile yolcuların tespiti ve sayılması üzerine çalışıldığı görülmüştür. Bu çalışmalarda yolcuların hangi bölümlerde yoğunlaştığı üzerinde durulmazken sadece yolcuların sayısal değeri ile ilgilenilmiş olup vagon içerisinde hareket eden yolcular ve çok sayıda kapısı olan havayolları veya raylı sistemler için gerekli sonuçları sunamamaktadır. Havacılık ya da raylı sistemler uygulamaları da bu sistemlerden evrilerek kullanıldığı görülmüştür. Çalışmamızda ise uygulanabilirlik ve maliyet gibi önemli konular göz önüne alınarak güvenli kameralarından alınan görüntüler fiyat ve performans olarak oldukça verimli bir platform üzerinde işlenerek sonuç üretilmiştir.

Çalışmamızda araç içerisindeki yolcu dağılımlarına bağlı olarak yoğunluk derin öğrenme algoritmaları ile belirlenmesi önerilmiş olup böylelikle gelecek istasyonlardaki yolcuların en uygun kapılara yönlendirilmesi hedeflenmiştir. Burada elde edilen verilerin raylı sistemler işletmesi açısından da planlama aşamasında ne kadar değerli olduğu görülmektedir. İstasyon bazında raylı sistemlerin işletmesine yönelik verilere odaklanılması çalışmamızın avantajları arasındadır.

Şekil 24

Yazılım Çıktı Sonuçları

```
Fusing Layers...
Model Summary: 213 Layers, 722585 parameters, 0 gradients
Yolcu Sayısı: 11
Image 1/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h29m18s264.jpg: 544x640 11 person, Done. (0.243s)
Yolcu Sayısı: 7
Image 2/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h29m38s110.jpg: 544x640 7 person, Done. (0.133s)
Yolcu Sayısı: 9
Image 3/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h29m48s046.jpg: 544x640 9 person, Done. (0.152s)
Yolcu Sayısı: 8
Image 4/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h29m58s140.jpg: 544x640 8 person, Done. (0.152s)
Yolcu Sayısı: 9
Image 5/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h30m09s026.jpg: 544x640 9 person, Done. (0.154s)
Yolcu Sayısı: 8
Image 6/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h30m15s078.jpg: 544x640 8 person, Done. (0.152s)
Yolcu Sayısı: 12
Image 7/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h30m21s127.jpg: 544x640 12 person, Done. (0.152s)
Yolcu Sayısı: 7
Image 8/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h30m26s317.jpg: 544x640 7 person, Done. (0.152s)
Yolcu Sayısı: 11
Image 9/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h30m31s555.jpg: 544x640 11 person, Done. (0.152s)
Yolcu Sayısı: 13
Image 10/18 /home/volkan/Desktop/Kodlar/yolov5/data/images/vlcsnap-2022-02-18-10h30m36s532.jpg: 544x640 13 person, Done. (0.153s)
volkan@volkan-desktop:~/Desktop/Kodlar/yolov5$
```

Algoritmanın yolcuları tespit etme süreleri incelendiğinde en uzun sürenin 0.243 saniye olduğu görülmektedir ki bu süre oldukça kısa bir süredir. Böylelikle tespitin yapılması ve istasyona gönderilmesi oldukça hızlı gerçekleşmektedir. Bu da bize yolcuların yönlendirilmesi ve yolcuların

uygun kapılara ulaşması noktasında yeterli zamanı vermektedir.

SONUÇ

Dijitalleşen dünyanın getirdiği büyük miktardaki veri çağımızın en önemli kaynağını oluşturmaktadır. Bu kaynak hem şirketler hem de devletler tarafından büyük önem arz etmektedir. Büyük veri yığınlarını anlamlandırmak ve depolamak için gerekli olan donanımsal cihazlar konusunda da son on beş yılda çok büyük gelişmeler yaşanmıştır. Yaşanan bu gelişmeler neticesinde büyük verilerin depolanması ve işlenmesi için gerekli donanımlar elde edilmiştir. Toplanan veriler ve elde edilen yüksek işlem gücü sayesinde yapay zekâ algoritmalarının eğitim süreçleri hem kısalmış hem de oldukça yüksek seviyeye çıkmıştır. Böylece günlük yaşantımızın her alanında gördüğümüz başarılı ve ilgi çekici yapay zekâ uygulamaları ortaya çıkmıştır.

