



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Derin öğrenme ile soket kablo sıralama hata tespiti

Socket cable sequencing error detection with deep learning

Yazar(lar) (Author(s)): Bahadır ELMAS¹, Hakan KORKMAZ²

ORCID¹: 0000-0002-8732-9997

ORCID²: 0009-0001-6851-5540

To cite to this article: Elmas B. and Korkmaz H., “Derin öğrenme ile soket kablo sıralama hata tespiti”, *Journal of Polytechnic*, 28(4): 1205-1215, (2025).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Elmas B. ve Korkmaz H., “Derin öğrenme ile soket kablo sıralama hata tespiti”, *Politeknik Dergisi*, 28(4): 1205-1215, (2025).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1500454

Derin Öğrenme ile Soket Kablo Sıralama Hata Tespiti


Socket Cable Sequencing Error Detection with Deep Learning

Önemli noktalar (Highlights)

- ❖ Kablo demeti üretiminde Derin Öğrenme yöntemlerinden evrişimli sinir ağlarının kullanılması. / Using convolutional neural networks from Deep Learning methods in wiring harness production.
- ❖ Bilgisayara bağlı bir kamera-fikstür düzeneği kurularak 30234 adet görsel içeren bir veri seti oluşturulması. / Creating a dataset containing 30234 images by installing a camera-fixtue setup connected to a computer.
- ❖ Kablo demeti üretiminde soketlerin kablo sıralama kalite kontrol denetiminin otomatikleştirilmesi. / Automating the quality control inspection of cable sequencing of sockets in wiring harness production.

Grafik Özet (Graphical Abstract)

Kablo demeti üretiminde soketlerin kablo sıralaması kalite kontrol denetimini otomatikleştirmek için ResNet-50 ağı, transfer öğrenme yöntemiyle kullanılmıştır. Modeli eğitmek için bilgisayara bağlı bir kamera-fikstür düzeneği kurularak 30234 adet görsel içeren bir veri seti oluşturulmuştur. / ResNet-50 network was used to automate the quality control inspection of the cable sequence of the sockets in the harness production using transfer learning method. To train the model, a camera-fixtue setup connected to the computer was installed and a data set containing 30234 images was created.



Şekil. Önerilen yöntem akış diyagramı /Figure. Flow chart of the proposed method

Amaç (Aim)

Kablo demetinin üretiminde soketlerin kablo sıralama kalite kontrol denetiminin otomatikleştirilmesi. / Automating the quality control inspection of cable sequencing of sockets in wiring harness production.

Tasarım ve Yöntem (Design & Methodology)

ResNet-50 modelinin tam bağlantılı katmanı kaldırılarak yerine üç tam bağlantılı katman yerleştirilmiştir. Oluşturulan veri seti ve eğitim seçenekleri ile yeni model eğitilmiştir. / The fully connected layer of the ResNet-50 model was removed and replaced with three fully connected layers. The new model was trained with the created dataset and training options.

Özgünlük (Originality)

Endüstrisinde soketlerin güvenlik açısından montaj kalitesinin sağlanması önem taşımaktadır. Montaj sürecinde insan kaynaklı kalite kontrol denetim hatalarının önlemek amacıyla derin öğrenme yöntemi kullanılmış, hata oranı azaltılmış ve denetimi otomatikleştirilmiştir. / In the industry, it is important to ensure the assembly quality of the sockets in terms of safety. In order to prevent human-induced quality control inspection errors in the assembly process, deep learning method is used, the error rate is reduced and the inspection is automated.

Bulgular (Findings)

Model, soket türlerini ayırt etmekte %100, kablo sıralama hata tespitinde %97,25 başarı elde etmiştir. / The model achieved 100% success in distinguishing socket types and 97.25% success in cable sorting error detection.

Sonuç (Conclusion)

Önerilen yöntem soket kablo sıralama hata tespitinde hedeflenen değerin üzerinde başarılı olmuştur. / The proposed method was more successful than the targeted value in socket cable sequencing error detection.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Derin Öğrenme ile Soket Kablo Sıralama Hata Tespiti

Araştırma Makalesi / Research Article

Bahadır ELMAS^{1*}, Hakan KORKMAZ²

¹Fen Edebiyat Fakültesi, İstatistik Bölümü, Mimar Sinan Güzel Sanatlar Üniversitesi, Türkiye

²Elektrik Elektronik Mühendisi, PAS South East Europe Sanayi Ticaret Ltd. Şti, Türkiye

(Geliş/Received : 12.06.2024 ; Kabul/Accepted : 26.12.2024 ; Erken Görünüm/Early View : 10.01.2025)

ÖZ

Beyaz eşya ve küçük ev aletlerinde ürün çeşitliliği ve işlevsellikteki artış, otomotiv endüstrisinde elektrifikasyon ve otonom sürüşe geçiş, kablo demetlerini kritik bir bileşen haline getirmiştir. Kablo demetleri, soketler aracılığıyla hedef üniteye veya diğer kablo demetlerine bağlanarak bilgi ve enerji akışını sağlamaktadır. Bu nedenle güvenlik açısından soket montaj kalitesinin sağlanması kritik önem taşımaktadır. Bu çalışmada, personel tarafından görsel olarak yapılan soket kablo sıralama hata kontrollü, transfer öğrenme yöntemi kullanılarak ResNet-50 evrişimli sinir ağıyla yapılmıştır. Otomatikleştirilen sistem kalite kontrol sürecinin belirli standartta kavuşması sağlanmış, insan kaynaklı hataların önüne geçilerek üretimde verim ve kalite artırılmıştır. Bunun sonucu olarak tamirat işlemleri minimize edilmiş; navlun, hurda gibi ek giderlerin de önüne geçilmiştir. Önerilen modeli eğitmek amacıyla PAS South East Europe'un Tekirdağ/Çerkezköy fabrikasında bilgisayara bağlı bir kamera-fikstür düzeneği kurulmuştur. Bu düzeneğe montajı sıklıkla yapılan üç soketin kablo bağlantı sıralamasına ait 30234 adet görsel içeren bir veri seti oluşturulmuştur. Ağın tam bağlantılı katmanı çıkarılarak üç tam bağlantılı katman eklenmiştir. Önerilen modelin eğitiminde K-kat çapraz doğrulama yöntemi kullanılmıştır. Eklenen ilk iki katmana L2 düzenleştirmesi ve dropout uygulanmıştır. Ağırlıkları güncellemek için Adam algoritması tercih edilmiş, hata ölçüsü olarak ise çapraz entropi kullanılmıştır. Modelin test doğruluğu ise %97.25'tir.

Anahtar Kelimeler: Evrişimli Sinir Ağları, Kablo Demetleri, Kablo Sıralama Hatası.

Socket Cable Sequencing Error Detection with Deep Learning

ABSTRACT

The increase in product variety and functionality in white goods and small household appliances, electrification in the automotive industry and the transition to autonomous driving have made wiring harnesses a critical component. Wire harnesses provide information and energy flow by connecting to the target unit or other wire harnesses via sockets. Therefore, it is critical to ensure the quality of socket assembly in terms of safety. In this study, the socket cable sorting error control made visually by the personnel was performed with ResNet-50 convolutional neural network using transfer learning method. The automated quality control process has been standardised and human-induced errors have been prevented, increasing efficiency and quality in production. As a result, repair operations were minimised and additional costs such as freight and scrap were prevented. In order to train the proposed model, a camera-fixture setup connected to a computer was installed in the Tekirdağ/Çerkezköy factory of PAS South East Europe. A dataset containing 30234 images of the wiring sequence of three sockets, which are frequently installed with this setup, was created. The fully connected layer of the network was removed and three fully connected layers were added. K-fold cross-validation method was used to train the proposed model. L2 regularisation and dropout were applied to the first two layers. Adam algorithm was used to update the weights and cross entropy was used as the error measure. The test accuracy of the model is 97.25%

Keywords: Convolutional Neural Networks, Wiring Harness, Cable Sequence Error.

