KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

LCD PİKSEL HATALARININ MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TESPİTİ

ASLI ÇELİK

KOCAELİ 2019

KOCAELİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

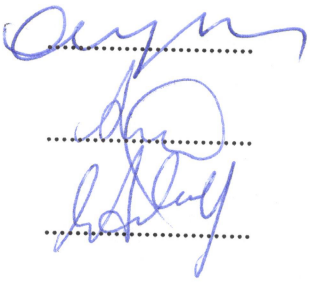
LCD PİKSEL HATALARININ MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE TESPİTİ

ASLI ÇELİK

Prof. Dr. Oğuzhan URHAN
Danışman, Kocaeli Üniversitesi

Dr. Öğr. Üyesi Aysun TAŞYAPI ÇELEBİ
Jüri Üyesi, Kocaeli Üniversitesi

Dr. Öğr. Üyesi Gökçen ÇETİNEL
Jüri Üyesi, Sakarya Üniversitesi



Tezin Savunulduğu Tarih: 21.01.2019

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında LCD ekranlardaki piksel hatalarının makine öğrenmesi temelli üç yöntem önerilmektedir. Bu alanda çalışacak araştırmacılara faydalı olmasını temenni ederim.

Bu konuda bana çalışma fırsatı veren, beni destekleyen ve bana çalışmalarımın her aşamasında yardımcı olan değerli hocam Prof. Dr. Oğuzhan URHAN'a teşekkür ederim. Çalışmalarımın her aşamasında ilgi ve desteğini esirgemeyen, değerli katkılarıyla bu süreçte yanımda olan hocam Dr. Ayhan KÜÇÜKMANİSA'ya , proje yürütücümüz Dr. Öğr. Üyesi Aysun TAŞYAPI ÇELEBİ'ye ve çalışma arkadaşım Aydın SÜMER'e teşekkür ederim.

Bu tez, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 1505 programı kapsamında 5150099 kodlu proje ile desteklenmiştir.

Ocak-2019 Aslı ÇELİK

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR i
İÇİNDEKİLER ii
ŞEKİLLER DİZİNİ iii
TABLOLAR DİZİNİ iv
SİMGELER VE KISALTMALAR DİZİNİ v
ÖZET vi
ABSTRACT vii
GİRİŞ 1
1. LİTERATÜRDEKİ ÇALIŞMALAR 3
2. DENEYSEL SİSTEM, VERİ SETİ VE PERFORMANS METRİKLERİ 8
2.1. Deneysel Sistem 8
2.2. Veri Seti 10
2.3. Performans Metrikleri 11
3. NESNE TESPİTİ 14
4. LCD PİKSEL HATALARININ TESPİTİ İÇİN ÖNERİLEN YÖNTEMLER 26
4.1. LCD Piksel Hatalarının GLCM Öznitelikleri ve SVM ile Tespiti 26
4.1.1. Özellik çıkartımı 27
4.1.2. Piksel hatası tespiti 29
4.1.3. Son işlem 29
4.1.4. Deneysel sonuçlar 30
4.2. LCD Piksel Hatalarının CNN ile Tespiti 32
4.2.1. Özellik çıkartımı 32
4.2.2. Piksel hatası tespiti 33
4.2.3. Son işlem 34
4.2.4. Deneysel sonuçlar 34
4.3. Piksel Hatalarının Tümleşik CNN Mimarisi ile Tespiti 35
4.3.1. Deneysel sonuçlar 36
4.4. Sonuçlar 38
SONUÇLAR 40
KAYNAKLAR 41
KİŞİSEL YAYINLAR VE ESERLER 44
ÖZGEÇMİŞ 45

ŞEKİLLER DİZİNİ

Şekil 1.1 LCD panellerde görülen piksel hataları 3
Şekil 1.2. LCD paneller için görüntüleme temelli kalite kontrol sistemlerinin sınıflandırılması 4
Şekil 2.1. Çizgi taramalı kamera ile görüntü alımı 8
Şekil 2.2. Deneysel sistem 9
Şekil 2.3. Çizgi taramalı ve alan taramalı kameralar kullanılarak elde edilen görüntüler (a) Çizgi taramalı kamera (b) Alan taramalı kamera 9
Şekil 2.4. Sözde-hatalı piksellerin alan taramalı kamera ile alınmış görüntüleri 10
Şekil 2.5. Veri setinden örnek bir görüntü 11
Şekil 2.6. Performans değerlendirmesi sırasında tespit sonuçlarının yorumlanması (a) Doğru pozitif (b) Yanlış negatif (c) Yanlış pozitif 12
Şekil 2.7. Karmaşıklık matrisi 12
Şekil 3.1. Tam bağlantılı yapay sinir ağı 15
Şekil 3.2. Konvolüsyonel sinir ağı 15
Şekil 3.3. İki boyutlu konvolüsyon işlemi 16
Şekil 3.4. Havuzlama işlemi 16
Şekil 3.5. LeNet-5 mimarisi 17
Şekil 3.6. Kalıntı (Residual) öğrenme bloğu 18
Şekil 3.7. R-CNN nesne tespitine genel bir bakış 20
Şekil 3.8. Fast R-CNN nesne tespitine genel bir bakış 20
Şekil 3.9. Faster R-CNN nesne tespitine genel bir bakış 21
Şekil 3.10. YOLO nesne tespitine genel bir bakış 22
Şekil 3.11. FPN (Feature Pyramid Network) 24
Şekil 4.1. Örnek eğitim verileri (a) Hatasız pikseller (b) Hatalı pikseller 27
Şekil 4.2. Referans ve komşu pikseller arasındaki ilişki 28
Şekil 4.3. d=1 ve θ=0 için örnek GLCM (a) Giriş matrisi (b) GLCM 28
Şekil 4.4. Kayan pencereler nesne tespiti 29
Şekil 4.5. Son işlem öncesi tespit sonuçları (a) Tespit görüntüsü (b) Tespit görüntüsünün yakınlaştırılmış hali 30
Şekil 4.6. Son işlem sonrası tespit sonuçları (a) Tespit görüntüsü (b) Tespit görüntüsünün yakınlaştırılmış hali 30
Şekil 4.7. CNN mimarileri (a) CNN-1 (b) CNN-2 (c) CNN-3 33
Şekil 4.8. Eğitim veri setinden örnekler (a) Eğitimde kullanılacak örnek bir görüntü (b) Etiketlenmiş hatalı piksel 36
Şekil 4.10. Örnek tespit sonuçları 37
Şekil 4.11. Yanlış pozitif tespit sonuçları 38

TABLOLAR DİZİNİ

Tablo 3.1 PASCAL VOC 2007 Test veri seti için iki-aşamalı nesne tespit yöntemlerinin başarımları 21
Tablo 3.2 Nesne tespit yöntemlerinin karşılaştırılması 23
Tablo 3.3. Nesne tespit yöntemlerinin karşılaştırılması 25
Tablo 4.1. Kullanılan öznitelikler 31
Tablo 4.2. Hatalı piksel tespit başarımı 31
Tablo 4.3. CNN eğitim parametreleri 32
Tablo 4.4. CNN tabanlı piksel hatası tespit yöntemlerinin başarımları 34
Tablo 4.5 Hatalı piksellerin sınıf ve konum bilgilerinin kaydedildiği text dosyası içeriği 36
Tablo 4.6. Önerilen tespit yöntemlerinin başarımları 39

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

LCD : Lyquid Cyristal Display (Sıvı Kristal Görüntü)
CNN : Convolutional Neural Network (Konvolüsyonel Sinir Ağları)
GLCM : Gray Level Co-Occurance Matrix (Gri Seviye Eş-Oluşum Matrisleri)
SVM : Support Vector Machines (Destek Vektör Makineleri)
YSA : Yapay Sinir Ağları
mAP : Mean Average Precision (Ortalama Kesinliğin Ortalaması)
AP : Average Precision (Ortalama Kesinlik)
SVDD : Support Vector Data Description (Destek Vektör Veri Tanımı)
WT : Wavelet Transform (Dalgacık Dönüşümü)
DFT : Discrete Fourier Transform (Ayrık Fourier Dönüşümü)
IDFT : Inverse Discrete Fourier Transform (Ters Ayrık Fourier Dönüşümü)
FOV : Field of View (Görüş Alanı)
FC : Fully Connected (Tam Bağlantılı)
RPN : Region Proposal Network (Alan Öneri Ağı)
FPN : Feature Pyramid Network (Öznitelik Piramit Ağı)
GPU : Graphics Processing Unit (Grafik İşleme Ünitesi)
SGD : Stochastic Gradient Descent (Olasılıksal Gradyan Azalış)

LCD PİKSEL HATALARININ MAKİNE ÖĞRENMESİ İLE TESPİTİ

ÖZET

Gelişen kamera ve bilgisayar teknolojilerine paralel olarak, bilgisayarla görü tabanlı yöntemlerin endüstriyel uygulamalarda kullanım sıklığı artmaktadır. Bilgisayarla görü sistemlerinin en yaygın kullanım alanlarından biri de kalite kontrol süreçleridir. Televizyon üretiminde, LCD panellerin istenen görüntü kalite standartlarını sağlamaları için kalite kontrol önemli bir süreç haline gelmiştir. Belirli bir kalite seviyesinin yakalanması için operatör denetimi ile bu işin yapılması ise öznel, yorucu ve zaman alıcı bir süreçtir.

LCD piksel hatalarının otomatik ve operatörden bağımsız bir şekilde tespiti için birçok bilgisayarla görme tabanlı yöntem önerilmiştir. Bu yöntemler, operatör denetimine kıyasla daha verimli, nesnel ve düşük maliyetlidir. Bu tez çalışmasında LCD piksel hatalarının tespiti problemine, bir nesne tespiti problemi olarak yaklaşılmış ve makine öğrenmesi temelli üç yöntem önerilmiştir. Birinci yöntem GLCM öznitelikleri ve SVM sınıflandırıcı kullanmaktadır. İkinci yöntemde CNN sınıflandırıcı kullanılmıştır. Üçüncü yöntem ise piksel hatalarının tespiti için tümleşik, tek aşamalı, CNN tabanlı bir nesne tespit mimarisi kullanmaktadır. Nesnel bir performans değerlendirmesi için kesinlik, duyarlılık ve F1 skoru ölçütleri kullanılmıştır. En iyi tespit sonuçları tümleşik ve tek aşamalı olan CNN tabanlı bir nesne tespit mimarisi kullanıldığı yöntemle elde edilmiştir. Deneysel sonuçlar önerilen yöntemin operatör denetimine alternatif olabileceği göstermektedir.

Anahtar Kelimeler: Derin Öğrenme, Destek Vektör Makineleri, Konvolüsyonel Sinir Ağları, Makine Öğrenmesi, Piksel Hatası.

LCD PIXEL DEFECT DETECION USING MACHINE LEARNING METHODS

ABSTRACT

With respect to developing computer and camera technologies, computer vision based methods are being used increasingly in industrial applications. One of the most common practise of computer vision systems in industrial applications is quality control processes. Inspection of LCD panels became a critical task in television manufacturing in order to guarantee the display quality. Using manual inspection in order to maintain a quality standard is a time-consuming, subjective, tiresome task.

Numerous methods have been proposed by researchers for automatic inspection. Such methods are relatively more efficient, objective and low-cost. In this thesis, LCD Pixel defect detection problem is considered as an object detection problem, and three machine vision-based method is proposed. First method is based on Gray-Level Co-Occurrence Matrix (GLCM) features and Support Vector Machines (SVM). Second method uses CNN classifier. Third method uses a unified one-stage CNN object detector for LCD pixel defect detection problem. Precision, recall, and F1 score metrics are used for objective performance evaluation. The best detection results obtained by using a CNN-based architecture which is a unified and one-stage object detector. Experimental results shows that proposed method might be an alternative to manual inspection.

Keywords: Deep Learning, Support Vector Machines, Convolutional Neural Networks, Machine Learning, Pixel Defect.

GİRİŞ

Gelişen kamera ve bilgisayar teknolojilerine paralel olarak, bilgisayarla görü tabanlı yöntemlerin endüstriyel uygulamalarda kullanım sıklığı artmaktadır. Bilgisayarla görü sistemlerinin en yaygın kullanım alanlarından biri de kalite kontrol süreçleridir. Günümüzde yüksek çözünürlüklü kamera, yüksek performanslı görüntü işleme yaklaşımı ve işlem birimlerinin kullanımı ile, insan gözü ile yapılan kalite kontrol işlemlerinin yerini kameralı kalite kontrol sistemleri alabilmektedir.

Televizyon üretim hacminin artması ve üretim hatası toleransının düşmesi ile beraber, üretici firmalarda panellerin kalite kontrolü önemli bir süreç haline gelmiştir. LCD panellerin son kullanıcılara istenen kalitede ulaştırılabilmesi için mevcut durumda çoğu üretici firma operatör denetimli kalite kontrol uygulamaktır. Operatör denetimi ile yapılan kalite kontrollerde belirli bir kalite standardını yakalamak ve bunun devamlılığını sağlamak güçtür. Değerlendirmeler kişiden kişiye değişebileceği gibi, kişilerin yorgunluk durumuna göre de değişkenlik gösterebilmektedir. Operatör denetimi öznel, yorucu, maliyetli ve zaman alıcı bir süreçtir. Literatürde LCD piksel hatalarının otomatik ve operatörden bağımsız bir şekilde gerçekleştirilebilmesi için birçok bilgisayarla görme tabanlı yöntem önerilmiştir. Bu yöntemler, operatör denetimine kıyasla daha verimli, nesnel ve düşük maliyetlidir. Renkli bir LCD panelde, bir fiziksel piksel K (kırmızı), Y (yeşil) ve M (mavi) olmak üzere üç adet alt-pikselden oluşmaktadır. Beyaz renk, bir piksele ait tüm alt-piksellerin en yüksek düzeyde (tamamen) aktif konumda olması ile elde edilmektedir. Hatasız üretilmiş bir panelin fiziksel yapısı, düzenli olarak kendini tekrarlayan bir örüntüdür. Piksel hataları bu örüntüde anomaliler şeklinde ortaya çıkmaktadır. LCD panellerin üretim sürecinde birçok farklı hata ortaya çıkabilmektedir. LCD panellerde görülen hatalar fiziksel karakteristiklerine göre nokta-tipi, çizgi-tipi ve alan-tipi hatalar olarak gruplanabilmektedir. Bu tez çalışması kapsamında LCD panellerdeki nokta-tipi hatalara odaklanılmaktadır. Nokta-tipi hatalar genellikle piksel/alt-piksel seviyesindeki hatalardan kaynaklanmakta olup alt-piksel hatası olarak da adlandırılmaktadır. Nokta-tipi hatalar arka plana göre daha aydınlık veya karanlık

olma durumlarına göre aydınlık-nokta-tipi ve karanlık-nokta-tipi hata olarak kendi içerisinde iki alt grupta değerlendirilebilir [1].

Yüksek çözünürlüklü panellerin yaygınlaşması ile birlikte özellikle alt piksel hatalarının tespiti zorlu bir problem haline gelmiştir. Ayrıca, piksel hataları çoğu durumda düşük karşıtlığa ve belirsiz sınırlara sahip kusurlardır. Bu durum tespitleri daha da güç hale getirmektedir.

Bu tez çalışmasında LCD piksel hatalarının tespiti için makine öğrenmesi temelli üç yöntem önerilmektedir. Tez çalışmasının literatüre katkıları şunlardır:

- LCD piksel hatalarının tespiti için Gri Seviye Eş-Oluşum Matrisi (GLCM) öznitelikleri ve Destek Vektör Makinaları (SVM) temelli bir yöntem önerilmiş; farklı öznitelik setlerinin kullanımı durumunda tespit performansları incelenmiştir.
- LCD piksel hatalarının tespiti için Konvolüsyonel Sinir Ağları (CNN) temelli bir yöntem önerilmiş; farklı derinlikte ağ mimarilerinin kullanımı durumunda tespit performansları incelenmiştir.
- LCD piksel hatalarının tespiti için tümleşik, CNN tabanlı bir nesne tespit mimarisinin kullanımı önerilmiş; tespit performansı incelenmiştir.

