

# Yarı-gözetimli Görüntü Kümeleme ile Baskılı Devre Kartı Bileşeni Tanıma

## PCB Component Recognition with Semi-supervised Image Clustering

Ahmet Emin ÜNAL, Kasım TAŞDEMİR ve Akif BAHÇEBAŞI

Bilgisayar Mühendisliği

Abdullah Gül Üniversitesi

Kayseri, Türkiye

ahmetemin.unal@agu.edu.tr, kasim.tasdemir@agu.edu.tr, akif.bahcebasi@agu.edu.tr

**Özetçe**—Baskılı devre kartlarının otomatik muayene sistemlerinde yüzeye monteli cihazların sınıflandırılması önemli bir rol oynamaktadır. Bu bileşenlerin etiketlendiği halka açık veri kümelerinin az sayıda olması ve bu veri kümelerinde yüksek sınıf içi varyans bulunması gözetimli yaklaşımlardan yeterince verim alınamamasına neden olmuştur. Bu çalışmada az sayıda etiketli veri kullanılarak, gözetimsiz kümeleme sistemleriyle güçlendirilen yarı-gözetimli bir derin öğrenme yöntemi önerilmiştir. Elde edilen sonuçlar, mevcut araştırma sonuçları ve gözetimli sistemler ile karşılaştırılmıştır. En iyileştirilmiş ayarlarda mevcut sınıflandırma yöntemlerinden daha yüksek doğruluk oranlarına ulaşılmıştır.

**Anahtar Kelimeler**—yarı-gözetimli görsel kümeleme, derin öğrenme, baskılı devre kartı, yüzeye monteli cihaz, otomatik görsel muayene sistemi.


**Abstract**—Classification of surface mounted devices plays an important role on automated inspection systems of printed component board production. Limited number of publicly available datasets which the components are labeled and high intraclass variance in these datasets causes the supervised approaches to be inefficient. In this study a deep learning method, enhanced with an unsupervised clustering system, which uses a small set of labeled data is proposed. The method compared with the current studies and the supervised systems. Most optimized setting reached high accuracy results by outrunning current classification methods.

**Keywords**—semi-supervised image clustering, deep learning, printed circuit board, surface-mount device, automated vision inspection system.

### I. GİRİŞ

Baskılı devre kartlarının (PCB) imalat hatlarının kalite kontrol aşamalarında bu kartlarda yapım anında gerçekleşmiş olabilecek hatalar denetlenmektedir. Bu denetlemeler geçmiş senelerde insanlar tarafından yapılıyor olsa da, bu sistemler de teknolojinin gelişimine ayak uydurarak, otomatikleştirilmeye başlanmıştır [1].

Bu denetleme noktalarının otomatikleştirilmesinde özellikle kullanılan teknolojilerden birisi bilgisayar görüşüdür. İmalat hatlarından geçen kartların üzerinde olan hataların



Şekil 1: Model, önceden kırılarak çıkarılmış ve ön işlemeden geçirilmiş bileşen görselinin hangi kümeyle ait olduğunu hesaplayıp tahmin sonucunu vermektedir.

nedenleri genellikle ya lehimleme işlemlerinde ortaya çıkan açık lehim noktası, lehim köprüleme, ve gözenekli lehim gibi sıkıntılar ya da kartlara, yüzeye monteli cihaz (Surface Mounted Device) olarak adlandırılan, elektronik bileşenlerin yerleştirilmesi işlemlerinde ortaya çıkan bileşenin yatay veya dikey kayması, dönmesi, eksik bileşen, ve yanlış bileşen gibi sıkıntılardır. Devre kartlarının görsel muayene sistemlerinde doğru bileşenlerin yaş lehim macununa doğru şekilde yerleştirildiğinden emin olmak gerekmektedir. Bahsedilen bu sıkıntılar bilgisayar görüşü algoritmalarından faydalanarak belirlenmekte ve kısa devre yaşanması gibi bu kartların kullanılmasında ortaya çıkabilecek olası problemlerin önüne geçilmektedir. [2]–[4]

Geçtiğimiz yıllarda görüntü işleme teknolojileri ile PCB üzerine kapsamlı çalışmalar yapılmıştır. Mevcut araştırmalar genellikle kartların iletim hatlarında bulunan kusurları tespit etmeye çalışmaktadır ve bileşenlerden kaynaklanan hataların belirlenmesi üzerine ya da başka nedenler ile bileşenlerin saptanması veya sınıflandırılması adına yapılan çalışmalar bizim dahilinde yetersiz kalmıştır.