1. GİRİŞ (INTRODUCTION)

Kablo demeti, bilgi sinyallerinin veya enerjinin güvenli iletimini sağlamak için hizalanmış bir grup kablo veya teldir. Kablo demetleri son derece özelleştirilmiş ürünlerdir ve her kablo demeti farklı bileşenlerden oluşur. Bunlar; soketler, konektörler ve sabitleme elemanları gibi sert nesneler ile teller, aparatlar ve hortumlar gibi deforme olabilen bileşenlerdir [1, 2]. Şekil 1'de çeşitli kablo demeti örnekleri verilmiştir.

Kablo demeti, beyaz eşya, küçük ev aletleri ve otomotiv sektöründe yaygın olarak kullanılmaktadır. Beyaz eşya sektörü; buzdolabı, dondurucular, çamaşır makineleri, bulaşık makineleri, fırınlar ve elektrikli süpürgelerini içerir. Küçük ev aletleri ise; mini fırın, fritöz, ekmek kızartma makinesi, yoğurt yapma makinesi veya su

ısıtıcısı gibi ürünleri içerir. Her geçen yıl bu sektörlerdeki ürün ve model çeşitliliği ile ürün ve modellerin işlevsellikleri artmakta, buna paralel olarak da sektörün kablo demetlerine olan ihtiyacı büyümektedir. Otomotiv endüstrisinde elektrifikasyon ve otonom sürüş bir değerler dizisi değişikliğine neden olmuştur. Söz konusu bu değişiklik, otomotiv kablo demetlerini; manevra, sürüş yardımı ve güvenlik sistemi gibi çeşitli işlevler için giderek daha kritik hale getirmiştir [3]. Otomotiv endüstrisindeki değerler dizisi değişiminin gelişim süreci ve bunun sonucu olarak kullanılan kablo demetlerinin artışı, önümüzdeki yıllarda giderek daha fazla kablo demetine ihtiyaç duyulacağını göstermektedir.

Kablo demeti, beyaz eşya, küçük ev aletleri ve otomotiv sektöründe yaygın olarak kullanılmaktadır. Beyaz eşya

*Sorumlu Yazar (Corresponding Author)
e-posta : bahadir.elmas@msgsu.edu.tr

sektörü; buzdolabı, dondurucular, çamaşır makinaları, bulaşık makinaları, fırınlar ve elektrikli süpürgelerini içerir. Küçük ev aletleri ise; mini fırın, fritöz, ekmek kızartma makinesi, yoğurt yapma makinesi veya su ısıtıcısı gibi ürünleri içerir. Her geçen yıl bu sektörlerdeki ürün ve model çeşitliliği ile ürün ve modellerin işlevsellikleri artmakta, buna paralel olarak da sektörün kablo demetlerine olan ihtiyacı büyümektedir. Otomotiv endüstrisinde elektrifikasyon ve otonom sürüş bir değerler dizisi değişikliğine neden olmuştur. Söz konusu bu değişiklik, otomotiv kablo demetlerini; manevra, sürüş yardımı ve güvenlik sistemi gibi çeşitli işlevler için giderek daha kritik hale getirmiştir [3].



Şekil 1. Kablo demeti (Wiring harness)

Otomotiv endüstrisindeki değerler dizisi değişiminin gelişim süreci ve bunun sonucu olarak kullanılan kablo demetlerinin artışı, önümüzdeki yıllarda giderek daha fazla kablo demetine ihtiyaç duyulacağını göstermektedir.

Kablo demeti üretimi; kesme, ön montaj ve son montaj olmak üzere üç ana üretim aşamasında gerçekleştirilir. Kesme ve ön montaj aşamasında birden fazla iş istasyonunda teller işlenerek kablo demeti alt montajları hazırlanır ve söz konusu bileşenler son montaja verilir [4]. Son montaj aşamasında yine birden fazla iş istasyonunda bileşenler kademeli olarak birleştirilir. Son montaj aşaması çoğunlukla manuel ve beceri gerektiren işlemler içerir. Manuel iş tekrarlanabilir değildir, hataya açıktır ve izlenmesi zordur [4]. Bunun yanı sıra üretim süreci parti boyutunda yüksek hacimli olup, aynı temele dayanmakla birlikte farklı özellikler içermektedir.

Kablo demeti üretimindeki kalite testleri ise; elektrik, bütünlük kontrolü ve sızıntı testleridir [5]. Söz konusu bu testler genellikle son montaj hattından sonra gerçekleştirilir. Testler teknik standartları karşılamıyorsa, manuel sorun giderme için yeniden işleme gönderilir [4]. Yeniden işleme süreci, maliyetlerin artması ve zaman kaybı demektir. Ayrıca bu süreçte geriye dönüşün mümkün olmadığı sorunlar nedeniyle hurdaya ayırma maliyetlerin daha da artmasına neden olur. Bu nedenle kaliteyi korumak ve kalite sorunlarını ortaya çıktıklarında tespit ederek çözmek için hat içi kalite izleme ve değerlendirmenin uygulamaya koyulması gerekmektedir [4]. Son montaj sürecinin manuel ve beceri gerektiren bir süreç olması, partilerdeki ürün sayısının çok ve farklı özellikler içermesi, kısıtlı ürün teslim süreleri gibi nedenler montajın kalitesini kontrol edecek ve iyileştirecek otomasyon çözümlerinin geliştirilmesi için çeşitli engellerdir. Fakat ortaya çıkan ürünün kullanıldığı beyaz eşya, küçük ev aletleri,

otomotiv sektöründeki güvenlik, kalite ve maliyetler göz önünde bulundurulduğunda kalite standartlarının artırılması ve maliyetlerin düşürülmesi için kablo demeti üretiminde akıllı kalite kontrol sistemlerinin geliştirilmesi de zorunluluk haline gelmiştir.

Günümüzde dijital dönüşüm, tüm üretim süreçlerini etkilenmekte, otomatik ve optimize edilmiş imalat süreçlerini getirmektedir. Dijital dönüşüm makinelerde verilerin toplanmasını ve analiz edilmesini sağlayarak; hızlı, esnek ve verimli süreçler sayesinde üretim performansını artırır. Bununla birlikte finansal ve insan kaynağı açısından birçok kazanımlar getirmektedir. Dijital dönüşümün etkisiyle günümüzde geleneksel görüntü işleme yöntemlerinin aksine, algısal nitelikteki karmaşık problemleri çözmek için derin öğrenme yöntemlerinden evrimsel sinir ağları, bilgisayarla görme görevleri için güçlü bir algoritma haline gelmiştir [6]. Bu çalışma, kablo demeti soket montaj hatalarının otomatik denetimi için derin öğrenme yöntemlerinden biri olan evrimsel sinir ağlarının kullanılmasını önermektedir.

Kablo demetleri, soketler aracılığıyla hedef üniteye veya diğer kablo demetlerine bağlanır. Böylece, sinyal çeşitli işlevlerinden sorumlu elektronik sistemler içinde kesintisiz ve güvenli bir şekilde iletilir [3]. Bu nedenle diğer soket ve birimlerle eşleşen soketlerin kalitesinin sağlanması kritik önem taşımaktadır. Montaj hataları; montaj hattındaki süreçlerde yanlış renkte kablo takılması ve boş priz hatası sonucu kablo sıralamasının sağa veya sola kayması sonucu ortaya çıkan durumlardır. Söz konusu hataların tespiti personel tarafından görsel kontrol ve elle yapılmakta, bu ise hataların bir bölümünün tespit edilememesine neden olmaktadır. İnsan faktörü ile yapılan görsel kontrol hatalarının önüne geçmek amacıyla problemin çözümü için önerilen derin öğrenme yöntemi, soketlerin belirli bir iş istasyonunda doğru monte edilip edilmediğini kontrol etmeyi amaçlamaktadır.

Derin sinir ağlarının güçlü yönü, özellikleri otomatik çıkarma, düzenlemiş ve düzenlenmemiş verileri işleme ve daha önce görmediği verilere genelleme yeteneğidir [7]. Bu özelliklerinden dolayı, üretim ortamında derin öğrenme üzerine yapılan araştırmalarda önemli bir artış olmuştur [8-11]. Fakat derin sinir ağlarının eğitimi için gerekli olan veri seti önemli bir darboğazdır. Verilerin toplanması ve hazırlanması zaman alıcı ve maliyetli bir süreçtir. Bu çalışmanın amaçlarından biri söz konusu sektörlerde akıllı kalite kontrol sistemleri geliştirmek için derin sinir ağlarının ihtiyaç duyduğu veri seti oluşturmaktır.