Tez çalışmasının birinci kısmında literatürde bulunan LCD panellerin kalite kontrolünde kullanılan görüntüleme temelli yöntemler incelenmiştir. Tez çalışmasının ikinci kısmında deneysel sistem, veri seti ve performans değerlendirmesinde kullanılacak metrikler hakkında bilgi verilmiştir. Bu tez çalışmasında LCD piksel hatalarının tespiti problemine bir nesne tespiti problemi olarak yaklaşılmıştır. Bu nedenle tez çalışmasının üçüncü kısmında, nesne tespiti problemi ve derin öğrenme tabanlı nesne tespit yaklaşımları ayrıntılı incelenmiştir. Bu tez kapsamında önerilen yöntemler çalışmanın dördüncü kısmında ayrıntılı olarak irdelenmiştir.

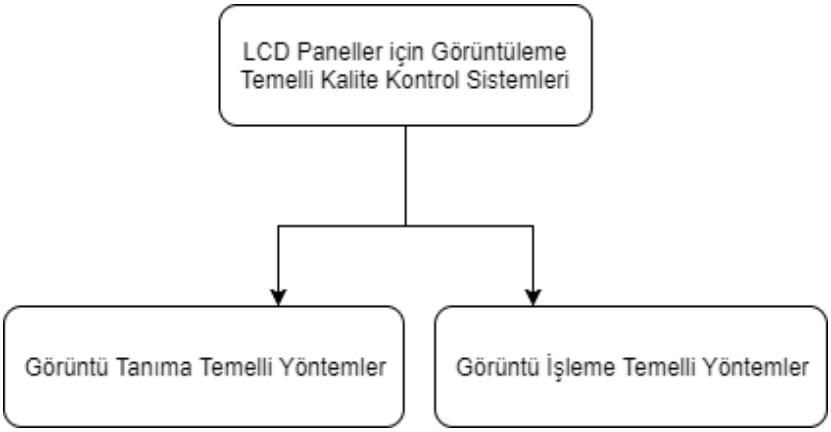
1. LİTERATÜRDEKİ ÇALIŞMALAR

LCD panellerin üretim sürecinde birçok farklı hata ortaya çıkabilmektedir. LCD panellerde görülen hatalar [2]'de fiziksel karakteristiklerine göre nokta-tipi, çizgi-tipi ve alan-tipi hatalar olarak gruplanabilmektedir. Farklı hata tiplerine birkaç örnek Şekil 1.1'de verilmiştir.



Şekil 1.1. LCD panellerde görülen piksel hataları

Literatürde LCD piksel hatalarının otomatik ve operatörden bağımsız bir şekilde gerçekleştirilebilmesi için birçok bilgisayarla görme tabanlı yöntem önerilmiştir. Bu yöntemler, operatör denetimine kıyasla daha verimli, nesnel ve düşük maliyetlidir. LCD panellerdeki kusurların tespiti için önerilen görüntüleme temelli kalite kontrol yöntemleri, [3]'teki çalışmada Şekil 1.2'de görüldüğü üzere görüntü işleme temelli yöntemler ve görüntü tanıma temelli yöntemler olarak iki ayrı grupta değerlendirilmiştir.



Şekil 1.2. LCD paneller için görüntüleme temelli kalite kontrol sistemlerinin sınıflandırılması [3]

Görüntü tanıma temelli yöntemlerde veriden öznitelikler çıkartılır ve elde edilen öznitelikler hataların tespiti ve/veya sınıflandırılması için bir sınıflandırıcıya giriş olarak uygulanır. Öznitelik seçimi ve sınıflandırıcı tasarımı başarımı doğrudan etkiler. Görüntü tanıma temelli yöntemler, genellikle LCD üretim hattındaki belirli bir proseste gözlenebilecek hataların sınıflandırılması için kullanılmışlardır. İlgili proseste gerçek zamanlı hata tespiti, panelin son kullanıcıya ulaşmadan onarımını mümkün kılmaktadır. Görüntü işleme temelli yöntemlerde ise görüntü farkı alma yaklaşımı ve bölütleme/eşikleme temelli yöntemler sıkça kullanılmaktadır. Piksel hatalarının tespit için görüntü işleme temelli, tespit edilen hataların sınıflandırılması içinse görüntü tanıma temelli yöntemlerden yararlanan, iki aşamalı karma kontrol sistemleri de mevcuttur.

[4]'teki çalışmada mura hatalarının üretim hattında gerçek zamanlı tespiti için SVDD (Support Vector Data Description) kullanmıştır. Çalışmada LCD paneldeki hataların tespiti, hatalı panallerin ise yeniden işleme yoluyla onarımı hedeflenmektedir. Çalışma kapsamındaki çok çeşitli hata türlerinin veri setinde yeterli temsilinin mümkün olmadığı fikriyle, sınıflandırıcı hatasız bölgelerden alınan örnekler ile eğitilmiştir. SVDD tek sınıflı bir sınıflandırıcı olması sebebiyle, sınıf dengesizliğinin olduğu mevcut problem için tercih edilmiştir. Çalışmada hızlandırılmış bir SVDD algoritması önerilmiştir. Hata tespit oranı %95'in üzerindedir. 14,1 inç boyutlu bir panel için tarama tarama süresi 0,13 dakikadır.

[5]'teki çalışmada, test edilecek paneller öncelikle ön incelemeden geçirilmektedir. Ön inceleme aşamasında görüntü çıkartımı ve eşikleme kullanmıştır. Çalışmada, hatalı

olduğu ön incelemede tespit edilen görüntüler için, hata sınıflandırma yapmak amacıyla yapay sinir ağları eğitilmiştir. Çalışmada öznitelik olarak 11 Gri Seviye Eş-Oluşum Matrisi (GLCM) özniteliği ve MATLAB regionprops fonksiyonu kullanılmıştır. Performans değerlendirmesi için Tanıma Oranı (Recognition Rate) metriği hesaplanmıştır. En yüksek performans dört farklı açısal ofset değeri için hesaplanan GLCM öznitelikleri ve regionprops fonsiyonunun birlikte kullanıldığı durumda %83,3 olarak bulunmuştur. [6]'daki çalışma ise LCD panel üretimindeki fotolitografi prosesinde oluşabilecek hata türlerini sınıflandırmak için dört farklı yapay sinir ağı modeli önermiştir. En başarılı model için doğruluk (accuracy) %97 bulunmuştur.

Görüntü işleme temelli yöntemlerden biri, görüntü farkı alma (image subtraction) yaklaşımıdır. Görüntü farkı alma kullanan yöntemler ilk aşamada oluşturdukları taslak görüntüyü, hata tespiti yapılacak görüntüden çıkartır. Daha sonra fark görüntüsü bir eşikle karşılaştırılarak hata tespiti yapılır. Taslak görüntünün nasıl elde edileceği önemli bir nokta olup model uydurma uygulanan en etkili ve yaygın yöntemlerden biridir [3]. [7]'deki çalışma mura hatalarının tespiti için önerdiği yöntemde, özyinelemeli polinom-yüzey uydurma algoritması ile taslak görüntüyü oluşturmaktadır. Görüntü fark alma işleminden sonra elde ettiği fark görüntüsüne gürültü giderimi için Gauss süzgeçleme uygular. En son aşamada ise mura hatalarını eşikleme yoluyla bölütler. Çalışmada performans değerlendirmesi için görsel karşılaştırma kullanılmıştır. [8]'deki çalışmada LCD panellerin arka plan modellemesi için Gauss Karışımı (Gaussian-Mixture) temelli bir yöntem önerilmiştir. Görüntü çıkartımı görece basit ve etkili bir yöntem olmasına karşın taslak imgenin hafızada tutulmasına ihtiyaç duyar ve ışıklılık değişimlerine ve uzamsal değişiklilere karşı gürbüz değildir [3].

Literatürde önerilen görüntü işleme tabanlı piksel hatası tespiti yöntemlerinin bir çoğu bölütleme/eşikleme tabanlı yöntemlerdir. LCD piksel hataları belirli bir şekle sahip olmayan, düşük karşıtlıkta, arka-plana kıyasla keskin kenar geçişleri olmayan anomaliler şeklinde ortaya çıkmaktadır. Söz konusu karakteristikleri sebebiyle, bu hataların tek başına bölütleme tabanlı yöntemlerle tespiti güçtür. Bu yöntemler, bölütleme öncesinde görüntüye arka-plan çıkartımı, gürültü giderimi, gri seviye düzeltmesi, karşıtlık pekiştirme gibi ön-işlemler uygulamaktadır. LCD hatalarının

bölütlenmesini kolaylaştıran en etkili yöntem arka plan görüntüsünün bastırılmasıdır. [9]'daki çalışmada arka plan sinyalinin bastırılması için Dalgacık Dönüşümü'nden (Wavelet Transform - WT) faydalanılmıştır. WT sonucunda elde edilen yaklaşım (approximation) katsayıları girişin genel karakteristiğini temsil ederken, detay katsayıları yerel değişimlere karşı duyarlıdır. Çalışmada yaklaşım katsayılarına, görüntünün genel karakteristiğini bastırmak amacıyla düzleştirici bir fonksiyon (flattenning function) uygulanmıştır. Detay katsayıları ise mura hatalarını pekiştirmek amacıyla ACS (Adapted Contrast Sensitivity) fonksiyonuna göre ağırlıklandırılmıştır. Daha sonra eşikleme tabanlı tespit yapılmıştır. [10]'daki çalışmada arka plan sinyalinin bastırılması için Ayrık Fourier Dönüşümü (Discrete Fourier Transform - DFT) kullanılmıştır. Giriş görüntüsünün Ayrık Fourier Dönüşümü alınmış, ideal alçak geçiren süzgeç uygulanmış, daha sonra ters Ayrık Fourier dönüşümü (Inverse Discrete Fourier Transform - IDFT) alınarak arka plan sinyali bastırılmıştır. Böylelikle çalışmada hata tespit problemi bir bölütleme problemine dönüştürmüştür. [11]'deki çalışmada benzer bir yaklaşımla görüntüye Bağımsız Bileşen Analizi (Independent Component Analysis) uygulanmış, genel yapıyı temsil eden bağımsız bileşenler modifiye edilerek arka plan sinyali bastırılmıştır. [12]'deki çalışmada LCD piksel hatalarını pekiştirmek için süzgeçleme temelli bir yaklaşım sunulmuştur. Çalışmada her pikselin komşuluğundaki piksellere kıyasla standart sapması hesaplanmış, daha sonra standart sapma bilgisi kullanılarak piksellerin gri seviyeleri hataları pekiştirecek şekilde yeniden ölçeklenmiştir.

[13]'teki çalışma LCD panellerdeki hataların tespiti için modifiye edilmiş belirginlik haritalarını (saliency map) kullanmaktadır. Belirginlik haritaları görüntüdeki renk, yönelim (orientation) ve yoğunluk (intensity) özellikleri kullanılarak oluşturulur. Çalışmada LCD panelden gri-seviye görüntüler alındığı için renk özelliği yerine karşıtlık ve kenar özellikleri kullanılarak belirginlik haritaları oluşturulmuştur. Çalışmada 50 hatalı ve 50 hatasız olmak üzere 100 adet görüntü için performans değerlendirmesi yapılmıştır. Sistemin doğruluk performansı %95'tir.

LCD panellerdeki hatalarının tespiti için önerilen yöntemlerin çoğu alan-tipi hatalar olan mura hatalarının tespitini hedeflemektedir. Yüksek çözünürlüklü panellerin yaygınlaşması ile birlikte özellikle alt piksel hatalarının tespiti zorlu bir problem haline gelmiştir. [1]'deki çalışmada alt piksel seviyesindeki hataların tespiti için çentik

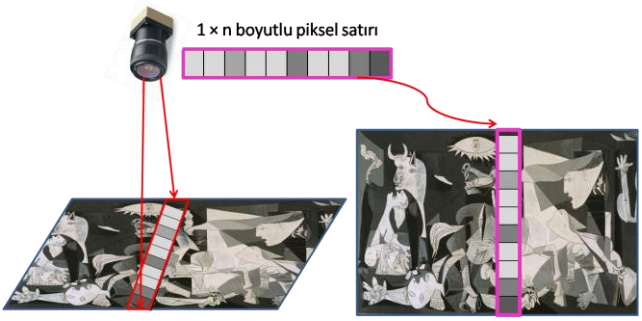
süzgeçleme (notch filter) temelli bir arka plan sinyal bastırımı uygulanmıştır. Alt-piksel seviyesindeki hataların tespiti ise diğer bölütleme temelli yöntemlere benzer şekilde eşikleme ile gerçekleştirilmiştir. Çalışmada test veri seti olarak 95 adedi alt-piksel hatası barındıran 100 LCD görüntüsü kullanılmıştır. Bu veri setindeki tespit başarımı %100'dür.

2. DENEYSEL SİSTEM, VERİ SETİ VE PERFORMANS METRİKLERİ

Bu bölümün birinci alt bölümünde tez çalışmasında kullanılan deneysel sistem incelenecektir. İkinci alt bölümünde deneysel sistem kullanılarak oluşturulan veri seti hakkında bilgi verilecektir. Üçüncü alt bölümde ise, literatürde ve bu tez çalışması kapsamında önerilen yöntemlerin performans değerlendirmesi için kullanılan performans metrikleri açıklanacaktır.

2.1. Deneysel Sistem

Tez çalışmasında kullanılan LCD panel 55 inç boyutludur. Ayrıca önerilecek yöntemlerin, 32-65 inç aralığındaki LCD ekranların kontrolünde kullanılabilmesi hedeflenmektedir. Bu durumda LCD ekranların görüntüsünün alan taramalı kameralar kullanılarak alınması, çok sayıda kamera kullanımı ihtiyacını doğuracaktır. Bu sebeple çalışmada satır taramalı (line-scan) kamera kullanılmıştır. Kullanılan kamera siyah-beyaz görüntü vermektedir. Satır taramalı kameralar, tek bir sensör satırına sahiptir. Görüntü alımı sırasında ya nesne sabitken kamera hareket etmektedir ya da nesne hareketli iken kamera sabit durmaktadır. Satırlar halinde alınan görüntü birleştirilerek ilgili alana ilişkin iki boyutlu görüntü elde edilir. Şekil 2.1'de görüldüğü üzere, herhangi bir anda çizgi taramalı kamera kullanılarak elde edilen bir piksel satırı, oluşturulacak görüntüdeki bir satıra karşılık gelmektedir.



Şekil 2.1. Çizgi taramalı kamera ile görüntü alımı

Deneysel sistem çizgi taramalı kamera ve kameranın istenilen hızda ve hassasiyette hareketini sağlayacak tek eksende hareket eden gantry sistemden oluşmaktadır.

Sistemde Basler firmasının racer raL6144-16gm model numaralı çizgi taramalı kamerası ve VS-L5028/F model lens kullanılmıştır. Deneysel sistem Şekil 2.2'de görülmektedir. Hedeflenen çözünürlükte görüntü elde edebilmek için en uygun çalışma mesafesi 530 mm olarak belirlenmiştir. Bu durumda FoV (Field of View) 441 mm olmaktadır. Süre kısıtı göz önünde bulundurularak, gantry sisteminin hız değeri 60 cm/s olarak seçilmiştir. Bu durumda deneysel sistemin 55 inç paneli tarama süresi 25 saniyedir.



