KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

KISITLANMAMIŞ GÖRÜNTÜLER ÜZERİNDEN OTOMATİK PLAKA TESPİTİ VE TANIMA

COŞKU ÖKSÜZ

KOCAELİ 2015

KOCAELİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

KISITLANMAMIŞ GÖRÜNTÜLER ÜZERİNDEN OTOMATİK PLAKA TESPİTİ VE TANIMA

COŞKU ÖKSÜZ

Doç.Dr. M. Kemal GÜLLÜ
Danışman, Kocaeli Üniv. .....

Doç.Dr. Oğuzhan URHAN
Jüri Üyesi, Kocaeli Üniv. .....

Doç.Dr. G. Bora ESMER
Jüri Üyesi, Marmara Üniv. .....

Tezin Savunulduğu Tarih: 17.09.2015

ÖNSÖZ VE TEŞEKKÜR

Bu tez çalışmasında otomatik plaka tanıma sistemi ile ilgili yaptığım çalışmaların bu konuda çalışmak isteyenlere faydalı olmasını temenni ederim.

Yüksek lisans eğitimim boyunca uzun mesafelere rağmen beni yönlendirerek ufkumu genişleten, bilgi ve tecrübelerini benden esirgemeyerek değerli vaktini ayıran hocam Doç. Dr. M. Kemal GÜLLÜ'ye teşekkürlerimi sunarım.

Yüksek lisans çalışmalarım boyunca manevi desteğini eksik etmeyen değerli kardeşim Oğuz ÖKSÜZ, meslektaşlarım Fatih ÖNCÜL, Kadir EKER ve diğer arkadaşlarıma teşekkür ederim.

Hayatımın her evresinde sonsuz sevgi, ilgi ve destekleriyle her zaman yanımda olan beni bugünlere getiren sevgili aileme teşekkürü borç bilirim.

Yüksek lisans çalışmalarım boyunca manevi desteğini eksik etmeyen değerli eşim Sibel'e teşekkür ederim.

Eylül - 2015 Coşku ÖKSÜZ

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR i
İÇİNDEKİLER ii
ŞEKİLLER DİZİNİ iv
TABLOLAR DİZİNİ vii
SİMGELER DİZİNİ VE KISALTMALAR ix
ÖZET x
ABSTRACT xi
GİRİŞ 1
1. GENEL BİLGİLER 3
1.1. Otomatik Plaka Tanıma Sistemi (OPTS) 3
1.2. Otomatik Plaka Tanıma Sisteminde Görüntü İşleme 3
1.3. OPTS Aşamaları 5
1.3.1. OPTS'nin donanımsal boyutu 5
1.3.1.1. Görüntü yakalama aşaması 5
1.3.2. OPTS'nin yazılımsal boyutu 7
1.3.2.1. Plaka tespit aşaması/ plaka bölgesi çıkartımı 7
1.3.2.2. Karakter ayrıştırma aşaması 7
1.3.2.3. Optik karakter tanıma aşaması (OCR) 7
1.4. OPTS Başarımına Etki Eden Faktörler 8
1.5. OPTS'nin Uygulama Alanları 9
1.6. Tezin Amacı 11
2. PLAKA TESPİTİ 12
2.1. Giriş 12
2.2. Plaka Tespiti İçin Literatüre Bir Bakış 12
2.2.1. Kenar özelliğini kullanan yöntemler 12
2.2.2. Doku özelliğini kullanan yöntemler 13
2.2.3. Renk özelliğini kullanan yöntemler 14
2.2.4. Karakter özelliğini kullanan yöntemler 15
2.2.4.1. MSWT yöntemi ile plaka tespiti 15
2.2.4.2. Hough dönüşümünden yararlanan kümeleme temelli plaka tespiti 18
2.3. Motivasyon 19
2.4. Önerilen Plaka Tespit Yöntemi 21
2.4.1. Ön işleme 22
2.4.1.1. Gri seviye dönüşümü 22
2.4.1.2. Görüntü eşikleme 22
2.4.2. Bağlı bileşen analizi (CCA) 29
2.4.2.1. Bağlı bileşen etiketleme 29
2.4.3. Yatay izdüşüm ile karakter bölgesi kestirme 32
2.4.3.1. İzdüşümler 32
2.4.4. Plaka bölgesinin yatayla paralel hale getirilmesi (Geometrik düzeltme) 37
2.4.4.1. Yöntem 37

2.5. Deneysel Sonuçlar 38
2.6. Sonuç 44
3. KARAKTER AYRIŞTIRMA VE TANIMA 46
3.1. Giriş 46
3.2. Karakter Ayrıştırma 46
3.2.1. Literatür inceleme 46
3.2.2. Önerilen yöntem 47
3.2.2.1. Plaka çerçevesinin çıkarılması 47
3.2.2.2. Gürültülü bölgelerin elenmesi 48
3.2.2.3. Birleşmiş karakterlerin ayrıştırılması 49
3.3. Karakter Tanıma 50
3.3.1. Literatür inceleme 50
3.3.1.1. Ham veri ile karakter tanıma 50
3.3.1.2. Özellik çıkartımı ile karakter tanıma 50
3.3.2. Önerilen yöntem 51
3.3.2.1. Eğitim kümesi belirleme 51
3.3.2.2. Özellik uzayında eğitim 53
3.3.2.3. Sınıflandırma 55
3.3.2.4. Gürültüsüz eğitim 63
3.3.2.5. Gürültülü eğitim 66
3.3.2.7. Sınıflandırma başarımının karşılaştırılması 72
3.3.2.8. Plaka tanıma birimi başarısının değerlendirilmesi 78
3.4. GUI (Kullanıcı Arayüzü) Tasarımı 79
SONUÇLAR VE ÖNERİLER 81
KAYNAKLAR 82
KİŞİSEL YAYIN VE ESERLER 87
ÖZGEÇMİŞ 88

ŞEKİLLER DİZİNİ

Şekil 1.1. Tipik bir OPTS 3
Şekil 1.2. Klasik bir OPTS'nin dört aşaması 4
Şekil 1.3. (a) Jobin ve diğ. için OPTS aşamaları, (b) Alegria ve Girao için OPTS aşamaları 5
Şekil 1.4. Hareket bulanıklaşması, (a) Bulanıklaşmış çerçeve, (b) Görüntü restorasyonu sonucu 7
Şekil 1.5. (a) Özelleştirilmiş Türk plakası, (b) Standart Türk plakası 9
Şekil 1.6. (a) Plaka üzerinde ışıklılık değişimi, (b) Farklı görüş açısı durumu 9
Şekil 1.7. Farklı ülkelere ait plaka örnekleri 11
Şekil 1.8. Türk Sivil Plaka Örnekleri 11
Şekil 2.1. MSWT yöntemi akış şeması 16
Şekil 2.2. (a) Örnek giriş imgesi, (b) Oluşturulan ışın imgesi (ray image), (c) Tespit sonucu 17
Şekil 2.3. (a) Giriş imgesi, (b) Oluşturulan ışın imgesi (ray image) 17
Şekil 2.4. (a) Giriş imgesi, (b) Niblack yöntemi ile yerel eşikleme çıkışı, (c) 30'dan az piksele sahip bölgelerin temizlenmesi, (d) 0,25-1 en/boy oranı aralığındaki bölgeleri işaretleme 18
Şekil 2.5. (a) Kümelenen üst ve alt nokta koordinatları, (b) Her bir küme üzerinde uygulanan Hough dönüşümü ile bulunan doğrusal noktalar, (c) Hatalı bölgeler ile bulunan plaka karakterleri 19
Şekil 2.6. Önerilen yöntem 21
Şekil 2.7. (a) Spot gölgesi ile bozulmuş doküman imgesi, (b) Sinüs gölgeleri ile bozulmuş doküman imgesi, (c)-(d) Otsu yöntemi ile global eşikleme sonucu, (e) 20x20 blok boyutu seçimi için Sauvola yöntemi ile uyarlamalı yerel eşikleme sonucu 25
Şekil 2.8. (a) 5x5'lik örnek imge bloğu, (b) İlgili integral imge bloğu 26
Şekil 2.9. (a) Örnek giriş imgesi, (b) 0-1 aralığına normalize edilmiş integral imgesi 28
Şekil 2.10. (a) Giriş imgesi, (b) Parlaklık imgesi, (c) Sauvola yöntemi çıkışı, (d) Sauvola yönteminin tümleyeni, (e) Ağırlıklandırılmış pikseller, (f) Tv=0,3 için eşikleme sonucu 30
Şekil 2.11. (a) 4-komşuluk, (b) 8-komşuluk 31
Şekil 2.12. Komşulukların kontrol edilmesi 31
Şekil 2.13 (a) Örnek bir örüntü, (b) Örüntüye ait yatay izdüşüm histogramı, (c) Örüntüye ait dikey izdüşüm histogramı 33
Şekil 2.14. (a) Bağlı bileşen eleme adımı sonucu, (b) Yatay izdüşüm vektörü 35
Şekil 2.15. (a) Yatay izdüşüm vektöründe tespit edilen karakter bölgesi, (b) Kestirilen satır aralıkları 35
Şekil 2.16. Karakterlerin $\hat{I}_c$ vektöründen belirlenmesi 36
Şekil 2.17. (a) Kestirim sonucu, (b) Bölge birleştirme ile bulunan plaka bölgesi 36

Şekil 2.18. (a) Elipsin büyük ekseni ve yatay eksen arasındaki α açısının tespiti: mavi sürekli çizgi elipsin büyük eksenini, yeşil sürekli çizgi elipsin küçük eksenini, mavi kesikli çizgi yatay eksen paralelini göstermektedir, (b) Çıkartılan plaka bölgesi, (c) Bulunan α açısının Shear dönüşümü matrisinde kullanılarak yatay ile paralel hale getirilen araç plakası 38
Şekil 2.19. Örnek tespit sonuçları 39
Şekil 2.20. Plaka tespitinin yapılamadığı durumlar (Yanlış negatifler), (a) Plaka üzerindeki aşırı kir, (b) Deforme olmuş plaka, (c) Karakter boyası silikliği, (d) Aşırı boyanmış karakterler 39
Şekil 2.21. Plaka tespit biriminin yanlış alarm (yanlış pozitif) oluşturduğu durumlar 41
Şekil 2.22. (a) Giriş imgesi, (b) Yer doğrusu, (c) Önerilen yöntem için kestirim sonucu, (d) Modified SWT çalışması için kestirim sonucu, (e) Alegria ve Girao çalışması için kestirim sonucu 42
Şekil 2.23. Performans karşılaştırma için ROC eğrileri 43
Şekil 2.24. Zamansal tüketim eğrilerinin karşılaştırılması 44
Şekil 3.1. Örnek plakaya ait İzdüşüm eğrileri: (a) Dikey izdüşüm, (b) Yatay izdüşüm 47
Şekil 3.2. Çerçevesi temizlenmiş plaka imgesi 48
Şekil 3.3. Çerçevesi temizlenmiş plakaya ait dikey izdüşüm eğrisi 48
Şekil 3.4. Gürültü temizlenmiş plaka imgesi 48
Şekil 3.5. Karakter ayrıştırma süreci 49
Şekil 3.6. ICDAR 2003 karakter veri tabanından örnek bir görünüm 52
Şekil 3.7. Türk sivil plakalarında kullanılan 33 kusursuz karakter sınıfı 52
Şekil 3.8. ICDAR 2003 veri tabanından yararlanılarak derlenen her bir rakam sınıfının 50 farklı versiyonu 53
Şekil 3.9. ICDAR 2003 veri tabanından yararlanılarak derlenen her bir harf sınıfının 50 farklı versiyonu 53
Şekil 3.10. (a) [2 2] hücre boyutu seçimi için örnek bir imge, (b) [2 2] hücre boyutu için özellik vektörü oluşum süreci 54
Şekil 3.11. Örnek 'B' karakterine ait çıkartılmış HOG özellikleri 55
Şekil 3.12. Tek katmanlı algılayıcı modeli 56
Şekil 3.13. Aktivasyon fonksiyonları: (a) Keskin sınırlı, (b) Simetrik keskin sınırlı, (c) Doğrusal, (d) Pozitif doğrusal, (e) Doğrusal doyan, (f) Simetrik doğrusal doyan, (g) Lojistik sigmoid, (h) Tanjant sigmoid, ve (i) Radyal tabanlı 58
Şekil 3.14. MLP modeli 60
Şekil 3.15. En uygun ağırlık değerlerinin aranması 60
Şekil 3.16. Tek giriş tek çıkışlı ileri beslemeli ağ üzerinden geri yayılım algoritmasının incelenmesi 61
Şekil 3.17. Örnek A karakterinin üzerine ortalaması sıfır, değişintisi 0-1 arasında kademeli artan rasgele dağılmış gürültü eklenerek elde edilen gürültülü kopyaları 62
Şekil 3.18. Farklı HOG hücre boyutu için oluşturulan sinir ağının yapısı 63
Şekil 3.19. 4x4 HOG hücre boyutu seçimi için eğitilen her bir ağın eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi 73

Şekil 3.20. 8x8 HOG hücre boyutu seçimi için eğitilen her bir ağın eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi 73
Şekil 3.21. Farklı hücre boyutları için gürültüsüz eğitilen Ağ 1'in eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi. MSE: 0,004 74
Şekil 3.22. Farklı hücre boyutları için 0 ortalamalı 0,3 değişintili rasgele gürültü eklenmiş veri ile eğitilen Ağ 2'nin eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi. MSE: 0,067 74
Şekil 3.23. Farklı hücre boyutları için 0 ortalamalı 0,4 değişintili rasgele gürültü eklenmiş veri ile eğitilen Ağ 3'ün eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi. MSE=0,093 74
Şekil 3.24. Her bir ağın aynı eksende görünümü 75
Şekil 3.25. Excel'de oluşturulan veri tabanından örnek bir görünüm 78
Şekil 3.26. Tasarlanan arayüz üzerinde örnek tespit ve tanıma sonucunun görüntülenmesi 80

TABLOLAR DİZİNİ

Tablo 1.1. Ticari plaka tanıma sistemleri 10
Tablo 2.1. Bir plaka imgesi için MSWT yöntemi ile karakter adaylarının oluşturulması 16
Tablo 2.2. Plaka çıkartım yöntemlerinin avantaj ve dezavantajları 20
Tablo 2.3. Farklı yöntemler ile ortalama filtreleme işlemi için harcanan hesapsal zamanlar 29
Tablo 2.4. Geometrik dönüşümler 37
Tablo 2.5. TPR ve FPR oranlarının elde edilmesinde yararlanılan değişkenler 40
Tablo 2.6. T=0,5 için doğru tespit, yanlış alarm oranları, tespit başarımları (AUC), 324 imge için ortalama tespit zamanı 42
Tablo 2.7. 324 imge için ortalama tespit zamanı 43
Tablo 3.1. 4x4 HOG hücre boyutu seçimi için gürültüsüz eğitilen ağın (Ağ 1_4x4) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,9512 64
Tablo 3.2. 8x8 HOG hücre boyutu seçimi için gürültüsüz eğitilen ağın (Ağ 1_8x8) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,955 65
Tablo 3.3. 4x4 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 2_4x4) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,0929 67
Tablo 3.4. 8x8 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 2_8x8) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,5111 68
Tablo 3.5. 4x4 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 3_4x4) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,0237 69
Tablo 3.6. 8x8 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 3_8x8) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,4262 70
Tablo 3.7. Değişen hücre boyutları için eğitilen her bir ağın eğitim seti üzerinde kademeli artan gürültü seviyesine göre sınıflandırma hatalarının gözlenmesi 72
Tablo 3.8. 4x4 HOG hücre boyutu seçimi için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerleri 76
Tablo 3.9. 8x8 HOG hücre boyutu seçimi için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerleri 76
Tablo 3.10. 4x4 ve 8x8 HOG hücre boyutu seçimi için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerleri 76
Tablo 3.11. (a) Örnek giriş imgeleri, (b) Örnek tespit sonuçları, (c) Farklı sınıflandırıcılar için örnek tanıma sonuçları 77

Tablo 3.12. OPTS birimlerinin performansının gözlenmesi ve farklı sınıflandırma yöntemlerinin tüm sistem performansına etkisi 79

SİMGELER DİZİNİ VE KISALTMALAR

I	: Giriş imgesi
I_b	: İkili imge
In	: İntegral imge
O(.)	: Hesapsal karmaşa notasyonu
P_h	: Yatay izdüşüm vektörü
P_v	: Dikey izdüşüm vektörü
μ	: Dağılım ortalaması
σ	: Standart sapma
TPR	: Doğru pozitif oran
FPR	: Yanlış pozitif oran
AUC	: Eğri altında kalan alan
$\|\|.\|\|$	: Öklid normu

Kısaltmalar

ALPR	: Automated License Plate Recognition System (Otomatik Plaka Tanıma Sistemi)
CCA	: Connected Component Analysis (Bağlı Bileşen Analizi)
FSM	: Fraction of Samples Misclassified (Hatalı Sınıflandırılmış Örnekler Oranı)
GUI	: Graphical User Interface (Grafiksel Kullanıcı Arayüzü)
HOG	: Histogram of Oriented Gradients (Yönlü Gradyan Histogramları)
MLP	: Multilayer Perceptron (Çok katmanlı Algılayıcı)
MSE	: Mean Square Error (Ortalama Karesel Hata)
OCR	: Optical Character Recognition (Optik Karakter Tanıma)
OPTS	: Otomatik Plaka Tanıma Sistemi
PTS	: Plaka Tanıma Sistemi
RMSE	: Root Mean Square Error (Ortalama Karekök Hata)
ROC	: Receiver Operating Characteristics (Alıcı İşlem Karakteristikleri)
SSE	: Sum of Squared Error (Toplam Karesel Hata)
VEDA	: Yeni ve Hızlı Dikey Kenar Çıkartım Algoritması
YSA	: Yapay Sinir Ağı

KISITLANMAMIŞ GÖRÜNTÜLER ÜZERİNDEN OTOMATİK PLAKA TESPİTİ VE TANIMA

ÖZET

Otomatik plaka tanıma, renkli, siyah/beyaz ya da kızılötesi kameranın herhangi birinden alınan bir video dizisinden veya bir imgeden araç plaka bilgisinin çıkartılması işlemidir. Çıkartılan bilgi, çalıntı araç takibi, elektronik ödeme sistemleri, trafik gözetimi gibi birçok gerçek yaşam uygulamasında bir veri tabanı ile kullanılabilmektedir.

Farklı ülkelerin farklı plaka standartları, özelleştirme, farklı renkler, kirle kaplanma, kamera ve plaka arası mesafe nedeniyle değişen plaka boyutları, eğiklik vs. tespiti zorlaştıran plaka kaynaklı faktörlerdir. Aydınlatma koşulları ve karmaşık arka plan ise tespiti zorlaştıran çevresel faktörleri oluşturmaktadır. Geliştirilecek bir otomatik plaka tanıma sisteminin tüm bu zor koşullar altında hızlı ve başarılı olarak çalışması istenmektedir. Bu nedenle etkili ve güvenilir bir OPT sistemi tasarlamak oldukça zorlu bir problemdir.

Bu tez çalışmasında, karakter özelliklerinden plaka bölgesini bulan, düşük hesapsal yüke sahip bir otomatik plaka tanıma yaklaşımı önerilmektedir. Ön işleme adımında klasik Sauvola yöntemi çıktısı ışıklılık bilgisine göre ağırlıklandırılarak koyu bölgeler tespit dışına çıkartılmaktadır. Ön işleme sonrasında karakter özelliği göstermeyen bölgeler bağlı bileşen analizi ile elenerek, ardından yatay izdüşüme bağlı olarak karakter bölgeleri tespit edilmektedir. Karakter ayrıştırma işlemi için yatay ve dikey izdüşümlerden faydalanılmıştır ve ayrıştırılan karakterler çok katmanlı algılayıcı modelinden yararlanılarak tanınmıştır.

Çalışmada plaka bölgesinin tespitinde %96, karakter ayrıştırma ve tanıma için %89,2 başarım oranlarına ulaşılmıştır.

Anahtar Kelimeler: İntegral İmge, İzdüşümler, Plaka Çıkartımı, Plaka Tanıma.

AUTOMATIC NUMBER PLATE DETECTION AND RECOGNITION OVER UNRESTRICTED IMAGES

ABSTRACT

Automated license plate recognition is the process of extracting license plate knowledge from an image or video sequence captured by color, black/white, infrared cameras. Extracted plate data can be used via a database in lots of real life applications such as stolen car tracing, electronic payment systems and traffic surveillance.

Varying plate standards of different countries, customized plates, different colors, dirty plates, varying plate size due to distance between plate and camera, inclination etc. are the issues originating from plate itself for plate detection. Bad illumination and complex background are the environmental issues which complicates plate detection. Fast and successful ALPR system is desired to design under given issues. Therefore it is a quite difficult problem to design an effective and reliable ALPR system.

In this thesis, an automatic number plate recognition approach with low computational load has been proposed to detect license plate area using character features. In the preprocessing step, unlike classical Sauvola method, output is weighted according to the pixel luminance values, and therefore dark regions are eliminated from the detection. After preprocessing step, regions that cannot show a character property are eliminated using connected component analysis, and then character regions are detected utilizing horizontal projection. Horizontal and vertical projections have been used for character segmentation and segmented characters have been recognized using multilayer perceptron model.

Accuracy of 96% is achieved for license plate localization and %89,2 for character segmentation and recognition in this work.

Key Words: Integral Image, Projections, Plate Extraction, Recognition.

GİRİŞ

Teknolojinin küresel dünyada olağanüstü hızlı ilerlemesi ve bu ilerlemenin son yıllarda daha büyük bir hızda gerçekleşmesi onunla uğraşanları dahi hayrete düşürecek hale gelmiştir. Hızla gelişen teknoloji ile birlikte günlük yaşamda karşılaşılan problemlerin giderilmesi veya rutin olarak tekrarlanan işlemlerin yapılması sırasında, işleri hızlandırmak ve hata yapmaya çok müsait bir varlık olan insan faktörünü en aza indirmek için, her alanda bilgisayar kontrollü sistemlere bir başka deyişle otomasyon sistemlerine geçiş yaşanmaktadır. Tabi ki teknolojinin hızla ilerlemesi ve otomasyon sistemlerine yönelme eğilimi, otomotiv sektöründeki yerini de almıştır. Bu durum kısa sürede ve yüksek kalitede daha çok otomobilin üretilmesini ve buna bağlı fiyatlardaki düşmeyle beraber tüm dünyada olduğu gibi Türkiye'de de trafiğe çıkan motorlu araç sayısını katlanarak arttırmıştır. Bu artışa bağlı olarak günlük yaşamı oldukça etkileyen araç trafiği problemleri trafik akışını kontrol eden otomatik araç tanıma sistemlerine duyulan ihtiyacı oldukça arttırmıştır. Bu ihtiyaca cevap vermeye yönelik olarak yapılan çalışmaların amacı; araçları özel bir noktadan geçerken tanımlamak, konumunu belirlemek, hareketlerini gözlemlemek ve bu verileri kullanarak trafik denetimini sağlamaktır [1].

Plaka tanımak için kullanılan manuel yöntemler her ne kadar en kolay yöntem olarak görünse de araç sayısının oldukça artması, yorgunluk ve benzeri faktörler nedeniyle okuma hatalarına neden olmaktadır. Manuel sistemler ayrıca kötü çalışma ortamı, sıkıcı iş, yoğun emek ve düşük verimlilik gibi sorunları da beraberinde getirmektedir.

Belirtilen problemler trafik kontrolünü sağlama ve araç yönetiminin verimliliğini geliştirmek için insansız plaka tanıma sistemlerinin ortaya çıkışında temel motivasyon noktasını oluşturmuştur. Otomatik plaka tanıma sistemi (OPTS) sadece araç plakalarını tanımlayabilmek için geliştirilmiş akıllı ulaşım sistemlerinin bir parçasıdır. Dünya çapında tüm araçlar asıl tanımlayıcıları olarak benzersiz bir plakaya sahiptirler. Plaka araca ait her türlü bilgiyi içermektedir. Otomatik plaka tanıma sistemlerini kullanışlı ve pratik yapan; aracı belirlemek için hali hazırda aracın üzerinde bulunan

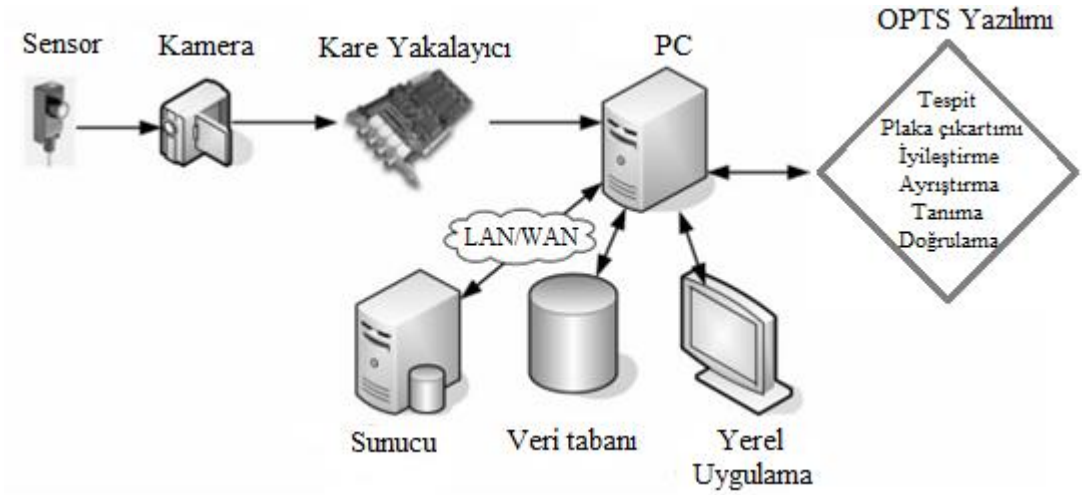
plakayı kullanmasıdır. Bu nedenle akıllı ulaşım sistemleri güçlü otomatik plaka tanıma sistemlerine ihtiyaç duymaktadır.

Tez çalışması şu şekil organize edilmiştir. Bölüm 1'de OPTS hakkında genel bilgiler verilmiştir. Bölüm 2'de OPTS'nin en önemli aşamalarından olan plaka tespiti için literatürdeki bazı çalışmalar ile tez çalışmasında önerilen yöntem sunulmuştur. Bölüm 3'de karakter ayrıştırma ve tanıma için literatür gözden geçirilerek önerilen yöntem sunulmuştur. Ardından sonuçlar ve önerilere yer verilerek çalışma sonlandırılmıştır.

1. GENEL BİLGİLER

1.1. Otomatik Plaka Tanıma Sistemi (OPTS)

Otomatik plaka tanıma sistemi kameralar aracılığıyla alınan araç görüntüsü üzerinde çeşitli görüntü işleme tekniklerini uygulayarak plaka bölgesini imgeden ayrıştıran ve plaka üzerindeki karakterleri çeşitli optik karakter okuma (OCR) teknikleri kullanarak tanıyan bir takım yazılım ve donanım bileşenlerinden oluşan tümleşik bir sistemdir. Genel bir OPTS yapısı Şekil 1.1'de verilmektedir.

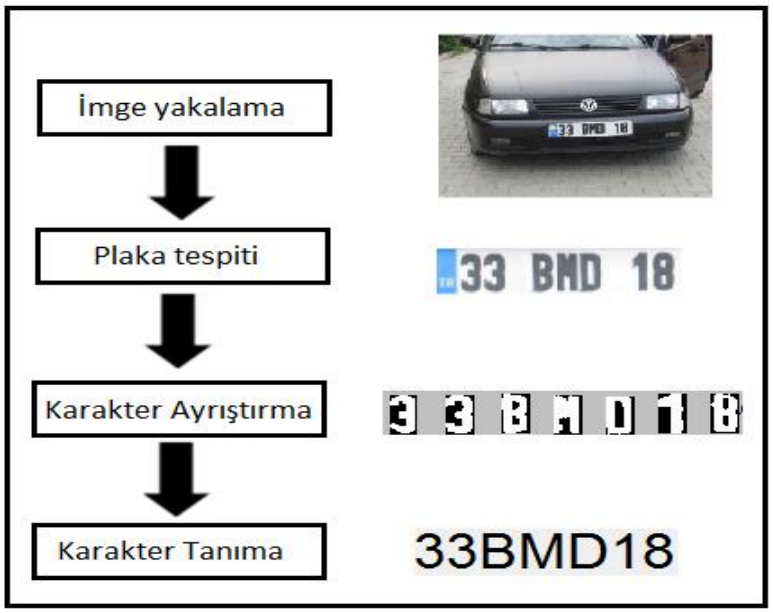


Şekil 1.1. Tipik bir OPTS [2]

1.2. Otomatik Plaka Tanıma Sisteminde Görüntü İşleme

Görüntü işleme, girişin sayısal bir imge veya video dizisinden oluştuğu işaret işlemenin bir alt alanıdır. Sayısal görüntü işlemenin çıktısı, bir imge ya da uygulama temelli problemleri çözme için kullanışlı özellikler kümesinden herhangi biridir. Plaka tanıma işlemi açısından bakıldığında giriş renkli veya gri ölçekli imge iken çıkış karakter dizisi olmaktadır. Klasik bir OPTS dört aşamadan oluşmaktadır.

İlk aşamayı, Şekil 1.1'de görüldüğü gibi kamera tarafından araç imgesinin yakalanması oluşturmaktadır. Bu aşamada kamera türü, çözünürlüğü, pozlama hızı vb. parametrelerin dikkate alınması gerekmektedir. İkinci aşama; doku, kenar, renk gibi özniteliklerden yararlanılarak plaka bölgesinin tespitinden oluşmaktadır.

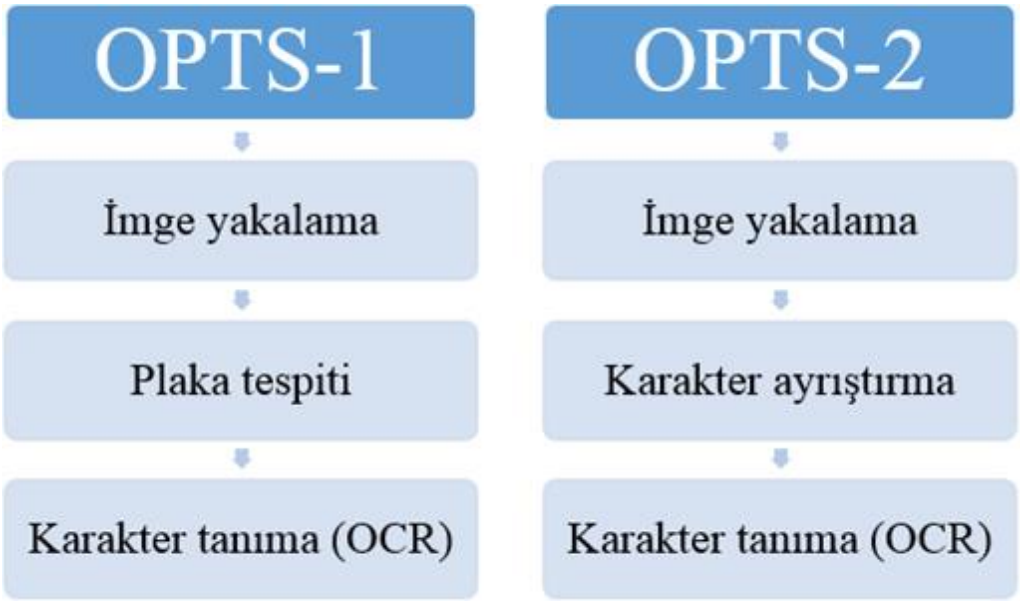


Şekil 1.2. Klasik bir OPTS'nin dört aşaması

Sistemin üçüncü adımı bir önceki adımda çıkartılan araç plakasından karakterlerin arka plandan ayrıştırıldığı karakter ayrıştırma aşamasıdır. Sistemin son aşamasını ayrıştırılan plaka karakterlerini tanıyan optik karakter tanıyıcı (OCR) oluşturmaktadır. Yapay sinir ağları, şablon eşleme ve destek vektör makinaları gibi yöntemlerden bu aşamada sıklıkla yararlanılmaktadır. Şekil 1.2'de klasik bir OPT sürecinin yapısı gösterilmektedir.

Şekil 1.2'deki her bir OPTS aşaması ayrı bir hesapsal yüke sahiptir. Hesapsal yükün artması OPTS için önemli bir faktör olan zamansal tüketim değerinin artması anlamına gelmektedir. Bu nedenle literatürdeki bazı çalışmalarda, klasik OPTS aşamalarından farklı yöntemler izlenmektedir.

Jobin ve diğ. [26] tarafından yapılan çalışmada, araç imgesi yakalandıktan sonra karakter bölgeleri elde edilmiş, sonrasında karakter bölgelerinden plaka bölgesi tespit edilerek OCR ile tanınmıştır. Alegria ve Girao [27] tarafından yapılan çalışmada ise araç imgesi yakalandıktan sonra karakter bölgeleri elde edilmiş ve her bir karakter doğrudan OCR birimine gönderilmiştir.



(a) (b)

Şekil 1.3. (a) Jobin ve diğ. [26] için OPTS aşamaları, (b) Alegria ve Girao [27] için OPTS aşamaları

1.3. OPTS Aşamaları

1.3.1. OPTS'nin donanımsal boyutu

1.3.1.1. Görüntü yakalama aşaması

Bu kısım OPTS'nin donanımsal boyutunu oluşturmaktadır. Bir plaka tanıma sistemi kurmak, sistemin başarılı olarak işletilmesindeki önemli rol oynayan bir süreçtir. Uygun bir sistemin kurulumu bazı problem durumlarını hesaba katmayı gerektirmektedir. Ele alınması gereken önemli faktörler yirmi dört saatlik zaman dilimi içerisinde değişen aydınlatma koşulları ve görüntünün yakalanmasındaki (tetikleme cihazları ve kamera kalibrasyonu) uygun zamanlama ile ilişkilidir. İlk faktör uygun tetikleme cihazlarının seçilmesini ve yakalama cihazlarını (kamera veya video kamera) dikkatli olarak kalibre etmeyi gerektirirken ikinci faktör, insan görsel sistemi ile karışmayan veya sürücünün dikkatini dağıtmayan yardımcı aydınlatma birimleri kullanılmasını gerektirmektedir.

Tetikleme Cihazları: Tetikleme cihazlarının temel görevi görüntünün uygun zamanda yakalanmasıdır. Görüntünün yakalanması sürecinde; sensor tetikleme, yazılım tetikleme, serbest akış olmak üzere temelde üç ayrı tetikleme yöntemi bulunmaktadır. Görüntü yakalama süreci, yolun herhangi bir köşesine yerleştirilmiş bir sensorun

tetiklenmesi ile başlatılıyorsa kullanılan yöntem sensor tetikleme; herhangi bir fiziksel sensor kullanılmaksızın değişim/hareket algılama algoritmaları tarafından üretilen tetikleme sinyali ile başlatılıyorsa kullanılan yöntem yazılım tetikleme olarak adlandırılmaktadır. İletişim hattının herhangi bir yazılım ya da donanım cihazından tetikleme sinyali almaksızın, doğrudan video kamera ya da akıllı kameralar ile görüntüler alması, sonrasında belirlenen bazı kurallar altında görüntüleme yazılımının araç plakasını araması ise serbest akış yöntemi olarak adlandırılmaktadır.

