

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DAİRESEL ŞEKİL HİSTOGRAMI İLE MAKİNE ÖĞRENMESİNE DAYALI PLAKA
TANIMA ÇALIŞMASI

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

SEDAT DİKİCİ

ARALIK 2019

ZONGULDAK BÜLENT ECEVİT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DAİRESEL ŞEKİL HİSTOGRAMI İLE MAKİNE ÖĞRENMESİNE DAYALI PLAKA
TANIMA ÇALIŞMASI

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Sedat DİKİCİ

DANIŞMAN : Dr. Öğr. Üyesi Rukiye UZUN ARSLAN

İKİNCİ DANIŞMAN : Dr. Öğr. Üyesi Mürsel Ozan İNCETAŞ

ZONGULDAK

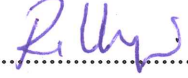
Aralık 2019

KABUL:

Sedat DİKİCİ tarafından hazırlanan “Dairesel Şekil Histogramı ile Makine Öğrenmesine Dayalı Plaka Tanıma Çalışması” başlıklı bu çalışma jürimiz tarafından değerlendirilerek Zonguldak Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak oybirliğiyle kabul edilmiştir.
16/12/2019

Danışman: Dr. Öğr. Üyesi Rukiye UZUN ARSLAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü




Üye : Doç. Dr. Yusuf ALTUN

Düzce Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü



Üye : Dr. Öğr. Üyesi İbrahim ALIŞKAN

Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü



ONAY:

Yukarıdaki imzaların, adı geçen öğretim üyelerine ait olduğunu onaylarım.

.../.../2019



Prof. Dr. Ahmet ÖZARSLAN
Fen Bilimleri Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”


Sedat DİKİCİ

ÖZET

Yüksek Lisans Tezi

DAİRESEL ŞEKİL HISTOGRAMI İLE MAKİNE ÖĞRENMESİNE DAYALI PLAKA TANIMA ÇALIŞMASI

Sedat DİKİCİ

Zonguldak Bülent Ecevit Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Dr. Öğr. Üyesi Rukiye UZUN ARSLAN

İkinci Danışman: Dr. Öğr. Üyesi Mürsel Ozan İNCETAŞ

Aralık 2019, 57 sayfa

Bu çalışmada, dairesel şekil histogramı ile plaka karakterlerine ait özellik vektörleri oluşturarak yeni bir plaka tanıma yöntemi sunulmuştur. Öncelikle literatürdeki plaka tanıma yöntemleri, plaka karakterlerine ait özellik çıkarım yöntemleri ve bu yöntemler doğrultusunda karakterlerin sınıflandırılma yöntemleri tanıtıldı. Daha sonra sayısal görüntü histogram çeşitlerinden dairesel şekil histogram modelleri tanıtıldı. Söz konusu dairesel şekil histogramı ile plaka karakterlerinin özellik vektörlerinin oluşturulabilmesi için plaka görüntüleri üzerinde gerçekleştirilmesi gereken bazı ön işlemler vardır. Bu doğrultuda, plaka görüntüleri üzerindeki gürültüler azaltılarak, karakterleri farklı nesnelere olarak inceleyebilmek için eşikleme ve bölütleme işlemleri uygulandı. Karakterlere ait özellik vektörlerinin elde edilebilmesi için dairesel şekil histogram modellerinden en uygun model tespit edildi. Elde edilen özellik vektörleri iki farklı yöntem ile sınıflandırıldı. Özellik vektörlerinin matematiksel olarak

ÖZET (devam ediyor)

benzerliklerinin ölçüldüğü lineer yöntem ve yapay sinir ağı kullanılarak makine öğrenmesine dayalı yöntem ile karakterlerin tespit edilmesi sağlandı. Bu sayede mevcut özellik çıkarım yöntemlerine göre daha az eleman sayısına sahip özellik çıkarım yöntemi geliştirilmiştir.

Anahtar Kelimeler: Karakter tanıma, Plaka tanıma, Özellik çıkarımı, Şekil Histogramı

Bilim Kodu: 608.04.06



ABSTRACT

M. Sc. Thesis

LICENSE PLATE RECOGNITION BASED ON MACHINE LEARNING WITH CIRCULAR SHAPE HISTOGRAM

Sedat DİKİCİ

**Zonguldak Bülent Ecevit University
Graduate School of Natural and Applied Sciences
Department of Electrical and Electronics Engineering**

Thesis Advisor: Assist. Prof. Dr. Rukiye UZUN ARSLAN

Co-Advisor: Assist. Prof. Dr. Mürsel Ozan İNCETAŞ

December 2019, 57 pages

In this study, a license plate recognition method is presented by constructing feature vectors of license plate characters with circular shape histogram. Firstly, plate recognition methods in the literature, property extraction methods of plate characters and classification methods of characters in line with these methods were introduced. Then, circular shape histogram models of digital image histogram types are introduced. There are some preliminary operations that must be performed on the plate images in order to generate feature vectors of the plate characters with circular shape histogram. Accordingly, the noise on the plate images were reduced and segmentation and thresholding operations were performed in order to examine the characters as different objects. In order to obtain the feature vectors of the characters, the most suitable model was determined from the circular shape histogram models. The obtained feature vectors were classified by two different methods. The characters were determined by linear

ABSTRACT (continued)

method and the method based on machine learning with artificial neural network in which statistical similarities of feature vectors were measured. In this way, feature extraction method with less number of elements was developed compared to existing feature extraction methods.

Keywords: Character recognition, Plate recognition, Feature extraction, Figure Histogram

Science Code: 608.04.06



TEŐEKKÜR

Yüksek Lisans tez çalışmamda her türlü bilgi ve tecrübelerini benden esirgemeyen, saygıdeğer danışman hocalarım Sayın Dr. Öğr. Üyesi Rukiye UZUN ARSLAN ve Dr. Öğr. Üyesi Mürsel Ozan İNCETAŐ' a içtenlikle teşekkür ederim.

Hayatımın tüm anlarında, sevgi ve desteğini her daim hissettiğim çok kıymetli hayat arkadaşım Fehime DAĞ DİKİCİ' ye teşekkür ederim. Bu günlere getirebilmek adına hiç bir fedakarlıktan kaçınmayan, emek ve sevgilerini esirgemeyen çok sevgili annem Saniye DİKİCİ' ye, babam Erhan DİKİCİ' ye ve çok kıymetli abi ve ablalarımaya sonsuz teşekkür ederim. Eğitim hayatım boyunca maddi manevi desteğini esirgemeyen çok kıymetli abim Bilal AYAYDIN'a teşekkür ederim. Ayrıca tez sürecim boyunca ilgi ve alakaları ile bana güç ve şevk veren çok kıymetli Kayınbabam ve Kayınvalidem'e çok teşekkür ederim.

Yüksek Lisans eğitimim boyunca her daim yanıma olup maddi ve manevi desteklerini esirgemeyen değerli çalışma arkadaşım Arş. Gör. Rıdvan KESKİN' e teşekkür ederim.



İÇİNDEKİLER

	<u>Sayfa</u>
KABUL	ii
ÖZET.....	iii
ABSTRACT	v
TEŞEKKÜR	vii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ.....	xv
BÖLÜM 1 GİRİŞ	1
1.1 LİTERATÜR İNCELEMESİ	2
1.2 TEZİN AMACI VE ORGANİZASYONU	3
BÖLÜM 2 PLAKA KARAKTERLERİNİN AYRIŞTIRILMASI VE SINIFLANDIRILMASI	5
2.1 KARAKTER TANIMA YÖNTEMLERİ	5
2.1.1 Görüntü Piksellerinin Kullanılması ile Karakter Tanıma	5
2.1.2 Özellik Vektörleri Oluşturarak Karakter Tanıma	7
2.2 KARAKTER TANIMA ÇALIŞMALARINDA KULLANILAN SINIFLANDIRMA YÖNTEMLERİ	10
BÖLÜM 3 ŞEKİL HİSTOGRAMI	13
3.1 HİSTOGRAM	14
3.2 DAİRESEL ŞEKİL HİSTOGRAMI	16

İÇİNDEKİLER (devam ediyor)

	<u>Sayfa</u>
BÖLÜM 4 MATERYAL VE YÖNTEM.....	21
4.1 ÖZELLİK ÇIKARIMI ÖNCESİ ÖN İŞLEMLER.....	23
4.1.1 Renkli Plaka Görüntülerinin Gri Seviye Görüntüye Dönüştürülmesi	24
4.1.2 Plaka Görüntülerinde Gürültülerin Giderilmesi.....	25
4.1.3 Eşikleme ile Görüntünün İkili Formata Çevrilmesi.....	26
4.1.4 Görüntüdeki Nesnelerin Etiketlendirilmesi	27
4.2 DAİRESEL ŞEKİL HİSTOGRAMI İLE KARAKTER ÖZELLİKLERİNİN ÇIKARILMASI.....	28
4.3 KARAKTERLERİN SINIFLANDIRILMASI.....	38
4.3.1 Lineer Yöntem ile Karakterlerin Sınıflandırılması	38
4.3.2 Makine Öğrenmesine Dayalı Karakter Sınıflandırma	42
BÖLÜM 5 BULGULAR VE TARTIŞMA.....	45
5.1 LİNEER YÖNTEM İLE KARAKTER TANIMA SONUÇLARI.....	45
5.2 YAPAY SİNİR AĞLARI İLE KARAKTER TANIMA SONUÇLARI	46
5.3 ÖNERİLEN SINIFLANDIRMA YÖNTEMLERİN KARŞILAŞTIRILMASI.....	47
BÖLÜM 6 SONUÇ VE ÖNERİLER.....	49
KAYNAKLAR.....	51
ÖZGEÇMİŞ	57

ŞEKİLLER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Şekil 2.1 Karakterlerin yatay ve dikey izdüşümleri.	8
Şekil 2.2 Yatay ekseninde kaymış bir karakterin ve düz bir karakterin alt ve üst kısımlarının bir doğru ile birleştirilmesi.	9
Şekil 3.1 Sayısal görüntüleri oluşturan pikseller.	13
Şekil 3.2 Örnek bir görüntünün çeşitli gri seviye dağılımları ve histogramları.	14
Şekil 3.3 Dairesel şekil histogram modelleri	16
Şekil 3.4 ‘A’ ve ‘Z’ Harflerinin kabuk modeli şekil histogramı ile incelenmesi.	17
Şekil 3.5 ‘A’ ve ‘Z’ Harflerinin sektör modeli şekil histogramı ile incelenmesi.	18
Şekil 3.6 ‘A’ ve ‘Z’ Harflerinin örümcek ağı modeli şekil histogramı ile incelenmesi.	19
Şekil 4.1 Plaka fontları.	21
Şekil 4.2 Önerilen yöntemeye ait akış diyagramı.	23
Şekil 4.3 Renkli görüntünün gri seviye görüntüye dönüştürülmesi.	24
Şekil 4.4 Ortalama filtre matrisi.	25
Şekil 4.5 Plaka görüntüsü üzerinde ortalama filtre uygulanması.	26
Şekil 4.6 Otsu metodu ile plaka görüntüsünün ikili formata çevrilmesi.	27
Şekil 4.7 Plaka karakterlerinin ayrıştırılması.	28
Şekil 4.8 Dairesel şekil histogram modelleri.	30
Şekil 4.9 4 çemberli model (a) ve 8 çemberli model (b).	31
Şekil 4.10 4 kesit ve 2 çemberli model (a), 4 kesit ve 4 çemberli model (b).	32
Şekil 4.11 8 kesitli model	33
Şekil 4.12 8 kesit ve 2 çemberli model (a), 8 kesit ve 4 çemberli model (b).	34
Şekil 4.13 16 kesitli model (a), 16 kesit ve 2 çemberli model (b).	35
Şekil 4.14 17 elamanlı dairesele şekil histogramı ve plaka görüntüsü üzerinde uygulanması. .	36
Şekil 4.15 ‘B’ ve ‘D’ harflerine ait özellik vektörleri.	37
Şekil 4.16 ‘B’ harfine ait özellik vektörlerinin elde edilmesi.	39
Şekil 4.17 Plaka karakterleri arasındaki mesafelerin incelenmesi.	40
Şekil 4.18 Çok katmanlı algılayıcı modeli.	43
Şekil 4.19 Harf ve rakamlar için oluşturulan ileri yayımlı yapay sinir ağları.	44



ÇİZELGELER DİZİNİ

<u>No</u>	<u>Sayfa</u>
Çizelge 4.1 Türkiye'deki araç plakalarının genel yapısı.....	21
Çizelge 4.2 Örnek plaka karakterlerinin tüm karakterlerine ait hata değerleri.	41
Çizelge 5.1 Lineer yöntem ile karakter tanıma sonuçları.....	46
Çizelge 5.2 Yapay Sinir Ağları ile karakter tanıma sonuçları.....	47
Çizelge 5.3 Diğer çalışmalar ile karşılaştırma sonuçları.....	48





SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

sn	: saniye
μ	: ortalama deęer
σ	: varyans

KISALTMALAR

DVM	: Destek Vektör Makineleri
EPM	: Etiketlendirilmiş Plaka Matrisi
GYSA	: Geri Beslemeli Yapay Sinir Aęı
İYSA	: İleri Yayılımlı Yapay Sinir Aęı
KPS	: Karakter Piksel Sayısı
OKT	: Optik Karakter Tanıma
SPS	: Sektör Piksel Sayısı



BÖLÜM 1

GİRİŞ

Karakter tanıma, dijital çağın gelişmesiyle birlikte günümüzde ortaya çıkan; kâğıt, para, plaka ve her türlü dijital baskı yazı ve sayıların bilgisayar ortamında tanınmasını sağlayan bir görüntü işleme alanıdır. Bilgisayarlar, kamera ya da tarayıcılar ile elde edilen, içerisinde harfler, sayılar ve semboller barındıran bir bölgedeki karakterleri, çeşitli piksel gruplarından oluşan bir sayısal görüntü olarak algırlar. Bu piksel gruplarının ifade ettiği anlamları ortaya çıkarmak için karakterlerin sahip oldukları belirli görsel dayanaklara göre tanımlamaya ihtiyaç duyulmaktadır. Çeşitli yöntemler aracılığıyla bankamatikler banknotları seçip gruplandırabilir, tek tek metin haline getirilmesi istenilen kitaplar hızlıca yazı dosyaları haline getirilebilir ve trafikteki araçların taşıdıkları plaka numaraları hızlıca tespit edilebilir. Bu sayede otoyollardaki düzenin sağlanması ve kuralların uygulanabilmesi, daha az personel ile daha hızlı bir şekilde gerçekleştirilebilir.

Dijital ortamda tüm resimler, piksel denilen renk ya da gri seviye değerine sahip en küçük görsel taneciklerden oluşmaktadır. Pikseller, yatay ve düşey düzlemde bir araya gelerek 2 boyutlu bir görüntüyü meydana getirirler. Bilgisayar için her görüntü, piksel değerlerinden oluşan iki boyutlu bir matristir. Görüntü içeriğindeki cisim, harf, sayı ya da herhangi bir nesneyi tanımak akıl gerektirir. Bir görüntü içerisinde yazılar olduğunu insan kendi zihniyle algılar, tanımlar ve bunu çözümlyerek okuyabilir. Görüntü içerisinde karakterler olduğunu ve bunların hangi sayı, harf ya da sembolü temsil ettiğini ortaya çıkarabilmek için bilgisayarın bu işlemi çeşitli karakter tanıma uygulamaları ile yapması gerekmektedir. Çünkü insanın okuyup algılayabildiği harf, sayı ya da sembollerden oluşan yazılar, bilgisayar için sadece piksel değerlerinden oluşan matrislerdir. Bu işlemlerin doğru ve hızlı şekilde yapılabilmesi için günümüze kadarki süreçte çok çeşitli karakter tanıma metotları geliştirilmiştir.

Karakter tanımanın çok yaygın olarak kullanıldığı bir alan da plaka tanımadır. Tüm motorlu taşıtların kendisine ait özel bir plaka kodu vardır. Bu kodlar çeşitli harf ve rakamlardan

oluşmaktadır. Otoyollarda araçların hız limitlerini kontrol etmek, adli işlemler gerektiren durumlarda araçların kameralar ile tespit edilmesini sağlamak, otoyol geçiş ücretlerinin tahsil edilmesi, otoparklarda hızlıca giriş ve çıkışın sağlanabilmesi, özel ya da kamusal alanlara giriş ve çıkışların otomatik yapılabilmesi gibi çok çeşitli ihtiyaçların karşılanabilmesi için bu teknolojiden faydalanılmaktadır. Araçların belirli hızlarının olması, hava şartlarının bazen görüntüyü olumsuz etkileyebilmesi, plaka karakterlerinin farklı yazı tiplerinden oluşması, kamera açılarının değişkenlikler gösterebilmesi ve çok sayıda aracın kısa sürede atlanmadan tespit edilmesi gerekliliği gibi zorluklar mevcuttur. Bu çeşitli koşullarda plakaların doğru ve hızlı bir şekilde tespit edilebilmesi için üretilen sistemlerin olabildiğince doğru sonuçları azami sürede ve hızda yapması beklenmektedir.