Şekil 2.2. Deneysel sistem

C# dilinde geliştirilen yazılım kullanılarak, sistemin harekete başladığı andan hareketin bitme anına kadar satır taramalı kameradan alınan 1×6144 piksel boyutlu veri arka arkaya eklenerek panelin iki boyutlu görüntüsü oluşturulur ve bu görüntü diske kaydedilir. Şekil 2.3'te bir kutunun, mevcut deneysel sistem kullanılarak alınmış görüntüsü ve alan taramalı bir kamera kullanılarak alınmış görüntü verilmiştir

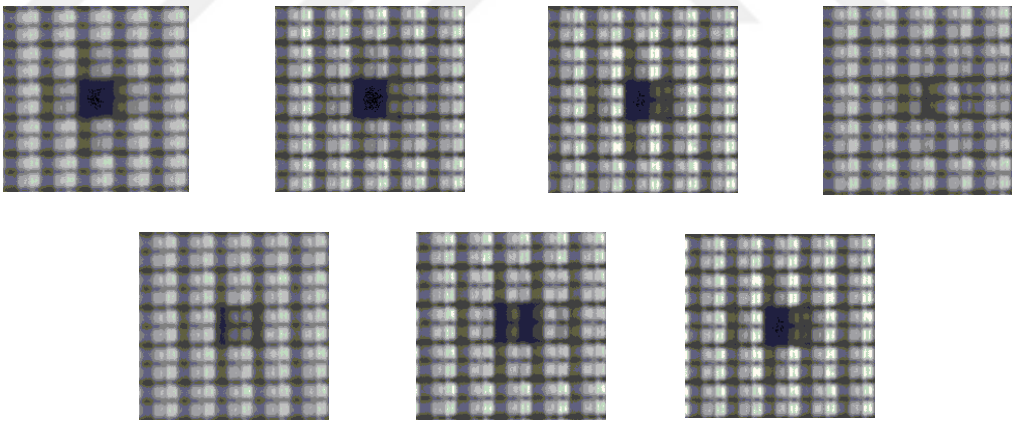


(a) (b)

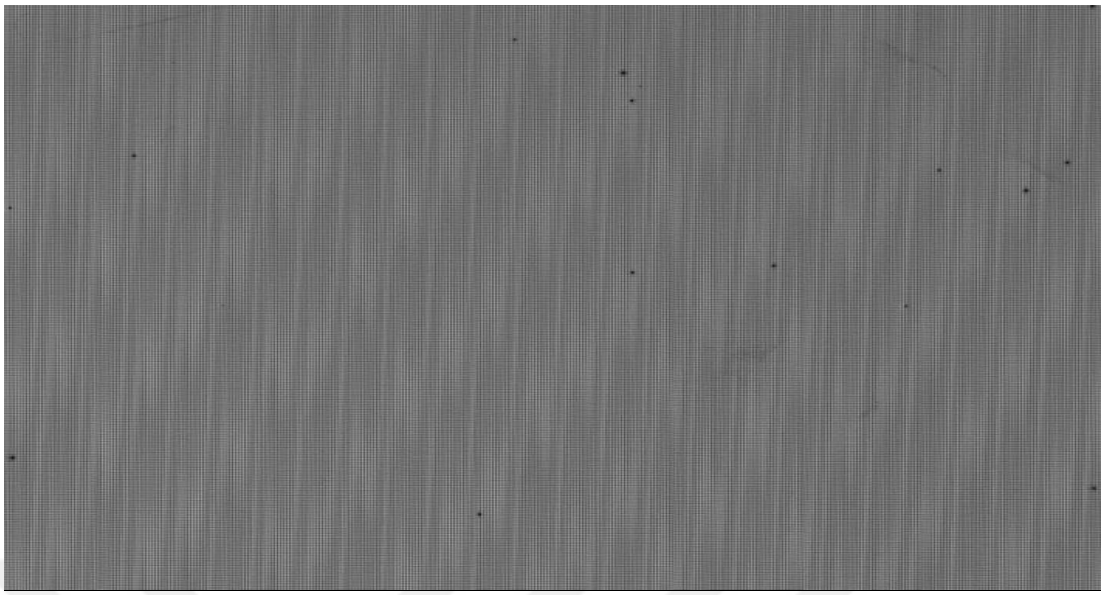
Şekil 2.3. Çizgi taramalı ve alan taramalı kameralar kullanılarak elde edilen görüntüler (a) Çizgi taramalı kamera (b) Alan taramalı kamera

2.2. Veri Seti

LCD paneller üzerinde kısıtlı sayıda hatalı piksel örneği bulunmaktadır. Bu durum hatalı piksel bulunan ekranlardan örnek görüntüler toplayarak bir veri seti oluşturmayı oldukça güçleştirmektedir. Bu nedenle piksel hatalarını simüle eden örüntüler sanal olarak bilgisayar ortamında, beyaz arka plan üzerine rastgele dağılmış bir şekilde yapay olarak oluşturulmuştur. Bir pikseli oluşturan bütün transistörlerin arızalı/kapalı olması durumunda bu piksel ekranda siyah olarak görünmektedir. Alt-piksel düzeyindeki anomalilerde, piksellerin bir veya herhangi iki renk kanalı kapalı konumdadır. Bu durum ilgili piksellerin beyaz yerine kırmızı, yeşil, mavi, sarı, macenta, camgöbeği ve siyah renklerde görünmesine karşılık gelir. Üretilen yapay hatalı piksellerin alan taramalı kamera ile alınmış görüntüleri Şekil 2.4'te görülebilir. Testler için 3840×2160 piksel boyutlu bir görüntüde toplamda 1050 adet olacak şekilde 30 adet hatalı piksel içeren test görüntüsü üretilmiştir. Ekrana yansıtılan örüntülerin görüntüsü çizgi taramalı bir kamera kullanılarak elde edilmiştir. Veri setinden örnek bir görüntü Şekil 2.5'te görülmektedir.



Şekil 2.4. Sözde-hatalı piksellerin alan taramalı kamera ile alınmış görüntüleri

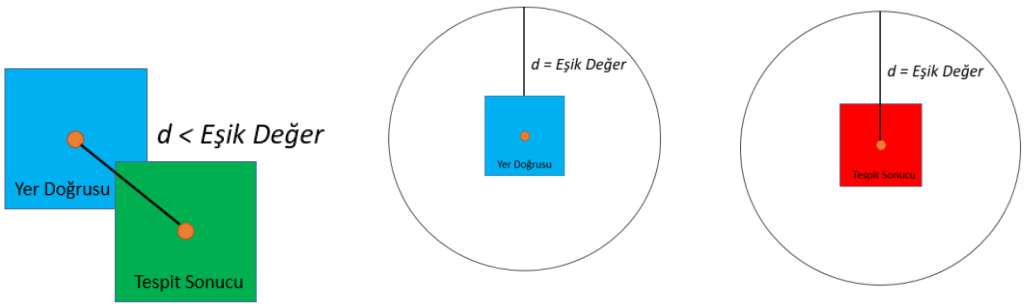


Şekil 2.5. Veri setinden örnek bir görüntü

2.3. Performans Metrikleri

Giriş bölümünde açıklandığı üzere piksel hatalarını tespit problemi bu tez kapsamında nesne tespiti problemi olarak değerlendirilmiştir. Bu nedenle bu alt bölümde nesne tespiti için kullanılan performans ölçütleri açıklanmıştır. Literatürde nesne tespiti yöntemlerinin performans değerlendirmesinde sıklıkla kullanılan ölçütler kesinlik (precision), duyarlılık (recall), F1 skoru (F1 score) ve mAP (Mean Average Precision)'dır.

Bu tez çalışmasında önerilen yöntemlerin nesnel performans değerlendirmesi için kesinlik, duyarlılık ve F1 skoru ölçütleri kullanılmıştır. İlgili yöntem tarafından tahmin edilen sınırlayıcı kutuların (n adet), yer doğrusu haritasındaki sınırlayıcı kutularla (m adet) olan öklid uzaklığı matrisi (n×m boyutlu) hesaplanmıştır. Tahmin edilen herhangi bir sınırlayıcı kutu, en yakın olduğu yer doğrusu sınırlayıcı kutusuna, belirlenen eşik değerinden daha yakın ise (bkz. Şekil 2.6 (a)), Doğru Pozitif (True Positive - DP) olarak kabul edilmiştir. Herhangi bir yer doğrusu sınırlayıcı kutusuna, eşik değeri uzaklığında hiçbir sınırlayıcı kutu tahmini yapılmamışsa (bkz. Şekil 2.6 (b)), Yanlış Negatif (False Negative - YN) sayısı bir arttırılmıştır. Tahmin edilen herhangi bir sınırlayıcı kutuya, eşik değeri uzaklığında hiçbir yer doğrusu sınırlayıcı kutusu yer almıyorsa (bkz. Şekil 2.6 (c)), Yanlış Pozitif (False Positive - YP) sayısı bir arttırılmıştır.



(a) (b) (c)

Şekil 2.6. Performans değerlendirmesi sırasında tespit sonuçlarının yorumlanması (a) Doğru pozitif (b) Yanlış negatif (c) Yanlış pozitif

TP, YP, YN durumlarına karşılık gelen senaryolar Şekil 2.7'daki karmaşıklık matrisinde verilmiştir. Kesinlik, duyarlılık ve F1 skoru ölçütleri Denklem 2.1, 2.2 ve 2.3'teki gibi hesaplanır. Mevcut problemde duyarlılık, ilgili yöntem tarafından tespit edilen hatalı piksel sayısının, yer doğrusundaki hatalı piksel sayısına oranıdır. Kesinlik ise ilgili yöntem tarafından tespit edilen hatalı piksel sayısının, bu sayı ve ilgili yöntem tarafından yapılan Yanlış Pozitif tespitlerin toplamına oranıdır. Son kullanıcıların ürün memnuniyeti göz önüne alındığında kalite kontrol sistemlerinin yüksek duyarlılıkta çalışması beklenmektedir. Dolayısıyla performans değerlendirmesinde duyarlılık metriği, kesinlik metriğine kıyasla daha belirleyici olmaktadır.

		Gerçek Durum	
		Pozitif	Negatif
Tahmin	Pozitif	Doğru Pozitif	Yanlış Pozitif
	Negatif	Yanlış Negatif	Doğru Negatif

Şekil 2.7. Karmaşıklık matrisi

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif(DP)}}{\text{Doğru Pozitif(DP)} + \text{Yanlış Pozitif(YP)}} \tag{2.1}$$

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif(DP)}}{\text{Doğru Pozitif}\left(\text{DP}\right) + \text{Yanlış Negatif(YN)}} \tag{2.2}$$

$$\text{F1 Skoru} = \frac{2 \times \text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \tag{2.3}$$

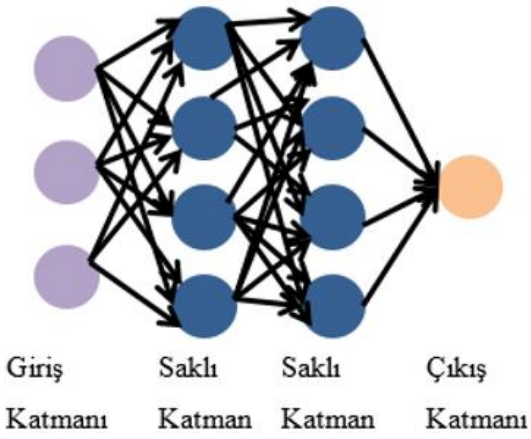
Literatürde nesne tespiti yöntemlerinin performans değerlendirmesinde sıklıkla kullanılan başka bir metrik ise mAP (Mean Average Precision) metriğidir. AP (Average Precision) kesinlik ve duyarlılık eğrisinin altında kalan alandır. Çok sınıflı tespit problemleri için AP metriğinin ortalaması olan mAP, tespit başarımının ölçütü olarak değerlendirilir.

3. NESNE TESPİTİ

Nesne tespiti bilgisayarla görmenin en ilgi çekici ve temel problemlerinden biridir. Nesne tespiti, verilen bir görüntüde ilgilenilen nesne sınıflarına ait örnekleri, sınıf ve konum bilgileriyle birlikte bulma problemidir. Nesne tespiti çok geniş ve çeşitli uygulama alanına sahiptir. Nesne tespiti algoritmalarının kullanıldığı yerlere örnek olarak robotik, tıbbi görüntü analizi, gözetleme, güvenlik, otomatik araç park sistemleri ve insan bilgisayar etkileşimi verilebilir.

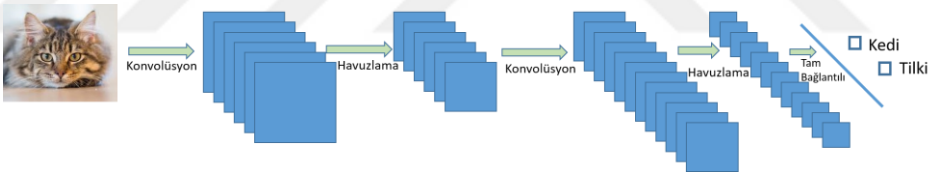
Makine öğrenmesi temelli geleneksel nesne tespiti yöntemleri üç aşamadan oluşur: nesnelerin bulunduğu potansiyel bölgelerin belirlenmesi, öznitelik çıkartımı (feature extraction) ve sınıflandırma. Bilgisayarla görü uygulamalarında, derin öğrenme yöntemleri yaygınlaşmadan önce, öznitelik çıkartımı temelli geleneksel tespit yöntemleri sıklıkla kullanılmaktaydı. Bu yöntemlerde uygun öznitelik çıkartımı nesne tespit performansını doğrudan etkileyen kritik bir süreçtir. Uygun öznitelik çıkartımı uzmanlık isteyen, zahmetli bir iştir. Yakın geçmişte bilgisayarla görü uygulamalarında derin öğrenme yöntemlerinin yaygınlaşmasıyla birlikte, nesne tespitinin tüm aşamaları derin öğrenme mimarileri tarafından başarıyla gerçekleştirilebilmektedir [14].

Derin öğrenme, çok katmanlı yapay sinir ağlarını kullanan bir makine öğrenmesi yöntemidir. Derin öğrenme yöntemleri, günümüzde birçok makine öğrenmesi probleminde, klasik makine öğrenmesi yöntemlerini geride bırakan yüksek başarımlar ile çalışmaktadır. Temel bir YSA mimarisi, giriş katmanı, çıkış katmanı ve bu iki katman arasındaki saklı katmanlardan oluşur. Temel YSA mimarisindeki katmanlar tam bağlantılı (fully connected) yapıdadır. Tam bağlantılı bir katmanda her bir nöron, bir önceki katmandaki nöronlara tam bağlantılıyken, bulunduğu katmandaki diğer nöronlardan bağımsız ve onlara bağlantısız durumdadır. YSA içerisindeki nöronlar farklı girişler için farklı çıkış değerleri üretirler. Nöronların işlem kapasiteleri, yalnızca toplama ve çarpma işlemleriyle ile sınırlıdır. Örnek bir tam bağlantılı YSA mimarisi Şekil 3.1'de görülmektedir.



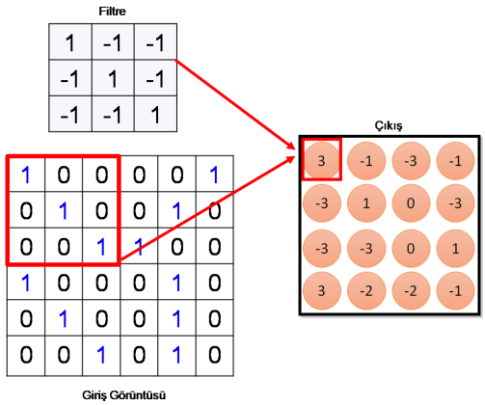
Şekil 3.1. Tam bağlantılı yapay sinir ağı

Görüntü işleme uygulamalarında tercih edilen YSA mimarisi ise Konvolüsyonel Sinir Ağı (Convolutional Neural Netwotk - CNN) mimarileridir. CNN mimarileri, sinir sisteminin çevredeki görsel uyarıcıları işleme biçiminden esinlenerek ortaya çıkmış özel bir YSA mimarisidir. Temel bir CNN mimarisi konvolüsyon katmanı, doğrusal olmayan katman ve havuzlama (pooling) katmanının tekrar eden kullanımı ile oluşur. Örnek bir CNN mimarisi Şekil 3.2'de verilmiştir.