Yardımcı Aydınlatma Birimleri: Değişen aydınlatma problemlerinin üstesinden gelebilmek için kızılötesi yardımcı birimler kullanılır. Kızılötesi birimleri kullanma düşüncesi plaka yüzeyinin doğasından ortaya çıkmıştır. Araç plakası, yüzeyine doğrudan bir ışık geldiğinde parıldamasına sebep olan geri yansıtıcı (Retro reflektif) materyalden yapılmaktadır. Bu özellik, plakayı kızılötesi aydınlatmaya duyarlı kameralar için kusursuz bir aday haline getirmektedir.

Kamera Kalibrasyonu: Kamera yerleşimi ve kalibrasyon parametreleri tüm sistemin başarımında önemli bir rol oynamaktadır.

Tüm sistem performansını önemli derecede etkileyen parametreler yatay ve dikey görüş açılarıdır. Bu parametrelerdeki büyük değerler plaka görünüşüne ve OCR tarafından tanınacak karakterlere etki ederek sistem performansının bozulmasına sebep olmaktadır. Böyle bir durumda plaka tanıma aşaması öncesinde bir görüntü restorasyon tekniğine ihtiyaç duyulabilmektedir.

Söz edilmesi gereken bir diğer konu kamera pozlama hızıdır. Düşük pozlama hızı aşırı hızlı hareket eden araç plakalarının bulanık görünmesine sebep olan özel bir problem durumudur. Şekil 1.4(a)'da bu durum gösterilmiştir. Bulanıklaşma etkisinden kaçınmak için kamera pozlama hızı 1 ms'den küçük değerlere kurulmalıdır. Yavaş ilerleyen trafik, ücret toplama gibi uygulama gereksinimlerine bağlı olarak kamera pozlama hızı daha düşük değerlerde seçilebilir. Ele alınması gereken diğer bir durum kamera ve plaka arasındaki etkin mesafedir. Bu mesafe kamera kalibrasyon parametrelerine göre değişmekte ve tasarlanan OPT sisteminin ayırt etme yeteneğini ortaya koymaktadır. Ayırt etme yeteneği tasarlanan sistemin en küçük boyutlardaki plakayı bulabilme gücünü ifade etmektedir. Ayırt etme yeteneği ile ilgili detaylı hesaplamalar [4]'te bulunmaktadır.



(a) (b)

Şekil 1.4. Hareket bulanıklaşması, (a) Bulanıklaşmış çerçeve, (b) Görüntü restorasyonu sonucu [26]

1.3.2. OPTS'nin yazılımsal boyutu

1.3.2.1. Plaka tespit aşaması/ plaka bölgesi çıkartımı

OPT sisteminin bu aşamasında, giriş imgesindeki plaka bölgesi bir özellik çıkartım süreci ile elde edilmektedir. Kenar, doku, renk gibi plaka bölgesi özniteliklerinden bu aşamada sıklıkla yararlanılmaktadır. Plaka tespit aşaması için literatürde önerilen yöntemler Bölüm 3'te gözden geçirilmiştir. Özetle, bu aşamada bir tümdengelim stratejisi işletilerek giriş imgesinden plaka bilgisi çıkartılmaktadır.

1.3.2.2. Karakter ayrıştırma aşaması

Karakter ayrıştırma aşaması, karakter tanıma (OCR) öncesindeki son işlem adımını oluşturmaktadır. Bir önceki aşamada elde edilen plaka bilgisi bu aşamada uygun bir eşikleme yöntemi ile ikili hale dönüştürülerek karakter adayları üretilmektedir. Eşikleme öncesinde; geometrik düzeltme, imge iyileştirme, plaka normalizasyonu gibi ön işlemlerden sıklıkla yararlanılmaktadır. Sonrasında plaka karakterleri gürültü içerisinden ayrıştırılmaktadır. Karakter ayrıştırma, OPT sürecindeki kritik adımlardan birini oluşturmaktadır. Pek çok tanıma hatası tanıma sisteminin yetersizliğinden değil, karakter ayrıştırma aşamasında yapılan hatalarından kaynaklanmaktadır [4].

1.3.2.3. Optik karakter tanıma aşaması (OCR)

Ayrıştırılan karakterler, bu aşamada istatistiksel sınıflandırıcılar, yapay zeka mimarileri, örüntü eşleme tekniklerinin herhangi birinden yararlanılarak

tanınmaktadır. OCR için karakter yükseklikleri en az 20 piksel olmalıdır [4]. Karakter tanıma aşamasındaki önemli kavramlardan biri de Bölüm 1.3.1.1'de anlatılan etkin mesafedir. Bu mesafe tanınacak en küçük boyutlardaki plaka ve dolayısıyla karakter yüksekliklerine etki edeceğinden, OCR öncesinde karakter yükseklikleri normalize edilmelidir. OCR tasarımları artık yeterli olgunluğa erişmiştir. Yazılım geliştiriciler dikkatlerini yeni bir OCR tasarımı kurmak yerine, belirsiz karakterleri (0-O, I-1, B-8-3, S-5, G-6 vs.) çözme üzerine odaklamışlardır [4].

1.4. OPTS Başarımına Etki Eden Faktörler

Bir OPT sisteminin başarımı her bir aşamanın sağlamlığına dayanmaktadır. Sistem başarımına etki eden faktörler, plakanın kendisinden ya da çevresel etkenlerden kaynaklanabilir.

Plakadan kaynaklanan faktörler;
-Konum: Plakalar bir görüntü içerisinde farklı konumlarda olabilir.
-Miktar: Bir görüntü ya hiç plaka içermez ya da çok sayıda plaka içerebilir.
-Boyut: Plakalar yakınlaştırma faktörü ve kamera mesafesi nedeniyle farklı boyutlarda olabilir.
-Renk: Plakalar farklı plaka türleri veya çekim cihazları nedeniyle çeşitli karakterler ve arka plan rengine sahip olabilir.
-Yazı tipi (Font): Farklı ulusların plakaları farklı fontlarda ve dillerde yazılmış olabilir.
-Standart karşısında özelleştirme: Örneğin Şekil 1.5(a) ve 1.5(b)'de gösterildiği gibi.
-Kaplanma: Plakalar kirle kaplanmış olabilir.
-Eğim: Şekil 1.6(b)'de gösterildiği gibi plakalar eğik olabilir.
-Diğer: Karakterlere ek olarak, bir plaka çerçeve ve vidalar içerebilir.

Çevreden kaynaklanan faktörler;
-Aydınlatma: Giriş imgeleri, araç farları ve çevresel aydınlatma gibi başlıca nedenlerle farklı aydınlatma türlerine sahip olabilir.
-Arka plan: İmge arka planı plakaya benzer örüntüler içerebilir.



(a) (b)

Şekil 1.5. (a) Özelleştirilmiş Türk plakası, (b) Standart Türk plakası



(a) (b)

Şekil 1.6. (a) Plaka üzerinde ışıklılık değişimi, (b) Farklı görüş açısı durumu

Geliştirilecek OPTS'nin tüm bu zor koşullar altında etkili olarak çalışması istenmektedir.

1.5. OPTS'nin Uygulama Alanları

Plaka tanıma sistemleri geniş bir uygulama alanına sahiptir. Bunlardan en popüler olan uygulamalar:

-Çalıntı araç tespiti,

-Işık ihlalleri,

-Güvenlik uygulamaları,

-Elektronik geçiş ücreti ödemeleri,

-Hız kontrol uygulamaları,

-Kontrollü araç geçişinin ihtiyaç duyulduğu yerler.

Dünyada ticari olarak plaka tanıma sistemi tasarlayan ve ürün olarak satan birçok firma mevcuttur. Tomasetti ve Frechette [5] tarafından hazırlanan bu firmaların bazıları Yavuz [6] tarafından düzenlenmiştir.

Türk sivil plakaları 7 veya 8 karakterden oluşmaktadır. Plaka karakterlerinden ilk ikisi plakanın en solunda bulunup plakanın ait olduğu il kodunu temsil ederler. Ortada 1, 2 veya 3 karakter bulunabilir ve ortadaki karakter sayısına göre sonda 4, 3 veya 2 rakam yer alabilmektedir.

Tablo 1.1. Ticari plaka tanıma sistemleri [6]

Firma	Ürün adı
AITEK Srl	TarGet
Alphatech Inc.	Argus; VES (Violation Enforcement System)
Amano Cincinnati, Inc.	LPR (License Plate Recognition System)
American Traffic Systems, Inc.	AutoPass/AutoScan
AutoVu Technologies, Inc.	Auto Trace
Belgian Advanced Technology Systems	CIS (Car Identification System)
ECM Inc.	Neuroplak
Elettronica Santerno SpA.	SIRIO
ELIOP Tráfico SA	SIPA
Federal APD, Inc.	License Plate Inventory
Fornix Information Technologies	Carina
Fraunhofer-Institute	ISYPLATE
Gevis Video Identifizierungs Systeme	VIS1000 (Video Identification System)
Hi-Tech Solutions	LPR (License Plate Reader); SEE/CAR
Hughes Transportation Management	Video-Tag
MAZ Hamburg GmbH	MAZ-VIS (Vehicle Identification System)
Monitron International Ltd.	Number Plate Recognizer
Neurotechnologija Ltd.	CIS (Car Identification System)
Non-Cooperative Target Recognition Ltd.	VIA
OMRON Corporation	Automatic Vehicle Identifier
Optasia Systems Pte Ltd	IMPS (Integrated Multi-Pass System)
Parsytec Computer GmbH	Ruggedized ID-Recognition Systems
Perceptics Corporation	Perceptics Corporation
R&H Systems BV	KEVER
Racal Messenger Ltd.	Talon
R.B. TEC Ltd.	CMPS (Car Plate Matching System)
Redflex Traffic Systems Pty Ltd	TCO (Automated Traffic Camera Office)
Siemens Traffic Controls Ltd.	ARTEMIS-IC
Telematica Systems Ltd	Automatic Number Plate Recognition
Telstra Applied Technologies	Safe-T-Cam
Visual Image Dynamics Ltd.	ANPR (Automatic Number Plate Reader)
Zamir Recognition Systems Ltd.	Centurion



Şekil 1.7. Farklı ülkelere ait plaka örnekleri [7]



Şekil 1.8. Türk Sivil Plaka Örnekleri

1.6. Tezin Amacı

Bu tezde yapılan çalışmaların amacı, OPT sistemlerinde uygulanan yöntemlerin incelenmesi, farklı bakış açıları, mesafe değişimleri, değişen aydınlatma koşulları ve karmaşık arka plan altında başarılı ve hızlı çalışan bir OPT sisteminin geliştirilmesidir. Tez çalışmasında, araç imgesini yakalayacak donanım kısmına odaklanılmamış olup alınan görüntüden plaka tespiti ve tanıma üzerine çalışmalar yapılmıştır.

2. PLAKA TESPİTİ

2.1. Giriş

Otomatik plaka tanıma; renkli, siyah/beyaz ya da kızılötesi kameranın herhangi birinden alınan bir video dizisinden veya bir imgeden araç plaka bilgisinin çıkartılması işlemidir. Çıkartılan bilgi; çalıntı araç takibi, elektronik ödeme sistemleri, trafik gözetimi gibi birçok gerçek yaşam uygulamasında bir veri tabanı ile kullanılabilmektedir.

Farklı ülkelerin farklı plaka standartları, özelleştirme, plakada kullanılan renkler, kirle kaplanma durumu, araç ve plaka arası mesafe nedeniyle değişen plaka boyutları, eğiklik vs. tespiti zorlaştıran plaka kaynaklı faktörlerdir. Aydınlatma koşulları ve karmaşık arka plan ise tespiti zorlaştıran çevresel faktörleri oluşturmaktadır. Geliştirilecek bir otomatik plaka tanıma (OPT) sisteminin tüm bu zor koşullar altında hızlı ve başarılı olarak çalışması istenir. Bu nedenle belirtilen problemler karşısında etkili çalışan bir OPT sistemi tasarlama oldukça zorlu bir problemdir [3].

Bu çalışmada, Türk sivil araç plakaları için farklı görüş açıları, mesafe değişimleri, değişen aydınlatma koşulları ve karmaşık arka planda başarılı ve hızlı çalışan bir sistem geliştirmek amaç edinilmiştir.

2.2. Plaka Tespiti İçin Literatüre Bir Bakış

Literatür incelendiğinde sunulan çoğu yöntemin kenar, doku, renk gibi plaka özniteliklerini doğrudan kullandığı görülmektedir.

2.2.1. Kenar özelliğini kullanan yöntemler

Araç plakası bilinen en/boy oranında bir dikdörtgensel şekle sahip olduğu için görüntüdeki tüm olası dikdörtgensel bölgeler tespit edilerek bulunabilmektedir. Kenar tespit algoritmaları sıklıkla bu amaç için kullanılmaktadır. Bunlardan en bilindiği Sobel kenar tespit algoritmasıdır. [16]'da plaka bölgesi içerisindeki dikey kenarlar Sobel filtresiyle tespit edilmiştir. Bu çalışmada dikey kenar genliği, güçlü bir plaka

çıkartım özelliği olarak görülmüş, yatay kenar genliğinin araç tamponu gibi etkenlerden dolayı genellikle hatalı tespitlere neden olduğu belirtilmiştir.

Bu çalışmadaki temel varsayım, eğer dikey kenarlar çıkartılmış ve arka planda yer alan kenarlar elenmiş ise, plaka bölgesinin kenar haritasından kolaylıkla elde edilebileceğidir. 1165 imge üzerindeki tespit oranı %100'e yakınken, 384x288 boyutunda bir imge için hesapsal zaman 47,9 ms olarak belirtilmiştir.

[18]'de blok temelli taramalar ile ilgili bloklar içerisindeki dikey kenar yoğunlukları incelenmiş, yüksek kenar yoğunluğuna sahip bloklar muhtemel plaka bölgesi olarak görülmüştür. Bu çalışmada blok temelli taramaların plaka sınırlarına bağlı olmadığı, bu nedenle sınırları kir ve benzeri etkenlerden dolayı net olmayan plakalara da kolaylıkla uygulanabileceği belirtilmiştir. Çalışmada belirtilen doğruluk oranı %92,5'dir.

[17]'de plaka tespit problemi için yeni ve hızlı dikey kenar çıkartım algoritması (VEDA) geliştirilmiştir. Bu çalışmada VEDA' nın, Sobel operatöründen 7-9 kat arası daha hızlı olduğu belirtilmiştir.

Kenar bilgisi görüntüdeki düşük seviyeli özelliklerdendir. Bu nedenle kenar temelli yöntemler hızlılık ve basitlik avantajına sahiptir, ancak kenarların sürekliliğini gerektirmektedirler. Parçalanmış kenarlar genellikle CCA gibi eleme adımlarında beklenen istatistiksel özellikleri taşımadıkları için elenmektedirler. Plaka tespitinde kenar özelliklerini kullanan yöntemlerin bu eksikliği, bir morfolojik imge işlemi yöntemi ile telafi edilerek tespit başarımları nispeten arttırılabilmektedir.

2.2.2. Doku özelliğini kullanan yöntemler

Plaka bölgesi tespitinde doku özelliğini kullanan yöntemler plaka karakterlerinin varlığına bağlıdırlar. Plakanın arka plan rengi ve karakter renkleri arasındaki geçiş, plakaya özel bir doku oluşturmaktadır. Bu renk geçişleri ayrıca kenar yoğunluğu yüksek olan bir alanı da beraberinde getirmektedir. [19]'da görüntü içerisindeki metin bölgelerinin tespiti için vektör kuantalama (VQ) kullanılmıştır. VQ gösterimi görüntünün çeşitli bölgeleri hakkında belirli ipuçları vermektedir. Bu gösterimde yüksek kontrasta sahip bölgeler daha küçük bloklar ile temsil edilmektedir. Bu

çalışmadaki tespit oranı %98, tespit için geçen işlem süresi ise 200 ms olarak belirtilmiştir.

Gabor filtresi doku analizi için kullanılabilen güçlü yöntemlerden biridir. Bu tekniğin en büyük avantajı sınırsız yön ve ölçekte analiz yapmaya olanak tanımasıdır. [21]'de plaka bölgesi tespiti için belirlenen özel bir ölçek ve açı değerinde yapılan analizler %98 tespit başarısı vermiştir. Ancak bu yöntem çok zaman alıcıdır.

[20]' de SCW yöntemi geliştirilmiştir. Bu çalışmada plaka, imge dokusundaki düzensizlikler olarak düşünülmüş, bu nedenle yerel karakteristiklerdeki ani değişimler muhtemel plaka bölgesi olarak görülmüştür.

Plaka tespitinde doku özelliğini kullanan yöntemler sınırlar net olmasa da tespit yapabilme avantajına sahiptir, ancak özellikle karmaşık arka plan ve farklı ışıklılık koşulları altında üretilen çok sayıda kenar, hesapsal yükü arttırarak OPT için önemli bir etken olan hızı düşürmektedir.

2.2.3. Renk özelliğini kullanan yöntemler

Bazı ülkeler araç plakalarına özel renkler kullanmaktadır. Plaka tespitinde renk özelliğini kullanan yöntemlerin temel varsayımı, plaka ve karakter renkleri arasındaki renk kombinasyonu tektir ve bu kombinasyon neredeyse yalnızca plaka bölgesinde oluşur, üzerine kuruludur.

[23]'de renkli imgeler ortalama kayma algoritmasıyla aday bölgelere ayrılmış, ardından plaka olup olmamasına göre sınıflandırılmıştır. [22]'de plaka bölgesi yalnızca beyaz, siyah, kırmızı ve yeşil renklerini içerdiğinden, renk kenar algılayıcısı yalnızca siyah-beyaz, kırmızı-beyaz, yeşil-beyaz gibi geçişlerden oluşan kenarlara odaklanmaktadır. Plaka tespitinde renk özelliğinin kullanılması eğik ve deforme olmuş plakaların tespitini sağlayabilmektedir, ancak özellikle değişen ışıklılık koşullarında RGB değerini kullanarak piksel renklerinin tanımlanması oldukça zordur. Bu durumda HSL alternatif bir renk modeli olarak düşünülebilir, ancak HSL renk uzayı da gürültüye karşı çok duyarlıdır.

2.2.4. Karakter özelliğini kullanan yöntemler

[24]'de kenar, doku, renk gibi plaka özniteliklerini doğrudan kullanmak yerine karakter bölgelerini arayan bir algoritma geliştirilmiştir. Bölge temelli bir yaklaşım izlenerek bulunan bölgeler bir sinir ağı ile sınıflandırılmış, karakter bölgelerinin doğrusal bir kombinasyonu bulunmuşsa tüm plaka bölgesinin bulunduğu varsayılmıştır.

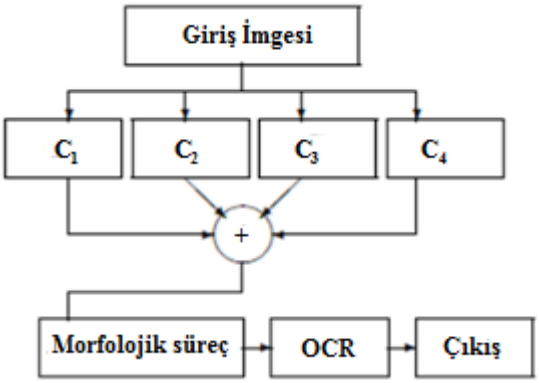
[25]'de doğal manzaralardaki metin bölgelerinin tespiti için SWT yöntemi geliştirilmiştir. SWT yönteminin çıkışı; her pikselin en olası genişliğini içeren giriş imgesi ile aynı boyutlardaki imgedir. Pikseller sonrasında stroke değişintisi gibi bazı kurallar eşliğinde karakter adaylarına gruplanmaktadır.

[26]'nın yazarları ise SWT yönteminden esinlenerek MSWT yöntemini geliştirmişlerdir. Geliştirilen MSWT yöntemi Şekil 2.1'de gösterilmiştir.

2.2.4.1. MSWT yöntemi ile plaka tespiti

Bu çalışmada giriş imgesindeki yatay, dikey, 45° ve 135° pozitif ve negatif kenarlar çıkartılıp bağlı ışın adı verilen sınırlı uzunluktaki ışınlarla bağlandığı dört imge oluşturulmuştur. Sonrasında imgeler birleştirilerek ışın imgesi (ray image) elde edilmiştir. Işın imgesi tüm karakter adaylarını içermektedir. Işın imgesindeki karakter adayları arasından plaka karakterlerinin bulunmasında özel bir yöntem geliştirilmemiş, CCA ile bulunan bağlı bölgeler arasından yakınlık ve yükseklik faktörlerine göre plaka karakterlerinin bulunup çıkartıldığı belirtilmiştir.

MSWT yöntemi, değişen aydınlatma ve karmaşık arka plan altında başarılı tespit yapabilirken, karakter bölgesi çok dar ya da deforme olduğu durumda ise orijinal çalışmada da belirtildiği gibi başarısız sonuçlar üretmektedir. Bu durum Şekil 2.3(b)'de gösterilmiştir.



Şekil 2.1. MSWT yöntemi akış şeması [26]

Tablo 2.1. Bir plaka imgesi için MSWT yöntemi ile karakter adaylarının oluşturulması

Giriş imgesi	**Kenar haritaları**		**Işın bağlama**		**Işın imgesi**
					$R = C_1 \cup C_2 \cup C_3 \cup C_4$
	I_1		C_1		
	I_2		C_2		
	I_3		C_3		
	I_4		C_4		

Önerilen MSWT algoritmasının uygulanışı klasik SWT yöntemine kıyasla basittir ve nispeten SWT'den daha iyi sonuçlar vermektedir; ancak bu yöntemde dört ayrı kenar imgesi oluşturulması, sonrasında her bir kenar imgesinde belirtilen başlangıç ve bitiş koşullarının aranarak ışın bağlanması, tespit sürecini fazlasıyla yavaşlatmaktadır. Şekil 2.2'de MSWT yöntemi ile örnek bir tespit sonucu gösterilmektedir.



(a)

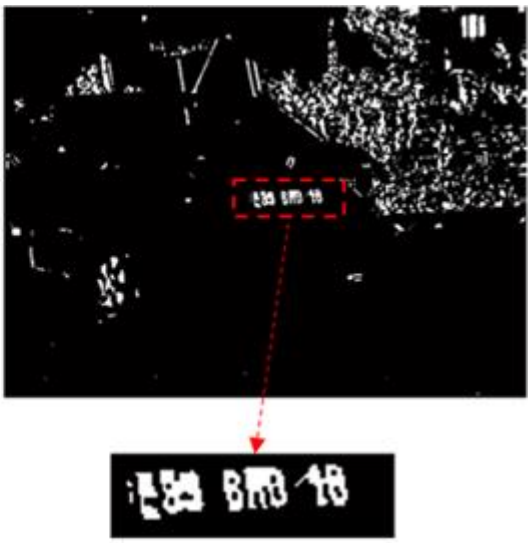




(b) (c)

Şekil 2.2. (a) Örnek giriş imgesi, (b) Oluşturulan ışın imgesi (ray image), (c) Tespit sonucu



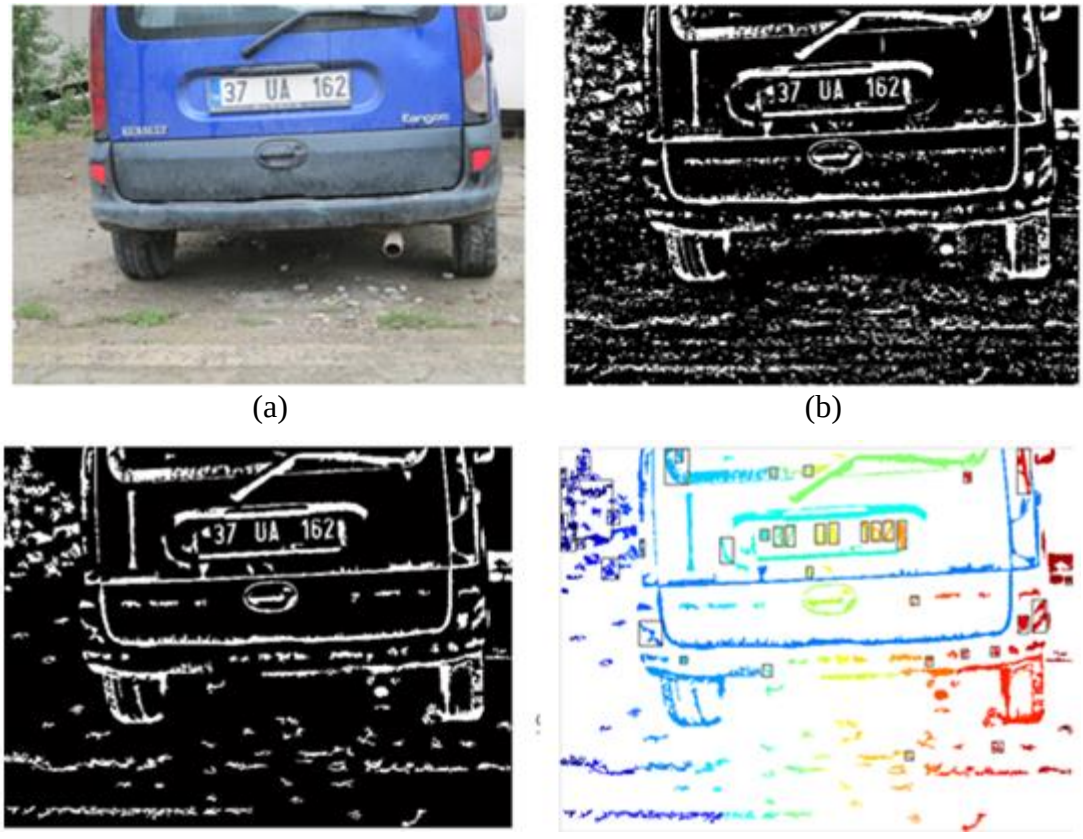


(a) (b)

Şekil 2.3. (a) Giriş imgesi, (b) Oluşturulan ışın imgesi (ray image)

2.2.4.2. Hough dönüşümünden yararlanan kümeleme temelli plaka tespiti

[27]'deki çalışmada uyarlamalı yerel eşikleme ile ikili hale dönüştürülen görüntüdeki 30 pikselden küçük bağlı bileşenler elenmiş, 0,25-1 en/boy aralığında kalanların üst noktaları bir küme, alt noktalarını ise ayrı bir küme olarak işaretlenmiştir. Sonrasında işaretlenen kümeler üzerinde Hough dönüşümü uygulanarak doğrusal bölgeler tespit edilmiş, karakterler paralel doğrular arasındaki boşluk yaklaşık eşittir varsayımına göre bulunmuştur. Şekil 2.4 ve Şekil 2.5'de bu yöntemden yararlanılarak gerçekleştirilen tespit süreci gösterilmektedir.



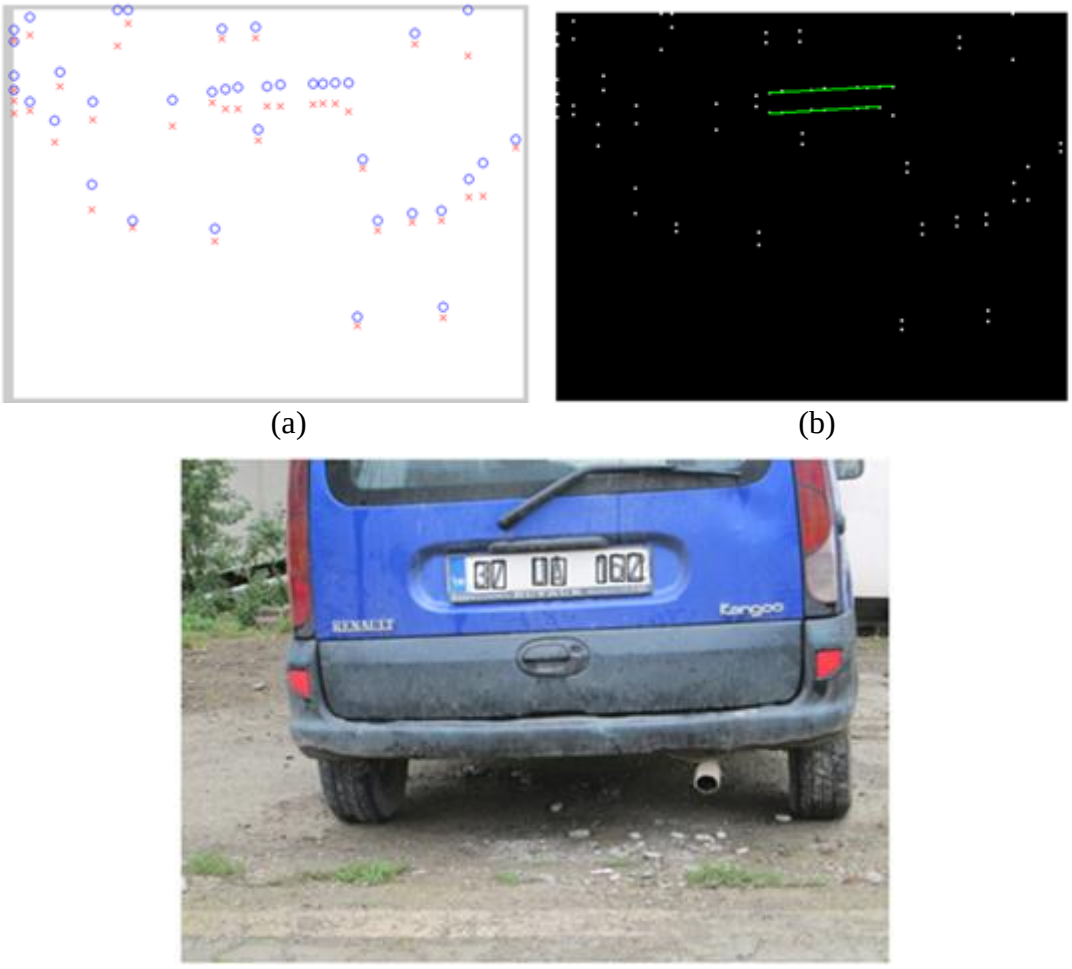
(a) (b)

(c) (d)

Şekil 2.4. (a) Giriş imgesi, (b) Niblack yöntemi ile yerel eşikleme çıkışı, (c) 30'dan az piksele sahip bölgelerin temizlenmesi, (d) 0,25-1 en/boy oranı aralığındaki bölgeleri işaretleme

Bu yöntemde plaka karakteri olmayan bölgelerin işaretlenen üst ve alt nokta koordinatları da doğrusal çıkabileceğinden yanlış bölgeler tespit edilebilmektedir. Belirtilen 0,25-1 en/boy aralığında kalan; ancak plaka karakteri olmayan birbirine yakın nesnelerin üst ve alt nokta koordinatları Hough dönüşümleri sonucunda yanlış bölgeler olarak bulunabilmektedir. Yöntemde hesapsal zaman kavramına

değinilmemiştir. Literatürde hesapsal yükü ağır olarak adlandırılan Hough dönüşümü bu çalışmada iki kez uygulanmaktadır.



Şekil 2.5. (a) Kümelenen üst ve alt nokta koordinatları, (b) Her bir küme üzerinde uygulanan Hough dönüşümü ile bulunan doğrusal noktalar, (c) Hatalı bölgeler ile bulunan plaka karakterleri

2.3. Motivasyon

Tez çalışması kapsamında gerçekleştirilen çalışmaların esas amacı farklı bakış açıları, mesafe değişimleri, değişen aydınlatma koşulları ve karmaşık arka plan altında altında hızlı ve başarılı olarak çalışan bir plaka konum tespit yöntemi geliştirmektir. Yapılan çalışmada karakter özelliklerinden yararlanılarak plaka bölgesi tespit edilmeye çalışılmıştır. Çalışmada karakter özelliklerinden yararlanan bir yöntem izlenmesinin temel nedenleri şunlardır:

-Karakter özelliklerini kullanan yöntemler plaka sınırlarından bağımsızdır. Bu nedenle sınırları net olmayan plakalarda başarılı sonuçlar alınabilir.
-Tablo 2.2'de özetlendiği gibi, karakter özelliklerini kullanan yöntemler rotasyona dayanıklıdır. Bu nedenle önemli derecede rotasyon içeren plakalarda da başarılı sonuçlar alınabilir.

Tablo 2.2. Plaka çıkartım yöntemlerinin avantaj ve dezavantajları [3]

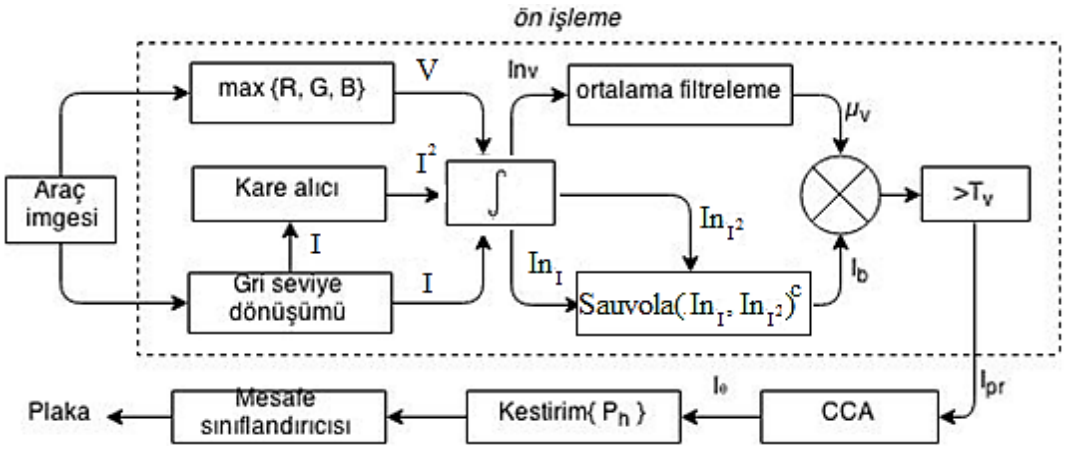
Yöntem	**Temel Mantık**	**Avantaj**	**Dezavantaj**
Sınır ya da kenar özelliklerini kullanma	Plaka sınırlarının dikdörtgenselliği	Basit, hızlı ve anlaşılırdır	İstenmeyen kenarlara aşırı duyarlı olması nedeniyle karmaşık imgelere uygulamak zordur
Doku özelliklerini kullanma	Plakadaki sık renk geçişleri	Sınırlar deforme olsa bile plaka tespitini yapabilmektedir	Çok sayıda kenar olduğunda hesapsal yükü ağırdır
Renk özelliklerini kullanma	Plaka üzerindeki özel renk	Plaka bölgesi eğimli ve deforme olsa bile plaka tespitini yapabilmektedir	RGB aydınlatma koşullarına, HSI gürültüye karşı duyarlıdır
Karakter özelliklerini kullanma	Plaka üzerindeki karakterler	Rotasyona karşı sağlamdır	Zaman harcayıcıdır (tüm ikili nesneleri işler), imge içinde farklı metin bölgeleri olduğunda hatalı tespit üretebilmektedir
İki veya daha fazla özelliği kullanma	Daha etkili olan özellikleri birleştirme	Daha güvenilirdir	Hesapsal yükü ağırdır

Karakter özelliklerinden yararlanarak plaka bölgesini tespit eden yöntemler imgedeki karakter bölgelerini bulabilmek için tüm ikili nesneleri işler. Bu yaklaşım geliştirilecek plaka tanıma sisteminin hesapsal yükünü arttırmaktadır.

