



**T.C.
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY ZEKA YÖNTEMLERİ İLE ARAÇ
PLAKA TANIMA SİSTEMİ**

Kerim Kürşat ÇEVİK

YÜKSEK LİSANS TEZİ

**Elektronik ve Bilgisayar Sistemleri Eğitimi
Anabilim Dalını**

**Ağustos-2010
KONYA
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Kerim Kürşat ÇEVİK tarafından hazırlanan “Yapay Zeka Yöntemleri ile Araç Plaka Tanıma Sistemi” adlı tez çalışması 01./02./2010 tarihinde aşağıdaki jüri tarafından oy birliği / ~~oy çokluğu~~ ile Selçuk Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Bilgisayar Sistemleri Eğitimi Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Yrd. Doç. Dr. Adem Alpaslan ALTUN



Danışman

Yrd. Doç. Dr. Hasan Erdinç KOÇER

Üye

Yrd. Doç. Dr. Ömer Kaan BAYKAN

İmza



Yukarıdaki sonucu onaylarım.

Prof. Dr. Bayram SADE
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.



Kerim Kürşat ÇEVİK

Tarih: 07.03/2010

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY ZEKÂ YÖNTEMLERİ İLE ARAÇ PLAKA TANIMA SİSTEMİ

Kerim Kürşat ÇEVİK

**Selçuk Üniversitesi Fen Bilimleri Enstitüsü
Elektronik ve Bilgisayar Sistemleri Eğitimi Anabilim Dalı**

Danışman: Yrd. Doç. Dr. Hasan Erdiñ KOÇER

2010, 75 Sayfa

Jüri

Yrd. Doç. Dr. Adem Alpaslan ALTUN

Yrd. Doç. Dr. Hasan Erdiñ KOÇER

Yrd. Doç. Dr. Ömer Kaan BAYKAN

Günümüzde teknolojiadaki hızlı gelişme insan hayatını büyük ölçüde kolaylaştırmaktadır. Özellikle güvenlik alanında teknolojinin kullanım oranı her geçen gün artmaktadır. Son yıllarda trafikte seyreden araç sayısının artmasıyla trafik denetlemesi yapan personel ihtiyacı artmaktadır. Bu ihtiyacı azaltmak amacıyla bilgisayar kontrollü otomatik denetleme sistemleri geliştirilmektedir. Bu sistemlerden bir tanesi de otomatik araç plaka tanıma sistemleridir. Bu sayede araçların belirleyici özelliği olan plakalar bir kamera yardımıyla bilgisayarlı sisteme iletilmekte ve plaka tanınmaktadır. Bu tanıma işlemi çeşitli yöntemler kullanılarak gerçekleştirilir. Araç plakası görüntü işleme algoritmaları kullanılarak tanınmaktadır. Bu çalışmada, insan gücünden tasarruf sağlamak ve güvenliği artırmak amacıyla görüntü işleme algoritmaları ve yapay sinir ağları ile plaka tanıma sistemi gerçekleştirilmiştir.

Bu tezde gerçekleştirilen plaka tanıma sistemi bir kamera yardımıyla görüntüyü alıp sisteme bağlı bilgisayara iletmekte, alınan araç görüntüsü içersinde yer alan plaka bölgesi tespit edilmekte, plaka içersindeki karakterler ayrıştırılıp tanınmaktadır. Plaka bölgesinin tespiti aşamasında kenar bulma algoritması kullanılmıştır. Karakterlerin ayrıştırılması işleminde blob coloring yöntemi uygulanmıştır. Ayrıştırılan karakterler ileri beslemeli geri dönüşümlü çok katmanlı perseptron sinir ağı kullanılarak tanınmıştır.

Gerçekleştirilen motorlu araçlar için plaka tanıma sistemi trafik denetleme, gişe otomasyonu ve denetimli saha giriş kontrolü (hastane, askeri tesis vb.) uygulamalarında kullanılabilir.

Bu tez çalışmasında 259 araç görüntüsü kullanılarak plaka tanıma işlemi gerçekleştirilmiştir. Plaka yerinin tespitinde 259 araç görüntüsü içersinden 255’inde plaka bölgesi doğru olarak tespit edilmiştir. Plaka bölgesi tespitinde başarı oranı %98,45 olarak elde edilmiştir. Doğru tespit edilen bu 255 plakanın karakterlerine ayrılması işleminde 3 plakanın karakterlerinin yanlış tespit edildiği gözlenmiştir. Karakterlere

ayırma işleminde %98,82 başarı elde edilmiştir. Bu görüntülerden elde edilen plaka bölgesinde yer alan karakterler harf ve rakam olarak ayrıştırılmıştır. Ayrıştırma işlemi sonunda 1222 adet rakam, 597 adet harf elde edilmiştir. Elde edilen rakamlardan 200 tanesi yapay sinir ağının eğitim aşamasında, kalan 1022 adet rakam bilgisi test aşamasında kullanılmıştır. 597 adet harften ise 250 tanesi yapay sinir ağının eğitim aşamasında, kalan 347 adedi ise test aşamasında kullanılmıştır. Rakamların test edilmesi sonucunda 22 adet rakamın doğru sınıflandırılmadığı, kalan 1000 adet rakamın doğru sınıflandırıldığı gözlemlenmiştir. Dolayısıyla rakam için genel doğru sınıflandırma oranı %97,84 olmuştur. Harflerin test edilmesi sonucunda 3 adet harfin yanlış sınıflandırıldığı, kalan 344 adet harfin doğru sınıflandırıldığı gözlenmiştir. Dolayısıyla harfler için genel doğru sınıflandırma oranı %99,13 olmuştur. Genel anlamda 259 araç görüntüsünden 247 adedinin plakası tam ve doğru olarak tanınmıştır. Dolayısıyla genel başarı oranı 95,36 olmuştur.

Anahtar Kelimeler: Araç plaka tanıma, görüntü işleme, karakter tanıma, yapay sinir ağları

ABSTRACT

MS THESIS

VEHICLE LICENSE PLATE RECOGNITION SYSTEM WITH ARTIFICIAL INTELLIGENCE METHODS

Kerim Kürşat ÇEVİK

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
SELÇUK UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRONIC AND COMPUTER SYSTEMS EDUCATION**

Advisor: Asst. Prof. Dr. Hasan Erdiñ KOÇER

2010, 75 Pages

Jury

Asst. Prof. Dr. Adem Alpaslan ALTUN

Asst. Prof. Dr. Hasan Erdiñ KOÇER

Asst. Prof. Dr. Ömer Kaan BAYKAN

The fast development in today's technology make human being life easier. Especially usage rates of technology in security feild is growing up day by day. In recent years, the necessity of personal working in traffic control is increasing because of inceasing of vehicle number. For this purpose, computer based automatic control systems are being developed. One of these systems is automatic vehicle plate recognition system. In these systems, the image of the plate which recognize the vehicles are taken by camera and this image send to computerized system and then the plate is identified. This identification can be implemented by using different methods. The vehicle plate can be identified by applying the images processing algorithms. In this work, for saving human force and increasing the security, the vehicle plate recognition system is developed by using image processing algorithms and artificial neural networks.

The vehicle plate recognition system carried out in this thesis is transfers the vehicle pictures taken from the camera to the computer, then the plate region is determined by using image processing algorithms, then the characters placing in the plate are located and reconized. In determination of the plate region, the edge detection operators are used. The blob coloring method is applied for seperation of the characters. These seperated characters are classified by using feed forward back propagated multi layered perceptron neural networks.

The implemented vehicle plate recognition system can be used in traffic control, toll automations and controlled area entry (hospital, car-parking etc.) applications.

In this thesis study, 259 vehicle pictures is used in plate recognition system. In determination of the plate region, 255 of 259 vehicle pictures are determined correct. The success rate of determination of the plate region is 98,45 percent. In localization of the characters stage, 3 of 255 plate image is mislocalized. The success rate of the localization of the characters is 98,82 percent. The characters which determined form the plates, are categorized as letters and numbers. After this process, 1222 number and 597 letter is obtained. 200 of these numbers are used in training process of artificial neural networks and the rest (1022 numbers) is used in testing phase. 250 of the obtained letters are applied in training phase of the neural networks and the rest (347 letters) is used for testing the system performance. As a result of the testing processes, 22 of the numbers are misclassified and 3 of the letters are misclassified. Therefore, the correct classification rate for the numbers is 97,84 percent, the correct classification rate for the letters is 99,13 percent. In general, 247 of 259 vehicle pictures are classified correctly. Consequently, the overall success rate for this application is 95,36 percent.

Keywords: Vehicle plate recognition, image processing, character recognition, artificial neural networks

ÖNSÖZ

Bu çalışmanın ortaya çıkmasında büyük sabır göstererek yardımlarını esirgemeyen ve değerli akademik bilgileri ile bana yol gösteren danışman hocam Yrd. Doç. Dr. Hasan Erdinç KOÇER' e sonsuz teşekkürlerimi sunarım.

Ayrıca çalışmam sırasında bana maddi manevi desteklerini esirgemeyen canım aileme teşekkürü bir borç bilirim.

Kerim Kürşat ÇEVİK
KONYA-2010

İÇİNDEKİLER

ÖZET	i
ABSTRACT.....	iii
ÖNSÖZ	v
İÇİNDEKİLER	vi
ŞEKİLER LİSTESİ	viii
TABLolar LİSTESİ	x
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	4
3. MATERYAL VE METOT.....	11
4. TEORİK ESASLAR.....	13
4.1. Örüntü Tanıma	13
4.1.1. Örüntü tanıma kavramı	14
4.1.2. Örüntü tanıma sistemleri.....	15
4.1.3. Örüntü tanıma sisteminin bileşenleri	19
4.2. Yapay Sinir Ağları	24
4.2.1. YSA'nın genel özellikleri.....	25
4.2.2. YSA'nın dezavantajları	25
4.2.3. YSA'nın temel yapısı	26
4.2.4. Yapay sinir ağı hücresi	28
4.2.5. YSA öğrenme algoritmaları.....	30
4.2.6. Performans fonksiyonunun seçimi.....	31
4.2.7. YSA modelleri	32
4.2.8. Çok Katmanlı Perseptron (MLP) Modeli	33
5. PLAKA TANIMA SİSTEMİ	39
5.1. Resmin Kameradan Alınması	39
5.2. Alınan Resimde Plakanın Bulunması	39
5.2.1. Kenar Bulma algoritması	40
5.3. Plakanın Görüntüsünün Netleştirilmesi	42
5.3.1. Kontrast genişletme	43
5.3.2. Ortanca filtresi	43
5.4. Karakterlerin Ayrıştırılması	44
5.4. Karakterlerin Tanınması	46
5.5. Deneysel Sonuçlar	50
6. SONUÇLAR VE ÖNERİLER.....	54
KAYNAKLAR	57

ÖZGEÇMİŞ	62
-----------------------	-----------

ŞEKİLER LİSTESİ

Şekil 3.1. Araç plaka tanıma sistemi blok şeması	11
Şekil 4.1. Aynı sınıfa ait örüntülerin sınıflandırılması	13
Şekil 4.2. Karakter örüntüsü	14
Şekil 4.3. Örüntü tanıma kavramı ve aşamaları.....	15
Şekil 4.4. Yaygın olarak kullanılan örüntü tanıma sistemi.....	15
Şekil 4.5. Bayes karar teorisi	16
Şekil 4.6. Yapısal örüntü tanıma sistemi	17
Şekil 4.7. Yapısal örüntü tanıma yöntemleri	18
Şekil 4.8. Akıllı örüntü tanıma sistemi	18
Şekil 4.9. Yapay sinir ağı sistemi	19
Şekil 4.10. Örüntü tanıma sisteminin bileşenleri.....	20
Şekil 4.11. Eşikleme işleminden geçirilmiş resim.....	21
Şekil 4.12. Kenarları çıkartılmış örüntülerden oluşan resim	23
Şekil 4.13. Temel yapay sinir ağı hücresi.....	28
Şekil 4.14. Çok katmanlı perseptron ağ yapısı	33
Şekil 4.15. Eğitim işlemi.....	38
Şekil 5.1. RGB-Gri seviye dönüşüm ekranı	39
Şekil 5.2. Kameradan alınan ve Sobel kenar bulma algoritması uygulanmış görüntü ..	40
Şekil 5.3. Kameradan alınan ve Prewit kenar bulma algoritması uygulanmış görüntü.	40
Şekil 5.4. Resimdeki 3x3'lük bölge	41
Şekil 5.5. Canny kenar bulma operatörü	41
Şekil 5.6. Kameradan alınan ve Canny kenar bulma algoritması uygulanmış görüntü.	42
Şekil 5.7. Plaka yeri belirlenmiş araç görüntüsü	42
Şekil 5.8. Plakanın netleştirilmesi	43
Şekil 5.9. Ortanca filtresi uygulanacak alan	44
Şekil 5.10. L şablonu	45
Şekil 5.11. Blob coloring algoritması	45
Şekil 5.12. Blob coloring uygulanmış plaka görüntüsü.....	46
Şekil 5.13. Karakterleri ayrılmış plaka	46
Şekil 5.14. Araç plaka tanıma YSA yazılımı.....	48
Şekil 5.15. Araç plaka tanıma YSA yazılımı.....	48
Şekil 5.16. Araç plaka tanıma yazılımı.....	49

Şekil 5.17. Tanıma işlemi gerçekleştirilmiş yazılım görüntüsü	50
Şekil 5.18. Rakamların eğitim aşamasında hata oranlarının değişimi.....	51
Şekil 5.19. Harflerin eğitim aşamasında hata oranlarının değişimi.....	52

TABLÖLAR LİSTESİ

Tablo 5.1. Rakamlar için elde edilen test sonuçları	51
Tablo 5.2. Rakamlar için elde edilen test sonuçları	53
Tablo 5.3. Sistemin doğruluk oranları.....	53

1. GİRİŞ

Son çeyrek yüzyılda araç sayısının artması ve trafikte oluşan sorunlar, otomatik araç tanıma ve trafik akış kontrolü sistemlerine duyulan ihtiyacı arttırmıştır. Bu ihtiyacı karşılamaya yönelik çalışmalar temel olarak araçların bir noktadan geçerken tanımlanması, aracın konumunun belirlenmesi ve bu veriler kullanarak trafik denetiminin daha iyi yapılmasına hizmet etmektedir.

Günümüzde trafik denetimi için, radyo frekanslarını kullanan radarlar, mikrodalga detektörleri, yolun altına yerleştirilen tüpler ve loop (döngü) detektörleri bulunmaktadır. Radar detektörü araç hızını ölçmek için, mikrodalga detektörü belli bir noktadan araç geçişini algılamak için, yine yol altındaki tüpler ve loop (döngü) detektörleri araç sayısını ya da uzunluğunu ölçmek için kullanılır. Bu sistemlerde, denetimin sağlanacağı yolun giriş ve çıkışlarına yukarıda bahsedilen detektörlerin yerleştirilmesi gerekmektedir. Ancak bu donanımların kurulumu ve algılayıcıların fazlalığı bu sistemleri pahalı hale getirmektedir. Bununla beraber, bu sistemlerin işletimi de zordur (Setchell 1997).

Bilgisayar tabanlı sistemler, detektör kullanan sistemlere göre çok daha etkin bir çözüm sunmaktadır. Trafik akışının gözlemleneceği noktaya bir kamera düzeneğinin kurulması yeterli olmaktadır. Bu sistemlerin kurulumu kolay ve ucuz, verdiği bilgiler daha ayrıntılı olmaktadır.

Bununla birlikte, bilgisayar tabanlı araç plaka tanıma sistemleri yeni geliştirilen sistemlerdir. Genel olarak araç plakası tanıma işlemi iki temel adımda gerçekleştirilir; plaka yer tespiti ve plaka üzerindeki karakterlerin tanınması. Çalışmalarda plaka yeri bulma işleminde görüntü işleme rutinlerinden yararlanılmıştır. Plaka tanınmanın ikinci aşaması olan karakter tanıma işleminde ise genelde üç yöntem kullanılır: Örnek eşleştirme (template matching) (Collomosse ve Oliver 2001; Chanson ve Roberts 2001), karakteristik tabanlı tanıma ve yapay sinir ağlarıdır (Setchell 1997; Draghici 1997; Fahmy 1993; Auty ve ark. 1995).

Bu çalışmada Türkiye'de trafikte seyreden sivil araçların plakasının tanınması hedeflenmektedir. Bu plakaların genel özelliği; beyaz zemin üzerine siyah

karakterlerden oluşması, ilk iki karakterde şehir kodunu belirten rakamların olması ve ondan sonra gelen karakterlerin rastgele harf ve rakam dizisinden oluşmasıdır. Bu amaçla yolda seyreden sivil aracın görüntüsü kamera yardımıyla alınıp, görüntü işleme algoritmalarıyla plakanın yeri tespit edilerek, plakada yer alan karakterlerin yapay sinir ağları ile tanınması işlemleri gerçekleştirilmiştir. Sistemi gerçekleştiren yazılım C#.Net programlama dili kullanılarak kodlanmıştır.

Sistem kameradan alınan renkli araç görüntüsünü gri seviyeye dönüştürmektedir. Bu görüntüye kenar bulma algoritmaları uygulanarak plakanın resimden ayrıştırılması gerçekleştirilmiştir. Elde edilen görüntü 220x50 boyutundadır. Bu plaka görüntüsünün iyileştirilmesi amacıyla görüntüye kontrast genişletme ve ortanca değer filtresi uygulanmıştır. Gürültülerden arındırılan plaka görüntüsüne blob coloring algoritması uygulanmış ve plakada yer alan harf ve rakamların ayrıştırılması sağlanmıştır. Karakterlerin plaka görüntüsü içerisindeki konumuna göre harf ve rakam olarak veritabanına alınmıştır. Bu görüntüler ortalama mutlak sapma formülü ile sayısallaştırılmıştır. Bu sayısal bilgiler harf ve rakam için tasarlanan iki farklı yapay sinir ağında eğitilmiştir.

Bu tez çalışması giriş, kaynak araştırması, materyal ve metot, teorik esaslar, plaka tanıma sistemi ve sonuçlar ve öneriler olmak üzere altı bölüm ve kaynaklardan oluşmaktadır.

Birinci bölüm, giriş bölümü olup konunun genel tanımı yapılmış, çalışmanın amacı ve önemi üzerinde durulmuştur.

İkinci bölümde bu alanda yapılmış önceki çalışmalar hakkında literatür bilgisi verilmiş, bu çalışmaların özellikleri belirtilmiştir.

Üçüncü bölümde tez çalışmasında kullanılan materyal ve metotlar verilmiştir.

Dördüncü bölümde örüntü tanıma ile ilgili teorik esaslardan bahsedilmiş, yapay sinir ağlarının özellikleri, yapısı ve algoritmaları anlatılmıştır.

Beşinci bölümde uygulaması yapılan araç plaka tanıma sistemi aşama aşama anlatılmıştır. Uygulama ile ilgili resimler, şekiller ve tablolar bu bölümde sunulmuştur.

Altıncı bölümde tez çalışmasının sonuçları üzerine genel bir değerlendirme yapılmıştır. Ayrıca çalışma ile ilgili öneriler de bu bölümde yer almaktadır.

Tez çalışmasının sonunda yararlanılan kaynaklar verilmiştir.

2. KAYNAK ARAŞTIRMASI

Son yıllarda araç sayısının artması ve trafikte oluşan sorunlar, otomatik araç tanıma ve trafik akışının kontrolü üzerine çalışmalar yapılmasını gerektirmiştir. Bu amaca yönelik çalışmalar yapılmış ve değişik yaklaşımlar denenmiştir. Çalışmalar temel olarak güvenlik ihtiyacının giderilmesini yönelik olarak, araçları özel bir noktadan geçerken tanımlamak, aracın konumunu belirlemek ve buna göre trafik denetimi sağlamaya yöneliktir.

Otomatik Araç Tanıma konusunda ilk gelişme optik tarayıcı sistemlerin kullanılmasıyla 1960'larda ABD'de gerçekleşmiştir (Hauslen 1977). Daha sonraki yıllarda mikro elektronikteki gelişmeler çalışmaları yoğunlaştırmış, induktif döngü, radyo frekansları, kızılötesi ve mikrodalga sistemleri araç gözetleme ve trafik kontrolünde kullanılmıştır.

Araç tanıma teknolojisinin yol ücretlendirilmesi için denenmesi ilk olarak Hong Kong'da 1983–1985 tarihleri arasında uygulanmıştır. Önce gönüllü bir araç grubu elektronik plakalarla donatılmıştır. Sonra bu plakalara sahip araçlar yoldan geçtiğinde araçların fotoğrafları kapalı devre TV ile alınmış ve kontrol merkezine iletilmiştir (Dawson 1986). Araç Tanıma Sistemine yönelik çalışmalar özellikle Avrupa ve Japonya'da devam etmektedir. "Prometheus" denen dokuz yüz milyon dolarlık altı ülkeyi kapsayan bir proje hayata geçirilmiştir. Bu program araçları takip, elektronik ceza kesme, plaka tanıma ve araç tanımayı içermektedir. Bununla güvenliği, verimi ve konforu arttırmak, ekonomik çözümler üretmek, kirliliği azaltmak amaçlanmaktadır (Gillan 1988). Japonya'da da Prometheus' a benzer bir program yapılmıştır. Programda yapay zekâya daha çok önem verilmiş, otomatik şoför denenmiştir. Hollanda ve Norveç'te de elektronik ücret toplamaya yönelik araç tanıma sistemleri kurulmuştur (Stoelhurst ve Zandbergen 1990).

Hâlihazırda araç tanıma sistemlerinde kullanılan dört temel yöntem vardır;

- Optik ve kızılötesi sistemler
- İnduktif döngü sistemleri
- Radyo frekansları ve mikrodalga sistemleri
- Yüzey akustik dalga (Surface Acoustic Wave- SAW) sistemler

Araç plakası tanıma, araç tanıma ve gözetleme için kullanılan tekniklerden biridir. Bu teknikte aracın plakasının yeri bulunur sonra bu plaka bilgisi ASCII karakterlere çevrilir.

1980’de Elsydel Ltd. şirketi gişelerde kullanılmak üzere bir araç plakası tanıma sistemi geliştirmiştir. Optik sensörle algılanan aracın önden CCD kamera ile plakasının resmi yakalanmış, sonra araç plakasındaki karakterler deşifre edilmiştir. Sistem Fransa’da otoyollarda 1988’de test edilmiştir (Setchell 1997).

“Computer Recognition Stsytems Ltd.” şirketi 1989’da syntax forcing algoritması kullandığı bir araç plaka tanıma sistemi geliştirmiştir. Algoritması hakkında bilgi verilmeyen sistemin başarısının % 93 olduğu açıklanmıştır (Williams ve ark. 1989).

1990’larda Newcastle-Upon-Tyne Üniversitesinin geliştirdiği plaka tanıma sisteminde aracın geçtiğini algılayan tetikleme ünitesi ve bu tetiklemeyle resim yakalayan kamera ünitesi bulunmaktaydı. Plakanın yeri, plaka zemini ve karakterlerin renk farkından yararlanılarak bulunmuştur. Yeri tespit edilen plakadaki karakterler etiketleme algoritması ile ayrıştırılmış ve yapay sinir ağları kullanılarak tanınmıştır (Fahmy 1993).

1995’de “CSIRO ve Telstra Corporation” işbirliği ile geliştirilen trafik denetleme sistemi bir araç plakası tanıma modülü ve araç tespit modülünden oluşmaktaydı. Sistem yüksek kaliteli resimlerden araçların plakasını bulup kontrol merkezine göndermekteydi. Merkez araçların hızını ölçmekteydi ve şoförlerin yolda geçirdikleri süreyi hesaplamaktaydı. Yapay sinir ağları, sistemde hem plakanın yerinin tespiti hem de karakter tanımda kullanılmaktaydı. Plakaların %90 başarıyla tanındığı rapor edilmiştir (Auty ve ark. 1995).

Bristol Üniversitesi bünyesinde bulunan araştırma merkezi “The Advanced Computing Research Centre” trafik denetleme, trafik gözetleme ve plaka tanıma sistemleri geliştirmiştir. Üniversiteden E. L. Dagless ve arkadaşları plaka yerini bulmak için çizgi metodunu geliştirmişlerdir. Metot da, görüntüden yatay çizgiler alınmış ve bu çizgiler üzerindeki histogramdan yararlanmıştır. Histogramdaki değişimlerden karakter

olabilecek yerler saptanmış ve karakterler aynı yöntemle ayrıştırılmıştır (Barroso ve ark. 1997). Aynı üniversiteden C. John Setchell trafik denetleme amacıyla yaptığı çalışmada, plaka yerini bulmada bu yöntemi kullanmış karakterleri tanımayı yapay sinir ağlarıyla gerçekleştirmiştir (Setchell 1997).

Avustralya'daki Edith Cowan Üniversitesi öğretim üyeleri tarafından yapılan çalışmada plaka yeri tespitinde kenar belirleme algoritmaları kullanmışlar ve karakterlerin belirlenmesi aşaması için yapay sinir ağlarından yararlanmışlardır (Gendy ve ark. 1997).

Tayland'da 1998 yılında yapılan bir çalışmada da yapay sinir ağları kullanarak plaka yeri tespitinden %84, karakter belirlemede ise %80 oranında başarı elde edilmiştir (Sirithinaphong ve Chamnongthai 1998).

Öğrenme tabanlı plaka tanıma sistemi kavramının başarısı görülmüş ve 2000'li yıllarda yaygın olarak bilimsel çalışmalarda kullanılmaya başlamıştır. Kim ve arkadaşları öğrenme tabanlı plaka tanıma sistemi çalışmalarında araba tespitinde %90, plaka tespitinde %88 ve karakter tespitinde %85 oranında başarı elde etmişlerdir (Kim ve ark. 2000).

Çin araç plaka sistemi için Changsha Üniversitesi'nde yapılan çalışmada resim içerisinden kesilen plakaların karakterlerinin tanınması için yöntemler denenmiştir. Çin plaka sisteminin özellikleri belirlenmiş ve bu özellikler kullanılarak yapay sinir ağı ile öğrenme tabanlı bir uygulama yapılmıştır (Wei ve ark. 2001).

2003 yılında Tayvan Uluslararası Chiao-Tung Üniversitesinde yapılan çalışmada plaka yeri tespitinde plaka zemini ve karakterlerin renklerinden yararlanılmıştır. Karakter tanıma işleminde ise Template Matching denilen birebir karşılaştırma işlemi kullanılmıştır (Wang ve Lee 2003).

Araç plakalarının tespitinde yapay zekânın bir dalı olan bulanık mantık kullanılarak %95 başarı elde edilen çalışma 2004 yılında Shyang-Lih Chang ve arkadaşları tarafından gerçekleştirilmiştir (Chang ve ark. 2004).

Leonard Hamey ve Colin Priest 2005 yılında Avustralya plaka sistemi için geliştirdikleri algoritma ile Avustralya plakalarının renk ve şekil özelliklerinin farklılığını kullanarak plaka yeri tespitinde başarılı sonuçlar elde etmişlerdir. Kullandıkları algoritmada resim içerisindeki plaka aday bölgeleri teker teker karakterler okununcaya kadar kontrol edilmektedir ve bu sistem için bir handikap oluşturmaktadır (Hamey ve Priest 2005).

Suudi Arabistan plakaları için King Fahd University of Petroleum & Minerals Üniversitesi'nde yapılan çalışmada plaka yeri tespiti için kenar köşe belirleme tabanlı algoritmalarından yararlanılmış, karakter tanıma işlemleri için ise bulanık mantık algoritmaları kullanılmıştır. Çalışma sonucunda Suudi Arabistan araç plakaları için %94 başarı elde edilmiştir (Sayed ve Sarfraz 2005).

Plaka yeri tespitinde köşelerin etkisi çok önemli yer kaplamaktadır. Plakanın en belirgin özelliklerinden biri olan kenar ve köşelerinin bulunması yöntemi ile oldukça yüksek oranlarda başarı elde edilmiştir. College of Traffic and Communications Southern China University of Technology bölümünde yapılan köşe tabanlı plaka yeri tespiti çalışmalarında %95 başarı elde edilmiştir (Qin ve ark. 2006).

Çin 'de yapılan bir diğer çalışmada ise Novel Metodu kullanılarak görüntü içerisindeki plaka aday bölgelerine based projection algoritması uygulanmıştır. Çalışma sonucunda plaka yeri tespiti %88 başarı elde edilmiştir (Chen ve ark. 2007).

Shandong Normal Üniversitesi'nde yapılan bir diğer çalışmada plaka yeri tespitinde hough algoritması kullanılmıştır. Ayrıca karakter tanıma işlemi de template match yöntemi ile veritabanındaki örnekler kullanılarak yapılmıştır. Sistem 15sn de veritabanındaki kayıtlı veriler ile bulunan plakayı kontrol edebilmektedir (Yang ve ark. 2007).

Dalian Denizcilik Üniversitesi Bilgi Mühendisliği'nde yapılan çalışmada karakterlerin sınıflandırılmasında bilgi tabanlı öğrenme metodu kullanılmıştır. Önceden belirlenmiş karakter özellikleri bilgi tabanına yüklenmiş ve sınıflandırma sırasında yeni veriler bu bilgiler ile kıyaslanmıştır. Çalışma sonucunda karakterlerin tanınmasında %94 başarı elde edilmiştir (Gao ve ark. 2007).

2008 yılında Hindistan'da yapılan çalışmada plaka yerinin tespitinde morfoloji algoritmaları kullanılmış ve Hindistan'da kullanılan plaka türlerinin tespitinde %96 başarı elde edilmiştir (Babu ve Nallaperumal 2008). Aynı yıl Beijing Teknoloji Enstitüsü'nde yapılan plaka tanıma sisteminde novel metodu kullanılarak plaka yerinin tespiti için %98 başarı oranı elde edilmiştir (Tan ve Chen 2008). Yine aynı yıl Ying ve Nannan yaptıkları çalışmada karakterlerin sınıflandırılmasında kendilerinin ürettikleri "uyumlu algoritma" yı kullanmışlar ve bu yöntem ile %92 oranında karakter tanıma başarısı elde etmişlerdir (Ying ve Nannan 2008).

Shahrood Teknoloji Üniversitesi'nde plaka yerinin tespiti için yazıların fazlalığı ve renk farklılıkları kullanılmıştır. Bu yöntem ile İran plakasına sahip araçların plaka sınıflandırması yapılmaya çalışılmış ve %92 oranında bir başarı elde edilmiştir (Ahmadyfard ve Abolghasemi 2008)

Kuzey Çin Üniversitesi'nde plaka yerinin tespitinde piksel özellikleri olan RGB değerlerinden yararlanılmıştır. RGB değerlerinin dağılımına göre plaka tespiti yapılmaya çalışılmış ve %76 oranında bir başarı elde edilmiştir (Wei ve Yanping 2009). Aynı yıl Cincinnati Üniversitesi'nde yapılan başka bir çalışmada ise karakter tanıma üzerinde durulmuş ve karakterlerin sınıflandırılması için birebir karşılaştırma deniler "Template Matching" yöntemi kullanılmıştır. Bu yöntem ile %96 oranında çin plaka karakterlerinin tanınması sağlanmıştır (Quan ve ark. 2009). 2009 yılında yapılan başka bir çalışmada ise plaka yeri tespitinde öznitelik çıkarım yönteminden faydalanılmıştır. Bu yöntem ile plakanın belirgin özellikleri resim üzerinde araştırılarak en uygun plaka alanı belirlenmiştir. Sistemin başarı oranı %93,1 olarak belirtilmiştir (Chen ve ark. 2009).

Plaka tanıma sistemleri son yıllarda ülkemizde de oldukça ihtiyaç duyulan sistemler arasına girmiştir. Ülkemizde bu alanda son yıllarda yapılan çalışmalar;

Mustafa Kemal Üniversitesi'nde yapılan plaka tanıma sisteminde YSA kullanılarak plaka yerinin tespiti ve karakterlerin tanınması işlemleri yapılmıştır. Sistem plaka yeri tespitinde %88,6, karakterlerin tanınmasında %76,8 oranında başarı elde etmiştir (Çelik 2003).

2006 yılında gerçekleştirilen bir diğer çalışmada, plaka bölgesi çıkartılırken, kenar belirleme, lekeleme algoritmaları kullanılmıştır. Ayırıştırma bölümünde, lekeleme, filtreleme ve bazı morfolojik algoritmalar kullanılmaktadır. Plaka karakterlerinin tanınması için istatistiksel temelli şablon eşleştirme kullanılmıştır. Sistem genel olarak %91,2 başarı oranına sahiptir (Özbay 2006).

Plaka tanıma sistemleri yaygınlaştıkça sadece bilgisayarda çalışan değil; gömülü sistem olarak adlandırılan Mikrobilgisayarlar (FPGA vb.) için yazılan versiyonları da çıkmıştır. Hacettepe Üniversitesi'nde yağılan bir gömülü sistem plaka tanıma uygulamasında plaka yeri tespitinde kenar belirleme algoritmaları ve karakter tanıma işlemlerinde ise eğitim tabanlı yapay sinir ağları kullanılmıştır. Gömülü sistemin başarı oranı %87 olarak belirtilmiştir (Caner 2006).

Ankara Üniversitesi'nde yapılan çalışmada plaka yerinin tespitinde plaka zemin rengi ve plaka karakterlerinin renginden yararlanılmıştır. Karakterlerin ayırıştırılmasında sütun toplam vektörü (stv) kullanılarak, resimdeki imza bölgesi araştırılmıştır. Ayırıştırılan karakterler, ileri beslemeli, eğitim için geri yayılım algoritması kullanılan yapay sinir ağı (YSA) ile tanınmışlardır. Plakanın bulunması, karakterlerin ayırıştırılması, harf ve rakamların ayrı ayrı tanınması ile ilgili başarı oranları kullanılan değişik yöntem ve mimarilere göre verilmiştir. Çalışma içerisinde sistemin genel başarı oranı yer almamaktadır (Çamaşırcıoğlu 2007).

2008 yılında yapılan bir uygulamada taşıt plakalarının yerlerinin bulunabilmesi için yeniden boyutlandırma, gri seviyeye indirgeme, Histogram eşitlemesi, Thresholding, Smearing algoritmalarından oluşan karma bir sistem tasarlanmış ve bu algoritmalar morfolojik filtreleme yöntemleri ile birbirlerini tamamlayacak şekilde entegre edilmişlerdir. Plakanın okunması işleminde ise morfolojik filtrelemeler, şablon eşleştirme ve tümevarımsal öğrenme yöntemleri kullanılmıştır. Uygulamanın başarı oranı %92,5 olarak gösterilmiştir (Yalım 2008).

Atılım Üniversitesi'nde yapılan plaka tanıma sisteminde ise yapay sinir ağları veya karmaşık matematiksel işlemler yerine insan gözü ile karakterin nasıl algılandığına dikkat edilmiştir. Plaka görüntüsü ikili sisteme çevrilmiş ve sonra dikey ve yatay doğrultularda taranarak karakterlerin sınırları bulunmuştur. Bulunan

karakterler soldan sağı, sağıdan sola, yukarıdan aşağıya, aşağıdan yukarı taranarak her bir karakter için özellik sınıfları oluşturulmuştur. Daha önceden karakterler için hazırlanmış olan özellik sınıfları veritabanı ile karakterin özellik sınıfı karşılaştırılmıştır. Karakterin diğer karakterlere benzeme oranı kullanıcıya gösterilmiştir. Çalışma karakter tanıma işleminde %88,9 başarı oranı elde etmiştir (Kayhan 2009).

3. MATERYAL VE METOT

Bu tez çalışmasında bilgisayar kontrollü araç plaka tanıma sistemi gerçekleştirilmiştir. Sistem bir kamera ve bir bilgisayardan oluşmaktadır. Sistemde kullanılan kamera 640x480 piksel çözünürlüğe sahip, renkli CCD kameradır. Kullanılan bilgisayar ise Intel Core 2 Dou P8700 işlemci, 4GB RAM'i bulunan ve Windows 7 işletim sistemine sahiptir.

Gerçekleştirilen araç plaka tanıma sistemi beş aşamadan oluşmaktadır. İlk aşamada kamera yardımıyla araç görüntüsü bilgisayara aktarılır. Aktarılan görüntü içerisinde yer alan plaka bölgesi çeşitli görüntü işleme algoritmaları kullanılarak tespit edilir. Daha sonra plaka görüntüsü gürültülerden arındırılmak amacıyla filtrelerden geçirilir. İyileştirilmiş plaka görüntüsü içerisindeki karakterler (harf ve rakamlar) ayrıştırılır. Ayrıştırılan karakterler sayısal hale dönüştürülüp yapay sinir ağları ile sınıflandırılır. Böylece tanıma gerçekleşmiş olur (Şekil 3.1).



Şekil 3.1. Araç plaka tanıma sistemi blok şeması

Plakanın yerinin tespiti için canny kenar bulma operatörü kullanılmış ve siyah ve beyaz renk geçişlerinin en yoğun olduğu bölge plaka bölgesi olarak tayin edilmiştir. Bu işlen sonucunda 220x50 piksel boyutunda plaka resmi elde edilmiştir.

Işık ve kontrast farklılıkları gibi tanımayı olumsuz etkileyebilecek faktörleri ortadan kaldırmak amacıyla plaka görüntüsüne kontrast genişletme ve ortanca değer filtreleri uygulanmıştır.

İyileştirilmiş plaka görüntüsüne Blob coloring algoritması uygulanarak birbirine değmeyen siyah bölgeler sınıflandırılmış ve karakterlerin yerleri tespit edilmiştir. Bu karakterler harf ve rakam olarak plaka bölgesindeki konumuna göre ayrıştırılarak 28x35 boyutunda rakam, 30x40 boyutunda harf görüntüleri olarak belirlenmiştir.


Tanırna aşamasında yapay zekâ yöntemlerinden olan yapay sinir ağıları (YSA) kullanılmıştır. Harf ve rakamlar farklı boyutlarda sayısallaştırılmıştır. Bu işlem sonucunda elde edilen harf ve rakam verileri iki farklı YSA'da eğitilmiştir. Test aşamasında gelen görüntüden elde edilen harf ve rakam bilgileri eğitilen YSA'ya verilerek sınıflandırma yapılmış ve plaka bilgisi elde edilmiştir.

4. TEORİK ESASLAR

4.1. Örüntü Tanıma


Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir.

Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirmedir. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişimin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip birçok etkinlikte örüntü tanıma kullanılır. Şekil 4.1’ de görüldüğü gibi aynı sınıfa ait olan kare veya dikdörtgen örüntüler, ait oldukları sınıf içerisinde düzenli olarak kümelenmişlerdir (Türkoğlu 2003).



Şekil 4.1. Aynı sınıfa ait örüntülerin sınıflandırılması

Örüntü tanıma olayını şu şekilde irdeleyebiliriz: Aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesneleri bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır. Bu bağlamda, örüntü tanımanın en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir. Şekil 4.2 de karakterlerden oluşan örüntüler ve bu örüntüleri tanıma işlemi görülmektedir.



Şekil 4.2. Karakter örüntüsü

Örüntü tanıma tekniklerinin uygulamaları birçok mühendislik, tıp, askeri ve bilim alanına açıktır. Bunlardan bazıları; görüntü tanıma, ses tanıma, EEG sınıflama, DTMF haberleşme işaretlerini tanıma ve radar hedef sınıflama, biyomedikal kontrol, veri madenciliği verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makine öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır (Bal 2006).


4.1.1. Örüntü tanıma kavramı

Örüntü tanıma kavramı Şekil 4.3 de görüldüğü gibi üç önemli aşamadan oluşmaktadır (Türkoğlu 2003).

1. İşaret / Görüntü İşleme: Ön işlem aşamasıdır. İşaret veya görüntünün filtre edildiği, çeşitli dönüşüm ve gösterim teknikleri ile işlendiği, bileşenlerine ayrıldığı veya modellendiği kısımdır.

2. Özellik Çıkarma: İşaret ve görüntünün veri boyutunun indirgendiği ve tanımlayıcı anahtar özelliklerinin tespit edildiği ve aynı zamanda normalizasyona tabii tutulduğu aşamadır. Sistemin başarımında en etkili rolü oynar.


3. Sınıflandırma: Çıkarılan özellik kümesinin indirgendiği ve formüle edildiği tanımlayıcı karar aşamasıdır.



Şekil 4.3. Örüntü tanıma kavramı ve aşamaları

4.1.2. Örüntü tanıma sistemleri

Örüntü tanıma sistemleri gözlenen veya ölçülen verileri tanımlanmasında birçok uygulamanın merkezinde yer alır. Şekil 4.4 de yaygın olarak kullanılan genel anlamda örüntü tanıma sistemi verilmiştir. Algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumlardan biri olabilen bazı fiziksel işlemleri ölçerler. Şekil 4.4 deki blok diyagramın en önemli görevlerinden biride, elde edilen ölçümlerin hepsinden oluşan giriş uzayından daha az boyutta özellik çıkartmaktır. Sonunda, sınıflandırıcının rolü örüntüyü özelliklerine göre kategorize ederek uygun sınıflara kaydetmektir.




Şekil 4.4. Yaygın olarak kullanılan örüntü tanıma sistemi

Mevut örüntü tanıma sistemleri üç ana grup altında toplanmaktadır:

4.1.2.1. İstatistiksel örüntü tanıma

İstatistiksel örüntü tanıma yönteminde, sınıflama algoritmaları istatistiksel analiz üzerine kurulmuştur. Aynı sınıfa ait örüntüler, istatistiksel olarak tanımlanan benzer karakteristiklere sahiptirler.

Bu yöntemde, özellik olarak nitelendirilen karakteristik ölçümler giriş örüntü örneklerinden çıkarılır. Her örüntü bir özellik vektörü ile tanımlanır. Genelde sınıflandırıcıyı oluşturan karar ve sınıflandırma yöntemleri üzerinde önemle durulur. Sınıflandırıcı tasarımı, ölçümler ve olasılıklar gibi işlenebilir örüntü bilgilerini birleştirmeyi esas alır. Böylece sınıflama, giriş veri uzayının olasılık yoğunluk fonksiyonlarının tahmini üzerine kurulu bir istatistiksel yapıdır.



Şekil 4.5. Bayes karar teorisi


İstatistiksel örüntü tanıma Şekil 4.5 de görülen Bayes Karar Teorisi üzerine kurulmuş olup, uzun bir geçmişe sahiptirler.

4.1.2.2. Yapısal örüntü tanıma

Yapısal (geometrik, kural dizilim) örüntü tanıma yaklaşımının da, verilen bir örüntü, şekilsel yapıdan temel karakteristik tanımlanmaya indirgenir. Çoğu zaman, örüntülerden çıkarılan bilgi yalnızca özellikler kümesinin sayısal değerlerinden değildir.

Özelliklerin birbirine bağlanması veya aralarındaki karşılıklı ilişki, tanımlamayı ve sınıflandırmayı kolaylaştıran önemli yapısal bilgiye sahiptir. Bir başka deyişle örüntünün işlenmemiş halinden elde edilen tanımlayıcı biçimsel sentaks veya bunların sentezinden çıkarılan gramer ile tanımlama gerçekleşir. Örneğin, örüntünün köşe sayısı, kenar açıları vb.


Genel olarak yapısal yöntemde daha basit alt örüntüler karışık örüntülerin hiyerarşik tanımlamalarını formüle eder. Yapısal yöntemde her örüntü, bileşenlerinin bir kompozisyonu olarak ele alınır. Şekil 4.6’ da bir yapısal örüntü tanıma sistemi görülmektedir.



Şekil 4.6. Yapısal örüntü tanıma sistemi

Yapısal örüntü tanıma yönteminde çeşitli birimler arasındaki ilişki çok büyük önem taşır ve gerçek tanımda kullanılan bazı şekilsel notasyonlar tarafından belirtilir. Örneğin, ekrandaki bir masayı tanıma, “köşelerinden eşit uzunlukta bacaklar tarafından desteklenen yatay bir dikdörtgen yüzey” gibi yapısal tanımlamayı temel alarak gerçekleştirilebilir.


Bu yöntemde, çevre uzunluğu, alan, ağırlık merkezi, eylemsizlik momenti ve Fourier tanımlayıcıları gibi genel özellikleri kullanır. Şekil 4.7’ de görüldüğü gibi otoregresif model, poligon sal yaklaşım ve zincir kodları yapısal örüntü tanıma yöntemine örnek olarak verilebilir.



Şekil 4.7. Yapısal örüntü tanıma yöntemleri

4.1.2.3. Akıllı örüntü tanıma


Örüntü tanıma sistemi, daha önceden öğrendiklerini tutabilecek bir hafızaya sahip, çıkarım, genelleme ve belirli bir hata toleransı ile karar verebilme yeteneklerini içermekte ise bu sistem akıllı örüntü tanıma sistemi olarak değerlendirilir. Şekil 4.8’de böyle akıllı ve öğrenebilen makineleri gerçekleştirmeye yönelik örüntü tanıma yaklaşımı verilmiştir.



Şekil 4.8. Akıllı örüntü tanıma sistemi

Akıllı örüntü tanıma yaklaşımları, öğrenme tabanlı olup, karar aşamasında geçmiş tecrübelerinden sonuç üretmektedirler. Günümüzde, öğrenmeli örüntü tanıma algoritmaları Şekil 4.9’ daki yapay sinir ağ merkezli olarak gelişmektedir ve bu doğrultuda çalışmalar yoğunluktadır. YSA yaklaşımları istatistik yaklaşıma karşı belirleyici olarak ifade edilebilir. Çünkü öğrenme algoritmaları örüntü sınıflarının


istatistiksel özellikleri hakkında hiçbir şey kullanmamaktadır. Bununla birlikte, istatistiksel ve YSA örüntü tanıma yaklaşımları şekil ve amaç olarak çok benzer olup, hatta YSA 'nın geleneksel istatistiksel örüntü tanımanın bir uzantısı olarak ifade edilen görüşlerde bulunmaktadır.



Şekil 4.9. Yapay sinir ağı sistemi

4.1.3. Örüntü tanıma sisteminin bileşenleri

Tipik bir örüntü tanıma sistemi, Şekil 4.10'da görülmektedir. Sistem, eğitim ve tanıma olmak üzere iki evreden oluşur. Sistemin en önemli elemanları; özellik çıkarma (niteleme), veri tabanı oluşturma ve sınıflandırma (eşleme) bileşenleridir. Eğitim ve tanıma evrelerindeki algılayıcılar ve özellik çıkarma elemanları değişik olabilir. Alt bölümlerde her elemanın işlevi, daha ayrıntılı olarak tartışılacaktır (Türkoğlu 2003).



Şekil 4.10. Örüntü tanıma sisteminin bileşenleri

4.1.3.1. Önışlem

Algılayıcılar vasıtasıyla, bilgisayara sayısal olarak alınmış olan örüntü, daha basit bir şekle getirmek için bir dizi önışlem sürecinden geçirilir. Örneğin alınan örüntü bir nesne görüntüsü ise; o nesnenin özelliğinin bulunması için çeşitli aşamalardan geçirilir. Bunlar;

4.1.3.2. Gürültü azaltma

Bir görüntüde gürültü demek görüntülerde genelde ani inişler ve çıkışlar demektir, bunlarda yüksek frekans bileşenlerine denk gelir. Eğer biz görüntümüzü bir frekans filtresinden geçirip yüksek frekanslara izin vermezsek doğal olarak bir gürültünün etkisini azaltmış oluruz (Boğaziçi 2010).


4.1.3.3. Gürültü yumuşatma

Gerçek uzayda imge yumuşatma yöntemi, bir pikselin çevre piksellere göre ortalamasını almaktadır (Boğaziçi 2010).

4.1.3.4. Eşikleme

Sayısal bir görüntünün eşikleme işlemine tutulmasındaki amaç, nesne görüntüsünün özelliklerini belirlemede kolaylık sağlamaktır. Eşikleme işlemiyle, görüntü iki renkle ifade edilebilir biçime getirilir. Görüntüyü eşikleme işlemine tabi tutmadan

önce bir eşik değeri saptanır. Eşik değerinden daha yüksek gri seviye değerine sahip olan piksellere “1” değeri, daha küçük değerlere sahip olan piksellere ise “0” değeri ataması yapılarak görüntü daha basit bir biçime (siyah-beyaz) getirilmiş olur. Şekil 4.11’de bir görüntünün, eşikleme işleminden önceki ve sonraki durumu gösterilmektedir.



Şekil 4.11. Eşikleme işleminden geçirilmiş resim

4.1.3.5. Bölge ayırma (region spitting)

Bölge ayırmanın temel prensibi şudur; ilk önce görüntü bir bütün olarak ele alınır. Sonra görüntüye bakılır. Eğer bütün parçaları uyumluysa algoritma sonra erer. Eğer uyumsuzsa bölge 4 ana parçaya ayrılır ve her biri için algoritma devam eder. Bu işlem daha fazla bölünme olmayana kadar devam eder. Bu bir böl ve fethet, taktiğidir. Olabilecek en kötü sonuç en küçük piksele kadar her şeyin bölünmesidir. Bu tür sonuçları engellemek için her bölünmeden sonra komşulara bakılır (Boğaziçi 2010).

4.1.3.6. Bölge büyümesi (region growth)

Bölge büyümesi, bölge ayırmanın tam tersi yoldan giden bir algoritmadır. Başlangıç değerleri olarak küçük bölgeler birleştirilir. Herhangi bir başlangıç tohum (seed) nokta bulunarak bu yapılır. Bölgenin büyümesi durunca şu an herhangi bir bölgeye dâhil olmamış noktalar seçilerek işleme devam edilir (Boğaziçi 2010).

4.1.3.7. Optik akış

Eğer zaman içinde bir dizi imge alırsak ve eğer ortamda hareket eden cisimler varsa, görüntü ve hareket eden cisim hakkında faydalı bilgiler toplanabilir. Örneğin hareket eden bir gök cismi, değişik zamanlarda çekilmiş fotoğraflar incelenerek hangi pikselin cisme, hangisinin hareket etmeyen uzaya ait olduğu anlaşılabilir. Eğer hareketleri düzgün inceleyebilirsek şu sorulara cevap verebiliriz (Boğaziçi 2010).

- Kaç tane hareket eden cisim var?
- Hangi yönlere hareket ediyorlar?
- Düzgün yoksa belirli bir fonksiyona göre mi hareket ediyorlar?
- Ne kadar hızlılar?

Bir görüntü dizisinden, optik akış diye bir fonksiyon hesaplarız. Her piksel için $V = (u, v)$ bulunur ki bu fonksiyon sayesinde şu değerler hesaplanır. Piksel resimde ne kadar hızlı hareket etmektedir. Piksel hangi hızda hareket etmektedir (Boğaziçi 2010).


4.1.3.8. Kenar çıkarma

Kenar çıkarmadaki amaç, görüntünün içerdiği bilgiyi değerlendirip, gereksiz ve tanıma işlemlerinde zaman kaybettiren bilgiyi eleyerek yeterli düzeye indirmektedir. Kenar çıkarma, görüntü işlemenin en temel konularından biridir. Görüntü analizinde ve sınıflandırılmasında çok değerli bilgiler taşıdığından, ilgi çeken bir araştırma alanı olmuştur.

Bir kenar çıkarma yönteminin başarısını değerlendirmede kenar noktasının tanımı çok önemli yer tutar. Görüntüdeki bir nesnenin kenarı, nesnenin yüzey yoğunluğundaki değişimi ile ilgilidir. Kenar, farklı aydınlık değerlerindeki iki homojen alan arasındaki sınır olarak tanımlanabilir. Bu tanım, kenarın görüntüdeki aydınlık seviyesinin yerel değişimi şeklinde de düşünüldüğünü sağlar. Kenar çıkarıcılarının etkinliği, homojen alan noktalarından gerçek kenar noktalarını ayırt etme yeteneğine bağlıdır.

Kenar çıkarma, robotik nesne görüntüsü tanımda çok önemli rol oynar. Bunu şu şekilde açıklayabiliriz. İnsan görme sistemi, nesneleri tanıma süreci içinde nesnenin dış

izgilerini izleyerek bir gz gezdirilir. Bu yaklařımı yapay grme sistemlerine uyarladığımızda, řayet nesnenin sınırları başarılı bir řekilde izlenirse nesne tanımada ok daha iyi sonular alınabilir. Bylece tanıma olayında kenar ıkarma nemli bir rol oynar. oęu grntler somut nesneleri iermez ve bu grntleri anlamak onların yapısal zelliklerine baęlıdır. Yapısal zelliklerin ıkarımı ise kenar ıkarma ile ilgilidir. Kenarları ıkarılmış bir resim řekil 4.12’ de grlmektedir.



řekil 4.12. Kenarları ıkarılmış rntlerden oluřan resim

4.1.3.9. zellik ıkarma

zellik ıkarma rnt tanımanın en nemli kısmı olup, bir anlamda rnt tanıma sisteminin başarımında anahtar rol oynar. rnt sınıfları arasında ayrımı gerekleřtirmek iin rnt zelliklerinin ıkarılması gerekir. Gnmzde, ok başarılı sonular veren rnt sınıflandırıcı trleri mevcut olup, sınıflandırıcının da doęrudan başarımını etkileyen zellik ıkarımı zerine alıřmalar odaklanmıřtır. zellik ıkarmanın ana sebepleri:

- 1) lm veya rnt uzayından daha kk boyuta dnřmeyi saęlamaktır. Bu sınıflandırıcının kk hatalar ile eęitimi ve karar ařamasının daha kısa srede gerekleřmesi demektir.
- 2) Boyut olarak daha dřk olan zellik uzayını sınıflandırıcının daha az parametre ile ęrenmesini mmkn hale getirecektir. Bunun yararı rnt uzayı ile karar uzayı arasındaki dnřm ařamasının daha kısa srede gerekleřmesidir.

- 3) Durağan olmayan zaman serilerinde olduğu gibi karmaşık örüntülerin tanımlayıcı karakteristiklerini bulabilmek için özellik çıkarımı şarttır. Böylece karar aşamasının güvenilirliği artacaktır.
- 4) Örüntü sınıflandırma sisteminin, sistem içi veya dışındaki kontrolsüz girişimlerden etkilenmemesini sağlayacak bir özellik çıkarımı kararlı bir yapının oluşmasında etken olacaktır. Bu tür kararlı özellikler, sınıflandırıcının genelleme ve ayırışım yeteneğinin yüksek olmasında önemlidirler.

4.2. Yapay Sinir Ağları

Yapay Sinir Ağları, insan beyninin işleyişini taklit ederek yeni sistem oluşturulmaya çalışılan yaklaşımlardır. Beynimizdeki biyolojik sinir hücrelerinin yapısı temel alınarak YSA yapısı oluşturulur. YSA’nda aynen beynimizde olduğu gibi öğrenme ve öğrenilen bilgilere göre karar verme mekanizmaları bulunur (Elmas 2003, Öztemel 2003, Sağıroğlu ve ark. 2003, Allahverdi 2002).

YSA alanında yapılan ilk çalışmalar McCulloch ve Pitts tarafından yapılmıştır (McCulloch ve Pitts 1943). Bu araştırmacıların yayınladığı “Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap” başlıklı makalede YSA konusunda ilk adım atılmıştır. İlerleyen zamanlarda Hebb (1949), Rosenblatt (1958), Widrow ve Hoff (1960), Hopfield (1982), Kohonen (1982), Rumelhart ve ark. (1986) ve daha birçok araştırmacı farklı YSA öğrenme algoritmaları geliştirmişlerdir.

Yapay Sinir Ağları, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (nöron) meydana gelmektedir. Temel olarak bir YSA’nın görevi, kendisine gösterilen giriş setine karşılık bir çıkış seti belirlemektir. Bunu gerçekleştirebilmek için ağ, ilgili problemin örnekleri ile eğitilerek (öğrenme), o problemle ilgili istenenleri çözebilme yeteneğine kavuşturulur. Literatürde birçok öğrenme algoritması ve sinir ağı modeli mevcuttur. Bu algoritmalar ve modeller bu bölümde ayrıntılı olarak anlatılacaktır.

4.2.1. YSA'nın genel özellikleri

YSA'nın karakteristik özellikleri uygulanan ağ modeline göre değişebilmektedir. Bu değişik ağ modelleri ilerleyen kısımlarda anlatılacaktır. Genel karakteristik özellikler şunlardır (Öztemel 2003, Sağiroğlu ve ark. 2003, Allahverdi 2002):

- YSA öğrenme gerçekleştirirler. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.
- Bilgi geleneksel yöntemlere göre farklı biçimde saklanır. Bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bir veritabanı yoktur.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.
- Görüntü tanıma ve sınıflandırma yapabilirler. Kendisine örnekler halinde verilen görüntüleri işleyerek öğrenme yapar ve daha sonra gelen bir örneğin hangi sınıfa dahil olduğuna karar verebilir.
- Kendi kendine organize olma yetenekleri vardır. Örnekler ile kendisine gösterilen durumlara adapte olup yeni olayları sürekli olarak öğrenebilmektedir.
- Eksik bilgi ile çalışabilir. YSA eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmamasına rağmen sonuç üretebilir.
- Hata toleransına sahiptir. Eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmasını sağlar.
- Dağıtık belleğe sahiptirler. YSA'nda bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir.
- Sadece sayısal bilgi ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin sayısal bilgilere çevrilmesi gerekir.

4.2.2. YSA'nın dezavantajları

YSA'nın birçok önemli dezavantajı vardır (Sağiroğlu ve ark. 2003, Haykin 1999). Bunlar:

- Probleme uygun ağ yapısının belirlenmesi zor bir süreçtir. Genellikle ağ yapısı belirlenirken deneme-yanılma metodu kullanılır. Bu da bazen çok uzun zaman almaktadır. Eğer problem için uygun ağ yapısı belirlenemezse, çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olmaktadır. Aynı zamanda bu durum bulunan çözümün en doğru çözüm olduğunun garantisini de vermez.
- Bazı ağlarda ağın parametre değerlerinin (örneğin öğrenme katsayısı, hücre sayısı v.b.) belirlenmesinde bir kural olmaması, çözümlere ulaşmada sorun oluşturur. Bu değerler kullanıcının tecrübesine bağlıdır ve her problem için farklı etkenlere dikkat etmek gerekir.
- Problemin ağa gösterimi çok önemli bir etkidir. YSA sadece sayısal bilgilerle çalışır ve problemin sayısal değerlere çevrilmesi gerekmektedir. Bu da kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulmamış olması problemin çözümünü engelleyebilir.
- Ağın eğitiminin ne zaman bitirileceğine dair kesin kurallar yoktur. Eğitimde hata toleransının belli bir değerin altına inmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat neticede en iyi öğrenmenin gerçekleştiği söylenememektedir.

4.2.3. YSA'nın temel yapısı

YSA sinir hücrelerinin bir araya gelmesiyle oluşurlar. Tabi bu işlem rastgele olarak yapılmamaktadır. Genelde hücreler, 3 katman halindedir ve her katman içinde paralel halde ağ oluştururlar. Bu katmanlar;

- Giriş Katmanı: Bu katmandaki hücreler giriş bilgilerini gizli katmana ulaştırmakla görevlidir.
- Gizli Katman: Giriş katmanından gelen bilgiler işlenerek çıkış katmanına gönderilir. Bir ağda problemin durumuna göre, birden fazla gizli katman olabilmektedir.
- Çıkış Katmanı: Bu katmandaki hücreler gizli katmandan gelen bilgiyi çıkış katmanına gönderirler. Üretilen çıkışlar problemin çözümünü içermektedir.

Gizli katman sayısının ve hücre sayısının belirlenmesi: YSA'nın tasarımı sırasında ağdaki katman sayısına ve katmanlardaki hücre sayısına doğru bir şekilde karar vermek sistemin performansı açısından oldukça önemlidir. Birçok problemde iki veya üç katmanlı bir ağ istenen sonuçları üretebilmektedir (Haykin 1999). Katmanlar, hücrelerin aynı doğrultu üzerinde bir araya gelmeleriyle oluşmaktadır. Katmanların farklı şekilde birbirleriyle bağlanmaları ile farklı ağ yapıları oluşmaktadır. Giriş ve çıkış katmanlarının sayısı da, problemin yapısına göre değişmektedir (Freeman ve Skapura 1991).

Ağın bir diğer yapısal özelliği ise her bir katmandaki hücre sayısıdır. Gizli katmandaki hücre sayısının tespitinde de genellikle deneme-yanılma yöntemi kullanılır. Bunun için takip edilecek yöntem, başlangıçtaki rasgele olarak belirlenen hücre sayısını istenilen performansa ulaşmaya kadar arttırmak veya tersi şekilde istenilen performansın altına inmeden azaltmaktır. Gizli katmanda kullanılacak hücre sayısı ne kadar az olursa eğitim işlemi de o kadar kısa sürmektedir. Çünkü hesaplama adım sayısı kısalmaktadır. Aynı zamanda hücre sayısının az olması sinir ağının “genelleme” yeteneğini artırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olmaktadır. Bununla birlikte hücre sayısının gereğinden az olması, ağın giriş verilerini öğrenememesi gibi bir sorun oluşturmaya neden olabilir.


Gizli katman hücre sayısının belirlenmesinde kullanılan bir diğer yöntem ise tecrübeye dayalı (heuristic) arama yöntemidir. Tecrübeye dayalı arama yönteminde arama doğruluğu, son arama adımında denenen mimari ile bir önceki arasındaki arama kriteri ile belirlenir (Breiman 1994). Bununla birlikte ağın genel hata oranına bakılarak da ağ yapısı belirlenmesi işlemi gerçekleştirilebilmektedir. Ağdaki gizli katman sayısı arttıkça ağırlık sayısı da artacağından dolayı ağ yapısı karmaşık bir hale gelecektir. Bu yöntemde, her bir modelin en uygun olabilirlik fonksiyonunu bulunur. Olabilirlik fonksiyonunun değeri en küçük olan model, en uygun model olarak seçilmektedir (Schwarz 1978).

Yapılan son çalışmalarda (Dodd 1990, Kitano 1990, Happel 1992, Nan ve ark. 2003, Boers ve Kuiper 1992) sinir ağı yapısının belirlenmesinde genetik algoritmaların oldukça etkili olduğu görülmüştür. Genetik algoritmaların optimizasyon problemlerinde ne denli iyi performans verdikleri bilinmektedir. Olasılıksal karakterleri ve çoklu

mümkün çözümleri araştırma gibi özelliklere sahip olan GA'ların sinir ağının yapısının belirlenmesinde çok iyi performans vereceği beklenmektedir.

4.2.4. Yapay sinir ağı hücresi

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli Şekil 4.13'de görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışı hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur (Haykin 1999).



Şekil 4.13. Temel yapay sinir ağı hücresi

Burada b bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Nöronun matematiksel modeli şöyledir.

Çıkış,

$$y = f(w.x + b) \quad (4.1)$$

şeklinde nöron çıkışı hesaplanır. Buradaki w ağırlıklar matrisi, x ise girişler matrisidir. n giriş sayısı olmak üzere;

$$w = w_1, w_2, w_3, \dots, w_n \quad (4.2)$$

$$x = x_1, x_2, x_3, \dots, x_n \quad (4.3)$$

şeklinde yazılabilir. Buradan;

$$net = \sum_{i=1}^n w_i x_i + b \quad \text{ve} \quad y = f(net) \quad (4.4)$$

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (4.5)$$

şeklinde de yazılabilir. Yukarıdaki formülde görülen f aktivasyon fonksiyonudur. Genelde lineer olmayan olan aktivasyon fonksiyonunun çeşitli tipleri vardır. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında +1 değeri verir. Eşik aktivasyon fonksiyonunun -1 ile +1 arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini verir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir (Bishop 1995).

$$f(x) = x \quad (4.6)$$

şeklinde ifade edilir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir. Böylece daha sonraki bölümlerde görülecek olan geri yayımlı ağlarda kullanmak mümkün olabilmektedir (Bishop 1995).

Fonksiyonu tanımlarsak,

$$f(x) = \text{lojistik}(x) = \frac{1}{1 + \exp(-\beta x)} \quad (4.7)$$

şeklinde ifade edilir. Buradaki β eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir (Haykin 1999, Bishop 1995).

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.8)$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir (Haykin 1999, Bishop 1995).

4.2.5. YSA öğrenme algoritmaları

Bugüne kadar geliştirilmiş birçok öğrenme algoritması mevcuttur. Bunların büyük çoğunluğu matematik tabanlıdır ve ağırlıkların güncelleştirilmesi için kullanılırlar. Mevcut öğrenme algoritmaları Hebb (1949), Delta, Kohonen (1982) ve Hopfield (1982) olmak üzere 4 öğrenme algoritması temel alınarak geliştirilmiştir (Sagiroğlu ve ark. 2003, Haykin 1999, Bishop 1995).

Hebb Öğrenme Kuralı: Bilinen en eski öğrenme kuralıdır. Hebb'in (1949) geliştirdiği bu öğrenme algoritması, “bir nöron diğer bir nörondan giriş alıyorsa ve her iki nöronda aktif ise (matematiksel olarak aynı işarete sahip ise), nöronlar arasındaki ağırlık kuvvetlendirilir” esasına göre çalışır. Diğer bir deyişle, bir hücrenin kendisi aktif ise, bağlı olduğu hücreyi aktif yapmaya çalışır. Tersisi durumda pasif yapmaya çalışır. Diğer birçok öğrenme kuralı bu felsefeyi baz alarak geliştirilmiştir.

Delta Öğrenme Kuralı: Bu kural Hebb kuralının biraz daha geliştirilmiş şeklidir. Bu kurala göre, beklenen çıkış ile gerçekleşen çıkış arasındaki farklılığı azaltmak için ağırlık değerleri sürekli değiştirilmelidir. Ağın ürettiği çıkış ile üretilmesi beklenen çıkış arasındaki hatanın karelerinin ortalamasını en aza indirmek hedeflenmektedir. Hata aynı zamanda bir katmandan bir önceki katmanlara geriye yayılarak azaltılır. Bu kural geri yayılım, Widrow-Hoff (1960) veya en küçük ortalama karesel öğrenme kuralı olarak da bilinir.

Kohonen Öğrenme Kuralı: Kohonen (1982) tarafından geliştirilmiş olan bu kurala göre ağın hücreleri ağırlıklarını değiştirmek için birbirleriyle yarışır. En büyük çıkışı veren yani kazanan hücre ağırlığını değiştirir. Bu, o hücrenin diğer hücrelere karşı

daha kuvvetli hale gelmesi anlamını taşır. Kohonen kuralı hedef çıkışa gereksinim duymaz ve dolayısıyla danışmansız bir öğrenme metodudur.

Hopfield Öğrenme Kuralı: Bu kural da Hebb kuralına benzer. Hopfield (1982) kuralında hücreler arası bağlantıların ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenir. Eğer beklenen çıkış ve girişlerin ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendirilir/zayıflandırılır. Öğrenme katsayısı 0 ile 1 arasında bir değer alır.

4.2.6. Performans fonksiyonunun seçimi

Performans fonksiyonu YSA'nın öğrenme performansını ölçmede kullanılan bir ölçüttür. (Rumelhart ve ark. 1986). İleri beslemeli ağlarda genellikle ortalama karesel hata (Mean Square Error - MSE) performans fonksiyonu olarak kullanılır. MSE fonksiyonu istenen sonuç ile hesaplanan sistem çıkışı arasındaki farkın kareleri toplamının ortalaması olup aşağıdaki formülle hesaplanır:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2 \quad (4.9)$$

Burada y , istenen çıkış değerini; y' ise sistem tarafından hesaplanan çıkış değerini ifade eder. N ise çıkış sayısını belirtmektedir. Hatanın sıfıra yaklaşması istenen çıkış değerine yakın çıkış değeri elde edilmiş olması demektir.

İleri beslemeli ağlarda kullanılan bir diğer performans fonksiyonu toplam karesel hata (Sum Square Error – SSE)'dir (Sağıroğlu ve ark. 2003). 4.10'de verilen denklem kullanılarak toplam karesel hata hesaplanır:

$$SSE = \sum_{i=1}^N (y'_i - y_i)^2 \quad (4.10)$$

Bunlardan başka performans fonksiyonu olarak kullanılan bir diğer hata hesaplama yöntemi ortalama karesel hatanın karekökü (Root Mean Square – RMS) fonksiyonudur ve aşağıdaki formül ile hesaplanır:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2} \quad (4.11)$$

Sağıroğlu ve ark. (2003) 'na göre performans fonksiyonuna ağırlık biaslarının ve ağırlıklarının kareleri toplamının ortalama değerini ifade eden bir terim eklenerek genelleştirme daha da iyileştirilebilir. Böylece ağırlık daha hassas hale getirilir ve ağırlık, eğitim kümesi haricindeki veriler için sağlıklı bir genelleme yapmasını engelleyebilir. Bunun yanı sıra genelleştirmeyi iyileştirmek için kullanılan yöntemlerden birisi de öğrenmeyi erken sonlandırmaktır (Sağıroğlu ve ark. 2003). Bu yöntemde, YSA'ya uygulanacak veri kümesi üç bölüme ayrılır. İlk küme YSA'nın eğitiminde kullanılarak ağırlıkların, biasın ve eğimin güncelleştirilmesinde kullanılır. İkinci bölüm veri kümesi ise doğrulama verisi olarak kullanılır. Eğitim süresince, eğitim verilerinden hesaplanan hata oranı düştüğü gibi test veri kümesine ait hata da normal şartlarda düşer.

4.2.7. YSA modelleri

Yapay sinir ağları yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde modellenebilir.


İleri beslemeli modelde, bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir (Özbay ve Karlık 2001). Katmanlardaki hücrelerin sayısı tamamen uygulanan probleme bağlıdır. Hücreler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Giriş bilgileri, gizli ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Türkoğlu ve Arslan 1996). İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcı (Multi Layer Perceptron – MLP), modüler sinir ağları (Modular Neural Networks – MNN), vektör kuantalamalı öğrenme (Learning Vector Quantization – LVQ), radyal

tabanlı fonksiyon (Radial Basis Function – RBF) ve olasılık tabanlı (Probabilistic Neural Network – PNN) sinir ağıları verilebilir.

Geri beslemeli sinir ağı modelinde ise çıkış katmanındaki ve gizli katmandaki çıkışlar, giriş katmanındaki hücrelere veya bir önceki gizli katmanlara geri besleme şeklinde iletilir (Öztemel 2003). Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tip sinir ağlarının hafızaları dinamiktir ve çıkış hem anlık hem de önceki girişleri yansıtır. Bundan dolayı, bu tip sinir ağı modeli önceden tahmin uygulamaları için daha uygundur (Haykin 1999). Geri beslemeli ağ modeline örnek olarak Hopfield, adaptif rezonans teori (ART), kendi kendine organize olabilen harita (Self Organizing Map – SOM) ağları, Elman ve Jordan ağları verilebilir.

4.2.8. Çok Katmanlı Perseptron (MLP) Modeli

Çok katmanlı perseptron (MLP), giriş, gizli ve çıkış katmanından oluşmuş ileri beslemeli bir ağıdır (Şekil 4.14) (Haykin 1999). Katmanlardaki nöronlar arasında ve bir katmandan önceki katmana geriye doğru bağlantı yoktur.



Şekil 4.14. Çok katmanlı perseptron ağ yapısı

Herhangi bir katmandaki j . birime gelen toplam giriş, önce k_i katmandaki birimlerin y_i çıkışlarının (1. katman için girişlerin) bağlantılar üzerindeki w_{ij} ağırlıkları ile hesaplanmış bir ağırlıklı toplamıdır.

$$x_j = \sum w_{ij} \cdot y_i \quad (4.12)$$

Birimin çıkışı, bu toplam girişi bir lineer olmayan fonksiyondan geçirerek belirlenir. Bunun için birçok fonksiyon teklif edilmiştir. Ancak en çok kullanım göreni aşağıdaki sigmoid fonksiyondur.

$$y_j = \frac{1}{1 + e^{-x_j}} \quad (4.13)$$

Bu fonksiyon yakınsama şartını, yani “her birimin çıkışı, toplam girişin devamlı artan, türevi sınırlı bir fonksiyonu olmalıdır” şartını sağlar. Bu fonksiyon y_j çıkışını 0 ve 1 değerleri arasına sınırlar.

MLP’ de, ilk katmana bir giriş vektör uygulanır. Daha sonra giriş ve 1. katman arasındaki ağırlıklar yardımıyla 1. katmandaki her birimin aldığı toplam giriş belirlenir. Her birim girişini bir lineer olmayan fonksiyondan geçirerek bir sonraki katmana göndereceği çıkış işaretini belirler. Bir katmandaki tüm birimlerin durumları paralel olarak belirlenir. Bu işlem çıkış katmanındaki birimlerin durumları belirleninceye kadar sırayla tekrar edilir.

MLP ağının eğitilmesi danışmanlı öğrenmeye bir örnek oluşturabilir. Bu ağda girişe bir giriş vektörü uygular ve bir çıkış vektörü elde eder. Daha sonra bu çıkış vektörünü istenilen bir “hedef” vektörü ile karşılaştırır ve bu iki vektör arasındaki fark en küçük olacak şekilde ağ ağırlıklarını ayarlar. Amaç her giriş vektörü için, ağın üreteceği cevabın istenilen çıkış vektörünün aynısı (veya yeterince yakını) olmasını sağlayan bir ağırlık kümesi bulmaktır.

Eğitme iki adımlı bir işlemdir. İlk adımda bir giriş vektörü uygulanır, ağ içindeki her birim için toplam giriş ve çıkış hesaplanır ve her birimin çıkışı daha sonra ağırlık ayarlamasında kullanılmak üzere saklanır. Çıkış vektörü oluşturulduktan sonra, eğitme işlemi çıkış hatasını hesaplar ve bu hatanın geriye doğru yayılımını sağlar. Birimlerin ağırlıkları bu hata işaretine göre ayarlanır. Bu iki adımlı işlem ağ istenilen cevapları üretinceye kadar, eğitme vektör çiftleri ile tekrar edilir (Bishop 1995, Haykin 1999).

Çıkış katmanını eğitmek bağıl olarak daha basittir. Sorun bir hedef vektörünün olmadığı ara katman ağırlıklarını eğitirken ortaya çıkar. Bunun çözümü, hata işaretinin

çıkıştan daha iç katmanlar doğru yayılımını sağlamakla bulunur. Yani bir iç veya ara katman birimi, kendisinden sonraki katmanın hata işaretlerinin ağırlaştırmış toplamı olan bir hata işareti alır. Bu hata işareti her birim ağırlıklarının eğitmek için kullanıldıktan sonra; eğitme işlemi, oluşturulan yeni hata işaretinin daha önceki katmanlara doğru yayılımını sağlar.

Önceden belli, sonlu sayıda giriş-çıkış çifti için, belli bir ağırlık kümesine sahip ağın davranışındaki hata, her çift gerçek ve istenilen çıkış vektörlerini karşılaştırarak hesaplanabilir. E toplam hatası aşağıdaki şekilde tanımlanabilir.

$$E = \frac{1}{2} \cdot \sum_j \sum_k (y_{j,k} - d_{j,k})^2 \quad (4.14)$$

Burada k giriş-çıkış çiftlerinin, j çıkış birimlerinin indisidir y bir çıkış biriminin gerçek durumunu, d ise istenen durumunu göstermektedir. Verilen bir giriş-çıkış çifti için hata her ağırlığa göre iki adımda hesaplanır.

Geri yön adımı, her çıkış birimi için $\partial E / \partial y$ büyüklüğünü hesaplayarak başlar. Belli bir k çifti için denklem (4.15) türetilirse ve k indisi yazılmazsa,

$$\frac{\partial E}{\partial y_j} = y_j - d_j \quad (4.15)$$

elde edilir. Daha sonra $\partial E / \partial x_j$ 'yi hesaplamak için aşağıdaki zincir kuralı kullanılabilir.

$$\frac{\partial E}{\partial y_j} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{dx_j} \quad (4.16)$$

dy/dx 'nin değerini bulmak için 4.14 denklemi türetilerek yukarıda yerine konursa,

$$\frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \cdot y_j \cdot (1 - y_j) = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \quad (4.17)$$

ifadesi elde edilir. Bu da, j . çıkış birimine toplam giriş büyüklüğündeki (X_j) bir değişimin hatayı nasıl etkilediğini bildiğiniz anlamına gelir. Bu ifade çıkış katmanından bir birimden geriye doğru yayılımı yapılacak hata işaretidir. Bu toplam giriş, alçak katman birimlerinin y_i çıkışlarının bir lineer fonksiyonudur. x_j girişi aynı zamandaki ağırlıkların da bir lineer fonksiyonudur. Dolayısıyla ara katman çıkışlarındaki veya ağırlardaki bir değişimin hatayı nasıl etkileyeceğini hesaplamak kolaydır. i . birimden, j . birime bir w_{ij} ağırlığındaki değişimin hataya etkisi,

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dw_{ij}} = \frac{\partial E}{\partial x_j} \cdot y_i = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot y_i \quad (4.18)$$

ifadesinden bulunabilir. Sonndan bir önceki katmandaki i . birimin çıkışı için, i 'nin J üzerindeki etkisi nedeniyle ortaya çıkan $\partial E / \partial y_i$ katkısı,

$$\frac{\partial E}{\partial y_i} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dy_i} = \frac{\partial E}{\partial x_j} \cdot w_{ij} \quad (4.19)$$

şeklindeir. Bu şekilde i . birimden çıkan tüm bağlantıları göz önüne alarak,

$$\frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \cdot w_{ij} = \sum_j (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot w_{ij} \quad (4.20)$$

elde edilir. Bu şekilde son katmandaki bu birimler için $\partial E / \partial y$ verildiğinde, sonndan bir önceki katmandaki herhangi bir birim için $\partial E / \partial y$ 'nin nasıl hesaplanacağı gösterilmiş olmaktadır. Bu ifade sonndan bir önceki katmandaki i . birime gelen hata işaretidir. Daha önceki katmanlarda bu terimi hesaplamak için burada yapılan işlem tekrar edilebilir.

Ağırlıkları ayarlamak için $\partial E / \partial w_{ij}$ türevsel bilgisi kullanılır. Bu bilgiyi kullanmanın bir yolu ağırlıkları her giriş çıkış çiftinin uygulanmasından sonra

değiştirmektedir. Bu yöntemin $\partial E / \partial w_{ij}$ türevlerini saklamak için hiç ayrı bellek ihtiyacı göstermemesi gibi bir avantajı vardır. Öte yandan ağırlıkları ayarlamanın bir başka yolu, tüm giriş-çıkış çiftlerinin uygulanması ile elde edilen $\partial E / \partial w_{ij}$ değerlerini toplamak ve daha sonra bu bilgiyi w_{ij} ağırlığının değişiminde kullanmaktır. Eğim azalmasının en basit şekli, her w_{ij} ağırlığını $\partial E / \partial w_{ij}$ değerine orantılı olacak şekilde değiştirmek.


$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} \quad (4.21)$$

Burada $w_{ij}(n)$ i . birimden j . birime olan ağırlığın hesaplamasının n .adımındaki değerini göstermektedir. ε ise 0 ile 1 arasında (tipik olarak 0,1'ler mertebesinde) değer alan bir kazanç terimidir.

Ağırlık değişimindeki bu yöntem, ikinci türevleri kullanan yöntemler gibi hızlı yakınsamaz, fakat daha basittir ve paralel donanımda lokal hesaplamalar ile kolayca gerçekleştirilebilir. Bu yöntem aşağıdaki şekilde geliştirilebilir.

$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} + \alpha \cdot (w_{ij}(n) - w_{ij}(n-1)) \quad (4.22)$$

Burada α ağırlıktaki değişimi önceki değişimin değerine bağlayan bir katsayıdır ($0 < \alpha < 1$). Bu yeni öğrenme denklemi, ε 'nun daha büyük değerlerine imkân sağlayarak yakınsamayı hızlandırır. Geri yayılım algoritmasında çıkışın hesaplanması işlemi ileri yönde gerçekleşir. Ancak eğitim sırasında hatanın bulunması ve değiştirilmesi geri doğru gerçekleştirilir (Şekil 4.15).




Şekil 4.15. Eğitim işlemi

Geri yayılım algoritması uygulamada oldukça sık rastlanan bir algoritmadır. Bu algorithmada, hataların çıkıştan girişe geriye doğru azaltılmaya çalışılmasından dolayı geri yayılım ismini almıştır (Parker 1985).

5. PLAKA TANIMA SİSTEMİ

5.1. Resmin Kameradan Alınması

Bu çalışmada araç görüntülerinin alınması için renkli CCD (Charge Coupled Device) kamera kullanılmıştır. Alınan görüntüler RGB formatından gri seviye (gray level) formata dönüştürülmüştür (Şekil 5.1). Resim üzerinde daha rahat ve daha hızlı çalışmak için resim nesnesinin piksel değerleri iki boyutlu olan ve elemanları 0–255 arasında olan bir diziye aktarıldı. Daha sonraki tüm işlemler de bu dizi üzerinde gerçekleşti.



Şekil 5.1. RGB-Gri seviye dönüşüm ekranı

5.2. Alınan Resimde Plakanın Bulunması

Plakanın bulunması işlemi için öncelikle resme kenar bulma algoritması uygulanmış ve resim içerisinde var olan kenar ve köşeler ortaya çıkartılmıştır. Daha sonra ise kenar ve köşelerin en yoğun olduğu bölge plaka bölgesi olarak belirlenmiştir.

5.2.1. Kenar Bulma algoritması

Kenar bulma işleminde literatürde yer alan ‘sobel’, ‘log’, ‘canny’, ‘prewitt’ operatörleri uygulanmıştır (Şekil 5.2 ve Şekil 5.3). Yapılan plaka bölgesi bulunması uygulamasına göre bu operatörler içerisinde canny operatörü en iyi sonucu vermiştir.



Şekil 5.2. Kameradan alınan ve Sobel kenar bulma algoritması uygulanmış görüntü



Şekil 5.3. Kameradan alınan ve Prewit kenar bulma algoritması uygulanmış görüntü

Bu operatör içerisinde yer alan kanarın belirlenmesi için gerekli eşik değeri ayarlanarak en iyi sonuç elde edilmiştir. Bu algoritmaya göre resim içerisinde 3x3 lük bir matris kullanılarak bir döngü ile yan yana olan pikseller arasındaki farka bakılmıştır (Şekil 5.4). Bu 3x3 lük matris elemanları canny operatöründe yer alan değerler kullanılarak uygulanmıştır (Şekil 5.5). Bu fark belli bir değerden büyükse o bölge kenar bölgesi olarak kimliklendirilmiş ve rengi beyaz yapılmıştır. Diğer kısımlar ise siyah

yapılmıştır (Denklem 5.1). Aynı şekilde döngü yukarıdan aşağıya tekrarlanmış ve bu kez alt alta gelen piksel değerlerine bakılarak kenar bölgeler bulunmuştur (Şekil 5.6).

$$\begin{aligned}
 DikeyFark &= \int_0^{I_t} \int_0^{J_t} P(i, j) - P(i+1, j) & YatayFark &= \int_0^{I_t} \int_0^{J_t} P(i, j) - P(i+1, j) \\
 DikeyFark &= \sum_0^{I_t} \sum_0^{J_t} P(i, j) - P(i+1, j) & YatayFark &= \sum_0^{I_t} \sum_0^{J_t} P(i, j) - P(i+1, j) \\
 if(fark > 50) \{ &P(i, j) = white; \} else \{ P(i, j) = black; \}
 \end{aligned} \tag{5.1}$$

P_1	P_2	P_3
P_4	P_5	P_6
P_7	P_8	P_9

Şekil 5.4. Resimdeki 3x3'lük bölge

-1	0	+1
-1	0	+1
-1	0	+1

Gx

+1	+1	+1
0	0	0
-1	-1	-1

Gy

Şekil 5.5. Canny kenar bulma operatörü



Şekil 5.6. Kameradan alınan ve Canny kenar bulma algoritması uygulanmış görüntü

Plakanın bulunması için resme canny kenar bulma (edge detection) algoritması uygulanmıştır. (Şekil 5.7). Kenar bulma algoritması yapılan resimde siyah-beyaz arası geçişlerin en yoğun olduğu bölge tespit edilmiştir. Tespit edilen plaka bölgesi 220x50 piksel boyutunda resimden ayrılmıştır.



Şekil 5.7. Plaka yeri belirlenmiş araç görüntüsü

5.3. Plakanın Görüntüsünün Netleştirilmesi

Farklı açılardan ve günün değişik zamanlarında alınan görüntülerde resimler arasında ışığın yoğunluğuna, yönüne ve diğer bazı etkenlere bağlı olarak resimlerin canlılığı arasında bir farklılık görülmektedir. Bu farklılığı azaltmak, resimlerdeki gürültüyü yok etmek ve işlenecek resimler arasında bir standart oluşturmak için plaka

resmine önce kontrast genişletme işlemi, daha sonra ortanca değer filtresi (Median filter) uygulanmıştır (Şekil 5.8).



Şekil 5.8. Plakanın netleştirilmesi

5.3.1. Kontrast genişletme

Bir resmin kontrastını genişletmek resmin sahip olduğu histogramı genişletmektir. Daha uygun bir açıklama ile koyu bölgeleri daha koyu açık bölgeleri ise daha açık hale getirerek resmi keskinleştirmektir (Şekil 5.8.b). Bu amaçla bir döngü ile plakanın bulunduğu bölgenin 0–255 arasında olan ortalama değeri bulunmakta ve bu değer bulunduktan sonra bir döngü daha yapılmakta ve bu ikinci döngüde okunan her piksel değeri için belli bir formül uygulanmaktadır (Denklem 5.2). Böylece değeri ortalama değerden büyük olan pikseller (aydınlık olan değerler) kendisi ile orantılı ve 1’den daha büyük bir değer ile çarpılarak daha aydınlık hale getirilmektedir. Aynı şekilde değeri ortalama değerden küçük olan pikseller (karanlık olan değerler) kendisi ile orantılı ve 1’den küçük bir değer ile çarpılarak daha karanlık hale getirilmektedir.

$$Ort = \left[\left(\int_0^I \int_0^J P(i, j) \right) / I_t J_t \right] \quad P(i, j) = (P(i, j) \cdot P(i, j)) / Ort \quad (5.2)$$

5.3.2. Ortanca filtresi

Ortanca filtresi resim üzerindeki istenmeyen gürültüleri yok etmek için kullanılan bir filtredir (Şekil 5.8.c). Resim matrisi üzerinde 3X3’lük bir matris dolaştırılır. Gürültünün yoğunluğuna göre bu kare matrisin boyutları ayarlanabilmektedir.

Ortanca filtresinde bir piksel merkezi piksel olarak seçilir ve onun etrafındaki pikseller de komşu pikseller olarak belirlenir. Bu dokuz piksel arasında küçükten büyüğe sıralama yapılır ve sıralama yapıldıktan sonra merkezi pikselin değeri sıralama yapılan dizinin 5. elemanı (ortadaki eleman) olarak atanır. Daha sonra bir sonraki piksele geçilir ve bu işlem baştan sona tüm pikseller için yapılır.

123	125	126	130	140
122	124	126	127	133
118	120	150	125	134
119	115	119	123	133
111	116	110	120	130

Şekil 5.9. Ortanca filtresi uygulanacak alan

Şekil 5.9 de verilen örnek için ortanca filtresini uyguladığımızda;

Merkezi piksel=150

Komşuluklar={124, 126, 127, 120, 150, 125, 215, 119, 123}


Sıralanan Dizi={119, 120, 123, 124, 125, 126, 127, 150, 215 }

Ortakdaki değer=125 olarak bulunur.

5.4. Karakterlerin Ayrıştırılması

Bu çalışmada plaka içerisinde yer alan harf ve rakamların ayrıştırılması amacıyla görüntüye Blob (**B**inary **L**arge **O**bject) coloring algoritması kullanılmıştır. Bu algoritma bir resimde birbirine değmeyen kapalı bölgeleri tespit edip ayırabilen güçlü bir yapıya sahiptir.

Blob coloring algoritması ikili sistemde kodlanmış görüntü içerisinde soldan sağa ve yukarıdan aşağıya olmak üzere özel bir L şeklinde şablon kullanarak tarama yapmaktadır (Şekil 5.10).



Şekil 5.10. L şablonu

Yapılan bu tarama 0'lardan oluşan arka plan içerisindeki 1'lerin dört taraflı bağlantıları ortaya çıkararak, birbirinden bağımsız her bir bölgeyi tespit eder. Bu algoritmanın çalışma şekli aşağıda verilmiştir.

```

Eğer  $f(X_c) = 0$  ise "Devam Et"
Değilse
    Başla
    Eğer  $(f(X_L) = 1 \text{ ve } f(X_U) = 0)$ 
    ise  $\text{Renk}(X_c) := \text{Renk}(X_U)$ 

    Eğer  $(f(X_L) = 1 \text{ ve } f(X_U) = 0)$ 
    ise  $\text{Renk}(X_c) := \text{Renk}(X_L)$ 

    Eğer  $(f(X_L) = 1 \text{ ve } f(X_U) = 1)$ 
    İse
        Başla
             $\text{Renk}(X_c) := \text{Renk}(X_L)$ 
             $\text{Renk}(X_U) \text{ eşittir } \text{Renk}(X_U)$ 
        Bitir

    Açıklama: İki renk birbirine eşittir.

    Eğer  $(f(X_L) = 0 \text{ ve } f(X_U) = 0)$ 
    İse  $\text{Renk}(X_L) = k;$ 
     $k := k + 1$ 

    Açıklama: Yeni Renk

    Bitir.
  
```

Şekil 5.11. Blob coloring algoritması

Bu çalışmada Plaka görüntülerine 4-komşulu blob coloring algoritması uygulanmıştır. Uygulama sonucunda karakterler plaka içerisinde tespit edilmiştir (Şekil 5.12).



Şekil 5.12. Blob coloring uygulanmış plaka görüntüsü

Yukarıdaki algoritmayla birbirinden bağımsız her bölgeye bir sınıf numarası verilir. İstenilen boyuttaki sınıflar resim içerisinden alınarak bir sonraki aşama olan tanıma işlemine dahil edilir (Şekil 5.13).



Şekil 5.13. Karakterleri ayrılmış plaka

Plaka içerisinde yer alan karakterler harf ve rakam olarak ayrı ayrı belirlenmiştir. Bu işlem için plaka üç bölgeye ayrılmıştır. Bu bölgelerden ilki il kodunu içeren ve iki rakamdan oluşan bölgedir. İkinci bölge ise sadece harf veya harflerden oluşmaktadır. Üçüncü bölge ise yine sadece rakamlardan oluşmaktadır. Bu işlemde yatay olarak plaka taranmış ve karakterler arası boşlukların belirlenen eşik değerden fazla veya az olmasına göre bu bölgeler belirlenmiştir. İlk bölge rakamlardan oluşmakta ve içerisindeki rakamlar ayrıştırılırken 28x35 boyutunda resim haline getirilmektedir. İkinci bölge sadece harflerden oluşmakta ve içerisindeki harfler 30x40 boyutunda resim olarak ayrıştırılmaktadır. Üçüncü bölgede yer alan karakterler yine 28x35 boyutlarında rakam görüntüsü olarak veritabanına kaydedilmektedir.


5.4. Karakterlerin Tanınması

Yapılan çalışmada ayrıştırma işlemi sonunda plaka içerisindeki tüm karakterler birer resim dosyası olarak kaydedilmiştir. Rakamların boyutu 28x35, harflerin boyutu ise 30x40 olarak belirlenmiştir. Sistemin daha verimli ve doğru çalışabilmesi için harf ve rakamlar için iki ayrı yapay sinir ağı kullanılarak sınıflandırma işlemi yapılmıştır.

Sinir ağının girişine uygulanacak sayısal karakterlerin her pikselinin verilmesi durumunda rakam için $28 \times 35 = 980$ tane veri, harf için ise $30 \times 40 = 1200$ veri girileceği için ve bu büyüklükteki verilerin eğitim aşamasında süreyi çok uzatacağından görüntüler belirli oranlarda bölünerek verilmesi uygun görülmüştür. Resimler; rakamlar için 4×5 harfler için 5×5 'lik matrislere bölünmüştür. Bölünen her resme ortalama mutlak sapma formülü uygulanmış ve rakam resimleri için 49, harf resimleri için 48 giriş değeri elde edilmiştir (Denklem 5.3). Rakamları bulan sinir ağının çıkış değeri 10 (0...9) ve harfleri bulan sinir ağının çıkış değeri ise 23 (A...Z) olarak belirlenmiştir.


$$F = \frac{1}{N} \left(\sum_{i=1}^N |a(x, y) - m| \right) \quad (5.2)$$

Bu çalışmada karakterlerin tanınması amacıyla tasarlanan yapay sinir ağı üç katmandan (Giriş-Gizli-Çıkış) oluşan ileri beslemeli geri dönüşümlü bir mimariye sahiptir. Giriş katmanı eğitime giriş olarak verilen harf veya rakam örneklerini içermektedir. Çıkış katmanı ise sınıflandırılacak harf veya rakam bilgisini vermektedir. Gizli katmandaki nöron sayısı 5–100 arasında 5'er artırılarak 100'er iterasyon çalıştırılmış ve en iyi sonuç hem harf hem de rakamları bulan sinir ağı için 40 nöron olarak bulunmuştur. Dolayısıyla harfleri bulan sinir ağı 48–40–23 şeklinde bir mimariye, rakamları bulan sinir ağı 49–40–10 şeklinde bir mimariye sahiptir. Aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır. Eğitim parametrelerinden olan öğrenme hızı (α) yapılan denemeler sonucunda 0,7 olarak belirlenmiştir. Eğitimin bitirilmesi için ortalama kare hata (MSE) denklemi uygulanmıştır. Her iki sinir ağının eğitim aşamasında hata değeri 0,0001 olarak alınmıştır. Yazılım içerisinde bu hata miktarı istenilen değere düşürülebilir. Aynı şekilde maksimum iterasyon sayısı da dışarıdan girilerek eğitimin durdurulması mümkün hale getirilmiştir. Araç plaka tanıma sistemi için geliştirilen yapay sinir ağı yazılımının ekran görüntüsü şekil 5.14' de verilmiştir.




Şekil 5.14. Araç plaka tanıma YSA yazılımı

Yapay sinir ağının eğitimi tamamlandıktan sonra katmanlar arası ağırlıklar bir dosyaya kaydedilebilir. Gerekğinde bu ağırlıklar dosyadan yüklenerek sistem test edilebilir. Yazılım tek bir karakter resmini alarak önceki kaydedilmiş ağırlıklara göre test etme imkânı sunmaktadır. Test sonucunda bulunan karakter ekrana yazdırılır (Şekil 5.15).



Şekil 5.15. Araç plaka tanıma YSA yazılımı

Eğitim tamamlandıktan sonra dosyaya kaydedilen ağırlıkları kullanarak karakter tanıma işlemi gerçekleştirilir. Bu işlemi tek bir seferde gerçekleştiren yazılımın ekran görüntüsü Şekil 5.16'de verilmiştir. Bu yazılımda tanınması istenen araç görüntüsü "Araç Görüntüsü Al" butonuna basılarak seçilir. Araç görüntüsü içerisinde plaka bölgesi "Plaka Bul" butonuna basılarak tespit edilir. Daha sonra "Karakterleri Ayır" butonuna basılarak plaka resminde yer alan karakterler ayrıştırılır. Ayrıştırılan karakterler "Oku" butonuna basılarak eğitim sonrası elde edilen ağırlıklara göre okunarak tanıma işlemi gerçekleştirilir. Tüm bu işlemler "Tanıma" butonuna tıklanarak tek bir seferde gerçekleştirilebilir. Tanıma işlemi gerçekleştirildikten sonra alınan ekran görüntüsü Şekil 5.17'de görülmektedir. Plaka tanıma sonrasında elde edilen plaka bilgisi sağ tarafta yer alan araç bilgileri kısmından veritabanına girilebilir. Bu kısımda plaka, ad-soyad, marka, model, yıl bilgileri veritabanına kaydedilir. Yeni gelen aracın tanıma işlemi yapıldıktan sonra "Kontrol Et" butonuna basılarak veritabanında olup olmadığı tespit edilir ve gerekli geçiş izni verilir.



Şekil 5.16. Araç plaka tanıma yazılımı



Şekil 5.17. Tanıma işlemi gerçekleştirilmiş yazılım görüntüsü

5.5. Deneysel Sonuçlar


Deneysel çalışmalarda kullanılan araç görüntüsü sayısı 259 dur. Bu 259 aracın 255’inde plaka bölgesi doğru olarak tespit edilmiştir. Dolayısıyla plaka bölgesi tespitinde başarı oranı %98,45 olarak elde edilmiştir.

Plaka bölgesi doğru tespit edilen bu 255 aracın plakalarında yer alan karakterlerin ayrılması işleminde 252 aracın plakasının karakterlerinin doğru olarak tespit edildiği gözlenmiştir. Dolayısıyla karakterlere ayırma işleminde %98,82 başarı elde edilmiştir.

Doğru olarak ayrıştırılmış bu karakterler harf ve rakam olmak üzere iki kategoride değerlendirilmiştir. Ayırıştırma işlemi sonunda 1222 adet rakam, 597 adet harf elde edilmiştir.

Sistemin karakterleri tanınması aşamasında harf ve rakamlar için iki farklı yapay sinir ağı kullanılmıştır. Harfler ve rakamlar için ayrı ayrı sinir ağı kullanılarak başarı oranının artırılması sağlanmıştır. Örneğin “B” harfi ile “8” rakamının tek bir sinir ağı ile sınıflandırılmasının iki farklı sinir ağı ile sınıflandırılmasına göre daha zor olduğu belirlenmiştir. Dolayısıyla harf ve rakam görüntüleri birbirinden ayrılarak sistemin karakterleri doğru sınıflandırma oranı artırılmıştır.

Elde edilen rakamlardan 200 tanesi yapay sinir ağının eğitim aşamasında, kalan 1022 adet rakam bilgisi test aşamasında kullanılmıştır. Eğitim aşamasında ulaşılması istenen hata değeri 0,001'dir. Yapılan deneysel çalışmalar sonucu bu hata değerine 4457 iterasyonda ulaşılmıştır. Eğitim süresi 2 dakika 10 saniye olarak ölçülmüştür. Rakamların eğitime ilişkin eğitim grafiği Şekil 5.16'da verilmiştir. Test aşamasında 1022 rakamdan 1000 adedinin doğru, kalan 22 adedinin ise yanlış sınıflandırıldığı tespit edilmiştir. Dolayısıyla rakam için genel doğru sınıflandırma oranı %97,84 olmuştur.



Şekil 5.18. Rakamların eğitim aşamasında hata oranlarının değişimi


Eğitim işlemi tamamlandıktan sonra her bir rakam için elde edilen test sonuçları Tablo 5.1' de verilmiştir.

Tablo 5.1. Rakamlar için elde edilen test sonuçları

KARAKTER	EĞİTİM	TEST	DOĞRU	YANLIŞ	BAŞARI
0	20	171	169	2	98,80%
1	20	58	56	2	96,50%
2	20	149	146	3	97,90%
3	20	146	143	3	97,90%
4	20	85	84	1	98,80%
5	20	79	79	0	100%
6	20	80	77	3	96,25%

7	20	146	140	6	95,80%
8	20	59	58	1	98,30%
9	20	49	48	1	97,90%
TOPLAM	200	1022	1000	22	97,84%

Ayrıştırma işlemi sonucunda elde edilen harflerden 250 tanesi yapay sinir ağının eğitim aşamasında, kalan 347 adet harf bilgisi test aşamasında kullanılmıştır. Eğitim aşamasında ulaşılması istenen hata değeri 0,001'dir. Yapılan deneysel çalışmalar sonucu bu hata değerine 1180 iterasyonda ulaşılmıştır. Eğitim süresi 59 saniye olarak ölçülmüştür. Harflerin eğitimine ilişkin eğitim grafiği Şekil 5.17'de verilmiştir. Test aşamasında 347 harften 344 adedinin doğru, kalan 3 adedinin ise yanlış sınıflandırıldığı tespit edilmiştir. Dolayısıyla harf için genel doğru sınıflandırma oranı %99,13 olmuştur.



Şekil 5.19. Harflerin eğitim aşamasında hata oranlarının değişimi

Eğitim işlemi tamamlandıktan sonra her bir harf için elde edilen test sonuçları Tablo 5.2'de verilmiştir.

Tablo 5.2. Rakamlar için elde edilen test sonuçları

KARAKTER	EĞİTİM	TEST	DOĞRU	YANLIŞ	BAŞARI
A	20	56	56	0	100%
B	10	9	9	0	100%
C	20	13	13	0	100%
D	20	47	45	2	95,70%
E	20	48	48	0	100%
F	20	31	31	0	100%
G	3	3	3	0	100%
H	20	18	18	0	100%
I	2	2	2	0	100%
J	4	4	4	0	100%
K	13	8	8	0	100%
L	9	9	9	0	100%
M	3	2	2	0	100%
N	9	9	9	0	100%
O	3	3	3	0	100%
P	6	8	7	1	88%
R	10	17	19	0	100%
S	10	9	9	0	100%
T	10	13	13	0	100%
U	10	9	9	0	100%
V	8	5	5	0	100%
Y	10	14	14	0	100%
Z	10	10	10	0	100%
TOPLAM	250	347	344	3	99,13%

Genel anlamda 259 araç görüntüsünden 247 adedinin plakası tam ve doğru olarak tanınmıştır. Dolayısıyla genel başarı oranı plakanın doğru olarak tanınma oranı 95,36 olmuştur. Yapılan deneysel çalışmalar sonucunda elde edilen başarı yüzdeleri Tablo 5.3 'de verilmiştir.

Tablo 5.3. Sistemin doğruluk oranları

Uygulama	Örnek Sayısı	Olumlu Sonuç	% Değer
Plakanın Yerinin Tespiti	259	255	98,45
Karakterlerin Ayrılması	255	252	98,82
Genel Başarım	259	247	95,36

6. SONUÇLAR VE ÖNERİLER

Son yıllarda teknolojinin günlük hayatta kullanımının artmasıyla insan hayatının kolaylaştırılmasına yönelik çalışmalar artmıştır. Hayatımızı zorlaştıran en önemli sorunlardan biri de trafik yoğunluğudur. Günümüzde araç sayısının artması ve trafikte oluşan sorunlar, otomatik araç tanıma ve trafik akış kontrolü sistemlerine duyulan ihtiyacı arttırmıştır. Bu ihtiyacı karşılamaya yönelik çalışmalar temel olarak araçların bir noktadan geçerken tanımlanması, aracın konumunun belirlenmesi ve bu veriler kullanarak trafik denetiminin daha iyi yapılmasına hizmet etmektedir.

Bu çalışmada 640*480 çözünürlüğündeki CCD kameradan görüntü alınmaktadır. Alınan renkli araç görüntüsü gri seviyeye dönüştürülmüştür. Bu dönüşümün yapılmasının sebebi renkli görüntüde 3 farklı renk değeri (RGB) bulunmakta iken gri seviyede tek bir değer döndürülmektedir. Dolayısıyla görüntü işleme açısından daha hızlı sonuç alınabilmektedir.

Bu görüntüye kenar bulma algoritmaları uygulanarak plakanın resimden ayrıştırılması işlemi gerçekleştirilmiştir. Bu işlem yapılırken literatürde yer alan farklı kenar bulma operatörleri uygulanmış ve Canny kenar bulma operatörünün en iyi sonuç verdiği tespit edilmiştir. Plaka bölgesi elde edilirken uygulanan kenar bulma algoritmasında siyah ve beyaz arasındaki geçişlerin en fazla olduğu bölge plaka bölgesi olarak belirlenmiştir. Bu çalışmada plaka bölgesi olarak 220x50 piksel boyutunda resim araç görüntüsünden kesilmiştir. Bu aşamada özellikle araç görüntüsünün alımında çekim açısının önemli olduğu gözlemlenmiştir. Deneysel çalışmalar göstermiştir ki, karşıdan çekilen görüntülerde bir problem oluşmamakta, sağ ve sol taraftan 60 derece ve üzeri açılardan alınan görüntülerde plaka bölgesi yanlış olarak tespit edilmektedir. Bunun yanı sıra plaka dışında araç üzerinde yer alan şirket logoları gibi geçişlerin çok yoğun olduğu bölgelerde plaka bölgesi olarak tanımlanabilmektedir. Bu sorunun üstesinden gelebilmek için geçiş yoğunluğu için bir eşik değeri belirlenmiş ve plakanın yerinin doğru olarak tespit edilme oranı artırılmıştır.

Plaka bölgesi elde edildikten sonra görüntü iyileştirme işlemleri yapılmıştır. Bunun amacı plaka görüntüsünde yer alabilecek ışık ve kontrast farklılıklarının en aza

indirilmesidir. Bu amaçla plaka görüntüsüne kontrast genişletme ve ortanca değer filtresi uygulanmıştır.

Gürültülerden arındırılan plaka görüntüsüne blob coloring algoritması uygulanmış ve plakada yer alan harf ve rakamların ayrıştırılması sağlanmıştır. Karakterlerin plaka görüntüsü içerisindeki konumuna göre harf ve rakam olarak ayrılarak veritabanına alınmıştır. Harflerin boyutu 30x40 piksel, rakamların boyutu ise 28x35 piksel olarak belirlenmiştir.

Harf görüntüleri 5x5 piksel boyutunda alt görüntülere bölünmüş, her bir alt görüntüye ortalama mutlak sapma formülü uygulanarak sayısallaştırılmıştır. Rakam görüntüleri 4x5 piksel boyutunda alt görüntülere bölünmüş, her bir alt görüntüye ortalama mutlak sapma formülü uygulanarak sayısallaştırılmıştır. Bu işlemin yapılmasının sebebi YSA'na verilecek giriş sayısının azaltılmak istenmesidir. Harf ve rakam için iki farklı yapay sinir ağı tasarlanmıştır. Bu eğitimler sonucunda elde edilen ağırlık değerleri kullanılarak resim içerisinde ayrılaştırılmış karakterler tanınmıştır.

Kullanılan YSA mimarisi literatürde en çok karşılaşılan ileri beslemeli geri dönüşümlü çok katmanlı perseptron yapısına sahiptir. Gizli katman nöron sayısı ve öğrenme katsayısı deneme yanılma yoluyla belirlenmiştir. Kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur.

Test işlemlerinin sonuçlarına göre; plaka yerinin tespitinde 259 plakanın 255'inde olumlu sonuç alınarak %98,4 başarı elde edilmiştir. Bu 255 plakanın da 252'ü karakterlerine ayrılarak %98,8 başarı elde edilmiştir. Karakterlerine ayrılan bu 252 plakadan 247'sinin karakterleri doğru okunarak %98 başarı tespit edilmiştir. Sistemin genel başarısına bakarsak; 259 adet araç resmi içerisinde doğru biçimde okunan plaka miktarı 247 olarak tespit edilmiştir. Dolayısıyla genel sistem başarısı %95,3 olmuştur.

Elde edilen sistem başarısı ile literatürde bulunan sistemlerin başarı oranları karşılaştırıldığında; literatürdeki sistemlere göre yapılan çalışmanın daha yüksek yüzde ile tanıma gerçekleştirildiği görülmektedir. Fakat bu oranlar araç görüntülerinin durumuna göre farklılık gösterebilmektedir. Başka bir deyişle ulusal veya uluslar arası bir veritabanından alınmamış olan araç görüntülerinin; çekim zamanı, ışık miktarı,

çekim açısı, görüntü boyutu gibi özelliklerine göre sistemin başarımlı oranı değişebilmektedir. Dolayısıyla literatür ile karşılaştırma yaparak sağlıklı bir sonuca ulaşmak mümkün değildir.

Çalışmanın ileriki aşamalarında daha fazla sayıda araç görüntüsü alınarak test edilmesi düşünülebilir. Hatta il trafik müdürlüğü ile irtibata geçilerek kayıtlarında bulunan araç görüntüleri alınarak sistemin performansı test edilebilir. Bu çalışmada gece görüş özelliğı olmayan bir kamera kullanılmıştır. Dolayısıyla alınan görüntüler gün içerisinde çekilmiştir. Gerçekleştirilen sistem gece görüş özelliğı olan bir kamera ile test edilebilir.

KAYNAKLAR

- Ahmadyfard, A. and Abolghasemi, V., 2008, Telecommunications, 2008. IST 2008. International Symposium, Tehran, 804-808.
- Allahverdi, N. 2002. Uzman Sistemler Bir Yapay Zeka Uygulaması, Atlas Yayın Dağıtım, İstanbul.
- Auty, G. , Corke, P. , Dunn, P. , Jensen, M. , Macintyre, I. , Mills, D. , Nguyen, H. and Simons, B., 1995, An Image Aquisition System for Trafic Monitoring Applications, SPIE: Cameras and Systems for Electronic Photography and Scientific Imaging, 118-133.
- Babu, C.N.K. and Nallaperumal, K., 2008, India Conference, 2008. INDICON 2008. Annual IEEE, Kanpur, Vol. 1, 34-39.
- Bal, H., 2006, “Kamera ile Görüntü İşleme Teknikleri İle Malzeme Tane Büyüklüğü Analizi”, Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü Makina Mühendisligi*, Ankara, 24-42.
- Bayraktar, H., 2004, “Development Of A Stereo Vision System For An Industrial Robot”, Yüksek Lisans Tezi, *Middle East Technical University*, Ankara, 1-120.
- Bishop, C.M. 1995. Neural Network for Pattern Recognition, Oxford University Pres, England.
- Boğaziçi, 2010, İnternet Sitesi. <http://robot.cmpe.boun.edu.tr> [Ziyaret Tarihi:24.07.2010]
- Boers, E.J.W. and Kuiper, H. 1992. Biological metaphors and the design of modular artificial neural networks, Master thesis, Departments of Computer Science and Experimental and Theoretical Psychology at Leiden University, the Netherlands.
- Breiman, L. 1994. Heuristics of instability in model selection. Technical Report Statistics Department, University of California at Berkeley.
- Caner, H., 2006, FPGA Donanımı Üzerinde Araç Plaka Tanıma Sistemi, Yüksek Lisans Tezi, *Hacettepe Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 11-38.
- Chang S.L., Chen L.S., Chung Y.C. and Chen S.W., 2004, Intelligent Transportation Systems, IEEE Transactions, Vol. 5, Issue 1, 42-53.
- Chanson, D. and Roberts, T., 2001, License Plate Recognition System. The 2001 International Conference on Imaging Science, Systems, and Technology (CISST'2001). Monte Carlo Resort, Las Vegas, Nevada. USA.
- Chen H., Ren J., Tan H. and Wang J., 2007, Image and Graphics, 2007. ICIG 2007. Fourth International Conference, Sichuan, 604-609.

- Chen Z.X., Liu C.Y., Chang F.L. and Wang G.Y., 2009, Vehicular Technology, IEEE Transactions, Vol. 58, Issue 7, 3781-3785.
- Collomosse, J. P. and Oliver, M. A., 2001, Recognition of Vehicle Licence Plates from Real World Images. Final year project. University of Bath, pp. 40.
- Çamaşırcıoğlu, E., 2007, Araç Plakası Algılama ve Tanıma, Yüksek Lisans Tezi, *Ankara Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 42-67.
- Çelik, U., 2003, Motorlu Araçlar İçin Plaka Tanıma Sistemi, Yüksek Lisans Tezi, *Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü*, Hatay, 40-60.
- Dawson, J. A. L. and Gatling, I., 1986, Electronic Road Pricing In Hong Kong. Transportation Research, A. Vol. 20, 129-134.
- Dodd, N. 1990. Optimization of network structure using genetic algorithms. Proceedings of the International Neural Network Conference, INNC-90-Paris, 693-696, B. Widrow and B. Angeniol (Eds.), Kluwer, Dordrecht.
- Draghici, S., 1997, A Neural Network Based Artificial Vision System for Licence Plate Recognition. International Journal of Neural Systems. 18(1):113-126.
- Ellsworth, D. and Moran, P. 2003. Accelerating Large Data Analysis By Exploiting Regularities. Proceedings of IEEE Visualization 2003, WA, pp. 561-568.
- Fahlman, S.E. 1988. An empirical study of learning speed in back-propagation networks. Technical report, Carnegie Mellon University.
- Fahmy, M., 1993, Computer Vision Application to Automatic Number-Plate Recognition, In Proceedings of 26th. International Symposium on Automotive Technology and Automation, Aachen-Germany, 625-633.
- Fausett, L.V. 1994. Fundamentals of Neural Networks: Architectures, Algorithms And Applications, Prentice Hall Publ.
- Fine, T. L. 1999. Feedforward Neural Network Methodology. Springer, New York.
- Freeman, J., and Skapura, D. 1991. Neural Networks. Reading MA: Addison-Wesley Publ.
- Gao Q., Wang X. and Xie G., 2007, Automation and Logistics, 2007 IEEE International Conference, Jinan, 2964-2968.
- Gendy, S., Smith, C.L. and Lachowicz, S., 1997, Security Technology, 1997. Proceedings. The Institute of Electrical and Electronics Engineers 31st Annual 1997 International Carnahan Conference, Canberra, 209-218.
- Gillan, W. J., 2000, PROMETHEUS-Reducing Traffic Congestion By Advanced Technology, In Roads And Traffic 2000, International Road and Traffic Conference, Berlin, Vol. 1, 111-115.

- Hamey, L.G.C. and Priest, C., 2005, Digital Image Computing: Technqiues and Applications, 2005. DICTA ' 05. Proceedings, 87-94.
- Happel, B.L.M. 1992. Architecture and function of neural networks: designing modular architectures. In prep.
- Hauslen, R. A., 1977, The Promise Of Automatic Vehicle identification. IEEE Transactions on Vehicular Technology, VT-Vol. 26, 30-38.
- Haykin, S. 1999. Neural Networks A Comprehensive Foundation, Prentice Hall publishing, New Jersey.
- Hebb, D.O. 1949. The Organization of Behaviour: A Neuropsychological Theory, New York: Wiley.
- Hopfield, J.J. 1982. Neural Networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences, USA, vol. 79, pp. 2254-2258.
- Kayhan, B., 2009, Car Plate Recognition, M. Sc. Thesis, *Atilim University in Computer Engineering*, Ankara, 19-34.
- Kim, K.K., Kim, K.I., Kim, J.B. and Kim, H.J., 2000, Neural Networks for Signal Processing X, 2000. Proceedings of the 2000 IEEE Signal Processing Society Workshop, Sydney, Vol. 2, 614-623.
- Kitano, H. 1990. Designing neural networks using genetic algorithms with graph generation system. Complex Systems, 4, 461-476, Champaign, IL.
- Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. Biological Cybernetics, vol. 43, pp. 59-69.
- Luenberger, D. G. 2003. Linear and nonlinear programming, second edition. Springer.
- McCulloch, W. S. and Pitts, W. H. 1943. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 5:115-133.
- Nan, J., Zhiye, Z. and Liqun, R. 2003. Design of structural modular neural networks with genetic algorithm, Advances in Engineering Software, 34:17-24.
- Özbay, S., 2006, Automatic Vehicle Identification by Plate Recognition, M. Sc. Thesis in Electrical& Electronics Engineering, *Gaziantep University Graduate School of Natural & Applied Sciences*, Gaziantep, 45-62.
- Öztemel, E. 2003. Yapay Sinir Ağları, Papatya Yayınevi, İstanbul.
- Qin Z., Shi S., Xu J. and Fu H., 2006, Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress, Dalian, Vol. 2, 8645-8649.

- Quan J., Shuhai Q., Ying S. and Zhihua X., 2009, Image and Signal Processing, 2009. CISP '09. 2nd International Congress, Tianjin, 1-6.
- Rosenblatt, F. 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65:386-408.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. 1986. Learning representations by back-propagating errors. *Nature*, 323:533—536.
- Sağıroğlu, Ş., Beşdok, E. ve Erler, M. 2003. Mühendislikte Yapay Zeka Uygulamaları-1 Yapay Sinir Ağları, Ufuk Yayıncılık, Kayseri.
- Schwarz, G. 1978. Estimating the Dimension of a Model. *The Annals of Statistics*, 6, 2, 461-464.
- Setchell, J., 1997, Application of Computer Vision to Road-Traffic Monitoring, PhD Thesis, University of Bristol.
- Sirithinaphong, T. and Chamnongthai, K., 1998, Circuits and Systems, 1998. IEEE APCCAS 1998. The 1998 IEEE Asia-Pacific Conference, Chiangmai, Vol. 3, 559-562.
- Stoelhurst, H. J. , and Zandbergen, A. J. , 1990, The Development Of A Road Pricing System In The Netherlands, *Traffic Engineering And Control*, Vol. 31, 66-71.
- Syed, Y.A. and Sarfraz, M., 2005, Information Visualisation, 2005. Proceedings. Ninth International Conference, Issue Date : 6-8 July 2005, 227-232.
- Tan H.C. and Chen H., 2008, Machine Learning and Cybernetics, 2008 International Conference, Kunming, Vol. 7, 4034-4039.
- Thamsanqa, M., 2006, “The identification of mammalian species through the classification of hair patterns using image pattern recognition”, *ACM Special Interest Group on Computer Graphics and Interactive Techniques ACM Press*, Image-based techniques, 10:177 – 181.
- Türkoğlu, İ., 2003, Örüntü Tanıma Sistemleri Ders Notları, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 1-80.
- Türkoğlu, İ., Arslan, A. 1996. Yapay Sinir Ağları ile Bozuk Örüntü Tanıma, *F.Ü. Fen ve Mühendislik Bilimleri Dergisi*, 8, 147 – 158.
- Wang S.Z. and Lee H.J., 2003, Intelligent Transportation Systems, 2003. Proceedings. 2003 IEEE, Vol. 2, 979-984.
- Wei S. and Yanping B., 2009, Image and Signal Processing, 2009. CISP '09. 2nd International Congress, Tianjin, 1-4.

- Wei W., Li Y., Wang M. and Huang Z., 2001, Neural Networks for Signal Processing XI, 2001. Proceedings of the 2001 IEEE Signal Processing Society Workshop, North Falmouth, 529 - 538.
- Widrow, B. And Hoff, M.E. 1960. Adaptive switching circuits. IRE WESCON Convention record, pp. 96-104.
- Wikipedia, 2010, <http://www.wikipedia.org>, [Erişim Tarihi:24.07.2010]
- Yalım, B., 2008, Türk Sivil Plaka Standartları İçin Araç Plaka Tanıma Sistemi, Yüksek Lisans Tezi, *Gazi Üniversitesi Bilişim Enstitüsü*, Ankara, 46-88.
- Yang H., Xu L., and Shi L., 2007, Information Technologies and Applications in Education, 2007. ISITAE '07. First IEEE International Symposium, Kunming, 602-605.
- Ying L. and Nannan L., 2008, Automation and Logistics, 2008. ICAL 2008. IEEE International Conference, Qingdao, 2818-2821.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Kerim Kürşat ÇEVİK
Uyruğu : T.C.
Doğum Yeri ve Tarihi : KARAMAN - 21/01/1985
Telefon : 03883114527
Faks : 03883115438
e-mail : kcevik@nigde.edu.tr

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Anadolu Lisesi Merkez-KARAMAN	2003
Üniversite	: Süleyman Demirel Ün.v. Merkez-ISPARTA	2007
Yüksek Lisans	: -	
Doktora	: -	

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2003-2007	S.D.Ü. Bilgi İşlem D. Başkanlığı	Kısmi Zamanlı Öğrenci
2007-2010	M.E.B.	Teknik Öğretmen
2010-	Niğde Üniversitesi Bor M.Y. O.	Öğretim Görevlisi

UZMANLIK ALANI

Görüntü İşleme, Yapay Zekâ, .NET Programlama

YABANCI DİLLER

İngilizce

BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

YAYINLAR