Bu hataların saptanması için bileşenlerin kart üzerindeki konumlarını hesaplayarak analiz edilen sistemlerde bu konumların yüksek doğrulukta hesaplanması gerekmektedir. Mevcut nesne saptama algoritmaları yapıları bakımından genellikle ikiye ayrılmaktadırlar [5]. Regresyon temelli algoritmalar daha hızlı çalışmaktadır fakat doğruluk oranları daha düşüktür. Bu grubun en gelişkin teknolojilerden YOLO gibi algoritmaların kullanılması için etiketlenmiş bol miktarda görsel bileşen veri-

sine ihtiyaç vardır ki elimizdeki bu spesifik konu üzerine yeterli etiketlenmiş veri bulunması zor bir durumdur. Diğer yöntem grubu ise sınıflandırma temelli algoritmaları ve özet olarak mevcut nesne tanıma algoritmaları ile lokalizasyon algoritmalarının birleştirilmesi ile oluşmaktadır. Bir önceki gruptaki algoritmalarından daha yavaş çalışsalar da daha yüksek doğruluk oranlarına sahiptirler. Ayrıca genel resimlerde sınıflandırma algoritmalarının çalışması için gerekli ilgi bölgelerinin çıkarılması zaman alıcı olsa da baskılı devre kartlarının tek renkli yapısı, bileşen olma olasılığı olan bölgelerin seçilmesi için, basit görüntü işleme algoritmalarının ya da mevcut bölge çıkarma algoritmalarının [6] kullanılmasına olanak sağlar. Böylece geliştirilecek sınıflandırma sistemleri regresyon temelli algoritmalar için gerekli görsel veri etiketlerini oluşturmak için de kullanılabilirler [7].

Bu çalışmada Şekil 1'de görüldüğü gibi PCB görsel veri kümeleri ile bileşenlerin sınıflandırılması adına bir çalışma gerçekleştirilecektir. Literatürde bu konuda olan çalışmalar bilginiz dahilinde zayıf kalmıştır. Hedefimiz gözetimsiz bir şekilde resimleri kümeleyerek, yarı-gözetimli şekilde modeli iyileştirmek ve kümeleri mevcut sınıflar ile eşleştirmektir. Çalışmalar alt başlığında araştırma sonuçları, Yöntem alt başlığında oluşturulan deneyler, Deneyler alt başlığında deneylerin sonuçları ve geliştirmeler, Sonuç alt başlığında ise çıkarımlar anlatılmıştır.

## II. ÇALIŞMALAR

PCB odaklı çalışmalar için kullanıma açılmış mevcut görsel veri tabanları sınırlıdır. Bu veri tabanlarının çoğu lehim kaynaklı problemlere odaklanmakta ya da kartların imalat hattı üzerinde saptanması için oluşturulmuş görüntü ve maske çiftlerinden oluşmaktadır (DeepPCB, PCBA-defect, PCB-DSLR). PCB bileşenlerinin etiketli ve kırılmış olarak bulunduğu sayılı veri kümesinde ise eksiklikler göze çarpmaktadır. Genel kullanıma açık olarak paylaşılmış FICS-PCB [8] veri kümesi DSLR(digital single-lens reflex) kamera ve dijital optik mikroskop ile farklı yakınlaştırma ve ışıklandırma ayarlarında kuş-bakışı çekilen fotoğraflardan bileşenlerin kırılması ve etiketlenmesi işlemi gerçekleştirilerek oluşturulmuştur. Bu veri kümesinde düşük sayıda etiketlenmiş görsele (toplamda yaklaşık 8000 DSLR görsel), kartlarda bulunan bileşen türlerinin sayısının orantısızlığından kaynaklanan dengesiz oranlarda sınıf örneklerine ve aynı kategoride bulunan bileşenlerde marka ve alt tiplerinden kaynaklanan şekil bakımından ve görüntü boyutu bakımından yüksek varyasyona (domain shift) rastlanmaktadır.