Bu makale şu şekilde düzenlenmiştir: Bölüm 2'de kablo demeti montajında kameralardan elde edilen görsel verileri analiz eden bilgisayarla görme tabanlı yöntemlerin kullanıldığı çeşitli görüntü işleme ve derin öğrenme araştırmaları verilmektedir. Bölüm 3'te evrimsel sinir ağları, montaj hataları, çalışmada kullanılan verilerin toplama yöntemi ve toplanan veri seti hakkında bilgiler verilmektedir. Bölüm 4'te sinir ağlarının eğitimi, test süreçleri tanıtılmakta ve deneysel

sonuçlar verilmektedir. Bölüm 5'te ise elde edilen sonuçlar değerlendirilmekte ve gelecekte yapılacak çalışmalara ait bilgiler verilmektedir.

2. LİTERATÜR ÇALIŞMALARI (LITERATURE REVIEW)

Kablo demeti montajındaki optik denetim, bileşenlerin kalitesine, konumu ve yönlendirilmesi gibi kritik ürün ve süreçlerin izlenmesine ve montaj hatalarının tespit edilmesine olanak tanır [12]. Konektörlerin robotlu eşleştirilmesinde farklı alt görevleri kolaylaştırmak için optik denetimin kullanıldığı çeşitli görüntü işleme tabanlı çözümler literatürde yer almıştır. Parmar, tellerin, halatların, hortumların üst üste binmesini algılamak, yani karışıklıkları tespit etmek için kameradan elde edilen görsel verileri analiz eden bilgisayarla görme tabanlı bir yöntem önermiştir. Önerilen yöntemde göre görüntü işlendikten sonra elde edilen bilgiler, nesnelerdeki karışıklıkların konumunu ve hangi telin hangi tel üzerinden geçtiğini içerir. Testler sonucunda %74.9 doğruluk oranı elde edilmiştir [13]. Sun ve arkadaşları, elektrik konektörlerinin eşleşmesini gerçekleştirmek için optik denetim ve kuvvet/tork sensörlerine dayanan robotik bir kablo demeti montaj sistemi geliştirilmişlerdir. Önerdikleri sistem, konektörün sorunsuz ve güvenilir bir şekilde takılmasını sağlamıştır [14]. Lee ve arkadaşları, bir kablo demetinin bileşen tespiti ve uzunluk ölçümü için otomatik bir optik denetim sistemi geliştirmişlerdir. Bileşen tespiti için desen eşleştirme yöntemi ve kablo dallarının uzunluk ölçümü için kenar algılama yöntemi kullanmışlardır. Çalışmalarında %100 doğruluk elde etmişlerdir [15]. Mohandoss ve arkadaşları, izolasyondan sonra telin renginin tutarlılığını kontrol etmek ve yalıtım boyunca meydana gelen renk düzensizlikleri de görüntülenmek için görüntü işleme tekniklerini kullanan otomatik bir optik denetim sistemi sunmuşlardır. Önerilen çalışma farklı renkteki tellerle test edilmiş ve %100 eşleşme doğruluğuna kadar tanımlayabildiği görülmüştür [16].

Nguyen ve arkadaşları gerçek ve sentetik olarak oluşturdukları nokta bulutlarını kullanarak kablo demetlerinin otomatik denetimi için derin öğrenme tabanlı bir veri işleme hattı önermişlerdir. Elde ettikleri bulgular sonucunda, CAD ve simülasyon modellerinden elde ettikleri sentetik verilerin derin öğrenme ağlarının eğitimi için gereken gerçek veri miktarını azalttığını göstermişlerdir Kablo demeti bileşenlerinin nokta bulutu segmentasyonunu deneysel sonuçlarla doğrulamışlardır [2]. Zhou ve arkadaşları yarı deforme olabilen kablo demeti-soket bağlantı görevini gerçekleştirmek için yapay görme tabanlı çift kollu robot stratejileri geliştirmişlerdir. Yapılan doğrulama testlerinde önerilen çözüm %86.66 başarı elde etmiştir. Doğrulama sonuçları, önerilen çözümün endüstriyel bir senaryoda uygulanabilir olduğunu göstermiştir [17]. Kicki ve arkadaşları, deforme olabilen doğrusal nesnelerin yönlendirilmesiyle ilgili endüstriyel işlemlerin robotlaştırılması bağlamında kablo demeti dallarını

sınıflandırabilecek ve montaj sürecinde nereye yerleştirilecekleri konusunda bilgi sağlayabilecek yapay görme sistemi önermişlerdir. Çalışmalarında ortalama %94 doğruluk elde etmişlerdir [6]. Nguyen ve arkadaşları otomotiv sektöründe enerji ve bilgi akışında kullanılan crimp (kırımlı) konektör bağlantılarının kalite değerlendirmesi için görüntü işleme ve evrişimli sinir ağı tabanlı bir model önermişlerdir. Çalışmalarında transfer öğrenme yöntemini kullanarak VGG16 ağını eğitmişler ve yüzde %99.87 test doğruluğu elde etmişlerdir [18]. Mou ve arkadaşları, robotik kablo yönlendirilmesi için kablo etkisinin modellenmesi ve kontrol metodolojisinin geliştirilmesinde evrişimli sinir ağını önermişlerdir. Yöntemlerinde kablo kuvvet ve torklarını %85 doğrulukla tahmin etmişler ve 0.01 mm'den daha az bir konumlandırma hatasıyla yönlendirme gerçekleştirmişlerdir [19]. Thum ve arkadaşları, güç aktarımı ve iletişime dayalı faaliyetlerde yaygın olarak kullanılan sualı kablolarını sınıflandırmak için transfer öğrenme yöntemiyle çeşitli evrişimli sinir ağı modellerini kullanmış ve %93.5 doğruluk elde etmişlerdir [20]. Zheng ve arkadaşları çalışmalarında, uçak gövdelerine monte edilen kablo etiketlerinin hızlı bir şekilde algılanması ve tanınması için evrişimli sinir ağlarına dayalı sanal gerçeklik gözlüğü geliştirmişlerdir. Yaptıkları çalışma ile etiketlerin sayısını, türlerini, konumlarını tanımlama ve kablolarının üzerindeki metnini okumada ortalama %85.69 başarı elde etmişlerdir [21]. Wang ve Johansson araştırmalarında robotize otomotiv kablo demeti montajı için derin öğrenme tabanlı konektör algılama modeli önermişlerdir. Çalışmalarında, otomotiv kablo demetlerinde yaygın olarak kullanılan yirmi tür konektör içeren bir veri kümesi toplamışlar, iki aşamalı Faster R-CNN tabanlı bir tespit modeli ve tek aşamalı YOLOv5 tabanlı bir tespit modeli eğitmişlerdir. Yaptıkları deneylerle her iki yönteminin etkinliğini göstermişlerdir [3]. Shi ve Jian, görüntü işleme ile kablo demetine montajı yapılan kablonun renk ve konum hatalarını belirlemeye çalışmışlardır. Çalışmalarında; İlk olarak, net bir resim elde etmek için gürültü ve paraziti ortadan kaldırmak amacıyla medyan filtre kullanmışlardır. Ardından görüntü eşiklemede Otsu yöntemini ve görüntüdeki kablo demetini tam konumun belirlemek amacıyla kenar tespitinde Sobel operatörünü kullanmışlardır. Son olarak ise görüntüyü eşleştirmek ve karşılaştırmak amacıyla renk eşleştirme algoritması kullanmışlardır. Deneysel sonuçlar, sisteminin basit, doğru ve yüksek kararlılığa sahip olduğunu göstermiştir [22].