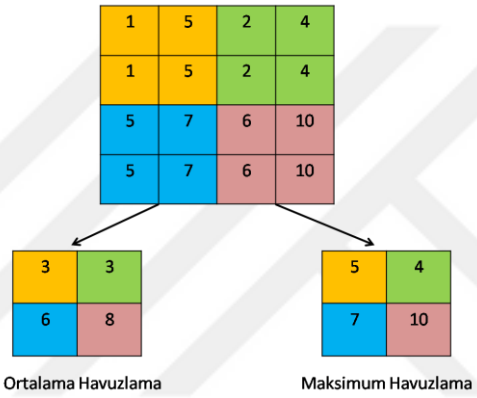


Şekil 3.2. Konvolüsyonel sinir ağı

Konvolüsyon katmanında öznitelik çıkartıcı görevi üstlenen birçok filtre bulunmaktadır. Eğitim esnasında söz konusu filtrelerin katsayıları maliyet fonksiyonuna göre güncellenir. Böylece, ağ istenen çıkışı vermek için gerekli öznitelikleri çıkartmaya yarayacak filtreleri tasarlamış olur. Havuzlama katmanı alt örnekleme yoluyla veri boyutunu azaltmaya yarayan bir katmandır. Doğrusal olmayan katmanda ise giriş doğrusal olmayan bir fonksiyondan geçirilir, literatürde en çok kullanılan aktivasyon fonksiyonu ReLu (Rectified Linear Units) aktivasyon fonksiyonudur. İki boyutlu konvolüsyon ve havuzlama işlemlerine örnekler Şekil 3.3 ve Şekil 3.4'te verilmiştir.

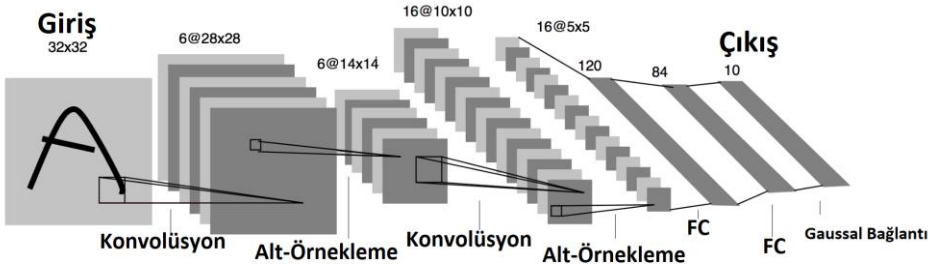


Şekil 3.3. İki boyutlu konvolüsyon işlemi



Şekil 3.4. Havuzlama işlemi

Literatürde CNN olarak kabul edilen ilk mimari LeCun tarafından, elle yazılmış karakterleri tanıma problemi için önerilen LeNet-5 mimarisidir [15]. LeNet-5, 7 katmandan oluşmaktadır. LeNet-5 mimarisi Şekil 3.5'te verilmiştir. Derin olarak nitelendirilebilecek bir ağ yapısına sahip olmamakla beraber, günümüzde kullanılan derin ağlara yapıca çok benzerdir ve onlara temel oluşturmuştur. CNN mimarisinin eğitiminde geriye yayma algoritması (Backpropogation) ile SGD (Stochastic Gradient Descent) kullanılmıştır. Böylece, CNN mimarilerinin eğitimi için uygun optimizasyon algoritması boşluğu doldurulmuştur. LeNet-5 mimarisi, geriye yayma algoritması kullanılarak eğitilen CNN mimarilerine literatürdeki ilk örnek olması ve bu mimarilerin gerçek bilgisayarla görme problemlerinde başarıyla uygulanabileceğini göstermiş olması sebebiyle önemlidir.



Şekil 3.5. LeNet-5 mimarisi [15]

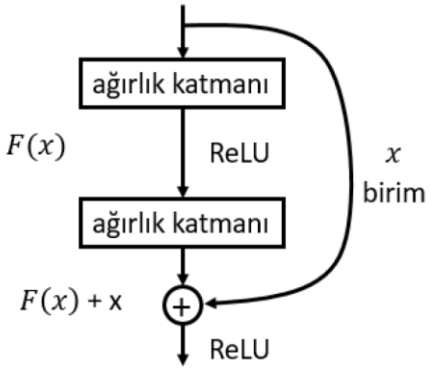
Derin öğrenme alanındaki ilk çalışmalar yeni olmamakla birlikte, yöntemlerin başarılı bir şekilde kullanımı son yıllara kadar sağlanamamıştır. Derin öğrenme yöntemlerinin başarı ile çalışabilmeleri için büyük eğitim verilerine ve eğitim algoritmalarını çalıştırabilecek kapasitede donanımlara ihtiyaç vardır. Son yıllarda multimedya verisinin artışı ile büyük veri setlerinin ortaya çıkışı ve aynı zamanda derin ağların eğitiminde grafik işlemcilerin (GPU) kullanımı, derin öğrenme yöntemlerinin yükselişinin önünü açmıştır. Görüntü işleme özelinde ise, 2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından önerilen CNN mimarisi AlexNet'in [16] ImageNet Büyük Ölçekli Görsel Tanıma Yarışması'nda (ImageNet Large Scale Visual Recognition Challenge - ILSVRC) aldığı birinciliğe kadar CNN mimarilerinin başarımlarının görece basit problemlerle sınırlı kalacağı düşünülmüştü. 2012 yılına kadar bilgisayarla görü dünyasını öznitelik çıkartma temelli makine öğrenmesi yöntemleri domine etti.

AlexNet ILSVRC nesne sınıflandırma yarışmasında aldığı birincilikle en iyi-5 (top-5) test hata oranını %15,3'e düşürerek büyük ilgi uyandıran bir başarı elde etti. AlexNet'in başarısının arkasındaki sebep, CNN mimarisinde yaptığı büyük yapısal değişiklikler değildi. Aksine, mimari yapı LeNet-5'e çok benzerdi. AlexNet daha fazla sayıda katmandan (25 katman) oluşmaktaydı ve eğitim için kullanılan veri seti çok daha büyüktür [16].

Takip eden yıllarda ILSVRC yarışmasında birincilik alan sınıflandırıcılar yine CNN mimarileri oldu. 2013 yılında ZFNet [17], AlexNet nimarisindeki hiperparametreleri optimize ederek başarımı bir miktar arttırdı. 2014 yılında GoogleNet [18], CNN mimarisine kattığı görü modülü (inception modüle) ile daha derin ağların eğitilmesine imkan sağladı. 2015 yılında ResNet mimarisi [19], kalıntı ağ bağlantıları (residual

connection) ile bağlı yeni bir CNN mimarisini literatüre kazandırarak çok derin ağların verimli bir şekilde eğitilebilmesinin önünü açtı.

Çok derin ağların türev tabanlı optimizasyon algoritmalarıyla eğitilmeleri durumunda sıfırlanan gradyan (vanishing gradient) ve patlayan gradyan (exploding gradient) gibi problemlerle karşılaşılabilmektedir. Ayrıca standart CNN mimarileri birim fonksiyonu (identity function) öğrenmekte güçlük çekerler. Bu sebeple, bir noktadan sonra kullanılan katman sayısındaki artış, ağın başarımını olumsuz etkilemeye başlamaktadır. ResNet mimarisi, derin ağların kullanımında karşılaşılan bu gibi problemleri aşabilmek için önerilmiş bir CNN mimarisidir. ResNet'ler geleneksel ardışık CNN mimarisinden farklı olarak kısa yollar (skip connection) içeren kalıntı öğrenme bloklarını içermektedir. Kalıntı öğrenme bloğu Şekil 3.6'da verilmiştir. Kısa yollar sayesinde önceki bir katmanın girişi olan *x*, kısa yol vasıtasıyla ileriki bir katmanın çıkışına, yani *F(x)*'e direkt bağlanmaktadır/eklenmektedir. Bu kısa yollar sayesinde çok derin ağlar verimli bir şekilde eğitilebilmektedir [19].



Şekil 3.6. Kalıntı (Residual) öğrenme bloğu [19]

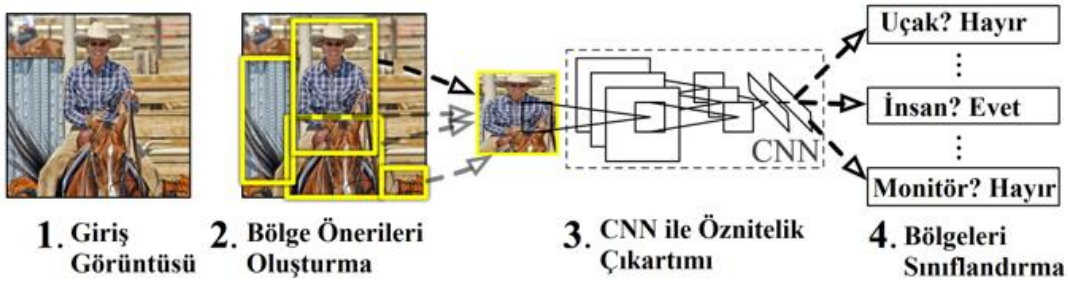
CNN mimarilerinin bilgisayarla görmedeki ilk kullanım alanı nesne sınıflandırma uygulamalarıydı. Mimarilerin son katmanı sınıf sayısı kadar çıkış üreten bir softmax ile birlikte tasarlandığı takdirde, CNN mimarileri sınıflandırıcı olarak kullanılabilmektedirler. CNN mimarileri sınıf sayısının sınırlı olduğu görece basit tespit problemlerinde kayan pencereler yaklaşımı ile tespit yöntemi olarak kullanılmaktaydı [20]. Nesne tespiti için en yaygın yaklaşımlardan biri olan kayan pencereler yaklaşımı, tespit problemini ikili bir sınıflandırma problemine indirger. Geleneksel kayan pencereler nesne tespiti yaklaşımında, sabit boyutlu bir çerçeve

görüntü üzerinde bütün olası konumlarda kaydırılarak tüm görüntü taranır. Kaydırılan çerçevenin sınırları içerisinde kalan alt-imge/blok için bir sınıflandırma sonucu üretilir. Böylece tespit edilecek nesne veya nesnelerin, sınıf ve konum bilgisi elde edilmiş olur. Fakat burada kayan pencere boyutu seçimi çok kritiktir. Sınıf sayısının çok olduğu, sınıflara ait nesnelerin farklı boyut ve en-boy oranında da bulunabildiği senaryolarda, optimum pencere seçimi yapabilmek zordur. Çoğu zaman farklı boyut ve çerçeve oranlarına sahip pencereleri birlikte kullanmak gerekir. Bu yüzden pek çok uygulama için bu çözüm makul olmamaktadır.

CNN-tabanlı nesne tespiti yöntemleri, iki aşamalı tespit yöntemleri ve tek aşamalı tespit yöntemleri olarak iki grupta değerlendirilebilir. İki aşamalı tespit yöntemleri, ilk aşamada görüntü içerisinde nesnenin/nesnelerin bulunabileceği potansiyel bölgeleri (alan önerileri) belirler. İkinci aşamada ise bu alan önerileri için sınıflandırma yapar. Tek aşamalı tespit yöntemlerinde ise nesnelerin konumları ve sınıfları eş zamanlı olarak tahmin edilir. İki aşamalı tespit yöntemlerine örnek olarak R-CNN [21], Fast R-CNN [22] ve Faster R-CNN [23], tek aşamalı tespit yöntemlerine örnek olarak ise YOLO [25] ve SSD [26] gösterilebilir. Herhangi bir uygulama için kullanılabilecek en uygun yöntem uygulamanın hafıza, süre ve başarım kısıtlarına göre değişecektir.

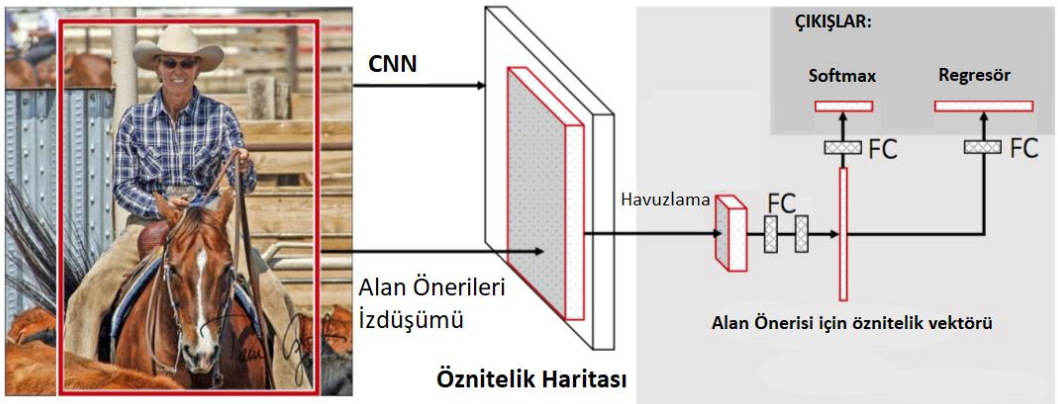
R-CNN iki aşamalı bir nesne tespit yöntemi olup CNN mimarilerinin nesne sınıflandırma problemindeki yüksek başarımından esinlenilerek önerilmiş ilk nesne tespit algoritmalarındandır. İlk aşamada, harici bir algoritma ile alan önerileri oluşturulur. R-CNN'in alan önerilerini oluşturmak için kullandığı Seçici Arama (Selective Search) algoritması, bir görüntü için 2000 alan önerisi üretmektedir. İkinci aşamada, alan önerileri birer birer CNN ile işlenerek öznitelikleri çıkartılır, son aşamada ise sınıflandırma SVM sınıflandırıcılar kullanılarak yapılır. Ayrıca mimaride, Seçici Arama algoritmasınca belirlenen sınırlayıcı kutulara düzeltme uygulayan bir regresör de yer almaktadır. R-CNN'de, CNN mimarisi bir öznitelik çıkartıcı olarak çalışmaktadır. R-CNN mimarisi Şekil 3.7'de verilmiştir. Yöntem her bir alan önerisini mimaride ayrı ayrı işlediği için hem eğitim hem de test aşamaları uzun sürmektedir. Ayrıca çok fazla öznitelik haritasının oluşmasına ve yüksek hafıza ihtiyacına sebep olmaktadır. Mimaride birbirinden bağımsız bir çok modül bulunması eğitim

vermimliliğini de düşürmektedir. Yöntemin PASCAL VOC 2010 veri setindeki mAP (mean average precision) değeri % 53,7'dir [21].



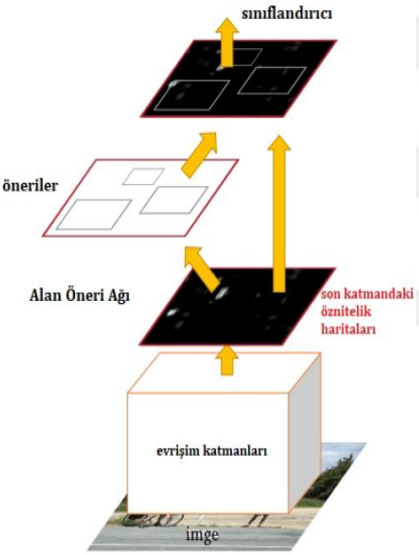
Şekil 3.7. R-CNN nesne tespitine genel bir bakış [21]

R-CNN metodunun en büyük dezavantajı, alan önerilerini ayrı ayrı işlemesidir. Bunun önüne geçmek için Fast R-CNN, giriş görüntüsünün tamamını tek seferde bir CNN mimarisine sunarak, tek bir öznitelik haritası çıkartmayı önermiştir. Böylece ikinci aşamada, alan önerileri giriş görüntüsü yerine öznitelik haritasına izdüşürüldüğünde, her alan önerisi için öznitelik haritası tek seferde elde edilmiş olur. Fast R-CNN alan önerilerinin sınıflandırılması için SVM yerine CNN mimarisinim softmax katmanını kullanmaktadır. Ayrıca CNN çıkışında, Seçici Arama algoritmasınca belirlenen sınırlayıcı kutulara düzeltme uygulayan bir regresör de yer almaktadır. Fast R-CNN mimarisi Şekil 3.8'de görülebilir. Fast R-CNN ile R-CNN yaklaşımı hızlanmış olsa da işlem zamanın çoğunun alan önerilerinin oluşturulmasında harcandığı farkedilmiştir. Pascal VOC 2010 test seti için, eğitimde Pascal VOC 2007 ve 2012 veri setleri kullanıldığı durumda mAP değeri % 68,8 bulunmuştur [22].