Bileşenlerin etiketlenmesinde karşılaşılan zorluklar az sayıda görsel veri kümesinin oluşturulmasına neden olmuştur. Genel görsel veri kümelerinin etiketlenmesi uzmanlık gerektirmezken, PCB üzerinde bulunan bu bileşenlerin her birinin şekillerine ve boyutlarına göre ek açıklama (annotation) eklenmesi ve spesifik öğelerin sınıflarına göre etiketlenmesi uzmanlık gerektiren bir işlemdir ve maliyeti arttırmaktadır [9]. Geleneksel görüntü işleme teknikleri belirtilen yüksek varyasyonda bileşen görüntüsü içeren veri kümelerini geliştirememekte, yeni ve gelişmiş derin öğrenme yöntemlerinin karşısında yetersiz kalmaktadır.

Bileşenlerin etiketlendiği veri kümelerinin nadirliğinden dolayı bu çalışmada bileşen parçalarını sınıflandırmak için



Şekil 2: Çeşitli Sığaç Örnekleri.

tam gözetimli yaklaşımlardan kaçınılmıştır. Elimizdeki veri kümesinin etiketlerinin tamamı kullanılmadan yarı gözetimli bir kümeleme işlemi gerçekleştirilecektir. İşlem bittikten sonra, önceden ayrılmış az sayıda ve etiketlenmiş bir görsel set ile kümeler karşılıklı gelen sınıflarına ayrılınarak (pseudo-labeling) eğitimde kullanılmayan etiketler ile validasyon ve test performans hesaplamaları yapılacaktır. Veri kümesi hazırlanırken belirlenmeyen varyasyonların (alt sınıfların) algoritma tarafından keşfedilmesi, örneklerin tamamında etikete ihtiyaç duyulmadığı için daha çok veri kullanılabilmesi gibi durumlar, bahsi geçen veri kümelerinin zafiyetlerini öterek sınıflandırma işleminin yüksek başarıda gerçekleşmesini sağlayacaktır.

Bahsedilen sınırlı PCB veri kümeleri arasından FICS-PCB [8] veri kümesi genel kullanıma açık en fazla veri örneği içeren bileşen etiketli veri kümesi olduğu için analiz edilecek bileşenlerin kümelmesi için kullanılacaktır. Tutarlı ve pahalı muayene sistemleri içermeyen imalat hatlarındaki genel düzeneklere uygun olması göz önünde bulundurularak sadece DSLR kamera ile çekilmiş bileşen fotoğrafları kullanılacaktır.

Veri kümesindeki bileşen görselleri, sınıf ismi ve miktarı belirtilecek şekilde: Sığaçlar, 3453; Dirençler, 3348; Tümlüşik Devreler, 542; Diyotlar, 195; İndüktörler, 182; Geçirgeçler, 165 olarak altı ayrı sınıfa ayrılmıştır. Veri kümesinde dengesiz bir yapı gözlemlenmektedir. Veri kümesindeki bileşen görsellerinin boyutları, alana göre sıralandığında,  $1523 \times 1543$  ile  $31 \times 46$  arasında, çeşitli en-boy oranları ile büyük miktarda değişmektedir. Veri kümesi incelendiğinde farklı yüzeye monteli cihaz paketleme (SMD packaging) türlerinden kaynaklanan sınıf içi varyansın yüksek olduğu göze çarpmaktadır. Örneğin sığaç sınıfı altında etiketlenmemiş polyeşter, seramik, elektrolitik, mkt ve smt gibi süper sınıf örneklerine rastlanmaktadır (Şekil 2).