Tez çalışması kapsamında karakter özelliklerinden yararlanılarak plaka bölgesini tespit eden MSWT yöntemi [26] incelenmiştir. Bu çalışma imgedeki karakter bölgelerini bulabilmek için tüm ikili nesneleri işlemektedir. Karakter özelliklerinden yararlanarak plaka bölgesini bulan yöntemlerin getirdiği hesapsal yük dezavantajını gösterebilmek, bu çalışmanın incelenmesinin temel sebebini oluşturmaktadır.

Tez çalışma kapsamında incelenen ve plaka bölgesi tespitinde karakter özelliklerinden yararlanan diğer bir yöntem [27]'de önerilmiştir. Bu çalışmada karakter bölgelerini tespit edebilmek için imgedeki tüm ikili nesnelerin incelenmesi yerine Hough

dönümünden yararlanan kümeleme temelli bir yaklaşım ile doğrudan plaka karakterleri bulunmaktadır. Bu çalışmada hesapsal yükü düşürebilmek için klasik OPTS aşamalarından konum tespitinin atlanarak doğrudan karakter ayrıştırma ve tanımanın hedeflenmesi çalışmanın incelenmesinin temel sebebini oluşturmaktadır. İncelenen her iki çalışma Bölüm 2.2.4'de detaylarıyla anlatılarak her bir yöntemin performansı ve istatistiksel sonuçlar Bölüm 2.5'de sunulmuştur.



Şekil 2.6. Önerilen yöntem

2.4. Önerilen Plaka Tespit Yöntemi

Tez çalışması kapsamında plaka bölgesi çıkarımında karakter özelliklerinden yararlanan bir yöntem izlenmiştir. Bir önceki bölümde de söz edildiği gibi plaka bölgesi çıkarımında karakter özelliklerini kullanan yöntemler karakterlerin varlığı için giriş imgesini incelemektedir. Eğer karakterler bulunursa, karakterlerin bulunduğu bu bölge plaka bölgesi olarak çıkartılacaktır.

Plaka tespit problemi için literatürde önerilen pek çok yöntem araç plakalarının hemen hemen tam karşıdan yakalandığı varsayımı altında çalışır. Plaka bölgesi tespitinde karakter özelliklerini kullanan bir yöntemin izlenmesindeki temel sebep görüş açısı değişimlerinde de başarılı sonuçlar elde etme isteği olmuştur.

Tez çalışması kapsamında önerilen tespit yöntemi; ön işleme, bağlı bileşen analizi (CCA) ve yatay izdüşüm ile karakter bölgesi kestirme adımlarından oluşmaktadır. Önerilen yönteme ait blok diyagram Şekil 2.6'da gösterilmektedir.

2.4.1. Ön işleme

Ön işleme adımında temel amaç gelecek tespit adımlarının hesapsal yükünü düşürebilmek için plaka adayı olamayacak (istenmeyen) piksel bölgelerini mümkün olduğunca elemektir. Bu amaçla ilk adımda giriş görüntüsü ikili forma dönüştürülmektedir. Ardından, elde edilen imge Sauvola yönteminden yararlanılarak eşiklenmektedir [13].

2.4.1.1. Gri seviye dönüşümü

Renkli giriş görüntüsündeki her bir piksel kırmızı, yeşil, mavi (RGB) renklerin farklı oranlarda birleşmesinden oluşmaktadır. Böylece her bir pikselin farklı bir rengi olacaktır. Türk sivil araç plakaları beyaz arka plan üzerindeki siyah karakterlerden oluşarak tek bir renk geçişine sahiptir. Bu nedenle renkli görüntüler ile çalışmak OPT sistemleri açısından gereksiz birçok veri ile çalışmaya sebep olur. Ayrıca araç plakası ile araç gövdesinin benzer renklerde olması da plaka tespitini zorlaştırabilmektedir. Tüm bu söz edilenlerin önüne geçebilmek için renkli görüntü gri seviyeli görüntüye dönüştürülerek giriş görüntüsü gereksiz verilerden arındırılmaktadır. Giriş görüntüsünü gri seviyeli görüntüye Eşitlik (2.1),

$$I=0,299R+0,587G+0,114B \tag{2.1}$$

ile dönüştürülmektedir.

2.4.1.2. Görüntü eşikleme

Eşikleme, imgedeki piksellerin ön plan ve arka plan olarak sınıflandırılması süreci olarak düşünülebilmektedir. Bu nedenle nesne tanıma uygulamalarında önemli bir rol oynamaktadır. Eşikleme ile belirli bir eşik değerin üzerindeki değerler için bir değer, altındaki değerler için ise farklı bir değer atanarak giriş görüntüsü ikili hale dönüştürülmektedir. İmge, ikili hale dönüştürülerek yapılacak işlemlerin yükü de aza indirgenmiş olacaktır.

Birçok çalışmada görüntü eşikleme genellikle global ve yerel eşikleme olarak iki ana kategoriye ayrılmaktadır. Sezgin ve Sankur [9] birçok eşikleme tekniğini inceleyerek eşikleme tekniklerini;
-Histogram şekil temelli yöntemler,

-Kümeleme temelli yöntemler,
-Entropi temelli yöntemler,
-Nesne özniteliği temelli yöntemler,
-Uzamsal yöntemler,
-Yerel uyarlamalı yöntemler,
olmak üzere altı ana kategoriye ayırmışlardır.

Global eşikleme: Işıklılığın tek düze dağıldığı imgelerde tüm imge için tek bir eşik değer kullanılması, piksellerin ön plan ve arka plan olarak sınıflandırılmasında istenilen sonuçları vermektedir. Tüm imge için tek bir eşik değeri kestirimi yapan böyle yöntemler global ya da bütünsel eşikleme yöntemleri, kestirilen eşik değeri ise global eşik olarak tanımlanmaktadır. I, giriş imgesini; T, global eşik değerini belirtmek üzere global eşikleme için genel bir ifade Eşitlik (2.2)'deki gibi;

$$I_b(i,j)=\begin{cases}1, & \text{eğer } I(i,j)>T\\ 0, & \text{eğer } I(i,j)\leq T\end{cases} \tag{2.2}$$

verilebilmektedir. Bu yöntemler eşik değer kestiriminde de oldukça hızlı sonuçlar üretmektedir. Otsu eşik belirleme algoritması [11] global eşikleme yöntemlerine güzel bir örnektir.

Yerel eşikleme: Işıklılığın tek düze dağılmadığı, arka planın önemli derecede gürültü içerdiği imgelerde global eşikleme yöntemleri piksellerin ön plan ve arka plan olarak sınıflandırılmasında istenilen sonuçları vermekte yetersiz kalabilmektedir. Yerel eşikleme yöntemlerinde, komşu piksellerin ışıklılık bilgileri dikkate alınarak her bir piksel değeri için eşik değeri belirlenmektedir. T(x,y), her bir piksel konumuna ait eşik değerini belirtmek üzere yerel eşikleme için genel bir ifade Eşitlik (2.3)'deki gibi;

$$I_b(i,j)=\begin{cases}1, & \text{eğer } I(i,j)>T(x,y)\\ 0, & \text{eğer } I(i,j)\leq T(x,y)\end{cases} \tag{2.3}$$

verilebilmektedir. Klasik yerel eşikleme yöntemlerinden bazıları Niblack [12] ve Sauvola [13] yöntemleridir. Bu iki yerel eşikleme yöntemi için eşik değerinin hesaplanmasında pencere ortalamasının yanında standart sapma da dikkate alındığından literatürde yerel değişinti yöntemleri olarak bilinmektedirler.

Niblack yöntemi ile uyarlamalı yerel eşikleme: σ(x,y), yerel standart sapmayı; μ(x,y), yerel ortalamayı; k, yanlılık değerini belirtmek üzere bu yöntemde wxw boyutundaki her bir yerel pencere için eşik fonksiyonu T(x,y), Eşitlik (2.4)'deki gibi;

$$T(x,y)=\mu(x,y)+k.\sigma(x,y) \tag{2.4}$$

hesaplanmaktadır [10]. Plaka tespit problemi için Bölüm 2.2.4.2'de anlatılan çalışmada Niblack yönteminden yararlanılmıştır.

Sauvola yöntemi ile uyarlamalı yerel eşikleme: Sauvola yöntemi, kötü ışıklılık koşullarına karşı Niblack yönteminin iyileştirilmiş hali olarak da görülebilir. Bu yöntemde piksel konumları için eşik değeri Eşitlik (2.5)'de verilen fonksiyon,

$$T(x,y)=\mu(x,y).\left[1+k.\left(\frac{\sigma(x,y)}{R}-1\right)\right] \tag{2.5}$$

ile hesaplanmaktadır. (2.5)'deki μ ve σ, sırasıyla yerel ortalama ve standart sapmaları; R, standart sapmanın maksimum değerini; k ise değeri 0,2-0,5 arasında değişen yanlılığı ifade etmektedir.

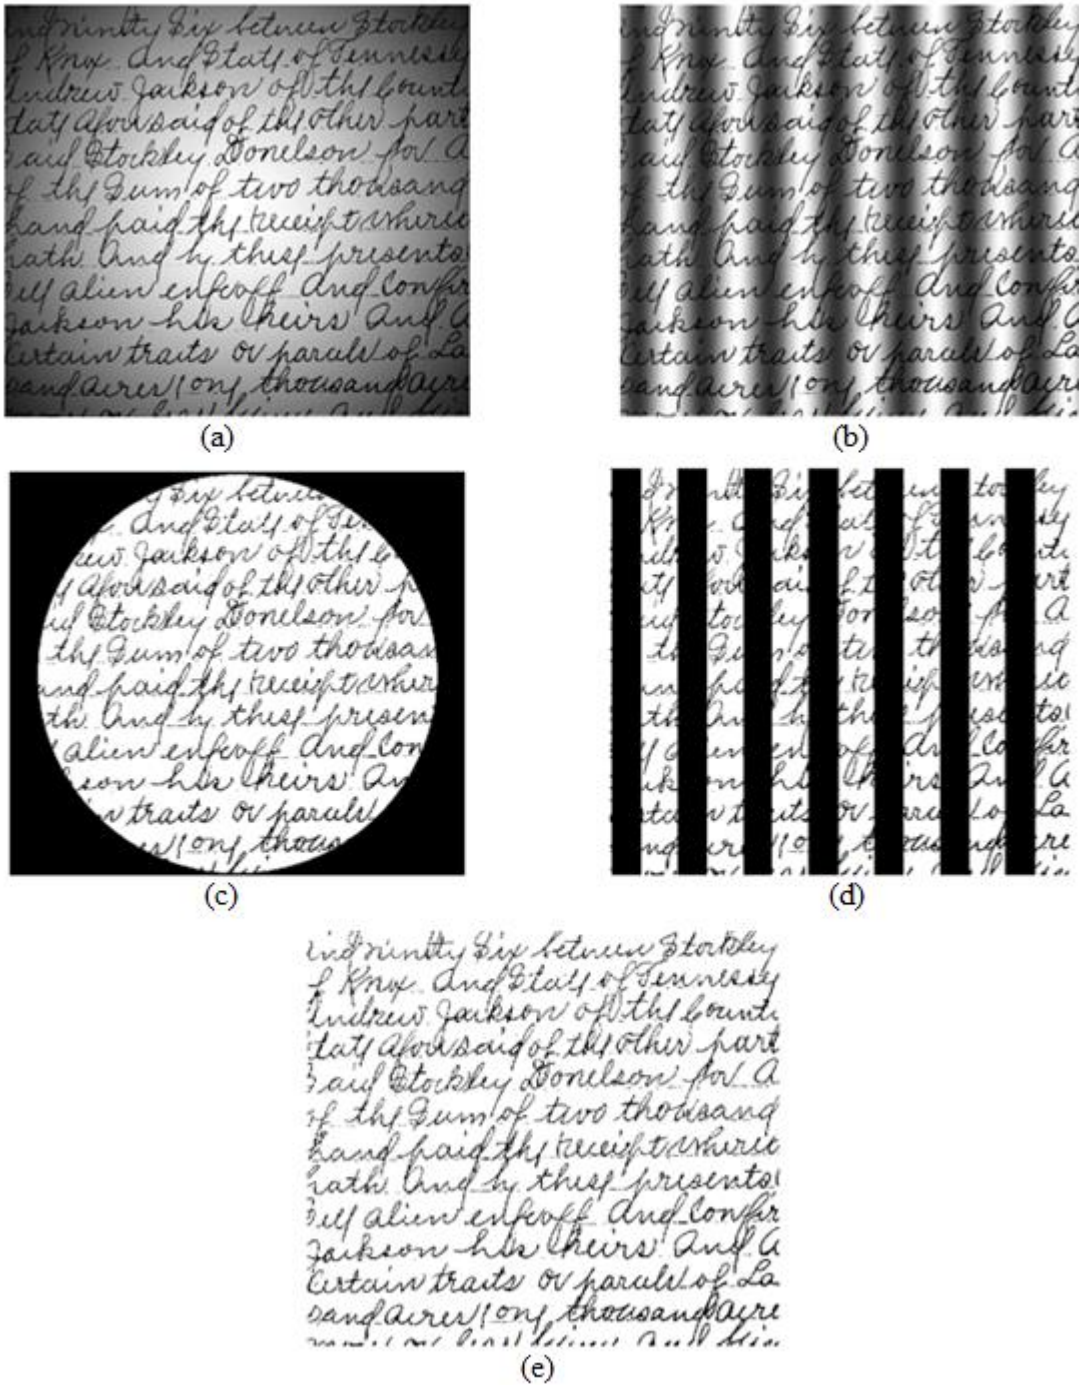
İmgenin herhangi bir bölgesinde kontrast yüksek olduğunda, Eşitlik (2.5)'den açıkça anlaşılabileceği gibi eşik değer ortalama değere yaklaşacaktır. Bu durum, Niblack yöntemine benzer bir sonuç oluşturmaktadır. Böylece, kontrastın düşük olduğu imge bölgelerinde, eşik değer ortalamadan daha düşük seviyelere inerek arka plandaki nispeten karanlık bölgelerin başarılı olarak temizlenmesini sağlayabilecektir. [10]

Şekil 2.7'de bozulmuş doküman görüntüleri üzerinde uygulanan global ve yerel eşikleme yöntemlerine ilişkin sonuçlar gösterilmektedir.

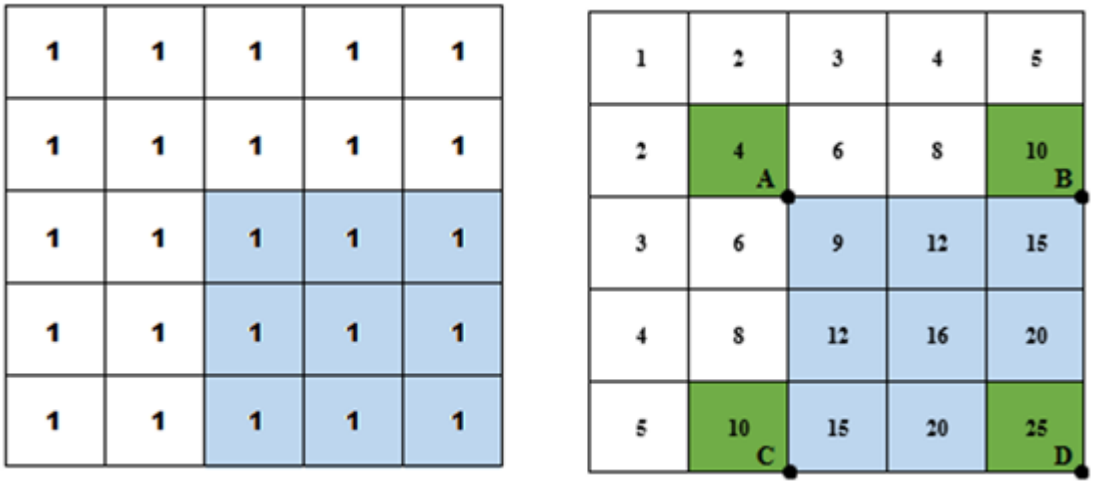
Yerel eşikleme yöntemlerinin hesapsal yükü yerel pencere boyutlarına bağlı olarak değişmektedir; ancak integral imgeden yararlanılarak hesapsal yük pencere boyutlarından bağımsızlaştırılabilmektedir.

Tez çalışması kapsamında, ön işleme adımında görüntü eşikleme için Sauvola yöntemi kullanılmıştır. Sauvola yöntemine ait eşik fonksiyonunun ve parlaklık imgesi yerel ortalamalarının hızlı hesaplanması amacıyla integral imgeden yararlanılmıştır. İntegral imge, bir imgenin belirli bir dikdörtgensel bölümündeki toplamları hesaplamanın hızlı

bir yoludur. Bilgisayarla görü alanındaki ilk belirgin kullanımı Viola ve Jones [14] nesne tespitinde yer almaktadır.



Şekil 2.7. (a) Spot gölgesi ile bozulmuş doküman imgesi [8], (b) Sinüs gölgeleri ile bozulmuş doküman imgesi [8], (c)-(d) Otsu yöntemi ile global eşikleme sonucu, (e) 20x20 blok boyutu seçimi için Sauvola yöntemi ile uyarlamalı yerel eşikleme sonucu



(a) (b)

Şekil 2.8. (a) 5x5'lik örnek imge bloğu, (b) İlgili integral imge bloğu

Şekil 2.8(b)'den açıkça görüleceği gibi integral imgenin herhangi bir (x,y) konumuna ait toplam; ilgili konumdaki piksel değeri dâhil olmak üzere konumun üstünde ve solunda kalan piksel değerleri toplamına eşittir. İntegral imge üzerinde istenilen herhangi bloğun toplamı, iki toplama ve bir çıkarmadan oluşan üç aritmetik işlemle kolaylıkla hesaplanabilmektedir. Örnek olarak Şekil 2.8(b)'deki mavi boyalı alanın toplamı Eşitlik (2.6);

$$\text{Blok toplamı}=In(A)+In(D)-In(B)-In(C) \tag{2.6}$$

ile bulunabilmektedir. Eşitlik (2.5)'deki eşik fonksiyonu, integral imgeye geçilerek hızlı hesaplanabilmektedir. Gri değerli giriş imgesi için integral imge Eşitlik (2.7);

$$In_I(x,y)=\sum_{i=1}^{x}\sum_{j=1}^{y} I(i,j) \tag{2.7}$$

ile hesaplanabilmektedir. In_I, gri değerli I giriş imgesinin integral imgesini belirtmek üzere yerel blok toplamı S_1, Eşitlik (2.8)'deki gibi;

$$S_1(x,y)=\begin{matrix}[In_I(x+d-1,y+d-1)+In_I(x-d,y-d)]\\ -[In_I(x-d,y+d-1)+In_I(x+d-1,y-d)]\end{matrix} \tag{2.8}$$

üç aritmetik işlem ile bulunabilmektedir. Sauvola yönteminin eşik fonksiyonunda yer alan yerel blok ortalaması μ, Eşitlik (2.8)'den yararlanılarak Eşitlik (2.9)'daki gibi;

$$\mu(x,y)=\frac{S_I(x,y)}{w^2} \tag{2.9}$$

tek işlemle hesaplanabilmektedir. İntegral imge ile standart sapma hesaplamak ise iki integral imge gerektirmektedir. I^2; gri değerli I giriş imgesi için karesel piksel değerlerini belirtmek üzere ikinci integral imge Eşitlik (2.10)'daki gibi;

$$In_2(x,y)=\sum_{i=1}^{x}\sum_{j=1}^{y} I^2(i,j) \tag{2.10}$$

verilmektedir. Böylece ikinci integral imgedeki yerel toplamlar Eşitlik (2.11)'deki gibi;

$$S_2(x,y)=\begin{matrix}\left[In_{I^2}(x+d-1,y+d-1)+In_{I^2}(x-d,y-d)\right]\\ -[In_{I^2}(x-d,y+d-1)+In_{I^2}(x+d-1,y-d)]\end{matrix} \tag{2.11}$$

hesaplanabilmektedir. N, imgedeki belirli bir ABCD yerel bloğunun toplam piksel sayısını; μ, yerel blok ortalamasını; I_i, i. piksel değerini belirtmek üzere blok değişintisi yerel toplamlar türünden Eşitlik (2.12)'deki gibi;

$$\begin{aligned}\sigma^2&=\frac{1}{N}\sum_{i=1}^{N}(I_i-\mu)^2=\frac{1}{N}\left(\sum_{i=1}^{N}I_i^2-2\mu\sum_{i=1}^{N}I_i+N.\mu^2\right)\\ &=\frac{1}{N}(S_2-2\mu.S_1+N.\mu^2)=\frac{1}{N}\left(S_2-\frac{S_1^2}{N}\right)\end{aligned} \tag{2.12}$$

verilebilmektedir. Böylece, wxw boyutlu yerel blokların standart sapma değerleri, Eşitlik (2.13);

$$\sigma(x,y)=\sqrt{\frac{1}{w^2}\left(S_2(x,y)-\frac{S_1^2(x,y)}{w^2}\right)} \tag{2.13}$$

ile hızlı hesaplanabilmektedir. Örnek bir giriş imgesine ait integral imge Şekil 2.9(b)'de gösterilmektedir. Özetle, bu algoritma kullanılarak yapılan işlemlerde pencere boyutlarından bağımsız olarak sabit bir işleme zamanı sağlanmaktadır. Tablo 2.3'de, blok boyutunun değişimine bağlı olarak yöntemlerin hesap için harcadıkları zamanlar verilmektedir. Tablodaki n ve m sırasıyla imge satır ve sütun sayılarını ifade etmektedir.



(a) (b)

Şekil 2.9. (a) Örnek giriş imgesi, (b) 0-1 aralığına normalize edilmiş integral imgesi

Eşitlik (2.14)'deki V, nxm boyutlu parlaklık imgesini; R, G, B renkli giriş imgesi bileşenlerini; Eşitlik (2.15)'deki In_v, parlaklık matrisine ait integral imgesini; Eşitlik (2.16)'daki μ_v, wxw boyutlu yerel pencereler için tek geçişte hesaplanan ortalama imgesini; S_v, integral imge üzerinden hesaplanan yerel blok toplamlarını; Eşitlik (2.17)'deki $\circ$ notasyonu Hadamard çarpımını; T_v, parlaklık eşiğini; I_{pr} ise ön işleme çıkışını;

$$V=\max\{R,G,B\} \tag{2.14}$$

$$In_v(x,y)=\sum_{i=1}^{x}\sum_{j=1}^{y} V(i,j) \tag{2.15}$$

$$\mu_v(x,y)=\frac{S_v(x,y)}{w^2} \tag{2.16}$$

$$I_{pr}=\left(\underbrace{(I>T)^c}_{I_b} \circ \mu_V\right)_{ij} > T_v \tag{2.17}$$

ifade etmektedir. Eşitlik (2.17)'deki I_b, Sauvola yönteminin tümleyeni olan ikili çıkış imgesini ifade etmektedir. Tümleyen üzerinden çalışmak karakter adaylarını ön plana çıkartacaktır. Şekil 2.10(d)'de görüldüğü gibi Sauvola yöntemi beyaz arka planlı plaka bölgesindeki karakterleri çıkarmada başarılı sonuçlar vermekte ancak motor ızgaraları gibi ilgilenilmeyen koyu (siyah) bölgelerde de tespit yapmaktadır. Bu bölgelerde tespit yapılması sonraki adımların hesapsal yükünün artmasına neden olmaktadır. Bu

nedenle bu çalışmada özgün olarak, Sauvola yönteminin bulduğu pikseller parlaklık imgesinin yerel ortalamaları ile ağırlıklandırılmış ve sonrasında Şekil 2.10(f)'de gösterildiği gibi Eşitlik (2.17)'den yararlanılarak bir eşikleme ile tespit dışına çıkartılmıştır.

Tablo 2.3. Farklı yöntemler ile ortalama filtreleme işlemi için harcanan hesapsal zamanlar

		Hesapsal zaman (ms)							**Hesapsal karmaşa (O(.))**
Yerel pencere boyutları (w)		**3**	**5**	**7**	**9**	**11**	**17**	**25**	
Yöntem	**Kayan pencereler**	70	122	207	320	468	1091	2254	$O(n.m.w^2)$
	İntegral imge	23	23	23	23	23	23	23	O(n.m)

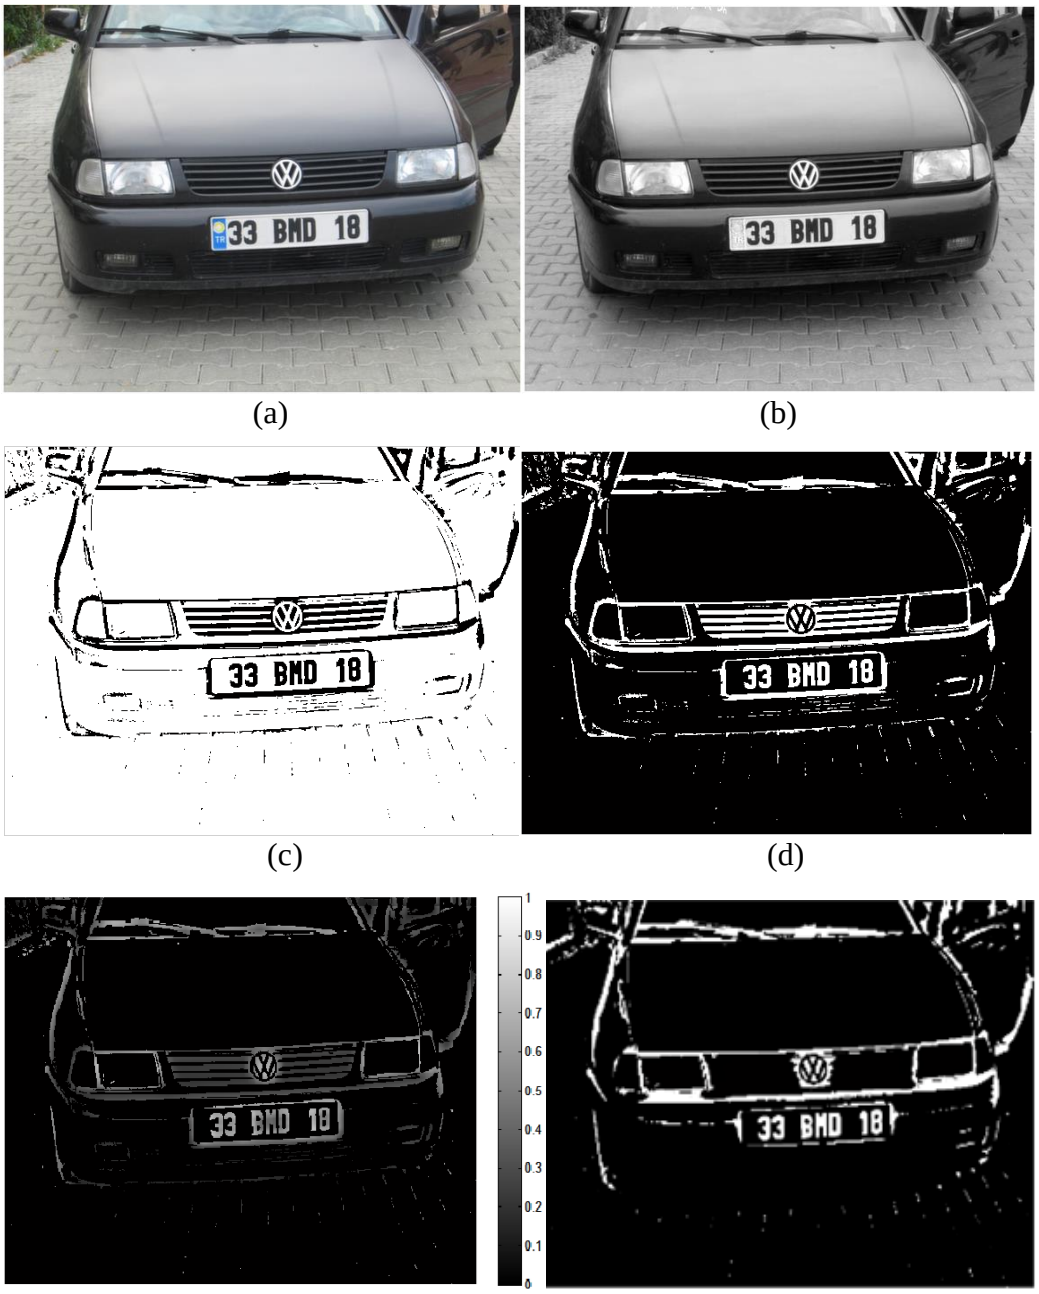
2.4.2. Bağlı bileşen analizi (CCA)

Bu adımda I_{pr} imgesindeki tüm bağlı bileşenler tespit edilerek, düşünülen karakter en/boy oranı aralığı dışında kalan bileşenler elenmektedir.

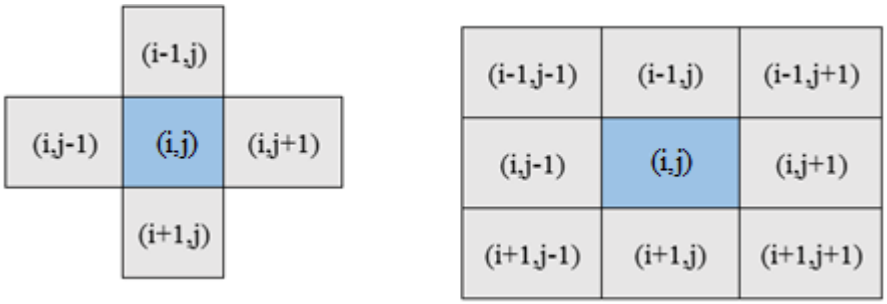
2.4.2.1. Bağlı bileşen etiketleme

Bağlı bileşen etiketleme, bir görüntüyü tarayarak görüntüdeki pikselleri piksel bağlılıklarını temel alarak bileşenler içine gruplayan, basit ve etkin bir yöntemdir. Bağlı bileşenler içerisindeki tüm pikseller aynı gri seviye değeri ile atanmaktadır. Bir görüntüdeki bağlantılı bileşenleri çıkartmak ve etiketlemek pek çok görüntü analiz uygulamasının temelini oluşturmaktadır.

Bağlı bileşen etiketleme, ikili veya gri seviyeli görüntüler üzerinde uygulanabilmektedir. Bağlı bileşen etiketlemede bağlı piksel bölgelerini belirleyebilmek için giriş görüntüsünü yukarıdan aşağıya, soldan sağa piksel-piksel taranmaktadır. Bağlı piksel bölgeleri aynı ya da benzer yoğunluk değerinden oluşan kümeler olarak da görülebilir. İkili bir görüntü için bu küme V={1} olacaktır. Ancak gri seviyeli bir görüntü için küme elemanları belirli gri seviye değer aralıkları olmaktadır. Ayrıca 4 veya 8 bağlılık olmak üzere farklı bağlılık ölçüleri de kullanılabilir.



Şekil 2.10. (a) Giriş imgesi, (b) Parlaklık imgesi, (c) Sauvola yöntemi çıkışı, (d) Sauvola yönteminin tümleyeni, (e) Ağırlıklandırılmış pikseller, (f) T_v=0,3 için eşikleme sonucu



(a) (b)

Şekil 2.11. (a) 4-komşuluk, (b) 8-komşuluk

V={1} ve p tarama sürecinin herhangi bir zamanında etiketlenecek piksel olmak üzere, bağlı bileşen etiketleme operatörü bir p noktasıyla karşılaşana kadar satır boyunca hareket etmektedir. Eğer p=1 ise daha önceden taranmış olan 4 komşusu incelenecektir.



Şekil 2.12. Komşulukların kontrol edilmesi

-Eğer tüm dört komşunun değeri de sıfır ise p'ye yeni bir etiket atanır,
-Eğer sadece bir komşu V={1} kümesinin elemanı ise ilgili komşu etiketi p'ye atanır,
-Eğer birden fazla komşu V={1} kümesinin elemanı ise etiketlerden küçük olanı p'ye atanarak denklik varsa denklik tablosuna not edilir. Atanan etiketlerde denklik olması bu etiketlerin aynı nesnenin bir parçası olduğunu ifade etmektedir.
-Tarama tamamlandıktan sonra eşdeğer etiket çiftleri denklik sınıflarına ayrılarak her bir sınıf için tek bir etiket atanmaktadır. Son adım olarak görüntüdeki her bir etiketin eşdeğerlik sınıfına atandığı etiket ile yer değiştirildiği ikinci bir tarama gerçekleştirilmektedir. [8, 15]

Etiketleme işlemi sonucunda her bir nesnenin en/boy oranı dikkate alınarak analiz edilmektedir. nxm boyutunda bir giriş imgesi için w_i, ikili imgedeki i. etiketin genişliğini; h_i, ise yüksekliğini belirtmek üzere kullanılan aralıklar Eşitlik (2.18);

$$0{,}2 \leq \frac{w_i}{h_i} \leq 0{,}8 \tag{2.18}$$

ile verilmektedir. Bağlı bileşen analizi adımının çıkışı I_e imgesidir. Şekil 2.14(a)'da bağlı bileşen analizi sonuç imgesi gösterilmektedir.

2.4.3. Yatay izdüşüm ile karakter bölgesi kestirme

Tez çalışması kapsamında plaka tespit aşamasında yatay izdüşümden, karakter ayrıştırma aşamasında ise yatay ve dikey izdüşümlerden yararlanılmıştır. Bu nedenle yatay ve dikey izdüşüm kısaca anlatılacaktır.

2.4.3.1. İzdüşümler

İkili bir imgenin bir çizgi üzerindeki izdüşümü, bu çizgiyi parçalara ayırıp her bir parçadaki mantıksal 1 olan piksel sayısının hesaplanması ile elde edilebilmektedir. İzdüşüm alarak görüntü sıkıştırılmış bir forma sahip olmakta ve uygulamaya yönelik kullanılabilecek özellikler çıkartılan histogramlardan görülebilmektedir. Böylelikle verideki istenmeyen bölgeler kolaylıkla elenebilmektedir. Yatay ve dikey olmak üzere iki temel izdüşümden söz edilebilir.

Yatay izdüşüm; sayısal görüntüdeki her bir satır ikili görüntünün yatay bilgisini taşıyacaktır. Böylelikle dikey bir çizgi üzerinde her bir satırın toplamı, dik olduğu konuma atanarak oluşturulan sütun vektörü ikili görüntünün yatay izdüşümünü verecektir. n ve m, sırasıyla giriş görüntüsündeki satır ve sütun sayılarını; I_b, ikili imgeyi; P_h, yatay izdüşüm vektörünü belirtmek üzere yatay izdüşüm için genel bir ifade Eşitlik (2.19);

$$P_h(j) = \sum_{i=1}^{m} I_b(i,j) \tag{2.19}$$

ile verilebilmektedir [15]. Dikey izdüşüm; sayısal bir görüntünün her bir sütunu görüntünün dikey bilgisini içerir. Böylelikle yatay bir çizgi üzerinde her bir sütunun toplamını dik olduğu konuma atanarak oluşturulan satır vektörü ikili görüntünün dikey izdüşümünü verecektir.