Şekil 3.8. Fast R-CNN nesne tespitine genel bir bakış [22]

R-CNN ve Fast R-CNN alan önerilerini oluşturmak için Seçici Arama (Selective Search) benzeri harici bir yönteme ihtiyaç duymaktadır. Faster R-CNN, bu ihtiyacı ortadan kaldırmak için harici bir algoritma yerine Region Proposal Network (RPN - Alan Öneri Ağı) yapısını kullanmayı önermiştir. RPN de bir CNN mimarisidir ve öznitelik haritaları üzerinden alan önerileri üretir. RPN, Fast R-CNN mimarisinin içine yerleştirilmiştir. Başka bir deyişle, Faster R-CNN mimarisi RPN ve Fast R-CNN mimarilerinin birleşiminden oluşmaktadır [23]. Faster R-CNN mimarisi Şekil 3.9'da verilmiştir. R-CNN, Fast R-CNN, Faster R-CNN yöntemlerinin nesne tespit başarımları Tablo 3.1'de verilmiştir. Çerçeve işleme hızları [32]'deki çalışmada, GeForce GTX Titan X GPU üzerinde hesaplanmıştır.



Şekil 3.9. Faster R-CNN nesne tespitine genel bir bakış [23]

Tablo 3.1.PASCAL VOC 2007 Test veri seti için iki-aşamalı nesne tespit yöntemlerinin başarımları [22, 23, 26]

Yöntem	**Eğitim Veri Seti**	**mAP**	**Saniyedeki Çerçeve**
R-CNN	VOC 07	%66,0	-
Fast R-CNN	VOC 07 + VOC 12	%70,0	0,5
Faster R-CNN	VOC 07 + VOC 12	%73,2	7

Tek aşamalı tespit yöntemleri görüntüyü işlerken, alan önerilerini ve sınıflandırma sonuçlarını eş zamanlı olarak üretirler. Tek aşamalı bir nesne tespit yöntemi olan YOLO, sınırlayıcı kutuların ve sınıf olasılıklarının tahmini için tek bir CNN kullanır. Görüntüyü, tek bir CNN ile tek seferde işlediği için, iki aşamalı tespit yöntemlerine kıyasla hızlı çalışır. Eğitim verisi hazırlanırken, görüntü önce S×S adet kutucuğa bölünür. Konumları bilinen nesnelerin, bu kutucukların içine düşüp düşmediğine göre eğitim verisi hazırlanır. Kullanılan anchor box sayısına bağlı olarak bir kutucukta birden fazla sayıda nesne yer alabilir. Anchor box sayısı N adet olduğu durumda, S×S×N adet sınırlayıcı kutu tahmini oluşmaktadır. Test aşamasında YOLO, nesne tespitine bir regresyon problemi gibi yaklaşır. Tespit sonucunda bir sınırlayıcı kutu x, y, w, h, g değerleri ile temsil edilir. x,y nesnenin kutucuktaki merkez koordinatları, w,h nesnenin genişliği ve yüksekliği, g ise nesne hakkındaki bir güven skorudur. Daha sonra, Maksimum Olmayanların Bastırılması (Non Max Supression) yöntemiyle tahmin edilen sınırlayıcı kutular arasında bir eleme yapılır ve son tespit sonuçları oluşturulur. YOLO nesne tespiti modeli Şekil 3.10'da verilmiştir [24]. YOLO öznitelik olarak tek bir katmandaki aktivasyon haritasını kullanır ve küçük nesneleri tespitte görece başarısızdır. CNN mimarilerinin özellikle ilk katmanlarındaki öznitelik haritaları küçük ölçekli nesnelerin tespiti için önemlidir. Bir diğer tek aşamalı tespit yöntemi olan SSD ise, birçok katmanın çıkışında oluşacak aktivasyon haritalarının sentezini öznitelik olarak kullanır. Fakat ilk katmanlarda oluşan yüksek çözünürlüklü öznitelik haritalarını kullanmadığı için küçük nesnelerin tespitinde görece başarısız kalmıştır.



Şekil 3.10. YOLO nesne tespitine genel bir bakış [24]

YOLO v2 [26], YOLO'ya tespit başarımını ve çalışma hızını arttıran bir takım yenilikler getirmiştir. YOLO v2, öznitelik çıkartıcı CNN mimarisi olarak Darknet-19 kullanmaktadır. YOLO v2, sınırlayıcı kutuların tahmininde anchor box kullanmaktadır. Küçük nesnelerin tespit başarımını yükseltmek amacıyla YOLO v2

ağında, yüksek çözünürlüklü öznitelik haritaları alt örneklenerek, düşük çözünürlüklü öznitelik haritaları ile birleştirilmektedir. YOLO v2'nin orijinal YOLO mimarisine kattığı önemli yeniliklerden bir diğeri ise çok-ölçekli eğitimdir (multi-scale training). Çok ölçekli eğitim esnasında, giriş görüntüsünün boyutu sabit değildir. Tablo 3.2'te Pascal VOC 2007 veri seti için tespit başarımları yer almaktadır. Modeller 2007 ve 2012 Pascal VOC veri setleri kullanılarak, GeForce GTX Titan X GPU üzerinde eğitilmiştir. YOLO v2 için giriş görüntüleri 480×480 piksel boyutludur. YOLO'da ise giriş görüntüleri 448×448 piksel boyutludur.

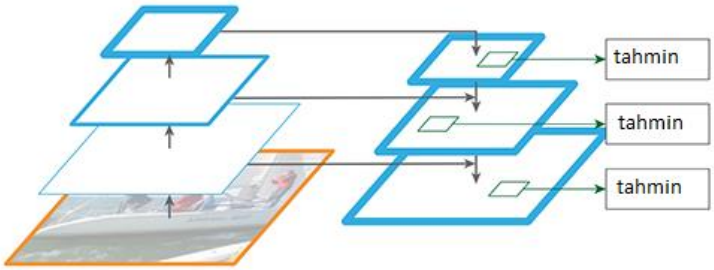
Tablo 3.2.Nesne tespit yöntemlerinin karşılaştırılması [26]

Model	**mAP**	**Saniyedeki Çerçeve**
YOLO	% 63,4	45
Fast R-CNN	%70,0	0,5
Faster R-CNN	%73,2	7
YOLO v2	%77,8	59

Öznitelik piramitleri ölçek değişmezliğini gürbüzleştirmek için geleneksel nesne tespiti algoritmalarında kullanılan bir öznitelik çıkartma tekniğidir. Fakat verinin öznitelik piramitleri ile temsili ekstra hafıza ihtiyacını ve işlemsel yükü beraberinde getirdiği için derin öğrenme mimarilerinde tercih edilmemekteydi. FPN (Feature Pyramid Network) [27] ise CNN mimarilerinin doğasındaki hiyerarşik yapıdan faydalanarak, öznitelik piramitlerine benzer bir yaklaşım önermiştir.

FPN mimarisi çok ölçekli öznitelik piramidi oluşturmak için önerilmiş, öznitelik çıkartıcı bir CNN mimarisidir. Mimari düşük çözünürlüklü ve anlamsal olarak güçlü öznitelikler ile yüksek çözünürlüklü ve anlamsal olarak zayıf öznitelikleri yatay ve tepeden alta (top-down) bağlantılarla ilişkilendirir. Önce giriş görüntüsü bir CNN mimarisi tarafından işlenerek öznitelik haritaları oluşturulur. Eş boyutlu öznitelik haritaları bir araya getirilir ve her birinin son katmanı o grubun temsilcisi olarak seçilir. Mimarideki düşük çözünürlüklü, anlamsal (semantik) olarak güçlü öznitelik haritaları üst örneklenir. Üst örneklenen haritalar, yatay bağlantılar (lateral connections) ile eş boyutlu öznitelik haritalarının pekiştirmekte kullanılır. Her katmanda bir sınıflandırıcı

ve regresör çıkışı bulunmaktadır, Şekil 3.11'de görüldüğü üzere nesne tespiti tüm katmanlarda ayrı ayı ve bağımsız olarak yapılır.



Şekil 3.11. FPN (Feature Pyramid Network) [27]

İki aşamalı tespit yöntemleri daha yüksek tespit başarımları ile çalışmaktadırlar; fakat daha karmaşık bir işleyişe sahiptirler, optimizasyonları daha güçtür ve yavaş çalışırlar. Tek aşamalı tespit yöntemlerinin tespit başarımları daha düşük olup bu yöntemler nesnelerin (özellikle küçük boyutlu) konumlarının tahmininde görece daha başarısızdır. Buna karşın bu tip yöntemler daha hızlı çalışırlar ve gerçek zamanlı uygulamalar için daha uygundurlar. İki aşamalı tespit yöntemlerinin tek aşamalı tespit yöntemlerine göre daha yüksek tespit başarımı ile çalışmasının altında yatan sebep sınıf dengesizliğidir. İki aşamalı tespit yöntemleri, tek aşamalı tespit yöntemlerine kıyasla çok daha az sayıda alan önerisini işlemek üzere eğitilmektedirler. Dolayısıyla, tek aşamalı tespit yöntemleri eğitim esnasında kolay negatif (easy negative) örneklere boğulmaktadır. Bu sebeple eğitimin verimliliği düşmektedir. RetinaNet ağı [28] eğitimin ağırlıklı olarak zor örnekleri (hard example) baz alarak yapılabilmesi için kayıp fonsiyonu olarak "Focal Loss" kayıp fonksiyonunu kullanmayı önermiştir. RetinaNet bir iskelet ağ ve iki eyleme özgü (task specific) alt-ağdan oluşan, basit ve tümleşik bir yapıdır. Alt-ağlardan biri CNN çıkışındaki öznitelik haritasına göre sınıflandırma yaparken, diğer alt-ağ regresyon ile sınırlayıcı kutuları üretir. RetinaNet iskelet ağ olarak FPN kullanmaktadır. RetinaNet'in tespit başarımı daha önce önerilmiş tüm iki aşamalı tespit yöntemlerini geçerken, hız bakımından da tek aşamalı tespit yöntemlerine yetişmiştir [28].

YOLO v3, öznitelik çıkartıcı CNN mimarisi olarak Darknet-53 kullanmaktadır. YOLO v3, sınıf tahmini yaparken FPN benzeri bir yaklaşım ile üç farklı ölçekteki öznitelik haritalarını kullanarak çok ölçekli tahmin (multi-scale prediction)

yapmaktadır. Nesne sınıflarını tahmin ederken ise softmax yerine çok etiketli bir sınıflandırmaya imkan sağlayan bağımsız lojistik sınıflandırıcı (independent logistic classifier) kullanmaktadır. YOLO v3'te, maliyet fonksiyonu da diğer YOLO versiyonlardan farklı hesaplanmaktadır. Önceki YOLO versiyonları küçük nesnelerin tespitinde düşük başarım ile çalışmaktadır. YOLO v3'te ise diğer versiyonlara kıyasla özellikle küçük nesnelerin tespit başarımı önemli derecede artmıştır. Tablo 3.3'teki yöntemlerin başarımları COCO veri seti için hesaplanmıştır. En yüksek başarımla çalışan yöntem olan RetinaNet, YOLO v3'e kıyasla yaklaşık 3,8 kat daha yavaş çalışmaktadır [29].

Tablo 3.3. Nesne tespit yöntemlerinin karşılaştırılması [29]

Yöntem	İskelet CNN	AP	AP_{50}	AP_{75}	AP_S	AP_M	AP_L
YOLO V2	DarkNet-19	21,6	44,0	19,2	5,0	22,4	35,5
RetinaNet	ResNet-101-FPN	**39,1**	**59,1**	**42,5**	**21,8**	**42,7**	**50,2**
YOLO V3	DarkNet-53	33,0	57,9	34,4	18,3	35,4	41,9

4. LCD PİKSEL HATALARININ TESPİTİ İÇİN ÖNERİLEN YÖNTEMLER

Bu tez çalışmasında LCD panellerde bulunan piksel hatalarının tespiti için makine öğrenmesi temelli üç yöntem önerilmektedir. Birinci yöntem, Gri Seviye Eş-Oluşum Matrislerinden (GLCM) elde edilen özniteliklerinin Destek Vektör Makinaları (SVM) ile sınıflandırılması temellidir. İkinci yöntem CNN sınıflandırıcı kullanmaktadır. Üçüncü yöntemde ise LCD piksel hatalarının tespiti için tümleşik ve tek aşamalı bir CNN mimarisi kullanılmıştır

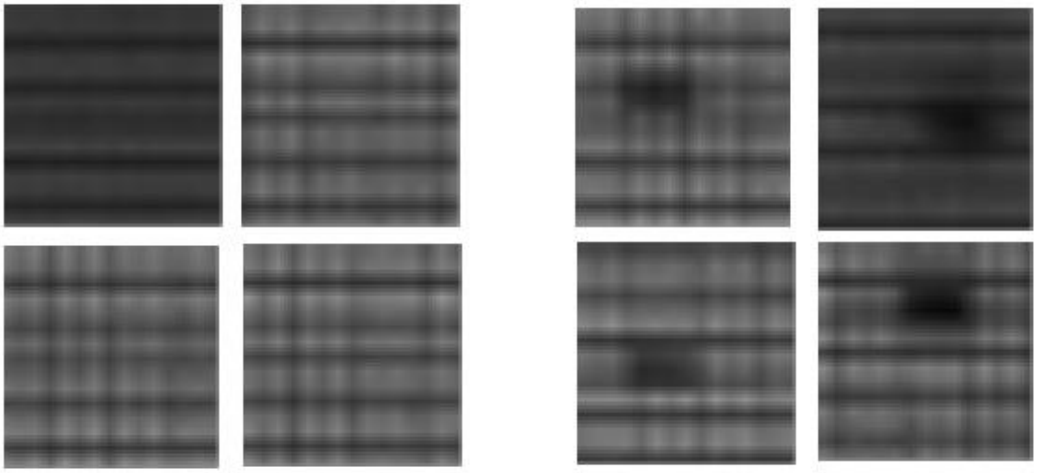
4.1. LCD Piksel Hatalarının GLCM Öznitelikleri ve SVM ile Tespiti

Bu yöntemde Gri Seviye Eş-Oluşum Matrislerinden (GLCM) elde edilen öznitelikler Destek Vektör Makinaları (SVM) kullanılarak sınıflandırılmaktadır. SVM sınıflandırıcı, hatalı piksel barındıran ve barındırmayan örnek görüntülerden elde edilmiş öznitelikler ile eğitilmiştir. Test aşamasında, hatalı piksellerin tespiti için geleneksel kayan pencereler yaklaşımı kullanılmıştır. Son olarak, her bir hatalı piksel için, yalnız bir sınırlayıcı kutu elde etmek amacıyla örtüşme oranı tabanlı bir eleme yapılmıştır.

Tez çalışmasının bu bölümünde önerilen yöntem, denetimli öğrenme kullanan bir makine öğrenmesi algoritmasıdır. Yöntem eğitim ve test aşamalarından oluşmaktadır. Eğitim ve test görüntüleri deneysel sistem kullanılarak oluşturulan veri setinden elde edilmiştir. Veri seti ile ilgili detaylı bilgi Bölüm 2.1'de verilmiştir.

Eğitim için, veri setindeki orijinal görüntülerden 15×15 boyutlu 3702 adet çerçeve alınmıştır. Çerçevelerin 3183 adedi hatasız piksel sınıfını, 519 adedi ise hatalı piksel sınıfını temsil eden örneklerdir. Eğitim veri setinden örnek görüntüler Şekil 4.1'de verilmiştir. Eğitim verileri, SVM sınıflandırıcının eğitiminde kullanılmıştır. Test için, veri setindeki orijinal görüntülerden 1000×1000 boyutlu 50 adet çerçeve alınmıştır.

Test verisi, hatalı piksel tespiti için kayan pencereler yaklaşımı uygulayan yöntemin performans değerlendirmesinde kullanılmıştır.