Mühendislik uygulamaları açısından yapılan çalışmalar birçok noktada uygulanabilir olmalıdır. Bu noktada donanımsal araçlarımızın yapay zekâ algoritmalarını çalıştırmak için performans olarak yeterli olması kadar maliyetinin de uygun olması gereklidir. Bizlerde projemizde üzerinde yapay zekâ algoritmalarını çalıştırabileceğimiz NVIDIA tarafından tasarlanan Jetson Nano bilgisayar kullanılmıştır. Fiyat olarak oldukça makul olan bilgisayarımız performans olarak da sahip olduğu grafik işlem birimi sayesinde oldukça iyi bir sonuç göstermiştir.

Büyükşehirlere yaşanan göç ile artan şehir nüfusu tüm Dünyada şehir yaşamı üzerinde olumsuz etkiler oluşturmaktadır. Bu etkilerin azaltılması için birçok çalışma yapılmaktadır. Bu çalışma alanlarından biri de toplu taşıma sistemleridir. Toplu taşıma sistemleri kalabalık şehirlerin trafik problemlerinin çözümü noktasında önemli bir yer teşkil etmektedir. Çalışmamızda dünya genelinde toplu taşımanın en verimli ve konforlu alanı olan havayolları ve raylı sistemlerin durumu incelenmiş olup ülkemizdeki durumu ile geleceğe yönelik yapılan planlamalardan bahsedilmiştir. İstasyonlarda bekleyen yolcu sayısı arttığında çıkan problemler ve bu problemlerin oluşturduğu sorunlar hem yolcular hem de işletme açısından irdelenmiştir.

Projemiz kapsamında raylı sistemlerde yaşanan önemli bir problem olan iniş binişlerde yaşanan zaman kayıplarının önemi belirtilmiş ve gömülü bir sistem üzerinde derin öğrenmeli bir yöntem kullanılarak vagonlardaki yoğunluğun belirlenerek gelecek istasyonlardaki yolcuların yönlendirilmesi üzerine bir çözüm önerilmiştir. Bu sistem ile sosyal hayatımızın bir parçası olan yolculukların daha konforlu gerçekleştirilebilmesi amaçlanırken, elde edilen bilgiler sayesinde işletmenin planlama ve yönetim süreçlerinin kolaylaştırılması hedeflenmiştir.

Uygulama gerçek bir sefer üzerinde test edilmiş ve sonuçları incelenmiştir. Yapılan çalışmalar sonucunda yolcuların yerleşimleri ve ışık değişimlerinin çeşitli sorunlar oluşturduğu görülmüştür. Yolcu yerleşimlerinden oluşan problemlerin çözümü için belirli aralıklar resimler alınarak algoritma çalıştırılmış ve yolcu hareketleri ile arkada kalan yolcularında tespit edilebilmesi hedeflenmiştir. Işık değişimi sayısal görüntü işleme projeleri için her zaman büyük bir problem olmuştur. Bu noktada projemizde resimler üzerinde bir filtre gezdirilerek bulanıklaştırma işlemi gerçekleştirilmiş ve ardından YOLO algoritmasına verilmiştir. Resimlere YOLO algoritması gibi öğrenme temelli sistemlerin piksel temelli işlem yapmayıp nesneleri tanıyabilmeleri nedeniyle basit ön işleme uygulanmış resimlerde verimli bir şekilde nesne tanıma işlemi gerçekleştirdikleri görülmüştür.

Projenin saha uygulaması ile trenlerden verilerin toplanmasını sağlayan tramvay takip sistemi, istasyonlarda bekleyen yolcuların araçların kaç dakika sonra geleceğini bildiren yolcu bilgilendirme sistemi ve projemizin konusu olan yolcu yoğunluğunun tespiti ile yolcuların uygun kapılara yönlendirilmesi sistemleri birbirleri ile entegre olarak çalışacak ve uçtan uca çözüm sağlanacaktır. Bu sayede işletme açısından önemli olan ilgili konuların yönetilmesi tek noktadan etkin şekilde sağlanacaktır.

Projemizin ilerleyen safhalarında daha çok kamera ile alınan görüntüler ile incelenmesi hedeflenmektedir. Böylelikle yolcuların belirli bölgelerde oluşturduğu yığılmalar belirlenebilecektir. Ayrıca, algoritmanın yolcuların beraberlerinde taşıdığı bagajların ve bisikletlerin de tanınması ve yoğunluğa bu verinin de etki etmesi hedeflenmektedir.