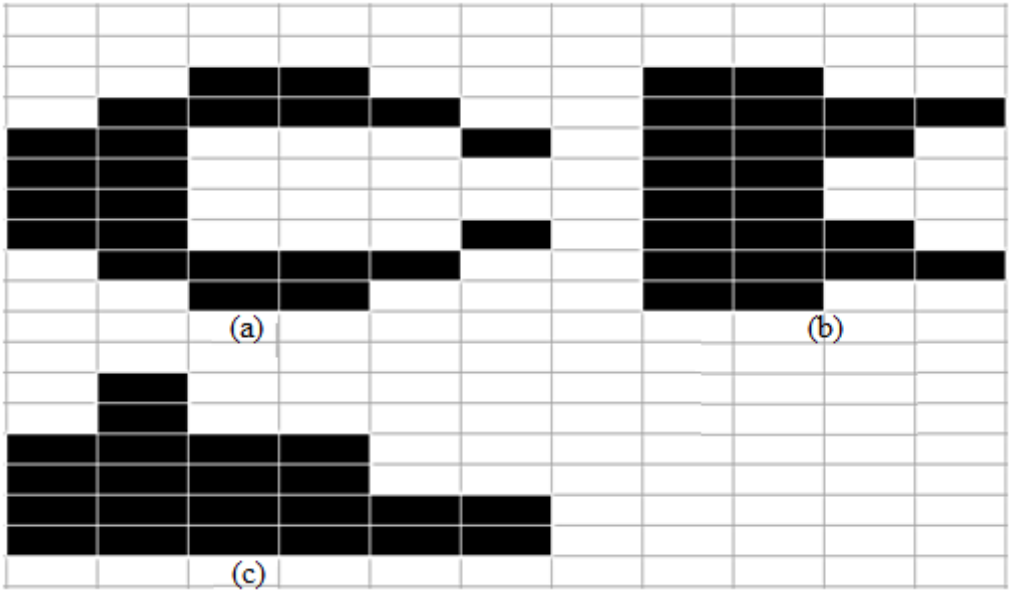
P_v, dikey izdüşüm vektörünü belirtmek üzere dikey izdüşüm için genel bir ifade Eşitlik (2.20);

$$P_v(i)=\sum_{j=1}^{n} I_b(i,j) \tag{2.20}$$

ile verilebilmektedir [15]. P_h, normalize edilmiş satır toplamlarını veren nx1 boyutlu sütun vektör olmak üzere satır toplamları Eşitlik (2.21);

$$P_h(i)=\frac{\sum_{j=0}^{m-1} I_e(i,j)}{m} \tag{2.21}$$

ile verilebilir. Şekil 2.13'de örnek bir harf örüntüsünün dikey ve yatay izdüşümü gösterilmektedir.



Şekil 2.13 (a) Örnek bir örüntü, (b) Örüntüye ait yatay izdüşüm histogramı, (c) Örüntüye ait dikey izdüşüm histogramı

Şekil 2.14'den görüldüğü gibi problem, bölge belirleme ve maksimum genliğe sahip bölgeyi korumaya indirgenmiştir. Bu aşamada CCA sonucunda elde edilen imgenin yatay izdüşüm vektörü üzerinden ayrık bölgeler tanımlanmaktadır. Ardından tanımlanan bölgeler arasından maksimum genliğe sahip olan bölgenin işaret ettiği satır indisleri, CCA sonuç imgesi içerisinden kestirilerek giriş imgesi ile aynı boyutlardaki Î imgesine taşınmaktadır. Ancak bazı Türk sivil araç plakalarında karakterlerin bir kısmı daha alt satırlarda olabilmektedir. Bu durum, birbirine yakın genliğe sahip ve yakın satır aralıklarında olan bölgelerin de dikkate alınmasını gerektirmektedir. Bu

nedenle Eşitlik 2.26'da görüldüğü gibi birbirine genlik ve uzaklık anlamında yakın olan iki bölge varsa her iki bölgenin işaret ettiği satır indisleri kullanılmaktadır. Aksi durumda karakterlerin tek bir bölgede bulunduğu düşünülmektedir. Eşitlik (2.22)'deki $C\{i_n\}$, her bir bölgenin satır indislerini saklayan kümeleri; M, her bir bölgenin maksimum değerini saklayan 1xk birim uzunluğundaki vektörü; Eşitlik (2.23)'deki $M^{-1}(max_1)$, M vektörünün maksimum değerini aldığı indisi, Eşitlik (2.24)'deki $M^{-1}(max_2)$, ikinci maksimum değeri aldığı indisi; Eşitlik (2.25)'daki idx_1 ve idx_2 ise bu indis değerlerinin işaret ettiği bölge indislerini taşıyan vektörleri;

$$M(i_n)=\max_{i_n} P_h\,(C\{i_n\}),\quad \{i_n: n=1, 2, \ldots,k-1, k\} \tag{2.22}$$

$$\text{argmax } M(i)=\{n|M(i_n=max_1)=:M^{-1}(max_1)\} \tag{2.23}$$

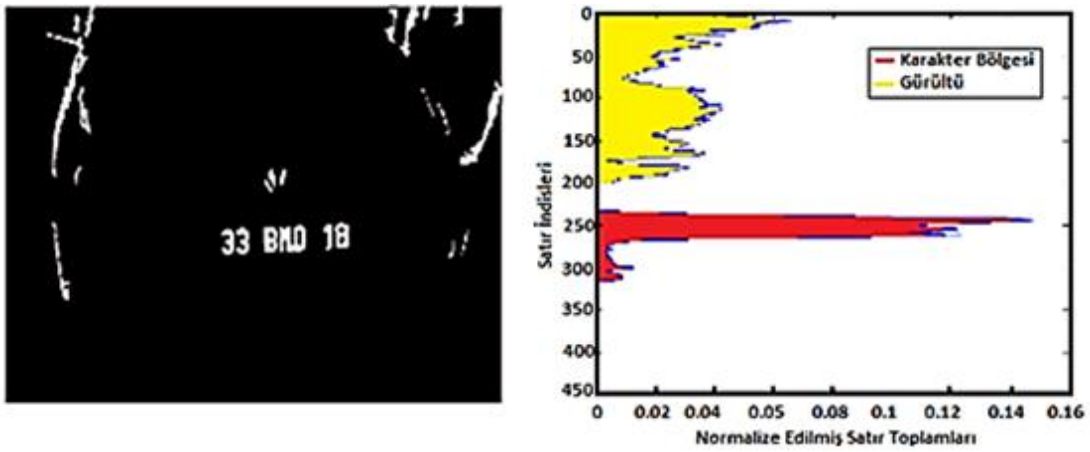
$$\text{argmax } M(i)=\{n|M(i_n=max_2)=:M^{-1}(max_2)\} \tag{2.24}$$

$$idx_1=C\{M^{-1}(max_1)\},\ idx_2=C\{M^{-1}(max_2)\} \tag{2.25}$$

$$\hat{I}=\begin{cases} I_e(idx_1:idx_2,\ 1:m), & |max_1\text{-}max_2|<A \ \ \& \\ & |idx_1(end)\text{-}idx_2(1)|<B \\ I_e(idx_1,1:m), & \text{diğer} \end{cases} \tag{2.26}$$

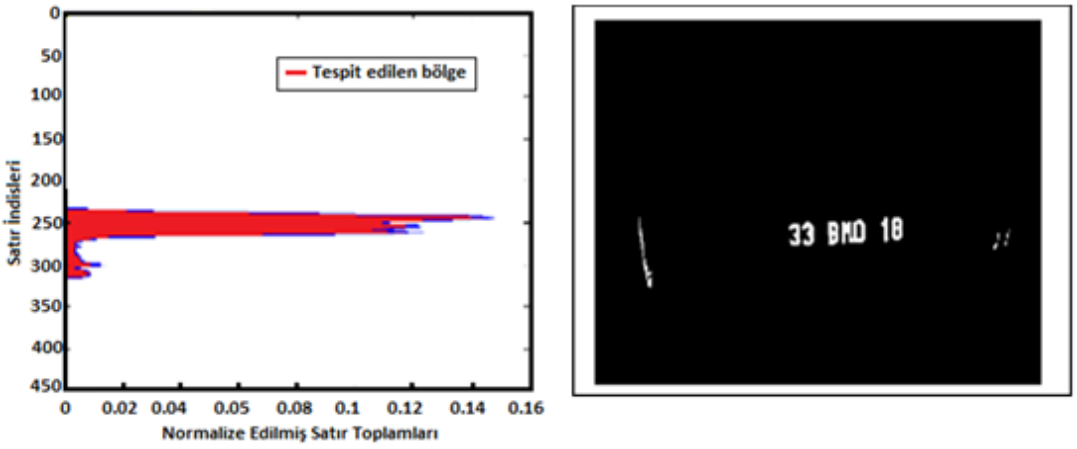
ifade etmektedir. Yapılan deneysel çalışmalarda A eşik değeri 0,017; B eşik değeri ise 10 olarak belirlenmiştir. Kestirilen satır aralıkları Şekil 2.15(b)'de gösterilmektedir. Bu aralık içerisindeki karakterler ise ardışık nesneler arasındaki yükseklik ve mesafe farkları yaklaşık olarak eşittir varsayımı ile bulunmaktadır. Bu aşamada her bir nesne etiketlenir.

Kestirilen satır aralıklarındaki karakter bölgesinin, kalan az sayıdaki gürültülü bölge arasından bulunması gerekmektedir. Türk sivil araç plakaları 7 veya 8 karakter olarak değişmektedir ve perspektif bozukluklarına da bağlı olarak karakter yükseklikleri hemen hemen eşittir kabul edilebilmektedir. Yapılacak aramada sadece yükseklik faktörünün düşünülmesi karakterlerle aynı yükseklikte bulunabilecek gürültü benzeri bölgelerin de dikkate alınması anlamına gelecektir. Kompakt yapıdaki karakter bölgesinin bulunabilmesi için karakter yakınlıkları da dikkate alınmalıdır. Bu nedenle kestirilen satır aralıklarındaki karakterlerin bulunmasında ardışık nesnelerin yükseklikleri ve Öklid uzaklıkları düşünülmüştür.



(a) (b)

Şekil 2.14. (a) Bağlı bileşen eleme adımı sonucu, (b) Yatay izdüşüm vektörü



(a) (b)

Şekil 2.15. (a) Yatay izdüşüm vektöründe tespit edilen karakter bölgesi, (b) Kestirilen satır aralıkları

Eşitlik (2.27)'deki L_i, i. etiketi; T_h ve T_x, eşik değerleri; d_h ve d_x, ardışık nesneler arasındaki eşiklenmiş yükseklik ve Öklid mesafesi farklarını içeren 1x(l-1) boyutlu vektörleri; $\hat{I}_c$ ise eşiklenmiş fark vektörlerinin mantıksal VE işlemi sonucunu ifade etmektedir. Şekil 2.15(b)'deki karakter adayları arasından karakterlerin tespiti Şekil 2.16'daki örnek çıkarımda gösterilmektedir. $\{L_i: i=1, 2,\ldots, l\}$, olmak üzere Eşitlik (2.27);

$$d_h=|d(h_i,h_{i+1})|<T_h;\ \ d_x=|d(L_i,L_{i+1})|<T_x;\ \ \hat{I}_c=AND(d_h,d_x) \qquad (2.27)$$

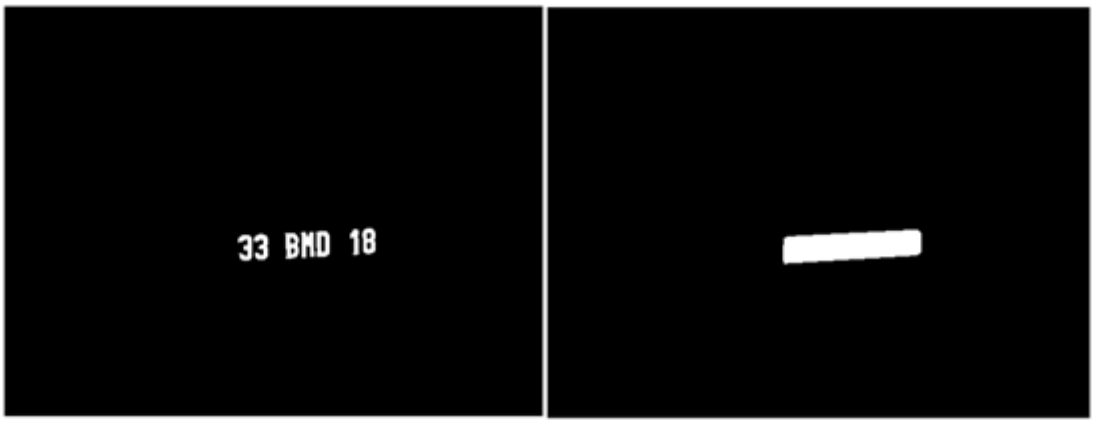
şeklinde verilmektedir. Şekil 2.16'daki h vektörü, etiketlenen 10 nesnenin yükseklik değerlerini göstermektedir. d_h, d_x ve $\hat{I}_c$ vektörlerinin uzunlukları, fark alma işlemleri

nedeniyle 1x9 boyutlu olmaktadır. $\hat{I}_c$ vektörü içerisinde mantıksal 1 olarak bulunan konumlara karşılık gelen etiket değerli nesneler karakter imgesine taşınmaktadır.

$$
\begin{array}{rl}
 & h=[84\ \ 27\ \ 27\ \ 27\ \ 27\ \ 27\ \ 27\ \ 27\ \ 20\ \ 28] \\
yük.\ farkları: & [\ 57\ \ 0\ \ 0\ \ 0\ \ 0\ \ 0\ \ 0\ \ 7\ \ 8\ ] < T_h \\
mesafe\ farkları: & [19.41\ \ 1.70\ \ 3.30\ \ 1.80\ \ 1.50\ \ 3.70\ \ 1.30\ \ 13.23\ \ 1.92] < T_x \\
AND & \begin{array}{l} d_h = [\ 0\ \ 1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 0\ \ 0] \\ d_x = [\ 0\ \ 1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 0\ \ 1] \end{array} \\
Etiket\ numarası: & 1\ \ 2\ \ 3\ \ 4\ \ 5\ \ 6\ \ 7\ \ 8\ \ 9 \\
\hat{I}_c = & [\ 0\ \ \boxed{1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 1\ \ 0}\ \ 0\ ]
\end{array}
$$

Şekil 2.16. Karakterlerin $\hat{I}_c$ vektöründen belirlenmesi

Karakter olan ve olmayan ardışık nesneler arasındaki farklar kurulan eşik değerlerinin üzerinde ise vektörde mantıksal 0 olacaktır. Bu nedenle $\hat{I}_c$ vektöründe son mantıksal 1 değerinden sonra gelen ilk mantıksal 0 konumuna karşılık gelen etiket değerli nesne de karakter imgesine taşınmaktadır. Bu sonlandırma durumu oluşturur. Ardından bulunan karakter adaylarına, bir dışbükey gövde (convex hull) algoritması ile tek bir dışbükey gövde biçimi verilerek plaka bölgesi elde edilmektedir. Şekil 2.17(a)'da kestirilen karakterler, Şekil 2.17(b)'de bulunan plaka bölgesi, 2.17(c)'de ise çıkartılan plaka gösterilmektedir.



(a) (b)

Şekil 2.17. (a) Kestirim sonucu, (b) Bölge birleştirme ile bulunan plaka bölgesi

2.4.4. Plaka bölgesinin yatayla paralel hale getirilmesi (Geometrik düzeltme)

Giriş imgesinden çıkartılacak plaka bölgesi genellikle bazı geometrik bozukluklar içermektedir. Bulunan plaka bölgesi, her zaman düzlem ile paralel olmayabilir. Düzleme paralel olmayan görüntüden, karakterleri ayrıştırma işleminin başarısı önemli ölçüde azalacaktır. Bu nedenle bulunan plaka bölgesinin yatayla yaptığı α açı değeri tespit edilmiştir.

2.4.4.1. Yöntem

Plaka bölgesinin yatay ile yaptığı açının tespiti için bölge birleştirme sonucunda bulunan bölgenin elipsi çıkartılmıştır. Elipsin büyük ekseni ve yatay eksen arasında kalan açı değeri rotasyon açısını verecektir. Bu nedenle çıkartılan elipsin büyük ekseni ve yatay eksen arasındaki α açı değeri, Shear dönüşümü matrisinde kullanılarak plaka bölgesi yatay eksen ile paralel hale getirilmektedir. Şekil 2.18(a), Şekil 2.17(b)'de bulunan plaka bölgesinin elipsi ile elipsin büyük ve küçük eksenlerini göstermektedir.

Tez çalışması kapsamında plaka tanıma sürecinde yararlanılan afin dönüşümüne ait bazı geometrik dönüşümler Tablo 2.4'de gösterilmiştir.

Tablo 2.4. Geometrik dönüşümler [8]

AFİN DÖNÜŞÜMÜ	ÖRNEK	DÖNÜŞÜM MATRİSİ	
Ölçekleme		$\begin{bmatrix} c_x & 0 & 0 \\ 0 & c_y & 0 \\ 0 & 0 & 1 \end{bmatrix}$	c_x; x ekseni boyunca ölçekleme değeri. c_y; y ekseni boyunca ölçekleme değeri.
Shear		$\begin{bmatrix} 1 & s_h & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$	S_h; x ekseni boyunca Shear değeri. $S_h = \tan\alpha$

MATLAB ortamında yapılan deneylerde Şekil 2.18(a)'da sunulan örnek için rotasyon açısı α= 3,10°; büyük eksen uzunluğu 171,035; küçük eksen uzunluğu ise 36,01 olarak bulunmuştur.



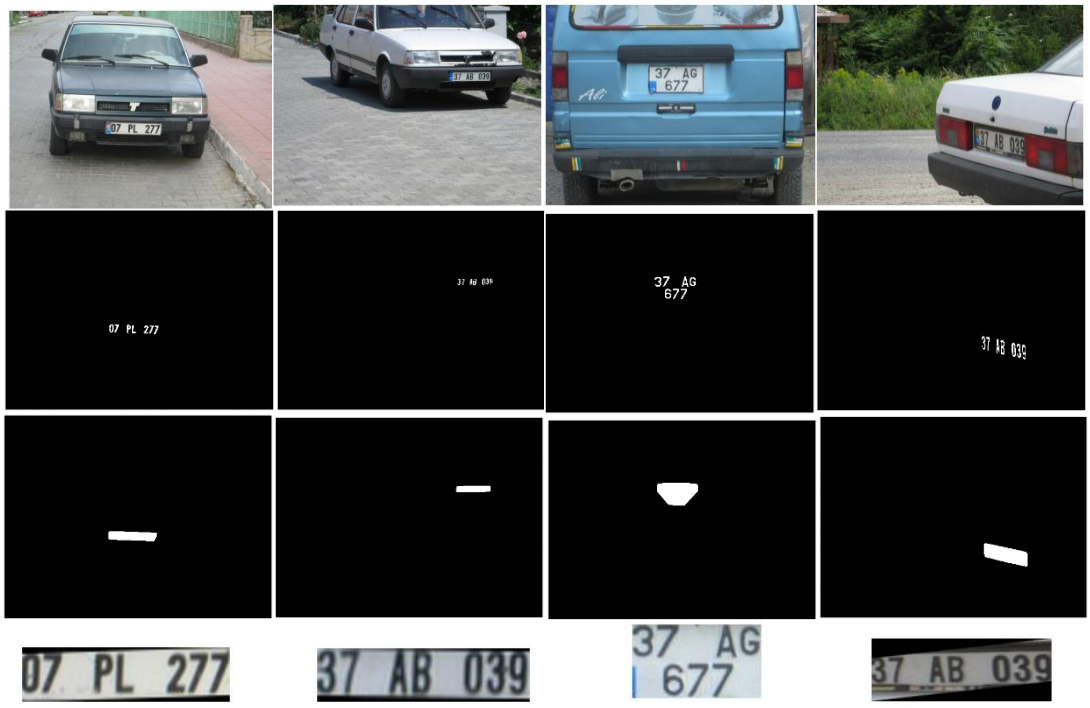
(a) (b) (c)

Şekil 2.18. (a) Elipsin büyük ekseni ve yatay eksen arasındaki α açısının tespiti: mavi sürekli çizgi elipsin büyük eksenini, yeşil sürekli çizgi elipsin küçük eksenini, mavi kesikli çizgi yatay eksen paralelini göstermektedir, (b) Çıkartılan plaka bölgesi, (c) Bulunan α açısının Shear dönüşümü matrisinde kullanılarak yatay ile paralel hale getirilen araç plakası

2.5. Deneysel Sonuçlar

Çalışılan sistem özellikleri; Intel(R) Core(TM) i5-3470 CPU @ 3,20 Ghz 4GB RAM, çalışılan imge boyutları ise 432x576'dır. Algoritma MATLAB yazılım ortamında koşturulmuştur. Şekil 2.19(a) için [26]'da önerilen yöntem tespit yapamazken, [27]'de önerilen ve geliştirilen yöntem tespit yapabilmektedir. Plaka ve kamera arası mesafenin arttığı Şekil 2.19(b) için [26] ve [27]'de önerilen yöntemler tespit yapamazken, geliştirilen yöntem tespit yapabilmektedir. Plaka boyutunun farklı olduğu Şekil 2.19(c)'de [26]'da önerilen yöntem tespit yapabilirken, [27]'de önerilen yöntem tespit yapamamaktadır. Karmaşık arka plan ve görüş açısının olduğu Şekil 2.19(d)'de incelenen ve geliştirilen çalışmaların her biri tespit yapabilmektedir.

Şekil 2.20(a) ve 2.20(c)'deki durumlarda plaka arka planı ve karakterler arasındaki kontrast önemli derecede azaldığından eşikleme sonucunda karakter bölgeleri tespit dışında kalmaktadır. Şekil 2.20(b)'deki gibi deforme olmuş plakalar eşikleme adımı sonucunda eksik ya da parçalanmış karakterler meydana getirmektedirler. Şekil 2.20(d)'deki gibi aşırı boyanmış karakterler ise eşikleme sonrasında gelen bağlı bileşen eleme adımında karakterlere ait beklenen istatistiksel özellikleri karşılamadıkları için kaybedilmektedir.



(a) (b) (c) (d)

Şekil 2.19. Örnek tespit sonuçları



(a) (b)

(c) (d)

Şekil 2.20. Plaka tespitinin yapılamadığı durumlar (Yanlış negatifler), (a) Plaka üzerindeki aşırı kir, (b) Deforme olmuş plaka, (c) Karakter boyası silikliği, (d) Aşırı boyanmış karakterler

Bir OPT sistemi araç plakası içeren görüntülerde doğru tespit yapabilirken, araç plakası içermeyen görüntülerde tespit yapmamalıdır. Diğer bir ifadeyle yüksek doğru tespit oranı (TPR) karşısında yanlış alarm oranı (FPR) olabildiğince düşük tutulmalıdır. Alıcı işletim karakteristik (ROC) eğrileri her iki bilgiyi bünyesinde barındırarak farklı eşik değerler için elde edilen TPR karşısında FPR ile çizilmektedir. Eğri altında kalan alan (AUC) ise yöntem başarımını ortaya koymaktadır. [28-30]

$$\text{TPR=Duyarlılık=}\frac{\text{TP}}{\text{TP+FN}} \tag{2.28}$$

$$\text{FPR=1-Özgüllük=1-}\frac{\text{TN}}{\text{FP+TN}} \tag{2.29}$$

Tablo 2.5. TPR ve FPR oranlarının elde edilmesinde yararlanılan değişkenler

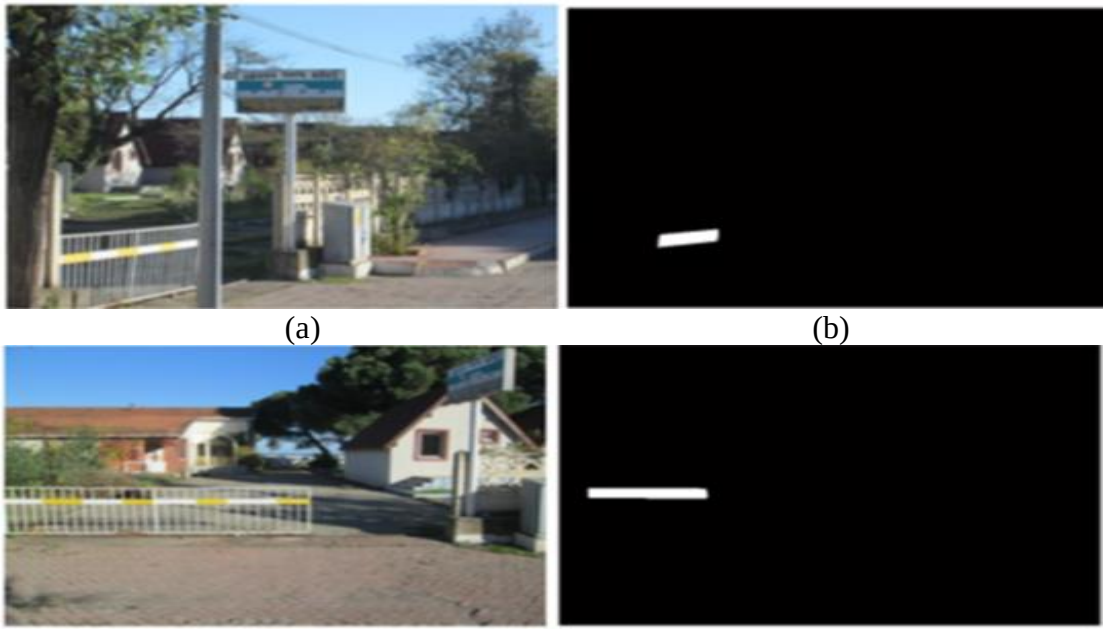
OPTS Başarımı		Gerçekler	
		Plaka (+) 324	Plaka (-) 90
Tahminler	Tespit (+)	Doğru pozitifler (TP)	Yanlış pozitifler (FP)
	Tespit (-)	Yanlış negatifler(FN)	Doğru negatifler (TN)

Eşitlik (2.28)'de verilen doğru pozitif oranı (TPR) ya da duyarlılık, önerilen yöntemin plaka içeren araç imgelerinden plaka bölgesini bulabilme yeteneğini; Eşitlik (2.29)'daki özgüllük ise önerilen yöntemin plaka içermeyen imgelerde bölge bulmama yeteneğini vermektedir. Eşitlik (2.29)'dan anlaşılabileceği gibi yüksek özgüllük değeri, düşük yanlış alarm oranı verecektir. Toplam tespit başarımı (doğruluk) ise Eşitlik (2.30) ile verilmektedir. ROC eğrisi altında kalan alana bakmak doğruluk değerinin kestirimini sağlayabilmektedir. [28-30]

$$\text{Doğruluk=}\frac{\text{TP+TN}}{\text{TP+FP+FN+TN}} \tag{2.30}$$

Bu nedenle karakterlerden plaka bölgesini bulan [26] ve [27] çalışmaları ile hibrit bir tespit yöntemi olan [52] çalışması incelenmiş, ROC eğrileri çıkartılarak tespit başarımları karşılaştırılmıştır. Veri tabanına günün çeşitli saatlerinde çekilmiş, karmaşık arka plan, değişen araç, kamera arası mesafesi, görüş açısı içeren 324 imge;

yanlış alarmları belirleyebilmek için 90 manzara imgesi, tespit sonuçlarını doğrulayabilmek için de 324 yer doğrusu oluşturulmuştur. Tespit sonuçları ve yer doğrusu arasındaki tutarlılığı belirlemede ise ilinti katsayısından yararlanılmıştır. ROC eğrilerinin çıkartılmasında ilinti katsayısının 0-1 arasındaki değerleri eşik olarak kullanılmıştır. Böylece her bir yöntem tarafından bulunan bölgelerin doğrulanması amaç edilmektedir. Şekil 2.21'de önerilen yöntemin örnek yanlış alarmları verilmektedir. Şekil 2.22, tez çalışmasında incelenen ve önerilen yöntemlere ait kestirim sonuçlarının yer doğrusu ile ilintisine göre belirlenen tespit durumunu göstermektedir. Şekil 2.23'de ise tez çalışmasında incelenen ve önerilen yöntemlerin ROC eğrileri karşılaştırılmaktadır.

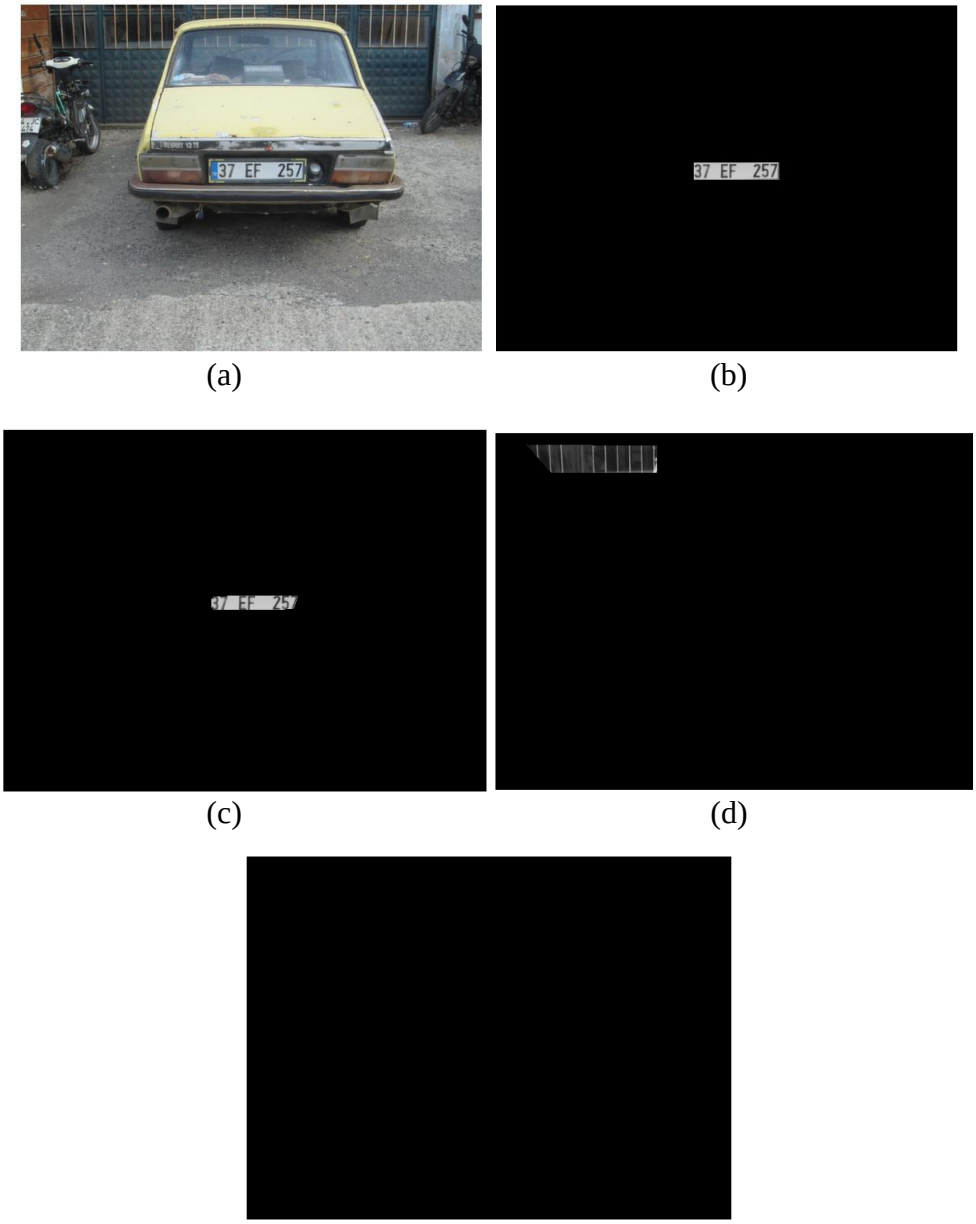


(a) (b)

(c) (d)

Şekil 2.21. Plaka tespit biriminin yanlış alarm (yanlış pozitif) oluşturduğu durumlar

Önerilen yöntem karşısında [26]'de önerilen yöntemin Tablo 2.6'da görülen düşük tespit başarımının sebebi, araç ve kamera arasındaki mesafe artışına bağlı olarak orijinal çalışmada da belirtildiği gibi karakter aralıklarının daralması ve CCA adımlarında karakter adaylarının kaybedilmesidir. Önerilen yöntem karşısında [27]'de önerilen yöntemin düşük tespit başarımının sebebi, bu çalışmada kullanılan Hough dönüşümünün özellikle karmaşık arka plan içeren imgelerde farklı doğrular bulmasıdır. Şekil 2.24'de her bir yönteme ilişkin zamansal tüketim eğrileri, Tablo 2.7'de ise bu eğrilerden elde edilen değişintiler ve ortalama tespit zamanları verilmektedir.



(a) (b)

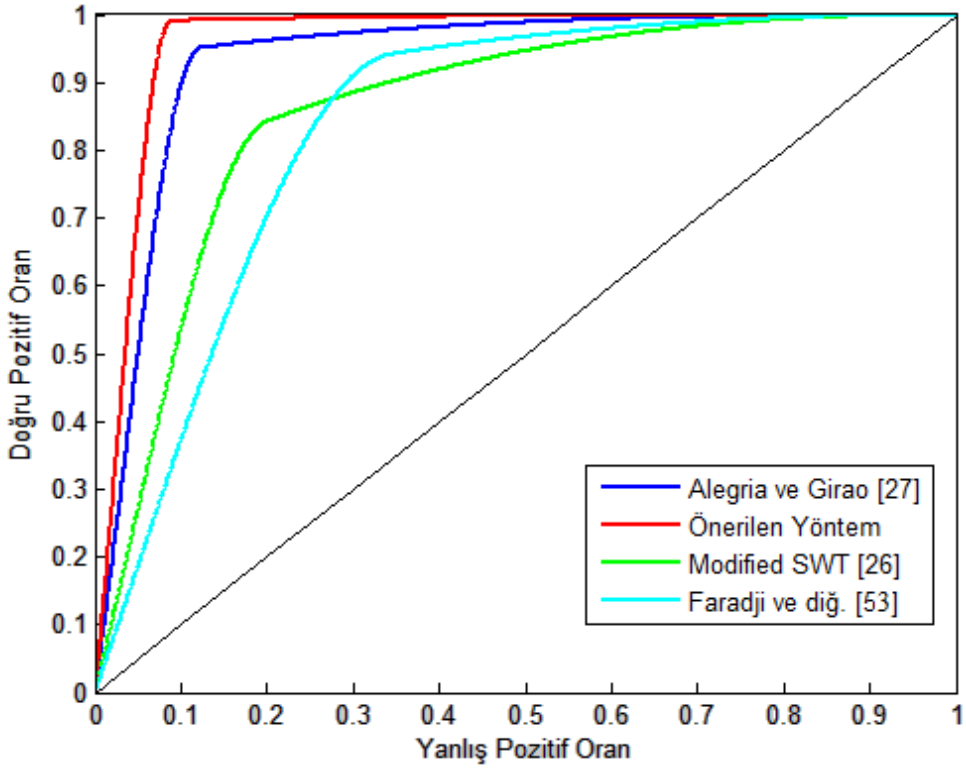
(c) (d)

(e)

Şekil 2.22. (a) Giriş imgesi, (b) Yer doğrusu, (c) Önerilen yöntem için kestirim sonucu, (d) Modified SWT [26] çalışması için kestirim sonucu, (e) Alegria ve Girao [27] çalışması için kestirim sonucu

Tablo 2.6. T=0,5 için doğru tespit, yanlış alarm oranları, tespit başarımları (AUC), 324 imge için ortalama tespit zamanı

Yöntemler	**TPR**	**FPR**	**AUC**
Modified SWT [26]	0,84	0,20	0,82
Alegria ve Girao [27]	0,95	0,12	0,91
Faradji ve diğ. [52]	0,94	0,34	0,80
Önerilen yöntem	0,99	0,08	0,96



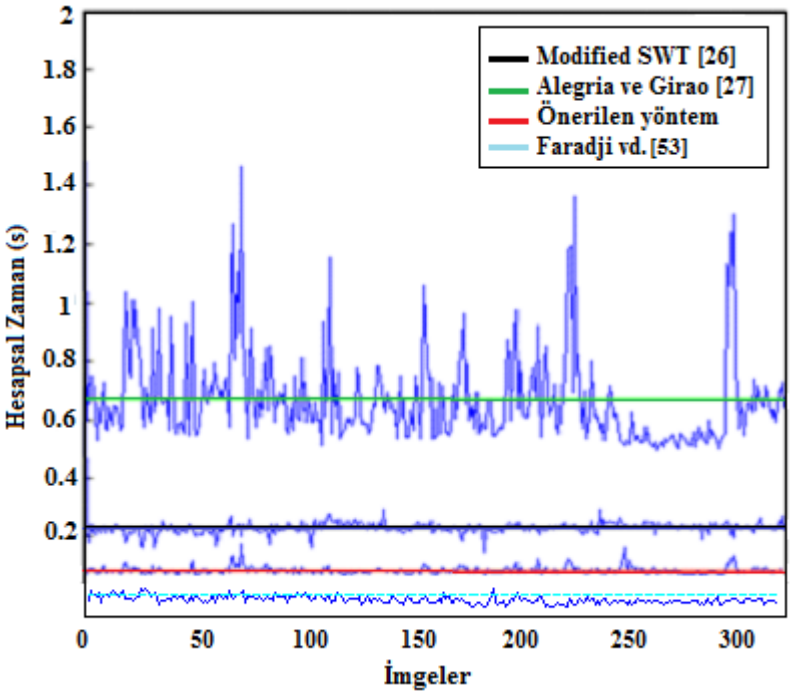
Şekil 2.23. Performans karşılaştırma için ROC eğrileri

Tablo 2.7. 324 imge için ortalama tespit zamanı

	Yöntemler			
	Modified SWT [26]	**Alegria ve Girao [27]**	**Faradji ve diğ. [52]**	**Önerilen Yöntem**
Ortalama CPU Zamanı (ms)	657	226	67	84
Değişinti (10^{-3})	22,7	0,39	4	0,14

Önerilen yöntem karşısında [26]'daki yöntemin Tablo 2.7'de görülen yüksek hesapsal zamanının sebebi, bu çalışmada dört ayrı kenar imgesinin her biri için başlangıç ve bitiş koşullarının blok temelli taramalar ile aranarak ışın bağlanması ve morfolojik imge işleme yöntemlerinin kullanılmasıdır.