(a) (b)

Şekil 4.1. Örnek eğitim verileri (a) Hatasız pikseller (b) Hatalı pikseller

4.1.1. Özellik çıkartımı

Gri-seviye eş oluşum matrisleri kullanılarak çıkartılan Haralick öznitelikleri kullanılmıştır. Gri-seviye eş oluşum matrisleri, gri ölçekli bir görüntüde pikseller arasındaki mesafe d ve açı θ iken gri seviye i değerinden gri seviye j değerine geçiş olasılıklarını ifade eder. Eş oluşum matrisleri referans piksel ve komşu piksel için gri seviyesi farklılıkları inceler [31]. Açı ve sıklık bilgisi barındıran bu matrisler iki boyutlu histogramlardır. Eş oluşum matrisleri ikinci dereceden istatistiksel özniteliklerin çıkartımında kullanılırlar. Her mesafe ve açı için ayrı ayrı N×N boyutlu GLCM matrisleri oluşacağından hesapsal yükü fazla olabilmektedir. Hesapsal yükün azaltılması için imgenin gri ton sayısı azaltılabilirse de bu bir miktar bilgi kaybına sebep olacaktır. Önerilen yöntemde gri ton sayısı azaltmak için herhangi bir ön işlem yapılmamıştır.

$$\text{Enerji} = \sum_{i,j} P_{ij}^2 \tag{4.1}$$

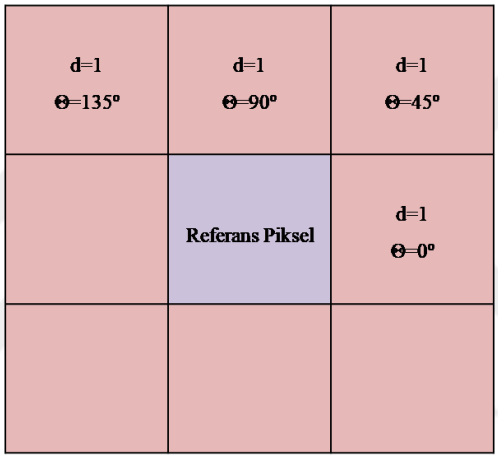
$$\text{Karşıtlık} = \sum_{i,j} |i-j|^2 \, P_{ij} \tag{4.2}$$

$$\text{Korelasyon} = \frac{\sum_{i,j} (ij) P_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \tag{4.3}$$

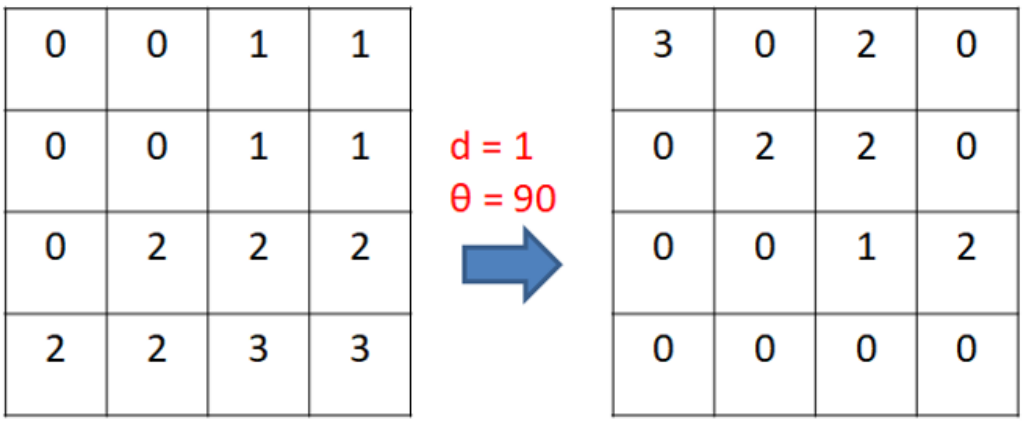
$$\text{Homojenlik} = \sum_{i,j} \frac{P_{ij}}{1+|i-j|} \tag{4.4}$$

$$\text{Entropi} = -\sum_{i,j} P_{ij} \log P_{ij} \tag{4.5}$$

GLCM matrisleri referans ve komşu pikseller arasındaki mesafenin d=1, açının ise $\theta = 0°, \theta = 45°, \theta = 90°,\ \theta = 135°$ olması durumlarında hesaplanmıştır. Referans piksel ve komşu pikseller arasındaki uzamsal ilişki Şekil 4.2'de de görülmektedir. Örnek bir GLCM hesabı Şekil 4.3'te verilmiştir. Hesaplanan GLCM matrisleri kullanılarak enerji, korelasyon, karşıtlık, entropi, homojenlik özellikleri elde edilmiştir.



Şekil 4.2. Referans ve komşu pikseller arasındaki ilişki

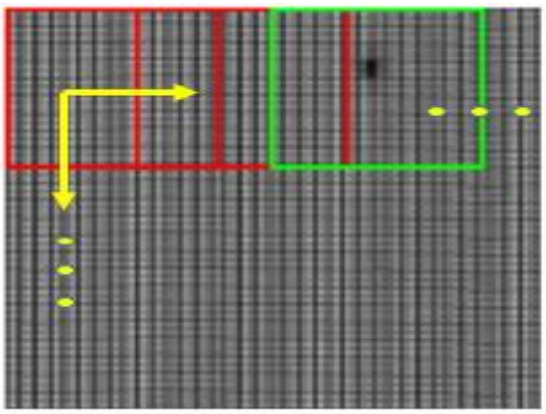


(a) (b)

Şekil 4.3. d=1 ve θ=0 için örnek GLCM (a) Giriş matrisi (b) GLCM

4.1.2. Piksel hatası tespiti

Piksel hatalarının tespiti kayan pencereler yaklaşımı kullanılarak gerçekleştirilmiştir. Geleneksel kayan pencereler nesne tespiti yaklaşımında, sabit boyutlu bir pencere görüntü üzerinde kaydırılarak tüm görüntü taranır. Kaydırılan pencerenin sınırları içerisinde kalan alt-imge için sınıflandırma yapılır. Böylelikle ilgilenilen nesne veya nesnelerin, sınıf ve konum bilgisi elde edilmiş olur. Kayan pencereler nesne tespiti yaklaşımının işleyişi Şekil 4.4'te görülmektedir. Test için, veri setindeki orijinal görüntülerden elde edilen 1000×1000 boyutlu 50 adet çerçeve üzerinde kayan pencere yaklaşımı uygulanmıştır. Çerçeve boyutu 15×15, atlama miktarı 5'tir. Kaydırılan pencerenin sınırları içerisinde bulunan alt-imge için enerji, korelasyon, karşıtlık, entropi, homojenlik özellikleri hesaplanmıştır, eğitilen SVM sınıflandırıcı her bir konum için hatalı ve hatasız piksel sınıflandırması gerçekleştirilerek tüm görüntü taranmıştır. Piksel hatalarının sınıflandırılmasında kullanılan SVM yaklaşımı iki sınıflı sınıflandırma problemi için literatürde yaygın olarak kullanılan bir yaklaşımdır [32]. SVM yaklaşımı, iki sınıflı bir sınıflandırma probleminde, sınıfları ayıracak optimum ayırtacı bulmayı hedefler. Ayırtaca en yakın eğitim verilerine destek vektörleri denilir. En iyi ayırtaç sınıflar arası mesafeyi en büyükleyecek ayırtaçtır. Verilerin doğrusal ayrışabilir olduğu durumda, optimum ayırtaç bir doğru olur.

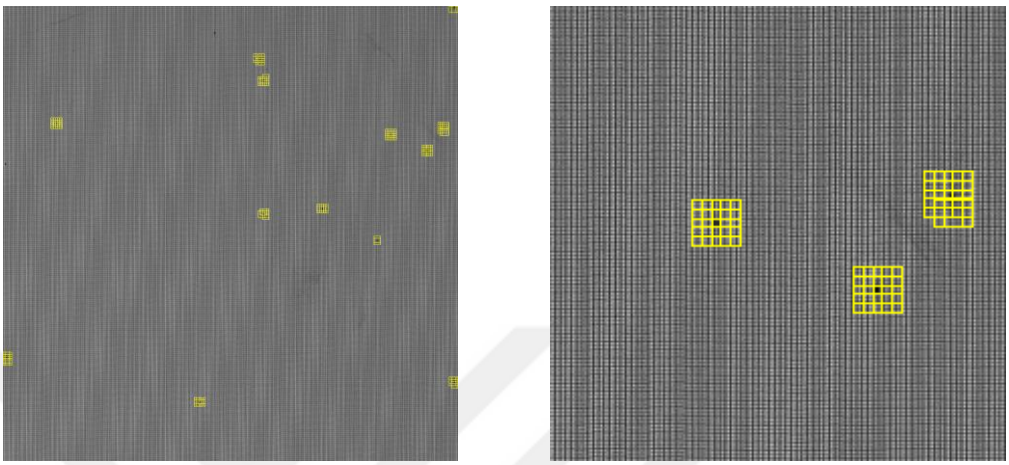


Şekil 4.4. Kayan pencereler nesne tespiti

4.1.3. Son işlem

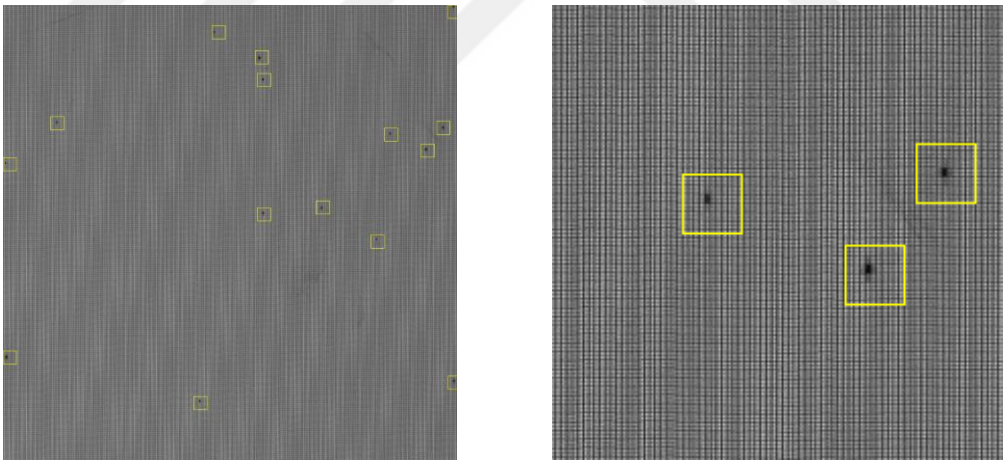
Kayan pencereler yaklaşımı ile tüm test görüntü tarandığında, tek bir hatalı piksel için tespit yöntemi birden fazla sayıda sınırlayıcı kutu tahmini yapmaktadır. Son işlem olarak, her bir hatalı piksel için, yalnız bir sınırlayıcı kutu elde etmek amacıyla örtüşme

oranı tabanlı bir eleme yapılmıştır. Örtüşme oranı %20'den fazla olan sınırlayıcı kutulardan yalnızca biri son tahmin olarak seçilmiş, sınırlayıcı kutunun boyutları ise 30×30 olarak güncellenmiştir. Son işlem öncesindeki ve sonrasındaki örnek sonuçlar sırasıyla Şekil 4.5 ve Şekil 4.6'da görülmektedir.



(a) (b)

Şekil 4.5. Son işlem öncesi tespit sonuçları (a) Tespit görüntüsü (b) Tespit görüntüsünün yakınlaştırılmış hali



(a) (b)

Şekil 4.6. Son işlem sonrası tespit sonuçları (a) Tespit görüntüsü (b) Tespit görüntüsünün yakınlaştırılmış hali

4.1.4. Deneysel sonuçlar

Bu çalışmada önerilen LCD piksel hatası tespit yönteminin nesnel bir performans değerlendirmesi için kesinlik, duyarlılık ve F1 skoru ölçütleri kullanılmıştır. Tablo 4.2'de, GLCM matrisleri kullanılarak hesaplanan farklı özniteliklerin kullanımı

durumunda tespit performansları verilmiştir. Her satır farklı özniteliklerin kullanım durumunu incelemektedir. Kullanılan öznitelikler Tablo 4.1'de verilmiştir.

Tablo 4.1. Kullanılan öznitelikler

Öznitelik Seti	Korelasyon	Homojenlik	Karşıtlık	Enerji	Entropi
Ö-1	×				
Ö -2		×			
Ö -3			×		
Ö -4				×	
Ö -5					×
Ö -6	×	×			
Ö -7	×	×			×
Ö -8	×	×		×	
Ö -9	×	×	×		
Ö -10	×		×	×	
Ö -11	×	×	×	×	
Ö -12	×	×	×	×	×

Tablo 4.2. Hatalı piksel tespit başarımı

	Ö-1	**Ö-2**	**Ö-3**	**Ö-4**	**Ö-5**	**Ö-6**	**Ö-7**	**Ö-8**	**Ö-9**	**Ö-10**	**Ö-11**	**Ö-12**
Kesinlik	0,33	0	0	0	0,12	0,88	0,89	**0,99**	0,62	0,93	0,95	0,98
Duyarlılık	0,83	0	0	0	0,40	0,84	0,85	**0,80**	0,81	0,79	0,79	0,70
F1 Skor	0,47	-	-	-	0,18	0,86	0,87	**0,89**	0,71	0,85	0,86	0,81

Tablo 4.2'de verilen farklı GLCM özniteliklerinin kullanımı durumunda kesinlik, duyarlılık ve F1 skoru metriklerinin başarımı incelendiğinde bazı özniteliklerin birlikte kullanıldıkları durumlarda ayırt ediciliğe ve dolayısıyla tespit başarımına olumlu katkı sağladıkları, bazı özniteliklerin ise katkısının görece az olduğu görülmektedir. Örneğin korelasyon ve homojenlik özniteliklerinin birlikte kullanımı (Ö-6) durumunda ayırt edicilik artmıştır. Öte yandan korelasyon, homojenlik ve entropi özniteliklerinin birlikte kullanımı durumunda (Ö-7), entropi özniteliğinin mevcut ayırt ediciliğe katkı sağlamadığı görülmüştür. En iyi tespit sonuçları homojenlik, korelasyon ve enerji

öznitelikleri kullanılarak elde edilmiştir. Bu durumda elde edilen kesinlik, duyarlılık ve F1 skorları sırasıyla 0,99, 0,80 ve 0,89'dur. Öznitelik seti seçiminde ReliefF yaklaşımı [32] denenmiştir. Bu yaklaşımı ile seçilen en iyi üç öznitelik ile öznitelik seti Ö-7 oluşmaktadır.

4.2. LCD Piksel Hatalarının CNN ile Tespiti

Tez çalışmasında önerilen ikinci yöntem LCD piksel hatalarının tespiti için Konvolüsyonel Sinir Ağları (CNN) ve kayan pencere yaklaşımını birlikte kullanmaktadır. Yöntem eğitim ve test aşamalarından oluşmaktadır. Eğitim ve test verileri SVM temelli yöntemde anlatıldığı şekilde deneysel sistem kullanılarak oluşturulan veri setinden elde edilmiştir. CNN sınıflandırıcı, hatalı piksel barındıran ve barındırmayan örnek görüntülerden elde edilmiş öznitelikler kullanılarak eğitilmiştir.

CNN mimarisinin son tam bağlantılı katmanı bir softmax olarak tasarlanmış, böylece CNN hem bir öznitelik çıkartıcı hem de sınıflandırıcı olarak kullanılmıştır. Eğitimde kullanılan parametreler Tablo 4.3'te verilmiştir.