3. MATERYAL VE METOT (MATERIAL AND METHOD)

3.1. Evrişimli Sinir Ağları (Convolutional Neural Network)


Derin öğrenme, birbirini takip eden katmanlarda veriler işlenirken giderek artan şekilde daha kullanışlı gösterimler elde edebilen bir yöntemdir. Geleneksel bilgisayarla görme yaklaşımlarına kıyasla, derin

öğrenme kapsamlı özellik modellemesi gerektirmez ve genelleştirmeye izin verir. Buna karşın, derin öğrenme eğitim için büyük veriler, yüksek hesaplama maliyeti ve bellek kapasitesi ile sonuçlanan büyük model mimarileri gerektirir. Derin öğrenme mimarileri Evrişimli Sinir Ağı, Tekrarlayan Sinir Ağları, Boltzmann Makinesi, Kısıtlanmış Boltzmann Makineleri, Derin İnanç Ağları, Derin Oto Kodlayıcılar olarak kategorize edilebilir [23, 24, 25, 26, 27].

Derin Öğrenme, son zamanlarda farklı alanlarda özellikle de görüntü tanımda klasik yöntemlerin performansını aşmaya başlamıştır. Günümüzde araştırmacılar tarafından en çok kullanılan derin sinir ağı Evrişimli Sinir Ağıdır. Evrişimli Sinir Ağları, iki boyutlu görüntü verilerini özellik çıkarma ve boyut indirgeme yoluyla

işleyen ve verileri tek boyutlu bir özellik vektörüne eşleyen çok katmanlı hiyerarşik ağlardır. Bu ana prensibe dayanarak başlangıçta nesne tanıma görevleri için yaygın olarak kullanılmıştır. Ancak günümüzde nesne izleme [28], poz tahmini [29], metin algılama ve tanıma [30], görsel belirginlik algılama [31], eylem tanıma [32] ve sahne etiketleme [33] gibi birçok alanlarda da problemleri çözmektedir.


Evrişimli Sinir Ağları Şekil 2'deki gibi Evrişim, ReLU, Havuzlama ve Tam Bağlantılı Katmanlar dahil olmak üzere birden fazla katmana sahiptir [34, 35, 36, 37]. Evrişim ve tam bağlantılı katmanların parametreleri vardır ancak havuzlama ve ReLU katmanlarının parametreleri yoktur.



Şekil 2. Evrişimli Sinir Ağ Katmanları (Convolutional Neural Network Layers) [38]

Önceden eğitilmiş bir derin evrişimli sinir ağı modelinin farklı bir görev için yeni girdi verileriyle yeniden eğitime tabi tutulduğu öğrenme tekniğine transfer öğrenme denir. Geleneksel makine öğrenme teknikleri, her görevi en baştan öğrenmeye çalışırken, transfer öğrenme önceki görevlerden elde ettiği bilgileri yeni bir görevi öğrenme hedefine başarıyla aktarır [39]. Çok fazla zaman ve maliyet gerektiren yeni bir modeli baştan inşa etmek yerine, transfer öğrenme tekniğinin modelin performansını etkilemeden yeniden kullanılması literatürde birçok çalışmada ispatlanmıştır.

Evrişimli Sinir Ağları giriş ve ara katmanlar veri kümesinin düşük seviye özelliklerini öğrenirken son katmanlar daha spesifik özelliklerini öğrenir. Dolayısıyla giriş ve ara katmanlar korunurken spesifik özelliklerin öğrenildiği son katmanlar probleme uygun şekilde düzenlenip, mevcut veri setiyle eğiterek yeni bir model hızlı bir şekilde elde edilebilir [40, 41]. Bu yöntemde aktarılan şey temel olarak parametrelerin başlangıç değerleridir. Şekil 3'teki gibi tam bağlantılı katman dışındaki katmanları aktarmak en yaygın transfer öğrenme yöntemidir.




Şekil 3. Çalışmada kullanılan transfer öğrenme yöntemi (Transfer learning method used in the study) [42]

Bu çalışmada da transfer öğrenme yöntemi olarak bu yöntem tercih edilmiş ve bir milyondan fazla görüntü içeren ImageNet veri kümesi üzerinde eğitilmiş ResNet50 modeli kullanılmıştır [43, 44, 45]. ResNet-50

mimarisi, eğitim sırasında meydana gelebilecek gradyan kaybolması veya patlaması sorunlarına çözüm getirmesi amacıyla He ve arkadaşları tarafından önerilmiştir [43]. ResNet50 mimarisi bir 7×7 evrişim katman, bir

maksimum havuzlama katmanı, bir ortalama havuzlama katmanı ve 16 artık blok içerir. Her blok bir adet 1×1 , bir adet 3×3 ve bir adet 1×1 evrişim katman içerir. Son


bloğun çıkışı, tahmini sağlamak için 1000 nöronlu bir tam bağlantılı katmanına bağlanır [43]. ResNet-50 mimarisinin ağ yapısı Şekil 4'te verilmiştir.



Şekil 4. ResNet-50 Mimarisi (ResNet-50 Architecture)


3.2. Veri Hazırlama ve Önişleme (Data Preparation and Pre-processing)

Çalışma kapsamında PAS South East Europe'un her yıl kablo demeti üretiminde bağlantı şeklini kullandığı üç farklı sokette insan faktörü ile yapılan montaj ve kalite kontrol sürecinde karşılaşılan yanlış sıralama hatası üzerine odaklanılmıştır. Yanlış sıralama kabloların priz yuvasına yerleştirilirken doğru sıralamanın yapılmamasıyla meydana gelen durumdur. Bu hata durumu yanlış renk ve boş priz hatalarını içermektedir. Aşağıdaki şekillerde üç farklı sokete ait doğru sıralama ve değişik hatalı sıralama durumlarını içeren görseller verilmiştir.




Şekil 5. S1 kodlu soketin örnek sıralama hataları (Sample sequencing errors for socket code S1)

Şekil 5a on priz yuvalı birinci sokete ait hatasız sıralamadır. Şekil 5b kahverengi-siyah çapraz renk hatası, Şekil 5c turuncu-kırmızı çapraz renk hatası, Şekil 5d kahverengi-turuncu ikilisi ile siyah-kırmızı ikilisi çapraz renk hatası, Şekil 5e ise boş priz yuvası nedeniyle mavi, beyaz ve sarılı grubun birer sola kaymasıyla oluşan boş priz hatasıdır.



Şekil 6. S2 kodlu soketin örnek sıralama hataları (Sample sequencing errors for socket code S1)

Şekil 6a sekiz priz yuvalı ikinci sokete ait hatasız sıralamadır. Şekil 6b beyaz-sarı çapraz renk hatası, Şekil 6c kahverengi-siyah çapraz renk hatası, Şekil 6d turuncu-kırmızı çapraz renk hatası, Şekil 6e ise boş priz yuvası nedeniyle kırmızı kabloların bir sola kaymasıyla oluşan boş priz hatasıdır.



Şekil 7. S3 kodlu soketin örnek sıralama hataları (Sample sequencing errors for socket code S1)


Şekil 7a sekiz priz yuvalı üçüncü sokete ait hatasız sıralamadır. Şekil 7b mavi-siyah çapraz renk hatası, Şekil 7c turuncu-kırmızı çapraz renk hatası, Şekil 7d ise boş priz yuvası nedeniyle sarı kabloların bir sağa kaymasıyla oluşan boş priz hatasıdır.

Söz konusu soketlerde montaj sonrası kontrol sürecinde insan faktörü ile yapılan görsel kontrol hatalarının önüne geçmek ve süreci daha hızlandırmak için çalışmada önerilen evrişimli sinir ağının eğitiminde kullanmak amacıyla bir veri seti oluşturulmuştur. Veri seti oluşturmak ve daha sonra kalite kontrol sürecinde kullanılmak için Şekil 8'deki bilgisayara bağlı bir kamera ve üç farklı soket fişkürlerinden oluşan bir düzenek tasarlanmıştır.

Veri setinin oluşturulması sürecinde birinci aşamada personel, montajlanmış ürünün görsel kontrolünü yeterince uzun bir sürede dikkatlice yaparak ürünün hatalı veya hatasız durumunu belirlemiştir. Veri seti oluşturmak için hazırlanmış yazılımın arayüzüne soket tip kodunu (S1, S2, S3) ve aşağıda verilen durum kodunu işaretlemiştir.