1.1 LİTERATÜR İNCELEMESİ

Literatürdeki plaka tespit çalışmalarında kullanılan karakter tanıma yöntemleri temel olarak ikiye ayrılmaktadır. Bunlar şablon eşleştirme yöntemleri ve özellik çıkarım yöntemleridir. Şablon eşleştirme yöntemi, bir veritabanında ya da bir yapay zekâ katmanlarında tüm karakter piksel bilgilerinin tutulduğu yöntemdir. Bu yöntem, tespit edilmesi amaçlanan aday karakter pikselleri ile eldeki karakter piksellerinin çeşitli şekillerde karşılaştırılması ile en uygun karakterin seçildiği bir yöntemdir [1]. 2000 yılında yapılan bir çalışmada [2], tüm karakterlerin çeşitli yazı tiplerindeki plaka görüntülerine ait şablonlar ile eşleştirilmeler yapılmıştır. Çeşitli plaka görüntülerinden elde edilen 400 karakter görüntüsü için %97,2'lik doğru karakter tespit oranı elde edilmiştir. 2009 yılında yapılan bir çalışmada [3] plaka karakterleri 76 pikselden oluşan karakter şablonları ile eşleştirilerek %97,3'lük bir başarı oranı elde edilmiştir. Şablon eşleştirme yönteminin kullanıldığı başka bir çalışmada 20x100 piksel boyutlarına sahip şablonlar ile plaka karakterleri eşleştirilmiştir [4]. 2005 yılında yapılan bir başka çalışmada [5], karakter aday bölgesinin karakterler ile benzerliklerini hesaplamak için çapraz korelasyon işlemi [6] kullanılmıştır.

Özellik çıkarım yöntemlerinde ise, karakter piksellerinin tamamı karşılaştırılmaz. Karakter görüntüsü içerisinde belirli piksel grupları oluşturulur. Oluşturulan piksel gruplarından çeşitli yaklaşımlar ile sayısal veri dizileri oluşturulur. Oluşturulan veri dizilerinin sayısal benzerlikleri doğrultusunda karakter tespiti yapılır. Özellik çıkarımı ile plaka tanıma çalışmalarında kullanılan yöntemlerden yatay/dikey izdüşüm yöntemi ile karakterlerin bir satır ya da sütun boyunca sahip olduğu piksel sayıları ile özellik vektörleri elde edilmiştir [7]. 2004 yılında

yapılan bir çalışmada karakterler, pencereleme yöntemi ile 3x4 piksellik bölgelere ayrılmış ve tüm ayrılan bölgelerdeki karakter piksel sayıları ile özellik vektörleri elde edilmiştir [8]. Aynı yıl yapılan bir başka çalışmada, karakterler 3x3 piksel boyutlarındaki bölgelere ayrılmış ve tüm alt bölgelerdeki çeşitli eğimlere sahip çizgiler ile karakter özellik vektörleri elde edilmiştir [9]. 2004 yılında yapılan başka bir çalışmada, karakterin en alt ve en üst noktalarını birleştiren bir doğru boyunca, karakter pikselleri ile arka plan pikselleri arasındaki geçiş sayıları ve söz konusu piksel sayıları ile karakter özellik vektörleri oluşturulmuştur. Ko ve Kim tarafından yapılan bir çalışmada, plaka karakterini çevreleyen kenar çizgilerinin konumsal değişimlerini gösteren bir işaret üretilerek karakterlere ait özellik vektörleri ortaya konmuştur. 2006 yılında yapılan bir çalışmada [10], aday karakterlere Kirch Kenar Belirleme Algoritması [11] uygulanarak karakter kenar sayıları elde edilmiş ve elde edilen kenar bilgileri ile karakter özellik vektörleri oluşturulmuştur. Jiao ve arkadaşları [12] tarafından yapılan bir çalışmada ise karakterler birbirinden farklı boyutlara ve şekillere sahip alt bloklara ayrılarak çeşitli konumlardaki karakter piksel yoğunlukları ile özellik vektörleri elde edilmiştir.

1.2 TEZİN AMACI VE ORGANİZASYONU

Bu tez kapsamında, plaka karakterlerinin hızlı ve etkili bir şekilde tespit edilmesi için yeni bir özellik çıkarım yöntemi önerilmiştir. Özellik çıkarım yöntemleri, plakalardaki yazı tipi değişkenlikleri ve görüntülerdeki bozukluklara karşı daha kararlı sonuçlar verebilen yöntemlerdir. Ayrıca incelenen veri sayısının daha az olması, işlem hızı açısından şablon eşleştirme yöntemlerine karşı daha avantajlı bir yöntem olmasını sağlamaktadır. Bu amaç doğrultusunda, görüntü içerisindeki nesnelerin tanımlanmasında kullanılan şekil histogramından yararlanılmıştır. Plaka karakterleri dairesel bölge içerisine alınarak çeşitli bölgelere ayrılmıştır. Ayrılan bölgelerdeki karakter piksel yoğunlukları ile karakter özellik vektörleri elde edilmiştir. Söz konusu özellik vektörleri, lineer sınıflandırma yöntemi ve Yapay Sinir Ağı (YSA) kullanılarak iki farklı yöntem ile sınıflandırılmıştır. Bu sayede söz konusu özellik vektörleri ile daha hızlı bir plaka tanıma çalışması yapılması amaçlanmıştır.

Bu çalışmada ilk olarak (Bölüm 2), plaka tanıma yöntemleri hakkında genel bilgiler verilmiştir. Literatürde, karakterlerin eşleştirilme aşamasında uygulanan yaklaşımlar ve karakterlerin sınıflandırılması için kullanılan yöntemlerden bahsedilmiştir.

Üçüncü bölümde, sayısal görüntü hakkında bilgi veren histogram kavramından bahsedilmiştir. Karakterlerin özellik vektörlerini elde etmek için kullanılan dairesel şekil histogramı anlatılmıştır. Dairesel şekil histogram modelleri ve söz konusu modeller ile karakter analizleri ele alınmıştır.

Dördüncü bölümde, Türkiye'deki mevcut plaka yapıları hakkında genel bilgiler verilmiştir. Plaka karakterlerinin incelenmesi için uygulanan çeşitli ön işlemler anlatılmıştır. Plaka görüntülerinde yapılan iyileştirmeler, karakterlerin ayrıştırılması için yapılan eşikleme işlemi ve karakterlerin dairesel şekil histogramı ile özellik vektörlerinin elde edilme aşamaları ayrıntılı bir şekilde anlatılmıştır. Elde edilen özellik vektörlerinin, lineer yöntem ve YSA ile sınıflandırılması ile karakterlerin tespit edilmesi araştırılmıştır.

Beşinci bölümde, plaka karakterlerine ait özellik vektörlerinin her iki sınıflandırma yöntemi ile sınıflandırılarak, çeşitli plaka görüntüleri üzerinden elde edilen sonuçlar ortaya konmuştur. Ayrıca, literatürde bahsi geçen bazı özellik çıkarım yöntemleri ile hız ve başarı oranları referans alınarak karşılaştırılmıştır.

Son bölümde, bu tez kapsamında ele alınan yöntem ve elde edilen sonuçlar tartışmalı bir şekilde incelenmiştir. Ayrıca, ortaya konulan yöntem ile gelecekte yapılabilecek çalışmalar ve bu çalışmada sunulan yöntemin uygulanabilirliği hakkında çeşitli öneriler sunulmuştur.

BÖLÜM 2

PLAKA KARAKTERLERİNİN AYRIŞTIRILMASI VE SINIFLANDIRILMASI

Plaka tanıma çalışmalarında amaç, belirli yöntemler doğrultusunda görüntü içerisindeki harf ya da rakamlardan oluşan karakterlerin belirlenmesidir. Karakter piksellerinin nasıl inceleneceği ve ne tür işlemlere tabi tutulacağı ile ilgili çeşitli yaklaşımlar bulunmaktadır. Öncelikle karakter piksellerinin belirlenmesi ve bu piksellerin ne şekilde kullanılacağına karar verilir. Söz konusu işlem için temel olarak iki farklı yaklaşım mevcuttur. Bu yaklaşımlardan ilki karakter piksellerinin tamamını kullanarak bir şablon elde edilmesidir. Diğer yaklaşım ise karakterleri oluşturan piksellerden çeşitli özellik vektörleri elde edilmesi ve karakterleri birbirlerinden ayırabilmek için bu özelliklerin kullanılmasıdır.

Söz konusu iki yaklaşımda da karakterlere ait birbirlerinden farklı sayısal veriler elde edilmektedir. Bu veriler doğrultusunda plaka karakterlerini doğru bir şekilde tanımlayabilmek için karakterlerin sınıflandırılması gerekmektedir. Her iki yöntem ile elde edilen veriler kullanılarak, tanımlanması istenilen aday karakterleri doğru şekilde belirleyebilmek için çok çeşitli sınıflandırma yöntemleri kullanılmaktadır. Karakter şablonlarının ya da özellik vektörlerinin kullanılması ile karakterlerin sınıflandırılmasında istatistiksel yaklaşımlar [14], lineer işlemler [57] ve çeşitli yapay zekâ uygulamaları [45-50] kullanılmaktadır.

2.1 KARAKTER TANIMA YÖNTEMLERİ

2.1.1 Görüntü Piksellerinin Kullanılması ile Karakter Tanıma

Karakter tanıma çalışmalarının temelini oluşturan Optik Karakter Tanıma (OKT) metodunun büyük bir çoğunluğu şablon eşleştirme yöntemleri ile yapılmıştır. Şablon eşleştirme yöntemi, tanımlanması istenilen karakter ile elde tutulan karakter şablonlarının birbirlerine olan benzerliklerinin ölçülmesi esasına dayanır [1]. Bunun için de karakter şablonlarının tutulduğu bir veritabanına ihtiyaç vardır. Veritabanındaki tüm karakterlerin çeşitli yazı tiplerinden elde

edilen çok sayıda şablonları olmalıdır. Tanımlanması istenecek karakterlere ait pikseller, tüm karakterlere ait mevcut şablonlarla karşılaştırılır ve en yakın benzerlik oranını sağlayan karakter olarak tanımlanır. Bu yöntemde dikkat edilecek noktalardan birisi, şablonlara ait piksel ile karakter piksel sayılarının aynı olması gerekliliğidir. Fakat incelenecek görüntünün boyutuna veya karakterlerin görüntüye oranına bağlı olarak aday karakter piksel sayısında farklılıklar olacaktır. Bu yüzden aday karakter boyutlarının belirli bir karakter büyüklük değerine yeniden boyutlandırılması edilmesi gerekir. Şablon eşleştirme yöntemi tüm karakter piksellerinin aynı öneme sahip olduğu bir yöntemdir. Bu durum farklı yazı tiplerine sahip karakterlerin yanlış algılanmasına sebep olmaktadır. [13] Ayrıca tüm karakter piksellerinin şablon eşleştirme işlemine dahil olması, gürültü ve küçük eğim farklılıklarına karşı bu yöntemin daha duyarlı olmasına yol açabilmektedir. Bu yüzden, yüksek bir karakter tanıma başarısının sağlanabilmesi için veritabanında çeşitli fontlarda ve eğimlerde karakter şablonları tutulması gerekmektedir. X ve arkadaşlarının yaptıkları çalışmada [2], tüm karakterlerin çeşitli yazı tiplerindeki plaka görüntülerinden elde edilen karakter pikselleri ile karakter şablonları elde edilmiştir. Şablonlar belirli bir büyüklüğe yeniden boyutlandırılarak siyah ve beyaz renklerden oluşan ikili formata çevrilmiştir. Tanımlanması amaçlanan karakterler, karakter şablonları ile aynı boyutlara getirilerek, veritabanındaki tüm karakter şablonları ile eşleştirilmiştir. 2009 yılında yapılan bir çalışmada [3] plaka karakterleri 26x50 piksel büyüklüğüne yeniden boyutlandırılmıştır. 76 pikselden oluşan aday görüntüsü sadece siyah ve beyaz renklerden oluşan ikili görüntü formatına çevrilmiştir. Tüm piksel değerleri 76 elemanlı bir dizi olarak Geri Beslemeli Yapay Sinir Ağı (GYSA) girişine verilerek %97,3'lük bir başarı oranı elde edilmiştir. Söz konusu çalışmaya benzer olarak karakter görüntüsünün aynı boyutlara getirilmesi için karakterler 20x100 piksel olarak yeniden boyutlandırılmış ve şablon eşleştirme yöntemi ile plaka tanıma çalışması yapılmıştır [4]. 2005 yılında yapılan bir başka çalışmada [5], karakter aday bölgesinin karakterler ile benzerliklerini hesaplamak için çapraz korelasyon işlemi [6] kullanılmıştır. Comelli ve arkadaşlarının [14] yaptıkları çalışmada ise karakter pikselleri ile oluşturulan şablonlar yerine tüm plaka bölgesi üzerinde çapraz korelasyon işlemi yapılmıştır. Plaka karakterlerini içeren dikdörtgensel bölgeler 20x230 piksel olarak yeniden boyutlandırılmıştır. Daha sonra plakalarda görülen 31 karakterin tüm şablonları, plaka bölgesi matrisi üzerinde yatay yönde birer piksel kaydırılarak korelasyon matris değerleri hesaplanmıştır. Eşik değeri üzerinde benzerliğe sahip sonuçlar ile karakterlerin belirlenmesi sağlanmıştır. Şablon eşleştirme yöntemlerinde görülen bir diğer yaklaşım ise, karakter pikselleri ile karakter şablonları arasındaki benzerlikleri hesaplayan Jaccard değerinin kullanılmasıdır [15,16]. Jaccard değeri, iki veri setindeki aynı elemanların sayısının, veri setlerinin birleşim

kümesindeki eleman sayılarına oranını hesaplayan bir benzerlik ölçüm değeridir. Böylece plaka karakter pikselleri ile veritabanındaki karakter şablonları arasındaki benzerlikler ölçülerek en yüksek benzerlik oranını sağlayan karakterler tespit edilir. Söz konusu yöntem ile 2340 karakter görüntüsü için %98,6'lık bir doğru karakter tespit oranı elde edilmiştir [15]. Bir diğer şablon eşleştirme çalışmasında [17] yine karakter bölgesindeki pikseller farklı bir yöntem olan Mahalanobis Uzaklığı ölçümü ile karakter benzerlikleri hesaplanmış ve Bayes Karar Teorisi ile karakter tespiti yapılmıştır. Kanayama ve arkadaşları tarafından yapılan bir çalışmada [18] yeniden boyutlandırılmış karakter görüntülerinde sadece yatay piksel sayıları hesaplanmış ve tüm karakterlere ait şablonlar ile istatistiksel olarak karşılaştırılmıştır. Chang ve arkadaşları [19] tarafından yapılan bir çalışmada ise karakter pikselleri ile arka plan pikselleri arasındaki en yüksek gri seviye değişimini tespit ederek sadece kenar verilerinden oluşan karakter şablonları elde etmiştir. Daha sonra karakter şablonları ile YSA aracılığıyla karakter belirleme işlemi gerçekleştirilmiştir.

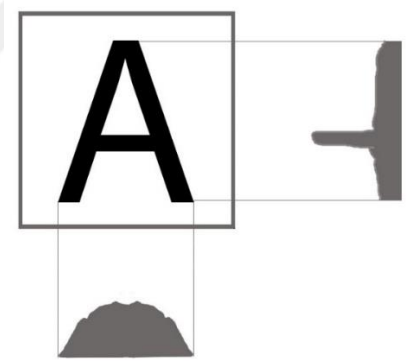
Şablon eşleştirme çalışmalarında, karaktere ait olduğu düşünülen tüm pikseller ile karakter eşleştirilmesi yapılmaktadır. Karakterin yazı tipinden ya da çeşitli gürültü piksellerinden dolayı veritabanındaki karakter şablonları ile aralarındaki benzerlik miktarı oldukça değişken olabilmektedir. Bu durum, düşük kaliteli görüntülerde başarı oranını düşürebileceği gibi veritabanında çok çeşitli yazı tiplerine sahip karakter şablonları tutulması ihtiyacını doğurmaktadır [20]. Çeşitli görüntü bozukluklarından etkilenmeyen ve çok çeşitli yazı tiplerine ait plakaları tanımlayabilen bir şablon eşleştirme yöntemi için oluşturulan büyük bir veritabanı kullanılması ise işlem yükünü artıracaktır. Çünkü bir plaka karakterinin, veritabanındaki her bir karaktere ait çok sayıda şablon ile benzerlikleri ölçülmektedir [21].

2.1.2 Özellik Vektörleri Oluşturarak Karakter Tanıma

Karakter tanıma işlemlerinde çokça karşılaşılan diğer bir yaklaşım ise özellik çıkarım yöntemleridir. Özellik, bir nesneye ait bilgiler içeren elemanların oluşturduğu bir fonksiyon olarak tanımlanır. [22]. Görüntü içerisindeki nesnelere renk, gri seviye dağılımı, kenar bilgileri ve şekilsel içerikleri gibi özelliklerinin bir dizi haline getirilmesi ile özellik vektörleri oluşturulur. Özellik vektörleri, görüntü hakkında nicel bilgiler verir. Bu nedenle özellikle karakter tanıma [23], görüntü eşleştirme [24] ve benzerlik hesaplamaları [25] gibi çeşitli çalışmalarda sıklıkla kullanılır. Bu çalışmada plaka karakterlerine ait özellik vektörlerinin elde edilebilmesi için şekil histogramından yararlanılmıştır. Literatürde, şekil histogramı ile özellik

vektörleri oluşturularak nesnelerin benzerliklerinin hesaplandığı ve bu sayede nesnelerin tanımlanabilmesinin sağlandığı çalışmalar yer almaktadır [26-30]. Harf, rakam, sembol vb. karakterleri birbirinden ayıran şekilsel farklılıkların, matematiksel bir dizi haline getirilmesi ile birçok karakter tespit yöntemi oluşturulmuştur. Söz konusu yaklaşımlarda amaç, tüm piksellerin sınıflandırma işlemine dahil olması değil, görüntüye daha geniş bir perspektiften bakılarak karakter analizi işleminin gerçekleştirilmesidir.


Özellik çıkarımı ile plaka tanıma çalışmalarında yaygın olarak kullanılan bir yöntem, karakterlerin yatay ve/veya dikey izdüşümleri ile özellik vektörlerinin oluşturulması yöntemidir. Bu yöntemde, plaka görüntüsü ikili görüntüye çevrilir. Daha sonra plaka karakterleri yatay veya dikey yönde taranır (Şekil 1.1). Tarandığı düzlem boyunca karakterlere ait piksel sayıları hesaplanır ve karakter özellik vektörleri elde edilir [7,31,32]. Ayrıca söz konusu yöntemin kullanıldığı başka bir çalışmada, plaka karakterlerinin yatay izdüşümlerinden elde edilen işaretlerin örnekleme ve ikili sayısal kodlara çevrilmesi ile özellik vektörlerindeki küçük gürültü hatalarının giderilmesi sağlanmıştır [33].



Şekil 2.1 Karakterlerin yatay ve dikey izdüşümleri.

Yatay ve dikey izdüşüm sayıları ile özellik çıkarım yöntemleri pratik ve hızlı bir yöntem olsa da karakterlerin şekilsel farklılıklarını net olarak ortaya koyamamaktadır. Ayrıca font değişikliklerine ve gürültüye karşı da duyarlı bir yöntemdir. 2004 yılında yapılan bir çalışmada, gri seviye karakter görüntüsü üzerinde 3x4 pencereleme işlemi yapılmıştır [8]. Bahsi geçen pencereleme yönteminde, plaka karakteri 3x4'lük bölgelere ayrılarak buradaki karakter piksel sayısı ile o karaktere ait özellik vektörü elde edilmiştir. Bu sayede tüm karakter piksellerini karşılaştırmak yerine, karakter piksel sayısının 12'de 1'i adetinde eleman sayısı kullanılmıştır. Fakat görüntü boyutuna bağlı olarak özellik vektör eleman sayısı değişkenlik göstermektedir. Büyük görüntü boyutlarında işlem yükü fazla olacağı gibi küçük boyutlu görüntülerde de başarı

oranı hayli düşecektir. Aynı yıl yapılan bir başka çalışmada ise 3x3 piksel boyutlarına ayrıştırılan bölgelerdeki 0, 45, 90 ve 135 derecelik eğime sahip olan çizgiler ile özellik vektörleri oluşturulmuştur [9]. Söz konusu çalışmada ise görüntüdeki eğime karşı hassasiyet fazladır. Karakter tanıma işleminin doğru yapılabilmesi için karakterlerin görüntü içerisinde doğru konumlara sahip olması gerekmektedir. Aynı yıl yapılan başka bir çalışmada karakter özellik vektörleri oluşturulurken, Şekil 2.2’de gösterilen yatay doğrultudaki kayma problemine karşı alternatif bir özellik çıkarım yöntemi sunulmuştur [34]. Aday karakterin en üst ve en alt bölgesinin tam ortalarını birleştiren bir doğru çizilmiştir. Bu doğru boyunca karakter pikselleri ile arka plan pikselleri arasındaki geçiş sayısı ve karakter piksel genişlikleri tüm plaka karakterleri için farklılık göstermektedir. Karakterlere ait özellik vektörleri oluşturulurken, bu bilgiler kullanılmaktadır. Böylece plaka karakterlerinde görülebilecek eğim ile paralel bir doğru çizileceği için özellik vektörleri söz konusu durumdan etkilenmeyecektir. Fakat çeşitli yazı tiplerine sahip karakterlerin, kalınlıkları ve karakter pikselleri arasındaki boşlukların büyüklükleri değişebileceği için tüm yazı tiplerindeki karakterler için aynı başarı oranının sağlanması beklenemez.



Şekil 2.2 Yatay eksende kaymış bir karakterin ve düz bir karakterin alt ve üst kısımlarının bir doğru ile birleştirilmesi.

Ko ve Kim tarafından yapılan bir çalışmada, plaka karakterini çevreleyen kenar çizgilerinin konumsal değişimlerini gösteren bir işaret üretilmiştir [35]. Elde edilen işaret örneklendirilerek, karakter özellik vektörleri elde edilmiştir. Bu yöntemin sahip olduğu önemli avantaj, aralarında çok küçük çizgi ya da nokta farklılıkları olan ve genel olarak birbirine benzeyen karakterlerin (O-Q C-Ç, E-F vb.) birbirlerinden ayırt eden şekilsel özelliklerini net bir şekilde ortaya çıkartabilmesidir. Fakat %86’lık bir başarı oranı ile genel olarak çok yüksek bir başarı oranı sunmamaktadır. 2006 yılında yapılan bir çalışmada [10], aday karakterlere Kirch Kenar Belirleme Algoritması [11] uygulanarak karakter kenarları ortaya çıkartılmıştır. Karakterlere ait yatay, dikey ve çapraz doğrultulardaki kenar sayıları hesaplanarak karakterlere ait özellik

vektörleri elde edilmiştir. Jiao ve arkadaşları tarafından yapılan bir çalışmada ise karakterler 16x16 piksel büyüklüğüne yeniden boyutlandırılarak, birbirinden farklı şekillere sahip 11 alt bloğa ayrılıp piksel sayıları hesaplanmıştır. Elde edilen piksel sayıları ile 448 elemanlı özellik vektörleri elde edilmiştir [12].

Özellik çıkarımı yöntemlerinde tüm karakter pikselleri eşit derecede sonuca etki etmediği için yazı tipi değişikliklerinin, görüntüdeki eğimlerin ve gürültülerin karakter eşleştirilmesine etkisi daha düşük seviyede kalmaktadır. Çünkü belirli miktardaki eleman sayısı ile eşleştirme yapılmaktadır. Söz konusu niteliklerinden dolayı özellik çıkarım yöntemleri, çeşitli görüntü bozukluklarına ve yazı tipi değişikliklerine karşı daha güçlü bir yöntemdir. [36] Fakat şablon eşleştirme metoduna göre dezavantajı ise sınıflandırma öncesi yapılan özellik çıkarma işlemi için de ekstra süre harcamasıdır. Ayrıca doğru kurgulanmamış bir özellik çıkarımı ile karakter tanıma işlemi çok yanlış sonuçlar verebilmektedir [37]. İncelenen özellik çıkarım yöntemleri, çoğunlukla gürültü ve yazı tipi değişikliklerine karşı daha kararlı olsa da işlem hızı, yüksek başarı oranı ve işlem kolaylığı gibi avantajların tümüne birden sahip değildir.

2.2 KARAKTER TANIMA ÇALIŞMALARINDA KULLANILAN SINIFLANDIRMA YÖNTEMLERİ

Plaka tanıma çalışmalarında karakter bölgesinin çeşitli şekillerde değerlendirilip ayrıştırılması için son aşamada karakterlerin doğru ve hızlı bir şekilde sınıflandırılması gerekmektedir. Gerek şablon eşleştirme yöntemlerinde gerekse özellik çıkarım yöntemlerinde, aday karakterlerin hangi harf ya da rakam olduğuna karar verilmesi için çeşitli sınıflandırma yöntemleri kullanılmaktadır. Aday karaktere ait pikseller ya da özellik vektörleri, tüm karakterler ile karşılaştırılarak, en yüksek benzerlik oranına sahip karakterin tespit edilmesi amaçlanmaktadır. Bu amaç doğrultusunda çeşitli makine öğrenme yapıları ya da matematiksel benzerlik ölçüm yöntemleri ile sınıflandırmalar yapıp karakterlerin ne olduğuna karar verilir.

İstatistiksel yaklaşımlarda, tanımlanmak istenilen aday karakter pikselleri ya da karakter özellik vektörleri, karakter şablonları ya da karakter özellik vektörleri ile matematiksel olarak karşılaştırılır [38]. Öğrenebilen bir algılayıcı yerine, tüm şablonlar ya da özellik vektörleri ile karakterlerin benzerlikleri ayrı ayrı hesaplanır. Matematiksel benzerlik hesaplanan sınıflandırıcılar içerisinde çapraz-korelasyon işlemi yaygın olarak kullanılmaktadır [6]. Ayrıca

lineer yaklaşım ile aday karaktere ait veriler ile tüm karakter verileri ile matematiksel olarak karşılaştırılarak, tüm karakterlere ile benzerlik miktarı hesaplanır [39].

Makine öğrenmeli sınıflandırıcılardan Yapay Sinir Ağları (YSA), karakter tanıma çalışmalarında yaygın olarak kullanılmaktadır [40-42]. Bilgisayar sistemlerinin ortaya çıkışıyla birlikte, insanüstü hesaplamaların makinelere yaptırılması ile ilgili gelişmeler geçtiğimiz yüzyıl içerisinde oldukça dikkat çekmiştir. Bilgisayar sistemlerinin lojik mantıkla üretilip algoritmaların oluşturulması ile büyük hesaplamaların yapılması kolaylaştırılmıştır. Fakat günümüze kadarki süreçte, olası bir problem karşısında çok fazla varyasyon ve ihtimalin olabileceği problemlerde lojik sistemler yetersiz kalabilmektedir. Akıllı öğrenme çalışmaları ile çözümlene sistemleri içerisine tüm olası durumları tek tek tanımlamak yerine, öğrenebilir ve yorumlayabilir sistem tasarımları başlamıştır [43]. YSA, insanlar tarafından örneklendirilen gerçek bilgilerle genelleme yaparak öğrenebilen ve bunun sonucunda karşılaştığı problemleri bu öğrenme sayesinde sonuçlandırabilen sistemlerdir [44].

Plaka tanıma çalışmalarında, çok sayıda olası harf ya da rakam sonucu vardır. Bu nedenle birçok çalışmada karakterlerin sınıflandırılmasında YSA kullanılmıştır [45]. Geri Yayılımlı Sinir Ağları (GYSA) [46, 47], Çift Katmanlı Sinir Ağları (ÇYSA) [48], İleri Yayılımlı Sinir Ağları (İYSA) [49], gibi çeşitli sinir ağları metotları yardımıyla karakter tanıma işlemleri yapılmıştır. GYSA, çıkış katmanındaki sonuç ile mevcut düğümlerin üretmesi beklenen sonuç arasındaki farklar doğrultusunda, ağ katmanlarına ait ağırlıkların güncellenmesi ile oluşturulur. İYSA'da ise ağa verilen eğitim setindeki girdilere ait çıktılar, ağ katmanına ait ağırlıkları değiştirir. Eğitim setleri ile güncellenen ağırlıklara sahip ağ eğitilerek istenilen sonuçları vermesi beklenen bir algılayıcıya dönüştürülmüş olur.


Bir diğer benzerlik hesaplama aracı olarak Destek Vektör Makineleri (DVM) ile belirli veri grupları arasındaki benzerlikler doğrultusunda sınıflandırma yapılabilmektedir. DVM, daha önceden belirlenmiş alt gruplara, çözümlenmesi istenilen bir veri girdisini atayarak sınıflandırma yapan makine öğrenme yöntemleridir. Bu alt gruplarda, kullanıcı tarafından önceden atanmış veriler vardır. DVM, bu verilerin alt gruplara dağıtıldığındaki benzerliklerini ve farklılıklarını çözümlyerek test edilen verinin hangi kümede olması gerektiğine karar verir. Plaka verilerinin hangi karaktere ait olduğunu belirlemek için DVM'nin sınıflandırıcı olarak kullanıldığı bir çalışmada %97,3'lük başarı oranı elde edilmiştir [50].



BÖLÜM 3

ŞEKİL HİSTOGRAMI

Sayısal görüntü, görsel verilerin elektronik ortamda iki boyutlu bir sinyal olarak temsil edilmesidir. $G(r, c)$ matematiksel ifadesi ile belirtilen sayısal görüntüler, çeşitli gri seviye değerlerini temsil eden matris elemanlarından oluşmaktadır. Bir $G(r, c)$ ile ifade edilen sayısal görüntüdeki r ifadesi, görüntünün yatay elemanlarını, c ise dikey elemanları gösterir. Görüntü ise $(r \times c)$ boyutundadır. Söz konusu görüntü matrisine ait tüm elemanlar, bir elektronik ekranda Şekil 3.1'deki gibi piksel olarak gösterilir. Pikseller, bir sayısal görüntüyü oluşturan en küçük renk ya da gri seviyeye sahip karesel alanlardır ve bir araya gelerek bir sayısal görüntüyü oluştururlar.



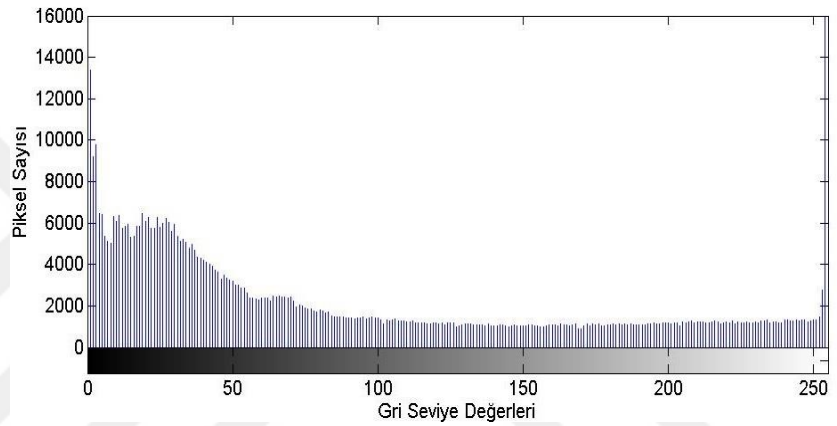
Şekil 3.1 Sayısal görüntüleri oluşturan pikseller.

Gri seviye görüntüler, çeşitli gri seviye değerlerine sahip piksel bilgilerini ifade eden tek bir matristen oluşturulurken, renkli görüntüler ise kırmızı, yeşil ve mavi renklere ait gri seviye değerlerine sahip 3 farklı matrisin üst üste eklenmesi ile oluşturulur. Renkli bir sayısal görüntüdeki bir pikselin 3 farklı gri seviye değeri vardır. Sayısal görüntü uygulamalarında yaygın olarak her bir piksel 8 bit ile kodlanmaktadır. Görüntülerde, her bir piksel $2^8 = 256$ farklı gri seviye değerinden oluşur ve gri seviye değer aralığı 0 ile 255 arasında değişir. Gri seviye değeri 0 olan bir piksel siyah rengi temsil ederken, 255 olan bir piksel beyaz rengi temsil

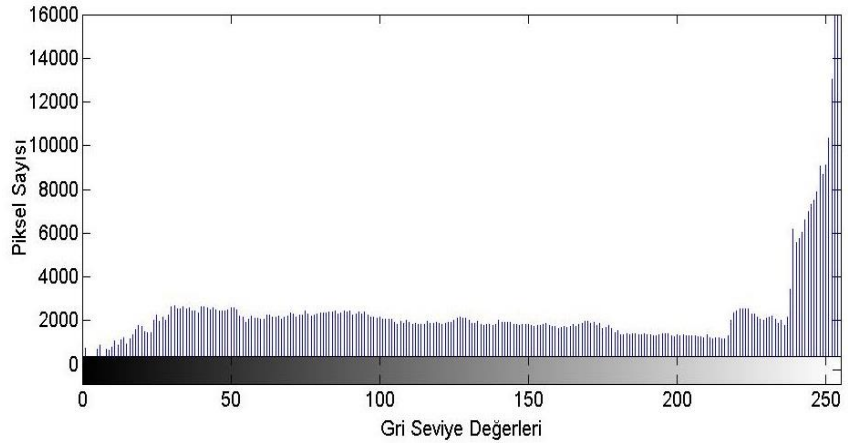
etmektedir. 0 ile 255 arasındaki gri seviye değerleri ise siyah ile beyaz arasındaki gri seviye tonlarını ifade eder.

3.1 HİSTOGRAM

Histogram, bir sayısal görüntüdeki tüm gri seviye değerlerinin istatistiksel dağılımı olarak tanımlanır [51]. Görüntünün sahip olduğu tüm gri seviyelerin sayısını ve görüntünün hangi gri seviye değerlerinde yoğunlaştığını gösterir. Şekil 3.2’de dört farklı görüntü ve bu görüntülerin gri seviye dağılımlarını belirten histogramları gösterilmiştir.



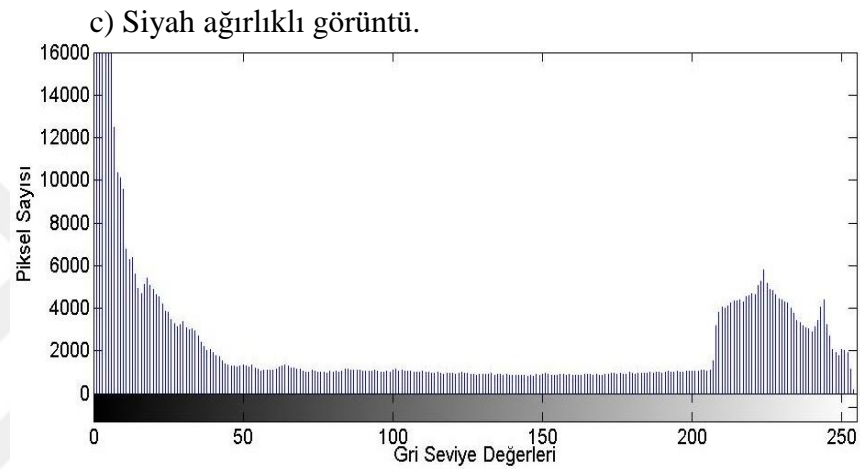
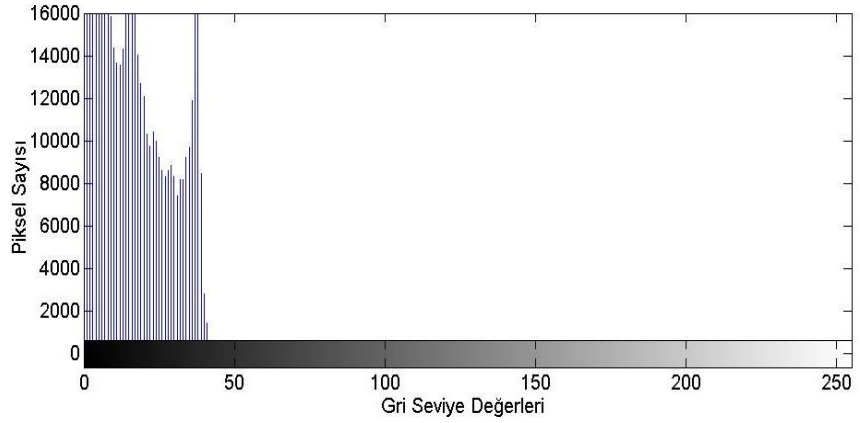
a) Eşit dağılımlı görüntü.



b) Beyaz ağırlıklı görüntü.

Şekil 3.2 Örnek bir görüntünün çeşitli gri seviye dağılımları ve histogramları.

Şekil 3.2 (devam ediyor).

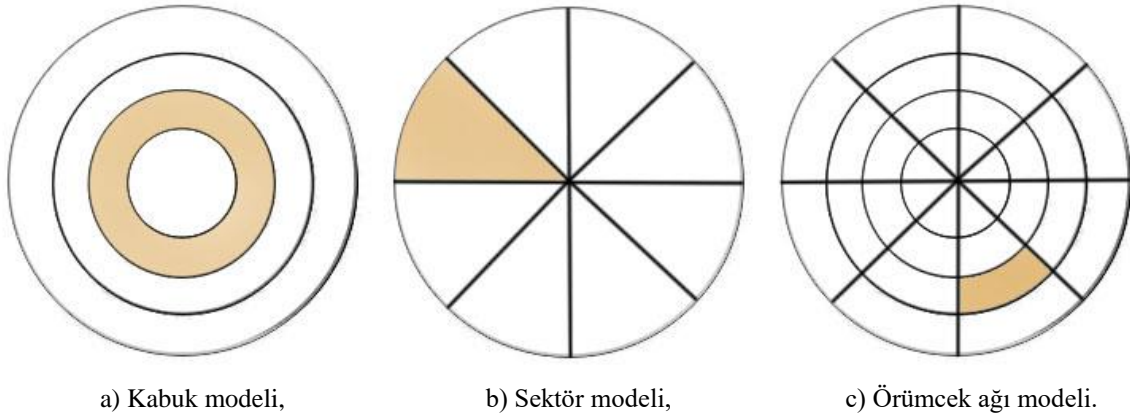


d) Siyah ve beyaz ağırlıklı görüntü.

Şekil 3.2 (a)'da gri seviye bir görüntüde ve gri seviye histogramında görüldüğü üzere görüntü, tüm gri seviye değerlerini hemen hemen aynı sayıda içermektedir. Görüntüye ait histogramdan da anlaşıldığı gibi ön plana çıkan bir gri seviye değeri de yoktur. Şekil 3.2 (b)'deki görüntü incelendiğinde beyaz tonlara sahip piksel sayısının daha fazla olduğu açıktır. Görüntü histogramı da incelendiğinde piksel değerlerinin 255 ve yakınlarındaki değerlerde toplandığı, siyah tonların ise görüntüde daha az olduğu görülebilmektedir. Şekil 3.2 (c)'de verilen görüntüde ise siyah tonlara sahip piksellerin daha fazla olduğu ve görüntünün siyah ağırlıklı olduğu görülmektedir. İlgili histogramı incelendiğinde piksel değerleri 0 ve yakınlarındaki değerlerde toplanmış, beyaz tonları içeren piksel sayısının daha az olduğu görülmektedir. Şekil 3.2 (d)'de verilen görüntü incelendiğinde ise görüntüdeki gri seviye değerlerinin keskin geçişlere sahip olduğu, çok açık ve çok koyu tonların ağırlıkta olduğu görülmektedir. Görüntüye ait histogramda da gri seviye değerlerinin 0 ve 255 değerleri etrafında toplandığı ve ara değerlere sahip piksel sayısının görüntüde daha az olduğu anlaşılabilir.



3.2 DAİRESEL ŞEKİL HİSTOGRAMI

Sayısal görüntülerin tüm gri seviye dağılımlarını göstermesi ile birlikte görüntülerin bölgesel şekillerde incelenerek çeşitli istatistiksel verilerin elde edildiği histogramlara şekil histogramı denir [52]. Şekil histogramı, görüntüdeki nesnelerin çeşitli şekillerde bölünmesiyle elde edilen bölgelerdeki piksellerin gri seviye dağılımlarını belirtir. Görüntülerin çeşitli bölgelerinden özellik vektörlerinin elde edildiği şekil histogramı; nesnelerin geometrik benzerliklerinin hesaplanabilmesine, karşılaştırılabilmesine ve tanımlanabilmesine olanak sağlar [53]. Bu alanda Tangelder ve arkadaşları [54] yaptıkları çalışmada görüntüyü dairesel olarak incelemiş ve üç farklı model geliştirmişlerdir. Şekil 3.3’ de gösterilen bu modeller; iç içe çemberlerden oluşturulan kabuk modeli, dairesel bölgeyi doğrusal kesitlerle eşit sektörlere ayıran sektör modeli ve bu iki modelin birleştirilmesi ile elde edilen örümcek ağı modelidir.

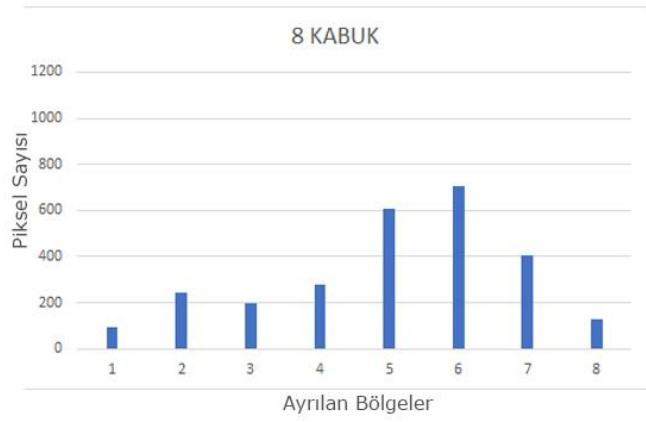



Şekil 3.3 Dairesel şekil histogram modelleri

Kabuk modelinde; görüntüdeki nesnenin merkezi tespit edilerek, bu noktadan itibaren nesne eş merkezli iç içe dairesel bölümlere ayrıştırılır ve piksellerin merkezden uzaklıklarına göre bir dağılım oluşturulur. Sektör modelinde; nesne merkezden eşit açılarda uzanan doğrusal kesitler ile dairesel sektörlere ayrıştırılır. Bu modelde her bir sektördeki piksel yoğunlukları kullanılarak elde edilen dağılımdan çıkarılan özellik vektörleri ile nesnenin çeşitli yönlerdeki piksel dağılımları elde edilebilir. Her iki modelin birleştirilmesiyle oluşturulan Örümcek ağı modelinde ise; nesne hakkında daha ayrıntılı bilgiler verebilen özellik vektörleri oluşturulur. Bu modelde nesne, farklı sayıda kabuk ve kesitlere bölünerek farklı yapılarda özellik vektörleri elde edilebilir.





a) 'A' Harfinin kabuk modeli şekil histogramı.





b) 'Z' Harfinin kabuk modeli şekil histogramı.

Şekil 3.4 'A' ve 'Z' harflerinin kabuk modeli şekil histogramı ile incelenmesi.

Şekil 3.4'de 'A' ve 'Z' harfleri için üç farklı model ile elde edilen şekil histogramları verilmiştir. Şekil 3.4 (a)'da incelenen kabuk modelinde 'A' harfi incelendiğinde, 2, 3, 4 ve 5 numaralı kabuklarda piksel yoğunluklarının yüksek, 1, 7 ve 8 numaralı kabuklarda daha düşük olduğu görülmektedir. Şekil 3.4 (b)'de incelenen 'Z' harfinde ise yoğunluk 5, 6 ve 7 numaralı kabuklarda yüksek, 1, 2 ve 3 numaralı kabuklarda ise düşüktür. Kabuk modelinde 'A' harfinin orta bölgelerde yoğunlaşmış merkez ve dış bölgelerde daha az piksel yoğunluğuna sahip olduğunu görebilmekteyiz. 'Z' harfinde ise çemberin dışına yakın bölgelerinde piksel yoğunluğunun yüksek olduğu ve merkez bölgelerde piksel yoğunluğunun çok az olduğu görülebilmektedir.




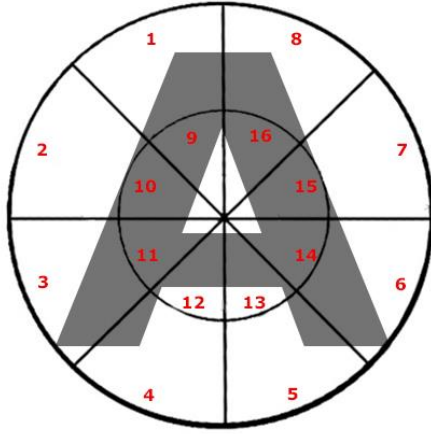
a) 'A' Harfinin sektör modeli şekil histogramı.





b) 'Z' Harfinin sektör modeli şekil histogramı.

Şekil 3.5 'A' ve 'Z' harflerinin sektör modeli şekil histogramı ile incelenmesi.

Şekil 3.5 (a)'da sektör modeli uygulanarak 'A' harfine ait şekil histogramı incelendiğinde 1, 5, 6, 11, 12 ve 16 numaralı sektörlerde piksel yoğunluğunun diğer bölgelerden daha yüksek olduğu görülmektedir. Şekil 3.5 (b)'de gösterilen 'Z' harfine ait sektör modeli şekil histogramında ise 6, 7, 14 ve 15 numaralı sektörlerde piksel yoğunlukları yüksek iken 3, 4, 12 ve 13 numaralı sektörlerde piksel yoğunluklarının çok düşük olduğu görülmektedir. Sektör modeli ile elde edilen şekil histogramları, 'A' harfinin yukarı, sol ve sağ alt çapraz bölgelerde yoğunlaştığını göstermektedir. 'Z' harfinin ise sağ üst ve sol alt çapraz bölgelerde yoğunlaştığını, merkezin sağ ve sol bölgelerinde piksel yoğunluğunun çok az olduğu görülmektedir.



a) 'A' Harfinin örümcek ağı modeli şekil histogramı.



b) 'Z' Harfinin örümcek ağı modeli şekil histogramı.

Şekil 3.6 'A' ve 'Z' harflerinin örümcek ağı modeli şekil histogramı ile incelenmesi.

Şekil 3.6'da ise 'A' ve 'Z' harflerinin sektör ve kabuk modelinin birleşimi ile elde edilen örümcek ağı modeli ile oluşturulmuş şekil histogramları gösterilmiştir. Bu model ile incelenen 'A' harfinin, üst, sol alt ve sağ alt bölgelerde yoğunlaşmasının yanı sıra merkez bölgesinde bir boşluk olduğu ve merkezin alt konumunda piksellerin kesintiye uğradığı Şekil 3.6 (a)'da görülmektedir. 'Z' harfinde ise sektör modelindeki sol alt ve sağ üst bölgede piksellerin yoğunlaştığı bilgisinin üzerine, bu iki bölgeyi birleştiren doğrultuda da piksel yoğunluklarının devam ettiği, sağ alt ve sol üst bölgeler ile merkez arasındaki bölgelerin boş olduğu bilgileri Şekil 3.6 (b)'de elde edilebilmektedir.

İncelenen 3 farklı model örneklerinden de anlaşılacağı üzere kabuk modelinde, karakter piksellerinin merkez ile dış kabuk arasındaki çeşitli aralıklardaki yoğunluklarının ortaya konulabildiği, karakter piksellerinin yoğunlaştığı doğrultuların ise elde edilemediği görülmektedir. Sektör modelinde ise, karakterlerin tüm doğrultulardaki piksel yoğunluklarının

ortaya konulduđu, karakter piksellerinin merkez ya da dıř blgedeki bilgilerinin elde edilemediđi grlmektedir. rmcek ađı modelinde ise, karakter piksellerinin hem yođunlařtıđı dođrultular, hem de merkezden dıř embere dođru eřitli blgelerdeki piksel yođunlukları elde edilebilmektedir. rmcek ađı modeli ile karakterlere ait grsel bilgilerin daha net bir řekilde ortaya koyulabildiđi anlařılmaktadır.

Dairesel blge ierisine alınan harf veya rakam karakterlerinin eřitli modeller ile blnmesi ve bu blnen alanlardaki piksel yođunluklarının hesaplanması ile karakterlere ait zellik vektrlerinin elde edilebilmesi bu alıřmanın da temel fikrini oluřturmuřtur.



BÖLÜM 4


MATERYAL VE YÖNTEM

Araç plakaları, harf ve rakamlardan oluşan araç kodlarıdır. Türkiye’de mevcut plakaların ilk iki hanesinde, kayıtlı olduğu ili ifade eden ve 01 ile 81 arasında değişen iki basamaklı bir sayı vardır. İl kodundan sonra araç özel plakası bir harf ve rakam grubu ile birlikte toplam 7 ya da 8 karakterden oluşur. Söz konusu harf ve rakamların plaka bölgesi içerisindeki yerleşim şekilleri Çizelge 4.1’deki gibi çeşitlilik gösterir.

Çizelge 4.1 Türkiye’deki araç plakalarının genel yapısı.

İl Kodu	Harfler	Rakamlar
XX (01-81)	A	1234
	A	12345
	AB	123
	AB	1234
	ABC	12
	ABC	123

Plaka karakterlerinin karakter yazı tiplerinde de çeşitlilik bulunmaktadır. Her ildeki plaka basım yerleri çeşitli yazı tipleri kullanılmaktadır. Türkiye’deki yaygın olarak kullanılan 4 farklı yazı tipine sahip plaka örnekleri Şekil 4.1’de gösterilmiştir.



Şekil 4.1 Plaka fontları.

Bu tezde temel olarak yeni bir özellik çıkarım yöntemi kullanılarak bir plaka tanıma çalışması sunulmuştur. Önerilen özellik çıkarım yöntemi için plaka karakterlerine ait dairesel şekil histogramları incelenmiştir. Şekil histogramı ile karakterler çeşitli bölgelere ayrılır ve ayrılan bölgelerdeki karakter piksel yoğunlukları hesaplanır. İncelenen tüm bölgelerdeki piksel yoğunlukları ile karakterlere ait özellik vektörlerinin elde edilmesi amaçlanmıştır.

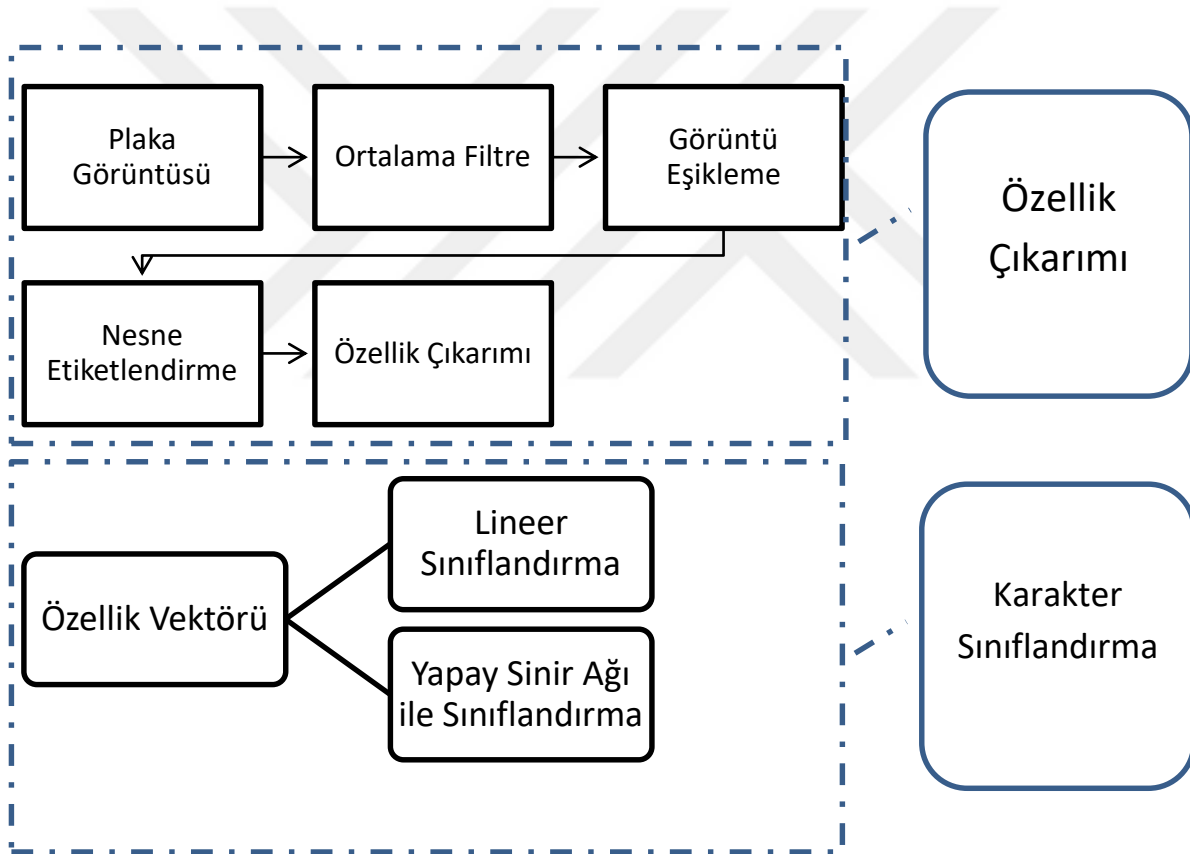
Plaka tanıma çalışması sürecine başlarken, incelenen araç plaka görüntüleri çeşitli ortamlarda çekilen araç fotoğraflarından elde edilmiştir. Farklı plaka yapılarına ve farklı yazı tiplerine sahip birçok araç plaka fotoğrafları, farklı mevsimlerde, farklı hava koşullarında ve farklı aydınlıklara sahip çeşitli ortamlarda elde edilmiştir. Söz konusu fotoğraflar içerisinde araç plaka bölgeleri kesilerek alınmıştır. Plaka karakterlerine ait özellik vektörlerini elde etmek için öncelikle plaka görüntüleri üzerinde çeşitli ön işlemler gerçekleştirilmiştir. İlk olarak renkli plaka görüntüleri gri seviye görüntüye dönüştürülmüştür. Ortalama Filtre ile gürültü azaltımı gerçekleştirilerek görüntü iyileştirme yapılmıştır. Daha sonra nesnelere ayrıştırabilmek için eşikleme yapılarak görüntü ikili formata çevrilmiştir. İkili görüntü içerisindeki tüm nesnelere etiketleme işlemi ile ayrıştırılmıştır. Bu nesnelere içerisinde karakter olmayan nesnelere elimine edilmiştir. Karakter olduğuna karar verilen nesnelere uygun dairesel bölge içerisine alınmıştır. Daha sonra şekil histogramı ile karakterlerin özellik vektörleri elde edilmiştir.

Tanımlanması istenilen plaka karakterlerinin özellik vektörleri elde edildikten sonra sınıflandırma işlemine tabi tutularak uygun karakter eşleştirilmesi yapılmıştır. Bu amaç doğrultusunda iki farklı sınıflandırma yöntemi önerilmiştir. Söz konusu sınıflandırma yöntemlerinden ilki Lineer Yöntem'dir. Lineer yöntem ile karakter tanıma yapabilmek için bir veritabanı oluşturulması gerekmektedir. Bilgisayar ortamında gürültüsüz ve doğru açılarda elde edilen plaka karakterlerinin şekil histogramları ile özellik vektörleri oluşturulmuştur. Oluşturulan özellik vektörleri söz konusu veritabanına aktarılmıştır. Veritabanında tutulan plaka karakterleri, yaygın olarak kullanılan ve Şekil 4.1'de gösterilen 4 farklı plaka yazı tipinden tüm karakterleri içeren 132 adet plaka görüntüleridir. Tanımlanması hedeflenen plaka karakterlerine ait özellik vektörleri, veritabanındaki özellik vektörleri ile matematiksel olarak karşılaştırılır. Tüm karakterler ile aralarındaki sayısal farklılıklar hesaplanır ve en düşük farklılık gösteren karakter olarak tanımlanır.

Karakterlerin doğru eşleştirilebilmesi için önerilen sınıflandırma yöntemlerinden diğeri de YSA ile karakter tanıma yöntemidir. Bu sınıflandırma yönteminde bir veritabanına ihtiyaç yoktur.

Ayrıca bu yöntemde tüm kullanılacak plaka görüntüleri, çeşitli farklılıklara sahip gerçek plaka fotoğraflarından elde edilen görüntülerdir. Herhangi bir eğitime, bozulmaya ya da gürültüye uğramış plaka görüntüleri ile ağ eğitilerek, sınıflandırıcının görüntü kalitesi düşük plaka görüntülerinde de başarılı olması amaçlanmıştır. YSA, plaka karakterinden elde edilen harf karakterleri için 322, rakam karakterleri için 200 özellik vektörleri ile eğitilmiştir. Daha sonra tanımlanması istenilen plaka karakterlerine ait özellik vektörleri, eğitilmiş ağa verilerek doğru karakter eşleştirmesi amaçlanmıştır.

Plaka karakterlerine ait özellik vektörlerinin oluşturulması ve söz konusu özellik vektörleri ile karakterlerin sınıflandırılması işlemlerine ait akış diyagramları Şekil 4.2’de gösterilmiştir.



Şekil 4.2 Önerilen yönteme ait akış diyagramı.

4.1 ÖZELLİK ÇIKARIMI ÖNCESİ ÖN İŞLEMLER

Araç plaka görüntüleri üzerinde, plaka karakterlerini tespit edebilmek için öncelikle bazı ön işlemler yapılmaktadır. Renkli görüntünün gri seviye görüntüye dönüştürülmesi, görüntü

üzerindeki gürültülerin ve karakterleri birbirlerinden ayırmak için eşikleme yapılarak görüntünün ikili görüntüye dönüştürülmesi gerekmektedir.

4.1.1 Renkli Plaka Görüntülerinin Gri Seviye Görüntüye Dönüştürülmesi

Plaka karakterlerinin tespit edilerek ayrıştırılabilmesi için öncelikle renkli plaka görüntüleri gri seviye görüntülere dönüştürülmektedir. Renkli görüntüler kırmızı (K), yeşil (Y) ve mavi (M) renk bileşenlerini taşıyan 3 farklı matristen oluşmaktadır. Plaka görüntülerinin eşiklenerek ikili formata dönüştürülebilmesi için, 3 farklı renk değerinin tek bir gri seviye değerine çevrilmesi gerekmektedir. Bu amaç doğrultusunda, plaka görüntüleri üzerinde yapılan ilk ön işlem gri seviye dönüşümüdür.

Renkli plaka görüntülerini oluşturan K , Y ve M matrislerinin tüm elemanlarının aritmetik ortalaması (4.1) eşitliğindeki gibi alınarak tek bir matris elemanı elde edilir. Bu işlem tüm matris elemanları için uygulanır. Elde edilen değerler, 0 ile 255 arasındaki gri seviye değerleridir. Şekil 4.3'de gri seviye dönüşümüne ait bir örnek yer almaktadır.

$$G(x, y) = \frac{K(x, y) + Y(x, y) + M(x, y)}{3} \quad (4.1)$$



Şekil 4.3 Renkli görüntünün gri seviye görüntüye dönüştürülmesi.

4.1.2 Plaka Görüntülerinde Gürültülerin Giderilmesi

Görüntü işleme çalışmalarında hatanın minimize edilebilmesi için gürültünün giderilmesi gerekmektedir. Gürültü, görüntü üzerinde noktasal veya daha büyük boyutlardaki istenmeyen piksel değerleridir. Bunları olabildiğince yok etmek için çeşitli filtreler uygulanabilir. Ortalama filtre ile plaka görselindeki istenmeyen gürültülerin azaltılması sağlanabilmektedir. Ortalama filtre, tek sayı boyutlarında bir kare matristir. Filtre matrisi içerisindeki elemanların sayı değerleri toplamı 1 olmalıdır. Filtre matrisi, gri seviye görüntü üzerindeki tüm pikseller üzerine getirilerek konvolüsyon işlemi yapılır. Filtreleme işlemine giren piksel ile çevresindeki komşu piksellerin aritmetik ortalaması alınarak merkezdeki piksel değerine atanır. Böylece görüntüdeki tüm piksellerin komşu pikseller ile aralarındaki nümerik farklar azaltılmış olur. Bu sayede görüntü içerisindeki küçük gürültü pikselleri azaltılmış ya da yok edilmiş olur. Ortalama filtrenin boyutları $n \times n$ olmak üzere, görüntüdeki tüm piksel değerlerinin filtrelenmiş yeni değeri (4.2) eşliğindeki gibidir.

$$G'(x, y) = \frac{1}{n^2} \sum_{k=-a}^a \sum_{p=-a}^a G(x + a, y + a) \quad (4.2)$$

Plaka görüntüsünün yumuşatılarak gürültünün azaltılması için kullanılan ortalama filtre matrisi Şekil 4.4'de gösterildiği gibi 3×3 boyutlu bir matristir. Şekil 4.5'de orijinal plaka görüntüsü ve gri seviye görüntüye dönüştürülüp ortalama filtre uygulanmış plaka görüntüsü bulunmaktadır.

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

Şekil 4.4 Ortalama filtre matrisi.



a) Filtre uygulanmamış görüntü,



b) Ortalama filtre uygulanmış plaka görüntüsü.

Şekil 4.5 Plaka görüntüsü üzerinde ortalama filtre uygulanması.

4.1.3 Eşikleme ile Görüntünün İkili Formata Çevrilmesi

Eşikleme, 0 ile 255 arasında çeşitli gri seviye değerlerine sahip piksellerin, 0 ya da 1 yapılarak görüntünün sadece siyah ve beyaz renklerle gösterildiği ikili formata çevrilmesidir. Bu sayede gri bölgeler yok edilerek, piksel değerleri 0 ya da 1 olan ikili görüntü elde edilir. Görüntü eşiklemede hangi değer aralıklarının siyah veya beyaz kabul edileceği önemlidir. Bu yüzden doğru bir eşik değeri seçilmelidir. Söz konusu eşik değerinin altındaki değerlere sahip pikseller siyah (0), eşik değerinin üzerindeki değerlere sahip pikseller ise beyaz (1) yapılıdır. Görüntü içerisindeki renk geçişleri yok edilerek farklı nesne bölgelerinin ayrıştırılması sağlanır.

Plaka görüntülerinde genellikle plaka karakterleri siyah, arka plan ise beyazdır. Fakat ışık ve çevresel faktörler sebebiyle görüntü içerisinde büyük oranda gri bölgeler olması kaçınılmazdır. Ayrıca karakterlerin görüntü içerisinde ayrıştırılması ve karakter piksellerinin ayrı ayrı ele alınabilmesi için görüntünün ikili formata çevrilmesi işlemi yapılmaktadır.

Görüntü eşiklemede her görüntü için aynı eşik değerinin seçilmesi, bölütlemeye hatalara sebep olabilir. Çünkü her görüntünün gri seviye dağılımı farklıdır ve aynı gri seviye değerine sahip iki nesne, bir görüntü için açık renk kabul edilebilecekken başka bir görüntüde ise koyu renk kabul edilebilir. Bu yüzden seçilecek eşik değerini üzerinde işlem yapılan görüntünün gri seviye dağılımına göre hesaplamak daha doğru sonuç verebilir. Bu amaçla kullanılan Otsu metodunda [55] görüntü içerisinde arka plan ve ön plan olarak ayrılan iki farklı gri seviye dağılımına sahip iki ayrı histogram bölgesi tespit edilir. Daha sonra tüm olası eşik değerleri için bu iki gri seviye grubunun grup içi varyans değeri (4.3.b) eşitliğinde gösterildiği gibi hesaplanır. Grup içi

varyans deęerinin en küçük olduęu eşik deęeri, eşikleme için en uygun eşik deęeri olarak seçilir.

$$\mu = \sum_{i=1}^N (i * g(i)) \quad (4.3.a)$$

$$\sigma^2 = \sum_{i=1}^N (g(i) - \mu)^2 * P_g(i) \quad (4.3.b)$$

Otsu eşikleme metodu ile birbirinden farklı gri seviye dağılımlarına sahip plaka görüntüleri için uygun eşik deęerleri otomatik olarak hesaplanmıştır. Otsu metodu kullanılarak plaka görüntülerinde eşikleme ve ikili görüntüye dönüştürme işlemi Şekil 4.6'da gösterildięi gibi yapılmıştır.



Şekil 4.6 Otsu metodu ile plaka görüntüsünün ikili formata çevrilmesi.

4.1.4 Görüntüdeki Nesnelerin Etiketlendirilmesi

Görüntü içerisindeki birbirinden farklı nesnelerin farklı kümelerde tutularak, birbirlerinden ayrılması için etiketlendirme yapılır. Bu çalışmada etiketlendirme işlemi ikili görüntülerde piksel deęerleri 1 olan nesne piksellerine uygulanmıştır. Mevcut ikili plaka görüntülerinde, karakter piksel deęerleri 0 iken arka plan piksel deęerleri 1'dir. Etiketlendirme işleminde ise etiketlenecek nesne pikselleri aranırken 1 olan pikseller seçilmiştir. Bu yüzden etiketlendirme işlemi öncesi ikili plaka görüntüleri Şekil 4.6 (b)'deki gibi tersine çevrilir. Etiketlendirme

sürecinde görüntünün herhangi bir köşesindeki bir pikselden başlanarak tüm pikseller satır satır kontrol edilir. İlk nesne pikseline bir etiket numarası verilir. Daha sonra sırayla tüm nesne piksellerine bakılır. Bakılan piksel, daha önce etiket numarası almış bir nesne pikseli ile komşu değilse yeni bir etiket numarası alır. En son aşamada ise birbirine komşu olan fakat farklı etiket numarasına sahip pikseller aynı etiket numarası ile etiketlenir. Bu sayede bağlantısı olmayan piksel grupları farklı numaralarla etiketlenmiş olur [56].

Etiketlendirilmiş tüm farklı nesnelere farklı renklerde gösterilerek birbirlerinden doğru bir şekilde ayrıştırıldığı Şekil 4.7 (c)'de gösterilmiştir. Etiketlendirme işlemi sonucunda, plaka görüntüsü bölütlenmiş olup, tüm nesnelere sahip olduğu etiket numaralarından oluşan ve plaka görüntüsü ile aynı boyutlara sahip bir Etiketlendirilmiş Plaka Matrisi (EPM) oluşturulmuştur.



Şekil 4.7 Plaka karakterlerinin ayrıştırılması.

4.2 DAİRESEL ŞEKİL HİSTOGRAMI İLE KARAKTER ÖZELLİKLERİNİN ÇIKARILMASI

Plaka karakterlerinin birbirlerinden ayrıştırılmasından sonra sınıflandırılabilmesi için tüm karakterlere ait özellik vektörleri oluşturulması gerekmektedir. Plakalardaki tüm karakterler 23

harf ve 10 rakamın çeşitli kombinasyonları ile oluşmaktadır. Plakalarda bulunan toplam 33 karaktere ait özellik vektörlerinin elde edilmesi için dairesel şekil histogramı kullanılmıştır.

Plaka karakterlerinin dairesel şekil histogramlarının oluşturulması için EPM kullanılmıştır. Fakat plaka içerisinde karakterlere ait olmayan piksel grupları da nesne olarak etiketlenmiştir. Örneğin plakaların en solunda bulunan ve genellikle mavi bir şerit içerisinde ülke kodunu içeren bölgeler, yok edilememiş çeşitli gürültüler, ya da plaka kenarlarında kalan şeritler de etiketlenilebilir. Karakterleri bu istenmeyen nesnel gruplardan ayırarak sadece karakterlere ait şekil histogramlarını oluşturmak için çeşitli ön koşullar içeren bir algoritma üretilmiştir. Plaka içerisindeki bir nesnenin karakter olabilmesi için içerebileceği en küçük karakter piksel sayısı ve en büyük karakter piksel sayısı arasında bir piksel sayısına sahip olması gerekmektedir. Ayrıca nesnelerin sahip olabileceği maksimum genişlik ve uzunluk içerisinde olup olmadığı da kontrol edilerek, istenmeyen nesnelerin karakterlerden ayrılması sağlanmıştır.

Görüntü içerisinde belirlenen karakterlerin şekil histogramlarını oluşturmak için öncelikle karakterlerin merkez konumları tespit edilir. En sağdaki karakter piksel konumu x_2 , en soldaki karakter piksel konumu x_1 , en üstteki karakter piksel konumu y_1 ve en alttaki karakter piksel konumu y_2 olmak üzere merkez konumu (4.4.b) eşitliğindeki gibi bulunur.


$$m_y = \frac{(y_2 - y_1)}{2}, m_x = \frac{(x_2 - x_1)}{2} \quad (4.4.a)$$

$$M_{x,y} = (m_x, m_y) \quad (4.4.b)$$


Merkez konum belirlendikten sonra, karakteri tam bir daire içine almak için gereken yarıçap ölçüsü (4.5) eşitliğindeki gibi hesaplanır.

$$r = \sqrt{(y_2 - m_y)^2 + (x_2 - m_x)^2} \quad (4.5)$$


Karakter dış çember içine alındıktan sonra, kullanılacak en uygun şekil histogramı modeline karar verilmesi gerekmektedir. Bunun için çok çeşitli dairesel şekil histogram modelleri kullanılarak karakterlerin özellik vektörleri elde edilmiştir. Şekil 4.8'de, çeşitli şekil histogram modelleri gösterilmektedir.




a) 4 çemberli model




b) 8 çemberli model




c) 2 çemberli ve 4 kesitli model




d) 4 çemberli ve 4 kesitli model




e) 8 kesitli model




f) 2 çemberli ve 8 kesitli model



g) 4 çemberli ve 8 kesitli model



h) 16 kesitli model





i) 2 çemberli ve 16 kesitli model


Şekil 4.8 Dairesel şekil histogram modelleri.

Karakter özellik vektörlerini oluşturmak için, çeşitli modellerle ayrılmış bölgelerdeki karakter piksel yoğunlukları hesaplanır. Elde edilen piksel yoğunlukları ile karakter özellik vektörleri elde edilir. Seçilen bir model ile elde edilen karakter özellik vektör eleman sayısı, karakterin bölüdüğü bölge sayısı kadardır. Özellik vektör eleman sayısının düşük olması, daha az sayıda veri ile karakter tanıma yapmayı sağlar. Bu durumun, işlem hızını artırabileceği gibi karakter tanıma başarı oranını da düşürmesi beklenir. Bu yüzden amaç, çeşitli modeller içerisinde optimum sonuç verecek olan modeli seçmektir. Çeşitli plaka görüntülerinden elde edilen ve görsel olarak birbirlerine benzeyen harf gruplarından seçilmiş bazı karakterlere ait şekil histogram modellerini gösteren grafikler Şekil 4.8'deki gibi elde edilmiştir. 9 farklı dairesel şekil histogram modeli ile 'A, B, D, E, H, I, J, O, U, V ve Y' harflerine ait şekil histogram modelleri oluşturulmuştur. Dairesel şekil histogramı ile karakterler çeşitli sektörlere ayrılırlar.

Bu sektörlerdeki karaktere ait piksel sayısı ve o sektördeki toplam piksel sayısı bulunur. Daha sonra tüm sektörler için Karakter Piksel Sayısı'nın (KPS), Sektör Piksel Sayısı'na (SPS) oranları hesaplanır. Elde edilen oranlar ile karakterlerin özellik vektörleri elde edilmiş olur.



(a)




(b)

Şekil 4.9 4 çemberli model (a) ve 8 çemberli model (b).


Şekil 4.9 (a)'da 4 çemberli model ile örnek karakterlerin dairesel şekil histogramları verilmiştir. Söz konusu modelde, 'A', 'B' ve 'H' karakterlerinin ve 'O' ve 'U' karakterlerinin özellik vektörleri birbirlerine benzerlik göstermektedir. Şekil 4.9 (b)'de verilen 8 çemberli modelde de

‘O’ ve ‘U’ karakterleri ile ‘B’ ve ‘E’ karakterlerinin özellik vektörleri birbirlerine benzerlik göstermektedir. Söz konusu iki model kullanılarak elde edilen karakter özellik vektörleri, karakterlerin birbirlerinden ayrılmasını zorlaştıracaktır.



ABDEHIJOUVY

(a)




ABDEHIJOUVY

(b)

Şekil 4.10 4 kesit ve 2 çemberli model (a), 4 kesit ve 4 çemberli model (b).



Şekil 4.10 (a)'da örnek karakterler, iki çember ve bu çemberleri yatay ve dikey olarak bölen dört kesitten oluşan model ile çeşitli bölgelere ayrılarak karakter özellik vektörleri elde edilmiştir. Söz konusu özellik vektörlerini gösteren grafik incelendiğinde, ‘O’ ve ‘U’ karakterleri ile ‘V’ ve ‘Y’ karakterlerine ait özellik vektörlerinin büyük oranda benzerlik

gösterdiği görülmektedir. Ayrıca söz konusu karakter özellik vektörleri ile karakterlerin net bir şekilde görsel farklılıklarının ortaya çıkarılmadığı görülmektedir. Şekil 4.10 (b)'de ise örnek karakterlerin dört kesit ve dört çemberden oluşan modelle dairesel şekil histogramları elde edilmiştir. Söz konusu modelde de karakterlere ait görsel farklılıklarının nümerik olarak ortaya çıkarılmadığı anlaşılabilmektedir.




Şekil 4.11 8 kesitli model .

Şekil 4.11'de 8 kesitli dairesel şekil histogramı modeli ile karakterlerin özellik vektörleri gösterilmiştir. Söz konusu özellik vektörleri incelendiğinde, karakterlerin ayrılan bölgelerdeki piksel yoğunlukları sayısal olarak birbirine yakın değerlerdedir. Bu durum, karakterlerin birbirinden ayrılmasını zorlaştıracaktır.





(a)





(b)

Şekil 4.12 8 kesit ve 2 çemberli model (a), 8 kesit ve 4 çemberli model (b).

Şekil 4.12 (a) ve (b)'de 8 kesit ve 2 çemberli model ile 8 kesit 4 çemberli modelin kullanılmasıyla elde edilen karakter özellik vektörleri gösterilmiştir. Bu modeller ile oluşturulan özellik vektörleri ile karakterlere ait görsel farklılıklar matematiksel olarak ortaya konulmuştur. Söz konusu modeller ile elde edilen özellik vektör grafiklerinde, örnek olarak incelenen tüm karakterlerin özellik vektörleri arasındaki istatistiksel farklılıklar görülebilmektedir.



(a)




(b)

Şekil 4.13 (a) 16 kesitli model, 16 kesit ve 2 çemberli model (b).


Şekil 4.13 (a)'da 16 kesitli dairesel şekil histogramı modeli ile karakter özellik vektörleri verilmiştir. Söz konusu modelde, 8 kesitli modelde olduğu gibi karakter özellik vektörleri 0 ile 1 arasında değil daha küçük bir aralıkta dağılım göstermektedir. Bu durum, karakterleri birbirinden ayırt etmeyi zorlaştırabilmektedir. Şekil 4.13 (b)'de ise 16 kesit ve 2 çemberli model ile karakterlerin dairesel şekil histogramları oluşturulmuştur. Elde edilen özellik vektörleri ile karakterlerin matematiksel olarak ayrılması sağlanmıştır.

İncelenen histogram modellerinden, 8 kesit-2 çember, 8 kesit-4 çember ve 16 kesit-2 çemberli modellerde, birbirlerine benzeyen karakterlerin özellik vektörlerinde farklılıklar olduğu görülmektedir. Fakat 8 kesit-2çember’li modelde özellik vektör eleman sayısı 16 iken diğer iki modelde bu sayı 32’dir. Daha az eleman sayısı ile daha hızlı işlem yapılabilmesi 8 kesit-2 çemberli model ele alınmıştır. Bu model ile elde edilen özellik vektör grafiklerindeki tek problem, B-D, G-C ve 0-8 karakterlerini birbirlerinden ayıran şekilsel farklılıkların karakterlerin merkezlerinde olması ve merkezin 8 parçaya bölünmesinden dolayı buradaki farklılıkların sayısal olarak belirgin şekilde ortaya çıkartılamamış olmasıdır. Bu nedenle bu modelde Şekil 4.14’de gösterildiği gibi bir merkeze bir ekleme yapılarak 17 elemanlı şekil histogramı elde edilmiş ve karakterlerin birbirlerinden tam olarak ayrıştırılması sağlanmıştır.




Şekil 4.14 17 elemanlı dairesel şekil histogramı ve plaka görüntüsü üzerinde uygulanması.

Dairesel bölgenin merkezinde oluşturulan küçük dairesel bölge ile söz konusu merkezi farklılıkların ortaya çıkarılması Şekil 4.15’deki grafiklerde gösterilmiştir.



a) 16 Elemanlı özellik vektörü



b) 17 Elemanlı özellik vektörü

Şekil 4.15 'B' ve 'D' Harflerine ait özellik vektörleri.

Şekil 4.15'deki grafiklerde 'B' ve 'D' harflerine ait şekil histogramlarının 16 elemanlı ve 17 elemanlı dairesel şekil histogramları ile oluşturulmuş özellik vektörleri görülmektedir. Söz konusu iki karakterin görsel farklılıklarının büyük bir kısmı merkez bölgelerindedir. Merkez bölgenin küçük parçalara ayrılmasından dolayı bu farklılıklar tam ortaya çıkarılamadığı için dairesel şekil histogramının merkezinde yeni bir kabuk açılarak söz konusu karakterlerin ve benzer durumdaki diğer karakterlerin ayrıştırılması kolaylaştırılmıştır. Verilen grafiklerden 17 elemanlı özellik vektörleri grafiğinde, 'B' harfinin merkezindeki piksel yoğunluğunun, 'D' harfinin merkezindeki piksel yoğunluğundan fazla olduğu görülebilmektedir.

4.3 KARAKTERLERİN SINIFLANDIRILMASI

Dairesel şekil histogramı ile plaka karakterlerine ait 17 elemanlı özellik vektörleri elde edilerek, karakterlerin şekilsel farklılıkları sayısal olarak ortaya çıkartılmıştır. Plaka karakterlerinin de bu doğrultuda sınıflandırılması ve hangi karakter olduğunun saptanması gerekmektedir. Bu aşamada, tanımlanması istenilen karakterlerin de şekil histogramları çıkartılarak, tüm karakter özellik vektörleri ile kıyaslanması ve uygun karakter eşleştirilmesinin yapılması amaçlanmaktadır. Bu çalışmada, karakter özellik vektörleri ile karakterlerin sınıflandırıldığı iki farklı yöntem önerilmiştir. Söz konusu yöntemler; özelliklerin matematiksel olarak sınıflandırıldığı Lineer Yöntem ve makine öğrenmesine dayalı gerçekleştirilen Yapay Sinir Ağı ile sınıflandırma yöntemidir.


4.3.1 Lineer Yöntem ile Karakterlerin Sınıflandırılması

Lineer yöntem, plaka karakterine ait özellik vektörleri ile tüm karakter özellik vektörlerinin matematiksel olarak karşılaştırıldığı bir yöntemdir [57]. Söz konusu yöntemde çeşitli fontlardaki tüm plaka karakterlerinin birer özellik vektörleri oluşturulup bir veritabanında tutulması gerekmektedir. Bu amaçla Türkiye araç plakalarında yaygın olarak kullanılan 4 farklı yazı tipindeki tüm karakterlerin dairesel şekil histogramları oluşturulmuştur. Böylece her bir karakter için 4 farklı yazı tipinde 17 elemanlı özellik vektörleri elde edilmiştir. Her bir karakterin dairesel bölge içerisinde on yedi sektöre bölünmesi ve bu bölgedeki KPS'nin o sektördeki toplam SPS'na oranı hesaplanarak, 4 farklı fonttaki tüm karakterlerin 17 elemanlı özellik vektörleri çıkarılmıştır. Her bir karakter için oluşturulan 4 farklı yazı tipine ait 17 elemanlı özellik vektörlerinin aritmetik ortalamaları (4.6) eşitliğinde belirtildiği gibi alınarak, her bir karakter için tek bir özellik vektörü (C_i) oluşturulmuştur.

$$C_i[j] = \frac{1}{4} \sum_{n=1}^4 \frac{SKPS_j}{SPS_j} \quad (4.6)$$

Burada; j dairesel şekil histogramındaki sektörü, C_i her bir karaktere ait 17 elemanlı özellik vektörünü ve n ise 4 farklı karakter fontunu ifade etmektedir. Elde edilen C özellik vektörleri, farklı yazı tiplerindeki karakterlerin bir sentezi olup, tüm karakterler için referans özellik

vektörleri olarak ortaya çıkarılmıştır. Şekil 4.16’da 4 farklı yazı tipine sahip ‘B’ harfi için oluşturulmuş olan özellik vektörünün 13. elemanının elde edilişi (4.7) eşitliğinde gösterilmiştir.



Şekil 4.16 ‘B’ Harfine Ait Özellik Vektörlerinin Elde Edilmesi.

$$C_B[13] = \frac{1}{4} \sum_{n=1}^4 \frac{SKPS}{SPS} = \frac{0.693 + 0.678 + 0.473 + 0.751}{4} = 0.649 \quad (4.7)$$

Lineer sınıflandırma yönteminde amaç tanımlanması istenilen plaka karakterlerine ait 17 elemanlı özellik vektörleri ile veritabanında bulunan 23 harf ya da 10 rakama ait 17 elemanlı özellik vektörlerini matematiksel olarak karşılaştırmaktır. Tanımlanması istenilen bir plaka karakterine ait özellik vektörü R 'nin bir elemanının sayı değeri ile veritabanındaki bir karaktere ait özellik vektörü C 'nin aynı indise sahip elemanının sayı değerinin farkı hesaplanır. Bu işlem 17 eleman için de yapılır ve elde edilen bu farklar toplanarak, aday karakter ile karşılaştırılan karakter arasındaki hata miktarını veren E_i değeri hesaplanır. Elde edilen tüm E değeri, aday karakter ile karşılaştırılan karakter arasındaki hata değeridir. Bu karşılaştırma işlemi, eğer aday karakter bir harf ise veritabanındaki 23 harf karakter ile, eğer bir rakam ise veritabanındaki 10 rakam karakteri ile (4.8) eşitliğinde ifade edildiği gibi yapılır.

$$E_i = \min \left(\sum_{k=1}^{17} (|R[k] - C_i[k]|) \right) \quad (4.8)$$

Burada k özellik vektör eleman indisi, i ise veritabanındaki karakterleri ifade etmektedir. Bu işlem sonucunda aday karaktere ait 23 ya da 10 adet E hata değeri hesaplanmış olur. Aday karakterin, mevcut harf ya da rakam grubundan hangi karakter olduğuna karar verebilmek için en küçük E hata değerini veren karakter aranır.

Aday karakterin veritabanındaki karakterler ile karşılaştırılmasında dikkat edilen önemli bir nokta, aday karakterlerin tüm 33 karakter özellik vektörleri ile karşılaştırılmamasıdır. Veritabanında harfler ve rakamlar farklı iki grupta toplanmıştır. Aday karakterleri 33 karakterin tümü ile karşılaştırmak yerine harf ya da rakam grubundan biri ile karşılaştırmak daha doğru sonuç alınmasını sağlayacaktır. Bu amaç doğrultusunda plaka karakterlerinin öncelikle harf ya da rakam karakterlerinden hangi gruba ait olduğuna karar vermek gerekmektedir. Plaka karakterinin harf ya da rakam olduğunu tespit edebilmek için karakterler arası mesafeler incelenmiştir. Plakalar iki haneli sayı ile başlar, daha sonra belirli sayıda harf içerir ve tekrar belirli sayıda rakam ile sonlanır. Şekil 4.17’de görüldüğü gibi rakam ve harf gruplarının kendi aralarındaki mesafeler ($d1$) kısa iken, rakam ve harf grupları arasındaki mesafeler ($d2$) daha uzundur. Bu mesafeleri, daha önce şekil histogram çemberini oluşturabilmek için bulduğumuz $x1$ ve $x2$ değerleri ile hesaplamak mümkündür. Plaka karakterlerinin ilk ikisi her zaman rakam, üçüncüsü ise her zaman harftir. Son plaka karakteri de yine her zaman rakamdır. Diğer karakterlerin tespiti için bir önceki karakter ile arasındaki mesafeye bakılır. Bu mesafe $d1$ ve $d2$ mesafelerinin ortalamasının altında ise bir önceki karakter ile aynı gruptandır.



Şekil 4.17 Plaka Karakterleri Arasındaki Mesafelerin İncelenmesi.

Çizelge 4.2’de örnek bir araç plaka görüntüsünde tespit edilen karakterlerin, veritabanındaki karakterler ile lineer olarak karşılaştırılması sonucu hesaplanan E hata değerleri verilmiştir. Tüm aday karakterler için elde edilen en küçük hata değerleri belirtilmiş olup, incelenen plaka görüntüsü için doğru bir sonuç elde edildiği görülebilmektedir.

Çizelge 4.2 Örnek Plaka Karakterlerinin Tüm Karakterlerine ait Hata Değerleri.


	0	6	A	F	8	8	4	4
A	3,670603	3,049177	<u>1,04657</u>	4,879131	2,84749	2,82533	1,74036	1,89952
B	3,055206	2,704576	5,61455	3,59566	2,84159	2,96769	5,89771	6,06481
C	2,714317	2,917569	5,106584	3,046516	3,62846	3,82069	4,54603	4,54867
D	2,000534	3,101969	6,023932	3,931239	3,25703	3,38313	5,50744	5,68275
E	4,221881	2,929666	5,414077	1,855004	3,82254	3,97588	5,55583	5,70041
F	4,63298	3,352229	5,716522	<u>1,14331</u>	4,01432	4,05800	5,74296	5,79865
G	2,0168	1,983784	4,893364	3,276457	2,93042	3,08083	4,41666	4,57110
H	3,467615	3,250783	5,734269	3,608652	3,24696	3,2423	5,62262	5,77058
I	4,846666	3,648372	2,797632	4,32602	3,69494	3,77817	3,69524	3,52759
J	3,814588	5,059881	5,622166	6,082696	4,88965	4,76915	5,44730	5,48557
K	3,967571	2,728893	3,16211	3,255504	2,60613	2,83903	4,07287	4,00439
L	4,190133	4,442592	6,105341	3,742724	5,14500	5,27454	5,42209	5,50317
M	3,113473	2,96405	4,659946	4,624412	2,49139	2,57770	5,21713	5,29533
N	3,311532	2,892656	4,124197	4,197196	2,44732	2,43012	4,02619	4,26590
O	1,668161	2,905216	5,756945	4,03277	2,98555	3,09389	5,17135	5,2369
P	3,949795	3,639421	6,074443	2,125082	3,61659	3,71268	6,15776	6,14606
R	3,811644	3,408751	4,932153	3,46591	2,77513	2,88507	5,24058	5,22651
S	3,123659	1,764213	4,020222	3,038179	2,63906	2,73308	4,55921	4,66923
T	4,659979	3,36488	3,879324	3,637809	3,81623	3,84873	4,50629	4,33864
U	1,925732	3,187081	5,660429	4,196879	3,33822	3,38121	5,06671	5,29090
V	3,29751	3,067749	2,622137	4,109886	2,39658	2,37055	2,83364	2,76707
Y	4,664767	3,67207	2,622896	4,04494	3,63337	3,64564	4,00854	3,95182
Z	4,902938	3,864816	3,511419	3,993842	4,22214	4,32367	5,35770	5,33336
0	<u>1,55351</u>	2,784909	5,64518	3,718222	2,89459	2,98473	5,13552	5,32786
1	4,602846	3,559136	2,712785	4,51519	3,55327	3,64500	3,70518	3,61166
2	3,741428	4,25822	4,055399	4,925179	3,95195	3,95273	4,54534	4,50834
3	3,571194	3,106392	4,012134	4,640574	3,29498	3,36127	5,30398	5,36733
4	3,800329	3,648973	2,86027	4,984557	3,84601	3,72471	<u>1,11098</u>	<u>1,28131</u>
5	2,815802	2,271172	4,352612	3,373943	3,02808	3,00264	4,11608	4,26821
6	2,717792	<u>1,758681</u>	3,827845	2,816746	2,60743	2,5747	3,45472	3,69157
7	4,285078	3,924324	4,666701	4,111576	4,03688	3,95024	4,89330	4,76741
8	2,329628	2,034261	4,857821	2,946149	<u>2,03666</u>	<u>2,13699</u>	5,27593	5,44303
9	2,671462	2,723473	4,677104	4,105589	2,48419	2,48157	4,52745	4,55315

İncelenen örnek 8 plaka karakteri için en küçük E hata değerleri çizelge içerisinde vurgulanmıştır. 0, 6, A, F, 8, 8, 4 ve 4 olan karakterler için en küçük hata değerlerini yine bu karakterlere ait özellik vektörleri sağlamıştır.

4.3.2 Makine Öğrenmesine Dayalı Karakter Sınıflandırma

Makine öğrenmesi, çok sayıda verilen bilgiler doğrultusunda, analiz yaparak sonuç çıkarabilen ve bu doğrultuda davranış geliştiren akıllı sistemlerdir. Düzenli bir şekilde aktarılan girdiler ve bu girdilerin sonuçları arasındaki ilişkileri sürekli genelleme yaparak öğrenebilen bu sistemler, çok çeşitli girdilere karşı doğru çıktılar üretebilmektedir. Bu sayede tüm olası problemlerin bir algoritma içerisinde vermesi gereken tüm sonuçları belirtmek yerine, ilk defa karşılaştığı bir probleme karşı, öğrenmiş olduğu yapı sayesinde çözümleme üretebilmektedir.

Yapay sinir ağları insanın biyolojik öğrenme sisteminden esinlenilerek geliştirilmiş olan bir öğrenme modelidir. İnsan beyni, doğduğu andan itibaren çok çeşitli bilgi giriş çıkışlarına maruz kalır ve tüm bunları genelleme yaparak öğrenir. Bu gelişim sayesinde düşünebilir, karar verebilir, analiz ve kıyaslama yapabilir. Makine öğrenme yapısının oluşturulabilmesi ve daha karmaşık problemlerin çözülebilmesi için çok katmanlı algılayıcılar kullanılır. Çok katmanlı algılayıcılar girdi katmanı, ara katman ve çıkış katmanından oluşur. Girdi katmanlarında birden çok girdi noktası, çıkış katmanında da birden çok çıkış noktası bulunmaktadır. Girdi katmanı, dış dünyadan gelen verileri alıp ara katmana iletmektedir. Her girdi noktasının tek bir girdisi vardır ve bir sonraki ara katmandaki tüm noktalara bağlıdır. Ara katmanlar, girdi katmanlarından gelen girişler üzerinde işlemler yapar. Ara katmanlarda birden fazla katman bulunabilir. Çıktı katmanı ise ara katmanlardan alınan işlenmiş girişlere karşı ağın oluşturduğu çıktıları üretir. Çıkış katmanındaki her noktanın tek bir çıktı verisi vardır. Çok katmanlı algılayıcı yapısı Şekil 4.18'de gösterilmiştir.



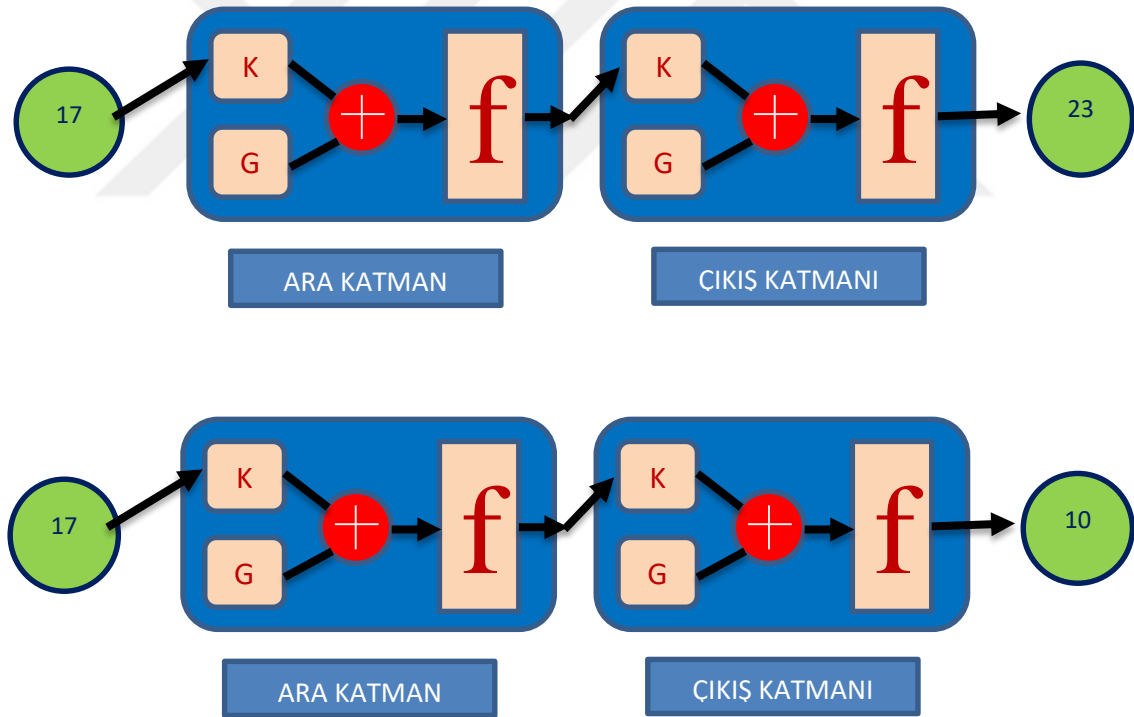
Şekil 4.18 Çok Katmanlı Algılayıcı Modeli.

İleri Beslemeli Yapay Sinir Ağı (İYSA), girdi katmanından çıktı katmanına doğru sinyal iletiminin olduğu birçok katmanlı algılayıcı modelidir. Giriş katmanından veriler ara katmana doğrudan iletilir. Ara katman içerisinde tek yönlü ileri doğru veri iletimi olur. Bu verilerin iletiği katman noktalarının kendi ağırlıkları vardır. Kendisine iletilen her veri de bu ağırlık katsayıları ile o katman noktasına verilmiş olur. Ağ kurulduğunda bu ağırlıklar rastgele oluşturulmuş olur. Ağ, öğrenme aşamasında iken, kendisine verilen öğrenme verileri ile bu ağırlıkları sürekli günceller. Yeterli miktarda ara katmana, eğitim verilerine ve uygun bir aktivasyon fonksiyonuna sahip, doğru çıktılar verebilen bir algılayıcı bu şekilde elde edilmiş olur. GYSA da girdi katmanlarından çıktı katmanlarına doğru sinyal iletiminin olduğu bir algılayıcı modelidir. GYSA eğitilirken, eğitim verilerinin çıktıları ile ağ çıktıları arasındaki hata miktarlarına göre ara katmandaki ağırlıklar güncellenerek öğrenme işlemi gerçekleşir.

Plaka karakterlerinin birbirlerinden farklı görsel yapılarını matematiksel olarak ortaya koymak amacıyla dairesel şekil histogramı ile 17 elemanlı özellik vektörleri oluşturulmuştur. Bu özellik vektörleri ile karakterleri birbirinden ayırarak doğru karakter tanıma yapmak için İYSA modeli oluşturulmuştur. İYSA modelinin tercih edilme sebebi, GYSA modeli ile aynı başarı oranlarını

vermesine karşılık, daha az iterasyon ile öğrenme gerçekleştirmesi ve işlem hızının daha düşük görülmesidir. 23 harf ve 10 rakamdan oluşan plaka karakterlerindeki harf ve rakamları ayrı ayrı tespit edebildiği için tek bir algılayıcı oluşturmak yerine harfler ve rakamlar için 2 farklı ağ yapısı üretilmiştir (Şekil 4.19). Bu sayede işlem yükü azalacağı gibi ağın öğrenmesi ve doğru sonuç verme olasılığı da artacaktır.

YSA, olabildiğince düşük hata ile sonuç alınabilmesi için gerekli miktarda eğitim verisi ile eğitilir. Bu nedenle çeşitli plaka görsellerinden elde edilen karakterlerin 17 elemanlı özellik vektörleri ile ağ eğitilmiştir. Harf karakterlerini sınıflandıran ağın eğitilmesi için her bir harfin 14 farklı örneğine ait özellik vektörleri içeren eğitim veri seti kullanılmıştır. Rakam karakterlerini sınıflandıran ağın eğitilmesi için de her bir rakamın 20 farklı örneğine ait özellik vektörleri içeren eğitim veri seti kullanılmıştır.



Şekil 4.19 Harf ve Rakamlar İçin Oluşturulan İleri Yayılımlı Yapay Sinir Ağları.

Harf ve rakam ağları 14 ara katmandan oluşturulmuştur. Aktivasyon fonksiyonu olarak logaritmik sigmoid fonksiyonu kullanılmıştır. Harf ağı toplam 322 adet özellik vektör verisi ile 16 iterasyon sonucu öğrenmesini tamamlarken, Rakam ağı ise 200 adet özellik vektör verisi ile 11 iterasyon sonucu öğrenme sürecini tamamlamıştır.

BÖLÜM 5

BULGULAR VE TARTIŞMA

Dairesel şekil histogramı ile plaka karakterlerine ait 17 elemanlı özellik vektörleri oluşturularak plakaların tespit edilmesi için iki farklı sınıflandırma yöntemi kullanılmıştır. Lineer yöntem ve YSA kullanılarak karakterler, özellik vektörleri ile sınıflandırılmıştır. Lineer sınıflandırma yönteminde bir veritabanı oluşturulmuş, plaka karakterlerinin özellik vektörleri ile veritabanındaki tüm karakterlere ait özellik vektörleri matematiksel olarak karşılaştırılmıştır. YSA ile karakter tanıma yönteminde ise bir ağ oluşturulmuş, plaka görüntülerinden elde edilen karakter özellik vektörleri ile ağ eğitilerek araç plaka karakterlerini tespit edebilen bir algılayıcı ortaya koyulmuştur.

5.1 LİNEER YÖNTEM İLE KARAKTER TANIMA SONUÇLARI

Karakterlerin tanımlanması için kullanılan lineer sınıflandırma yöntemi için, 4 farklı yazı tipine sahip plakalara ait karakterlerden ortalama özellik vektörleri elde edilerek bir veritabanı oluşturulmuştur. Veritabanı oluşturulurken kullanılan plaka karakterleri, bilgisayar ortamında hazırlanmış olan gürültüsüz ve çeşitli görüntü bozukluklarına maruz kalmamış plaka görüntülerinden elde edilmiştir. Bu sayede en doğru karakter özellik vektörlerini elde etmek amaçlanmıştır. Tanımlanması istenilen karakterler de veritabanındaki harf ya da rakam özellik vektörleri ile lineer olarak karşılaştırılıp her harf ya da her rakam ile arasındaki hata miktarları hesaplanmıştır.

Lineer yöntem ile çeşitli plaka yapılarına sahip yedi ya da sekiz adet harf ve rakam karakteri içeren 83 plaka görüntüsü incelenmiştir. Çizelge 5.1'de harfler ve rakamların ayrı ayrı incelenip, doğru ve yanlış tespit edilen karakter miktarları ile başarı oranları verilmiştir.

Çizelge 5.1 Lineer yöntem ile karakter tanıma sonuçları.

	Harf	Oran	Rakam	Oran
Toplam	183	%100	360	%100
Doğru Tespit Edilen	174	%95,1	342	%95
Yanlış Tespit Edilen	9	%4,9	18	%5

Elde edilen sonuçlarda görüldüğü üzere, 183 harf karakterinin 174 tanesi doğru tespit edilmiş, 9 karakter için hatalı sonuç elde edilmiştir. Rakam karakterlerinde ise toplam 360 karakter görüntüsünden 342 tanesi doğru harf olarak tespit edilirken, 18 tanesinde ise hatalı sonuç elde edilmiştir. Sonuç olarak lineer yöntem ile harf ve rakamlar için hemen hemen aynı başarı oranı yaklaşık %95 olarak sağlanmıştır.

5.2 YAPAY SİNİR AĞLARI İLE KARAKTER TANIMA SONUÇLARI

Özellik çıkarımı ile karakter tanıma işlemi için bir veritabanı oluşturmak yerine öğrenebilen bir YSA modeli oluşturularak, çok çeşitli yazı tiplerine ait gerçek plaka görüntüleri ile bir algılayıcı önerilmiştir. Ayrıca veritabanındaki özellik vektörlerinin, çeşitli yazı tipindeki karakterlerinin ortalamaları ile elde edilmesinden dolayı, herhangi bir karakter yanlış tanımlandığı zaman benzer karakterler için de yanlış sonuç vermesi muhtemeldir. Çünkü lineer yöntem kararlı sonuçlar vereceği için sonuçları düzeltmek adına yapılabilecek adımlar sınırlıdır. Her çeşit yazı tipindeki karakterler için ayrı ayrı matematiksel karşılaştırılma yapılması da işlem yükünü artıracaktır. Özellik çıkarım yöntemlerinin en büyük avantajı işlem yükünü azaltmaktır. Bu sebeple makine öğrenimi ile hazır plakalar kullanmak yerine dış ortamdan elde edilen çok çeşitli plaka görüntüsü ile öğrenme yapılması hedeflenmiştir.

Bu çalışmada İYSA ile harf ve rakamlar için iki farklı algılayıcı oluşturulmuştur. Tanımlanması istenilen tüm plaka karakter görüntülerinden elde edilen 17 elemanlı özellik vektörleri ile bir test verisi seti hazırlanmıştır. Plaka karakterlerinin harf ya da rakam olduğu zaten tespit edebildiği için harfler ve rakamlar kendi ağlarına verilmek üzere ayrı gruplarda toplanmıştır. Çizelge 5.2'de harf ve rakam karakterleri için incelenen test verileri ve sonuçları ifade edilmiştir.

Çizelge 5.2 Yapay Sinir Ağları ile karakter tanıma sonuçları.

	Harf	Oran	Rakam	Oran
Toplam	183	%100	360	%100
Doğru Tespit Edilen	178	%97,3	354	%98,3
Yanlış Tespit Edilen	5	%2,7	6	%1,7

Çizelge verilerinde görüldüğü üzere İleri Yayılımlı Yapay Sinir Ağı ile toplam 543 plaka karakteri için yaklaşık %98’lik doğru karakter tespit oranı elde edilmiştir. Ağların oluşturulup eğitilmesi ve tüm test verilerinin sonuçlandırılması harf grubu için 4 sn, rakam grubu için 3 sn sürmüştür.

5.3 ÖNERİLEN SINIFLANDIRMA YÖNTEMLERİN KARŞILAŞTIRILMASI

Karakter özellik vektörlerinin lineer yöntem ile sınıflandırılması sonucu %95’lik bir başarı oranı elde edilmesine rağmen, veritabanı oluşturulması, tüm karakterlerin 17 elemanı ile matematiksel farklılıklarının hesaplanıp toplanması ve kıyaslanması daha statik bir işlem süreci içermektedir. Veritabanındaki karakter özellik vektörlerinin, birkaç yazı tipine ait karakterlerin aritmetik ortalamaları ile oluşturulması, çok farklı yazı tiplerindeki karakterleri yanlış tanımasına sebep olabilmektedir. Ayrıca veritabanının önceden oluşturulması, yanlış tespit edilen bir yazı tipindeki karakterin sürekli aynı sonucu vermesine neden olacaktır. Daha dinamik bir sınıflandırma yöntemi için algılayıcının bir YSA ile oluşturulması, sistemin öğrenme becerisinin artırılabilmesine imkân sunmaktadır. YSA ile plaka karakter tanıma başarı oranı da bu sebeplerden dolayı lineer yönteme göre daha yüksek sonuç vermiştir. Ayrıca karakter tanıma sürecindeki işlem yükü lineer yönteme göre daha azdır ve daha hızlı sonuç verebilmektedir.

Dairesel şekil histogramları ile plaka karakterlerinin tespit edilmesinde, YSA kullanılarak %98’lik bir başarı oranı sağlanırken, karakterlerin özellik vektörleri 17 elemanlı olarak oluşturulmuştur. Literatürde bahsedilen diğer özellik çıkarımı ile plaka tanıma çalışmaları bu çalışma ile karşılaştırılırken, iki farklı parametre incelenmiştir. Söz konusu parametreler özellik vektör eleman sayıları ve doğru olarak tespit edilen karakter oranlarıdır. Çünkü kullanılan yöntemlerin hem başarılı hem de hızlı sonuç verebilen bir yöntem olması istenir. Hızlı bir plaka tanıma işlemi için gösterilebilecek referans, çıkarılan özellik vektörlerin eleman sayılarıdır. Çizelge 5.3’de bu çalışma ile örnek olarak incelenen iki farklı özellik çıkarım yöntemine dayalı

karakter tanıma çalışmaları karşılaştırılmıştır. Yatay izdüşüm yöntemi ile Pencereleme yöntemi, bu çalışmada incelenen plaka karakterleri üzerinde de uygulanmıştır.

Çizelge 5.3 Diğer çalışmalar ile karşılaştırma sonuçları.

Çalışmalar	Vektör Eleman Sayısı	Görüntü Sayısı	Başarı Oranı
Yatay İzdüşüm Yöntemi	16	543 Karakter	%92,1
Pencereleme Yöntemi	24	543 Karakter	%97,8
Önerilen Yöntem	17	543 Karakter	%98

Önerilen yöntem ile diğer özellik çıkarım yöntemlerinden Yatay izdüşüm yöntemi ve Pencereleme yöntemini karşılaştırmak için, bu tez çalışmasında kullanılan plaka görüntüleri kullanılmıştır. Plaka karakterlerinin tespit edilmesinde işlem hızının yüksek ve başarı oranının doğru olması beklenir. Bu sebepten dolayı, incelenen diğer özellik çıkarım yöntemlerinden en az özellik vektör eleman sayısına sahip yatay izdüşüm yöntemi ile en yüksek başarı oranını sağlamış olan pencereleme yöntemleri de incelenmiştir. Yatay izdüşüm yönteminde elde edilen özellik vektör eleman sayısı 16 iken, 543 plaka karakteri için %92,1'lik bir doğru karakter tespit oranı sağlamıştır. Pencereleme yönteminde ise 543 karakter için %97,8'lik karakter tanıma başarı oranı görülmekteyken, kullanılan özellik vektör eleman sayısı 24'tür. Önerilen yöntemde ise özellik vektör eleman sayısı 17 iken 543 plaka karakteri için %98'lik doğru karakter tespit oranı elde edilmiştir. Yatay izdüşüm yönteminden sadece 1 fazla özellik vektör eleman sayısı olmasına rağmen çok daha yüksek bir başarı oranı sağlanmıştır. Pencereleme yönteminden daha az özellik vektör eleman sayısı kullanarak daha yüksek bir başarı oranı elde edilmiştir.

BÖLÜM 6

SONUÇ VE ÖNERİLER

Bu tez kapsamında araç plakalarının tespit edilmesi için mevcut bir çok karakter tanıma çalışmalarına karşı yeni bir alternatif plaka karakterlerini belirleme yöntemi sunulmuştur. Literatürdeki plaka tanıma çalışmaları genel olarak şablon eşleştirme yöntemleri ve özellik çıkarım yöntemleri olarak ikiye ayrılmaktadır. Karakter piksellerinin eşleştirildiği şablon eşleştirme yöntemleri genel olarak yüksek başarı oranı sağlamakla birlikte gürültü ve diğer olumsuz görüntü koşullarına karşı daha duyarlı bir yöntemdir. Ayrıca özellik çıkarım yöntemlerine göre daha fazla işlem yükünün olduğu bir sürece sahiptir. Plaka tanıma uygulamaları ise genel olarak dinamik bir işlemdir. Araçlar genellikle durağan değildir ve kısa zaman içerisinde bir çok plakanın tespitine ihtiyaç duyulabilmektedir.

Özellik çıkarım yöntemlerinde ise karakterleri oluşturan piksellerin çeşitli yönlerden gruplandırılması ile karakterlere ait farklılıklar özellik vektörleri olarak ayrıştırılırlar. Bu sayede karakterlerin sınıflandırılması sürecinde daha az sayıda veri ile karakter tanıma yapılabilmektedir. Bu amaç doğrultusunda, karakterlere ait özellik vektörlerini oluşturmak için dairesel şekil histogramından yararlanılmıştır. Dairesel bir alan içerisinde incelenen karakterler, çeşitli bölgelere ayrılarak piksel yoğunlukları ortaya konulmuştur. Çok çeşitli dairesel şekil histogram modelleri içerisinde, karakterleri birbirinden ayırabilecek minimum eleman sayısına sahip model seçilmiştir. Karakterler iç içe iki çember ve sekiz doğrusal kesit ile bölünmüş, ayrıca karakter merkez bölgesi de bölünmemiş başka bir çember ile ayrılarak 17 sektöre sahip bir şekil histogram modeli oluşturulmuştur. Karakterler 17 farklı sektöre ayrılarak, tüm sektörlerdeki piksel yoğunlukları ile karakterlerin 17 elemanlı özellik vektörleri elde edilmiştir. Söz konusu özellik vektörleri ile iki farklı sınıflandırma yöntemi denenmiştir. Lineer yöntem ile veritabanında tutulan karakter özellik vektörleri matematiksel olarak karşılaştırılarak %95'lik bir başarı oranı elde edilmiştir. Başka bir sınıflandırma yöntemi için ise bir YSA modeli kullanılmıştır. Gerçek araç görüntülerine ait 17 elemanlı özellik vektörleri ile eğitilen bir algılayıcı ile %98'lik bir başarı oranı elde edilmiştir. Daha hızlı plaka tanıma

işlemleri yapabilmek için geliştirilen özellik çıkarım yöntemlerine göre daha az eleman sayısına sahip özellik vektörleri kullanılarak söz konusu çalışmalara göre hem daha hızlı hem de daha başarılı bir plaka tanıma çalışması sunulmuştur.

Araç plakaları elde edilirken maruz kalınan olumsuz koşullardan birisi de araç plakalarının düz bir şekilde değil, çeşitli eğimlere sahip olmasıdır. Dairesel şekil histogramı oluşturulurken, karakterleri içerisine alan dış çemberler, aralarında belirli açılar bulunan kesitler ile bölünmektedir. Oluşturulan kesitler ile ortaya çıkan sektör numaraları değiştirilerek, çeşitli açılardaki karakterlerin tespit edilebilmesi fikri de ortaya koyulabilir. Çünkü karakterler dikdörtgensel bir alan içerisinde değil, bir daireSEL bölge içerisinde incelenmektedir. Herhangi bir karakterin çeşitli açılarda döndürülmesi, karakteri içerisine alan dairenin açısını değiştirmeyecektir. Bu durumda sadece sektör numaraları değiştirilerek tüm açılardaki karakterlerin tespit edilebilmesi mümkün olabilir. Ayrıca bu yöntemin, diğer özellik çıkarım yöntemlerine göre daha az eleman sayısı içermesi, otoyollarda hız takip sistemlerine entegre edilerek yaygınlaşmasına da olanak sağlayabilecektir.

KAYNAKLAR

- [1] **Connell S D and Jain A K** (2001). Template-based online character recognition. *Pattern Recognition*, 34(1): 1-14.
- [2] **Naito T, Tsukada T, Yamada K, Kozuka K, and Yamamoto S** (2000). Robust license-plate recognition method for passing vehicles under outside environment. *IEEE Transactions on Vehicular Technology*, 49(6): 2309-2319.
- [3] **Huang Y P, Chen C H, Chang Y T and Sandnes F E** (2009). An intelligent strategy for checking the annual inspection status of motorcycles based on license plate recognition. *Expert Systems with Applications*, 36(5): 9260-9267.
- [4] **Xiaobo L, Xiaojing L, and Wei H** (2003). Vehicle license plate character recognition, *International Conference on Neural Networks and Signal Processing*, 14-17 December 2003, Nanjing, China, 1066-1069.
- [5] **Ozbay S and Ercelebi E** (2005). Automatic vehicle identification by plate recognition. *World Academy of Science, Engineering and Technology*, 9(41): 222-225.
- [6] **Horowitz M** (1957). Efficient use of a picture correlator. *JOSA*, 47(4): 327-327.
- [7] **Rahman C A, Badawy W and Radmanesh A** (2003). A real time vehicle's license plate recognition system, *IEEE Conf. Adv. Video Signal Based Surveillance*, 22-22 July 2003, Miami FL, USA, 163-166.
- [8] **Aghdasi F and Ndungo H** (2004). Automatic license plate recognition system, *Proc. AFRICON Conf. Africa*, 15-17 September 2004, Gaborone, Botswana, 45-50.
- [9] **Nukano T, Fukumi M and Khalid M** (2004). Vehicle license plate character recognition by neural networks, *Int. Symp. Intell. Signal Process. Commun. Syst.*, 18-19 November 2004, Seoul, Sputh Korea, 771-775.
- [10] **Abdullah S N H S, Khalid M, Yusof R and Omar K** (2006). License plate recognition using multicluster and multilayer neural networks, *2nd Information and Communication Technologies*, 24-28 April, Damascus, Syria, 1818-1823.
- [11] **Kirsch, R. A.** (1971). Computer determination of the constituent structure of biological images. *Computers and biomedical research*, 4(3): 315-328.
- [12] **Jiao J, Ye Q and Huang Q** (2009). A configurable method for multistyle license plate recognition. *Pattern Recognition*, 42(3): 358-369.

KAYNAKLAR (devam ediyor)

- [13] **Pan M S, Yan J B and Xiao Z H** (2008). Vehicle license plate character segmentation. *International Journal of Automation and Computing*, 5(4): 425-432.
- [14] **Comelli P, Ferragina P, Granieri M N and Stabile F** (1995). Optical recognition of motor vehicle license plates. *IEEE transactions on Vehicular Technology*, 44(4): 790-799.
- [15] **Lee E R, Kim P K and Kim H J** (1994). Automatic recognition of a car license plate using color image processing. *1st International Conference on Image Processing*, 13-16 November 1994, Austin, TX, USA, 301-305.
- [16] **Hidayatullah P, Syakrani N, Suhartini I and Muhlis W** (2012). Optical character recognition improvement for license plate recognition in Indonesia. *2012 Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation*, 14-16 November 2012, Valetta, Malta, 249-254.
- [17] **Miyamoto K, Nagano K, Tamagawa M, Fujita I and Yamamoto M** (1991). Vehicle license-plate recognition by image analysis, *Int. Conf. Ind. Electron. Control Instrum.*, 28 October-1 November 1991, Kobe, Japan, 1734-1738.
- [18] **Kanayama K, Fujikawa Y, Fujimoto K and Horino M** (1991). Development of vehicle-license number recognition system using real-time image processing and its application to travel-time measurement, *41st IEEE Vehicular Technology Conference*, 19-22 May 1991, St. Louis, MO, USA, 798-804.
- [19] **Chang S L, Chen L S, Chung Y C and Chen S W** (2004). Automatic license plate recognition. *IEEE transactions on intelligent transportation systems*, 5(1): 42-53.
- [20] **Singh S** (2013). Optical character recognition techniques: a survey. *Journal of emerging Trends in Computing and information Sciences*, 4(6): 545-550.
- [21] **Roy A and Ghoshal D P** (2011). Number Plate Recognition for use in different countries using an improved segmentation, *2nd National Conference on Emerging Trends and Applications in Computer Science*, 4-5 March 2011, Shillong, India, 1-5.
- [22] **Choras R S** (2007). Image feature extraction techniques and their applications for CBIR and biometrics systems. *International journal of biology and biomedical engineering*, 1(1): 6-16.
- [23] **Kumar G and Bhatia P K** (2014). A detailed review of feature extraction in image processing systems, *4th International Conference on Advanced Computing & Communication Technologies (ACCT)*, 8-9 February 2014, Rohtak, India, 5-12.
- [24] **Cheng L, Gong J, Yang X, Fan C and Han P** (2008). Robust affine invariant feature extraction for image matching. *IEEE Geoscience and remote sensing letters*, 5(2): 246-250.

KAYNAKLAR (devam ediyor)

- [25] **Cho M, Kwak S, Schmid C and Ponce J** (2015). Unsupervised object discovery and localization in the wild: Part-based matching with bottom-up region proposals, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7-12 June 2015, Boston, MA, USA, 1201-1210.
- [26] **Kazhdan M, Funkhouser T and Rusinkiewicz S** (2003). Rotation invariant spherical harmonic representation of 3d shape descriptors, *Symposium on geometry processing*, 23-25 June 2003, 156-164.
- [27] **Chen D Y, Tian X P, Shen Y T and Ouhyoung M** (2003). On visual similarity based 3D model retrieval, *Computer graphics forum*, 4 November 2003, Malden, MA, USA, 223-232.
- [28] **Körtgen M, Park G J, Novotni M and Klain R** (2003). 3D shape matching with 3D shape contexts, *The 7th central European seminar on computer graphics*, 22-24 April 2003, Budmerice, Slovakia, 5-17.
- [29] **Daras P and Axenopoulos A** (2010). A 3D shape retrieval framework supporting multimodal queries. *International Journal of Computer Vision*, 89(2-3): 229-247.
- [30] **Huang P, Hilton A and Starck J** (2010). Shape similarity for 3D video sequences of people. *International Journal of Computer Vision*, 89(2-3): 362-381.
- [31] **Duan T D, Du T H, Phuoc T V and Hoang N V** (2005). Building an automatic vehicle license plate recognition system. *Int. Conf. Comput. Sci. RIVF*, February 2005, Ninh Kieu, Vietnam, 59-63.
- [32] **Khalifa O O, Khan S, Islam M R and Suleiman A** (2007). Malaysian Vehicle License Plate Recognition. *Int. Arab J. Inf. Technol.*, 4(4): 359-364.
- [33] **Dia Y, Zheng N, Zhang X and Xuan G** (1988). Automatic recognition of province name on the license plate of moving vehicle, *Int. Conf. Pattern Recognit.*, 14 May-17 November 1988, Rome, Italy, 927-929.
- [34] **Ko M A and Kim Y M** (2004). A simple OCR method from strong perspective view, *Appl. Imagery Pattern Recognit. Workshop*, 13-15 October 2004, Washington, DC, USA, 235-240.
- [35] **Kim M K and Kwon Y B** (1996). Multifont and multisize character recognition based on the sampling and quantization of an unwrapped contour, *Int. Conf. Pattern Recognit.*, 25-29 August 1996, Vienna, Austria, 170-174.
- [36] **Tian D P** (2013). A review on image feature extraction and representation techniques. *International Journal of Multimedia and Ubiquitous Engineering*, 8(4): 385-396.

KAYNAKLAR (devam ediyor)

- [37] **Du S, Ibrahim M, Shehata M and Badawy W** (2012). Automatic license plate recognition (ALPR): A state-of-the-art review. *IEEE Transactions on circuits and systems for video technology*, 23(2): 311-325.
- [38] **Hyun-Chul K, Dajin K and Bang S Y** (2002). A numeral character recognition using the PCA mixture model. *Pattern Recognition Letters*, 23(1-3): 103-111.
- [39] **Hinton G E, Dayan P and Revow P** (1997). Modeling the manifolds of images of handwritten digits. *IEEE Transactions on Neural Networks*, 8(1): 65-74.
- [40] **Lazrus A and Choubey S** (2011). A robust method of license plate recognition using ANN. *Int. J. Comput. Sci. Inf. Technol*, 2(4): 1494-1497.
- [41] **Kakani B V, Gandhi D and Jani S** (2017). Improved OCR based automatic vehicle number plate recognition using features trained neural network, *8th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 3-5 July 2017, Delhi, India, 1-6.
- [42] **Jain A S and Kundargi J M** (2015). Automatic number plate recognition using artificial neural network. *International Research Journal of Engineering and Technology (IRJET)*, 2(4): 56-72.
- [43] **Yao X** (1999). Evolving artificial neural networks. *Proceedings of the IEEE*, 87(9): 1423-1447.
- [44] **Öztemel E.** (2012). *Yapay sinir ağları*. 3üncü basım, ISBN: 978-975-6797-39-6, Papatya, İstanbul, 232 pp/s.
- [45] **Kocer H E and Cevik K K** (2011). Artificial neural networks based vehicle license plate recognition. *Procedia Computer Science*, 3: 1033-1037.
- [46] **Capar A and Gokmen M** (2006). Concurrent segmentation and recognition with shape-driven fast marching methods, *18th Int. Conference on Pattern Recognition*, 20-24 August 2006, Hong-Kong, China, 155–158.
- [47] **Huang Y P, Chen C H, Chang Y T and Sandnes F E** (2009). An intelligent strategy for checking the annual inspection status of motorcycles based on license plate recognition. *Expert Systems with Applications*, 36(5): 9260-9267.
- [48] **Shi X, Zhao W and Shen Y** (2005). Automatic license plate recognition system based on color image processing, *International Conference on Computational Science and Its Applications*, 9-12 May 2005, Singapore, 1159-1168.
- [49] **Wang M L, Liu Y H, Liao B Y, Lin Y S and Horng M F** (2010). A vehicle license plate recognition system based on spatial/frequency domain filtering and neural networks, *International Conference on Computational Collective Intelligence*, 10-12 November 2010, Kaohsiung, Taiwan, 63-70.

KAYNAKLAR (devam ediyor)

- [50] Wen Y, Lu Y, Yan J, Zhou Z, von Deneen K M and Shi P (2011). An algorithm for license plate recognition applied to intelligent transportation system. *IEEE Transactions on Intelligent Transportation Systems*, 12(3): 830-845.
- [51] Gonzalez R C, and Woods R E (2002). *Digital image processing*. 2nd edition, Prentice Hall, New Jersey.
- [52] Wohlkinger W and Vincze M (2011). Ensemble of shape functions for 3d object classification, *2011 IEEE international conference on robotics and biomimetics*, 7-11 December 2011, Karon Beach, Phuket, Thailand, 2987-2992.
- [53] Ankerst M, Kastenmüller G, Kriegel H P and Seidl T (1999). 3D shape histograms for similarity search and classification in spatial databases, *International Symposium on Spatial Databases*, 20-23 July 1999, Hong Kong, China, Lecture Notes in Computer Science, Güting H G, Dimitris P, Lochovsky F (Ed.), vol. 1651, 207-226.
- [54] Tangelder J W and Veltkamp R C (2004). A survey of content based 3D shape retrieval methods. *Shape Modeling Applications*, 145-156.
- [55] Otsu N (1979). A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, 9(1): 62-66.
- [56] He L, Chao Y, Suzuki K and Wu K (2009). Fast connected-component labeling. *Pattern recognition*, 42(9): 1977-1987.
- [57] Arslan R U, İncetaş M O and Dikici S (2019). Effects of Character Recognition with Shell Histogram Method Using Plate Characters. *Politeknik Dergisi*, 22(4): 1093-1099.



ÖZGEÇMİŞ

Sedat DİKİCİ, 1992 yılında Ankara’da dünyaya geldi. İlk ve orta öğrenimini Ankara’da Batıkent İlköğretim Okulu’nda tamamladı. Kaya Bayazitođlu Lisesi’nden mezun olduktan sonra 2010 yılında Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi Elektrik-Elektronik Mühendisliđi Bölümü’ne girdi. 2015 yılında Elektrik-Elektronik Mühendisliđi Lisans diploması aldıktan sonra 2016 yılında ODTÜ Teknokent Erbul firmasında gömülü sistemler uygulamalarında görev alarak 9 ay mühendis olarak çalıştı. 2017 yılında yılında Bülent Ecevit Üniversitesi Elektrik-Elektronik Mühendisliđi Bölümü’nde Araştırma görevlisi pozisyonunda çalışmaya başladı. Aynı yıl Bülent Ecevit Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliđi Anabilim Dalı Yüksek Lisans Programına başladı. Halen Bülent Ecevit Üniversitesi’nde çalışmalarını sürdürmektedir.

İLETİŞİM BİLGİLERİ:

E-posta: sedat.dikici@beun.edu.tr.