[27]'deki çalışmada ise hesapsal yükü ağır olan Hough dönüşümü iki kez kullanılmaktadır. Önerilen yöntemde plaka bölgesi, tespit adımının işlem yükünü azaltan bir ön işleme adımı sonrasında yalnızca $n \times 1$ boyutlu sütun vektör ve $\hat{I}_c$ vektörü içerisinde aranmaktadır.



Şekil 2.24. Zamansal tüketim eğrilerinin karşılaştırılması

2.6. Sonuç

İmge işleme sırasında harcanan süre miktarı oldukça önemlidir. Plaka tanıma işleminin gerçek zamanlı video üzerinden yapıldığı düşünülecek olursa, saniyede 25 tane işlenebilecek imge yakalanacaktır.

Pratik bir senaryo olarak iki aracın kamera yönünde ve 60 kms^{-1}=16,67ms^{-1} hızda hareket ettiğini, aralarındaki mesafenin de 5 metre olduğunu varsayalım. Bu hızlarda hareket eden araç plakalarının tespit edilebilmesi için geliştirilecek OPTS'nin giriş imgesini 5m/16,67ms^{-1}=0,3 saniyede işleyebilmesi gerekmektedir. Araçların aralarındaki mesafe değişmeksizin, 90 kms^{-1} hızla hareket ettikleri düşünüldüğünde ise işleme süresi 0,2 s olacaktır. Araç hızlarının 90 kms^{-1}, aralarındaki mesafenin de 2,5 metre olduğu düşünüldüğünde ise işleme süresi 0,1 s olacaktır. Yapılan çalışmada 3.20 GHz Intel(R) Core(TM) i5-3470 işlemcili bir bilgisayarda 432x576 boyutlu bir imgeyi işleme süresi ortalama 84 ms sürmektedir. Bu durum, önerilen tespit yönteminin düşünülen senaryolarda başarılı olabileceğini göstermektedir. Böylelikle geliştirilen sistem; hareket halindeki trafiği izleyen bir video kameranın bulunduğu MOBESE (Mobil Elektronik Sistem Entegrasyonu) gibi sistemlerde kırmızı ışık ihlali, çalıntı araç takibi gibi hızın gerektiği birçok popüler uygulamada kullanılabilir.

Söz edilmesi gereken bir diğer konu, yakalanan imgelerin kalitesi daha yüksek olursa başarı oranının çok daha yüksek olacağıdır. İyi bir imge kalitesi, uygun bir yakalama cihazının seçimiyle doğrudan ilişkilidir. Kamera parametreleri sistem tarafından tespit edilebilecek en küçük boyutlardaki plakaya doğrudan etki etmektedir. Bu durum OPTS algoritmasının ayırt etme yeteneğini ortaya koymaktadır.

3. KARAKTER AYRIŞTIRMA VE TANIMA

3.1. Giriş

Plaka tanımanın bu aşamasında, ayrıştırılan karakterler oluşturulan OCR yapılarına beslenerek tanınmaktadır. OPT sistemlerinin karakter tanıma aşaması;
-Kamera yakınlaştırma faktörü,
-Plaka karakterlerinin yazı tipi (font),
-Ayrıştırılan karakterlerin gürültü içermesi ve/veya parçalanmış olması,
-Ayrıştırılan karakterlerin eğikliği,
-Bazı karakterlerin benzer örüntüleri (B-8, O-0, I-1, A-4, Z-2, S-5 vs.)
gibi nedenlerden dolayı bazı zorluklar içermektedir. Belirtilen sorunlar sınıflandırma hatalarına neden olarak yanlış tanımalar oluşturabilmektedir.

3.2. Karakter Ayrıştırma

Plaka bölgesi bulunmasının ardından, karakterlerin ayrıştırılarak tanıma işlemine hazır hale getirilmesi gerekmektedir. Bir önceki aşamada çıkartılan plaka bölgesi üzerinde eşit dağılmamış parlaklık ve benzeri birçok sorun içerebilmektedir. Plakaya ait karakterleri/rakamları karakter tanımlamada yüksek başarım verecek şekilde ayrıştırmak gerekmektedir.

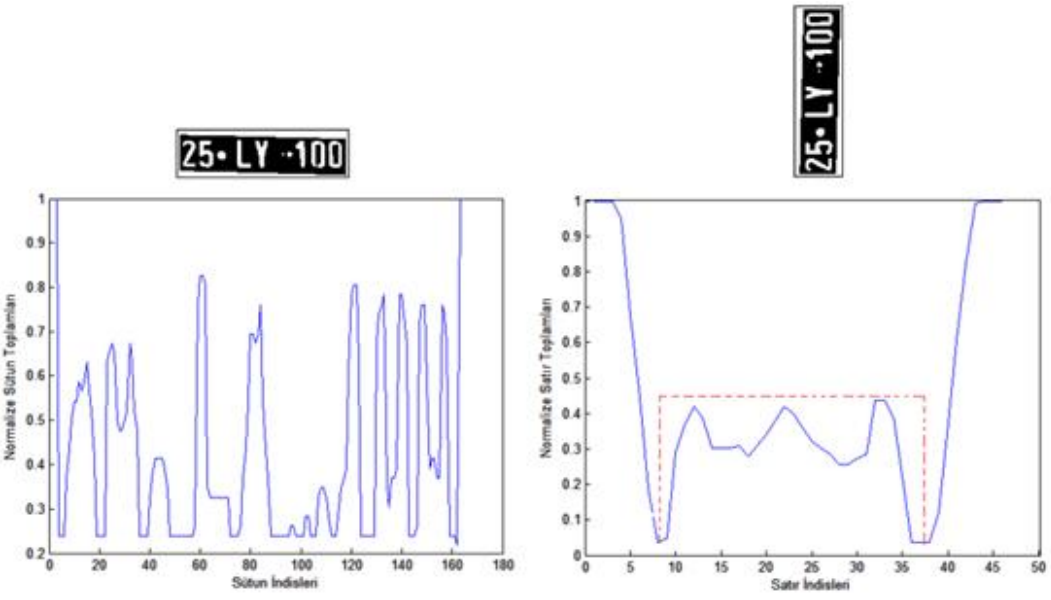
3.2.1. Literatür inceleme

Çıkartılan plakanın uygun olmayan bir eşik değer ile eşiklenmesi birleşmiş karakter problemi ile sonuçlanabilir. Bu tür bir problem karakter ayrıştırma aşamasını zorlaştırmaktadır. Karakter ayrıştırmayı zorlaştıran bir diğer problem de eşikleme sonrasında oluşan plaka çerçevesidir. Ayrıca bazı karakterler bu çerçeve ile birleşmiş de olabilmektedir. Eşikleme öncesinde imge kalitesini arttırmak uygun eşik değerinin belirlenmesine katkıda bulunabilir. Gürültü giderme, histogram eşitleme, kontrast iyileştirme gibi teknikler bu amaçla literatürde yaygın olarak kullanılmıştır. [32]'de

gürültüyü azaltan ve yalnızca karakter bölgelerini iyileştiren bir yöntem önerilmiştir. [33, 34]'de ikili haldeki plaka imgesindeki bağlı pikseller tespit edilerek etiketlenmiştir. Ardından aynı en/boy oranı ve boyuttaki etiketler karakter olarak düşünülmüştür. [35]'de eşikleme sonrasında plaka imgesinin dikey izdüşümü elde edilerek karakterlerin başlangıç ve bitiş noktaları tespit edilmiştir. Ardından yatay izdüşümü elde edilerek yalnızca bir karakterin çıkartılabilmesi sağlanmıştır.

3.2.2. Önerilen yöntem

Geometrik düzeltme işlemi ile yatay hale getirilen plaka imgesi gri seviyeye dönüştürüldükten sonra Sauvola yerel eşikleme yöntemi kullanılarak ikili görüntü elde edilir. Böylece arka plan siyah ve karakterler beyaz olarak ayrıştırılmış olur. Plaka çerçevesinin çıkarılması ve sadece karakter bilgisinin kalması için yatay ve dikey izdüşümden faydalanılmıştır. Şekil 3.1'de örnek bir plaka imgesinin yatay ve dikey izdüşüm eğrileri gösterilmektedir.



(a) (b)

Şekil 3.1. Örnek plakaya ait İzdüşüm eğrileri: (a) Dikey izdüşüm, (b) Yatay izdüşüm

3.2.2.1. Plaka çerçevesinin çıkarılması

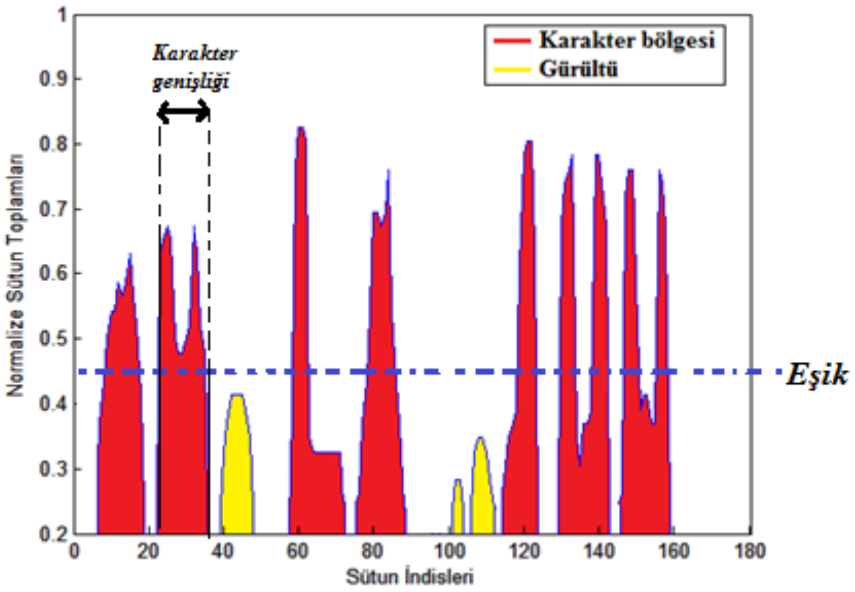
Sekil 3.1(b)'deki yatay izdüşümden görüldüğü gibi yatay düzleme paralel olduğundan iki minimum değer arasında kalan kısım plaka karakterlerini içereceğinden diğer

kısımlar silinir. Böylelikle plaka bölgesinden, plaka çerçevesi ayrıştırılarak Sekil 3.2'de görülen plaka karakter adayları elde edilmektedir.



Şekil 3.2. Çerçevesi temizlenmiş plaka imgesi

3.2.2.2. Gürültülü bölgelerin elenmesi



Şekil 3.3. Çerçevesi temizlenmiş plakaya ait dikey izdüşüm eğrisi

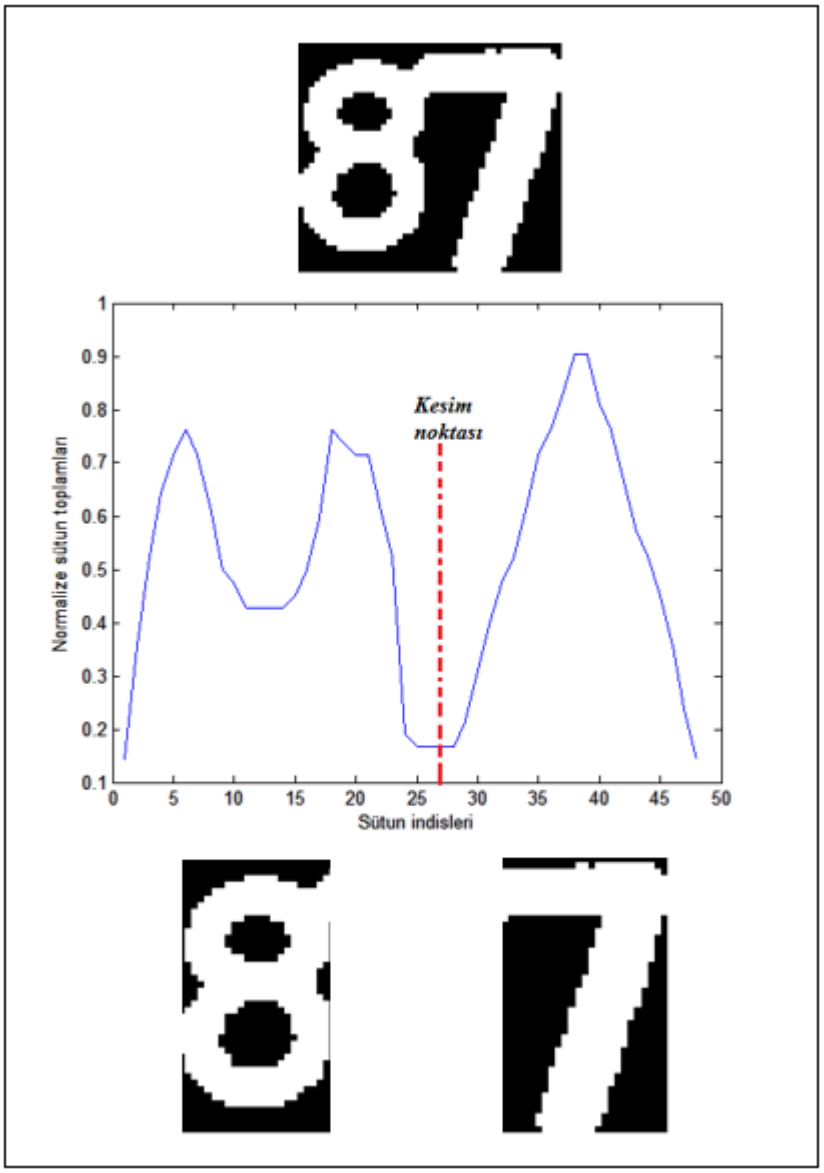
Bu aşamada ayrık bölgeler belirlenmiştir. Ardından her bir bölgenin maksimum değeri ve karakter genişlikleri dikkate alınmıştır. Eğer bölgenin maksimum değeri ve karakter genişliği önceden belirlenen eşik değerden küçük ise ilgili bölge gürültü kabul edilerek temizlenmiştir. Şekil 3.3, Şekil 3.2'de gösterilen çerçevesi temizlenmiş plakaya ait dikey izdüşüm eğrisini göstermektedir. Şekil 3.4'de gürültü temizlenmiş plaka imgesi gösterilmiştir.



Şekil 3.4. Gürültü temizlenmiş plaka imgesi

3.2.2.3. Birleşmiş karakterlerin ayrıştırılması

Eğer çıkartılan bölgenin en/boy oranı 0,8'den büyükse bölgedeki karakterlerin birleştiği düşünülmektedir. Böyle bir durum ile karşılaşıldığında dikey izdüşümden faydalanılarak birleşmenin minimum noktası tespit edilerek ayrıştırma işlemi yapılmaktadır.



Şekil 3.5. Karakter ayrıştırma süreci

Türk sivil araç plakaları 7 veya 8 karakterden oluşmaktadır. Karakter ayrıştırma süreci sonunda ayrıştırılan karakterlerin sayısı kontrol edilerek karakter tanıma (sınıflandırma) birimine gönderilmektedir. Şekil 3.5'de örnek bir karakter ayrıştırma süreci gösterilmektedir.

3.3. Karakter Tanıma

3.3.1. Literatür inceleme

3.3.1.1. Ham veri ile karakter tanıma

Ham veriden yararlanarak karakter tanıyan yöntemler, doğrudan piksel değerlerinden yararlanmaktadır. Şablon eşleme, karakter tanıma için yararlanılan böyle yöntemlerden biridir. Bu yöntemde önceden depolanmış karakter şablonlarının ayrıştırılan karakterler ile olan benzerliklerine bakılarak sınıflandırma yapılmaktadır. Sıklıkla yararlanılan benzerlik ölçüm teknikleri; normalize edilmiş çapraz ilinti, Mahalanobis mesafesi, Bayes karar tekniği, Jaccard değeri, Hausdorff mesafesi ve Hamming mesafesidir.

[36]'da ayrıştırılan karakterler ve şablonlar arasındaki benzerliği belirlemede normalize edilmiş çapraz ilinti kullanılmıştır. [33, 34, 37]'de şablon eşleme ile karakter tanıma gerçekleştirilmiştir.

Ayrıştırılan karakterler tek bir yazı tipine sahip, parçalanmamış, eğik olmayan ve sabit boyutlu ise, şablon eşleme ile karakter tanıma başarılı sonuçlar verebilmektedir. Ayrıştırılan karakterler belirtilen durumların herhangi biri nedeniyle önceden depolanan şablondan önemli derecede farklı ise başarısız tanımalar gerçekleşmektedir. Belirtilen problemler her bir karakter için birkaç şablon oluşturularak nispeten çözülebilmektedir.

[38]'de eğik karakterlerin tanınabilmesi problemi aynı karakterin farklı eğikliklere sahip formları oluşturularak çözülmeye çalışılmıştır.

Şablon eşleme yöntemi ile karakter tanıma basit ve anlaşılırdır, ancak her biri aynı ayırt ediciliğe sahip olmayan piksellerin de işlenmesi sınıflama sürecini yavaşlatmaktadır. Ayrıca herhangi bir yazı tipi, eğiklik, karakter kalınlığı değişimine karşı oldukça hassastır.

3.3.1.2. Özellik çıkartımı ile karakter tanıma

Karakteri oluşturan tüm pikseller aynı ayırt edicilik derecesine sahip olmadığından her bir pikselin işlenmesi hesapsal zamanı arttırmaktadır. Karakter tanıma sürecinde bir özellik çıkartım tekniğinden faydalanarak karakterlerin ayırt edici özelliklerinin

çıkartılması ve işlenmesi hesapsal zamanı düşürmesinin yanı sıra gürültü, eğiklik, karakter kalınlığı, yazıtipi gibi problemler altında oldukça hassas olan şablon eşleme tekniği karşısında başarılı sonuçlar üretebilmektedir. Bu yöntemde karakterlerden çıkartılan ilginç özellikler ile özellik vektörleri oluşturulmaktadır. Oluşturulan özellik vektörlerinin ayrıştırılan karakterler ile olan benzerlikleri ölçülerek sınıflandırma gerçekleştirilmektedir.

Literatürde özellik vektörlerinin elde edilmesinde yararlanılan pek çok yöntem bulunmaktadır. Özellik vektörleri, [39, 40]'de ikili karakterlerin yatay ve dikey izdüşümlerinden yararlanılarak oluşturulmuştur. [41]'de her bir karakterin Hotelling dönüşümünden yararlanılarak özellik vektörleri oluşturulmuştur. [42]'de ikili karakterler 3x3'lük bloklara bölünmüştür. Ardından her bir blok içindeki siyah pikseller sayılarak özellik vektörü oluşturulmuştur. [43]'de bir karakter inceltme operasyonu sonrasında her bir karakter 3x3'lük bloklara bölünmüş ve 0°, 45°, 90°, 135° eğime sahip bileşenler sayılarak özellik vektörleri elde edilmiştir. [44]'de Gabor filtresi özellik çıkartımı amacıyla kullanılmıştır. Kenar tespit yöntemleri de özellik çıkartımı amacıyla kullanılmıştır. [45]'de karakter imgesi üzerinde farklı yönlerde Kisch kenar operatörü uygulanarak özellik çıkartımı gerçekleştirilmiştir.

Özellik çıkartımı sonrasında çıkartılan özellikleri uygun sınıflara ayırabilmek için çok sayıda sınıflandırma yöntemi mevcuttur. Yapay Sinir Ağları [47], Destek Vektör Makineleri [48], Saklı Markov Modelleri [49] bunlardan en bilindik olanlarıdır. Bazı araştırmacılar iki çeşit sınıflandırma yöntemini bütünleştirmişlerdir.

3.3.2. Önerilen yöntem

3.3.2.1. Eğitim kümesi belirleme

Yapılan çalışmada ICDAR (International Conference on Document Analysis and Recognition) 2003 [50] karakter veri tabanından faydalanılmıştır. Burada eğitim (6185), test (5430) ve örnek (854) karakter veri setleri olmak üzere toplam 12469 karakter vardır. Şekil 3.6'da ICDAR 2003 [50] veri tabanından örnek bir görünüm sunulmuştur. SVHN, ETL, MNIST gibi birçok karakter veri tabanı da vardır. Ancak bunların çoğu el yazısı ile yazılan rakamları (Handwritten Digit Recognition) tanıma problem durumu için hazırlanmıştır.

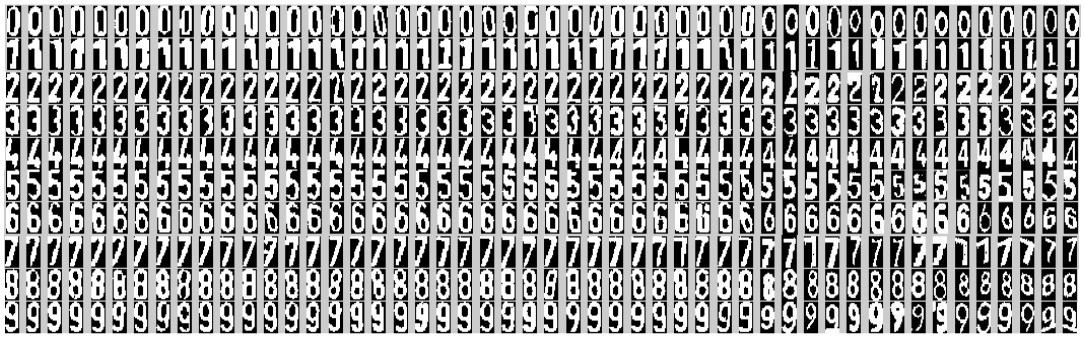


Şekil 3.6. ICDAR 2003 karakter veri tabanından örnek bir görünüm

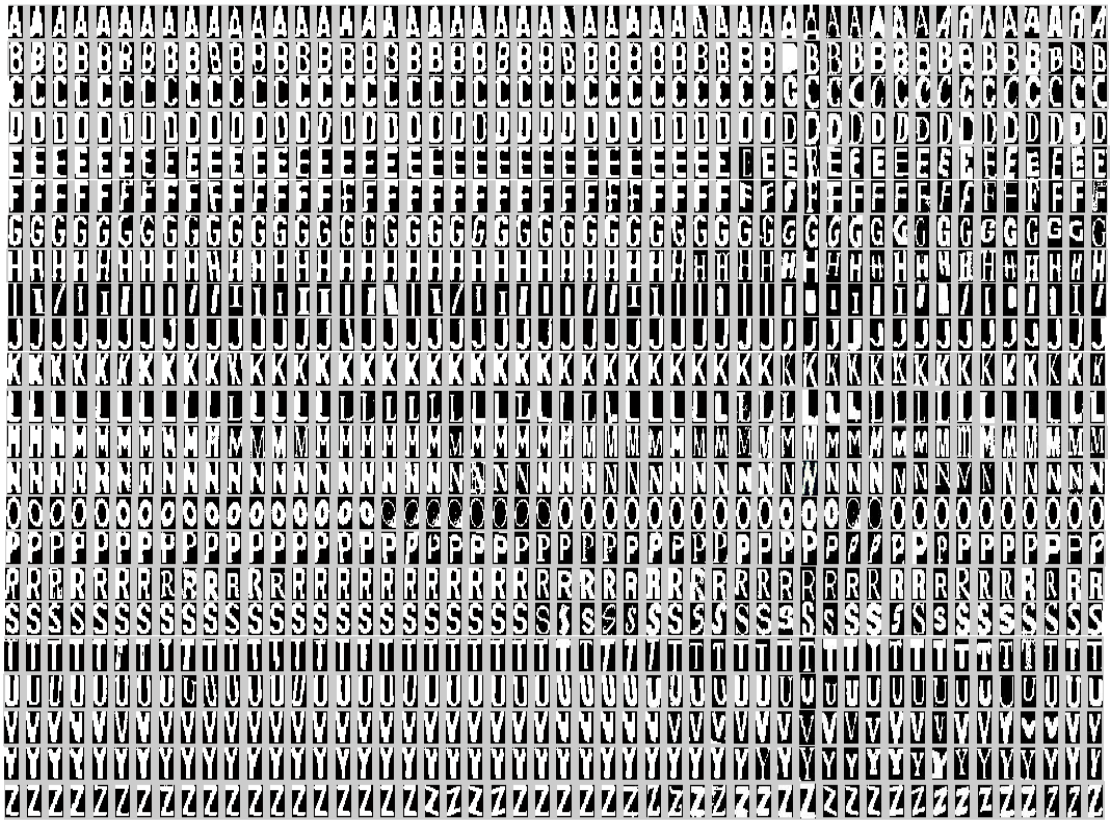
Şekil 3.6'dan görüldüğü gibi ICDAR 2003 [50] karakter veri tabanı küçük, büyük harf ve rakamlardan oluşmaktadır. Veri tabanındaki örnekler farklı yazı tiplerinde, ölçeklerde, renklerde, eğimlerde verilmektedir. Türk sivil araç plakaları küçük harf ve 'W, Q, X' gibi karakterler içermemektedir. Bu nedenle ICDAR 2003 veri tabanından, her bir karakterin problem durumuna uygun 50 farklı versiyonu seçilerek 42 satır 24 sütuna normalize edilmiş ve ikili haldeki derlenmiş yeni eğitim kümesi oluşturulmuştur. Yeni eğitim kümesi Şekil 3.8 ve 3.9'da verilmektedir.



Şekil 3.7. Türk sivil plakalarında kullanılan 33 kusursuz karakter sınıfı



Şekil 3.8. ICDAR 2003 veri tabanından yararlanılarak derlenen her bir rakam sınıfının 50 farklı versiyonu

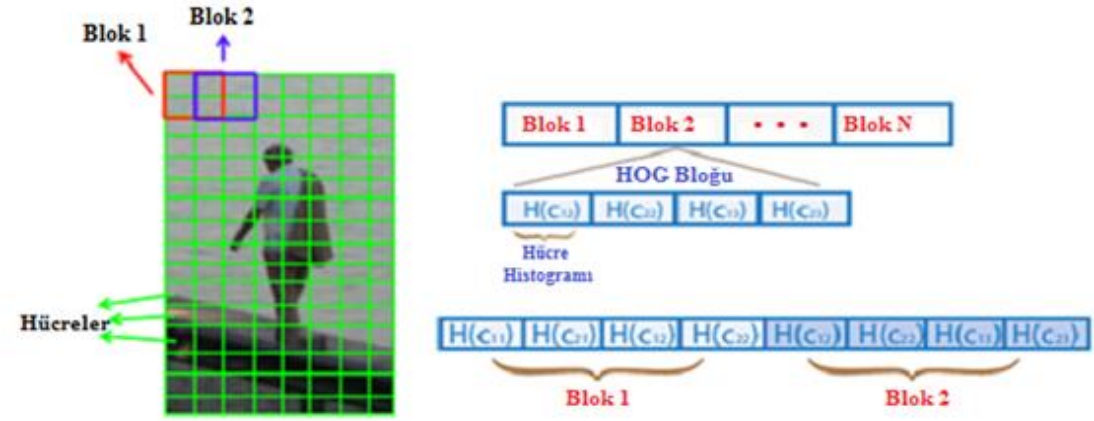


Şekil 3.9. ICDAR 2003 veri tabanından yararlanılarak derlenen her bir harf sınıfının 50 farklı versiyonu

3.3.2.2. Özellik uzayında eğitim

Çok sayıda veri ile yapılan analizler fazlaca hafıza gerektirmekte ve hesapsal yükü arttırmaktadır. Özellik çıkartımı; belirtilen problemlere veri boyutunu indirgeyen bir çözüm getirmektedir. İndirgenen veri boyutu yeterli doğrulukta temsil edilebilmektedir. Özellik çıkartımının en çok uygulandığı alanlardan biri görüntü işleme ve özellikle de optik karakter tanıma (OCR) uygulamalarıdır.

Bu çalışmada eğitim setindeki karakterlerin HOG (Histogram of Oriented Gradients) özellikleri çıkartılarak kullanılmıştır. HOG algoritması gradyan temelli bir öznitelik çıkarım yöntemidir. Bu algoritmada imge yerel bölgelere ayrılarak bu bölgeler için tanımlayıcılar oluşturulur. Oluşturulan tanımlayıcılar imgenin yerel bölgelerindeki imge şeklini kabaca betimlemektedir. Algoritma ile her bir yerel bölge için histogramlar oluşturulur. Oluşturulan histogramlar hücre adı verilen yerel imge bölgesine ait gradyanların oluşma sayılarının dağılımlarını vermektedir [46]. Şekil 3.10'da hücrelere ayrılmış örnek bir imge üzerinden özellik vektörü oluşum süreci gösterilmektedir.

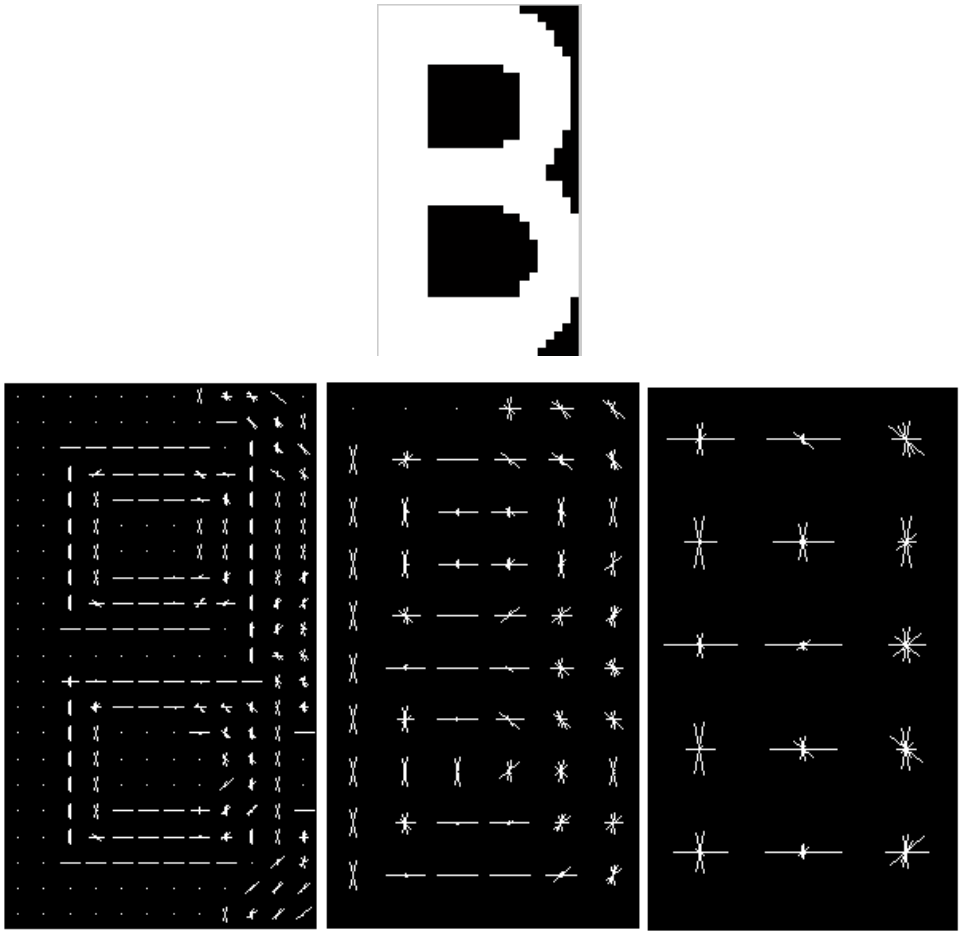


(a) (b)

Şekil 3.10. (a) [2 2] hücre boyutu seçimi için örnek bir imge, (b) [2 2] hücre boyutu için özellik vektörü oluşum süreci

Deneyler sürecinde Şekil 3.7, Şekil 3.8 ve 3.9'de görülen 33x51 boyutlu karakter uzayındaki her bir karakter için HOG özellik vektörü çıkartılmıştır. Şekil 3.11'de örnek bir karakter imgesinin farklı hücre boyutu seçimlerinden elde edilen HOG özellikleri gösterilmektedir.

Şekil 3.11 incelendiğinde, Hücre boyutunun 8x8 seçilmesi durumunda şekil bilgisinin yeterince örneklenemediği görülmektedir. Hücre boyutunun 2x2 seçilmesi çok fazla detay içereceğinden HOG özellik vektörünün boyutunu önemli derecede arttırarak eğitim hızını azaltmaktadır. Hücre boyutunun 4x4 seçilmesi ise yeterli uzamsal bilgiyi içererek bir ödünleşim (trade off) sağlamaktadır. Hücre boyutunun 4x4 seçilmesi durumunda oluşan özellik vektörü boyutu 1x1620 boyutunda olurken, 8x8 seçilmesi durumunda ise 1x288 boyutunda olmaktadır. Hücre boyutu 2x2 seçildiğinde ise Şekil 3.11(a)'da görüldüğü gibi detay fazla olduğundan özellik vektörü boyutu 1x7920 olmaktadır.