- Hatasız (H0)
- Yanlış Renk (H1)
- Boş Priz Hatası (H2)

Daha sonra Şekil 8b'deki söz konusu soket için tasarlanmış fişküre soket yerleştirilip masa üstünde bulunan Şekil 8c'deki butona basarak fotoğraflanmıştır. Yazılıma girilen soket tip kodu doğrultusunda; fotoğraf soket tipine uygun olarak önceden belirlenen noktalardan Şekil 9'daki gibi kesilmiştir. Bu işlemin sağlıklı gerçekleşebilmesi için kamera ve soket fişkürü arasındaki mesafe fotoğraf verisini hazırlama, gerçek montaj ve kalite kontrol durumları göz önünde bulundurularak sabitlenmiştir.



Şekil 8. Bilgisayara bağlı kamera ve fişüstü düzeneği (Camera and fixture assembly connected to the computer.)



Şekil 9. Soket tipine uygun fotoğraflanarak kesilen veri örneği (Photographed data sample cut according to the socket type.)

Son aşamada ise görsel, veri seti için yazılmış program girilen durum bilgisi doğrultusunda; eğer hatasız ise soket kodu ile aynı isimli (S1, S2 veya S3) klasörün altındaki H0 klasörüne, hatalı ise ilgili hata klasörüne (H1, H2,) kaydedilmiştir.

Veri toplama süreci 27 ay olup bu süre sonunda yukarıdaki düzenek aracılığıyla 11755 adet sokete ait hatalı durum verileri toplanmıştır. Daha önceki yıllarda kalite kontrol birimi tarafından toplanmış 1329 görsel ve firma müşterilerden gönderilen 459 görsel de veri setine eklenmiştir. Bunun yanı sıra hatalı olarak belirlenmiş fakat görselleştirilmeyen atıl durumdaki 1451 soket de görselleştirilerek veri setine eklenmiştir. Ayrıca soket montajında karşılaşılan ve bu çalışmanın kapsamı dışında tutulan yalıtım sorunu, pimi ters veya yarım yerleştirme gibi 5162 adet hatalı ürün toplanmış, veri setini dengelemek ve veri artırmak amacıyla çalışma kapsamındaki hatalı durumlar simüle edilerek yeniden montajlanmıştır. Veri setinin dengeli olabilmesi için her soket tipindeki hatalı durumların ortalaması alınarak örnek veri setine toplam 10078 hatasız durum görseli eklenmiştir. Oluşturulan veri seti 20156 adet hatalı, 10078 adet hatasız olmak üzere toplam 30234 adet görsel içermektedir. Çizelge 1'de oluşturulan veri seti verilmiştir.

Çizelge 1. Veri Seti (Dataset)


	Soket Tip (S1)	Soket Tip (S2)	Soket Tip (S3)
Hatasız (H0)	3377	3343	3358
Yanlış Renk (H1)	3438	3398	3414
Boş Pin Yuva Hatası (H2)	3316	3288	3302

Önerilen derin öğrenme yöntemi; veri toplama, veri ön işleme, veri bölme, model eğitimi ve değerlendirme işlem adımlarından oluşmaktadır. Araştırmada kullanılan donanım; Intel i9-12900H CPU, NVIDIA GeForce RTX2080Ti GPU ve 32 GB RAM'dir. Uygulama Matlab Programı ve Python kodlama dili ile geliştirilmiştir. Uygulanan tüm modeller için Matlab Toolbox'ları Keras ve matplotlib kütüphaneleri kullanılmıştır.

4. DENEYSEL ÇALIŞMA (EXPERIMENTAL STUDY)

Ağların eğitiminde veri seti, eğitim ve test veri seti olmak üzere iki gruba ayrılır. Literatürde eğitim ve test veri setinin tüm veri setini temsil etmesi için geliştirilen çeşitli yöntemler mevcuttur. Çalışmada literatürde yaygın olarak kullanılan K-katlamalı Çapraz doğrulama (K-fold Cross Validation) [46] yöntemi kullanılmıştır. Bu yöntemde; Şekil 10'daki gibi veri seti k parçaya ayrılır, ağ k-1 parça veriyle eğitilirken, kalan veri test için kullanılır ve süreç k defa tekrarlanır [40].

Bu çalışmada k iterasyon sayısı 10 seçilmiştir. K-fold Cross Validation yönteminin kullanıldığı her süreçte ağ 10'ar defa eğitilmiş, test edilmiş ve sonuçlar kaydedilmiştir.



Şekil 10. K-katlamalı Çapraz Doğrulama (K-fold Cross Validation) [46]


Bununla birlikte K-fold Cross Validation yöntemi uygulandıktan sonra veri seti karıştırılarak söz konusu yöntem döngüsel olarak 10 defa uygulanmıştır. Çalışmada verilen sonuçlar eğitim ve test sürecinde elde edilen ortalama değerlerdir.

ResNet-50 modelinin son katmanı hariç diğer katmanların parametreleri ImageNet kullanılarak

başlatılmıştır. Modelin son katmanı, 1000 sınıf için tam bağlantılı bir katmandır. Söz konusu katman kaldırılarak yerine üç tam bağlantılı katman yerleştirilmiştir. Bu katmanlardan;

- İlk tam bağlantılı katman 2048 hücreden oluşmaktadır. Katmanın transfer fonksiyonu ReLU'dur.

- İkinci tam bağlantılı katman ise 4096 hücreden oluşur ve transfer fonksiyonu ReLU'dur.
- Son tam bağlantılı katman da 9 hücreden oluşur ve transfer fonksiyonu softmax'tır.



Şekil 11. Çalışmada önerilen modeli (The model proposed in the study)

Ağ eğitiminde aşırı uyumu kontrol etmenin bir yolu kısıtlar koyarak ağırlıkların küçük değerlerde kalmasını sağlayarak ağırlıkların dağılımını düzenli hale getirmektir. Bu yöntemle ağırlıkların düzenlenmesi denir. L_1 ve L_2 düzenlenmesi olarak iki şekilde gerçekleştirilir. Çalışmamızda ağırlık azalımı (weight decay) olarak adlandırılan L_2 düzenlenmesi birinci (fc, 2048) ve ikinci (fc, 4096) katmanda düzenleme katsayısı 0.001 alınarak uygulanmıştır.

İletim sönümü (dropout) sinir ağlarının düzenlenmesinde kullanılan etkin bir tekniktir [47]. Eğitim esnasında iletim sönümü bir katsayıyla belirlenir. Belirlenen katsayıya göre uygulandığı katmandaki öğrendiği bilgilerin bir bölümünü rastgele sıfırlar. Söz konusu katsayı 0.2 ile 0.5 arasında bir değer olup çalışmamızda deneysel çalışmalar sonucunda 0.4 olarak belirlenmiştir.

Modelimizde ağırlıkları güncellemek için tek bir öğrenme oranı kullanmak yerine Adam algoritması kullanılarak farklı parametreler için bağımsız uyarlanabilir öğrenme oranları üretilmesi sağlanmıştır. Uyarlanırlı moment kestirimi olarak adlandırılan Adam (Adaptive moment estimation); momentum eniyilemesi gibi geçmiş gradyanların üstel olarak azalan ortalamasını takip ederken, RMSProp gibi karesi alınmış geçmiş gradyanların üstel olarak azalan ortalamasını takip eder [48, 49]. Algoritmanın tanımı aşağıdaki gibidir:

$$w_{t+1} = w_t - \frac{a}{\sqrt{\hat{S}_t + \epsilon}} \cdot \hat{V}_t \quad (1)$$

$$\hat{V}_t = \frac{v_t}{1 - \beta_1^t} \quad (2)$$

$$\hat{S}_t = \frac{s_t}{1 - \beta_2^t} \quad (3)$$

$$V_t = \beta_1 V_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial w_t} \quad (4)$$

$$S_t = \beta_2 S_{t-1} + (1 - \beta_2) \left[\frac{\partial L}{\partial w_t} \right]^2 \quad (5)$$

Denklemlerdeki; S ve V değerleri 0 ile başlatılırken, ölçekleyen azalış hiper parametresi β_2 genellikle 0.999,

momentum azalış hiper parametresi β_1 0.9, düzenleme terimi C ise 10^{-7} gibi bir değerle başlatılır. Adam, uyarlanırlı öğrenme oranı algoritması olduğundan, öğrenme oranı hiper parametresi daha az ayarlanması gerekir ve genellikle de 0.001 gibi bir değerle başlatılır [48, 50, 51].