Kullanılabilecek en iyi yöntemi seçmek için güncel incelemelerden birine [10] danışılmıştır. Bu incelemede yarı-gözetimli, kendi-gözetimli ve gözetimsiz görsel sınıflandırma algoritmaları karşılaştırılmaktadır. Araştırmada gerçek hayat uygulamalarında derin öğrenme algoritmaları için çok miktarda etiketli veri bulunmasının zorlu ve elverişsiz olduğuna işaret edilmektedir. Etiketsiz veri kullanın ya da etikete tamamen bağımlı olmayan, yakın zaman önce ortaya çıkmış, algoritmaları odaklanılmıştır. Araştırmacıların çıkardığı sonuca göre, geliştirilmiş en yetkin yöntemlerde gerçek dünyaya uyarlanabilirliği ve doğruluk payı eski yöntemlere göre artmakla kalmamakta, yöntemlerin gözetim derecesi ve veri etiketlerine olan ihtiyaç da azalmaktadır. Araştırmada paylaşılan yöntemlerin çoğunluğu yakın fikirler ortaya atarken bazıları bu fikirlerin kombinasyonları ile daha yüksek performans sonuçlar elde etmektedirler. IIC (Invariant Information Clustering) [11] tamamen gözetimsiz veya yarı-gözetimli olarak çalışabilen, farklı gözetimsiz yöntemlerin birleşimleri ile geliştirilmiş, en yeni ve yetkin yöntemlerden biridir. Yapılan karşılaştırmada görülen tek-sahne-gözetimsiz (one-stage-unsupervised) özel-

liği göz önünde bulundurularak ve yeni bir yöntem olmasına karşın geniş kullanımı olan bir yöntem olmasından dolayı bu çalışmada değerlendirilmeye karar verilmiştir.

### III. YÖNTEM

Bu çalışmada bileşen görsellerini kümelemek için yarı-gözetimli bir algoritma olan IIC kullanılmaya karar verilmiştir. Gözetimsiz yöntemler arasında ileri düzey tekniklerden biri olan bu yöntem, yarı-gözetimli ince ayarlama (semi-supervised fine-tuning) ile çok kullanılan genel görsel veri kümeleri arasında (CIFAR-10, CIFAR-100, STL-10), benzer algoritmalara kıyasla, yüksek doğruluk payı yakaladığı görülmektedir.

IIC algoritmasında temel olarak kendi-gözetimli (self-supervised) öznetelik öğrenmesi (feature learning) ile tek bir örnek görsele uygulanan rasgele dönüşümler ile oluşturulan yapay resim çiftleri arasındaki karşılıklı bilginin (mutual information) artırılması sağlanmaktadır. Bu dönüşümler, rasgele uygulanan kaydırma, döndürme, kırpma ve ölçekleme işlemleri; renk, parlaklık, karşıtlık, ve ton değişimleri sağlanarak oluşturulmaktadır.

Derin Evrişimli sinir ağlarından (CNN) oluşan temel model ile görsellerden öznetelik çıkarımı gerçekleştirilmektedir. Çıkarılan öznetelikler k-merkezli öbekleme (k-means clustering) gibi geleneksel kümeleme algoritmaları ile işlendiğinde oluşan kümelere dejenere sonuçlar gözlemlenmektedir. Bu durum bir kümenin baskınlığından dolayı tek bir kümenin oluşması ya da kümelerin kaybolmasına neden olmaktadır. IIC algoritmasında bu öznetelikler alt başlık (sub-head) olarak adlandırılan tamamen bağlı sinir ağlarına iletilerek sınıf sayısı boyutunda oluşturulan semantik vektörler çıktı olarak alınmaktadır. Böylece elde edilen bulanık kümeleme sonuçları, dejenere sonuçlar elde edilmesinin önüne geçmektedir. [11]

Araştırmacılar modelde kullanılabilir çeşitli geliştirmeler önermişlerdir. Bu geliştirmeler temel modelin farklı varyasyonlarını denemek (ResNet ve VGGNet benzeri modeller), birden fazla alt başlığı tek bir toptan veri (batch) içinde eğiterek modele varyasyon kazandırıp en optimal sonuca ulaşmak, tek bir toptan veri içerisinde yapay örnek tekrarları gerçekleştirmek, rasgele transformasyonların üst değişkenlerini (hyperparameters) eniyileştirmek, aşırı kümeleme (over-clustering) yapılan başka bir ek baş (auxiliary head) model ekleyerek sınıf içi benzerliklerin analiz edilmesi, ve son olarak da yarı-gözetimli bir yöntem olan ince ayarlama yani ara dönemlerde (epoch) modele sadece etiketli parçanın gözetimli bir şekilde beslenerek eniyileştirilmesinin sağlanması gibi listelenebilir. Bu çalışmada en yüksek test doğruluk oranı yakalanacak şekilde gerekli en iyileştirmeler gerçekleştirilerek, yönteme önerilen bu gelişmelerin tamamı uygulanmıştır.