Yazar Katkıları

Araştırma Tasarımı (CRediT 1) Yazar 1 (%50) – Yazar 2 (%50)

Veri Toplama (CRediT 2) Yazar 2 (%100)

Araştırma - Veri Analizi - Doğrulama (CRediT 3-4-6-11) Yazar 1 (%50) – Yazar 2 (%50)

Makalenin Yazımı (CRediT 12-13) Yazar 2

Metnin Tashihi ve Geliştirilmesi (CRediT 14) Yazar 1 (%50) – Yazar 2 (%50)

Finansman

Finansal destek yoktur.

Çıkar Çatışması

Çıkar çatışması yoktur.

REFERANSLAR

- Akkoyunlu, M. T., Polat, E., Özkılıçaslan, R., Keleş, V., Abdallatif, Y., & Samancı, A. (2024). Güneş Enerji Santralinin Temizlik Sonrası Üretim Verilerinin İncelenmesi. Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 6(3), 583-591.
- Chollet, F. (2019). Python ile Derin Öğrenme. Ankara: Buzdağı Yayın Evi.
- Goodfellow, I., Bengio, Y., & Courville, A. (2018). Derin Öğrenme. Ankara: Buzdağı Yayın Evi.
- Gonzalez, R. C., & Woods, R. E. (2002). Digital Image Processing. Prentice Hall: Pearson Education.
- İETT. (2021). <https://www.iett.istanbul/tr/main/pages/istanbulda-toplu-ulasim/95>
- Hacıbeyoglu, M., Çelik, M., & Erdaş Çiçek, Ö. (2023). K En Yakın Komşu Algoritması ile Binalarda Enerji Verimliliği Tahmini. Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi, 5(2), 65-74.
- İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gazi Osman Paşa Bilimsel Araştırma Dergisi*, 85-104.
- Karakuş, G. (2023). Türk Hava Yolları sürdürülebilirlik raporları üzerine bir araştırma. Aerospace Research Letters (ASREL) Dergisi, 2(2), 86-113.
- Kıymaz, Y. E., & Oguz, H. (2024). Assessment of Electricity Generation Using Deep Learning on Solar Power Plants. Necmettin Erbakan Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, 6(2), 289-311.
- Kızılkaya, A. (2008). EEM 740 Sayısal Görüntü İşleme. Denizli.
- Kızrak, M. A., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. Bilim Teknolojileri Dergisi, 11 (3), 263-286
- Lee J.H., Lee J.M., Kim H.J., Moon Y. S. (2008) Machine vision system for automatic inspection of bridges, Congress on Image and Signal Processing (CISP). 3363-366.
- Nasrullah, M., & Diker, A. (2021). Derin Öğrenme ve YOLO Algoritmaları ile Nesne Tespiti ve Şerit Belirleme. 2. Uluslararası Akıllı Ulaşım Sistemleri Konferansı, 68-79.
- Nilson, N. J. (2018). Yapay Zeka Geçmişi Ve Geleceği. İstanbul: Boğaziçi Üniversitesi Yayınevi.
- Nvidia web sayfası (2022). Jetson Nano. <https://www.nvidia.com/tr-tr/autonomous-machines/embedded-systems/jetson-nano/product-development/#features>
- NVIDIA Developer. (2022). Ocak 13, 2022 tarihinde NVIDIA Web sitesi: <https://developer.nvidia.com/opencv> adresinden alındı.
- OpenCV:Hakkında. (2022). <https://opencv.org/about/>
- Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. Takvim-i Vekayi, 6 (2), 25-36.
- Railway Turkey Dergisi. (2021). Railway Turkey , 70-72.
- RailTurkey web sayfası (2022). <https://tr.railturkey.org/kentici-rayli-sistemler/>
- Şen, Z. (2004). Yapay Sinir Ağları İlkeleri. İstanbul: Su Vakfı.
- Şenlik, İ. (2013). Kent İçi Raylı Ulaşım Sistemlerinin Değerlendirilmesi. İstanbul: EMO.

Wu, T.-H., Wang, T.-W., & Liu, Y.-Q. (2021). Real-Time Vehicle and Distance Detection Based on. 3rd World Symposium on Artificial Intelligence (WSAI) Guangzhou, China: IEEE, 1.