Çalışmada kategorik çok sınıflı sınıflandırma problemleri için bir hata ölçüsü olarak kullanılan çapraz entropi kullanılmıştır. Çapraz entropi kayıp fonksiyonu [52, 53], gerçek ve tahmin edilen olasılık dağılımları arasındaki farkları değerlendirerek tahmin doğruluğunu artırmak için yaygın olarak kullanılmaktadır. Bu teknik yalnızca bir sonucun tahmin edilen olasılığına odaklanır ve değeri yeterince önemli olduğu sürece tahmin sonucu doğru kabul edilebilir. Çapraz entropi kayıp fonksiyonunun tanımı aşağıda verilmiştir:


$$H(p, r) = - \sum_i p(x_i) * \log(r(x_i)) \quad (6)$$

Çizelge 2. Parametre değerleri ve yöntemler (Parameter values and methods)

Parametreler / Yöntemler	Değer
K-katlamalı çapraz doğrulama	k=10
L_2 düzenlenmesi	0.001
İletim sönümü	0.4
Optimizör	Adam
β_1	0.9
β_2	0.999
Düzenleme terimi C	10^{-7}
Öğrenme oranı	0.001
Kayıp Fonksiyonu	Çapraz Entropi
Yığın boyutu	32
Epok sayısı	40

Çalışmada; Karışıklık matrisi (Confusion Matrix), doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1-Skoru (F1-Score) değerlendirme göstergeleri kullanarak çalışma sonuçları

değerlendirilmiştir [54, 55]. Karışıklık matrisi bir sınıflandırma problemindeki tahmin sonuçlarının özetini sunan tablodur. Karışıklık matrisi sayesinde tahmin edilen değerlerin gerçek değerlerle kıyası yapılabilmektedir. Karışıklık matrisi sınıflandırma problemlerinde, modelin performansını tanımlamak için literatürde sıklıkla kullanılmaktadır.



Şekil 12. Karışıklık Matrisi (Confusion Matrix)

Karışıklık matrisindeki semboller, ikili bir sınıflandırma problemindeki Doğru Pozitif (DP), Yanlış Pozitif (YP), Yanlış Negatif (YN) ve Doğru Negatif (DN) durumların sayısını temsil eder. Değerlendirme için kullanılan doğruluk, kesinlik, geri çağırma ve F1-Skoru formülleri aşağıda tanımlanmıştır [54, 55]:


$$\text{Doğruluk}(ACC) = (DP + DN) / (DP + YP + YN + DN) \quad (7)$$

$$\text{Kesinlik}(P) = DP / (DP + YP) \quad (8)$$

$$\text{Geri Çağırma}(R) = DP / (DP + YN) \quad (9)$$

$$\text{F1 Skoru} = 2 * (P * R) / (P + R) \quad (10)$$

Şekil 13 modelin eğitim ve test setlerindeki doğruluğunu göstermektedir. Eğitim başladığında modelin doğruluğu hızla artmış, beşinci epoch'ta %81.3'e, 20'nci epoch'ta %94.18'e, 30'uncu epoch'ta ise %97.83'e ulaşmıştır. Eğitim doğruluğu 36'nci epoch'ta %97.85'e ulaşarak eğitimin sonlandırıldığı 40'ınci epoch'a kadar bu değerde sabitlenmiştir. Eğri, modelin özelliklerinin çoğunu ilk 25 epoch içinde öğrendiğini ve soket montajındaki sıralama hatalarını iyi bir şekilde tanıdığını göstermektedir.



Şekil 13. Eğitim ve Test doğruluk grafiği (Training and Test accuracy graph)

Modelin eğitim doğruluğu %97.85 test doğruluğu ise %97.25'tir. Çalışmanın kesinlik, geri çağırma ve F1-Skoru değerlendirme göstergeleri Çizelge 3'te verilmiştir.

Çizelge 3. Değerlendirme Göstergeleri (Evaluation Indicators)


Değerlendirme Göstergeleri	Oran (%)
Kesinlik	97.239
Geri Çağırma	97.240
F1-Skoru	97.239

S1_H0	323 0,96	2 0,01	13 0,04	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
S1_H1	3 0,01	341 0,99	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
S1_H2	10 0,03	0 0,00	322 0,97	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00
S2_H0	0 0,00	0 0,00	0 0,00	319 0,96	3 0,01	12 0,04	0 0,00	0 0,00	0 0,00
S2_H1	0 0,00	0 0,00	0 0,00	0 0,00	340 1,00	0 0,00	0 0,00	0 0,00	0 0,00
S2_H2	0 0,00	0 0,00	0 0,00	11 0,03	0 0,00	318 0,97	0 0,00	0 0,00	0 0,00
S3_H0	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	322 0,96	4 0,01	10 0,03
S3_H1	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	3 0,01	338 0,99	0 0,00
S3_H2	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	0 0,00	12 0,04	0 0,00	318 0,96
	S1_H0	S1_H1	S1_H2	S2_H0	S2_H1	S2_H2	S3_H0	S3_H1	S3_H2

Şekil 14. Test sonucu elde edilen karışıklık matrisi (Confusion matrix obtained from the test result)


Test sonucu elde edilen Şekil 14'teki karışıklık matrisi incelendiğinde, çalışmanın hedeflerinden biri olan ağır soket türlerini ayırt edebilme hedefine ulaştığı görülmektedir. Karışıklık matrisinden çıkarılan diğer bir sonuç ise ağır çapraz renk karıştırma hatalarının tespitinde oldukça başarılı olduğudur. Soket 1'de bu değer %99, Soket 2'de %100 ve Soket 3'te ise %99'dur. Bu değerler çalışmanın hem eğitim hem de test doğruluk oranının üzerinde değerlerdir.

Bunun yanı sıra boş priz hata tespitinde ise çapraz renk hata tespitine göre daha az başarılı olduğu görülmektedir. Soket 1 ve Soket 2'de bu değer %97, Soket 3'te ise %96'dır. Bu değerler çalışmanın hem eğitim hem de test doğruluk oranının altında değerlerdir. Buradaki başarı oranının düşme nedeni fikstüre yerleştirilen soketlerin kablo aralıklarının mevcut fikstüre sabitlenememesinin kabloların bükülmesine ve bunun da boş priz yuvası aralığının daralmasına veya kaybolmasına yol açmasıdır. Örneğin Şekil 15'te kırmızı kablo sola ve sarı kablo sağa doğru bükülerek 8 numaralı boş priz yuvası alanının daralmasına neden olmuştur.



Şekil 15. Daralan boş priz yuvası aralığı (Narrowing empty socket gap)

Bu sorunun bir değer nedeni ise aydınlatma hatalarının neden olduğu gölge durumlarıdır. Şekil 16'da montaj masasına sol taraftan gelen ışık nedeniyle oluşan gölge durumları verilmiştir. Şekil 16a'da turuncu ve sarı kabloların gölgeleri sağ tarafa düşerek boş priz yuvası alanında siyah bir bölgenin oluşmasına neden olmuştur. Turuncu kabloların gölgesi 3 numaralı boş priz yuvası alanını tamamen işgal ederken sarı kabloların gölgesi 8 ve 9 numaralı boş priz yuvaları alanında siyah bir kablo izlenimi oluşmasına neden olmuştur. Aynı şekilde Şekil 16b'de ise başka bir sokette sarı kabloların gölgesi 7 numaralı boş priz yuvasında siyah bir kablo izlenimi oluşmasına neden olmaktadır.



Şekil 16. Aydınlatma kaynaklı hata durumları (Error cases caused by lighting)

5. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSION)

Bu çalışma ile üretim hatlarında kontrolü zor bir süreç olan soket montaj sürecinin belirli standarta kavuşması sağlanmış, insan kaynaklı hataların önüne geçilerek üretimde verim ve kalite artırılmıştır. Tamirat işlemleri minimize edilerek; navlun, hurda/fire gibi ek giderlerin de önüne geçilmiştir. Ayrıca çevreye verilen zararlar alt seviyelere çekilmiştir. Çalışmamız kablo demeti soket kablo sıralama hata tespitinde derin öğrenme yöntemlerinden evrişimli sinir ağlarının kullanıldığı literatürde tespit edebildiğimiz ilk çalışma olması açısından önemlidir. Önerdiğimiz yöntemde elde ettiği %97,25 test başarı oranı ilk hedef değerimiz olan %95'ten yukarıda bir değerdir. Fakat ikinci hedef değerimiz olan %100 başarı için ise referans niteliğindedir. Çalışma sonunda tespit ettiğimiz aşağıda açıklamaları verilen aydınlatma, fiş tür tasarımı, soket tipi ve soket kablo sıralaması bağımlılığı gibi kusurları giderecek ikinci çalışmamız için ise rehber niteliği taşımaktadır.

Çalışmada elde sonuçlardan hareketle kamera düzeneğinin olduğu ortamın aydınlatılmasının ağ başarısında oldukça önemli olduğu görülmüştür. Aşırı ve zayıf aydınlatma durumlarında elde edilen görsellerde kırmızı-turuncu, kahverengi-siyah renklerin bir birine yakın olduğu gözlemlenmiştir. Çevreden gelen ışığın gölgeye neden olarak boş priz yuvası tespitini zorlaştırdığı görülmüştür. Gözlemlenen bir diğer durum ise; fotoğrafı anında aşırı aydınlatma nedeniyle parlak ve yansıtıcı özelliği olan kablo yüzeylerinin komşu kablo yüzeylerini etkilemesidir. Özellikle beyaz kablo bu durumdan en çok etkilenen kablodur. Kamera düzeneğine ait aydınlatmanın soket üzerindeki ölçüm değeri 4100 lüks'tür. Söz konusu bu değer ek aydınlatmalar ile artırılarak ölçülmüş sistemim aşırı aydınlatma değeri 7200 lüks olarak belirlenmiştir. Zayıf aydınlatma alt sınırının belirlenmesi için kamera düzeneğinin aydınlatmasına müdahale edilerek soket üzerindeki aydınlatma değeri 1200 lüks değerine çekilmiş, bunun yanı sıra personelden veya ekipmanlardan kaylanacak gölge durumları oluşturularak zayıf aydınlatma alt sınırı 290 lüks olarak ölçülmüştür. En uygun ışık seviyesini yakalamak için çözüm olarak kamera-fiş tür düzeneğine bir ışık şiddeti ölçme devresi eklenmesine ve söz konusu devreden gelecek bilginin yazılıma aktararak sistemin bir parçası haline getirilmesine karar verilmiştir. Kamera-fiş tür düzeneğinin çevreden gelen aydınlatmalardan etkilenmemesi için ise ışık yalıtım düzeneği kurulmuştur. Bunlarla birlikte tasarlanacak yeni fiş tür düzeneğinde soket yuvasının yanı sıra kablolarında yerleştirilebileceği yuvaların olmasının özellikle boş priz yuvası tespitinde yardımcı olacağı ve ağ başarısını yukarı çekeceği görüşüne varılmıştır.

Çalışmada üretimde sıklıkla montajı yapılan üç soketin kablo bağlantı sıralaması üzerinde durulmuş ve üretimde kaliteyi artırmak için uzun süre veri toplanarak sorun çözülmüştür. Fakat kablo demeti üretiminde onlarca farklı soket ve her soketin farklı bağlantı sıralaması yapılmaktadır. Kablo demeti üretiminde kullanılan tüm soket bağlantılarının kalite standartını aynı düzeye getirmek için çalışma kapsamının genişletilmesi zorunlu bir durumdur. Fakat sektördeki yüksek hacimli, değişken ve hızlı üretim süreci göz önüne alındığında mevcut yöntemimizdeki veri toplama sürecinin getireceği zorluk aşırıdır. Bu nedenle önerilen yöntemi soket tipi ve soketin kablo sıralamasından bağımsız hale getirmek bir sonraki çalışma için ana hedef olarak belirlenmiştir. Bu amaçla çalışmalara başlanmış ve dikate değer oranda ilerleme kaydedilmiştir. Bu konudaki çalışmalar en kısa sürede sonuca ulaştırılarak paylaşılacaktır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Çalışma PAS South East Europe Sanayi ve Ticaret Limitet Şirketi Tekirdağ-Çerkezköy tesislerinde gerçekleştirilmiştir. Destek ve katkılarından dolayı idari, Ar-Ge ve üretimdeki tüm çalışanlara teşekkür ederiz.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Bahadır ELMAS: Deneyleri yapmış ve sonuçlarını analiz etmiştir.

Hakan KORMAZ: Deneyleri yapmış ve sonuçlarını analiz etmiştir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Fröhlig S., Piechulek N., Friedlein M., Süß-Wolf R., Schmidt L., Nguyen M. K. H. et al. "Innovative signal and power connection solutions for alternative powertrain concepts", *2020 10th International Electric Drives Production Conference (EDPC)*, Ludwigsburg, Germany, 1–7, (2020).
- [2] Nguyen H. G., Habiboglu R., Franke J., "Enabling deep learning using synthetic data: A case study for the automotive wiring harness manufacturing", *ScienceDirect*, 107: 1263-1268, (2022).
- [3] Wang H., Johansson B., "Deep Learning-Based Connector Detection for Robotized Assembly of Automotive Wire Harnesses", *2023 IEEE 19th International Conference on Automation Science and Engineering (CASE)*, Auckland New Zealand, 1-8, (2023).
- [4] Nguyen H. G., Franke J., "Deep learning-based optical inspection of rigid and deformable linear objects in wiring harnesses", *ScienceDirect*, 104: 1765–1770, (2021).
- [5] Trommnau J., Kühnle J., Siegert J., Inderka R., Bauernhansl T., "Overview of the State of the Art in the Production Process of Automotive Wire Harnesses, Current Research and Future Trends" *ScienceDirect*, 81: 387–392, (2019).
- [6] Kicki P., Bednarek M., Lembicz P., Mierzwia G., Szymko A., Kraft M., Walas K., "Interpretable Classification of Wiring Harness Branches with Deep Neural Networks", *Sensors*, 21(13): 4327, (2021).
- [7] Shrestha A., Mahmood A., "Review of Deep Learning Algorithms and Architectures", *IEEE Access*, 7: 53040–53065, (2019).
- [8] Meiners M., Mayr A., Franke J., "Process curve analysis with machine learning on the example of screw fastening and press-in processes", *Procedia CIRP*, 97: 166–171, (2021).
- [9] Nguyen H. G., Meiners M., Schmidt L., Franke J., "Deep learning-based automated optical inspection system for crimp connections", *2020 10th International Electric Drives Production Conference (EDPC)*, Ludwigsburg Germany, 1–5, (2020).
- [10] Mayr A., Kißkalt D., Meiners M., Lutz B., Schäfer F., Seidel R. et al. "Machine Learning in Production – Potentials, Challenges and Exemplary Applications" *Procedia CIRP*, 86: 49–54, (2019).
- [11] Deng J., Dong W., Socher R., Li L.-J., Li K., Fei-Fei L., "ImageNet: A large-scale hierarchical image database", *2009 IEEE Conference on Computer Vision and Pattern Recognition*, Miami USA, 248–255, (2009).
- [12] Ebayyeh A. A. R. M. A., Mousavi A., "A Review and Analysis of Automatic Optical Inspection and Quality Monitoring Methods in Electronics Industry", *IEEE Access*, 8: 183192–183271, (2020).
- [13] Parmar P., "Use of computer vision to detect tangles in tangled objects", *Image Information Processing (ICIIP-2013)*, Shimla India, 39–44, (2013).
- [14] Sun B., Chen F., Sasaki H., Fukuda T., "Robotic wiring harness assembly system for fault-tolerant electric connectors mating", *International Symposium on Micro-NanoMechatronics and Human Science*, Nagoya Japan, 202–205, (2010).
- [15] Lee W., Cao K., "Application of Machine Vision to Inspect a Wiring Harness". In *Proceedings of the 2019 IEEE International Conference on Industrial Cyber Physical Systems (ICPS)*, Taipei Taiwan, 457–460, (2019).
- [16] Mohandoss R., Ganapathy V., Ramasubbu R., Rohit D., "Image processing based automatic color inspection and detection of colored wires in electric cables", *International Journal of Applied Engineering Research*, 12: 611–617, (2017).
- [17] Zhou H., Li S., Lu Q., Qian J., "A Practical Solution to Deformable Linear Object Manipulation: A Case Study on Cable Harness Connection", *2020 5th International Conference on Advanced Robotics and Mechatronics (ICARM)*, Shenzhen, Chinap. 329–333, (2020).
- [18] Nguyen H. G., Meiners M., Schmidt L., Franke J., "Deep learning-based automated optical inspection system for crimp connections", *2020 10th International Electric Drives Production Conference (EDPC)*, Ludwigsburg Germany, 1–5, (2020).
- [19] Mou F., Wang B., Wu D., "Learning-based cable coupling effect modeling for robotic manipulation of heavy industrial cables", *Scientific Reports*, 12: 6036, (2022).
- [20] Thum G. W., Tang S. H., Ahmad S. A. et al. "Toward a Highly Accurate Classification of Underwater Cable Images via Deep Convolutional Neural Network", *Journal of Marine Science and Engineering*, 8: 924, (2020).
- [21] Zheng L., Liu X., An Z., et al., "A smart assistance system for cable assembly by combining wearable augmented reality with portable visual inspection", *Virtual Reality & Intelligent Hardware*, 2: 12–27, (2020).
- [22] Shi G., Jian W., "Wiring harness assembly detection system based on image processing technology", In *Proceedings of the 2011 International Conference on Electronics, Communications and Control (ICECC)*, Ningbo China, 2397–2400, (2011).
- [23] Salem F. M., "Recurrent Neural Networks: From Simple to Gated Architectures", *Springer*, 1st edition, ISBN-13: 978-3030899288, Berlin, (2022).
- [24] Ackley D., Hinton G., Sejnowski T., "A Learning Algorithm for Boltzmann Machines", *Cognitive Science*, 9(1):147–169, (1985).
- [25] Fischer A., Igel C., "An Introduction to Restricted Boltzmann Machines", *Progress in Pattern Recognition*,

- Image Analysis, Computer Vision, and Applications*, Buenos Aires Argentina, 14-16, (2012).
- [26] Al-jabery K. K., Obafemi-Ajayi T., Olbricht G. R., Wunsch II D. C., “Selected approaches to supervised learning”, Computational Learning Approaches to Data Analytics in Biomedical Applications, *Academic Press*, Cambridge, Massachusetts, (2019).
- [27] Zakeri A., Xia Y., Ravikumar N., Frangi A. F., “Deep learning for vision and representation learning”, Medical Image Analysis, *Academic Press*, (2023).
- [28] Fan J., Xu W., Wu Y., Gong Y., “Human tracking using convolutional neural networks”, *IEEE Transactions on Neural Networks*, 21: 1610-1623, (2010).
- [29] Toshev A., Szegedy C., “Deep -pose: Human pose estimation via deepneural networks”, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1653-1660, (2014).
- [30] Jaderberg M., Vedaldi A., Zisserman A., “Deep features for text spotting”, *Computer Vision-ECCV 2014*, Zurich, Switzerland, 512-528, (2014).
- [31] Zhao R., Ouyang W., Li H., Wang X., “Saliency detection by multi-context deep learning”, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston USA, (2015).
- [32] Donahue J., Jia Y., Vinyals O., Hoffman J., Zhang N., Tzeng E., Darrell T., “DeCAF: A deep convolutional activation feature for generic Visual Recognition”, *Proceedings of the 31st International Conference on Machine Learning*, Berkeley USA, 32(1): 647-655, (2014).
- [33] Farabet C., Couprie C., Najman L., LeCun Y., “Learning hierarchical features for scene labeling”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35: 1915-1929, (2013).
- [34] Lawrence S., Giles C. L., Tsoi A.C., Back A.D., “Face recognition: A convolutional neural-network approach”, *IEEE Transactions on Neural Networks*, 8:98-113, (1997).
- [35] Indolia S., Goswami A. K., Mishra S. P., Asopa P., “Conceptual Understanding of Convolutional Neural Network-A Deep Learning Approach”, *Procedia Computer Science*, 132: 679-688, (2018).
- [36] Yamashita R., Nishio M., Do R. K. G., Togashi K., “Convolutional neural networks: an overview and application in radiology”, *Insights Imaging*, 9: 611–629, (2018).
- [37] Baykal E., Doğan H., Ercin M. E., Ersoz S., Ekinci M., “Transfer learning with pre-trained deep convolutional neural networks for serous cell classification”, *Multimedia Tools and Applications*, 1-19, (2019).
- [38] Khan A., Rajendran P., Sidhu J. S. S., Thanigaiarasu S., Raja V., Al-Mdallal Q., “Convolutional neural network modeling and response surface analysis of compressible flow at sonic and supersonic Mach numbers”, *Alexandria Engineering Journal*, 65: 997-1029, (2023).
- [39] Pan S. J., Yang Q., “A survey on transfer learning”, *IEEE Transactions on Knowledge and Data Engineering*, 22: 1345-1359, (2010).
- [40] Chollet F., “Deep Learning with Python”, Second Edition, *Manning Publications*, ISBN-13: 978-1617294433, New York, (2022).
- [41] Elmas B., Türkiye'deki Kelebek Türlerinin Basamaklı Evrişimli Sinir Ağları ile Sınıflandırılması, *Konya Mühendislik Bilimleri Dergisi*, 9(3), 568-587, (2021).
- [42] Mathworks, <https://uk.mathworks.com/help/deeplearning/gs/get-started-with-transfer-learning.html>, Erişim Tarihi: 06.04.2024
- [43] He K., Zhang X., Ren S., Sun J., “Deep Residual Learning for Image Recognition”, *IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas United States, 770-778, (2016).
- [44] Theckedath D., Sedamkar R. R., “Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks”, *Springer Nature Computer Science*, 79: 1-7, (2020).
- [45] Karadağ B., Arı A. ve Karadağ M., “Derin öğrenme modellerinin sinirsel stil aktarımı performanslarının karşılaştırılması”, *Politeknik Dergisi*, 24(4): 1611-1622, (2021).
- [46] Sontakke S. A., Dani R., Lohokare J., Shivagaje P., “Classification of Cardiotocography Signals using Machine Learning”, *Intelligent Systems Conference*, London UK, (2018).
- [47] Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., “Dropout: A Simple Way to Prevent Neural Networks from Overfitting”, *Journal of Machine Learning Research*, 15:1929-1958, (2014).
- [48] Geron A., “Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems”, Second Edition, *O'Reilly Publications*, California (2019).
- [49] Teke M., Civelek Z. ve Tümay M., “Glakom ve Katarakt Hastalığının Derin Öğrenme Modelleri ile Teşhisi”, *Politeknik Dergisi*, 27(5): 1813-1821, (2024).
- [50] Zeiler M. D., “ADADELTA: an adaptive learning rate method”. *arXiv preprint arXiv:1212.5701*, (2012).
- [51] Lydia A. A., Francis F. S., “Adagrad: An Optimizer for Stochastic Gradient Descent”, *International Journal of Information And Computing Science*, 6: 599-568, (2019).
- [52] Jamin A., Humeau-Heurtier A., “(Multiscale) Cross-Entropy Methods: A Review”, *Entropy*, 22(1): 45, (2020).
- [53] Köroğlu B., “Cascaded Cross Entropy-Based Search Result Diversification”, Yüksek Lisans, *Bilkent Üniversitesi Fen Bilimleri Enstitüsü*, (2012).
- [54] Kaycı B., Demir B. E. and Demir F., “Deep learning based fault detection and diagnosis in photovoltaic system using thermal images acquired by UAV”, *Politeknik Dergisi*, 27(1): 91-99, (2024).
- [55] Geze R. A. ve Akbaş A. “Derin öğrenme algoritmalarını kullanarak kumaş kusurlarının tespiti ve sınıflandırılması”, *Politeknik Dergisi*, 27(1): 371-378, (2024).