Yazarlar kıyasla bu çalışmadan daha küçük boyutta görsellerden oluşan veri kümeleri kullanarak yöntemlerini değerlendirmişlerdir, bu nedenle bu çalışmada araştırmada bahsi geçen konfigürasyonlar değiştirilmiş ve en optimize ana model aranmıştır. Algoritmada bulunan temel değişkenler; ana model (base model), yığın (batch) boyutu, alt başlık sayısı, yapay örnek tekrar miktarı, görsel kanal uzunluğu, semantik çıktı genişliği, eklenmiş ise aşırı-kümeleme küme miktarı, görsel kırpma boyutu ve girdi boyutudur. Ana model olarak algoritma çalışmasında VGG benzeri bir yapı ile ResNet benzeri bir yapı kullanılmıştır. Bu çalışmada ana model olarak verimlilik,

TABLE I: KARŞILAŞTIRMA TABLOSU

Model Performans Karşılaştırması	Modeller		
	Model-1	Model-2	Model-3 (Önerilen)
Doğruluk Oranları	%90,92	%91,91	<b>%96,51</b>

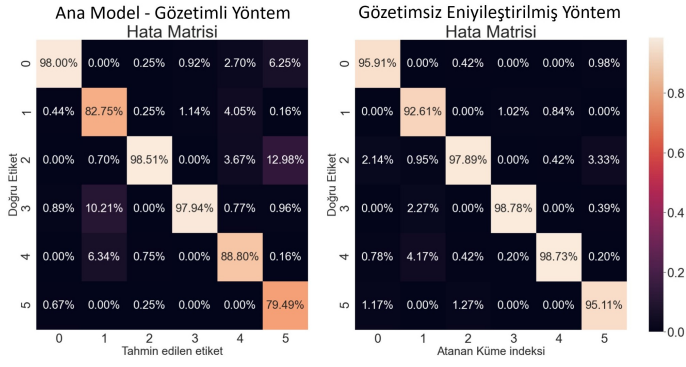
hız ve boyut endişeleri göz önünde tutularak geliştirilmiş MobileNet [12] mimarisi kullanılmıştır. MobileNet, ImageNet veri setinde ön eğitilmiş (pre-trained) ağırlıkları kullanılarak transfer öğrenme (transfer learning) gerçekleştirilmiştir. Temel modelin girdi boyutu, RGB resim kanallarına ve CNN girdisine uyacak şekilde  $256 \times 256 \times 3$  olarak belirlenmiştir. Çıktının alındığı alt başlığın semantik çıktı genişliği de sınıf sayısına eşit olacak şekilde altı olarak belirlenmiştir.

### IV. DENEYLER

Yöntem hazırlandıktan sonra seçilen yöntemde kararlaştırılan girdi boyutuna göre çeşitli boyutlardaki resimler veri ön işleme tekniğinden geçirilmiştir. Tüm resimlerin temel model girdisindeki CNN yapısına uyması için bileşenlerin uzun boyu yatay olacak şekilde döndürüldükten sonra uzun boyu 256 piksel olacak ve en-boy oranı korunacak şekilde yeniden boyutlandırılmıştır. Resmin kısa kenarı 256 birime yükselecek ve bileşen ortalanacak şekilde resim kenarlarına doldurma (padding) uygulanmıştır. Veri kümesinin dengelenmemiş yapısı itibarıyla modelleri doğrudan beslemek düşük performans sonuçları vereceği öngörülmüştür. Veri kümesini dengelemek için yüksek miktarda örnek içeren sınıflar (sığaç ve dirençler), benzer görselleri eleyecek şekilde, az örnekleme (undersampling) işlemine; düşük miktarda örnek içeren kalan sınıflar ise, veri arttırımı (data augmentation) ile fazla örnekleme (oversampling) işlemine başvurulmuştur. Sonuç olarak toplamda 3000 adet  $256 \times 256$  boyutunda RGB kanallarına sahip renkli bileşen görsellerinden oluşan dengelenmiş bir veri kümesi oluşturulmuştur.