(a) Hücre boyutu: 2x2 (b) Hücre boyutu: 4x4 (c) Hücre boyutu: 8x8

Şekil 3.11. Örnek ‘B’ karakterine ait çıkartılmış HOG özellikleri

Eğitim süresini çok fazla uzattığından 2x2’lik hücre boyutu seçimi düşünülmemiştir. Çalışmada hücre boyutu 4x4 ve 8x8 seçildiğinde sınıflandırma başarımının nasıl değiştiği incelenmiştir.

3.3.2.3. Sınıflandırma

Tez çalışmasında sınıflandırıcı olarak çok katmanlı algılayıcı modelinden yararlanılmıştır. Bu nedenle bu bölümde öncelikle yapay sinir ağları ile ilgili genel bilgilere yer verilecektir.

Yapay Sinir Ağları (YSA): Yapay sinir ağları insan beynindeki biyolojik sinir ağlarının yapısal ve işlevsel özelliklerinden esinlenilerek geliştirilen matematiksel bir modeldir. Yapay sinir ağı, nöron (sinir) olarak bilinen birbirine bağlı birçok işlem biriminden oluşmaktadır. Nöronlar özel bir görevi başarabilmek için yapılandırılmış bir yolla bağlı olup katmanlarda düzenlenmişlerdir. Bir katmanda bulunan her bir

nöron benzer işlevlere sahiptir. YSA, girişleri ve çıkışları arasındaki ilişkiyi öğrenme süreci boyunca sürekli değiştirdiği için uyarlamalı bir sistemdir. YSA'nın temel görevi, girişler ve çıkışlar arasındaki karmaşık ilişkiyi modellemek ya da verideki örüntüleri bulmaktır.

Yapay sinir ağları; regresyon analizi ve modelleme, sınıflandırma, örüntü tanıma, veri işleme, robotik gibi birçok uygulamada kullanılmaktadır.

Tez çalışmasında kolay kullanımı ve gürbüzlüğü nedeniyle plaka karakterlerinin tanınması amacıyla, çok katmanlı ileri yayılımlı sinir ağı kullanılmıştır. Bu türdeki sinir ağları işaretlerin bir katmandan gelecek katmana sürekli ilerlemesi nedeniyle ileri yayılımlı olarak adlandırılmaktadır. İleri yayılımlı ağların genel özellikleri şu şekilde özetlenebilmektedir:

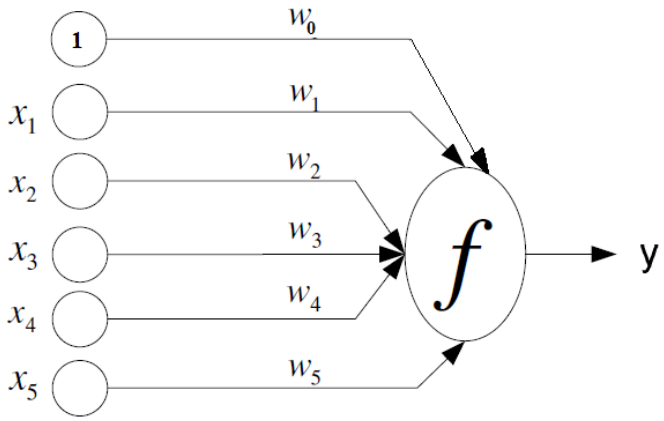
-Geriye besleme sağlayan herhangi bir bağlantı olmadığı için çıkış yalnızca mevcut girişe bağlıdır.

-Nöronlar katmanlarda düzenlenmişlerdir. İlk katman girişleri alırken son katman çıkış üretmektedir.

-Giriş ve çıkışlar arasında bir ya da daha çok katman bulunabilmektedir. Tüm bu ara katmanlar gizli katman olarak adlandırılmaktadırlar.

-Aynı katmandaki nöronlar arasında herhangi bir bağlantı yoktur.

Üç türde ileri yayılımlı sinir ağı bulunmaktadır: tek katmanlı ileri yayılımlı, çok katmanlı ileri yayılımlı ve radyal tabanlı ağlar. Her bir sinir ağı türünün avantaj ve dezavantajları bulunmaktadır.



Şekil 3.12. Tek katmanlı algılayıcı modeli [51]

Şekil 3.12'de tek katmanlı algılayıcı modeli gösterilmektedir. Buradaki x_1, x_2,.,, x_5 özellik vektörlerini; w_1, w_2, w_3,…,w_5 ise ağırlık değerlerini belirtmektedir. f, nöronun aktifleşme seviyesini karara bağlayan doğrusal olmayan bir aktivasyon fonksiyonunu ifade etmektedir. Nöronun çıkışı Eşitlik (3.1)'deki gibi hesaplanmaktadır. Eşitlik (3.1)'deki b bir sabit olup, bias (yanlılık) veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılmaktadır.

$$y=f\left(\sum_i w_i.x_i+b\right) \tag{3.1}$$

Aktivasyon fonksiyonları:

Bir nöron veya işlem biriminin davranışı aktivasyon fonksiyonlarıyla yakından ilişkilidir. Aktivasyon fonksiyonları şu kategorilere bölünebilmektedir:

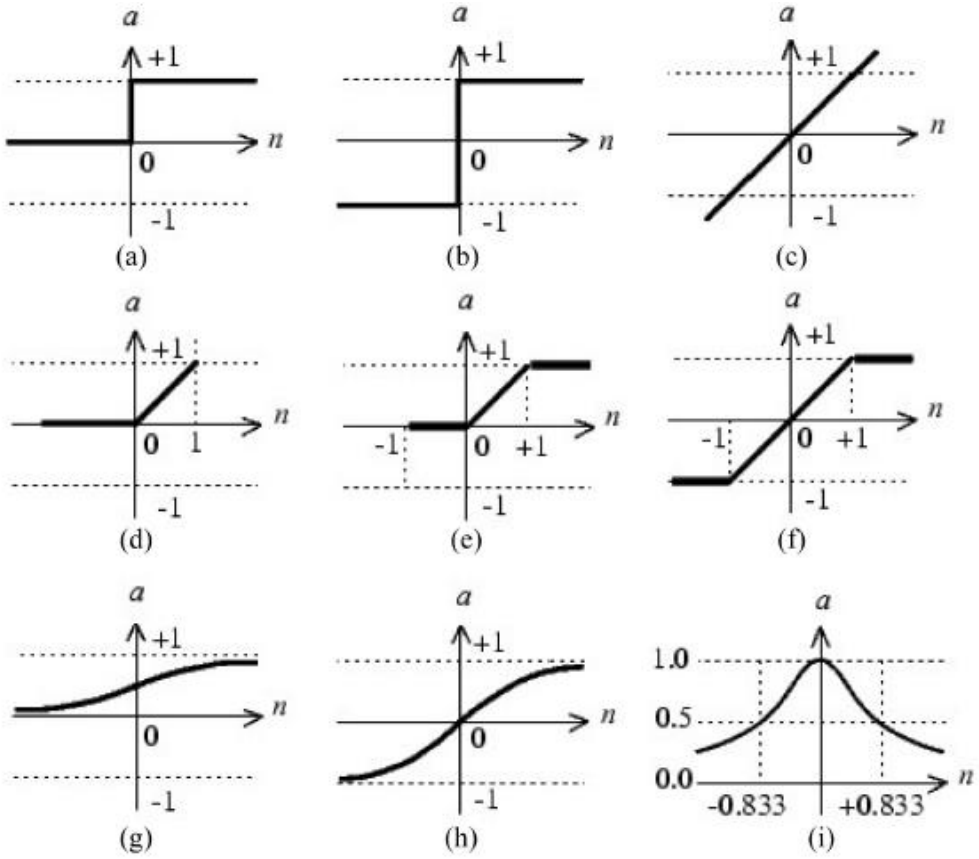
Doğrusal: Bu türdeki aktivasyon fonksiyonun çıkışı toplam ağırlıklandırılmış giriş ile doğrudan orantılıdır. Bu fonksiyonlar Şekil 3.13(c), 3.13(d), 3.13(e), 3.13(f)'de gösterilmektedir.

Eşik: Bu türdeki aktivasyon fonksiyonun çıkışı toplam girişin belirlenen bir eşik değerden büyük ya da küçük olması durumu dikkate alınarak iki seviyeden birine atanmaktadır. Bu fonksiyonlar Şekil 3.13(a) ve 3.13(b)'de sırasıyla gösterilmektedir.

Sigmoid: Bu türdeki aktivasyon fonksiyonun çıkışı, giriş değişimleriyle sürekli ancak doğrusal olmayan şekilde değişmektedir. Sigmoid aktivasyon fonksiyonlarına örnekler lojistik sigmoid, tanjant sigmoid ve radyal tabanlı aktivasyon fonksiyonları verilmektedir. Bu fonksiyonlar Şekil 3.13(g), 3.13(h), 3.13(i)'de sırasıyla gösterilmektedir. Lojistik sigmoid fonksiyonu Eşitlik (3.2)'deki gibi;

$$f(x)=\frac{1}{1+e^{-\alpha x}} \tag{3.2}$$

verilebilmektedir. Bu fonksiyon doğrusal olmadığı için türevi alınabilmektedir. Böylece geri yayılımlı ağlarda kullanılabilmektedir. Eşitlikteki α eğim sabitidir ve genellikle 1 olarak seçilmektedir.



Şekil 3.13. Aktivasyon fonksiyonları: (a) Keskin sınırlı, (b) Simetrik keskin sınırlı, (c) Doğrusal, (d) Pozitif doğrusal, (e) Doğrusal doyan, (f) Simetrik doğrusal doyan, (g) Lojistik sigmoid, (h) Tanjant sigmoid, ve (i) Radyal tabanlı [51]

Eşitlik (3.3)'de tanjant sigmoid fonksiyonu verilmiştir. Bu fonksiyon da lojistik sigmoid fonksiyonu gibi doğrusal değil ve türevi alınabilirdir. Fonksiyonun değeri +1 ve -1 aralığında değişmektedir.

$$f(x)=\frac{e^{x}-e^{-x}}{e^{x}+e^{-x}} \tag{3.3}$$

Tez çalışmasında gizli katmanlar ve çıkış katmanlarında sırasıyla lojistik sigmoid ve doğrusal aktivasyon fonksiyonları kullanılmıştır.

Öğrenme, nöronlar arasındaki etkileşimlerin en uygun ağırlıklarını bulmak için gerçekleşen interaktif ve iteratif bir süreçtir. YSA'nın öğrenme düzeyi, performans fonksiyonları ile ölçülmektedir [31].

Öğrenme sürecinin performans hedefi performans fonksiyonunu en küçüklemektir. Ortalama karesel hata (MSE) en yaygın kullanılan performans fonksiyonudur. Toplam karesel hata (SSE) ve ortalama karesel hatanın karekökü (RMS) ise bilindik diğer

performans fonksiyonlarıdır. Performans fonksiyonları Eşitlik (3.4), Eşitlik (3.5), Eşitlik (3.6)'daki gibi;

$$MSE=\frac{1}{N}\sum_{i=1}^{N}\left(\hat{y}_i-y_i\right)^2 \tag{3.4}$$

$$SSE=\sum_{i=1}^{N}\left(\hat{y}_i-y_i\right)^2 \tag{3.5}$$

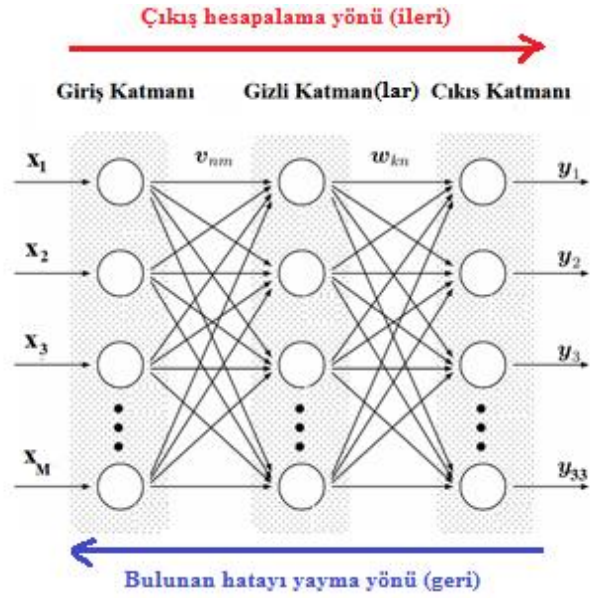
$$RMS=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\hat{y}_i-y_i\right)^2} \tag{3.6}$$

verilmektedir. Eşitliklerdeki $\hat{y}_i$ ağın öngördüğü mevcut çıkışı, y_i ise gerçek çıkışı simgelemektedir. Danışmanlı, danışmansız ve takviye öğrenme olmak üzere üç türde öğrenme tasarısı bulunmaktadır. Tez çalışmasında hedef çıkış değerleri önceden bilindiği için danışmanlı öğrenme tasarısından yararlanılmıştır.

Danışmanlı öğrenmede $x_i \in X$ girişleri ve $y_i \in Y$ hedefleri temsil etmek üzere elimizde X, Y çiftleri bulunmaktadır. Amacımız $f(x_i)=y_i$ yapan f fonksiyonunu bulmaktır.

Çok katmanlı algılayıcı (MLP) modeli: Çok katmanlı algılayıcı modeli genellikle ileri beslemeli ağları ifade etmek için kullanılmaktadır. Her bir katmandaki nöronlar birbirinden bağımsızdır ve katmanlar arasında geriye yönelik bir bağlantı yoktur.

Öğrenme nöronlar arasındaki ağırlıkların güncellenmesi olarak da tanımlanabilmektedir. Ağın eğitiminin ne zaman bitirileceğine ait kesin bir kural yoktur. Hedefler ve ağın öngördüğü çıkışlar arasındaki hata toleransı kabul edilebilir sınırlara ulaştığında ağın eğitiminin tamamlandığı varsayılmaktadır. Geri yayılım algoritması ağ eğitimi için uygulamada oldukça sık yararlanılan bir algoritmadır. Bu algoritmada, hataların çıkıştan girişe geriye doğru azaltılmaya çalışılmasından dolayı geri yayılım ismini almıştır.



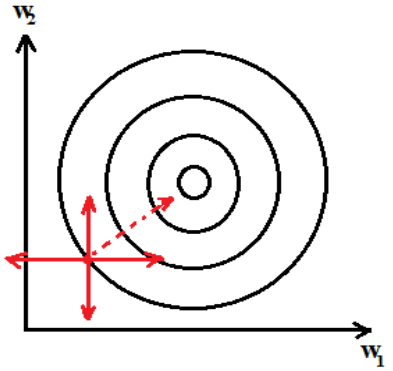
Şekil 3.14. MLP modeli

Geriye yayılım (backpropagation) algoritması ile eğitim: Eşitlik (3.7)'deki $\hat{x}$, ağın girişini; $\hat{w}$, ağırlıkları; $\hat{z}$, ağın öngördüğü çıkışı; $\hat{\varphi}$, gerçek çıkışları; f, daha önce söz edilen aktivasyon fonksiyonunu ifade etmek üzere performans fonksiyonu P, Eşitlik (3.8)'deki gibi;

$$\hat{z} = f(\hat{x}, \hat{w}), \quad \hat{\varphi} = g(\hat{x}) \tag{3.7}$$

$$P(\hat{\varphi}, \hat{z}) = -\frac{1}{2}\|\hat{\varphi} - \hat{z}\|^2 \tag{3.8}$$

verilebilmektedir. Daha önce de söz edildiği gibi öğrenme en uygun ağırlıkların arandığı bir optimizasyon sürecidir. Bu arama süreci basit anlamda Şekil 3.15'deki gibi gösterilebilir.

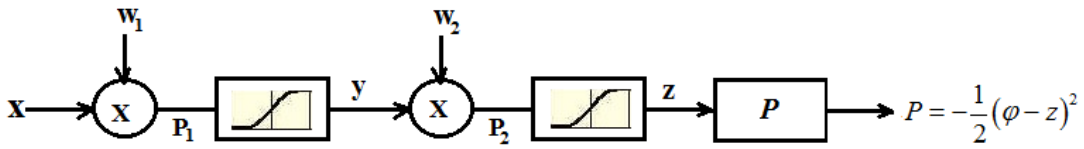


Şekil 3.15. En uygun ağırlık değerlerinin aranması

η, öğrenme katsayısını temsil etmek üzere en uygun ağırlık değerlerinin bulunması için Eşitlik (3.9)'da gösterildiği gibi;

$$\Delta w=\eta.\left(\frac{\partial P}{\partial w_1}i+\frac{\partial P}{\partial w_2}j\right) \tag{3.9}$$

performans fonksiyonunun ağırlıklara göre türevi alınmalıdır. Geri yayılım algoritmasının incelenebilmesi ve genel denklemlerin türetilebilmesi için Şekil 3.16'da tek girişli tek çıkışlı ileri beslemeli ağ yapısı verilmiştir. Şekildeki P, performans hesaplama kutusunu ifade etmektedir.



Şekil 3.16. Tek giriş tek çıkışlı ileri beslemeli ağ üzerinden geri yayılım algoritmasının incelenmesi

Performans fonksiyonunun ağırlıklara göre türevleri Eşitlik (3.10)'daki gibi;

$$\frac{\partial P}{\partial w_2}=\frac{\partial P}{\partial z}.\frac{\partial z}{\partial w_2}=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.\frac{\partial P_2}{\partial w_2}=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.y$$

$$\frac{\partial P}{\partial w_1}=\frac{\partial P}{\partial z}.\frac{\partial z}{\partial w_1}=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.\frac{\partial P_2}{\partial w_1}=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.\frac{\partial P_2}{\partial y}.\frac{\partial y}{\partial w_1} \tag{3.10}$$

$$=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.w_2.\frac{\partial y}{\partial P_1}.x$$

verilebilmektedir. α, genel bir sigmoid aktivasyon fonksiyonunun girişini; β, çıkışını ifade etmek üzere çıkıştaki işaretin girişteki işarete göre türevi Eşitlik (3.11)'deki gibi;

$$\beta=\frac{1}{1+e^{-\alpha}},\quad \frac{d\beta}{d\alpha}(1+e^{-\alpha})^{-1}=\beta.(1\text{-}\beta) \tag{3.11}$$

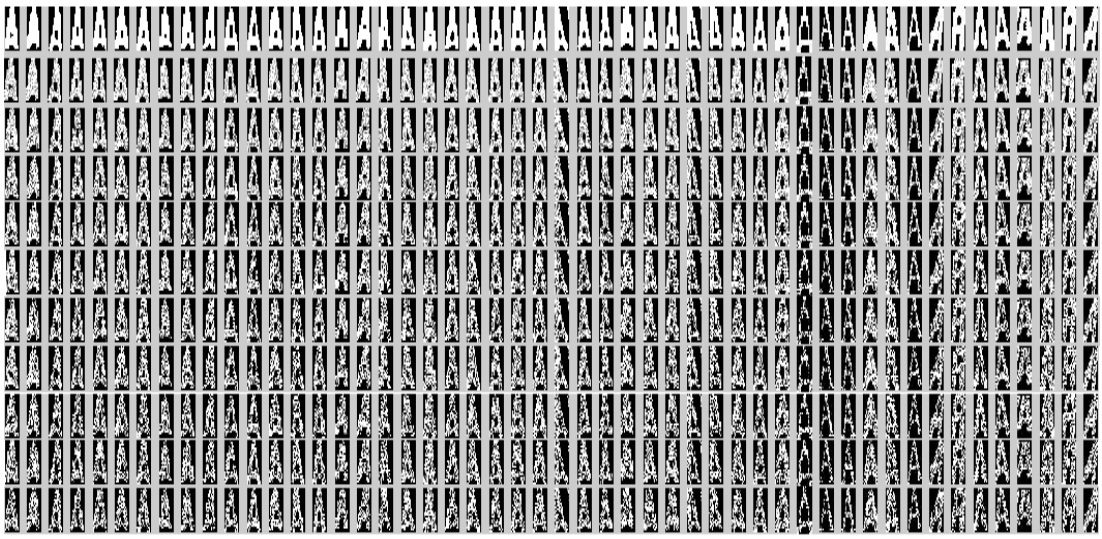
hesaplanmaktadır. Sigmoid aktivasyon fonksiyonunun çıkışının girişindeki işarete göre türevi çıkışlar cinsinden ifade edilebilmektedir. Sigmoid fonksiyonun aktivasyon fonksiyonu olarak tercih edilme sebebi bu matematiksel kullanışlılığa sahip olmasıdır.

Böylece Eşitlik (3.10), Eşitlik (3.12)'deki gibi;

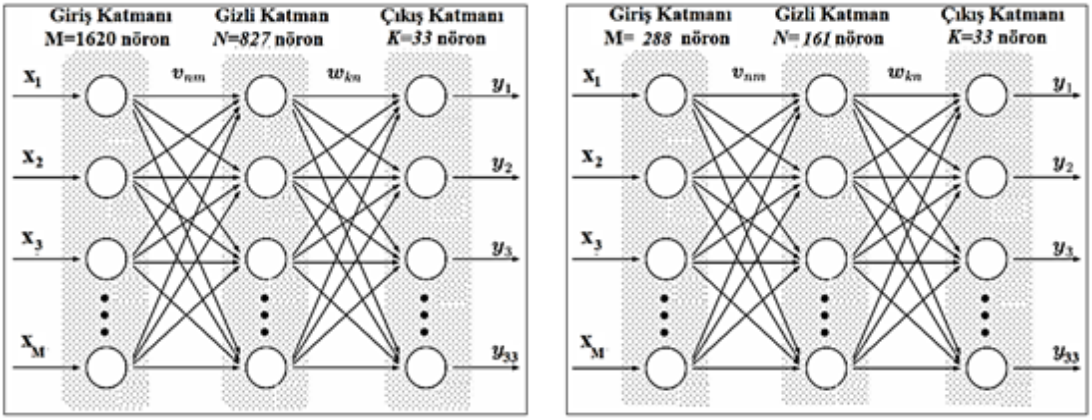
$$\frac{\partial P}{\partial w_2}=\frac{\partial P}{\partial z}.\frac{\partial z}{\partial w_2}=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.y=(\varphi\text{-}z).z(1\text{-}z).y$$
$$\frac{\partial P}{\partial w_1}=\frac{\partial P}{\partial z}.\frac{\partial z}{\partial w_1}=(\varphi\text{-}z).\frac{\partial z}{\partial P_2}.w_2.\frac{\partial y}{\partial P_1}.x=(\varphi\text{-}z).z(1\text{-}z).w_2.y.(1\text{-}y).x \quad (3.12)$$

yeniden düzenlenmektedir. Eşitlik (3.12)'den görüldüğü gibi çıkıştaki hata geriye doğru yayılarak güncellenerek w_1 ve w_2 ağırlıklarına etki etmektedir.

Eğitim sürecinde Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da verilen eğitim setleri kullanılmıştır. Çalışmada altı ayrı yapay sinir ağı oluşturularak eğitilmiştir. Ardından eğitim setlerine 0 ortalamalı 0,3 değişintili tekdüze dağılmış rasgele gürültü eklenerek test kümesi oluşturulmuş ve farklı hücre boyutu seçimleri ile gürültülü-gürültüsüz eğitilen her bir ağın oluşturulan test kümesini nasıl sınıflandırdığı gözlenmiştir. Test kümesi her bir karakterin 30 ayrı gürültülü kopyasından oluşmaktadır. Böylece test kümesinin boyutları, HOG hücre boyutu 4x4 seçildiğinde 1620x(33x51x30), HOG hücre boyutları 8x8 seçildiğinde ise 288x(33x51x30) olmaktadır. Şekil 3.18'de farklı hücre boyutu seçimi için oluşturulan sinir ağı yapıları gösterilmektedir.



Şekil 3.17. Örnek A karakterinin üzerine ortalaması sıfır, değişintisi 0-1 arasında kademeli artan rasgele dağılmış gürültü eklenerek elde edilen gürültülü kopyaları



(a) HOG hücre boyutu: 4x4 (b) HOG hücre boyutu: 8x8

Şekil 3.18. Farklı HOG hücre boyutu için oluşturulan sinir ağının yapısı [51]

3.3.2.4. Gürültüsüz eğitim

Bu aşamada iki farklı ağ oluşturulmuştur. İlk ağ (Ağ 1_4x4); 4x4 HOG hücre boyutu seçiminden edinilen özellik vektörü ile gürültüsüz, ikinci ağ (Ağ 1_8x8); 8x8 HOG hücre boyutu seçiminden edinilen özellik vektörü ile gürültüsüz olarak eğitilmiştir. Ardından eğitilen ağların gürültülü test kümesini nasıl sınıflandırdığı karışım matrisi (Confusion Matrix) üzerinden gözlenmiştir. Karışım matrisi, bir kare matristir. Matrisin sütunları öngörülen (Predicted) sınıflardan oluşurken, satırları ise gerçek (Actuals) sınıflardan oluşmaktadır. Değerlerin matrisin esas köşegeni üzerinde toplanması istenilen durumu oluşturmaktadır. Eğer bu değerler matrisin geneline yayılmışsa sınıflandırıcının sınıflandırma hatalarının fazla olduğu söylenebilmektedir. Tablo 3.1'de HOG hücre boyutu 4x4 için gürültüsüz eğitilen ağın gürültülü test kümesini nasıl sınıflandırdığı gösterilmektedir. Sonuçlar incelendiğinde ağın gürültülü test kümesini sınıflandırmada oldukça başarısız olduğu görülmektedir. Hatalı sınıflandırılmış örnekler oranı 0,9512'dir. Örneklerin yaklaşık %5'i doğru sınıflandırılabilmiştir. Tablo 3.2'de HOG hücre boyutu 8x8 için gürültüsüz eğitilen ağın gürültülü test kümesinin nasıl sınıflandırdığı gösterilmektedir. Test kümesini sınıflandırma başarısı beklendiği gibi daha kötüdür. Tablo 3.1, 3.2, 3.3, 3.4, 3.5 ve 3.6'daki karışım matrislerinin her biri yüzde formunda verilmiştir.

Tablo 3.1. 4x4 HOG hücre boyutu seçimi için gürültüsüz eğitilen ağın (Ağ 1_4x4) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,9512

		ÖNGÖRÜLEN SINIFLAR (PREDICTED)																																
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**	**J**	**K**	**L**	**M**	**N**	**O**	**P**	**R**	**S**	**T**	**U**	**V**	**Y**	**Z**
GERÇEK SINIFLAR (ACTUALS)	**0**	18	3	0	0	1	3	0	0	1	5	0	2	0	0	2	0	4	2	12	0	1	0	0	2	0	1	0	21	6	14	1	0	0
	1	11	8	0	1	2	2	0	0	0	5	0	1	1	0	2	1	3	4	17	0	2	0	0	1	0	3	0	21	5	6	2	0	1
	2	14	3	1	0	3	4	0	1	1	5	0	3	1	0	3	1	3	3	14	0	2	0	0	2	0	4	0	20	4	5	2	0	3
	3	13	3	0	1	3	4	0	0	1	5	0	3	0	0	3	1	4	1	14	0	1	0	0	3	0	2	0	27	4	5	1	0	1
	4	10	2	0	0	4	2	0	0	0	6	0	3	0	0	2	1	4	3	16	0	3	0	0	2	0	3	0	21	6	8	2	1	1
	5	11	2	0	1	2	5	0	0	0	7	0	3	0	0	2	2	3	2	11	0	1	0	0	2	0	2	0	26	6	7	2	0	1
	6	17	2	0	0	2	5	0	0	1	5	0	2	0	0	2	1	6	2	12	0	1	0	0	2	0	2	0	21	5	7	2	0	0
	7	14	3	0	0	2	3	0	1	1	4	0	2	1	0	2	2	1	2	16	0	3	0	0	3	0	4	0	18	7	7	3	0	2
	8	16	2	0	0	2	4	0	0	1	6	0	5	0	0	2	1	3	2	11	0	2	0	0	2	0	2	0	21	4	8	2	0	1
	9	13	2	0	0	3	3	0	0	1	10	0	3	0	0	3	1	3	4	10	0	1	0	0	1	0	3	0	26	3	7	2	0	0
	A	14	2	0	0	2	1	0	0	0	4	0	2	0	0	3	1	2	4	17	0	2	0	0	3	0	2	0	20	5	11	1	0	1
	B	10	3	0	1	2	3	0	0	1	5	0	6	0	0	3	2	2	2	13	0	2	0	0	2	0	4	0	25	4	6	2	0	1
	C	13	2	0	0	2	2	0	0	0	3	0	2	1	0	3	1	4	1	11	0	1	0	0	3	0	2	0	30	5	9	2	0	1
	D	15	3	0	0	1	3	0	0	1	6	0	3	1	0	3	0	3	3	14	0	1	0	0	2	0	2	0	22	3	11	1	0	1
	E	10	2	0	0	3	3	0	1	1	4	0	2	0	0	5	1	4	4	11	0	1	0	0	3	0	3	0	30	4	4	2	0	1
	F	12	2	0	0	2	3	0	1	0	4	0	2	0	0	2	4	4	4	14	0	1	0	0	2	0	5	0	27	6	3	1	0	1
	G	14	3	0	1	2	3	0	0	0	4	0	5	1	0	3	1	7	2	13	0	1	0	0	1	0	2	0	24	3	8	1	0	1
	H	11	2	0	0	2	2	0	0	0	7	0	3	0	0	3	2	3	4	17	0	2	0	0	3	0	3	0	20	5	9	2	0	0
	I	10	2	0	0	2	1	0	0	0	5	0	1	0	0	2	1	3	3	26	0	2	0	0	2	0	2	0	20	6	8	2	0	1
	J	11	5	0	0	2	4	0	0	0	7	0	4	0	0	2	1	2	2	13	0	1	0	0	2	0	1	0	19	6	13	1	0	1
	K	10	3	0	0	3	2	0	0	0	5	0	3	0	0	3	1	2	2	23	0	5	0	0	3	0	1	0	18	6	6	1	1	2
	L	12	2	0	0	2	4	0	0	0	4	0	2	1	0	3	1	3	1	16	0	3	0	0	2	0	2	0	24	5	8	3	1	1
	M	9	3	0	0	2	3	0	0	0	4	0	3	0	0	2	1	2	3	19	0	2	0	0	3	0	2	0	21	6	10	4	0	1
	N	9	3	0	0	3	2	0	0	0	3	0	2	1	0	2	2	4	3	18	0	3	0	0	5	0	3	0	18	7	9	2	0	1
	O	15	3	0	1	2	4	0	0	1	5	0	4	1	0	3	2	4	1	12	0	2	0	0	2	0	3	0	22	3	8	2	0	0
	P	13	2	0	0	2	3	0	1	0	4	0	2	1	0	3	2	3	3	12	0	1	0	0	2	0	5	0	29	5	5	1	0	1
	R	13	3	0	0	2	2	0	1	1	6	0	4	0	0	3	1	2	3	18	0	2	0	0	3	0	5	1	19	3	6	1	0	1
	S	12	2	0	0	1	3	0	1	0	6	0	3	0	0	2	1	4	1	10	0	1	0	0	3	0	2	0	36	4	5	1	0	1
	T	9	3	0	0	1	2	0	0	0	3	0	2	1	0	2	1	3	2	20	0	2	0	0	2	0	3	0	22	9	9	2	0	1
	U	13	2	0	0	2	2	0	0	0	5	0	3	0	0	2	0	3	2	16	0	1	0	0	2	0	3	0	19	4	17	2	0	1
	V	12	2	0	0	1	2	0	1	1	6	0	2	0	0	2	1	1	3	20	0	2	0	0	2	0	2	0	22	5	9	5	0	0
	Y	11	3	0	0	2	1	0	0	0	3	0	1	0	0	2	1	3	2	21	0	2	0	0	3	0	2	0	20	7	11	3	1	1
	Z	9	2	0	0	2	3	0	1	0	3	0	3	1	0	3	1	2	3	18	0	3	0	0	2	0	1	0	21	6	6	3	0	5

Tablo 3.2. 8x8 HOG hücre boyutu seçimi için gürültüsüz eğitilen ağın (Ağ 1_8x8) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,955

		ÖNGÖRÜLEN SINIFLAR (PREDICTED)																														
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**	**J**	**K**	**L**	**M**	**N**	**O**	**P**	**R**	**S**	**T**	**U**	**V**	**Y**	**Z**
GERÇEK SINIFLAR (ACTUALS)	**0**	0	0	0	1	0	0	0	1	0	0	0	0	0	0	10	1	12	1	34	5	0	5	2	1	4	9	1	9	0	0	0	0	2
	1	0	0	0	2	0	0	0	3	0	0	0	0	0	0	12	2	9	1	33	4	0	3	2	1	4	11	1	9	0	0	0	0	3
	2	0	0	0	1	0	0	0	2	0	0	0	0	0	1	11	1	10	1	36	3	0	4	1	1	4	11	1	9	0	0	0	0	4
	3	0	0	0	3	0	0	0	1	0	0	0	0	0	0	10	1	12	1	34	5	0	2	2	1	4	10	0	9	0	0	0	0	3
	4	0	0	0	1	0	0	0	1	0	0	0	0	0	0	15	1	11	1	30	6	0	4	1	0	4	9	0	11	0	0	0	0	2
	5	0	0	0	3	0	0	0	1	0	0	0	0	0	0	13	1	11	1	30	8	0	3	1	1	4	8	0	12	0	0	0	0	3
	6	0	0	0	2	0	0	0	1	0	0	0	0	0	1	15	2	12	1	29	4	0	3	1	0	3	11	0	11	0	0	0	0	2
	7	0	0	0	2	0	0	0	3	0	0	0	0	0	1	10	1	10	1	34	4	0	3	1	1	3	11	0	10	0	0	0	0	3
	8	0	0	0	2	0	0	0	1	0	0	0	0	0	0	11	1	9	1	31	5	0	3	2	2	4	13	1	11	0	0	0	0	3
	9	0	0	0	2	0	0	0	1	0	0	0	0	0	0	10	1	11	1	29	7	0	4	1	1	3	12	0	12	0	0	0	0	3
	A	1	0	0	1	0	0	0	1	0	0	0	0	0	0	12	1	13	1	32	4	0	4	1	1	5	10	1	8	0	1	0	0	2
	B	0	0	0	1	0	0	0	1	0	0	0	0	0	1	12	1	9	1	30	4	0	3	1	1	4	15	1	11	0	0	0	0	3
	C	1	0	0	2	0	0	0	2	0	0	0	0	0	0	12	1	10	1	33	4	0	5	1	1	3	9	1	11	0	0	0	0	4
	D	0	0	0	1	0	0	0	2	0	0	0	0	0	0	9	2	11	1	38	5	0	3	2	1	4	9	1	9	0	0	0	0	3
	E	0	0	0	1	0	0	0	1	0	0	0	0	0	0	17	2	12	1	29	4	0	4	1	0	4	13	1	7	0	0	0	0	2
	F	0	0	0	1	0	0	0	2	0	0	0	0	0	0	13	3	11	1	31	4	0	2	1	1	2	15	1	8	0	0	0	0	2
	G	0	0	0	2	0	0	0	1	0	0	0	0	0	0	12	1	16	1	32	2	0	4	1	1	4	10	0	10	0	0	0	0	2
	H	0	0	0	2	0	0	0	1	0	0	0	0	0	1	12	2	8	1	34	4	0	3	2	2	4	12	1	9	0	1	0	0	2
	I	0	0	0	1	0	0	0	2	0	0	0	0	0	0	10	1	10	0	39	4	0	3	2	1	3	10	1	9	0	0	0	0	3
	J	0	0	0	2	0	0	0	1	0	0	0	0	0	0	11	1	10	1	36	9	0	3	1	0	2	9	1	9	0	0	0	0	3
	K	0	0	0	1	0	0	0	1	0	0	0	0	0	0	12	1	11	1	37	3	0	4	1	1	3	9	1	9	0	0	0	0	3
	L	0	0	0	1	0	0	0	1	0	0	0	0	0	0	13	1	8	1	38	4	0	6	1	1	4	9	0	9	0	0	0	0	3
	M	0	0	0	1	0	0	0	1	0	0	0	0	0	1	11	1	8	1	34	4	0	4	2	1	4	13	1	9	0	0	0	0	3
	N	0	0	0	2	0	0	0	1	0	0	0	0	0	0	11	1	9	1	33	6	0	4	2	1	4	12	1	10	0	0	0	0	2
	O	1	0	0	2	0	0	0	1	0	0	0	0	0	0	11	1	12	1	33	5	0	4	1	0	6	10	0	10	0	0	0	0	2
	P	0	0	0	2	0	0	0	1	0	0	0	0	0	0	11	1	11	1	33	3	0	4	2	1	3	16	1	8	0	0	0	0	2
	R	0	0	0	1	0	0	0	1	0	0	0	0	0	0	11	2	8	1	36	4	0	3	2	1	3	12	2	9	0	0	0	0	3
	S	0	0	0	2	0	0	0	1	0	0	0	0	0	0	11	1	11	1	28	7	0	3	1	1	3	10	1	16	0	0	0	0	2
	T	0	0	0	2	0	0	0	2	0	0	0	0	0	0	11	1	9	1	38	4	0	3	1	0	3	10	1	8	0	0	0	0	3
	U	1	0	0	1	0	0	0	1	0	0	0	0	0	0	10	1	10	0	36	6	0	4	2	2	4	9	1	8	0	1	0	0	3
	V	0	0	0	1	0	0	0	1	0	0	0	0	0	0	11	1	9	1	35	5	0	3	2	0	4	12	1	9	0	0	0	0	2
	Y	0	0	0	1	0	0	0	1	0	0	0	0	0	0	10	1	7	1	38	4	0	3	1	1	4	12	1	10	0	0	0	0	3
	Z	0	0	0	1	0	0	0	1	0	0	0	0	0	0	12	1	10	1	37	4	0	3	1	1	3	10	0	9	0	0	0	0	4

3.3.2.5. Gürültülü eğitim

Bu bölümde Şekil 3.7, Şekil 3.8 ve Şekil 3.9'da görülen eğitim setlerine 0 ortalamalı 0,3 değişintili tekdüze dağılmış (uniform) rasgele gürültü eklenmiş ve HOG hücre boyutu 4x4 seçilerek elde edilen özellik vektörü ile üçüncü ağ (Ağ 2_4x4) eğitilmiştir. Ardından HOG hücre boyutu 8x8 seçilerek elde edilen özellik vektörü ile dördüncü ağ (Ağ 2_8x8) eğitilmiştir. Son olarak eğitilen her bir ağın test kümesini nasıl sınıflandırdığı karışım matrisleri üzerinden gözlenmiştir.

Tablo 3.3'de HOG hücre boyutu 4x4 için gürültülü eğitilen Ağ 2'nin gürültülü test kümesini nasıl sınıflandırdığı gösterilmektedir. Sonuçlar incelendiğinde Ağ 2'nin gürültülü test kümesini sınıflandırmada Ağ 1'den oldukça başarılı olduğu görülmektedir. Hatalı sınıflandırılmış örnekler oranı 0,0929'dir. Örneklerin yaklaşık %90'ı doğru sınıflandırılmıştır.

Tablo 3.4'de HOG hücre boyutu 8x8 için gürültülü eğitilen Ağ 2'nin gürültülü test kümesini nasıl sınıflandırdığı gösterilmektedir. Hatalı sınıflandırılmış örnekler oranı 0,5111'dir. Örneklerin yaklaşık %49'u doğru sınıflandırılabilmiştir. Hücre boyutunun 8x8 seçilmesi ile gerçekleştirilen eğitimin sınıflandırmada yeterli olamamaktadır.

Ardından eğitim setlerine 0 ortalamalı 0,4 değişintili tekdüze dağılmış rasgele gürültü eklenmiş ve HOG hücre boyutu 4x4 seçilerek elde edilen özellik vektörü ile beşinci ağ (Ağ 3_4x4), HOG hücre boyutu 8x8 seçilerek elde edilen özellik vektörü ile altıncı ağ (Ağ 3_8x8) eğitilmiştir. Son olarak eğitilen her bir ağın test kümesini nasıl sınıflandırdığı karışım matrisi üzerinden gözlenmiştir. Tablo 3.5'de HOG hücre boyutu 4x4 için gürültülü eğitilen Ağ 3'ün gürültülü test kümesini nasıl sınıflandırdığı gösterilmektedir. Sonuçlar incelendiğinde Ağ 3'ün gürültülü test kümesini sınıflandırmada Ağ 2'ye göre daha başarılı olduğu görülmektedir. Hatalı sınıflandırılmış örnekler oranı 0,0237'dir. Örneklerin yaklaşık %98'i doğru sınıflandırılmıştır. Tablo 3.6'da HOG hücre boyutu 8x8 için gürültülü eğitilen Ağ 3'ün gürültülü test kümesini nasıl sınıflandırdığı gösterilmektedir. Hatalı sınıflandırılmış örnekler oranı 0,4262'dir. Örneklerin yaklaşık %57'si doğru sınıflandırılabilmiştir. Hücre boyutunun 8x8 seçilmesi ile gerçekleştirilen eğitim sınıflandırmada yeterli olamamaktadır.

Tablo 3.3. 4x4 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 2_4x4) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,0929

		ÖNGÖRÜLEN SINIFLAR (PREDICTED)																															
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**	**J**	**K**	**L**	**M**	**N**	**O**	**P**	**R**	**S**	**T**	**U**	**V**	**Y**	**Z**
GERÇEK SINIFLAR (ACTUALS)	**0**	81	0	0	0	0	0	1	0	1	0	0	0	0	7	0	0	2	0	0	0	0	0	0	0	2	0	0	0	0	3	0	0	0
	1	1	94	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0
	2	0	0	94	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4
	3	1	0	0	93	0	0	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	97	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
	5	0	0	0	0	0	95	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0
	6	0	0	0	1	0	1	91	0	1	0	0	1	0	0	0	0	2	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0
	7	0	1	1	0	0	0	0	90	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	1	0	1	0	0	0	4
	8	1	0	0	0	0	0	0	0	87	1	0	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0
	9	1	0	0	1	0	0	0	0	1	95	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
	A	0	0	0	0	2	0	0	0	1	0	88	0	0	0	0	0	0	0	1	0	1	0	1	1	0	0	1	1	0	1	0	0	0
	B	0	0	0	0	0	0	1	0	10	1	0	82	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0
	C	1	0	0	0	0	0	0	0	0	0	0	0	95	0	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
	D	16	0	0	0	0	0	0	0	1	0	0	1	0	75	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	3	0	0	0
	E	0	0	0	0	0	1	1	0	0	0	0	0	0	0	93	1	1	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
	F	0	0	0	0	0	0	1	0	0	0	0	0	0	0	4	91	0	0	0	0	0	0	0	0	0	3	1	0	0	0	0	0	0
	G	1	0	0	0	0	0	3	0	0	0	0	0	0	0	0	0	94	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
	H	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	92	0	0	0	0	2	1	0	0	2	0	0	0	0	0	0
	I	1	0	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	0	80	0	1	1	2	0	0	0	1	0	7	1	1	1	0
	J	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	92	0	0	0	0	0	0	0	0	0	4	0	0	0
	K	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	97	0	1	0	0	0	1	0	0	0	0	0	0
	L	0	0	0	0	1	0	0	0	0	0	0	0	2	0	2	0	0	0	2	0	0	88	0	1	0	0	0	0	0	1	0	0	1
	M	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	1	0	88	3	0	0	0	0	0	2	1	1	0
	N	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	5	91	0	0	2	0	0	0	0	0	0
	O	5	0	0	1	0	1	1	0	1	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	88	0	0	1	0	0	0	0	0
	P	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	95	2	0	0	0	0	0	0
	R	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	2	94	0	0	0	0	0	0
	S	0	0	0	0	0	1	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	96	0	0	0	0	0
	T	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	5	0	0	0	0	0	0	0	1	0	90	0	0	1	0
	U	3	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	91	1	0	0
	V	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	3	1	0	0	0	0	0	1	92	2	0
	Y	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	2	0	0	0	1	0	1	0	2	91	0
	Z	0	0	2	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	95

Tablo 3.4. 8x8 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 2_8x8) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,5111

		ÖNGÖRÜLEN SINIFLAR (PREDICTED)																																
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**	**J**	**K**	**L**	**M**	**N**	**O**	**P**	**R**	**S**	**T**	**U**	**V**	**Y**	**Z**
GERÇEK SINIFLAR (ACTUALS)	**0**	28	4	1	2	0	0	1	1	4	2	2	2	3	13	0	0	4	0	5	2	0	1	1	1	9	1	1	0	2	5	2	1	1
	1	4	59	1	3	0	0	1	3	1	0	1	0	0	2	0	1	1	0	2	1	3	0	2	1	1	0	2	0	3	0	1	4	1
	2	1	1	51	2	2	0	1	6	3	0	1	0	1	0	1	1	0	0	1	0	1	0	0	0	1	3	2	0	0	0	0	0	21
	3	1	2	1	49	2	2	2	1	6	6	1	5	1	0	0	0	3	1	0	2	2	0	1	0	2	1	2	2	0	0	1	0	1
	4	0	0	1	2	67	1	0	1	1	1	3	0	1	0	1	1	1	0	1	1	5	1	1	0	0	1	2	1	0	1	1	0	3
	5	0	0	0	3	1	62	10	0	2	2	1	1	0	0	2	2	1	0	0	0	0	0	0	0	1	0	1	8	0	0	0	0	1
	6	0	1	0	4	0	8	48	0	6	1	1	3	1	0	2	1	9	0	0	0	1	0	1	1	2	1	2	6	0	0	1	0	0
	7	1	3	7	3	1	0	0	46	1	1	0	0	1	0	0	2	0	0	2	1	2	0	2	0	0	3	1	0	1	0	2	2	15
	8	0	1	0	5	1	1	5	1	39	5	2	10	1	0	1	0	2	1	1	0	1	0	3	1	3	2	4	3	0	0	1	1	1
	9	1	0	0	9	2	1	0	0	6	54	1	4	0	0	0	0	1	0	0	1	1	0	0	0	3	1	1	6	0	0	2	0	1
	A	2	1	1	1	4	1	1	0	4	2	51	2	1	1	0	0	2	0	1	1	3	1	4	3	3	1	2	2	0	2	0	0	1
	B	1	1	0	5	1	1	5	1	22	6	2	28	1	1	1	0	2	2	0	0	2	0	1	1	1	2	6	4	0	0	2	0	0
	C	2	0	0	1	1	0	2	0	2	0	0	1	69	1	2	0	4	0	1	0	0	3	0	0	3	1	1	0	0	0	0	0	1
	D	24	3	1	2	1	0	1	1	2	1	4	1	2	24	0	0	2	0	5	2	0	2	3	1	5	1	1	0	1	5	2	1	1
	E	0	0	1	0	1	3	4	0	2	1	0	2	2	0	60	9	3	0	0	0	1	1	0	0	0	4	1	1	0	0	0	0	1
	F	0	1	0	1	1	1	3	1	2	0	1	1	1	0	9	55	3	1	0	0	1	0	1	0	0	11	3	1	1	0	1	0	0
	G	1	1	0	4	3	1	12	0	3	1	1	2	3	0	2	1	47	0	1	0	2	1	1	1	4	1	3	2	0	0	1	1	1
	H	0	1	0	0	1	1	1	0	4	1	3	4	0	0	0	2	1	43	1	1	2	0	7	6	0	5	5	0	0	1	5	2	0
	I	4	4	1	1	2	0	0	4	1	0	2	1	2	4	0	0	1	1	26	2	3	3	6	2	1	1	3	0	8	4	4	5	2
	J	2	0	0	4	2	1	0	1	0	2	1	1	0	1	0	0	0	0	3	72	1	1	1	1	0	0	0	0	0	3	1	0	1
	K	0	1	1	3	4	0	0	0	1	0	1	1	1	0	0	0	1	0	1	1	65	0	5	2	0	0	3	1	0	0	1	2	1
	L	2	1	1	0	3	0	1	0	0	0	3	0	5	1	2	0	2	0	4	1	3	57	1	1	0	1	1	1	1	2	1	1	3
	M	1	2	0	0	1	0	1	1	5	1	3	1	0	1	0	1	1	4	4	1	5	1	29	9	1	1	3	1	2	3	10	6	1
	N	1	2	0	0	1	0	1	0	3	1	4	2	0	1	0	0	1	6	1	0	6	0	11	42	0	1	6	1	0	1	3	2	0
	O	3	0	1	3	1	1	2	0	3	2	1	1	2	2	0	0	5	0	0	0	0	0	1	0	66	1	1	1	0	0	1	0	1
	P	0	0	2	1	1	0	1	3	3	2	2	2	2	0	2	7	2	1	1	0	0	0	1	1	1	52	7	1	0	0	2	2	2
	R	1	2	0	2	1	1	1	0	6	2	1	5	1	0	1	2	2	4	1	0	4	0	3	4	0	6	45	1	1	0	2	2	1
	S	0	0	0	3	1	7	6	0	4	6	1	2	1	0	1	1	2	0	0	0	1	0	1	0	1	1	1	59	0	0	1	0	0
	T	4	6	0	1	0	0	1	3	0	0	1	1	2	2	0	1	2	1	16	1	3	1	6	1	0	1	2	0	29	2	4	4	2
	U	8	1	0	1	1	0	0	0	1	1	4	1	1	9	0	0	2	1	4	6	1	4	7	4	2	0	0	0	1	30	6	2	0
	V	1	1	0	1	1	0	0	1	3	2	0	1	0	1	0	0	1	4	2	1	2	0	11	3	1	1	1	0	1	3	47	8	1
	Y	1	4	0	0	0	0	1	1	2	0	0	1	0	1	0	0	1	1	2	0	5	0	9	2	0	1	1	0	2	0	13	50	1
	Z	0	0	15	2	1	0	0	7	1	0	0	0	1	0	1	1	0	0	1	0	2	1	1	0	0	1	1	0	0	0	1	0	63

Tablo 3.5. 4x4 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 3_4x4) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,0237

		ÖNGÖRÜLEN SINIFLAR (PREDICTED)																														
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**	**J**	**K**	**L**	**M**	**N**	**O**	**P**	**R**	**S**	**T**	**U**	**V**	**Y**	**Z**
GERÇEK SINIFLAR (ACTUALS)	**0**	93	0	0	0	0	0	0	0	0	0	0	0	0	4	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0
	1	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
	3	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	5	0	0	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	6	0	0	0	0	0	1	97	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
	7	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
	8	0	0	0	1	0	0	0	0	94	0	0	4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	A	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	B	0	0	0	0	0	0	0	0	3	0	0	95	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	C	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
	D	6	0	0	0	0	0	0	0	0	0	0	0	0	93	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
	E	0	0	0	0	0	0	0	0	0	0	0	0	0	0	99	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	F	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	99	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
	G	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	H	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
	I	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	95	0	0	0	0	0	0	0	0	0	2	0	0	0	0
	J	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0	0	1	0	0	0
	K	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0	0	0	0	0
	L	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	98	0	0	0	0	0	0	0	0	0	0	0
	M	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	96	1	0	0	0	0	0	0	1	0	0
	N	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	98	0	0	0	0	0	0	0	0	0
	O	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0	0
	P	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0	0	0
	R	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	97	0	0	0	0	0	0
	S	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	99	0	0	0	0	0
	T	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0	97	0	0	0	0
	U	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	97	0	0	0
	V	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	98	0	0
	Y	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	98	0
	Z	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	97

Tablo 3.6. 8x8 HOG hücre boyutu seçimi için gürültülü eğitilen ağın (Ağ 3_8x8) karışım matrisi üzerinden sınıflandırma hatalarının gözlenmesi. FSM: 0,4262

		ÖNGÖRÜLEN SINIFLAR (PREDICTED)																															
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**A**	**B**	**C**	**D**	**E**	**F**	**G**	**H**	**I**	**J**	**K**	**L**	**M**	**N**	**O**	**P**	**R**	**S**	**T**	**U**	**V**	**Y**	**Z**
GERÇEK SINIFLAR (ACTUALS)	**0**	30	2	1	1	0	0	1	1	1	1	3	1	4	18	0	0	3	0	4	2	0	2	1	1	7	1	1	0	3	8	1	1	0
	1	2	67	1	1	1	1	1	2	1	0	1	0	0	2	0	0	1	1	3	1	1	0	1	2	1	0	1	0	4	1	1	3	0
	2	1	0	65	1	2	0	0	5	1	0	1	1	1	0	0	1	0	0	0	0	0	1	0	0	0	1	1	0	0	0	0	0	15
	3	1	2	1	48	2	3	2	2	4	6	1	5	1	0	0	1	4	1	1	2	2	0	0	0	3	1	2	1	0	1	1	0	1
	4	0	0	1	1	76	1	0	1	1	2	2	0	0	0	0	0	1	0	0	1	2	2	0	0	0	1	0	1	0	1	1	0	1
	5	0	0	0	1	0	74	5	0	2	1	1	1	0	0	2	1	1	0	0	0	0	0	0	0	1	0	0	6	0	0	0	0	0
	6	1	0	0	2	1	8	49	0	5	1	1	3	1	0	2	2	11	0	0	0	0	0	0	2	2	0	1	6	0	0	0	0	0
	7	0	4	6	1	1	0	0	58	0	1	0	1	0	0	0	1	0	1	1	1	1	0	1	0	0	4	0	0	1	1	1	1	12
	8	0	1	1	3	1	1	5	1	36	4	3	13	1	0	1	1	3	3	0	0	1	0	2	1	2	2	3	5	0	1	2	1	1
	9	1	1	0	3	2	1	0	0	4	66	2	3	0	0	0	0	1	1	0	1	1	0	0	1	2	1	1	4	0	1	1	0	0
	A	2	0	1	1	3	1	1	0	3	1	58	1	1	1	1	0	1	2	1	1	1	2	2	3	2	1	1	1	0	4	1	0	0
	B	1	1	1	3	0	2	4	1	13	4	2	40	1	1	1	0	2	4	0	0	1	0	1	2	1	2	5	3	0	1	1	1	0
	C	1	1	0	0	0	0	1	0	1	0	0	0	78	1	1	0	3	0	0	0	0	3	0	0	2	1	0	1	0	1	0	0	0
	D	15	3	1	1	0	0	0	1	1	1	2	1	3	38	0	0	3	0	6	2	0	2	2	1	3	0	1	0	2	9	1	1	1
	E	0	0	0	0	0	2	2	0	1	0	0	1	1	0	72	7	2	1	0	0	0	1	0	0	0	2	1	1	0	0	0	0	0
	F	0	1	0	0	1	2	2	1	1	0	1	1	1	0	8	70	1	1	0	0	0	0	0	0	0	6	2	1	1	0	0	0	0
	G	0	0	0	1	2	1	8	0	1	1	2	2	4	1	2	1	58	0	1	0	0	1	0	1	2	1	1	2	1	1	0	1	0
	H	0	1	0	0	1	1	1	0	2	1	2	3	0	0	0	1	1	60	1	0	1	0	3	5	0	3	4	0	1	2	5	1	0
	I	3	5	1	0	1	0	0	3	0	0	1	0	1	5	0	0	1	2	27	3	2	5	3	1	1	1	1	0	14	8	2	5	2
	J	0	1	0	1	1	0	0	0	0	1	1	0	1	1	0	0	0	0	1	82	1	1	0	1	0	0	0	0	0	6	0	0	0
	K	0	2	0	2	3	0	0	1	0	0	2	1	0	0	0	0	2	1	1	1	69	1	2	2	0	0	2	1	0	1	1	2	0
	L	0	1	1	0	1	0	0	0	0	0	1	0	4	2	1	0	1	0	3	1	1	75	0	1	0	1	0	0	2	2	0	1	1
	M	1	2	1	0	2	0	0	1	3	0	4	2	0	1	0	1	1	9	3	0	5	1	25	10	1	1	3	1	3	5	7	6	0
	N	0	2	0	0	0	0	1	0	2	0	3	2	1	0	0	1	1	6	1	1	2	1	4	61	0	1	3	0	0	2	2	2	0
	O	3	1	1	1	1	1	1	1	2	1	1	1	3	1	0	0	5	0	0	0	0	0	0	0	71	1	1	1	0	1	1	0	0
	P	0	0	2	1	1	0	0	2	3	2	1	2	1	0	2	7	2	2	1	0	0	0	0	1	1	57	6	0	1	0	1	1	1
	R	1	2	0	2	1	1	1	0	3	2	1	5	1	0	1	3	3	6	1	0	3	0	2	4	0	6	46	1	1	0	2	1	0
	S	0	0	0	2	0	8	4	0	4	5	1	1	1	0	1	1	2	0	0	1	1	0	0	0	1	0	0	66	0	0	0	0	0
	T	3	6	0	0	1	0	0	4	0	0	1	0	1	2	0	2	1	1	14	1	1	1	1	2	0	1	1	0	46	3	1	3	1
	U	3	1	0	0	0	0	0	0	0	1	4	0	1	7	0	0	1	1	3	5	1	5	3	3	1	0	0	0	3	51	3	1	0
	V	0	0	0	0	1	0	0	1	1	1	1	2	0	1	0	0	1	5	2	1	1	1	4	3	0	1	1	0	2	6	51	9	0
	Y	1	3	0	0	0	0	1	1	0	0	0	0	0	1	0	1	0	1	2	0	3	0	4	2	0	1	1	0	2	1	10	61	0
	Z	0	0	17	1	1	0	0	7	0	0	0	0	1	0	1	0	0	0	1	0	1	1	0	0	1	1	0	0	0	0	0	1	62

Test aşamasına ilişkin sonuçlar:

Eğitim setindeki her bir karaktere ortalaması sıfır, değişintisi 0,3 olan gürültü eklenerek her bir karakterin 30 ayrı gürültülü kopyası oluşturulmuştur. Böylece 33 farklı karakter sınıfının her birine ait 51 farklı uyarlamanın bulunduğu orijinal eğitim setinde bir karaktere ait 51x30=1530 örnek oluşturulmuştur. 33 sınıf için test edilecek toplam örnek sayısı 33x51x30=50490 olmaktadır.

Tablo 3.1 ve Tablo 3.2'de verilen karışım matrislerindeki sonuçlar, sırasıyla 4x4 ve 8x8 HOG hücre boyutu seçimi için gürültüsüz eğitilen ağların gürültülü 50490 test verisini nasıl sınıflandırdığını göstermektedir. Tablolardan elde edilen FSM oranları, 50490 örneğin yalnızca %6'sının doğru sınıflandırılabildiğini göstermektedir. Ardından eğitim seti üzerine ortalaması sıfır, değişintisi 0,3 olan rasgele dağılmış gürültü eklenmiş ve HOG hücre boyutunun sırasıyla 4x4 ve 8x8 seçilmesi ile elde edilen özellik vektörleri ile eğitim gerçekleştirilmiştir. Tablo 3.3 ile Tablo 3.4'de verilen karışım matrisleri, sırasıyla HOG hücre boyutunun 4x4 ve 8x8 seçilmesi ile gürültülü eğitilen ağların gürültü 50490 test örneğini nasıl sınıflandırdığını göstermektedir. Tablolardan elde edilen FSM oranları, 4x4 HOG hücre boyutu seçimi için gürültülü eğitilen ağın, 50490 örneğin %98'inin doğru sınıflandırılabildiğini göstermektedir. 8x8 HOG hücre boyutu seçimi için gürültülü eğitilen ağın başarısı ise %68'dir. Hücre boyutunun 8x8 seçimi sonucunda başarımın düşmesinin en temel sebebi daha az detay ile yapılan eğitimdir. Ardından eğitim seti üzerine ortalaması sıfır, değişintisi 0,4 olan rasgele dağılmış gürültü eklenmiş ve HOG hücre boyutunun sırasıyla 4x4 ve 8x8 seçilmesi ile elde edilen özellik vektörleri ile eğitim gerçekleştirilmiştir. Tablo 3.5 ile Tablo 3.6'da verilen karışım matrisleri, sırasıyla HOG hücre boyutunun 4x4 ve 8x8 seçilmesi ile gürültülü eğitilen ağların gürültü 50490 test örneğini nasıl sınıflandırdığını göstermektedir. Tablolardan elde edilen FSM oranları, 4x4 HOG hücre boyutu seçimi için gürültülü eğitilen ağın, 50490 örneğin %96,5'inin doğru sınıflandırılabildiğini göstermektedir. 8x8 HOG hücre boyutu seçimi için gürültülü eğitilen ağın başarısı ise %65'dir. Hücre boyutunun 8x8 seçimi sonucunda başarının düşmesinin en temel sebebi daha az detay ile yapılan eğitimdir. Tablo 3.1'den elde edilen sınıflandırma başarımının düşüklüğü gürültüsüz eğitilen ağın genelleme yeteneğinin yetersizliğinden kaynaklanmaktadır. Tablo 3.3'den elde edilen sınıflandırma başarımının Tablo 3.1'e göre önemli derecede

artması ağın genelleme yeteneğinin arttığını göstermektedir. Tablo 3.5'den elde edilen sınıflandırma başarımının Tablo 3.3'e göre daha düşük olmasının sebebi ise eğitim seti üzerinde artan gürültü seviyesinin karakterlerin ayırt edici özelliklerini kaybetmesine sebep olması, böylelikle elde edilen özellik vektörleri ile eğitilen ağın oluşturulan test örneklerini yanlış genellemesidir. Ağın genelleme hatalarının arttığı söylenebilir.

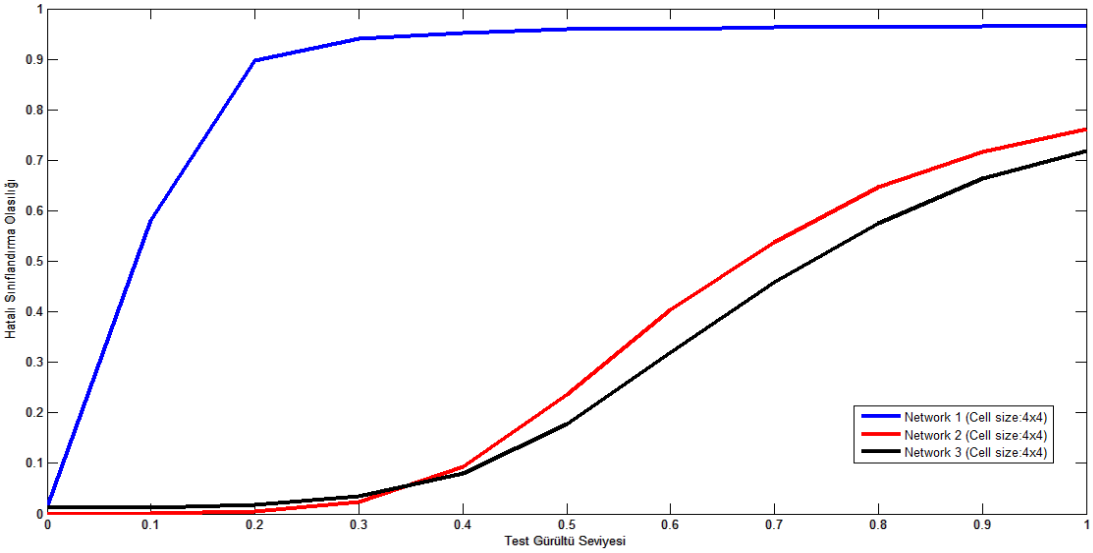
3.3.2.7. Sınıflandırma başarımının karşılaştırılması

Hatalı sınıflanan örüntü sayısının test edilen toplam örüntü sayısına bölümü hatalı sınıflandırma olasılığını vermektedir. Hatalı sınıflandırma olasılığı, sinir ağlarının performanslarını ortaya koymak için yaygın olarak kullanılmaktadır. [8]

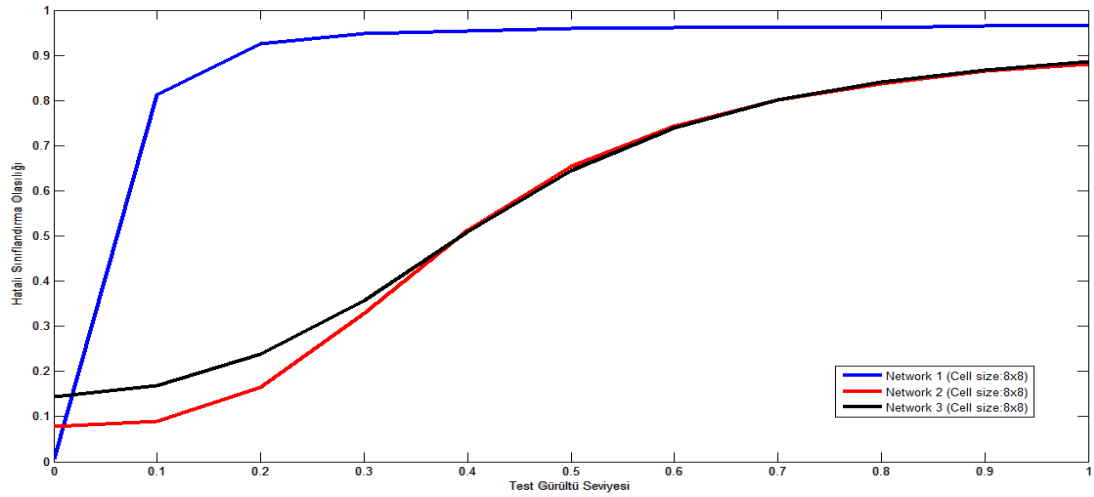
Bu nedenle eğitim seti üzerinde kademeli artan gürültü seviyeleri karşısında eğitilen her bir ağın ürettiği sınıflandırma hataları farklı HOG hücre boyutları için çıkartılarak Tablo 3.7'de sunulmuştur. Tablo 3.7'deki değerlerden elde edilen eğriler Şekil 3.19, 3.20, 3.21, 3.22, 3.23, 3.24'de verilmiştir.

Tablo 3.7. Değişen hücre boyutları için eğitilen her bir ağın eğitim seti üzerinde kademeli artan gürültü seviyesine göre sınıflandırma hatalarının gözlenmesi

Hatalı Sınıflandırılmış Örnekler Oranı (FSM)						
Eğitim Seti Üzerindeki Gürültü Seviyesi	**Gürültüsüz Eğitim**		**Gürültülü Eğitim**			
	Ağ 1 μ=0 ve σ^2=0		**Ağ 2 μ=0 ve σ^2=0,3**		**Ağ 3 μ=0 ve σ^2=0,4**	
	HOG 4x4	**HOG 8x8**	**HOG 4x4**	**HOG 8x8**	**HOG 4x4**	**HOG 8x8**
σ^2=0	0,0152	0,67	0	0,0774	0,0118	0,1439
σ^2=0,1	0,5819	0,8128	9,53e-04	0,0899	0,0127	0,1692
σ^2=0,2	0,8968	0,9250	0,0047	0,1640	0,0178	0,2377
σ^2=0,3	0,94	0,9478	0,0239	0,3291	0,0341	0,3570
σ^2=0,4	0,9526	0,9546	0,0925	0,5125	0,0794	0,5086
σ^2=0,5	0,9590	0,9604	0,2360	0,6539	0,1780	0,6443
σ^2=0,6	0,9603	0,9623	0,4039	0,7421	0,3196	0,7383
σ^2=0,7	0,9634	0,9633	0,5381	0,8004	0,4582	0,8021
σ^2=0,8	0,9636	0,9623	0,6463	0,8379	0,5757	0,8405
σ^2=0,9	0,9649	0,9650	0,7168	0,8647	0,6631	0,8678
σ^2=1	0,9650	0,9663	0,7611	0,8846	0,7185	0,8887

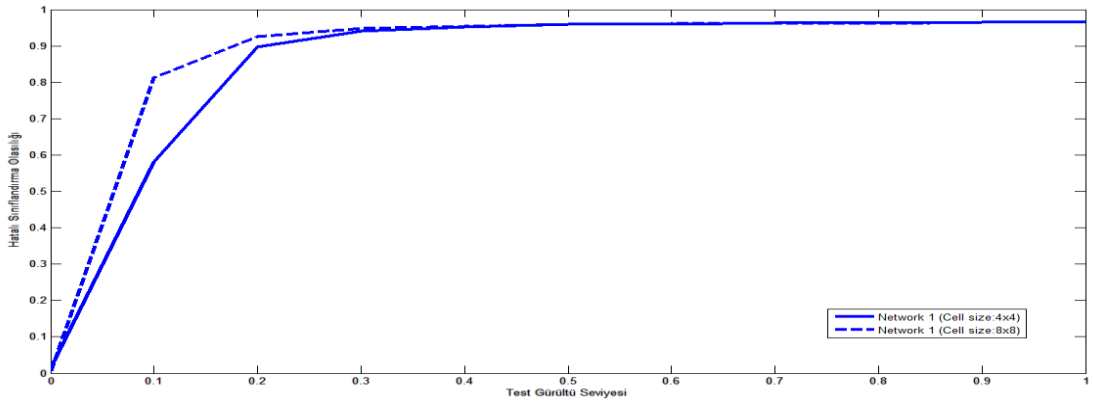


Şekil 3.19. 4x4 HOG hücre boyutu seçimi için eğitilen her bir ağın eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi

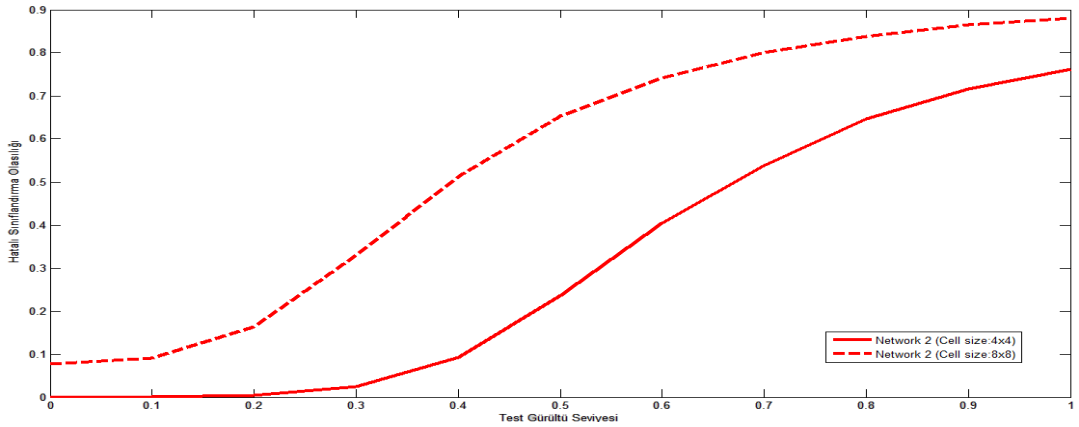


Şekil 3.20. 8x8 HOG hücre boyutu seçimi için eğitilen her bir ağın eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi

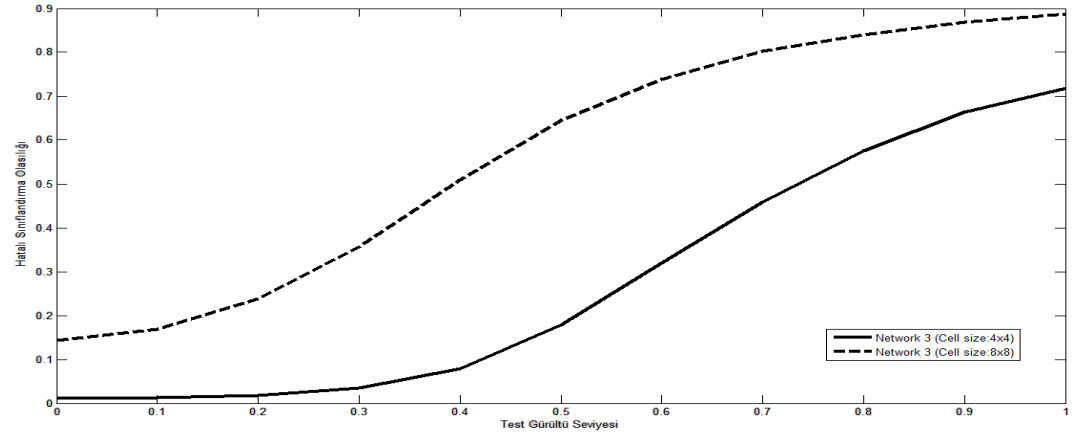
Bölüm 3.3.2'de anlatıldığı gibi HOG hücre boyutunun 2x2 seçilmesi özellik vektörünün boyutunu fazlaca arttırmaktadır. Bu boyut, eğitim süresini oldukça uzattığı için karşılaştırmalar 4x4 ve 8x8 hücre boyutları için yapılmıştır. Hücre boyutunun 4x4 seçilmesi eğitim süresi ve karakterin detaylarının yeterli temsilinde (ayırt edici özellikleri) ödünleşme (trade off) sağlamaktadır. 8x8'lik hücre boyutu ise az miktarda detay içerdiği için, bu boyuttaki özellik vektörleri ile eğitilen ağların eğitim sonrasında sınıflandırma hatalarının daha fazla olduğu Şekil 3.20'de görülmektedir. Ayrıca az sayıdaki detay ile eğitilen ağların artan gürültü seviyeleri karşısındaki sınıflandırma hatalarındaki değişimin daha sert geçişlere sahip olduğu da görülmektedir.



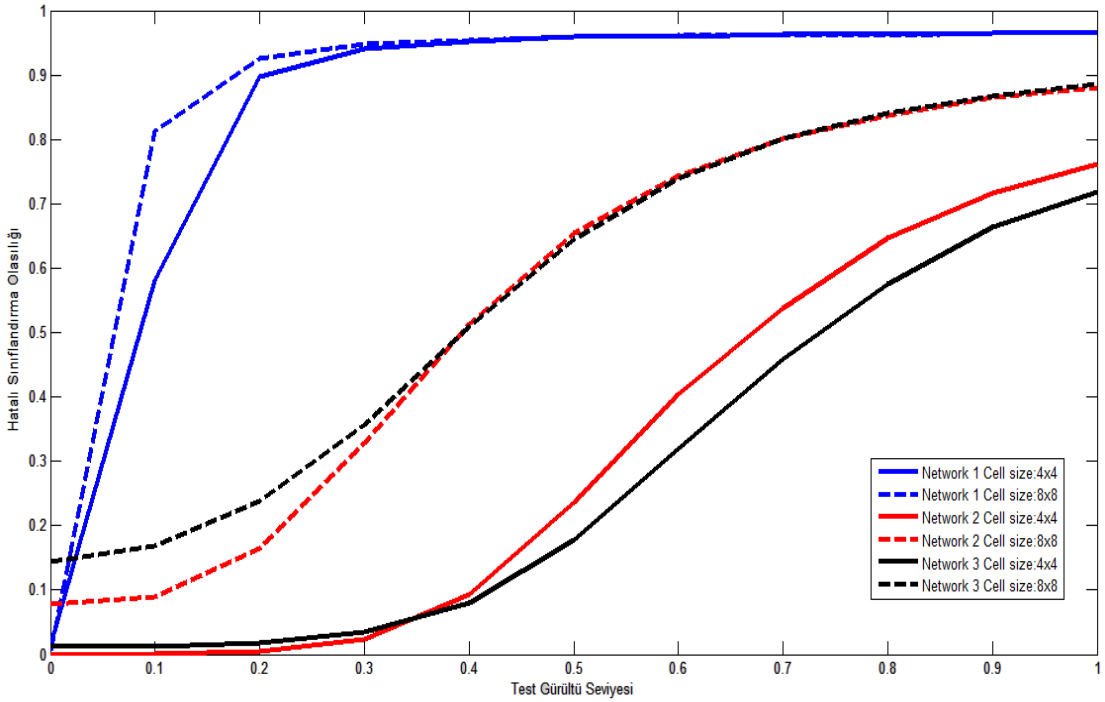
Şekil 3.21. Farklı hücre boyutları için gürültüsüz eğitilen Ağ 1'in eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi. MSE: 0,004



Şekil 3.22. Farklı hücre boyutları için 0 ortalamalı 0,3 değişintili rasgele gürültü eklenmiş veri ile eğitilen Ağ 2'nin eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi. MSE: 0,067



Şekil 3.23. Farklı hücre boyutları için 0 ortalamalı 0,4 değişintili rasgele gürültü eklenmiş veri ile eğitilen Ağ 3'ün eğitim seti üzerinde kademeli artan gürültü karşısında sınıflandırma başarımının gözlenmesi. MSE=0,093



Şekil 3.24. Her bir ağın aynı eksende görünümü

Şekil 3.24'de görsel karşılaştırma sağlayabilmek için her bir ağın sınıflandırma performansı aynı eksen üzerinde gösterilmiştir. Sonuç olarak, Şekillerden görüldüğü gibi gürültü ile eğitim sonucunda sınıflandırma hataları azaltılmıştır. Bu durum ağın sınıflandırma yeteneğinin sistematik yolla arttırılabildiğini ortaya koymaktadır. Şekil 3.19 ve 3.20 bu durumu göstermektedir.

Hücre boyutunun 8x8 belirlenmesi durumunda özellik vektörü karakter detaylarını yeterince temsil edememektedir. Bu şekilde eğitilen ağın sınıflandırma hataları, hücre boyutunun 4x4 belirlenmesi ile eğitilen ağa göre daha fazla olmaktadır. Bu durum her bir ağın kesikli ve sürekli eğrisi arasındaki farktan anlaşılabilmektedir. Tablo 3.8, 3.9 ve 3.10, farklı hücre boyutları için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerlerini göstermektedir. Örneğin Tablo 3.8'deki 4x4 hücre boyutunda gürültüsüz eğitilen Ağ 1 ile 8x8 hücre boyutunda gürültüsüz eğitilen Ağ 1 arasındaki ortalama karesel hata (MSE) 0,004'dur. Değerler Tablo 3.7'ye göre hesaplanmıştır. Tablo 3.11'de farklı sahnelerde örnek tespit ve tanıma sonuçları sunulmaktadır.

Tablo 3.8. 4x4 HOG hücre boyutu seçimi için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerleri

MSE		**HOG Hücre boyutu: 4x4**		
		Ağ 1	**Ağ 2**	**Ağ 3**
HOG Hücre boyutu: 4x4	**Ağ 1**	0	0,3572	0,3870
	Ağ 2	0,3572	0	0,0024
	Ağ 3	0,3870	0,0024	0

Tablo 3.9. 8x8 HOG hücre boyutu seçimi için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerleri

MSE		**HOG Hücre boyutu: 8x8**		
		Ağ 1	**Ağ 2**	**Ağ 3**
HOG Hücre boyutu: 8x8	**Ağ 1**	0	0,171	0,150
	Ağ 2	0,171	0	0,0015
	Ağ 3	0,150	0,0015	0

Tablo 3.10. 4x4 ve 8x8 HOG hücre boyutu seçimi için eğitilen ağların eğitim kümesi üzerinde kademeli artan gürültü karşısında ürettiği sınıflandırma hataları arasındaki MSE değerleri

MSE		**HOG Hücre boyutu: 8x8**		
		Ağ 1	**Ağ 2**	**Ağ 3**
HOG Hücre boyutu: 4x4	**Ağ 1**	0,0049	0,140	0,123
	Ağ 2	0,393	0,067	0,073
	Ağ 3	0,422	0,087	0,093

Tablo 3.11. (a) Örnek giriş imgeleri, (b) Örnek tespit sonuçları, (c) Farklı sınıflandırıcılar için örnek tanıma sonuçları

(a)	(b)	(c)		
		MLP	Şablon Eşleme	Tesseract OCR motoru [53]
		33BMD18	33BK018	33BHD18
		37AG677	37AG677	37AG677
		37AG957	37AR952	37AG957
		37AB039	37AB039	37IR039
		37UA007	37UA007	37UADU7
		34UR4676	70AY4F7R	3!.URL575

3.3.2.8. Plaka tanıma birimi başarısının değerlendirilmesi

Bu aşamada, plaka tanıma biriminin tanıma başarısını değerlendirebilmek için bir veri tabanı araştıran fonksiyon oluşturulmuştur. Oluşturulan fonksiyon, plaka tanıma birimi tarafından döndürülen değeri alarak Excel'de oluşturulmuş veri tabanı içerisinde araştırmaktadır. Oluşturulan veri tabanından örnek bir görünüm Şekil 3.25'da gösterilmektedir.

	A	B	C	D	E	F	G	H
1	SIRA	ARAÇ PLAKASI	TESCİL BİRİMİ	MARKA	CİNSİ	RENK	MODEL YILI	ARAÇ SAHİBİ
2	1	37NC856	İNEBOLU	TOFAŞ-FIAT	AA SEDAN	GRİ (Füme)	1990'	UNKNOWN
3	2	34SPT50	ÜSKÜDAR	HYUNDAI	AB Heçbek	GRİ (Açık-Metalik)	2012'	UNKNOWN
4	3	06DB7868	ANKARA	MERCEDES-BENZ	AA Sedan	GRİ (Füme)	1988'	UNKNOWN
5	4	37ND346	İNEBOLU	RENAULT	Panelvan	GRİ (Yıldız)	2007'	UNKNOWN
6	5	34FZ1089	MALTEPE	HYUNDAI	AF Çok amaçlı	BEYAZ	2011	UNKNOWN
7	6	37UA007	ABANA	RENAULT	OTOMOBİL	BEYAZ (Kristal)	1996'	UNKNOWN
8	7	37AG156	ABANA	TOFAŞ-FIAT	OTOMOBİL	BEYAZ	1996'	UNKNOWN
9	8	34AT2488	BEŞİKTAŞ	CITROEN	AA Sedan	BEYAZ	2012	UNKNOWN
10	9	37DN924	KASTAMONU	FIAT	OTOMOBİL	BEYAZ	2002'	UNKNOWN
11	10	34FET35	GÜNGÖREN	FIAT	OTOMOBİL	GRİ (Mistik)	2008'	UNKNOWN
12	11	34YN2014	BAĞCILAR	RENAULT	AA SEDAN	KIRMIZI (Kiraz)	2001'	UNKNOWN
13	12	34BVP75	KARTAL	FORD	OTOMOBİL	SARI (Kum)	1997'	UNKNOWN
14	13	37AJ850	KASTAMONU	RENAULT	AA SEDAN	BEYAZ	1999'	UNKNOWN
15	14	37AG500	ABANA	HONDA	AA SEDAN	KIRMIZI (Bordo)	2009'	UNKNOWN
16	15	37AB239	ABANA	FORD	AB Heçbek	MAVİ (DENİZ)	2005'	UNKNOWN
17	16	37AB839	ABANA	RENAULT	OTOMOBİL	BEYAZ	1994'	UNKNOWN
18	17	37SE827	KASTAMONU	RENAULT	AA SEDAN	BEYAZ	1992'	UNKNOWN
19	18	06MNT07	ANKARA	RENAULT	OTOMOBİL	MAVİ	1993'	UNKNOWN
20	19	34NJL28	KADIKÖY-İSTANBUL	FIAT	OTOMOBİL	MAVİ (Yıldız)	2005	UNKNOWN
21	20	37SE717	KASTAMONU	FIAT	KAPALI KASA	GRİ (Çöl)	2011'	UNKNOWN
22	21	34EN1362	TUZLA	OPEL	KAPALI KASA	BEYAZ	2000'	UNKNOWN
23	22	37AD554	KASTAMONU	FIAT	KAPALI KASA	GRİ (Mistik)	2009'	UNKNOWN
24	23	37AB343	ABANA	RENAULT	OTOMOBİL	GRİ	2006'	UNKNOWN

Şekil 3.25. Excel'de oluşturulan veri tabanından örnek bir görünüm

Fonksiyon araştırmayı karakter temelli yaparak her bir veri tabanı satırı için uyuşma oranı tanımlamaktadır. Böylelikle %100 uyuşma durumunun yanı sıra 1 ya da 2 karakterlik eksik tanıma durumları da değerlendirmeye alınabilecektir. Yapılan çalışmada en fazla 1 karakterlik eksik tanıma sonucu başarılı olarak değerlendirilmiştir. 8 karakterde 7 karakterin veya 7 karakterde 6 karakterin tanınması oranları düşünülerek eşik değer 0,8 olarak belirlenmiştir. Buna göre tüm sistem performansı %86 olmaktadır.

Tablo 3.12'de OPTS birimlerinin performansı ile farklı sınıflandırma yapıları kullanıldığında tüm sistemin performansının nasıl değiştiği gösterilmektedir. Tablo 3.12'de verilen klasik şablon eşleme yöntemi ile karakter tanıma başarısının düşüklüğünün sebebi; bu yöntemin yazıtipi, rotasyon, kalınlık gibi değişimlere karşı oldukça hassas olmasıdır. Bu nedenle birçok karmaşık sahnenin yer aldığı veri tabanındaki araç imgeleri üzerinde tanıma performansı yetersiz kalmaktadır.

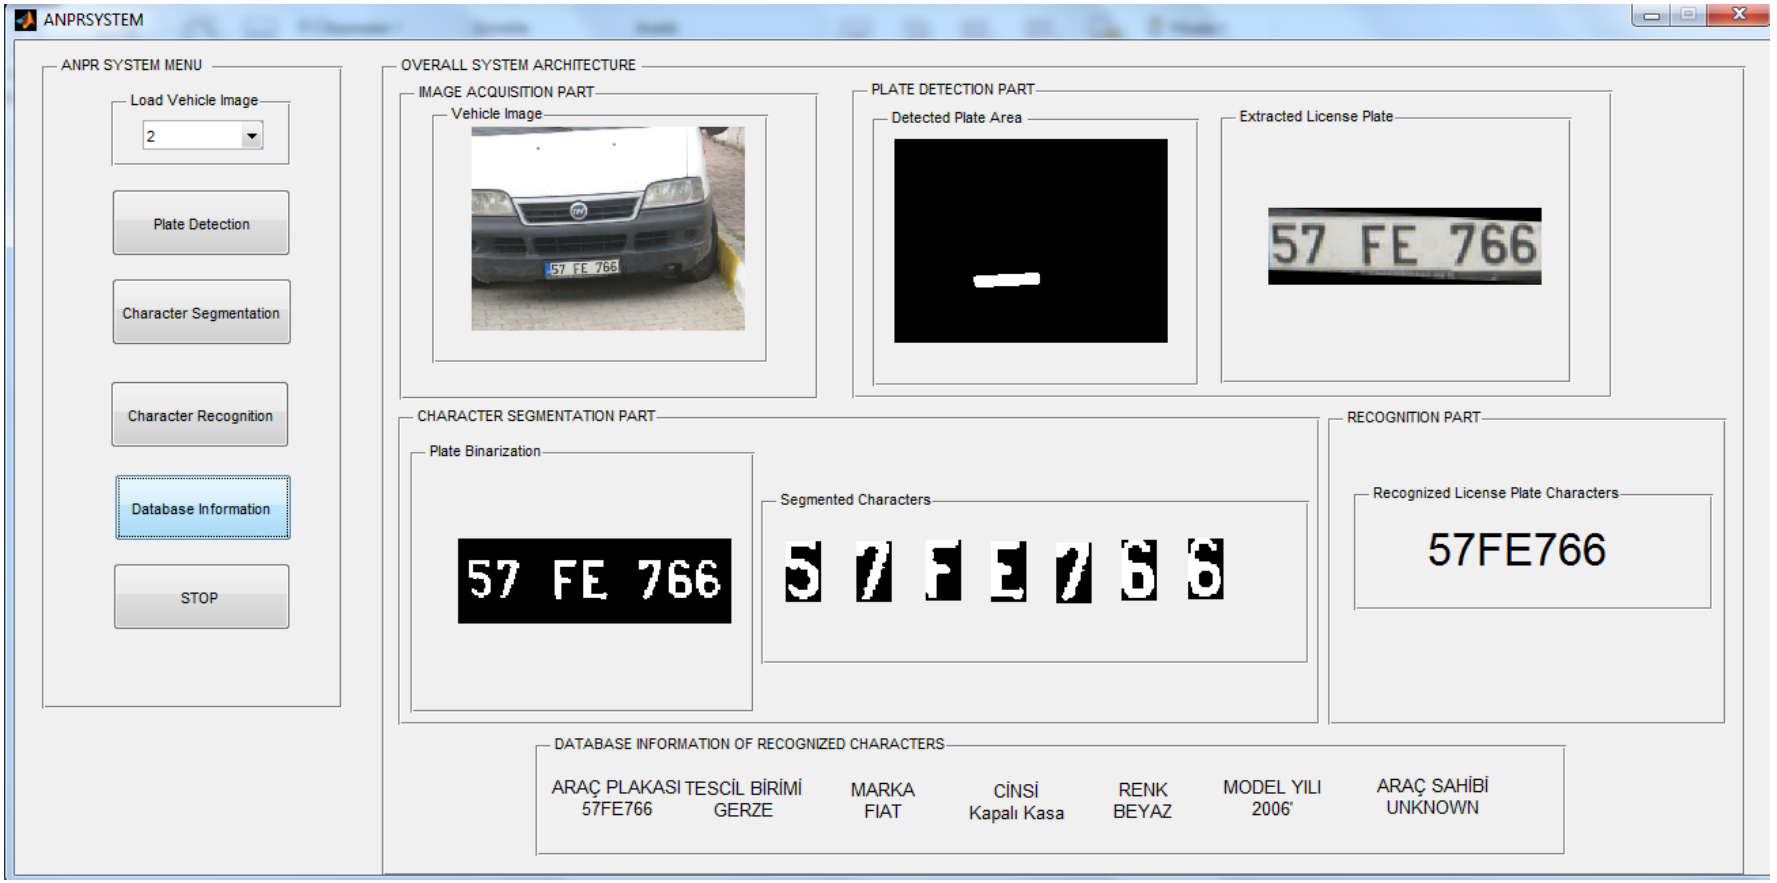
Performans; karakterlerin farklı rotasyonlarda, kalınlıklarda ve yazı tiplerinde şablonları oluşturularak nispeten yükseltilebilir, ancak hesapsal yük de artacaktır.

Tablo 3.12. OPTS birimlerinin performansının gözlenmesi ve farklı sınıflandırma yöntemlerinin tüm sistem performansına etkisi

<table>
<tr><th rowspan="2">Araç Sayısı</th><th rowspan="2">Plaka Tespit Birimi Başarı Oranı</th><th colspan="3">Plaka Tanıma Birimi</th><th rowspan="2">Tüm Sistem Performansı</th></tr>
<tr><th colspan="2">Sınıflandırıcı</th><th>Başarı Oranı</th></tr>
<tr><td rowspan="4">324</td><td rowspan="4">%96
(311)</td><td rowspan="2">MLP</td><td>HOG Hücre boyutu: 4x4</td><td>%89,20
(278)</td><td>%86</td></tr>
<tr><td>HOG Hücre boyutu: 8x8</td><td>%83
(258)</td><td>%80</td></tr>
<tr><td colspan="2">Şablon Eşleme</td><td>%74,69
(233)</td><td>%72</td></tr>
<tr><td colspan="2">Tesseract OCR motoru [53]</td><td>%81
(251)</td><td>%78</td></tr>
</table>

3.4. GUI (Kullanıcı Arayüzü) Tasarımı

Yapılan çalışmayı matematiksel hesaplamalar ve kodlardan arındırarak bir görsellik kazandırabilmek ve kullanım kolaylığı sağlamak amacıyla bir kullanıcı arayüzü tasarlanmıştır. Tasarımda tespit ve tanıma işlemleri beş ayrı aşamada gerçekleştirilmektedir. Bu aşamalar sırasıyla araç imgesinin seçildiği açılır menü, seçilen araç imgesinde plaka bölgesinin algılanıp çıkartıldığı plaka tespit düğmesi, çıkartılan plakanın ikili imge haline getirilip karakterlerin ayrıştırıldığı karakter ayrıştırma düğmesi, ayrıştırılan karakterlerin tanındığı karakter tanıma düğmesi ve tanınan plakaya ait bilgilerin veri tabanından çağrıldığı veri tabanı bilgisi düğmesinden oluşmaktadır. Tasarlanan kullanıcı arayüzü ve örnek bir plakaya ait tespit/tanıma sonuçları Şekil 3.26'de gösterilmektedir.



Şekil 3.26. Tasarlanan arayüz üzerinde örnek tespit ve tanıma sonucunun görüntülenmesi

SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında, karakter özelliklerinden plaka bölgesini bulan, düşük hesapsal yüke sahip bir otomatik plaka tanıma yaklaşımı önerilmiştir. Çalışılan sistem özellikleri; Intel(R) Core(TM) i5-3470 CPU @ 3,20 Ghz 4GB RAM'dır. Algoritma MATLAB® yazılım ortamında koşturulmuştur.

Çalışılan imge boyutları ise 432x576'dır. Veri tabanına günün çeşitli saatlerinde çekilmiş, karmaşık arka plan, değişen araç, kamera uzak-yakın mesafede, çekim açısı içeren 324 imge; yanlış alarmları belirleyebilmek için 90 manzara imgesi; tespit sonuçlarını doğrulayabilmek için de 324 yer doğrusu oluşturulmuştur. Yapılan testlerde plaka yerinin algılanmasında %96; karakterlerin tanınmasında ise %89,2 başarı oranına ulaşılmıştır. Deneysel sonuçlar önerilen yöntemin karmaşık arka plan, değişen aydınlatma koşulları, uzaklık ve eğiklik durumlarında daha hızlı ve başarılı olarak çalıştığını göstermektedir. Plaka bölgesinin algılanması için literatürde sunulan pek çok karmaşık yöntemin aksine önerilen yöntemde plaka tespit adımının işlem yükünü azaltan bir ön işleme adımı sonrasında nx1 boyutlu bir izdüşüm vektörü ve $\hat{I}_c$ vektörü içerisinde aranmaktadır. Tespit sonrası çıkartılan plaka bölgesi görüş açısı değişimlerinden dolayı eğikliğe sahip olabilmektedir. Bu durumda eşikleme gibi işlemler sonrasında birbirine bağlı karakterler oluşabilmektedir. Bu durum karakter tanıma biriminin performansını etkilemektedir. Bu nedenle çıkartılan plaka bölgesi yatay eksen ile paralel hale getirilmiştir. Ardından yatay ve dikey izdüşümden yararlanılarak plaka çerçevesi çıkartılmış ve gürültülü bölgeler temizlenerek karakterler ayrıştırılmıştır. Ayrıştırılan karakterler karakter tanıma birimine gönderilmiştir. Karakterlerin tanınması aşamasında çok katmanlı algılayıcı modelinden yararlanılmıştır. Tüm sistem performansı Tablo 3.12'de gösterilmektedir. Önerilen yöntemde karakter özelliklerinden yararlanılarak plaka bölgesi tespit edildiği için; Şekil 2.20'de gösterildiği gibi plaka karakter puntolarının aşırı büyük olması, plakanın deforme olması, plaka üzerinde fazlaca kirin bulunması, bazı ya da tüm plaka karakterlerinin silik olması durumlarında başarısız sonuçlar üretilmektedir. İleriki çalışmalarda bu sorun üzerinde durulacaktır.

KAYNAKLAR

[1] Yalım B., Türk Sivil Plaka Standartları İçin Araç Plaka Tanıma Sistemi, Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara, 2008, 216334.

[2] Günaydın A. G, A Constraint Based Real-Time License Plate Recognition System, Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2007, 199355.

[3] Ibrahim M., Shehata M, Badawy W., Automatic License Plate Recognition (ALPR): A State-of-the-Art Review, *IEEE Transactions on Circuits and Systems for Video Technology*, 2013, **23**(2), 311-325.

[4] Anagnostopoulos C.-N. E., License Plate Recognition: A Brief Tutorial, *IEEE Intelligent Transportation Systems Magazine*, 2014, **6**(1), 59-67.

[5] Tomasetti R., Frechette S., Passive Automatic Vehicle Identification System, http://xfactor.wpi.edu/Works/MQP/mpq/mpq.html, (Ziyaret tarihi: 11 Ocak 2015).

[6] Yavuz G., Plaka Tanıma Sistemi, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 2008, 216224.

[7] http://www.worldlicenseplates.com, (Ziyaret tarihi: 11 Ocak 2015).

[8] Gonzalez R. C., Woods R. E., *Digital Image Processing*, 3rd. ed., Prentice Hall, New Jersey, 2008.

[9] Sezgin M, Sankur B., Survey over Image Thresholding Techniques and Quantitative Performance Evaluation, *Journal of Electronic Imaging*, 2004, **13**(1), 146–165.

[10] Singh T. R., Roy S., Singh O. I., Tejmani S., Singh K. M., A New Local Adaptive Thresholding Technique in Binarization, *IJCSI International Journal of Computer Science Issues*, 2011, **8**(6), 271-277.

[11] Otsu N., A Threshold Selection Method from Gray-Level Histogram, *IEEE Transactions on System Man Cybernetics*, 1979, **9**(1), 62-66.

[12] Niblack W., *An Introduction to Digital Image Processing*, 1st. ed., Prentice Hall, New Jersey, 1986.

[13] Sauvola J., Pietikainen M., Adaptive Document Image Binarization, *Pattern Recognition*, 2000, **33**(2), 225-236.

[14] Viola P., Jones M. J., Robust Real-Time Face Detection, *International Journal of Computer Vision*, 2004, **57**(2), 137–154.

[15] Jain R., Kasturi R., Schunck B. G, *Machine Vision*, 1st. ed., McGraw Hill, New York, 1995.

[16] D. Zheng, Y. Zhao, and J. Wang, An Efficient Method of License Plate Location, *Pattern Recognition Letters*, 2005, **26**(15), 2431–2438.

[17] Al-Ghaili A. M., Mashohor S., Ismail A., Ramli A. R., A New Vertical Edge Detection Algorithm and Its Application, *in Proc. Int. Conf. Comput. Eng. Syst.*, Cairo, 25-27 November 2008.

[18] Lee H.-J., Chen S.-Y., Wang S.-Z., Extraction and Recognition of License Plates of Motorcycles and Vehicles on Highways, *IEEE 17th. International Conference on Pattern Recognition*, Cambridge, United Kingdom, 23-26 August 2004.

[19] Zunino R., Rovetta S., Vector Quantization for License Plate Location and Image Coding, *IEEE Transactions on Industrial Electronics*, 2000, **47**(1), 159-167.

[20] Anagnostopoulos C.-N. E., Anagnostopoulos I. E., Loumos V., Kayafas E., A License Plate-Recognition Algorithm for Intelligent Transportation System Applications, *IEEE Transactions on Intelligent Transportation Systems*, 2006, **7**(3), 377–392.

[21] Kahraman F., Kurt B., Gokmen M., License Plate Character Segmentation Based on the Gabor Transform and Vector Quantization, *18th International Symposium on Computer and Information Sciences*, Antalya, Turkey, 3-5 November 2003.

[22] Chang S.-L., Chen L.-S., Chung Y.-C., Chen S.-W., Automatic License Plate Recognition, *IEEE Transactions on Intelligent Transportation Systems*, 2004, **5**(1), 42-53.

[23] Jia W., Zhang H., He X., Region-Based License Plate Detection, *Journal of Network and Computer Applications*, 2007, **30**(4), 1324–1333.

[24] Matas J., Zimmermann K., Unconstrained License Plate and Text Localization and Recognition, *2005 IEEE Intelligent Transportation Systems Conference*, Vienna, Austria, 13-15 September 2005.

[25] Epshtein B., Ofek E., Wexler Y., Detecting Text in Natural Scenes with Stroke Width Transform, *2010 IEEE Conference on Computer Vision and Pattern Recognition*, San Francisco, CA, 13-18 June 2010.

[26] Jobin K., Anurenjan P., Jiji C., Automatic Number Plate Recognition System Using Modified Stroke Width Transform, *2013 Fourth National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG)*, Jodhpur, 18-21 December 2013.

[27] Alegria F., Girao P. S., Vehicle Plate Recognition For Wireless Traffic Control and Law Enforcement System, *2006 IEEE International Conference on Industrial Technology (ICIT 2006)*, Mumbai, 15-17 December 2006.

[28] http://darwin.unmc.edu/dxtests/Default.htm, (Ziyaret tarihi: 15 Ocak 2015).

[29] Keilthy L., ANPR System Performance, Parking Trend International, http://nebula.wsimg.com/496959ac4558db3f7dddddc81ee2f8a6?AccessKeyId=4CB8F2392A09CF228A46&disposition=0&alloworigin=1, (Ziyaret tarihi: 15 Ocak 2015).

[30] Zhu W., Zeng N, Wang N., Sensitivity, Specificity, Accuracy, Associated Confidence Interval and ROC Analysis with Practical SAS Implementations, *NESUG Proceedings: Health Care and Life Sciences*, Baltimore, Maryland, 14-17 November 2010.

[31] Rumelhart D. E., Hinton G. E., Williams R. J., Learning Representations by Back-propagating Errors, *Nature*, DOI:10.1038/323533a0.

[32] Zhang Y., Zhang C., A New Algorithm for Character Segmentation of License Plate, *2003 IEEE Intelligent Vehicles Symposium*, Columbus, OH, USA, 9-11 June 2003.

[33] Kanayama K., Fujikawa Y., Fujimoto K., Horino M., Development of Vehicle-License Number Recognition System Using Real-Time Image Processing and Its Application to Travel-Time Measurement, *41st IEEE Vehicular Technology Conference*, St. Louis, MO, 19-22 May 1991.

[34] Miyamoto K., Nagano K., Tamagawa M., Fujita I., Yamamoto M., Vehicle License-Plate Recognition by Image Analysis, *1991 IEEE International Conference on Industrial Electronics, Control and Instrumentation*, Kobe, 28 October-1 November 1991.

[35] Zhang S., Zhang M., Ye X., Car Plate Character Extraction under Complicated Environment, *2004 IEEE International Conference on Systems, Man and Cybernetics*, The Hague, 10-13 October 2004.

[36] Comelli P., Ferragina P., Granieri M. N., Stabile F., Optical Recognition of Motor Vehicle License Plates, *IEEE Transactions on Vehicular Technology*, 1995, **44**(4), 790 – 799.

[37] Sarfraz M., Ahmed M. J., Ghazi S. A., Saudi Arabian License Plate Recognition System, *2003 International Conference on Geometric Modeling and Graphics*, London, UK, 16-18 July 2003.

[38] Naito T., Tsukada T., Yamada K., Kozuka K., Yamamoto S., Robust License-Plate Recognition Method for Passing Vehicles under Outside Environment, *IEEE Transactions on Vehicular Technology*, 2002, **49**(6), 2309 – 2319.

[39] Rahman C. A., Badawy W., Radmanesh A., A Real Time Vehicle's License Plate Recognition System, *IEEE Conference on Advance Video and Signal Based Surveillance*, Miami, FL, USA, 21-22 July 2003.

[40] Dia Y., Zheng N., Zhang X., Xuan G., Automatic Recognition of Province Name on the License Plate of Moving Vehicle, *9th International Conference on Pattern Recognition*, Rome, 14-17 November 1988.

[41] Hegt H. A., Haye R. J., Khan N.A., A High Performance License Plate Recognition System, *1998 IEEE International Conference on Systems, Man, and Cybernetics*, San Diego, CA, 11-14 October 1998.

[42] Aghdasi F., Ndungo H., Automatic License Plate Recognition System, *7th AFRICON Conference in Africa*, Gaborone, 17-17 September 2004.

[43] Nukano T., Fukumi M., Khalid M., Vehicle License Plate Character Recognition by Neural Networks, *Proceedings of 2004 International Symposium on Intelligent Signal Processing and Communication Systems*, Seoul, South Korea 18-19 November 2004.

[44] Hu P., Zhao Y., Wang J., Recognition of Gray Character Using Gabor Filters, *Proceedings of the Fifth International Conference on Information Fusion*, Annapolis, MD, USA, 8-11 July 2002.

[45] Abdullah S. N. H. S., Khalid M., Yusof R., Omar K., License Plate Recognition Using Multicluster and Multilayer Neural Networks, *2nd Information and Communication Technologies Conference*, Damascus, 24-28 April 2006.

[46] Dalal N., Triggs B., Histograms of Oriented Gradients for Human Detection, *IEEE Conference on Computer Vision and Pattern Recognition*, San Diego, CA, USA, 25-25 June 2005.

[47] Jiao J., Ye Q., Huang Q., A Configurable Method for Multistyle License Plate Recognition, *Pattern Recognition*, 2009, **42**(3), 358–369.

[48] Kim K. K., Kim K. I., Kim J. B., Kim H. J., Learning-Based Approach for License Plate Recognition, *in Proc. IEEE Signal Process. Soc. Workshop Neur. Netw. Signal Process.*, Sydney, NSW, 11-13 December 2000.

[49] Llorens D., Marzal A., Palazon V., Vilar J. M., Car License Plates Extraction and Recognition Based on Connected Components Analysis and HMM Decoding, *Lecture Notes in Computer Science*, DOI:10.1007/11492429_69.

[50] http://algoval.essex.ac.uk/icdar/Datasets.html, (Ziyaret tarihi: 5 Haziran 2015).

[51] Simon Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd ed., Prentice Hall, USA, 1998.

[52] Faradji F., Rezaie A.H., Ziaratban M., A Morphological-Based License Plate Location, *IEEE International Conference on Image Processing (ICIP 2007)*, San Antonio, TX, 16 September – 19 October 2007.

[53] Kay A., Tesseract: an Open-Source Optical Character Recognition Engine, http://www.linuxjournal.com/article/9676, (Ziyaret tarihi: 13 Ekim 2015).

KİŞİSEL YAYIN VE ESERLER

Öksüz C., Güllü M. K., Uyarlamalı Yerel Eşikleme Temelli Plaka Tespiti, *SİU 2015-23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Malatya, 16-19 Mayıs 2015.

ÖZGEÇMİŞ

1986 yılında Aydın'da doğdu. İlk, orta ve lise öğrenimini Kuşadası'nda tamamladı. 2005 yılında girdiği Kocaeli Üniversitesi Elektronik Öğretmenliği programını 2009 yılında tamamladı. 2010-2013 yılları arasında Aydın Adnan Menderes Üniversitesi Aydın Meslek Yüksekokulu Elektronik ve Otomasyon bölümünde dersler verdi. 2013-2014 Bahar yarıyılından itibaren Kastamonu Üniversitesi'nde Öğretim Görevlisi olarak çalışmaktadır. 2010-2011 Bahar döneminde Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Ana Bilim Dalı'nda yüksek lisans eğitimine başladı. 2015-2016 Güz döneminde mezun olma durumundadır.