Tablo 4.3. CNN eğitim parametreleri

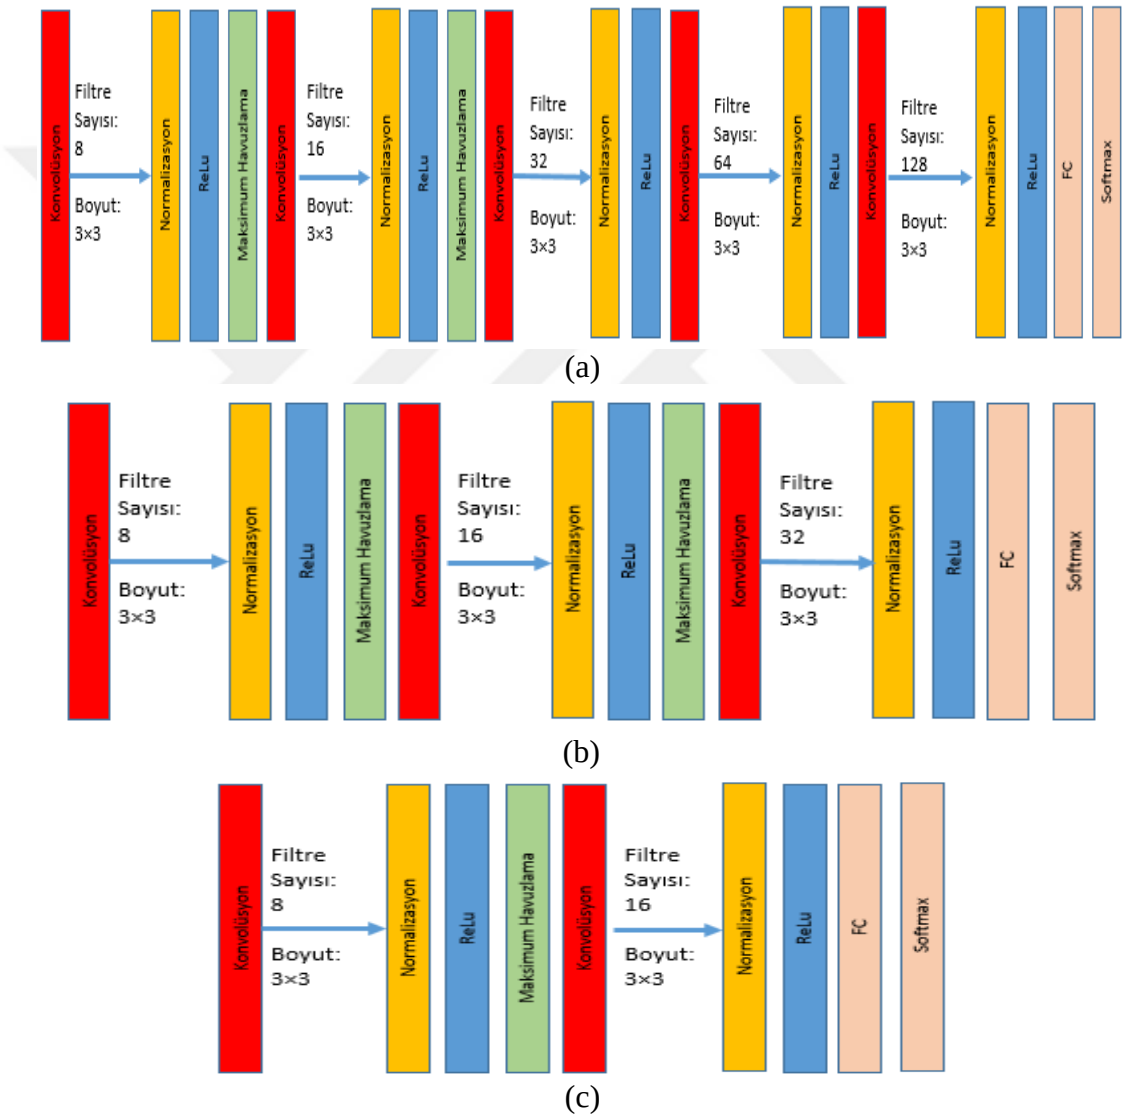
Optimizasyon Algoritması	SGDM
Öğrenme Oranı	0,01
Momentum	0,9
Maksimum Çevrim (Epoch)	4
Yığın Veri Adedi (Batch Size)	128

Test için, veri setindeki orijinal görüntülerden 1000×1000 boyutlu 50 adet çerçeve alınmıştır. Hatalı piksellerin tespiti için geleneksel kayan pencereler yaklaşımı kullanılmıştır. Son olarak, her bir hatalı piksel için, yalnız bir sınırlayıcı kutu elde etmek amacıyla örtüşme oranı tabanlı bir eleme yapılmıştır. Çalışmada, farklı derinlikte üç CNN mimarisinin tespit başarımları incelenmiştir.

4.2.1. Özellik çıkartımı

Öznitelikler CNN mimarisi kullanılarak elde edilmiştir. CNN mimarilerinin konvolüsyon katmanında öznitelik çıkartıcı görevi üstlenen filtreler bulunmaktadır.

Eğitim esnasında söz konusu filtelerin katsayıları güncellenir ve ağ istenen çıkışı vermek için gerekli öznitelikleri çıkartmaya yarayacak filtreleri tasarlamış olur. Böylelikle her konvolüsyon katmanının çıkışında öznitelik haritaları (feature map) oluşmaktadır. Çalışmada, üç farklı derinlikte CNN mimarisi oluşturulmuştur. Her konvolüsyon katmanı sonrasında bir normalizasyon katmanı ve bir ReLu aktivasyon katmanı bulunmaktadır. Konvolüsyon katmanlarında kullanılan filtre boyutları ve sayıları Şekil 4.7'de verilmiştir.



Şekil 4.7. CNN mimarileri (a) CNN-1 (b) CNN-2 (c) CNN-3

4.2.2. Piksel hatası tespiti

Piksel hatası tespiti için kayan pencereler yaklaşımı uygulanmıştır. Çerçeve boyutu 15×15, atlama miktarı 5'tir. CNN sınıflandırıcı her bir konum için hatalı ve hatasız

piksel sınıflandırması gerçekleştirmiş ve tüm görüntü taranmıştır. CNN mimarilerin son katmanı sınıf sayısı kadar çıkış üreten bir softmax ile birlikte tasarlandığı takdirde sınıflandırıcı olarak kullanılabilmektedirler. Bu yaklaşım kullanılarak, sınıflandırma sonucu CNN mimarisinin son tam bağlantılı katmanı olan softmax katmanında gerçekleştirilmiştir. Softmax sınıflandırıcı CNN tarafından çıkartılan öznitelik haritaları kullanılmıştır.

4.2.3. Son işlem

Kayan pencereler yaklaşımı ile tüm test görüntü tarandığında, tek bir hatalı piksel için tespit yöntemi birden fazla sayıda sınırlayıcı kutu tahmini yapmaktadır. Bu sorunu çözmek için SVM temelli yöntemde de kullanılan örtüşme eleme yaklaşımı son işlem olarak kullanılmamıştır.

4.2.4. Deneysel sonuçlar

Bu çalışmada önerilen LCD piksel hatası tespit yönteminin nesnel bir performans değerlendirmesi için kesinlik, duyarlılık ve F1 skoru ölçütleri kullanılmıştır. Tablo 4.4'te, farklı derinlikte CNN mimarilerinin kullanımı durumunda tespit performansları verilmektedir.

Tablo 4.4. CNN tabanlı piksel hatası tespit yöntemlerinin başarımları

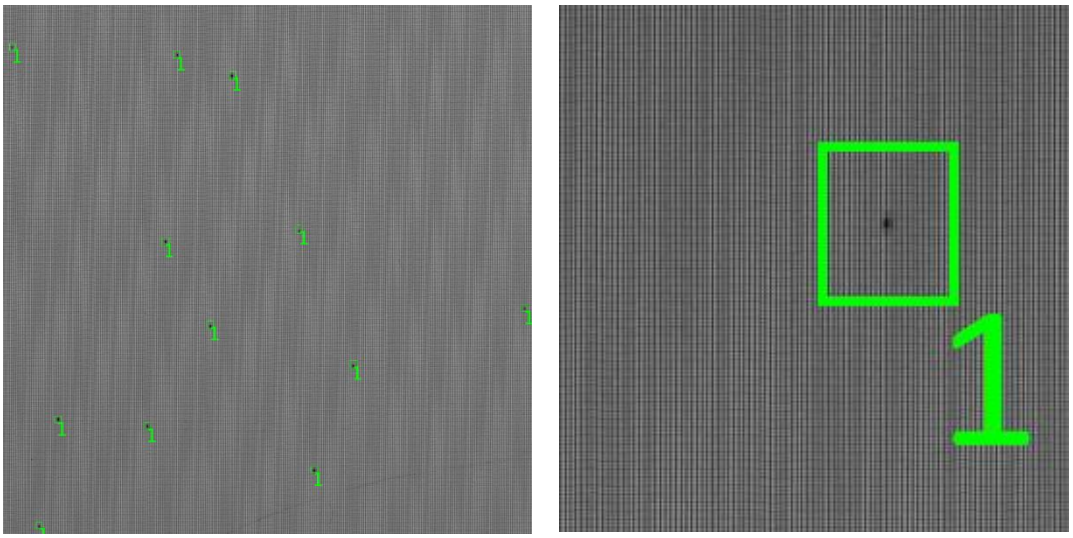
	CNN-1	CNN-2	CNN-3
Kesinlik	**0,982**	0,996	0,998
Duyarlılık	**0,959**	0,911	0,784
F1 Skoru	**0,970**	0,952	0,878

Farklı derinlikte CNN mimarilerinin kullanımı durumunda kesinlik, duyarlılık ve F1 skoru ölçütleri incelendiğinde, daha fazla sayıda konvolüsyonel katmanı ve filtre içeren mimarilerin daha yüksek başarım ile çalıştığı görülmüştür. En iyi tespit sonuçları CNN-1 mimarisi kullanılarak elde edilmiştir. Bu mimaride diğer mimarilere kıyasla daha fazla konvolüsyonel katman ve filtre yer almaktadır. Bu durumda elde edilen kesinlik, duyarlılık ve F1 skorları sırasıyla 0,98, 0,96 ve 0,97 dir.

4.3. Piksel Hatalarının Tümleşik CNN Mimarisi ile Tespiti

Bu tez kapsamında önerilen üçüncü yöntemde LCD piksel hatalarının tespiti için tümleşik bir CNN mimarisi kullanılmıştır. Bu amaçla kullanılabilecek yöntemin belirlenmesinde, küçük nesneleri tespit edebilmesi ve hızlı çalışması gibi kısıtlar dikkate alınmıştır. Bunlar göz önünde bulundurularak, tümleşik ağ olarak Facebook Yapay Zeka Araştırma Laboratuvarı'nda geliştirilen RetinaNet ağı bu problemde kullanılmak üzere tercih edilmiştir. RetinaNet ağı, öznitelik çıkartıcı bir iskelet ağ, sınırlayıcı kutuları ve sınıflandırma sonuçları üretecek iki alt-ağdan oluşmaktadır. Bu çalışmada iskelet ağ olarak 101 katmanlı bir ResNet ağı kullanılmıştır. RetinaNet ağının eğitiminde Detectron yazılımı kullanılmıştır. Detectron, Facebook Yapay Zeka Araştırma Laboratuvarında geliştirilmiş, yüksek başarımlarla çalışan tespit algoritmalarının gerçeklenmesine olanak sağlayan bir yazılımdır. Eğitim, Ubuntu 16.04 LTS işletim sisteminde GPU destekli Caffe2 çerçevesi kullanılarak yapılmıştır.

Eğitim için, veri setindeki orijinal görüntülerden 1000×1000 piksel boyutlu 1491 çerçeve oluşturulmuştur. Eğitim verisine veri arttırımı (data augmentation) teknikleri uygulanarak 5968 adet eğitim görüntüsü elde edilmiştir. Veri setiyle ilgili detaylı bilgi Bölüm 2.2'de verilmiştir. Eğitim setindeki görüntülerde yer alan hatalı piksellerin konumları MATLAB ortamında hazırlanmış bir yazılım aracı ile sınırlayıcı birer kutu içerisine alınmıştır. Eğitimde kullanılacak görüntülere bir örnek Şekil 4.8'de görülmektedir. Hatalı piksellerin etrafına çizilmiş sınırlayıcı kutuların konum bilgileri, her görüntü için ayrı bir text dosyasına kaydedilmiştir. İlgili text dosyasının içeriği Tablo 4.5'de görülmektedir. Text dosyasındaki her satır bir sınırlayıcı kutuyu temsil etmektedir. İlk sütunda, sınıf bilgisi kaydedilmiştir. x_c ve y_c sınırlayıcı kutunun yatay ve düşey koordinat bilgileri, w ve h sınırlayıcı kutunun yatay ve düşey genişliği olmak üzere, 2-4 numaralı sütunlar sırasıyla $x_c/1000$, $y_c/1000$, w/1000,h/1000 sayısal değerleridir. Detectron yazılımında kullanılmak üzere, text dosyalarında yer alan sınıf ve konum bilgileri, bir sonraki aşamada json veri formatına dönüştürülmüştür. Test için, veri setindeki orijinal görüntülerden 1000×1000 piksel boyutlu 647 adet çerçeve oluşturulmuştur.



(a) (b)

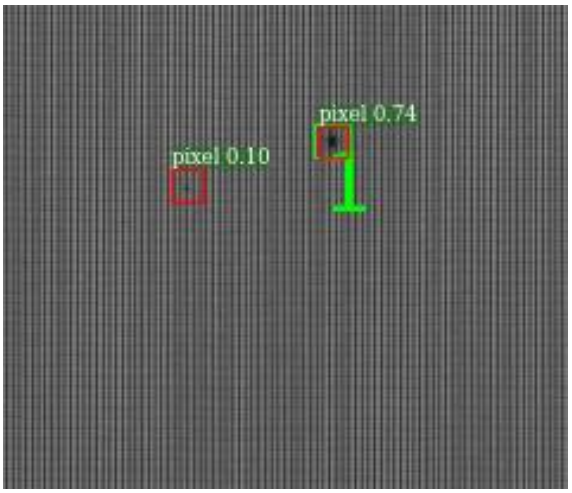
Şekil 4.8. Eğitim veri setinden örnekler (a) Eğitimde kullanılacak örnek bir görüntü (b) Etiketlenmiş hatalı piksel

Tablo 4.5. Hatalı piksellerin sınıf ve konum bilgilerinin kaydedildiği text dosyası içeriği

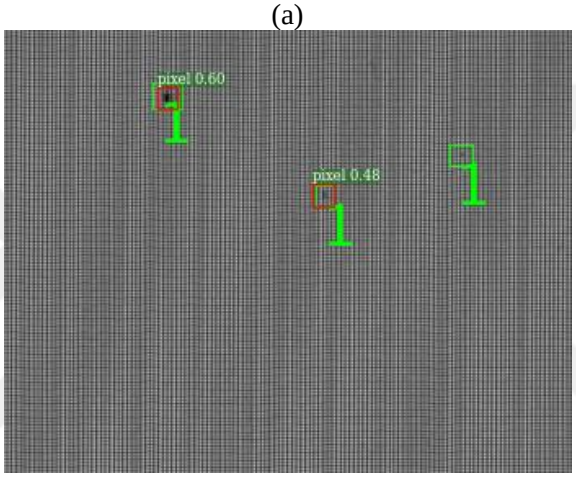
Sınıf	x_c	y_c	w/1000	h/1000
1	0,917	0,273	0,019	0,016
1	0,463	0,028	0,018	0,015
1	0,769	0,260	0,013	0,016
1	0,253	0,224	0,018	0,017
1	0,450	0,369	0,013	0,015
1	0,935	0,706	0,013	0,016
1	0,893	0,793	0,017	0,013
1	0,693	0,974	0,016	0,018
1	0,581	0,622	0,018	0,015
1	0,426	0,785	0,015	0,012
1	0,234	0,837	0,016	0,013
1	0,270	0,061	0,017	0,016
1	0,480	0,981	0,016	0,013

4.3.1. Deneysel sonuçlar

Bu bölümde önerilen yöntem ile elde edilen kesinlik, duyarlılık ve F1 skorları sırasıyla 0,95, 0,997 ve 0,97'dir. Şekil 4.10'da örnek tespit sonuçları verilmiştir. Şekilde yer alan yeşil sınırlayıcı kutular yer doğrusunu, kırmızı sınırlayıcı kutular ise ağ tarafından tahmin edilen sınırlayıcı kutuları göstermektedir. Şekil 4.10(a)'da örnek bir Yanlış Pozitif tespit sonucu, Şekil 4.10(b)'de ise örnek bir Yanlış Negatif tespit sonucu da yer almaktadır.