Veri kümesi betimlenen ön işlemeden (pre-processing) geçtikten sonra modele beslenmek için eğitim ve test setleri hazırlanmıştır. Veri setindeki örneklerin %10'u (300 örnek) test seti olarak ayrılmış ve kalan veri eğitim verisi olarak kullanılmıştır. Eğitim verisi ile 10-kat çapraz sağlama (k-fold cross validation) ile eniyileştirmeleri gerçekleştirilmek için validasyon işlemi gerçekleştirilmiştir. Validasyon üzerindeki eniyileştirmeler sonucunda; Yığın boyutu 64, alt başlık sayısı 5, yapay örnek tekrarı 3, aşırı-kümeleme kanal boyutu 50, girdi boyutu 256 olan resimlerin MobileNet girdisine uyması için görsel kırpma boyutu 224 olarak belirlenmiştir.

Karşılaştırma gereğince yöntemde kullanılan temel derin öğrenme modeli (MobileNet), başlangıçta gözetimli olarak eğitilmiştir (Model-1). Bu deneyin sonucunda test setinden elde edilen hata matrisi Şekil 3'da solda ana model olarak görülebilmektedir. Yöntem gözetimsiz şekilde eğitildikten sonra, veri kümesinden hazırlanan eğitim setinin bir kısmı (%10, 270 örnek) etiketli olarak gözetimli bir şekilde modelin ince ayarlanmasında kullanılmıştır (Model-2). Eğer model gözetimsiz eğitim sürecinde değişimli bir şekilde; bir dönem (epoch) semantik tahmin ve model eniyileştirmesi, bir dönem de aşırı kümeleme aktif edilerek aşırı kümelenecek değerler üzerinde model eniyileştirmesi sağlandığında (Model-3) performans değerinin yükseldiği görülmektedir. Model böylece, IIC'nin bir özelliği olarak, veri kümesinde gözlemlenen yüksek varyasyona uyum sağlamaktadır. Önerilen yaklaşım olan bu



Şekil 3: Yöntemde kullanılan ana modelin gözetimli eğitiminden elde edilen (solda) ve (**Önerilen**) aşırı kümeleme etkinleştirilerek eniyileştirilmiş yöntemin (sağda) hata matrisleri (Değerler sırasıyla 0:'ICs', 1:'capacitors', 2:'diodes', 3:'inductors', 4:'resistors', 5:'transistors'). Şekilde kümelenen indeksler doğru etiketlere karşılık gelecek şekilde haritalanmıştır.

son deneyin sonucunda test setinden elde edilen hata matrisi ise Şekil 3'da sağda görülebilmektedir.

Oluşturulan modeller kenara ayrılan test seti ile kontrol edildiğinde verdiği doğruluk oranları Tablo I'de karşılaştırılmıştır. Yöntem, seçilen veri kümesi ile tamamen gözetimsiz şekilde çalıştırıldığında eğitiminin sonucunda en yüksek %39 doğruluk oranı olacak şekilde düşük bir performans değeri göstermiştir ve bu sonuç karşılaştırma tablosuna eklenmemiştir. Önerilen yöntem ise %96,51 doğruluk oranı vermiştir. Mevcut akademik çalışmalarda benzer veri kümeleri ve bileşen tipleri üzerinde yapılan sınıflandırma çalışmalarında derin öğrenme yöntemleri sonucunda elde edilen doğruluk oranı sırasıyla %90,8 [4] ve %94,26 [13] olarak bildirilmiştir. Önerdiğimiz yöntemde elde ettiğimiz sonuç bu değerleri aşarak bilimiz dahilinde genel PCB bileşenlerinin çoklu etiketli sınıflandırıldığı çalışmalar arasında en yüksek doğruluk oranını yakalamıştır.

## V. SONUÇ

Oluşturulan model sağlanan veri kümesinde eğitilerek çeşitli geliştirmeler ile modelin performans değerlerinin artırılması sağlanmıştır. Model, istenildiği gibi, daha önce görmediği, verilen bileşen görselini yüksek doğrulukta sınıflandırabilmektedir. Her ne kadar gözetimli eğitim ile de yüksek performans değeri sağlamış olsa da, gözetimsiz algoritmanın sağladığı performans artışı göze çarpmaktadır.

Sistem gözetimli sistemlerde kullanılmak üzere veri kümesi oluşturmak için düşük küme olasılığı veren değerler göz ardı edilerek etiketsiz verilerin etiketlenmesinde kullanılabilir. Gelecek çalışma olarak bu çalışmada önerilen PCB bileşen kümeleme algoritması kullanılarak yeni bir PCB nesne tespit algoritması oluşturulabilir. Tamamlanan çalışma, PCB bileşen sınıflandırılması üzerine odaklanmış sayılı kapsamlı çalışmalardan biri olmakla kalmamış, bu çalışmalardan daha iyi performans değerleri yakalamıştır. İleride araştırmacıların bu alandaki çalışmalarının artması desteklenmektedir.

## KAYNAKLAR

[1] D. Demir, S. Birecik, F. Kurugollu, M. Sezgin, I. O. Bucak, B. Sankur, and E. Anarim, "Quality inspection in pcbs and smds using computer

vision techniques," *IEEE transactions on pattern analysis and machine intelligence*, vol. 2, pp. 857–861 vol.2, 1994.

- [2] DigiSource, "3 most common pcb assembly defects," <https://blog.thedigisource.com/3-common-pcba-defects>, Mar. 1 2021, accessed: 2021-03-03.
- [3] H. Wu, X. Zhang, and S. Hong, "A visual inspection system for surface mounted components based on color features," in *2009 International Conference on Information and Automation*, 2009, pp. 571–576.
- [4] H. Wu, G. Feng, H. Li, and X. Zeng, "Automated visual inspection of surface mounted chip components," in *2010 IEEE International Conference on Mechatronics and Automation*, 2010, pp. 1789–1794.
- [5] M. Maj and J. Świeżewski, "Yolo algorithm and yolo object detection: An introduction," <https://appsilon.com/object-detection-yolo-algorithm/>, May 22 2020, accessed: 2021-03-03.
- [6] J. Kim, Youn-Ae Lee, and T. Park, "Automatic extraction of component inspection regions from printed circuit board," in *2012 IEEE/SICE International Symposium on System Integration (SII)*, 2012, pp. 871–876.
- [7] D. Lim, Y. Kim, and T. Park, "Smd classification for automated optical inspection machine using convolution neural network," in *2019 Third IEEE International Conference on Robotic Computing (IRC)*, 2019, pp. 395–398.
- [8] H. Lu, D. Mehta, O. Paradis, N. Asadizanjani, M. Tehranipoor, and D. Woodard, "Fics-pcb: A multi-modal image dataset for automated printed circuit board visual inspection," 07 2020.
- [9] C.-W. Kuo, J. Ashmore, D. Huggins, and Z. Kira, "Data-efficient graph embedding learning for pcb component detection," 01 2019, pp. 551–560.
- [10] L. Schmarje, M. Santarossa, S.-M. Schröder, and R. Koch, "A survey on semi-, self- and unsupervised learning for image classification," 02 2020.
- [11] X. Ji, A. Vedaldi, and J. Henriques, "Invariant information clustering for unsupervised image classification and segmentation," in *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 2019, pp. 9864–9873.
- [12] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. We- yand, M. Andreetto, and H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," 2017.
- [13] X. Hu, J. Xu, and J. Wu, "A novel electronic component classification algorithm based on hierarchical convolution neural network," *IOP Conference Series: Earth and Environmental Science*, vol. 474, p. 052081, 05 2020.