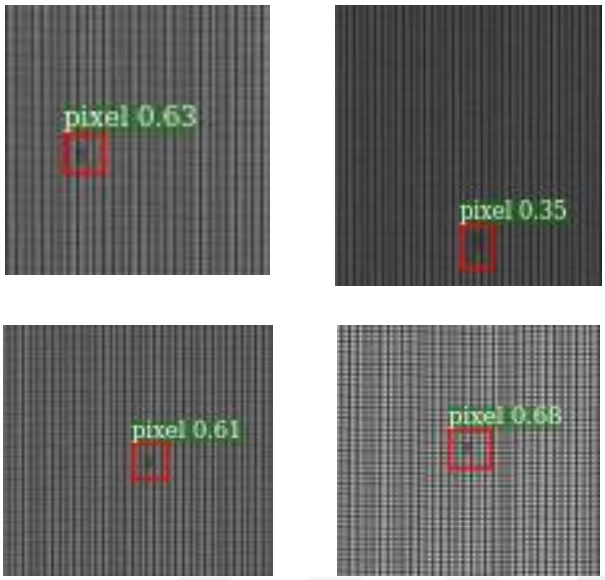
(a)



(b)

Şekil 4.10. Örnek tespit sonuçları

Yöntemin kesinlik skorunun görece düşük olması, yöntemin Yanlış Pozitif üretmeye eğilimli olduğunu göstermektedir. Yer doğrusu haritasında düşük karşıtlıkta ve görece küçük hatalı piksellerin (özellikle tek renk kanalının kapalı olduğu sözde hatalı pikseller) yüksek doğrulukla etiketlenemediği ve dolayısıyla veride yeterli ve tutarlı temsilinin sağlanamadığı görülmüştür. Bu durum söz konusu piksellerin ağ tarafından öğrenilememesine sebep olmakta ve yöntemin duyarlılık skorunu düşürmektedir. Ayrıca, başarım hesaplanırken Doğru Pozitif tespitlerin Yanlış Pozitif olarak değerlendirilmesine, dolayısıyla kesinlik skorunun da düşmesine yol açmaktadır. Şekil 4.11'de Yanlış Pozitif olarak değerlendirilen örnek tespit sonuçları görülmektedir. İlgili pikseller yer doğrusu haritasında yer almamaktadır.



Şekil 4.11. Yanlış pozitif tespit sonuçları

4.4. Sonuçlar

Bu tez çalışmasında LCD piksel hatalarının tespiti için makine öğrenmesi temelli üç yöntem önerilmiştir. Birinci yöntem Gri Seviye Eş-Oluşum Matrislerinden (GLCM) elde edilen özniteliklerin Destek Vektör Makinaları (SVM) ile sınıflandırılması temellidir. En iyi tespit sonuçları homojenlik, korelasyon ve enerji öznitelikleri kullanılarak elde edilmiştir. Bu yöntem için elde edilen kesinlik, duyarlılık ve F1 skorları sırasıyla 0,99, 0,80 ve 0,89'dur. Kalite kontrol sistemlerinin yüksek duyarlılıkta çalışması beklenir. Yöntemin kesinlik metriği değeri yüksek; fakat duyarlılık metriği değeri görece düşüktür. Özellikle ışıklılık seviyesinin düşük olduğu görüntülerde Yanlış Negatif sayısı (False Negative) fazladır. Ayrıca yöntem kayan pencereler yaklaşımı kullanması sebebiyle yavaş çalışmaktadır. Yöntemin 1000×1000 piksel boyutlu bir görüntüyü işleme süresi 32 GB RAM ve Nvidia Titan Xp GPU özellikli bir bilgisayarda 38 saniye sürmektedir. LCD piksel hatalarının tespiti endüstride uygulama alanı olan bir problemdir. Endüstride üretim hızı önemli olduğundan kalite kontrol sistemlerinin süre kısıtı bulunmaktadır. Dolayısıyla, yöntemin pratik uygulaması makul görünmemektedir.

Önerilen ikinci yöntem LCD piksel hatalarının tespiti için CNN mimarilerini kullanmaktadır. Yöntemde CNN mimarileri hem bir öznitelik çıkartıcı hem de sınıflandırıcı olarak kullanılmıştır. Çalışma kapsamında üç farklı derinlikle CNN mimarisi için tespit performansları incelenmiştir. En iyi kesinlik, duyarlılık ve F1

skorları sırasıyla 0,98, 0,96 ve 0,97'dir. Yöntem, birinci yönteme kıyasla daha yüksek başarım ile çalışıyorsa da hedeflenen duyarlılıkta çalışmamaktadır. Ayrıca, kayan pencereler yaklaşımı kullanması sebebiyle yavaştır. Daha derin CNN mimarilerinin kullanımı durumunda tespit başarımının iyileşmesi beklenmektedir; fakat bu durum yöntemin daha da yavaş çalışmasına neden olacaktır. Mevcut durumda yöntemin 1000×1000 piksel boyutlu bir görüntüyü işleme süresi 32 GB RAM ve Nvidia Titan Xp GPU özellikli bilgisayarda 68 saniyedir.

Tez kapsamında önerilen üçüncü yöntemde LCD piksel hatalarının tespiti için tümleşik ve tek aşamalı olan CNN tabanlı bir nesne tespit mimarisi kullanılmıştır. Mimari olarak Facebook Yapay Zeka Araştırma Laboratuvarı'nda geliştirilen RetinaNet ağı kullanılmıştır. RetinaNet küçük ölçekli nesnelerin tespitinde başarılı ve hızlı çalışan bir mimari olması sebebiyle tercih edilmiştir. Elde edilen kesinlik, duyarlılık ve F1 skorları sırasıyla 0,951, 0,997 ve 0,973'tür. Yöntemin duyarlılık skoru yüksektir. Yöntem 1000×1000 piksel boyutlu görüntüler üzerinden tespit yapmaktadır. 55 inç bir panelin taraması, yaklaşık 120 adet 1000×1000 piksel boyutlu görüntünün işlenmesine karşılık gelmektedir. Mevcut yöntem ile 55 inç boyutlu bir panelin 15 saniyede taranabileceği öngörülmektedir. Tüm yöntemler 32 GB RAM ve Nvidia Titan Xp GPU özellikli bilgisayar ortamında çalıştırılmıştır. Bu tez çalışmasında önerilen yöntemlerin başarımları Tablo 4.6'da verilmiştir. Tablo 4.6'da, CNN ve SVM tabanlı yöntemler için sırasıyla, en iyi F1 skorunun elde edildiği mimarinin ve öznitelik setinin kullanımı durumunda elde edilen skorlar yer almaktadır.

Tablo 4.6. Önerilen tespit yöntemlerinin başarımları

	CNN-1	SVM-Ö8	RetinaNet
Kesinlik	0,982	0,988	**0,951**
Duyarlılık	0,959	0,803	**0,997**
F1 Skoru	0,970	0,886	**0,973**

Bu tez çalışmasında LCD piksel hatalarının tespiti problemine, bir nesne tespiti problemi olarak yaklaşılmış ve LCD piksel hatalarının otomatik ve operatörden bağımsız bir şekilde tespiti için makine öğrenmesi temelli üç yöntem önerilmiştir. En iyi tespit sonuçları tümleşik ve tek aşamalı olan CNN tabanlı bir nesne tespit mimarisi kullanıldığı durumda elde edilmiştir. Deneysel sonuçlar önerilen yöntemin operatör denetimine alternatif olabileceği göstermektedir.

SONUÇLAR

LCD temelli ürünlerin (TV, tablet, telefon v.b.) ekranlarında piksel hatalarının bulunması günümüz tüketici beklentileri dikkate alındığında kabul edilemez durumdadır. Dolayısıyla bu sorunların üretim aşamasında ürün kullanıcıya ulaşmadan tespit edilmesi gerekmektedir. Bu kapsamda halihazırda çoğunlukla insan operatörlerin gözle yaptığı kontrollerin hataya açık olması ve süresinin uzun olması bu işlemin bilgisayarla görü yaklaşımları ile yapılmasının yolunu açmıştır.

LCD temelli ürünlerde karşılaşılan piksel hatası temelli sorunların önüne geçebilmesi için bu tez çalışması kapsamında LCD piksel hatalarının tespiti için makine öğrenmesi temelli üç yöntem önerilmiştir. Birinci yöntem, Gri Seviye Eş-Oluşum Matrislerinden elde edilen özniteliklerin Destek Vektör Makinaları ile sınıflandırılması temellidir. İkinci yöntem derin olmayan bir CNN sınıflandırıcı kullanmaktadır. Üçüncü yöntemde ise LCD piksel hatalarının tespiti için tümleşik ve tek aşamalı bir CNN mimarisi kullanılmıştır.

Tez kapsamında geliştirilen yöntemler arasında en iyi tespit sonuçları tümleşik ve tek aşamalı olan CNN tabanlı bir nesne tespit mimarisi kullanıldığı durumda elde edilmiştir. Ayrıca bu yöntemin çalışma hızı, gerçek zamanlı uygulamalarda kullanımını mümkün kılmaktadır. Deneysel sonuçlar önerilen yöntemin endüstriyel kalite kontrol sistemlerinde operatör denetimine alternatif olabileceğini göstermektedir.

KAYNAKLAR

[1] Guo L., Li S., Hu W., Wu J., Tu B., He W., Ou X., Zhang, G., Sub-pixel Level Defect Detection Based on Notch Filter and Image Registration. *International Journal of Pattern Recognition and Artificial Intelligence*, 2018, **32**(6), 1854016/1-1854016/15.

[2] Lee J. Y., Yoo S. I., Automatic Detection of Region-Mura Defect in TFT-LCD. *IEICE Transactions on Information and Systems*, 2004, **87**(10), 2371-2378

[3] Jian C. X., Gao J., Chen X., A Review of TFT-LCD Panel Defect Detection Methods, *Advanced Materials Research*, 2013, **734**, 2898-2902.

[4] Liu Y. H., Liu Y. C., Chen Y. Z., High-Speed inline Defect Detection for TFT-LCD Array Process Using a Novel Support Vector Data Description. *Expert Systems with Applications*, 2011, **38**(5), 6222-6231.

[5] Yang, S. W., Lin, C. S., Lin, S. K., Chiang, H. T., Automatic Defect Recognition of TFT Array Process Using Gray Level Co-Occurrence Matrix. *Optik-International Journal for Light and Electron Optics*, 2014, **125**(11), 2671-2676.

[6] Chen L. F., Su C. T., Chen M. H., A Neural-Network Approach for Defect Recognition in TFT-LCD Photolithographyprocess. *IEEE Transactions on Electronics Packaging Manufacturing*, 2009, **32**(1), 1-8.

[7] MaLing W., Implementation of Region-Mura Detection Based on Recursive Polynomial-Surface Fitting Algorithm. *Proceedings of the 2nd Asia International Symposium on Mechatronics*, Hong Kong, China, 2006.

[8] Saranli A., A Gaussian-Mixture Based Approach to Spatial Image Background Modeling and Compensation, *15th European Signal Processing Conference* , Poznan, Polonya, 1457-1461, 3-7 Eyül 2007.

[9] Oh J., H Yun., B. J. Park., K. H., The Defect Detection Using Human Visual System and Wavelet Transform in TFT-LCD Image, *Frontiers in the Convergence of Bioscience and Information Technologies*, Jeju City, Güney Kore, 498-503, 11-13 Ekim 2007.

[10] Guo B., Hu G. Q., Yang G. Y., TFT-LCD Spot-Type defect Detection in Module Process, *Advanced Materials Research*, 2014, **971**, 1368-1371.

[11] Lu C. J., Tsai D. M., Independent Component Analysis-Based Defect Detection in Patterned Liquid Crystal Display Surfaces, *Image and Vision Computing*, 2008, **26**(7), 955-970.

[12] Yeh C. H., Wu F. C., An image Enhancement Technique in Inspecting Visual Defects of Polarizers in TFT-LCD Industry. *2009 International Conference on Computer Modeling and Simulation*, Macau, Çin, 257-261, 20-22 Şubat 2009.

[13] Lee K. B., Ko M. S., Lee J. J., Koo T. M., Park K. H., Defect Detection Method for TFT-LCD Panel Based on Saliency Map Model, *IEEE Region 10 Conference TENCON*, Chiang Mai, Tayland, 223-226, 24 Kasım 2004.

[14] Zhao Z., Q Zheng., P., Xu S. T., Wu X., Object Detection with Deep Learning: A Review, *arXiv:1807.05511*, 2017.

[15] LeCun Y., Bottou L., Bengio Y., Haffner P., Gradient-based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 1998, **86**(11), 2278-2324.

[16] Krizhevsky A.,Sutskever I., Hinton G. E., Imagenet Classification with Deep Convolutional Neural Networks. *Advances In Neural Information Processing Systems*, 2012, 1097-1105.

[17] Zeiler M. D., Fergus R., Visualizing and Understanding Convolutional Neural Networks, *ECCV*, 818-833, Zürih, İsviçre, 6-12 Eylül 2014.

[18] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A., Going Deeper with Convolutions, *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9, Boston, MA, ABD, 7-12 Haziran 2015.

[19] He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778, Las Vegas, NV, ABD, 27-30 Haziran 2016.

[20] Sermanet P., Eigen D., Zhang X., Mathieu M., Fergus R., LeCun Y., Overfeat: Integrated recognition, localization and detection using convolutional networks. *arXiv preprint arXiv:1312.6229*. 2013.

[21] Girshick R., Donahue J., Darrell T., Malik J., Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation, *International Conference on Computer Vision and Pattern Recognition (CVPR)*, 580-587, Columbus, OH, ABD, 23-28 Haziran 2014.

[22] Girshick R., Fast R-CNN. *International Conference on Computer Vision (ICCV)*, 1440-1448, Santiago, Şili, 7-13 Aralık 2015.

[23] Ren S., He K., Girshick R., Sun J., Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *arXiv preprint arXiv:1506.01497, 2015.*

[24] Redmon J., Divvala S., Girshick R., Farhadi, A., You Only Look Once: Unified, Real-Time Object Detection, *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788, Las Vegas, NV, ABD, 27-30 Haziran 2016.

[25] Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C. Y., Berg A. C., SSD: Single Shot Multibox Detector, *European Conference on Computer Vision*, 21-37, Amsterdam, Hollanda, 8-16 Ekim 2016.

[26] Redmon J., Farhadi A. YOLO9000: Better, Faster, Stronger, *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, 6517-6525, Honolulu, HI, ABD, 21-26 Haziran 2017.

[27] Lin T. Y., Dollár P., Girshick R. B., He K., Hariharan B., Belongie, S. J., Feature Pyramid Networks for Object Detection. *IEEE International Conference on Computer Vision and Pattern Recognition (CVPR)*, 936-944, Honolulu, HI, ABD, 21-26 Haziran 2017.

[28] T. Y. Lin, P Goyal, R. Girshick., K. He, P. Dollar, Focal loss for dense object detection, *arXiv:1708.02002,* 2018.

[29] J. Redmon, A. Farhadi, Yolov3: An incremental improvement, arXiv*:1804.02767*, 2018.

[30] Raghtate G. S., Suresh S. S., Comparison of Classification Methods with Second Order Statistical Analysis and Wavelet Transform for Texture Image Classification, *International Conference on Computational Intelligence and Communication Networks*, 312-317, Jabalpur, Hindistan, Aralık 2015.

[31] Vapnik V., Pattern Recognition Using Generalized Portrait Method, *Automationand Remote Control*, 1963, **24**, 774-780.

[32] Kononenko I, Simec E, Robnik-Sikonja M. Overcoming the myopia of inductive learning algorithms with RELIEFF. *Applied Intelligence*, 1997, **7**(1), 39-55.

KİŞİSEL YAYINLAR VE ESERLER

[1] **Çelik A**., Sümer A., Küçükmanisa A., Çelebi A. T., Urhan O., LCD Piksel Hatalarının GLCM Öznitelikleri ve SVM ile Tespiti, *Uluslararası Marmara Fen ve Sosyal Bilimler Kongresi*, Kocaeli, Türkiye, 840-845, Kasım 2018.

ÖZGEÇMİŞ

1990 yılında İstanbul'da doğdu. Lise eğitimini Kocaeli Anadolu Lisesi'nde tamamladı. 2012 yılında İhsan Doğramacı Bilkent Üniversitesi İktisadi ve İdari Bilimler Fakültesi Psikoloji Bölümü'nden, 2016 yılında Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü'nden mezun oldu. 2016 yılında başladığı Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Anabilim Dalı'nda Yüksek Lisans öğrenimine devam etmektedir. 2018 Haziran ayından itibaren Kocaeli Üniversitesi Mühendislik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır.