



EGE ÜNİVERSİTESİ

YÜKSEK LİSANS TEZİ

RETİNA DAMAR GÖRÜNTÜLERİNDE

TİPİK NOKTALARIN BULANIK RBF

MODELİYLE ÇIKARILMASI

Cemre CANDEMİR

Tez Danışmanı : Doç. Dr. Muhammed Gökhan CİNSDİKİCİ

Uluslararası Bilgisayar Anabilim Dalı

Bilim Dalı Kodu : 619.02.04

Sunuş Tarihi : 14.06.2012

**Bornova-İZMİR
2012**

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

(YÜKSEK LİSANS TEZİ)

**RETİNA DAMAR GÖRÜNTÜLERİNDE
TİPİK NOKTALARIN BULANIK RBF
MODELİYLE ÇIKARILMASI**

Cemre CANDEMİR

Tez Danışmanı : Doç. Dr. Muhammed Gökhan CİNSDİKİCİ

Uluslararası Bilgisayar Anabilim Dalı

Bilim Dalı Kodu : 619.02.04

Sunuş Tarihi : 14.06.2012

Bornova-İZMİR

2012

Cemre CANDEMİR tarafından YÜKSEK LİSANS tezi olarak sunulan “Retina Damar Görüntülerinde Tipik Noktaların Bulanık RBF Modeliyle Çıkarsanması” başlıklı bu çalışma E.Ü. Lisansüstü Eğitim ve Öğretim Yönetmeliği ile E.Ü. Fen Bilimleri Enstitüsü Eğitim ve Öğretim Yönergesi’nin ilgili hükümleri uyarınca tarafımızdan değerlendirilerek savunmaya değer bulunmuş ve 14.06.2012 tarihinde yapılan tez savunma sınavında aday oybirliği/oyçokluğu ile başarılı bulunmuştur.

Jüri Üyeleri:

İmza

Jüri Başkanı : Doç. Dr. Muhammed G. CİNSDİKİCİ

Raportör Üye : Yrd. Doç. Dr. Cengiz GÜNGÖR

Üye : Yrd. Doç. Dr. Engin KARATEPE

ÖZET**RETİNA DAMAR GÖRÜNTÜLERİNDE TİPİK NOKTALARIN
BULANIK RBF MODELİYLE****ÇIKARSANMASI**

CANDEMİR, Cemre

Yüksek Lisans Tezi, Uluslararası Bilgisayar Anabilim Dalı

Tez Danışmanı: Doç. Dr. Muhammed Gökhan CİNSDİKİCİ

Haziran 2012, 74 sayfa

Retina damarları, bir takım hastalıkların teşhisinde önemli bir rol oynamaktadır ve bunların başında diyabetik retinopati hastalığı gelmektedir. Diyabetik retinopati (DR) gözün ışığı algılamasını sağlayan retina isimli sinir tabakasının şeker hastalığı nedeniyle kan damarlarındaki değişikliklere sebep olduğu bir hastalıktır. Hasar görmüş kan damarları sıvı ve kan sızmasına neden olarak dallar ve sert izli (scar) dokular oluşmasına, bunlar da retinanın beyine bozulmuş şekiller göndermesine sebep olmaktadır.

Diyabetik retinopati, diyabete bağlı olarak erken yaşta ortaya çıkan katarakt ve aynı sebepten dolayı diğer yetişkinlere oranla yaklaşık iki kat fazla görülen göz tansiyonu (glokom) içerisinde en sık görülenidir ve yetişkinlerde önemli bir körlük sebebidir. Diyabetik retinopatisi olan hastaların başlangıçta görmelerinde bazı değişiklikler ortaya çıkabilir. Hastalık ilerledikçe, retina yüzeyinde anormal yeni damar oluşumları meydana gelmektedir ve hastalığın tanısı ve ilerleyişi bu yeni damar oluşumlarının takibiyle yapılmaktadır. Bu takip için damardan flöresein boya verilerek özel bir anjiyo çekimi yapılmakta ve boya retina damarlarından geçerken art arda fotoğrafları çekilmektedir. Bu sayede damarlar daha net olarak elde edilebilmektedir. Hastalığın ilerleyişi, damar görüntülerinin karşılaştırılarak (registration) farklılıklarının ortaya konulması ile ancak gözlemlenebilmektedir.

Bu tez kapsamında, retina damar görüntülerinin karşılaştırılması amacıyla retina damar görüntülerindeki tipik noktaların çıkarsanması için yeni bir yöntem olarak Bulanık RBF (Fuzzy RBF) kullanılması amaçlanmaktadır.

Anahtar sözcükler: radyal temelli fonksiyon ağları, görüntü karşılaştırma, damar tipik noktaları, bulanık mantık, yapay sinir ağlar

ABSTRACT**VASCULAR LANDMARK DETECTION IN RETINAL IMAGES
USING FUZZY RBF**

CANDEMİR, Cemre

MSc Thesis in International Computer

Supervisor: Assoc. Prof. Dr. Muhammed Gökhan CİNSDİKİCİ

June 2012, 74 pages

Retinal vessels play an important role in the diagnosis of various diseases and diabetic retinopathy is one of the major diseases among those. Diabetic retinopathy (DR) is a disease that causes changes in vessels of the retina (nerve layer of the eye that allows the eye to detect the light) caused by diabetes. Damaged blood vessels cause fluid and blood leakage and as a result leading the formation of the branches and rough track (scar) tissue, which cause the retina to send distorted shapes to the brain.

Diabetes-related diabetic retinopathy, is one of the most common diseases of cataracts which is seen in early years and eye pressure (glaucoma) which is seen about two times higher in young people than adults and is an important cause of blindness among adults. At the beginning some changes related with the vision of patients with diabetic retinopathy may occur. As the disease progresses, abnormal new vessel formation occurs on the surface of the retina and the progression of the disease and the diagnosis is made by following the formation of new blood vessels. For this tracing, fluorescein dye is used for angiography and consecutive photographs are taken while the dye is circulating in the retinal vessels. In this way, the vessels can be obtained more clearly. The progress of the disease, can be observed only through overlaying images of blood vessels (registration), and uncovering the differences.

Within the context of this thesis, Fuzzy RBF (FRBF) is intended to be used as a new method for detection of the landmark points from retina vessels to register the retinal vascular images.

Keywords: radial basis function network, image registration, vascular landmark points, fuzzy logic, artificial neural networks

TEŞEKKÜR

Öncelikle bu tez konusu üzerinde bana çalışma imkanı sunan ve ayrıca yüksek lisans eğitimim süresince danışmanım olan Doç. Dr.Muhammed Gökhan CİNSDİKİCİ' ye deneyimleri, bilgileri ve önerileriyle araştırma ve geliştirmeye yönlendirmesi ve sağladığı kaynaklar ile destek olmasından dolayı teşekkürü bir borç bilirim. Ayrıca tez süresince her türlü fikir ve desteklerinden dolayı Araştırma Görevlisi ve doktora öğrencisi olan Cihat ÇETİNKAYA'ya, manevi destekleri ve yardımları için Araştırma Görevlisi arkadaşlarım Sebla DEMİRKOL ve Sercan DEMİRCİ' ye, öte yandan bana yüksek lisans eğitimi yapma imkanı sunan Uluslararası Bilgisayar Enstitüsü'ne ve tez çalışması boyunca yanımda olan aileme, manevi desteği ve anlayışı için sevgili eşime teşekkürlerimi sunarım.

İÇİNDEKİLER

Sayfa

ÖZET	v
ABSTRACT	vii
TEŞEKKÜR	ix
ŞEKİLLER DİZİNİ	xv
ÇİZELGELER DİZİNİ.....	xix
KISALTMALAR.....	xxi
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ.....	4
2.1 Model Tabanlı Yaklaşımlar	4
2.2 Geometrik Tabanlı Yaklaşımlar	5
3. GENEL KAVRAMLAR	11
3.1 Bulanık Mantık	11
3.2 Bulanık Kümeleme (Fuzzy Clustering)	15
3.3 Yapay Sinir Ağları	16
3.3.1 Yapay sinir ağı tanımı.....	17
3.3.2 Biyolojik sinir hücreleri ve biyolojik sinir hücresi modeli	17
3.3.3 Yapay sinir ağı modeli.....	19
3.3.4 Aktivasyon fonksiyonları.....	22

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
3.3.5 Öğrenme stratejileri.....	25
3.3.6 Basit algılayıcılar (Perceptrons).....	27
3.3.7 Çok katmanlı algılayıcılar (Multi layer perceptrons).....	28
3.3.8 Radyal tabanlı fonksiyon ağları (Radial basis functions)	28
4. ÖNERİLEN YÖNTEM.....	33
4.1 Veri Seti	33
4.2 Yöntem.....	33
4.2.1 Ön işleme (Preprocess)	34
4.2.2 Öz nitelik çıkarımı (Feature Extraction)	36
4.2.3 Bulanık RTF yapay sinir ağı ile tipik nokta tespiti	39
4.3 Performans	52
4.3.1 ROC eğrileri.....	52
4.3.2 Sonuçlar	55
5. SONUÇ ve ÖNERİLER.....	62
KAYNAKLAR DİZİNİ	64
ÖZGEÇMİŞ.....	73

İÇİNDEKİLER (devam)

EKLER.....	
EK – 1 İNGİLİZCE – TÜRKÇE SÖZLÜK	
EK – 2 KARŞILAŞTIRMA SONUÇLARI.....	

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
1.1 Oftalmoskop ile çekilmiş sağlıklı bir retina görüntüsü.....	1
1.2 Referans olarak kullanılacak noktalar	3
2.1 Coding based multi-directional exploratory	6
2.2 Bazı damar noktası sınıfları	6
2.3 Yanlış sınıflandırma örneği	7
2.4 Modified crossover point number metod.....	7
2.5 MCN metodu ile olası kesişim noktaları	8
2.6 CCN metodunda kullanılan 5x5lik pencere.....	8
2.7 Yerel ve topolojik analiz ile sınıflandırma	9
2.8 Yanlış sınıflandırma örnekleri	10
2.9 Öznitelik vektörü çıkarsaması için kullanılan şablon.....	10
3.1 Yaşlara ait üyelik fonksiyonu	12
3.2 Üçgen üyelik fonksiyonu... ..	13
3.3 Yamuk üyelik fonksiyonu	14
3.4 Çan eğrisi üyelik fonksiyonu	14
3.5 7 adet üyelik fonksiyonundan oluşan bulanık küme.....	15
3.6 Nöron yapısı.....	18

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
3.7 Yapay sinir hücresinin yapısı.....	19
3.8 Yapay sinir ağının genel blok şeması	19
3.9 Sınıflandırıcı olarak kullanılabilen altı sinir ağının taksonomisi	21
3.10 Yapay sinir ağı katmanlarının birbirleri ile ilişkileri	21
3.11 Bir yapay sinir ağı örneği.....	22
3.12 Sık kullanılan hard-limiter fonksiyonları	23
3.13 Eşik (threshold) fonksiyonu	24
3.14 Sigmoid fonksiyonu	25
3.15 Öğretmenli öğrenme blok diagramı	26
3.16 Destekleyici öğrenme blok diagramı	26
3.17 Kendi kendine öğrenme blok diagramı.....	27
3.18 Perceptron sinyal akış grafiği.....	28
3.19 RBF mimarisi.....	29
3.20 Boyut yükseltme ile lineer ayrıştırılabilirlik	29
3.21 Gauss fonksiyonu.....	31
4.1 Değerlendirme dışı bırakılan retina görüntüleri.....	35
4.2 Optik disk bölgesi çıkarılacak örnek bir retina görüntüsü	35

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
4.3 Öznitelik vektörü çıkarılmasında kullanılan şablon	37
4.4 Öznitelik vektörü çıkarılan noktalar	38
4.5 Öznitelik çıkarılacak olan noktaların ayrıntılı görüntüsü	38
4.6 FRBF mimarisi	41
4.7 Önerilen yöneme ait FRBF mimarisi	43
4.8 Önerilen yönemin genel akış şeması	51
4.9 Örnek ROC grafiği	54
4.10 İki ROC eğrisinin karşılaştırılması	54
4.11 Retina test görüntülerinde test yapılan noktalardan bazıları.....	55
4.12 Tipik nokta çıkarsamasına ait sistem performansını gösteren ROC eğrisi...	57
4.13 Tipik nokta sınıflandırmasına ait sistem performansını gösteren ROC eğrisi	60

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
3.1 Bilgisayar ile insan beyni arasındaki sistem yapısının karşılaştırılması.....	17
4.1 Öznitelik Vektörleri	37
4.2 FRBFNN Parametreleri	50
4.3 ROC eğrisi için sınıflandırma matrisi	52
4.4 Küme geçerlilik indeksleri ile önerilen küme sayılarının sistem üzerindeki doğruluk değerleri	56
4.5 DRIVE veritabanındaki her bir test görüntüsüne ait performans ölçüm sonuçları	56
4.6 Neimeijer et al.'a ait POI'lerin performans ölçüm sonuçları	57
4.7 Şablon eşleme yaklaşımında önerilen küme sayılarına ait sonuçlar	58
4.8 Şablon eşleme yaklaşımında deneysel küme sayılarına ait sonuçlar	59
4.9 Önerilen yöntemin diğer yöntemler ile karşılaştırılması	60
A.1 $m=1.5$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları	80
A.2 $m=1.6$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları	80
A.3 $m=1.7$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları	81
A.4 $m=1.8$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları	81
A.5 $m=1.9$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları	82

ÇİZELGELER DİZİNİ (devam)ÇizelgeSayfa

A.6 $m=2.1$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.....	82
A.7 $m=2.2$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.....	83
A.8 $m=2.3$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.....	83
A.9 $m=2.4$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.....	84
A.10 $m=2.5$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.....	84
A.11 $m=3.0$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.....	85
A.12 Farklı bulanıklık katsayılarına göre FRBF ağının ürettiği sonuçlar.....	85

KISALTMALAR


Kısaltmalar	Açıklama
ACC	Accuracy
ACO	Ant Colony Optimization
ANN	Artificial Neural Network
ART	Adaptive Resonance Theory
BP	Bifurcation Point
CCN	Combined Crossover Number
CLAHE	Contrast Limited Adaptive Histogram Equalizaiton
CO	Crossover Point
ÇN	Çatallanma Noktası
DR	Diabetik Retinopathy
DRIVE	Digital Retinal Images for Vessel Extraction
FCM	Fuzzy C-Means
FCQ	Fuzzy C-Quadratic Shells
FCR	Fuzzy C-Ring
FCRS	Fuzzy C-Rectangular Shells
FCS	Fuzzy C-Shells
FCSS	Fuzzy C-Spherical Shells
FCV	Fuzzy C-Varieties
FFA	Fundus Floresin Anjiyografi
FN	False Negative
FP	Folse Positive
FPR	False Positive Rate
FS	Fukuyama-Sugeno
KN	Kesişim Noktası
LMS	Least Mean Square

KISALTMALAR (devam)

Kısaltmalar	Açıklama
LVQ	Learning Vector Quantization
MCN	Modified Crossover Number
MLP	Multilayer Perceptrons
NÇB	Negatif Çok Büyük
PC	Partition Coefficient
PCA	Principal Component Analysis
PCAES	Partition Coefficient and Exponential Seperation
PÇB	Pozitif Çok Büyük
PE	Partition Entropy
POI	Point of Interest
RBF	Radial Basis Function
RBFNN	Radial Basis Function Neural Network
RLS	Recursive Least Square
ROC	Receiver Operating Characteristic
RTF	Radyal Tabanlı Fonksiyon
RTFSA	Radyal Tabanlı Fonksiyon Sinir Ağı
SCN	Simple Crossover Number
SOM	Self Organizing Maps
TBA	Temel Bileşenler Analizi
TN	True Negative
TP	True Positive
TPR	True Positive Rate
XB	Xie-Beni
YSA	Yapay Sinir Ağı

1. GİRİŞ

Retina, gözün arkasında yer alan, ışığa duyarlı hücreler ile görüntüye ilişkin bilgiyi beyne taşıyan sinir liflerini içeren ve görme işlevini gerçekleştiren göz tabakasıdır. Retina adı verilen ağ tabakası, göz küresinin iç arka duvarını tamamen kaplamakta ve milyonlarca görme hücresi ile bunların bağlı olduğu sinir hücrelerinden oluşmaktadır. Bu sinir hücrelerinin uzantıları bir araya gelerek görme sinirini oluşturur. Bu hücreleri besleyen damarlar da retina tabakası içinde yer alırlar. Retina merkezinde görmeyi sağlayan, ışığın odaklandığı, özelleşmiş bölgeye makula (sarı nokta) adı verilmektedir. Şekil 1.1'de DRIVE veritabanından alınmış sağlıklı bir retina görüntüsü gösterilmektedir.



Şekil 1.1 Oftalmoskop ile çekilmiş sağlıklı bir retina görüntüsü.

Retina, görme işlevinin gerçekleştiği yer olduğundan dolayı burada meydana gelecek bir bozukluk doğrudan görme duyusunu tehdit eder ve hatta görme yeteneği kaybedilebilir. Kişide meydana gelen diğer hastalıklar da retina üzerinde değişikliklere yol açabilmektedir. Retinayı tehdit eden en önemli hastalıklar diyabet ve hipertansiyondur. Kan basıncının yükselmesi, retina atardamar dallarının lokal ve genel olarak daralmasına neden olur. Yüksek basıncın süresindeki uzama nedeniyle kan-retina bariyerlerinin yıkılması sonucu plazma ve kırmızı kan hücreleri damar dışına sızar ve retina kanamaları oluşur.


Yüksek tansiyon aynı zamanda retina sinir lif tabakası ile bu tabakanın altında yer alan pigment epiteli tabakasının birbirinden ayrılarak retina yırtılmalarının (retina dekolmanları) meydana gelmesine de sebep olmaktadır.

Hipertansiyonun yanı sıra, retinayı tehdit eden diğer önemli bir hastalık ise şeker hastalığıyla birlikte gelişen diabetik retinopati (DR) dir. Diabetik retinopati, yüksek kan şekeri nedeniyle gözün retina tabasındaki damarların hasar görmesi sonucunda gelişen hastalıktır ve diabete bağlı göz hastalıkları içerisinde en sık görülenidir ve ayrıca yetişkinlerde önemli bir körlük sebebidir. Bu hastalığa sahip olanların %2'si kördür ve %10'u da şeker hastalığına yakalandıktan 15 yıl sonraki yıl içerisinde diabetik retinopati nedeniyle görme kaybına uğramaktadırlar. 2000 yılında dünya çapındaki nüfusun %2.8'inde şeker hastalığı bulunurken, Wild et al. 2004 yılında yaptığı çalışmada 2030 yılı itibariyle bu oranın %4.4'e çıkacağını öngörmektedirler. Bu da, hasta sayısının 171 milyondan 366 milyona çıkacağı anlamına gelmektedir. 15 yıllık diabeti olan birinde diabetik retinopati gelişme riskinin %80 oranında olduğu ve tedavi edilmeyen diabet hastalarının normal bir insana göre 25 kat daha fazla körlük riski taşıdığı düşünülürse, hastalığın erken teşhis ve tedavisinin önemi tartışılmaz bir gerçektir.

Diabetik retinopati teşhisinde, hastalığı saptamak için oftalmoskop cihazıyla detaylı göz dibi muayenesi yapılır. Daha fazla bilgi edinmek için göz dibinin renkli fundus fotoğrafı çekilir. Renkli fundus fotoğrafının çekilmesinde kullanılan en verimli yöntem, Fundus Floresein Anjiyografi (FFA) yöntemidir. Bu yöntemde, hastaya damar yoluyla floresein adlı ilaç verilmekte ve ilaç retina damarlarına ulaştığında anjiyografi cihazı ile retinanın siyah-beyaz fotoğrafları çekilmektedir. Hastada damarlardan bir kanama veya sızıntı olup olmadığı bu yöntemle ayırt edilebilmektedir. Ayrıca elde edilen bu görüntüler, hastanın durumunu değerlendirmek ve sonraki dönemlerinde hastalığın takibini yapmak üzere saklanmaktadır.

Hastalığın takibi süresince hastalardan alınan farklı görüntüler karşılaştırılarak hastalığın ilerleyişi hakkında bilgi sahibi olunabilmektedir. Hastalardan alınan görüntülerin karşılaştırılması görüntü çakıştırma (registration – kayıtlama) yöntemi ile yapılmaktadır. Görüntü çakıştırma, eldeki görüntü ile karşılaştırma için temel alınan referans görüntü üzerinden belirli noktaların seçilerek, bu noktaların üst üste bindirilmesi sonucu iki resimde meydana gelen farkın çıkarılması işlemidir. Bu görüntüler, farklı zamanlarda farklı bakış açılarından, farklı algılayıcılardan veya farklı aydınlanma koşullarından elde

edilmiş farklı boyutta görüntüler olabilir. İşte bunun gibi, retina görüntülerinde hastalığın ilerleyişi dışında hastalıktan meydana gelmeyen değişiklikler de söz konusudur ve bu değişiklikler görüntü çakıştırma işlemini zorlaştırmaktadır. Bu gibi etkenlerin görüntü çakıştırma işleminden önce görüntülerden mümkün olduğunca arındırılması gerekmektedir. Ancak görüntüler bu tür etkilerden arındırıldıktan sonra görüntü çakıştırma işlemi gerçekleştirilebilmektedir. Çakıştırma için kullanılacak noktaların seçimi ise çakıştırma işleminden önce yapılmalıdır. Retina görüntüsü için kullanılabilecek referans noktalar, damarların yapı/kalınlık bilgisi, sarı nokta (makula) bölgesi ile damarların çatallanma (bifurcation) ve kesişim (crossover – crossing) noktalarıdır. Referans nokta bilgisi ne kadar çok ise, çakıştırma işlemi de o kadar yüksek verimlilikle gerçekleştirilmektedir. Şekil 1.2’de tez kapsamında referans olarak kullanılacak olan noktalar gösterilmektedir. Bu referans noktalardan çatallanma noktaları, damarların kollara ayrıldığı noktalardır. Kesişim noktaları ise, gerçekte var olmayıp birbirleri üzerinden geçen damarların iki boyutlu görüntüde kesişiyormuş gibi görüldüğü noktalardır.



Şekil 1.2 Referans olarak kullanılacak noktalar (a) Çatallanma Noktası (BP) (b) Kesişim Noktası (CO).

Tezin bundan sonraki bölümleri şu şekilde düzenlenmiştir. İkinci bölümde, konu hakkındaki literatür çalışmalarına değinilecektir. Üçüncü bölümde ise geliştirilen yöntemde kullanılan genel kavramlar açıklanacaktır. Daha sonraki bölümde geliştirilen yöntem ve son bölümde de önerilen yönteme ait deneysel sonuçlar, karşılaştırmalar ve elde edilen verilerin yorumları yer alacaktır.

2. LİTERATÜR ÖZETİ

Bu bölümde, retina damarlarındaki tipik noktalar olan çatallanma ve kesişim noktalarının çıkarılmasına yönelik literatürde yer alan çalışmalar hakkında bilgi verilecektir. Literatürde bu çalışmalara yönelik yaklaşımlar iki sınıfta kategorize edilmektedir (Can et. al., 1999, Chanwimaluang et al., 2006, Bhuiyan 2007). İlk alt bölümde literatürde yer alan iki ana yöntemden biri olan model tabanlı yaklaşımlar anlatılırken ikinci alt bölümde geometrik tabanlı yaklaşımlardan bahsedilecektir.

2.1 Model Tabanlı Yaklaşımlar

Literatürde model tabanlı yaklaşımlar, öznelik tabanlı (feature based, Chanwimaluang et al., 2006) ve damar izleme (vessel tracking, Can et al., 1999) olarak da adlandırılmaktadır. Model tabanlı yaklaşım, damardaki çatallanma ve kesişim noktalarının belirlenmesi, damarların izlenmesi ve keşfedilmesi (exploring) esasına dayanmaktadır. Bu yöntemde, gri tondaki retina görüntüsündeki damar üzerinde bir başlangıç noktası belirlenerek, damar özyinelemeli (recursive) olarak izlenir ve modellenir. Bu izleme boyunca, her damar parçası yön, genişlik ve merkez noktası olmak üzere üç özellikte nitelendirilmektedir. Bu yaklaşımda, damarın başarılı bir şekilde modellenebilmesi için kullanılan algoritma damardaki çatal noktaları ve kesişim noktalarını ayırt edebilmelidir.

Bu yaklaşım altında literatürdeki ilk çalışmada, damarların başlangıç, bitiş, yön, genişlik değerleri ve komşulukları manuel olarak belirlenerek damar tipik noktaları çıkarılmaktadır (Mortensen et al., 1992). Zhou et al. (1994), çalışmalarında yön, damarların genişlik değerleri ve komşuluk bilgileri gibi manuel veri girişini çıkararak sadece damarların başlangıç ve bitiş noktalarını belirleyerek çatal nokta ve kesişim nokta çıkarılması yapmıştır.

Can et al., 1999 yılında yaptıkları çalışmada, damarların başlangıç ve bitiş değerlerini manuel olarak girmek yerine, bu bilgileri otomatik olarak belirleyen bir metot ortaya atmıştır. Bu metodda, retina damar görüntüleri ızgaralara bölünerek, ızgara içerisinde kalan bölgede kontrast ve yoğunluk değerlerinden minimuma sahip noktalar başlangıç noktaları olarak seçilmektedir. Damar izlenmesi boyunca, başka damarlarla karşılaşıldığı takdirde karşılaşma açlarına

ve sayılarına bakılarak kesişim noktası veya çatallanma noktası ayrımı yapılmaktadır.


Model tabanlı yaklaşım, sadece damara yakın belirli pikselleri işlediğinden dolayı düşük işlem karmaşıklığına sahiptir ve dolayısıyla hızlıdır. Ancak damar ağının doğal yapısının karmaşık olmasından dolayı damarları izlemek ve incelemek çok zordur. Ayrıca, model tabanlı yaklaşımların birçoğu kayıp tipik noktalardan etkilenmektedir ve retina damar ağının yapısı ile fiziksel bağlantılarını saptamak için herhangi bir komşu noktayı veya damarı kullanamamaktadırlar. Bu metot, gerçekleştirme (implementation) için hızlı, pratik ve daha uyarlanabilir (Bhuiyan et al., 2007) olmasına karşın damarların takibine yönelik başlangıç, bitiş, yön gibi parametreler için manuel bilgi gerektirdiğinden dolayı gerçek zamanlı uygulamalar için kullanılamamaktadır.

2.2 Geometrik Tabanlı Yaklaşımlar

Literatürde yer alan geometrik tabanlı yaklaşım da, farklı bilim insanları tarafından alan tabanlı (area-based), (Chanwimaluang et al., 2006) ve piksel işleme yaklaşımı (pixel processing), (Can et al., 1999) gibi farklı isimler altında incelenmişlerdir. Geometrik tabanlı yöntem, sırasıyla damarların çıkartılması (vessel extraction), damar ağacı iskeletinin elde edilmesi (skeletonization) ve çıkarılan damar iskeletinin analizi olmak üzere üç aşamadan oluşmaktadır.

Zhang et al.'un (2002) çalışmasında, damar görüntüleri öncelikle bir ön işlemden (preprocess) geçirilerek görüntülerdeki gürültüler giderilmiş, arka plan ile damarlar arasındaki düşük kontrast düzeltilmiştir. Görüntüdeki gürültüleri giderebilmek için Gaussian filtresi kullanılırken, damarların görülebilirliğini arttırmak için yapılan düşük kontrast düzeltme işlemi için ise Top-Hat filtering kullanılmıştır. Yapılan bu ön işlemlerin ardından, elde edilen damar görüntüleri inceltme (thinning) işlemi ile bir piksel kalınlığa düşürülerek damar ağacı iskeleti çıkartılmıştır. Bu çalışmada, damarlardaki çatallanma noktaları ve kesişim noktalarının yanı sıra uç noktalar (end points) da göz önüne alınmıştır. Bu noktaların çıkarsanması için, damar ağacı iskeletinin elde edilmesinin ardından damar ağacındaki her bir pikselin etrafına 3x3 lük bir pencere çizilerek damarlardaki tipik noktaların bulunabilmesi amaçlanmıştır. Her bir pencere saat yönünün tersi yönünde Şekil 2.1'de gösterildiği gibi numaralandırılmış ve 8 adet komşu piksel değerlerinin (2.1) formülü ile hesaplanmasıyla kesişim noktalarının sayısı (cross point number, cpn) bulunmuştur. Bu formüle göre $cpn=1$ ise bulunan


nokta bir uç nokta, $cpn=2$ ise, bir iç nokta (inner point), $cpn=3$ ise bir çatallanma nokta (BP) ve $cpn=4$ ise bulunan nokta bir kesişim noktası (CO) dır.



Şekil 2.1 Coding based multi-directional exploratory (Zhang et al, 2002).

$$cpn = \frac{1}{2} \left(\sum_{i=1}^8 |P_i - P_{i+1}| \right) : P_9 = P_1 \quad (2.1)$$

Formüle göre bulunan kesişim noktalarına ait bazı damar noktası sınıf örnekleri aşağıda yer almaktadır.



Şekil 2.2 Bazı damar noktası sınıfları (a) Uç nokta (b) İç nokta (c) Çatallanma noktası (d) Kesişim noktası.

Damarlardaki çatallanma ve kesişim noktalarının bulunmasına yönelik Zhang et al.'un (2002) çalışmasında kullandığı 3x3 lük pencere yöntemi farklı damar çıkarsama metodları ile damarları çıkarsayan Perez et al. (2002), Chanwimaluang et al. (2003), Bevilacqua et al. (2005) ve Bhuiyan et al. (2007) un çalışmalarında da bulunabilir.

Bir kesişim noktasının birbirini çok dar açıyla kestiği durumda bu noktalar damar inceltme işleminden sonra iki çatallanma noktasına ve/veya iki çatallanma


noktasının birbirine çok yakın olduğu durumda da bu iki nokta bir kesişim noktasına dönüşebilir. Bu durumda yanlış bulunan tipik noktalar bu metodun doğruluğunu azaltmakta ve metodun en büyük dezavantajını oluşturmaktadır.



Şekil 2.3 Yanlış sınıflandırma örneği (a) Kesişim noktası (b) Thinning işleminin ardından iki çatal nokta olarak değerlendirilen damar görüntüsü.


Bu dezavantajı ve yanlış sınıflandırmayı ortadan kaldırmak için literatürde farklı çalışmalar yer almaktadır. Bu çalışmalardan bir tanesi Iqbal et al. (2008) tarafından yapılmıştır. Iqbal et al.'un yöntemi ile 5x5 lik pencere içerisinde dışta yer alan 16 komşu pikseli kullanarak tipik noktaların sınıflandırılması amaçlanmıştır. *Modified crossover-point number* (MCN) metodu ile daha önceki yöntemlerde kullanılan 3x3 lük pencere boyutu genişletilerek, olası yanlış sınıflandırmaların azaltılacağı öngörülmüştür. Sözü edilen metotta, kesişim noktalarının sayısı (2.2) deki denklem ile bulunmaktadır.

$$cpn = \frac{1}{2} \left(\sum_{i=1}^{16} |P_i - P_{i+1}| \right) \quad (2.2)$$




Şekil 2.4 Modified crossover point number metod (Iqbal et al., 2008).

Zhang et al.'ın yönteminden farklı olarak MCN yönteminde kesişim noktalarının belirlenme kriteri $cpn \geq 4$ tür.



Şekil 2.5 MCN metodu ile olası kesişim noktaları ($cpn \geq 4$).

Her ne kadar, bu yöntem ile 3x3'lük pencere yöntemine oranla daha iyi bir sonuç alınsa da yine de bazı durumlarda bir kesişim noktasının iki çatallanma noktasına dönüştüğü ve 5x5'lik penceredeki 16 komşuluğun bunu tanımlayamaması gözlemlenmiştir. Bunun üzerine, Aibinu et al. 2010 yılında, 2008 yılında yaptıkları çalışmanın bir devamı ve uzantısı niteliğinde bir metot daha ortaya atmışlardır. Sözü edilen metot, hem SCN hem de MCN metodlarının birlikte çalıştığı hibrit bir yöntemdir (Combined Crosspoint Number - CCN). Bu yöntemde, tipik nokta çıkarsanması için hem 5x5 hem de 3x3'lük pencere iç içe kullanılmaktadır (Aibinu et al., 2010).




Şekil 2.6 CCN Metodunda kullanılan 5x5'lik pencere.

MCN yönteminde, bir noktanın kesişim noktası olarak tanımlanması için aşağıdaki iki koşulu da sağlaması gereklidir.

$$cpn_{MCN} \geq 4 \text{ ve } cpn_{SCN} \geq 4$$


Aksi halde, $2 < cpn_{MCN} < 4$ ve $2 < cpn_{SCN} < 4$ koşulunu aynı anda sağlayan bir nokta, çatallanma noktası olarak tanımlanmaktadır (Aibinu et al., 2010).

2010 yılında Calvo et al., ortaya attığı yöntemde öncelikli olarak Zhang'ın önerdiği yöntemle damarlardan tipik nokta ayrıştırması, diğer bir deyişle aday tipik nokta tespiti yapmaktadır. Elde edilen aday tipik noktaları ise sırasıyla yerel ve topolojik analiz uygulayarak sınıflandırmaktadır. Yerel analiz, noktanın diğer noktalara etkisi hesaplanmadan yapılan analizdir. Bu analizde aday tipik nokta etrafına pencere çizilerek çatal nokta ve kesişim noktası sınıflandırması yapılmaktadır. Bu sınıflandırmanın ardından, kesişim noktalarının kesişim açıları nedeniyle iki çatallanma noktasına dönüşmesinden dolayı yanlış sınıflandırmaları engellemek amacıyla topolojik analiz uygulanmaktadır. Topolojik analizde ise, ilk adımda sınıflandırılan noktaların etrafına farklı boyutta çemberler çizilerek, bu noktaların kesin sınıflandırmaları yapılmaktadır.




Şekil 2.7 Yerel ve topolojik analiz ile sınıflandırma (a) BP (b) CO (Calvo et al., 2010).

Ancak bu yöntem, yanlış sınıflandırmaları azaltmasına rağmen yine de damar yapısından kaynaklanan yanlış sınıflandırmaların önüne geçememektedir ve bu yanlış sınıflandırmaların oranı %6.4 olarak hesaplanmıştır.



Şekil 2.8 Yanlış sınıflandırma örnekleri (a) Kesişim noktası koşulunu sağlayan fakat kesişim noktası olmayan nokta (b) Kesişim noktası olan fakat uzaklık koşulundan dolayı kesişim noktası olarak değerlendirilmeyen nokta (Calvo et al., 2010).

Niemeijer et al. (2011) çalışmalarında tipik nokta tespiti için k-en yakın komşu regresyon, (k-Nearest Neighboring – kNN) yöntemi kullanılmıştır. Bu yöntemin öncesinde, retina görüntüleri üzerinde bir oftalmolog tarafından 719 tanesi BP, 1062 tanesi CO olmak üzere toplam 1781 adet ilgi noktası (Point-of-Interest, POI) işaretlenmiştir. Görüntülere uygulanan inceltme (thinning) işleminin ardından, eğitim (train) görüntülerinden Şekil 2.9’da gösterilen şablon (template) kullanılarak 32 adet özellik çıkarsaması yapılmıştır.



Şekil 2.9 Özellik çıkarsaması için kullanılan şablon (Neimeijer et al., 2011).

Kullanılan şablon için en iyi değerler $r_1=3$ ve $r_2=6$ olarak bulunmuştur. Özellik çıkarsanmasının ardından uygulanan kNN regresyon yöntemi ile bu metodun başarısı %89 olarak ölçülmüştür.

Geometrik tabanlı yaklaşımlar, model tabanlı yaklaşımlara oranla tipik nokta tespitinde daha yüksek doğruluklu sonuçlar üretmesine rağmen, bu yöntemin en büyük dezavantajı tüm piksellerin işlenmesinden doğan işlem karmaşıklığı ve zaman maliyetidir.

3. GENEL KAVRAMLAR

Bu bölümde, tez çalışması kapsamında kullanılacak olan bulanık mantık, bulanık c-ortalama kümeleme algoritması, küme sayısı geçerlilik yöntemleri ve yapay sinir ağlarından bahsedilmiştir. Çalışma dahilindeki bulanık radyal tabanlı fonksiyonlar da yine bu bölümde anlatılmıştır.


3.1 Bulanık Mantık

Niteliği tam olarak belli olmayan, açık seçik görünmeyen, net olmayan şeklinde tanımlanan bulanık mantık, ilk olarak Profesör Dr. Lotfi A.Zadeh'in 1965 yılında yayımladığı çalışma ile literatüre geçmiştir. Bu çalışma, kesin olmayan sınırlara sahip nesnelerin oluşturduğu bulanık küme teorisini ortaya koymaktadır (Zadeh, 1965). Bulanık mantık teorisi, klasik Aristo mantığının siyah-beyaz ikilemine karşılık, grinin çeşitli derecelerinin varlığının bilimsel olarak ifade edilebilmesidir (Gökçen, 2007). Aynı zamanda bulanık mantık, dilsel terimlerden kaynaklanan, kesin olmayışı ya da belirsizliği modellemeyi mümkün kılan ve belirsizliklerle çalışılabilmesi için kurulmuş katı bir matematiksel düzen olarak tanımlanabilir.

İstatistik, olasılık gibi bilimlerde, belirsizliklerle değil kesinliklerle çalışılmaktadır fakat hem insanın yaşadığı ortam, hem de insan kararları belirsiz ve bulanıktır ve kesin sayısal değerlerle ifade etmeye uygun değildir. Bu nedenle, bu tür modellemelerde, sözel değişkenler kullanmak daha gerçekçi olacaktır. Böylece biraz kısa, biraz sıcak, biraz aydınlık, epey soğuk gibi daha esnek niteleyicilerle gerçek dünyaya benzetim yapılabilmesi mümkün olabilmektedir. Bulanık mantıkla klasik matematiğin temel farklılığı, bulanık mantık sözel değişkenlerin kullanımına izin verirken, klasik matematiğin sadece 0-1 gibi aşırı uç değerlere izin vermesidir.

Klasik kümelerde, bir eleman o kümeye ya aittir ya da değildir. Diğer bir deyişle elemanın kümeye aitlik derecesi ya "0" dır ya da "1" dir. "0" mutlak yanlışlığı temsil ederken, "1" mutlak doğruluğu temsil etmektedir. Yani klasik kümede, kümeye ait olanlarla olmayanlar arasında kesin bir farklılık mevcuttur, bir eleman birden fazla kümeye ait olamaz. Bulanık kümelerde ise, bu keskin farklılık ortadan kaldırılarak bir elemanın kümeye olan üyelik derecesi $[0.0, 1.0]$ aralığında tanımlanmaktadır.

Şekil 3.1.b’de görüldüğü gibi, üyelik fonksiyonu 0 ile 1 arasında yer alan her değeri alabilir. Bu tür bir üyelik fonksiyonu ile “kesinlikle ait” ve “kesinlikle ait değil” arasında istenilen hassasiyetle ayarlama yapmak mümkündür.



Şekil 3.1 Yaşlara ait üyelik fonksiyonu (a) Klasik kümeye ait üyelik fonksiyonu
(b) bulanık kümeye ait üyelik fonksiyonu

X boş olmayan bir küme olmak üzere, bulanık bir A kümesi üyelik fonksiyonu $A: X \rightarrow [0,1]$ ile ifade edilir. $\forall x \in X$ için, üyelik derecesi $A(x)$ veya $\mu_A(x)$ şeklinde gösterilmektedir. X evrensel kümesi sonlu sayıda $x_1, x_2, x_3 \dots, x_n$ kümelerinden oluştuğunda bulanık A kümesi Zadeh’in açılım ilkesine göre aşağıdaki gibi ifade edilmektedir.

$$A = \left\{ \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \dots + \frac{\mu_A(x_n)}{x_n} \right\} = \sum_{i=1}^n \frac{\mu_A(x_i)}{x_i} \quad (3.1)$$


Eğer X evrensel kümesi sürekli ve sınırsız ise, A kümesi

$$A = \int \frac{\mu_A(x)}{x} \quad (3.2)$$

ile gösterilir. (3.1) numaralı denklemde cebirsel semboller, cebirsel anlamlarıyla kullanılmamaktadırlar. Örneğin, denklem içerisindeki toplama işareti A kümesinin eleman çiftleri ve üyelik derecelerinin topluca ifade edilmesi amacıyla kullanılırken, bölme işareti X evrensel kümesinde, A kümesinin sıfır olmayan üyelik derecelerine sahip olan tüm elemanlarını, A daki üyelik dereceleriyle birleştirmektedir.

Üyelik fonksiyonları genellikle, üçgen (triangular), yamuk (trapezoidal), veya çan eğrisi (Gauss, bell-shaped) biçimlerinde olmaktadır. En yaygın olarak kullanılan üyelik fonksiyonu ise, üçgen şeklinde olmaktadır.


Üçgen üyelik fonksiyonunda temel olarak kullanılan üç farklı parametre ve parametrelerin durumlarına göre elde edilebilecek sonuçlar Şekil 3.2 ve (3.3) numaralı denklemde verilmiştir.



Şekil 3.2 Üçgen üyelik fonksiyonu.

$$T(x; a, b, c) = \begin{cases} 0 & , x < a \\ (x - a)/(b - a) & , a \leq x \leq b \\ (c - x)/(c - b) & , b \leq x \leq c \\ 0 & , x > c \end{cases} \quad (3.3)$$


Yamuk üyelik fonksiyonu ise dört farklı parametreden oluşmaktadır. Şekil 3.3 ve (3.4) numaralı denklemde yamuk üyelik fonksiyonunun parametrelerinden elde edilen sonuçlar gösterilmiştir.



Şekil 3.3 Yamuk Üyelik Fonksiyonu.

$$T(x; a, b, c, d) = \begin{cases} 0 & , x < a \\ (x - a)/(b - a) & , a \leq x \leq b \\ 1 & , b \leq x \leq c \\ (d - x)/(d - c) & , c \leq x \leq d \\ 0 & , x > d \end{cases} \quad (3.4)$$


Çan eğrisi (Gauss) üyelik fonksiyonunda ise üç parametre söz konusudur. Tipik bir çan eğrisi üyelik fonksiyonu ile ilgili parametreler Şekil 3.4 ve elde edilen sonuçlar denklem (3.5) ile gösterilmiştir.



Şekil 3.4 Çan Eğrisi Üyelik Fonksiyonu.

$$G(x; a, b, c) = \begin{cases} 0 & , x < a \\ 1/(1 + |(x - c)/a|^{2b}) & , a \leq x \leq d \\ 0 & , x > d \end{cases} \quad (3.5)$$

Çok daha karmaşık üyelik fonksiyonları kullanabilmek mümkündür, fakat karmaşıklık arttıkça, algoritmaların karmaşıklığı da artmaktadır. Şekil 3.5'te pozitif çok büyük (PÇB) ve negatif çok büyük (NÇB) gibi toplam 7 adet dilsel etiketli üyelik fonksiyonlarından oluşan örnek bir bulanık küme gösterilmektedir.



Şekil 3.5 7 adet üyelik fonksiyonundan oluşan bulanık küme.

3.2 Bulanık Kümeleme (Fuzzy Clustering)

Veri kümeleme (data clustering), veri seti elemanlarından aynı sınıfta olanlarını birbirine olabildiğince çok, farklı sınıflarda olanları ise birbirine olabildiğince az benzeyecek şekilde sınıflara ya da kümelere ayırma işlemidir. Verinin dağılımına ya da kullanım amacına göre farklı kümeleme teknikleri kullanabilmek mümkündür. Literatürde kümeleme teknikleri, katı kümeleme (hard clustering - crisp clustering) ve yumuşak- bulanık kümeleme (soft clustering - fuzzy clustering) olmak üzere ikiye ayrılmaktadır. Katı kümeleme yaklaşımında, veri ayrık kümeler üzerine dağıtılır ve verinin her bir elemanı yalnızca bir kümeye ait olur. Bulanık kümeleme yaklaşımı ise bir elemanın farklı üyelik dereceleri ile aynı anda birden fazla kümeye ait olmasına izin verir. Birçok durumda, bulanık kümeleme bu esnekliğinden dolayı katı kümelemeden daha doğru ve doğal bir kümeleme sağlar.

Bulanık kümeleme yöntemleri uzaklığa dayalı (distance-based) ve ilişkiye dayalı (relation-based) olmak üzere iki çeşittir. Uzaklığa dayalı yöntemde, her bir verinin her bir kümeye aitlik dereceleri ile bu kümelerin ağırlık merkezlerine olan uzaklıklar çarpımı minimum yapılmaya çalışılır. Ancak bazı durumlarda veriler ile kümelerin ağırlık merkezleri arasındaki uzaklığı bulmak mümkün olmayabilir. Bu durumda da veriyi oluşturan birimler arasındaki ilişkiden yararlanılarak kümeleme yapılır.

Literatürde, verinin türüne ya da yapılacak sınıflandırmaların tipine göre farklı bulanık kümeleme algoritmaları yer almaktadır. Bu algoritmaların başlıcası ve bu çalışma kapsamında kullanılan bulanık kümeleme algoritması bulanık c-ortalama (fuzzy c-means) algoritmasıdır. Bu algoritmanın detayları bir sonraki bölümde anlatılacaktır. Höppner et al. (1999) çalışmasında, aşağıda yer alan literatürdeki diğer bulanık kümeleme algoritmalarını ayrıntılı bir biçimde incelemiştir. Bu algoritmalar şunlardır:

Fuzzy c-varieties (FCV) algoritması: 2-boyutlu uzayda doğrusal manifoldların bulunması ve sınıflandırılmasında,

Fuzzy c-shells (FCS), Fuzzy c-spherical shells (FCSS), Fuzzy c-rings (FCR) algoritmaları: çemberlerin bulunması ve sınıflandırılmasında,

Fuzzy c-quadratic shells (FCQ) algoritması: elipsoidlerin bulunması ve sınıflandırılmasında,

Fuzzy c-rectangular shells (FCRS) algoritması: dikdörtgenlerin bulunması ve sınıflandırılmasında kullanılmaktadırlar.

Çalışma kapsamında yer almadıkları için bu algoritmaların ayrıntılarına değinilmemiştir.

3.3 Yapay Sinir Ağları

İnsanoğlu tarih boyunca insan beyninin nasıl çalıştığını, fonksiyonlarını ve kapasitesini merak etmiştir ve insan beyninin çalışması ve fonksiyonları uzun yıllardan beri araştırma konusudur. Beynin fonksiyonlarıyla ilgili bilgi veren ilk eser 1890 yılında James tarafından yayımlanmıştır. 1940'lı yıllardan sonra Hebb, McCulloch ve Pitts gibi bilim adamları günümüzdeki yapay sinir ağlarının temellerini ve ilk yapay sinir hücresinin yapısını oluşturmaya başlamışlarsa da, bugün sinir ağı teorisinin babası Hebb olarak bilinmektedir. Hebb, iki sinir hücresinin birbirleriyle nasıl bir korelasyon sergilediklerini incelemiş ve sinir ağı teorisini bu temel üzerine oturtmuştur (Cinsdikici, 1994). Hebb (1949) yapay hücrelerden oluşan bir yapay sinir ağının değerlerini değiştiren bir öğrenme kuralı geliştirmiştir ve Hebbian öğrenme olarak bilinen bu kural günümüzde birçok öğrenme kuralının da temelini oluşturmaktadır.

3.3.1 Yapay sinir ağı tanımı


Yapay sinir ağları (YSA), insan beyninin bilgi işleme özelliğinden esinlenerek geliştirilmiş paralel dağılmış bir bilgi işleme sistemidir (Haykin, 2009). Diğer bir ifadeyle, yapay sinir ağları insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Düşünme ve gözlemleme yeteneklerine dayalı problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenebilme yeteneğidir. Bu yüzden yapay sinir ağı sistemine insan beyninin modeli denilebilir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Çizelge 3.1’de bilgisayar ile insan beyni arasındaki çalışma sistemi yapısı karşılaştırmalı olarak verilmiştir.

Çizelge 3.1 Bilgisayar ile insan beyni arasındaki sistem yapısının karşılaştırılması.

BİLGİSAYAR	İNSAN BEYNİ
Sayısal	Analog
Seri	Paralel
Komut Kümeli	Bilgiye Adapte Olma
Yanlış Hesaplamalar Sonucu Etkiler	Birimlerin Ana İşlemlere Etkisi Azdır
Giriş Verilerindeki Hatalar Sonucu Etkiler	Giriş Verilerindeki Hatalara Her Zaman Duyarlı Değil

3.3.2 Biyolojik sinir hücreleri ve biyolojik sinir hücresi modeli

Sinir sisteminin en temel fonksiyonel birimi sinir hücreleri ya da diğer adıyla nöronlardır. Bir sinir ağı milyonlarca nöronun bir araya gelmesi ile oluşmaktadır. Sinir hücreleri birbirleri ile bağlanarak fonksiyonlarını yerine getirmekte ve bu bağlantıların ayarlanması sayesinde öğrenme gerçekleşmektedir. İnsan beyninde yaklaşık olarak 10^{10} adet nöron olduğu ve hücre başına bağlantı sayısının 10^{14} , toplamda ise $6 \cdot 10^{13}$ ten fazla sayıda bağlantı olduğu bilinmektedir (Parent and Carpenter, 1995) . Vücudun çeşitli yerlerinden bilgi alışverişi yapan, nöron hücresidir.



Şekil 3.6 Nöron yapısı


Şekil 3.6’da gösterildiği gibi temel bir sinir hücresi soma, akson, dendritler ve sinaplardan oluşmaktadır. Sinapslar nöronlar arasındaki bağlantı işlevini gerçekleştirmektedir. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan boşluklardır. Aktarılan bu sinyaller somaya giderler. Soma gelen bu sinyalleri işleme tabi tutar, sinir hücresi kendi elektrik sinyalini oluşturur ve sinyal akson aracılığıyla dendritlere gönderilir.

Dendritler tarafından alınan sinyaller hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir iş yapılacaksa üretilen çıkış darbesi diğer nörona iletilir (Gülez, 1999). İki hücrenin birbirleri ile bilgi alışverişi sinaptik bağlantılarda neurotransmitter madde yoluyla sağlanmaktadır. Verilen özelliklerde milyarlarca sinir hücresi bir araya gelerek sinir sistemini oluşturmaktadır. Yapay sinir ağları biyolojik hücrelerin bu özelliklerinden yararlanılarak geliştirilmiştir.


Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik bağlantıların ayarlanması ile gerçekleşir. Diğer bir deyişle, insanlar doğumlarından itibaren yaşayarak öğrenme süreci içerisine girerler. Bu süreç içerisinde sinaptik bağlantılar ayarlanır ve hatta yeni bağlantılar oluşur; yani beyin sürekli bir gelişme ve öğrenme gösterir. Bu durum yapay sinir ağı için de geçerlidir. Öğrenme, eğitme yoluyla örnekler kullanılarak olur; başka bir deyişle, gerçekleşme girdi/çıkı verilerinin işlenmesiyle, yani eğitme algoritmasının bu verileri kullanarak sinapsların bağlantı ağırlıklarını bir yakınsama sağlanana kadar, tekrar tekrar ayarlanması ile olur (Yazıcı, 2006).

3.3.3 Yapay sinir ağı modeli

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri süreç (process) elemanları olarak da adlandırılmaktadır ve temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir (Haykin, 2009). Şekil 3.7 ve Şekil 3.8’de en temel nöron modeli yapısı ve yapay sinir ağının genel blok şeması gösterilmektedir.



Şekil 3.7 Yapay sinir hücresinin yapısı.




Şekil 3.8 Yapay sinir ağının genel blok şeması.

Bir yapay sinir ağı hücresi girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş temel eleman içermektedir. Dış ortamdan ya da diğer nöronlardan alınan veriler yani girdiler, ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girdinin önemini ve hücre üzerindeki etkisini belirler. Ağırlıkların büyük ya da küçük olması etkisinin önemli veya önemsiz olduğu anlamına gelmez. Ağırlığın değerinin sıfır olması herhangi bir etkisinin olmadığını gösterir ve ağırlığın sıfır olması o ağ için en önemli olay olabilir. Ağırlıklar değişken veya sabit değerler olabilirler. Toplam fonksiyonu ise bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi kendi ağırlığı ile çarpılarak toplanır, böylece ağa gelen net bilgi bulunmuş olur. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş uygun bir formül yoktur, genellikle deneme yanılma yoluyla toplama fonksiyonu belirlenmektedir (Haykin, 2009).

Aktivasyon fonksiyonu işlem süresince hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. Genellikle aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur. Bazı modeller bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşmaktadır. Kullanılan aktivasyon fonksiyonu örneklerine ilerleyen bölümlerde değinilecektir. Hücrenin çıktısı ise aktivasyon fonksiyonu tarafından belirlenir ve üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendi hücreğine girdi olarak da gönderebilir. Her nöron istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir. Fakat bu bağlantı kopya edilebilir, yani bu tek çıkış birçok hücreyi besleyebilir (Gülez, 1999).


Yapay sinir ağı bir takım alt kümelerle ayrılabilir. Bu alt kümelerdeki elemanların transfer fonksiyonları aynıdır. Bu küçük gruplara katman (layer) adı verilir. Ağ, katmanların birbirine hiyerarşik bir şekilde bağlanmasından oluşmuştur (Gülez, 1999). Genel olarak hücreler üç katman halinde ve her katman içerisinde paralel olarak bir araya gelerek ağı oluştururlar. Bu katmanlar, girdi katmanı, ara katmanlar ve çıktı katmanıdır.

Dış dünyadan alınan bilgiler girdi katmanı ile taşınır. Bir transfer fonksiyonları yoktur. YSA transfer fonksiyonu ve yerel bellek elemanı, bir öğrenme kuralı ile giriş çıkış işareti arasındaki bağlantıya göre ayarlanır. Kısaca bir YSA'dan beklenen görev, gerçek dünyadaki nesneler ile biyolojik sinir ağının yaptığı işlevi benzer bir yolla yerine getirmesidir. YSA'nın giriş veri tipleri ikili (binary) 0-1 veya sürekli değerlerdir ve Şekil 3.9'daki gibi sınıflandırılırlar. Bu giriş durumlarından başka, işlem elemanına ait girişleri matematiksel olarak da sınıflamak gerekmektedir, çünkü bir işlem elemanına gelen girişlerin bir kısmı azaltıcı uyarma girişleri olmaktadır (Lippmann, 1987). Bazı ağlarda, girdi katmanında herhangi bir bilgi işleme olmaz. Girdi katmanından gelen bilgiler işlenerek çıktı katmanına gönderilirler.




Şekil 3.9 Sınıflandırıcı olarak kullanılabilen altı sinir ağının taksonomisi (Lippmann, 1987).

Girdi katmanından gelen bilgilerin işlenmesi ara katmanlarda gerçekleştirilir. Bir ağ için birden fazla ara katman olabilir. Çıktı katmanındaki süreç elemanları ise ara katmandan gelen bilgileri işleyerek ağın girdi katmanından sunulan girdi seti için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir. Şekil 3.10 bu üç katmanın birbirleri ile olan ilişkisini göstermektedir.



Şekil 3.10 Yapay sinir ağı katmanlarının birbirleri ile ilişkileri.

Şekil 3.11’de, şekil 3.10’da sözü geçen üç katmanın her birinde bulunan süreç elemanları ve katmanlar arası ilişkiler şematik olarak gösterilmektedir. Her bir katmanda birbirine paralel elemanlar yer almaktadır. Süreç elemanlarını birbirine bağlayan çizgiler ise ağın bağlantılarını göstermektedir. Süreç elemanları ve bağlantıları bir yapay sinir ağı oluştururlar. Bağlantıların ağırlık değerleri öğrenme sırasında belirlenmektedir.



Şekil 3.11 Bir yapay sinir ağı örneği (Fausett, 1994).

3.3.4 Aktivasyon fonksiyonları


Bölüm 3.3.3’ te sözü edildiği üzere aktivasyon fonksiyonları hücreye gelen girdiye karşılık üretilecek çıktıyı belirleyen fonksiyonlardır. Aktivasyon fonksiyonu olarak ağıın süreç elemanlarının hepsinin aynı fonksiyonu kullanmaları gerekmemesine rağmen, sıklıkla yapay sinir ağıının her katmanındaki tüm nöronlar için aynı aktivasyon fonksiyonu kullanılmaktadır (Fausett, 1994). Çoğu durumda, doğrusal olmayan (nonlinear) bir aktivasyon fonksiyonu kullanılır (Fausett, 1994). Bir problem için en uygun aktivasyon fonksiyonu ağ tasarımcısının denemeleri sonucunda belirleyebileceği fonksiyondur, uygun fonksiyonu gösteren bir formül bulunabilmiş değildir (Haykin, 2009).

Lippmann (1987), temel olarak üç çeşit aktivasyon fonksiyonu türü belirlemiştir:

1. Hard Limiter–Basamak Fonksiyonu (Hard Limiter–Step Functions)

Transfer veya işaret fonksiyonları olarak da adlandırılan hard-limiter fonksiyonları, muhtemel sonsuz domen girişli işlem elemanlarını önceden belirlenmiş sınırdaki çıkış olarak düzenler (Gülez, 1999). Yaygın olarak kullanılan

hard-limiter fonksiyonları, lineer, rampa ve basamak (step-hard limiter) fonksiyonlarıdır. Şekil 3.12’de bu fonksiyonların grafikleri gösterilmiştir.



Şekil 3.12 Sık kullanılan hard-limiter fonksiyonları: (a) rampa (b) lineer (c) basamak.

Aktivasyon fonksiyonu $\varphi(v)$ ile gösterilmek üzere;

$$\varphi(v) = \begin{cases} 1 & , v \geq 0 \\ 0 & , v < 0 \end{cases} \quad (3.6)$$

olarak verilir. Mühendislikte hard-limiter değer fonksiyonunun bu formu genellikle *Heaviside fonksiyonu* olarak adlandırılmaktadır (Haykin, 2009).

k. nöronun çıktısı hard-limiter değer fonksiyonuyla şu şekilde ifade edilir:

$$y_k = \begin{cases} 1 & , v_k \geq 0 \\ 0 & , v_k < 0 \end{cases} \quad (3.7)$$

Burada v_k nöronun uyarıldığı alandır; yani,

$$v_k = \sum_{j=1}^m w_k x_j + b_k \quad (3.8)$$

(3.8) numaralı fonksiyon, doğrusal bir fonksiyondur.

α işlem elemanının x aktivitesini ayarlayan reel değerli bir sabittir. Lineer fonksiyon $[-\tau, +\tau]$ sınırları arasında kısıtlandığında rampa hard-limiter fonksiyonu elde edilir ve denklem,

$$f(x) = \begin{cases} +\tau & , x \geq \tau \\ x & , |x| < \tau \\ -\tau & , x \leq -\tau \end{cases} \quad (3.9)$$


şeklini alır.

$+\tau$ ($-\tau$) işlem elemanının maksimumu (minimumu) doyma seviyesi olarak da adlandırılan çıkış değeridir. Eğer hard-limiter fonksiyonu bir giriş işaretine bağlı ise yaydığı $+\tau$ toplamı pozitif, değilse negatif değer alır. Başka bir deyişle, bu fonksiyon girdi örüntülerinin (input pattern) değerlerine göre ayrık (discrete) sonuç elde etmek için kullanılır; girdi ya $+1$ sonucu ya da -1 sonucu verir. Böylece kesin bir limit alması sağlanmış olur (Cinsdikici, 1994). Denklemi ise aşağıdaki şekildedir:

$$f(x) = \begin{cases} +\tau, & x > 0 \\ -\tau, & x \leq 0 \end{cases} \quad (3.10)$$

2. Threshold Fonksiyonları (Threshold Functions)

Eşik değeri (threshold) fonksiyonları, hard – limiter fonksiyonuna benzemekle beraber, girdi örüntüsünün toplam değerine belli bir eşik değerine kadar doğrusal (lineer) artan değerlerle cevap vermektedir. Üst limite (eşik değeri, threshold) ulaşıldığında ise cevap ayrık olarak kesinlik göstermektedir. Artan bir eğilim göstermez (Cinsdikici, 1994).




Şekil 3.13 Eşik (threshold) fonksiyonu.

3. Sigmoid Fonksiyonları (Sigmoid Functions)

S biçimindeki Sigmoid fonksiyonları, seviyeli, sınırlı monoton artan, girdi örüntüsüne devam eden, nonlinear ve süreklilik gösteren (continous) cevaplar üreten fonksiyonlardır. Cevaplar ayırık değildir. Bu sebeple sigmoid fonksiyonları yaygın bir kullanıma sahiptir çünkü hassas değerlendirmelerin kullanılacağı problemler için uygulanması en uygun olan fonksiyonu temsil etmektedir. Sigmoid fonksiyonu yerine yine süreklilik gösteren tanjant fonksiyonları ya da benzeri fonksiyonlar da kullanılabilir. Önemli olan fonksiyonun türevinin alınabilecek bir fonksiyon olmasıdır (Fausett, 1994). Sigmoid fonksiyonlarının denklemi şu şekildedir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.11)$$




Şekil 3.14 Sigmoid fonksiyonu.

3.3.5 Öğrenme stratejileri

Mimarinin yanı sıra ağırlık değerlerinin ayarlanması metodu yani öğrenme de farklı yapay sinir ağlarının ayırt edici ve önemli karakteristik bir özelliğidir. Fausett (1994), öğrenme sürecini “öğretmenli öğrenme (supervised training)” ve “öğretmensiz (kendi kendine) öğrenme (unsupervised-self training)” olmak üzere iki ana stratejiye ayırmıştır.

1. Öğretmenli Öğrenme (Supervised Training)


Öğretmenli öğrenme stratejisinde, sistemin olayı öğrenebilmesine bir öğretmen yardımcı olmaktadır. Öğretmen sisteme öğrenilmesi istenilen olay ile ilgili bilgiyi ve/veya örnekleri girdi-çıkı seti olarak verir. Diğer bir deyişle, her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme gösterilir. Sistemin görevi girdi ve çıktı değerleri arasındaki ilişkiye göre ağırlık aralıklarını ayarlamaktır. Bu tür öğrenmeyi gösteren bir blok diyagram Şekil 3.15’te gösterilmiştir:



Şekil 3.15 Öğretmenli öğrenme blok diagramı (Haykin, 2009).

Destekleyici Öğrenme (Reinforcement Training)

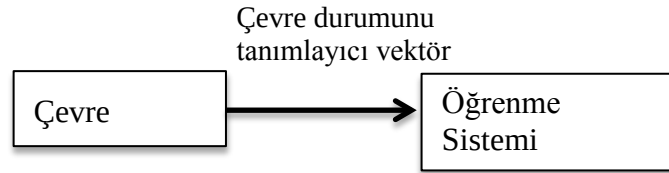
Destekleyici öğrenme stratejisinde de, sistemin öğrenmesine bir öğretmen yardımcı olur. Ancak destekleyici öğrenmenin standart öğretmenli öğrenmeden farkı, sisteme öğrenmesi istenilen olay ile ilgili örnek girdi/çıktı setinin verilmesi yerine, kendisine gönderilen girdilere karşılık bir çıktı üretilmesinin beklenmesi ve öğretmenin bu çıktının doğru ya da yanlış olduğunu belirten bir sinyal üretmesidir. Sistem, bu sinyalin sonucunu dikkate alarak öğrenmesini devam ettirmektedir. Bu tür öğrenmeyi gösteren blok diyagram Şekil 3.16'da gösterilmiştir.



Şekil 3.16 Destekleyici öğrenme blok diagramı (Haykin, 2009).

2. Öğretmensiz Öğrenme (Unsupervised Training)

Öğretmensiz (kendi kendine) öğrenme stratejisinde, sistemin olayı öğrenebilmesine yardımcı olan bir öğretmen yoktur. Bu tür öğrenme, yapay sinir ağının dışarıdan herhangi bir etki olmaksızın aldığı bilgileri kendi içerisinde kıyaslama yaparak sınıflandırması ile oluşan öğrenme sürecini belirtmektedir (Cinsdikici, 1994). Bu öğrenme metodunda, sisteme sadece girdi değerleri verilir ve örneklerle parametreler arasındaki ilişkiyi sistemin kendi kendine öğrenmesi beklenir. Bu strateji, daha çok sınıflandırma problemleri için kullanılan bir stratejidir. Kendi kendine öğrenmeye ait blok diyagram Şekil 3.17’de gösterilmiştir.




Şekil 3.17 Kendi kendine öğrenme blok diagramı (Haykin, 2009).

Yapay sinir ağlarında öğrenme, temel olarak bu iki ana öğrenme stratejilerinden biri veya hibrit olarak adlandırılan ve her iki metodun da kullanıldığı karma strateji kullanılarak gerçekleştirilmektedir. Ne tür öğrenme yöntemi kullanılırsa kullanılsın, herhangi bir ağ için gerekli karakteristik özellik, ağırlıkların verilen eğitime örneğine nasıl ayarlanacağını belirlenerek öğrenme kuralının oluşturulmasıdır. Öğrenme kuralının oluşturulması için bir örneğin ağa defalarca tanıtılması gerekebilir. Öğrenme kuralı ile ilişkili parametreler ağın zaman içinde gelişme kaydetmesiyle değişebilir.

3.3.6 Basit algılayıcılar (Perceptrons)

Yapay sinir ağlarının ilk bilinen modeli Hebb net modelidir (Fausett L., 1994). Hebb net modeline göre, eğer iki yapay sinir ağı hücresi aynı aktivasyonu gösteriyorsa, aralarındaki bağ kuvvetlenmelidir (Fausett L., 1994). Hebb net modelinden sonra ilk defa 1958 yılında Rosenblat tarafından ortaya atılan perceptron, lineer olarak ayrıştırılabilen (linearly seperable) şekillerin (örüntü - pattern) sınıflandırılması amacıyla kullanılan yapay sinir ağının en basit halidir. Temel olarak, ayarlanabilir sinaptik ağırlıklı ve biastan oluşan tek bir sinir

hücresidir. Perceptron modelinde en önemli faktör eşik değeridir. Saptanacak olan eşik değeri problemin karakteristiğine göre belirlenebilir. Model temelde kendine “hard limiter” tipindeki eşikleme fonksiyonunu referans olarak kabul etmektedir (Cinsdikici, 1994).



Şekil 3.18 Perceptron sinyal akış grafiği (Haykin, 2009).

3.3.7 Çok katmanlı algılayıcılar (Multi layer perceptrons)


Çok katmanlı algılayıcılar (MLP), giriş ve çıkış düğümleri arasında bir veya birden fazla katmandan oluşan, birçok perceptronun bir arada kullanılmasıyla oluşturulan ileri beslemeli yapıda ağlardır (Lipmann, 1987). Bölüm 3.3.6’da bahsedilen basit algılayıcı modeli olan perceptronlar, yalnızca doğrusal sınıflandırma yapabilmektedirler. Oysaki, gerçek hayatta birçok problem doğrusal olmayan yapıdadır. Çok katmanlı algılayıcılar, ağ yapısı itibariyle yapay sinir ağları içerisinde hemen hemen her probleme rahatlıkla uygulanabilir bir modeli oluşturmaktadır (Cinsdikici, 1994).

3.3.8 Radyal tabanlı fonksiyon ağları (Radial basis function)

Radyal tabanlı fonksiyonlar (RBF) ilk defa çok değişkenli bir interpolasyon probleminin çözümünde kullanılmıştır. Bu konudaki ilk çalışma Powell (1985) tarafından yapılmıştır. Broomhead ve Lowe (1988) RBF’yi sinir ağları içerisinde kullanan ilk kişilerdir. Moody ve Darken (1988), Renals (1989), Poggio ve Girosi (1990) ise bu alana katkı sağlayan diğer önemli isimlerdir.

Radyal fonksiyon tabanlı sinir ağları, çok katmanlı algılayıcıların özel bir halidir. Radyal tabanlı fonksiyon ağlarının iki karakteristik özelliği vardır. İlki, çok katmanlı algılayıcıların aksine tek bir gizli katman bulundurması, diğeri ise, gizli katman nöronlarında aktivasyon fonksiyonu olarak radyal tabanlı fonksiyonların kullanılmasıdır. Ağ mimarisinin basitliği nedeniyle çok katmanlı


sinir ağı modellerine göre birçok avantajı vardır. Bu avantajlardan başlıcası, diğer geri yayılım algoritmalarına göre daha hızlı eğitilebilmeleridir.



Şekil 3.19 RBF Mimarisi.

Şekil 3.19’da görüldüğü gibi, RBF ağına yapısı üç farklı katmandan oluşmaktadır. Bu basit yapı, yüksek dereceden doğrusal olmayan yapıdaki örüntüleri bile sınıflandırabilecek şekilde yapılandırılabilir. RBF ağına bu özelliğinin temeli Cover’ın örüntülerin ayrılabilirliği üzerine attığı teoreme dayanmaktadır (Haykin, 2009).

Cover Teoremi: Karmaşık yapıdaki örüntü sınıflandırma problemleri, doğrusal olmayan dönüşümlerle yüksek boyutlu uzaya taşındıklarında, düşük boyutlu uzaylarda yapılan çözümlere göre daha yüksek doğrusal ayrıştırılabilirliğe sahiptir (Cover, 1965).



Şekil 3.20 Boyut Yükseltme ile Lineer Ayrıştırılabilirlik.

Cover teoremi gereğince RBF ağı, doğrusal olmayan dönüşümler ile girdi uzayının içerdiği karmaşık yapıdaki, diğer bir ifadeyle yüksek dereceden doğrusal olmayan yapıdaki örüntülerin lineer ayrıştırılabilir hale getirdikten sonra doğrusal modeller ile problemin çözmektedir (Şekil 3.20). Bu yapı içerisinde radyal tabanlı fonksiyonun görevi, girdi uzayını yüksek boyutlu uzaya taşımaktır. Ağırlık parametreleri ise lineer ayırma yüzeyine karşılık gelmektedir.


Radyal tabanlı fonksiyon ağlarındaki ilk katman olan girdi katmanı, n boyutlu X vektöründen oluşmaktadır. Bu katmanda, girdi işlenmeden gizli katman nöronlarına iletilir. Diğer bir deyişle, girdi katmanı ve gizli katman arasındaki tüm ağırlık değerlerinin “1” olduğu varsayılır; bu sayede öğrenme sırasında değiştirilecek parametre sayısında önemli bir azalış gerçekleşir ve öğrenme hızlanır.

İkinci katman olan gizli katmanda her bir nöron, matematiksel olarak bir radyal tabanlı fonksiyon ile belirlenmektedir. Radyal fonksiyon, değeri yalnızca orijine ya da bir merkeze olan uzaklığa bağlı reel değerli bir fonksiyondur. $\phi(x) = \phi(|x|)$ veya $\phi(x, c) = \phi(|x - c|)$ özelliğini sağlayan her ϕ fonksiyonu radyal fonksiyondur. Radyal fonksiyonların karakteristik özelliği, fonksiyonun değerinin merkez bir noktaya olan uzaklığı ile monoton olarak artması ya da azalmasıdır. Farklı uzaklık fonksiyonlarının kullanılması mümkün olmakla beraber, en yaygın olarak kullanılan, öklit (Euclidean) uzaklık metriğidir. RBF ağında, gizli katman aktivasyon fonksiyonu genellikle öklit uzaklıklarını üstel fonksiyondan geçiren Gauss fonksiyonudur ve aşağıdaki gibi tanımlanmaktadır.

$$\begin{aligned}\phi(x) &= \phi(x - c_i) \\ &= \exp \left[-\frac{\|x - c_i\|^2}{2\sigma_i^2} \right]\end{aligned}\quad (3.12)$$

Burada, x giriş vektörü, c_i ise merkez vektörüdür.

Şekil 3.21’de, (3.12) denklemi ile tanımlanan Gauss fonksiyonu gösterilmiştir. Fonksiyon, merkez (c) ve varyans (σ) olmak üzere iki parametre belirler. (3.12) denkleminde de görüldüğü gibi, varyans arttıkça eğri yayvanlaşmakta ve fonksiyonun sayısal olarak duyarlı olduğu alan genişlemektedir. Varyans parametresi ile alt uzayların ne şekilde büyüyüp küçülebileceği hakkında yorum yapmak mümkün olabilmektedir.



Şekil 3.21 Gauss Fonksiyonu (Wikipedia, 2012).

Diğer radyal tabanlı fonksiyonlar aşağıda yer almaktadır. Chen et al. 1991 yılındaki çalışmasında, RBF seçiminin ağın performansı üzerinde önemli bir etkisinin olmadığını belirtmişlerdir. Bu tez kapsamında da, RBF ağında aktivasyon fonksiyonu olarak Gauss fonksiyonu kullanıldığından dolayı, diğer fonksiyonların ayrıntılarına yer verilmemiştir.

$x = ||x - c_i||$ olmak üzere;

Çoklu Quadratik RBF (Multi Quadratic RBF): $\phi(x) = \sqrt{1 + (\epsilon x)^2}$

Ters Çoklu Quadratik RBF (Inverse Multi Quadratic RBF): $\phi(x) = \frac{1}{\sqrt{1 + (\epsilon x)^2}}$

Ters Quadratik RBF (Inverse Quadratic RBF): $\phi(x) = \frac{1}{1 + (\epsilon x)^2}$

Çoklu Harmonik Spline (PolyHarmonic Spline): $\phi(x) = x^k, k = 1, 3, 5, \dots$

$$\phi(x) = x^k (\ln x), k = 2, 4, 6, \dots$$

Üçüncü katman olan çıktı katmanı, her ne kadar Şekil 3.17'deki RBF yapısında tek çıkış olarak gösterilmişse de, bu konuda herhangi bir kısıtlama bulunmamaktadır. Ancak, açıkça görülmektedir ki, çıktı katmanının boyutu, gizli katmanın boyutundan çok daha küçük olmalıdır (Haykin, 2009).

Şekil 3.12’de gösterilen RBF yapısı göz önüne alındığında, her bir nöronun çıktı değeri aşağıda verilen (3.13) numaralı denklem kullanılarak hesaplanmakta ve bu çıktı değerlerinin (3.14) denklemindeki ağırlıklı toplam içerisinde kullanılmasıyla ağ cevabı bulunmaktadır.

$$çıktı = \prod_{i=1}^m \psi(x_i, c_i, \sigma_i) \quad (3.13)$$

$$y = \sum_{i=1}^K w_i o_i = \sum_{i=1}^K [w_i \prod_{j=1}^m \psi(x_j, c_{ij}, \sigma_{ij})] \quad (3.14)$$

(3.14) numaralı denklemden de anlaşılacağı gibi, RBF ağının başarısındaki en önemli etken, uygun radyal tabanlı fonksiyonun seçilmesidir.

4. ÖNERİLEN YÖNTEM

Bu bölümde, tez çalışması dahilinde izlenen yöntem detaylı bir şekilde anlatılacaktır. Çalışma kapsamında, yeni bir yöntem olarak Bulanık Mantık ve Bulanık Radyal Tabanlı Fonksiyon Sinir Ağları (Fuzzy radial Basis Function Neural Network – FRBFNN) kullanılarak retina damarlarında tipik nokta tespiti amaçlanmaktadır.

4.1 Veri Seti

Çalışma kapsamında üzerinde çalışılan tüm retina görüntüleri DRIVE (Digital Retinal Images for Vessel Extraction, Staal et al., (2004)) veritabanından alınmış görüntülerdir. DRIVE, 20 adet eğitim (train) ve 20 adet de test görüntü setlerinden oluşan toplam 40 adet retina görüntüsü içeren kullanıma açık bir veritabanıdır. Veritabanındaki görüntüler, 565 x 584 piksel boyutlarında ve yaklaşık 540 piksel çapında yuvarlak yapıdaki retina görüntüleridir. DRIVE veritabanı, renkli RGB (red-green-blue) retina görüntülerinin yanı sıra, renkli retina görüntülerinden damar çıkarsanmasına yönelik çalışmaların performans ölçümlerinde kullanılan uzmanlar tarafından el ile çizilmiş altın standart (gold standart) ikili (binary) retina görüntü setlerini de içermektedir. Gold standart görüntüler üzerinde, eğitim seti için toplam 2440, test seti için toplam 2590 adet tipik nokta (Point of Interest – POI) işaretlenmiştir. Yöntem, ayrıca Niemeijer et al.’un (2011) çalışmasında kullanılan, eğitim seti için toplam 875 adet, test seti için ise toplam 905 adet POI ye de uygulanmıştır.


4.2 Yöntem

Yöntem, DRIVE veritabanındaki eğitim seti içerisindeki verilerin eğitim aşamasıyla başlamaktadır. Eğitim aşamasında, tüm eğitim seti içerisindeki görüntüler üzerindeki bilinen POI’lerden öznitelik çıkarsanması yapılmaktadır. Öznitelik çıkarsanmasının ayrıntıları Bölüm 4.2.2’de anlatılacaktır. Bunun ardından, çıkarsanan öznitelik vektörleri bulanık radyal tabanlı fonksiyon sinir ağına girdi olarak verilmekte ve ağ eğitilmektedir. Son olarak eğitilen ağ, daha önce görmediği görüntüler olan DRIVE veritabanındaki test görüntüleri üzerinde test edilmekte ve görüntüler üzerinde tipik noktalar tespit edilmektedir.

4.2.1 Önişleme (Preprocess)


Retina görüntülerinde tipik nokta tespiti yapılmadan önce, retina görüntülerinin bir takım önişlemlerden geçirilerek, görüntülerin işlenmeye uygun hale getirilmesi gerekmektedir. Retina görüntülerinin elde edilmesi sırasında damarlarda meydana gelen değişimlerin dışında, dış etkilere de kaynaklanan gürültüler, eşit olmayan aydınlatmalar gibi etkiler söz konusudur. Bu çalışmada, bu gibi etkileri gözardı edebilmek ve işlem karmaşıklığını azaltmak için ikili seviye (binary-level) görüntü üzerinde çalışılmıştır. Her ne kadar ikili görüntü üzerinde çalışılıyor olsa da, yine de görüntüler işlenmeye tam olarak hazır değildir. Retina damarlarında tipik noktaların çıkarsanmasından önce retina damarlarının sağlıklı bir şekilde çıkarılması gerekmektedir. Damar çıkarsama için literatürde farklı yöntemler yer almaktadır. Damar izleme (vessel tracking), matematiksel biçim (mathematical morphology), eşleme süzgeci (matched filtering), uyarlanabilir eşikleme (adaptive thresholding) ve piksel sınıflandırma (pixel classification) gibi yöntemler uygulanarak retina damarları elde edilebilmektedir. Chaudhuri et al. (1989), Chutape et al. (1998), Tolias and Panas (1998), Gagnon et al. (2001), Walter and Klein (2001), Jiang and Mojon (2003), Mendoza and Campilho (2006), Chanwimaluang and Fan (2003) ve Cinsdikici and Aydın'ın (2009) çalışmaları, damar çıkarsama konusundaki yöntemlerin ayrıntıları hakkında incelenebilir. Damar çıkarsama, ayrı bir araştırma konusu olduğu için bu tez kapsamında yer almamaktadır. Önerilen yöntem, DRIVE veritabanı içerisindeki altın standart damar görüntüleri üzerinden yapılmaktadır.

Önişleme adımında öncelikle, optik disk bölgesinin çok karmaşık olduğu ve görüntü üzerinde tipik noktaların istenilen şekilde yer almadığı görüntüler değerlendirme dışı bırakılmıştır. Çıkarılan görüntüler Şekil 4.1'de gösterilmiştir. Bu görüntülere ait hiçbir nokta, yöntem adımlarının herhangi birinde kullanılmamıştır.



Şekil 4.1 Değerlendirme dışı bırakılan retina görüntüleri
(a) 4 nolu test görüntüsü (b) 23 nolu eğitim görüntüsü.

Optik disk bölgesinin yapısının göstereceği değişiklik retina görüntüsü üzerindeki diğer damarların göstereceği değişiklikten çok daha az olacağı için bu bölgeler ilgi alanı (Area-of-Interest) dışında tutulmuştur. Optik diskin yer aldığı bölgeler, görüntülerin boyutları değiştirilmeden görüntüden çıkarılmışlardır. Çıkarılacak optik disk bölgesini gösteren bir retina görüntüsü Şekil 4.2’de gösterilmiştir.



Şekil 4.2 Optik disk bölgesi çıkarılacak örnek bir retina görüntüsü.

Önişleme adımı olarak uygulanan işlemde, koordinat değerleri verilen noktalar retina görüntüleri üzerinde işaretlenmiş ve doğru yerdeki noktaları gösterip göstermediklerini test edilmiştir. Bu sırada, herhangi bir tipik noktayı

ve/veya damarı göstermediği tespit edilen noktalar değerlendirme dışı bırakılmıştır. Optik disk bölgesinde yer alan ve hatalı işaretlenmiş olan noktaların çıkarılmasının ardından eğitim seti için toplam 2197 adet POI üzerinde çalışılmıştır.


Bir diğer önışleme adımı, bu aşamaya gelen görüntülerden damar ağacı iskeletinin çıkarılması işlemidir. Elde edilen retina damar görüntüleri inceltme (thinning) işlemi ile bir piksel kalınlığa düşürülerek damar ağacı iskeleti elde edilir. Bu işlemin ardından elde edilen bir piksel genişliğindeki damar görüntüsü damar orta çizgisidir (vessel centerline). İnceltme işlemi için ikili görüntüler üzerinde morfolojik değişiklikler yapan MatLab içerisindeki hazır *bwmorph* komutu kullanılmıştır.

```
>> I_Thin = bwmorph(I, 'thin', Inf); %I, inceltme işlemi
uygulanacak olan görüntüdür.
```

4.2.2 Öznitelik çıkarımı (Feature extraction)

Bu aşamada, önışlemden geçmiş retina damar görüntüleri üzerinde işaretlenmiş olan noktalardan tipik noktaları temsil eden öznitelik vektörleri çıkarılmaktadır. Önemli özniteliklerin seçilmesi, kullanılan sınıflandırma algoritmalarının hızlı çalışmasını, zaman kazancını ve gereksiz yere kullanılmamasını sağlayacaktır. Öznitelik seçilmesi sonucu boyutu azalan veri ideal olarak, yüksek ayırım gücü ve yüksek güvenilirliğe sahip esas bilgiyi korumalıdır. Bu boyut azalması literatürde “curse of dimesionality” (Jain et al., 2000) olarak bilinen “boyutun laneti” sorununu da hafifletebilir. Böylelikle iyi performanslı, daha basit ve anlaşılabilir sınıflandırma modellerinin oluşması sağlanır.

Önerilen yöntemde öznitelik vektörlerinin çıkarılması için, her bir işaretli nokta merkez alınacak şekilde r_1 ve r_2 yarıçaplı iç içe çemberler çizilmektedir (Niemeijer et al., 2011).




Şekil 4.3 Öznitelik vektörü çıkarılmasında kullanılan şablon.

Uygulanan bu şablonda, yarıçapların büyüklüğü görüntünün boyutuna direkt olarak bağlıdır. Bu şablonun uygulandığı DRIVE veritabanındaki tüm görüntüler aynı boyuttadır ve bu görüntüler için en optimal değerler $r_1 = 3$ ve $r_2 = 6$ olarak ölçülmüştür (Niemeijer et al., 2011). Öznitelik çıkarılmasında, merkez alınan her bir POI etrafına bu çemberler çizilmiş ve buradan 6 adet öznitelik çıkarılmıştır. Çıkarılan öznitelik vektörlerine ait sınıflandırmalar Çizelge 4.1’de gösterilmektedir.


Çizelge 4.1 Öznitelik Vektörleri.

No	Vektörler	Öznitelik Tanımı
1	IMD	Damarların iç çemberi kestiği noktaların uzaklıklarının ortalaması
2	OMD	Damarların dış çemberi kestiği noktaların uzaklıklarının ortalaması
3	ISD	Damarların iç çemberi kestiği noktaların uzaklıklarının standart sapması
4	OSD	Damarların dış çemberi kestiği noktaların uzaklıklarının standart sapması
5	ICN	Damarların iç çemberi kestiği nokta sayısı
6	OCN	Damarların dış çemberi kestiği nokta sayısı

Öznitelik vektörlerinin çıkarılması sırasında elde edilen örnek bir retina görüntüsü şekil 4.4 ve 4.5’te verilmiştir.



Şekil 4. 4 Öz nitelik vektörü çıkarılan noktalar.



Şekil 4.5 Öz nitelik vektörü çıkarılacak olan noktaların ayrıntılı görüntüsü.

Öznitelik şablonunun çizilirken, çember koordinatlarının damarları kestiği noktaları kaçırmaması için çemberler 3000 nokta sıklığında çizilmiştir. Damarlar ile çemberlerin kesişim koordinatları bulunduktan sonra, eğitim setine ait toplam 2377 adet noktanın Çizelge 4.1'e göre öznitelik vektörleri çıkarılmıştır. Ardından, çıkarılan $[2377 \times 6]$ boyutlu öznitelik matrisi normalize edilerek bulanık radyal tabanlı fonksiyon sinir ağına beslenmeye hazır hale getirilmiştir.

Bunun yanı sıra, retina görüntüsü verildiğinde ağın tipik nokta olmayan damar bölgelerini de öğrenmesi gerekmektedir. Bunun için, her bir eğitim görüntüsü üzerinde, tipik nokta içermeyen damar bölgerinden rastgele alınan bölgeler üzerinde de öznitelik çıkarsaması yapılmış ve tüm eğitim verileri aynı set içerisinde toplanıp karıştırılarak radyal tabanlı fonksiyon sinir ağına verilmiştir.

4.2.3 Bulanık radyal tabanlı fonksiyon yapay sinir ağı ile tipik nokta tespiti

Bu bölüm, geometrik tabanlı yaklaşım metodunun son basamağı olan analiz bölümüdür. Bu kısımda, önişlemden geçirilen ve öznitelik vektörleri çıkarılan görüntüler radyal tabanlı fonksiyon sinir ağları ile sınıflandırılırlar.

4.2.3.1 Bulanık radyal tabanlı fonksiyon ağları (Fuzzy RBFN)

Bulanık radyal tabanlı fonksiyon ağları (FRBF), RBF ağları ile bulanık c-ortalama (FCM) algoritmasının özelliklerinin bir araya getirilmesi ile oluşturulmuş yapay sinir ağlarıdır. FRBF ağı, bulanık girişlerden ve/veya bulanık çıktılarından ve/veya bulanık ağırlıklardan meydana gelmektedir (Mitra and Basak, 2001).¹ Ağ; girdi, gizli ve çıkış katmanları olmak üzere üç katmanlı mimariden oluşmaktadır.

İlk katman olan girdi katmanında, her bir X_j öznitelik vektörü, düşük orta ve yüksek olarak nitelendirilebilecek dilbilimsel (linguistic) özellikler cinsinden modellenir. n-boyutlu bir $X_i = [x_{i1}, x_{i2}, \dots, x_{in}]$ vektörü 3n-boyutlu vektör olarak aşağıdaki şekilde gösterilebilir.

$$[x_1, x_2, \dots, x_{3n}] = [\mu_{low(x_{i1})}(\bar{x}_i), \dots, \mu_{high(x_{in})}(\bar{x}_i)]$$


¹ Bu bölümde Mitra S., and Basak J., "FRBF: A Fuzzy Radial Basis Function Network", 2001 çalışmasından geniş ölçüde yararlanılmıştır.

Model hem dilbilimsel hem de sayısal (numeric) girdileri işleyebilir ve çıktıda çakışan örüntü sınıfları olması durumunda daha yumuşak bir karar verilmesini sağlayabilir. Gizli katmanda bulanık c-ortalama algoritmasının kullanımı, bir örüntünün iki ya da daha fazla sınıfın sıfırdan farklı üyeliğe sahip olabileceği gerçek-hayat durumlarını daha doğru göstermesini sağlayabilir. Optimum küme (cluster) sayılarının, diğer bir deyişle gizli katmandaki nöron sayılarının belirlenmesinde David-Bouldin, Hubert's istatistik, Fukuyama-Sugeno, Xie-Beni indeksleri gibi küme geçerlilik indeksleri kullanılmaktadır. Çıktı ise, üyelik derecesi olarak ifade edilir.

Girdi ve gizli katman arasındaki ağırlıklar, daha çok bilinen hard c-means (k-means) yerine bulanık c-ortalama algoritması kullanılarak küme merkezleri tarafından ilklendirilir. Bilinen RBF mimarisinde, girdi vektörü küme merkezindeki hiçbir örüntüyle eşleşmese bile gizli katmandaki nöronun sıfır olmayan bir cevap üretmesine izin verilen Gauss dağılım fonksiyonu kullanılmaktadır. FRBF ağında amaç, gizli katmanda bir örüntüyle eşleşmediği takdirde sıfır cevap üretilmesine izin verilen bulanık bir bölümlleme (fuzzy partitioning) oluşturmaktır. Bu bulanık bölümlleme bulanık c-ortalama algoritmasının üyelik fonksiyonu ile (4.1) hesaplanır. Ancak, fonksiyonun yapısı gereğince, bir örüntünün bir kümeye olan uzaklığı, mevcut tüm kümelere olan uzaklığına da bağlıdır.

$$u_{kj} = \frac{1}{\sum_{i=1}^c \left(\frac{d_{kj}}{d_{ij}} \right)^{2/m-1}} \quad (4.1)$$

Bu nedenle, eğer FRBF'nin yapısı RBF yapısıyla aynı olsaydı, bir örüntünün bulanık üyelik değerlerini (fuzzy membership values) yerel olarak hesaplayabilmek mümkün olamayacaktı. FRBF ağının mimarisi Şekil 4.6'da gösterilmektedir.



Sekil 4.6 FRBF Mimarisi.

Şekil 4.6’da görüldüğü gibi, FRBF mimarisinde yeni bir H nöronu göze çarpmaktadır. Bu yardımcı H nöronu, gizli katmandaki toplam aktivasyonu, çıktı katmanına beslemede kullanılır. Gizli katman nöronları ile H nöronu arasındaki tüm ağırlıklar tek değer olarak belirlenir.

FRBF ağı mimarisine eklenen yardımcı H nöronunun ağ üzerindeki etkisinin hesaplanabilmesi için, (3.14) numaralı denklem aşağıdaki şekilde yeniden yazılabilir.

$$h_i^{(j)} = \left(\frac{1}{d_{ij}}\right)^{2/m-1} \quad (4.2)$$

olmak üzere,

$$u_{kj} = \frac{h_k^{(j)}}{\sum_{i=1}^c h_i^{(j)}} \quad (4.3)$$

$$y_i^{(p)} = \sum_{j=1}^c w_{ij} \cdot u_{jp} \quad (4.4)$$

(4.4)) denklemi ile çıktı katmanındaki her nöronun aktivasyonu belirlenmektedir. Bu denklemde u_{jp} yerine (4.3) denklemi yerleştirildiğinde, denklem aşağıdaki hale dönüşür.

$$y_i^{(p)} = \frac{1}{H_a^{(p)}} \sum_{j=1}^c w_{ij} \cdot h_j^{(p)} \quad (4.5)$$

Burada,


$$H_a^{(p)} = \sum_{i=1}^c h_i^{(p)} \quad (4.6)$$

dir.

H ile, gizli katmandaki her bir nöronun çıktı üzerine etkisi yerel olarak bulunabilmektedir.

Açıkça görülebilir ki, bulanık c-ortalama tabanlı RBF ağı ile FRBF ağı mimarisi aynı değildir. Kim et al. (2005) ve Ziyang et al.'un (2008) çalışmalarında belirtildiği üzere, fuzzy c-means tabanlı RBF ağı yapısında, RBF mimarisinde bir değişiklik yapılmadan gizli katmandaki küme merkezleri FCM algoritması ile belirlenmektedir. Ziyang et al. (2008), Kim et al.'un (2005) yöntemine ek olarak karınca kolonisi optimizasyonu (Ant Colony Optimization-ACO) kullanarak yapıyı iyileştirmeye çalışmıştır.

Şekil 4.7'de önerilen yönteme ait mimari yer almaktadır. Önerilen yönteme ait FRBF ağı mimarisinde 6 boyutlu girdi vektörü, 12 adet gizli katman nöronu (merkez vektörü) ve ikili sınıflandırma yapan tek boyutlu çıktı vektörü bulunmaktadır.



Sekil 4.7 Önerilen yönteme ait FRBF Mimarisi.

Bu mimaride elde edilen girdi vektör boyutu öznelilik vektörleri çıkarsaması sonucu elde edilmiştir.

Yöntemin işleyişinde, bulanık radyal tabanlı fonksiyon ağının eğitimi iki aşamadan oluşmaktadır. İlk aşama, gizli katmandaki merkez vektörler (gizli katman nöron sayısı) ile bunların yayılım parametrelerinin bulunması, ikinci aşama ise gizli katman ile çıktı arasındaki ağırlıkların bulunmasıdır. Merkez vektörlerinin seçimi için literatürde farklı yaklaşımlar ortaya atılmıştır. Merkez vektörler veri seti içerisinde manuel olarak, veri seti içerisinde rastgele (randomly) ya da veri setinin uygun yapıda sınıflandırılması ile seçilebilirler.

Önerilen yöntemde, ağırlıklar en küçük ortalama kareler metodu (Least Mean Square – LMS) ile merkez vektörlerin seçimi ise bulanık c-ortalama algoritması ile yapılmıştır.

4.2.3.2 Bulanık c-ortalama algoritması (Fuzzy c-means algorithm)

Bulanık c-ortalama (Fuzzy c-Means - FCM) algoritması bulanık kümeleme algoritmalarının içerisinde en çok bilineni ve en sıklıkla kullanılanıdır. FCM, 1974 yılında Dunn tarafından ortaya atılmış ve 1981 yılında Bezdek tarafından geliştirilmiş ve bulanıklık katsayısı eklenmiştir. FCM, Dunn ve Bezdek tarafından denklem (4.7a)'da tanımlanan amaç fonksiyonunu minimize etmeyi amaçlamaktadır.

$$J_m = \sum_{i=1}^N \sum_{j=1}^c u_{ij}^m \|x_i - c_j\|^2, 1 \leq m < \infty \quad (4.7a)$$

Burada,

m : kümelerin bulanıklık derecelerini belirleyen parametreyi,

u_{ij} : i. elemanın j. kümeye ait üyelik derecesini,

c_j : j. kümenin merkezini,

x_i : d-boyutlu verinin i. elemanını,

$\| \cdot \|$: x_i ile c_j arasındaki normu (uzaklığı),

c : küme sayısını,

N : veri sayısını

göstermektedir.

$U = [u_{ij}] \in \mathbb{R}^{c \times n}$ olmak üzere, u_{ij} , c_j kümesindeki x_i elemanının üyelik derecesidir. u_{ij} 0 ile 1 arasında bir değerdir ve veri setindeki elemanların her bir kümeye olan üyelik dereceleri toplamı $U = \sum [u_{ij}] = 1$ dir.

$$C = [c_1, c_2, \dots, c_c], c_i \in \mathbb{R}^n \quad (4.7b)$$

ise küme merkezlerinin bir vektörüdür. x_i ile c_j arasındaki uzaklık,

$$d_{ij} = \left\| x_i - c_j \right\|^2 = (x_i - c_j)^T (x_i - c_j) \quad (4.7c)$$

iç-çarpım uzaklık normu (öklit uzaklığı – euclidean distance) ile hesaplanır.

Algoritma U üyelik matrisinin rastgele atanması ile başlatılır. Ardından U matrisi, üyelik derecelerinin toplamı 1.0 olacak şekilde normalize edilir. U matrisinin hesaplanması (4.8) numaralı denklem ile yapılmaktadır.

$$U = \frac{1}{\sum_{k=1}^c \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{2/m-1}}, U = [u_{ij}] \in \mathbb{R}^{c \times n} \quad (4.8)$$

c_i küme merkezleri ise,

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m}, 1 \leq j \leq N \quad (4.9)$$

denklemini ile hesaplanmaktadır.

Bulanık c-ortalama algoritmasının genel işleyişi aşağıda verilmiştir.

1. $U = [u_{ij}]$ üyelik matrisini (rastgele olarak - random), c küme sayısını, m bulanıklık katsayısını, i iterasyon sayısını, ε hata değerini belirle.
2. c_j küme merkezlerini denklem (4.9) ile hesapla.
3. Her bir x_i elemanı için c_j . küme merkezine olan uzaklığı hesapla.
4. k . adım için denklem (4.8)'e göre $U_k = [u_{ij}]$ yi ve denklem (4.9)'a göre $C_k = c_j$ yi güncelle.
5. k . üyelik değerleri ve küme merkez değerleri için denklem (4.7a)'ya göre J_m^k amaç fonksiyonunu hesapla.
6. $|J_m^k - J_m^{k-1}| < \varepsilon$ ise DUR. Aksi halde adım 4'e dön.

Kural olarak, $m=1$ değeri için, bulanık c-ortalama algoritması, üyelik değerlerinin yalnızca 0 veya 1 olarak belirlendiği k-means algoritmasına dönüşür. Her veri, aralarında en küçük uzaklık olan kümeye atanır. Ancak, bulanık c-ortalama algoritmasında $m=1$ değeri alamaz çünkü bu değer için (4.8) numaralı denklemde sıfıra bölme hatası gerçekleşir.

Deneyim veya alan bilgisi eksikliğinde m değeri genellikle 2 olarak belirlenmektedir (Bezdek, J., 1973). m 'nin çok büyük değerleri, daha küçük üyelik değerlerine sebep olmaktadır. u_{ij} 'nin belirttiği üyelik değerleri, küme merkezine olan uzaklık ile ters orantılıdır ve en yakın kümeye ne kadar ağırlık verileceğini m bulanıklık katsayısı belirlemektedir.

FCM'in avantajlarından biri, yalınlığının düşük işlem zamanı sağlamasıdır. Pratikte, birkaç iterasyon adımı, sonuç çözüme iyi yaklaşım sağlar, bundan dolayı 5 adımda gerçekleşen FCM, daha ileri teknikler için bir ilkleme adımı olarak çalışabilir (Höppner et al., 1999). Ancak, (4.7a) fonksiyonel denklemi, rastgele bir ilkleme adımıyla hesaplandığı için bir yerel minimum değerine yakınsayabilir. Dolayısıyla farklı ilk değerler farklı sonuçlar döndürecektir.

4.2.3.3 Küme geçerlilik indeksleri (Cluster validity index)

Kümeleme probleminde, oluşturulan kümelerin sayısı en önemli parametreyi oluşturmaktadır, yani bir anlamda diğer parametrelerin sonuç üzerinde küme sayısına oranla daha az bir etkisi vardır (Valentini G., 2005). Bu problem literatürde küme geçerliliği olarak bilinmektedir.

Küme geçerliliği problemi, algoritma ile bulunan bölünmenin doğruluğunu belirlemek için kullanılmaktadır. Bu kriter ile, en uygun küme sayısının belirlenmesinin yanı sıra veri setinin herhangi bir doğal gruplama yapısına sahip olup olmadığı da test edilmektedir. Fakat yine de, küme geçerlilik indekslerinin temel amacı en uygun küme sayısının belirlenmesidir.

Literatürde farklı birçok geçerlilik indeksi yer almaktadır. FCM algoritması ile ilişkili ilk geçerlilik indeksi Bezdek (1974a) tarafından ortaya atılan “*bölünme katsayısı*” (partition coefficient) dır. Bu fonksiyon, $U = \{u_1, u_2, \dots, u_c\}$ bulanık bölünmesinin, klasik bölünmeye ne kadar yakın olduğunu, diğer bir deyişle bulanık bölünmenin kalitesini veya bulanık olmama ölçüsünü ölçmektedir.

$$PC(c) = \frac{1}{n} \sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 \quad (4.10)$$

Burada, $\frac{1}{n} \leq PC(c) \leq 1$ dir. Genel olarak, c^* optimal küme sayısı $PC(c)$ nin maksimum değeri için en iyi performansı gösterir. Ancak, en iyi bölünme her zaman en yüksek bölünme katsayısı ile seçilmeyebilir. Bunun için “*bölünme entropisi*” (partition entropy) kullanılabilir.

Bezdek’in (1974b, 1975) önerdiği bölünme entropisi yöntemiyle, bir bulanık bölünmenin ne kadar bulanık olduğu ölçülebilmektedir. Bölünme entropisi,

$$PE(c) = -\frac{1}{n} \sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 \log_2 u_{ij}^2 \quad (4.11)$$

olarak hesaplanmaktadır. Burada $0 \leq PC(c) \leq \log_2 c$ dir. Bu yöntemde bölünme katsayısının aksine, en iyi küme $PC(c)$ nin minimum değeri için belirlenir. Diğer bir deyişle entropi sıfıra ne kadar yakınsa, küme o kadar iyi demektir. Öte yandan, entropinin ortalama değeri küme sayısı ile artmaktadır. Bunun anlamı, entropinin verideki yapıdan bağımsız olarak küme sayısı ile artacağıdır.

Bir diğer geçerlilik fonksiyonu da Dunn (1974)'un tanımladığı ayrılma indeksi (seperation index) dir. Dunn'un klasik kümeler için tanımladığı bu indeksi, Lazzerini ve Jain 2000 yılında kümeler arasındaki uzaklık kavramını kullanarak bulanık kümeler için genelleştirmişlerdir. Çoğunlukla bu indeks, küresel veya elipsoid şekli gösteren bulanık bölünmeler için kullanılmaktadır.

$$DI(c) = \min_{i \in C} \left\{ \min_{j \in C, j \neq i} \left\{ \frac{\delta(A_i, A_j)}{\max(\Delta(A_k))} \right\} \right\} \quad (4.12)$$

Burada,

$$\delta(A_i, A_j) = \min\{d(x_i, x_j | x_i \in A_i, x_j \in A_j)\}$$

$$\Delta(A_k) = \max\{d(x_i, x_j | x_i, x_j \in A_j)\} \text{ dir.}$$

Dunn indeksinin doğrudan uygulanmasındaki en temel sorun, c ve n değerleri arttıkça sayısal olarak hesaplamamanın çok maliyetli hale gelmesidir.

Fukuyama ve Sugeno 'nun (1989) tanımladığı geçerlilik fonksiyonu ise aşağıdaki gibidir.

$$\begin{aligned} FS(c) &= \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|x_j - c_i\|^2 - \sum_{i=1}^c \sum_{j=1}^n u_{ij}^m \|c_i - \bar{c}\|^2 \\ &= J_m(u, c) + K_m(u, c) \end{aligned} \quad (4.13)$$

Burada $\bar{c} = \sum_{i=1}^c \frac{c_i}{c}$ dir. $K_m(u, c)$ verinin ayrılmasını (seperation) ölçerken, $J_m(u, c)$ FCM fonksiyonunun amaç fonksiyonudur ve verinin yoğunluğunu (compactness) ölçer. Bu yöntemde de bölünme katsayısında olduğu gibi optimal küme sayısı $FS(c)$ nin maksimum değeri için belirlenmektedir.

Veri setinin yoğunluğunu ve ayrılmasını ölçen bir diğer küme geçerlilik indeksi ise Xie ve Beni (1991) tarafından önerilen Xie-Beni indeksidir. Diğer bir ifadeyle, bu küme geçerliliği indeksinde bulanık veri kümesinin kalitesini ölçmek için sadece üyelikler kullanılmaz.

$$XB(c) = \frac{\sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 ||x_j - a_i||^2}{n \min_{i,j} ||a_i - a_j||^2} \quad (4.14)$$

$$\pi = \frac{\sum_{i=1}^c \sum_{j=1}^n u_{ij}^2 ||x_j - a_i||^2}{n}$$

ile gösterilen oran, tüm veri setinin toplam varyasyonunu yani verilerin kümelerle nasıl dağıldığını ölçer ve π bulanık c-bölünmesinin yoğunluğu olarak adlandırılır. π değeri ne kadar küçükse, ayrılan sınıflar o kadar yoğun demektir. Bulanık bir c-bölünmesinin ayrılması ise,

$$sep(a) = \min_{i \neq j} ||a_i - a_j||^2$$

olarak tanımlanmaktadır. Büyük $sep(a)$ değeri, kümelerin iyi ayrılmış olduğunun bir göstergesidir. En iyi bulanık bölünme ise, tüm sınıfların yoğun ve iyi ayrılmış olduğunun göstergesi olan $XB(c)$ fonksiyonunu minimum yapan değerdir. $XB(c)$ 'nin tanımı, üyelik derecelerinin kullanıldığı algorithmadan bağımsızdır ve $XB(c)$ 'nin minimizasyonu FCM amaç fonksiyonunun minimizasyonu ile doğrudan ilişkilidir.

$$XB(c) = \frac{J(x, c)}{n \cdot \min_{i,j} ||a_i - a_j||^2} \quad (4.15)$$

Önerilen yöntemde gizli katman nöron sayısı küme geçerlilik indeksleri ile belirlenmiştir. Her bir indeksleme yönteminin önerdiği küme sayıları sistem üzerinde test edilmiş ve sistemin doğruluğu ölçülmüştür. Kullanılan bulanık c-ortalama algoritması için küme geçerlilik indeksleri aşağıdaki algorithmaya göre bulunmuştur (Haddadnia et al., 2003).

1. *Başla*
2. *Küme sayısını $c = 2$ al.*
3. *FCM algoritmasını birkaç adım çalıştır.*
4. *Küme geçerlilik indekslerini hesapla.*
5. *Küme geçerlilik indekslerinin her birindeki koşulları sağlıyor mu?*
 - *EVET ise, FCM algoritmasını bu c değeri için çalıştır.*
 - *HAYIR ise, c 'yi 1 arttır. $c \leq \sqrt{\text{data_size}}$ ise adım 3 e dön.*
6. *DUR.*

Bir sonraki bölümde, her bir küme değerine karşılık sistemin gösterdiği performans detaylı bir şekilde anlatılacaktır.


Çizelge 4.2'de sistemin en iyi performans gösterdiği değerler yer almaktadır.

Çizelge 4.2 FRBFNN Parametreleri.

Parametre	Değer
Öznitelik Vektör Boyutu	6
Gizli Katman Nöron Sayısı	12
Bulanıklık Katsayısı (m)	1.9
FRBFNN Merkez Seçimi	Bulanık c-Ortalama

Sistemin çalışmasının genel algoritması ise şu şekildedir.

1. *İkili seviyedeki altın standart retina görüntülerini al*
2. *İkili seviyedeki retina görüntülerine inceltme işlemini uygula*
3. *Tipik noktaları retina görüntüleri üzerinde işaretle*
4. *İnceltilmiş görüntü üzerindeki işaretli noktalardan öznitelikleri çıkar*
5. *Çıkarılmış öznitelikleri FRBFNN'ye besle*
6. *Öznitelikleri FRBFNN ile sınıflandır*
7. *Çıktı : Sonuç vektörü*



Şekil 4.8 Önerilen yöntemin genel akış şeması

4.3 Performans

Bu bölümde önerilen yöntemin çalışma performansı ve elde edilen sonuçlar incelenmektedir. Yöntemin performansı ROC eğrileri ile ölçülmektedir.

4.3.1 ROC eğrileri

Alıcı işletim karakteristiği (Receiver Operating Characteristic – ROC) ya da bilinen kısa adıyla ROC eğrisi, temel olarak sinyal algılama teorisinde bir alıcının gürültülü bir kanalda doğru algılama oranı ile yanlış algılama oranı arasında kesinlik ve hassasiyet arasındaki dengeyi değerlendirmek amacıyla 1950’li yılların ortalarında geliştirilmiştir. Testlerin kendi doğruluklarını tanımlaması ve testler arasında en doğru karşılaştırma yapmaya olanak sağlaması açısından sıklıkla kullanılmaktadır. Her ne kadar elektronik sinyal algılama teorisi içinde geliştirilmiş bir yöntem olsa da, son yıllarda tıp, makine öğrenmesi ve veri madenciliği gibi alanlarda da yaygın bir şekilde kullanılmaktadır (Fawcett, 2006).

ROC eğrileri yorumlayıcı performansını incelemek için iyi bir temel oluşturur. Bir durumun varlığı ya da yokluğuna karar vermek için yorumlayıcının kullandığı kriter ile durumu belirlemede yorumlayıcının yeteneği arasında ayrımın yapılması gerekir. ROC eğrisi bu ayrımı yapmak için kullanılabilir (Lusted, 1971). Daha sade olarak ifade etmek gerekirse, ROC, doğru pozitiflerin yanlış pozitiflere olan oranıdır.

Çizelge 4.3 ROC eğrisi için sınıflandırma matrisi (Fawcett, 2006).

		True Class		
		p	n	
Hypothesized Class	Y	True Positive	False Positive	Y
	N	False Negative	True Negative	N
		P	N	

Çizelge 4.3’te verilen matrise göre, bir sınıflandırıcı ve bir örnek için mümkün olan dört adet durum vardır:

- i. Örnek değeri pozitif ve sınıflandırma sonucu da pozitif ise *Doğru Pozitif (True Positive – TP)*
- ii. Örnek değeri pozitif ve sınıflandırma sonucu negatif ise *Yanlış Negatif (False Negative – FN)*
- iii. Örnek değeri negatif ve sınıflandırma sonucu pozitif ise *Yanlış Pozitif (False Positive – FP)*
- iv. Örnek değeri negatif ve sınıflandırma sonucu da negatif ise *Doğru Negatif (True Negative – TN)*


Çizelge 4.3 kullanılarak hesaplanan metrikler, pozitif örnek değerleri arasından doğru olarak sınıflandırılan örnekler Doğru Pozitif Oranı (True Positive Rate – TPR), negatif örnek değerleri arasından doğru olarak sınıflandırılan örnekler Yanlış Negatif Oranı (False Positive Rate – FPR) ve tüm örnek değerleri arasından doğru olarak sınıflandırılanların oranı olan sınıflandırmanın doğruluk oranı (Accuracy) dir.

$$TPR = \frac{TP}{P} \quad (4.16)$$

$$FPR = \frac{FP}{P} \quad (4.17)$$


$$Accuracy = \frac{TP + TN}{P + N} \quad (4.18)$$

ROC eğrileri, TPR y ekseninde ve 1-FPR (specificity) de x ekseninde olmak üzere çizilen iki boyutlu bir grafikdir. Bu eğriler, doğru pozitif oranı ile yanlış pozitif oranı arasındaki performansı gösterir. Örnek bir ROC grafiği Şekil 4.9’da gösterilmektedir. (0,0) noktasında tüm pozitif durumlar yanlış, tüm negatif durumlar da doğru alınmıştır. (1,1) noktası ise tüm durumların pozitif sınıflandırıldığı noktadır. Bu noktada sınıflandırıcı tüm pozitif durumları doğru ve tüm negatif durumları da yanlış alır. Rastgele olarak tahmin yapan bir sınıflandırıcının ROC eğrisi köşegen olacaktır.



Şekil 4.9 Örnek ROC grafiği (Uzunçarşılı M., 2005).

ROC eğrisi altında kalan alan, testin doğruluğunu tek bir sayısal değerle özetlemek için kullanılır. En büyük '1.0' değerini alabilir. Pratik olarak alabileceği en küçük değer '0.50' dir. İki test aynı ROC eğrisi altında kalan alan değerine sahip olabilir, ancak işleyişleri farklıdır. Düşük yanlış pozitif oran (yüksek seçicilik) gerekli ise, Şekil 4.10'daki eğrilerden B testi, A testine tercih edilebilir.




Şekil 4.10 İki ROC eğrisinin karşılaştırılması (Grey and Morgan, 1972).

4.3.2 Sonuçlar

Tez çalışması dahilinde tüm kodlar MATLAB (R2011b – 7.13.0.564) ile geliştirilmiş ve Intel i5 2.9Ghz işlemci, 8GB belleğe sahip masaüstü bilgisayar üzerinde çalıştırılmıştır.

Retina damar görüntülerinde tipik noktaların bulanık radyal tabanlı fonksiyon modeliyle çıkarsanmasına yönelik yaklaşımda, öncelikle Bölüm 4.2.1’de anlatılan önışleme adımında anlatıldığı gibi DRIVE veritabanı içerisindeki 40 adet altın standart retina görüntüsü içerisinde bir adet eğitim bir adet de test setinden olmak üzere iki adet retina görüntüsü çıkarılmıştır. Kalan 38 görüntünün 29 tanesi bulanık radyal tabanlı fonksiyon sinir ağının eğitimi, 9 tanesi de test için ayrılmıştır. Her bir eğitim ve test görüntüsü, yaklaşık 110 adet tipik nokta içermektedir. Testler, retina görüntüleri üzerindeki tipik noktalar üzerinden yapılmaktadır. Bölüm 4.2.3.3’de anlatılan küme geçerlilik indekslerinde her bir indekisleme yönteminin önerdiği küme sayısı ve bu değerlere karşılık sistemin performansı Çizelge 4.4’te verilmektedir.



Şekil 4.11 Retina test görüntülerinde test yapılan noktalardan bazıları. Örnek: 1 nolu test görüntüsü, test yapılacak toplam 124 adet tipik nokta.

Çizelge 4.4 Küme geçerlilik indeksleri ile önerilen küme sayılarının sistem üzerindeki doğruluk değerleri.

Küme Geçerlilik İndeksleri	Önerilen Küme Sayısı	Ortalama (%)		
		TPR	FPR	Acc
Partition Coefficient	5	-	-	-
Partition Entropy	5	-	-	-
Xie – Beni	13	97.93	3.77	97.08
Fukuyama - Sugeno	2	-	-	-
Kwon	13	97.93	3.77	97.08
PCAES	12	97.88	1.72	98.07

Çizelge 4.4’te en iyi performansı gösteren küme sayısının 12 olduğu görülmektedir. RBF’in görevi 6 boyutlu girdi katmanını daha yüksek boyuta taşımak olduğundan dolayı, önerilen ‘5’ ve ‘2’ küme değerleri dikkate alınmamıştır. Gizli katman nöron sayısının 12 olarak tasarlandığı bulanık tabanlı radyal fonksiyon sınır ağı mimarisine ait her bir test görüntüsü üzerindeki performans ölçüm sonuçları Çizelge 4.5’te gösterilmektedir.


Çizelge 4.5 DRIVE veritabanındaki her bir test görüntüsüne ait performans ölçüm sonuçları.

Görüntü	Ortalama (%)		
	TPR	FPR	Acc
1	98.97	4.25	97.36
2	98.94	2.30	98.32
3	96.85	1.93	97.46
4	97.14	1.72	97.71
5	98.99	2.24	98.84
6	97.68	3.96	97.86
7	98.99	2.43	98.28
8	98.63	2.31	98.64
9	98.61	2.39	98.11
ORT	98.31	2.61	98.07

Niemeijer et al.'un (2011) çalışmalarında kullandıkları POI'lere ait performans ölçüm sonuçları ise Çizelge 4.6'da verilmiştir.

Çizelge 4.6 Neimeijer et al.(2011)'a ait POI'lerin performans ölçüm sonuçları.

Görüntü	Ortalama (%)		
	TPR	FPR	Acc
1	96.70	2.50	97.10
2	98.28	3.98	97.15
3	96.56	2.46	97.05
4	96.94	1.54	97.70
5	99.19	1.97	98.61
6	98.76	3.24	97.76
7	98.09	1.71	98.19
8	98.68	2.06	98.31
9	98.01	2.11	97.95
ORT	97.91	2.39	97.76



Şekil 4.12 Tipik nokta çıkarsamasına ait sistem performansını gösteren ROC eğrisi. Eğri altında kalan alan 0,9807.

Şablon eşleme (template matching) yaklaşımında, retina görüntülerinden 25x25 boyutlarında kesilen 2000 tanesi BP, 2000 tanesi de CO bölgesi olmak üzere 4000 tipik nokta bölgesine ait öznitelik vektörleri ile bulanık radyal tabanlı fonksiyon ağı eğitilmiştir. Ağın test aşaması için 600 adet BP ve 610 adet CO bölgesine ait toplam 1210 adet damar görüntüsü kullanılarak sınıflandırma yapılmıştır. Bu yaklaşımda da, bulanık radyal tabanlı fonksiyon sinir ağının mimarisindeki gizli katman nöron sayısı küme geçerlilik indeksleri ile hesaplanmış olup, her bir indeksin önerdiği küme sayısına karşılık ağın ürettiği sonuçlar Çizelge 4.7’de verilmiştir.

Çizelge 4.7 Şablon eşleme yaklaşımında önerilen küme sayılarına ait sonuçlar.


Küme Geçerlilik İndeksleri	Önerilen Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
		TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
Partition Coefficient	12	80.79	9.07	85.90	90.93	19.21	85.90	85.86	14.14	85.90
Partition Entropy	2	43.79	21.56	61.26	78.44	56.21	61.24	61.12	38.88	61.25
Xie - Beni	58	86.58	10.52	88.04	89.48	13.42	88.43	88.03	11.97	88.24
Fukuyama - Sugeno	64	87.27	9.88	88.71	90.12	12.73	88.71	88.69	11.31	88.71
Kwon	58	86.58	10.52	88.04	89.48	13.42	88.43	88.03	11.97	88.24
PCAES	12	80.79	9.07	85.90	90.93	19.21	85.90	85.86	14.14	85.90

Küme geçerlilik indeksleri haricinde, deneysel olarak yapılan testlerde elde edilen sonuçlar ise Çizelge 4.8’de verilmiştir.

Çizelge 4.8 Şablon eşleme yaklaşımında deneysel küme sayılarına ait sonuçlar.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
10	84.83	22.62	81.07	77.38	15.17	81.07	81.11	18.89	81.07
20	81.40	9.81	85.83	90.19	18.60	83.64	85.79	14.21	84.74
30	83.79	9.46	87.19	90.54	16.21	86.03	87.17	12.84	86.61
40	86.17	10.56	87.82	89.44	13.83	87.60	87.81	12.19	87.71
50	81.00	7.54	87.79	92.46	21.00	87.77	86.73	14.27	87.78

Çizelge 4.8’ de görüldüğü gibi, tipik nokta sınıflandırmasında, ağ en iyi sonucu, Fukuyama - Sugeno’nun önerdiği 64 gizli katman nöron sayısı ile %88.71 doğruluk oranı olarak vermektedir. En yüksek doğruluk değerini veren gizli katman nöron sayısına sahip yapay sinir ağının performansına ait ROC eğrisi Şekil 4.13’te gösterilmiştir.



Şekil 4.13 Tipik nokta sınıflandırmasına ait sistem performansını gösteren ROC eğrisi. Eğri altında kalan alan 0,8871

Tez kapsamında önerilen yöntem ile literatürdeki diğer çalışmaların karşılaştırılması ise Çizelge 4.9’da yer almaktadır. Karşılaştırmalar, sadece DRIVE veritabanını kullanan yöntemler arasında yapılmıştır.

Çizelge 4.9 Önerilen yöntemin diğer yöntemler ile karşılaştırılması.

	Çıkarsama (%)	Sınıflandırma (%)
Aibinu et al.	96.00	-
Bevilacqua et al.	88.67	-
Bhuiyan et al.	95,82	48.00
Calvo et al.	93.60	83.00
Cinsdikici ve Çetinkaya	78.45	93.78
Neimeijer et al.	-	89.00
Önerilen Yöntem	98.07	88.71

Önerilen yöntemin uygulanması öncesinde, tipik nokta sınıflandırmasının retina damarlarından tipik nokta çıkarsamasından daha yüksek bir doğruluk vereceği öngörülmesine rağmen, yöntemin uygulanmasının ardından elde edilen sonuçların tam tersi olduğu görülmüştür. Bu durum çıkarılan öznetelik vektörlerinin niteliği ile yakından ilişkilidir. FRBF ağına beslenen öznetelik

vektörleri retina damarlarından tipik nokta sınıflandırmasından çok, çıkarsamasına daha uygundur. Bu durumda, yüksek doğrulukla sınıflandırma yapabilmek için farklı niteliklerde öznitelik vektörü çıkarsaması yapılabilir.

Önerilen yöntem, bulanık radyal tabanlı fonksiyon ağlarının retina damar görüntülerinde tipik nokta çıkarsaması üzerine literatürde ilk defa uygulanmıştır. Yeni bir yöntem olmasına karşılık, tipik nokta çıkarsamasında literatürde yer alan diğer yöntemlerin üzerinde bir başarı elde edilmiştir.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, retina görüntülerinde damar tipik noktaların çıkarsanmasında bulanık radyal tabanlı fonksiyon sinir ağı kullanılarak yeni bir yöntem geliştirilmesi amaçlanmıştır.

Çalışmanın ilk bölümünde çalışmanın amacı ve önemine değinilmiştir. Daha sonra ikinci bölümde, literatürde retina damarlarından tipik nokta tespiti için ortaya atılan iki farklı metot ve bu metot altındaki çalışmalar açıklanmıştır. Üçüncü bölümde ise çalışma kapsamında kullanılan bulanık mantık, bulanık kümeleme gibi genel kavramlar anlatılmış ve yapay sinir ağlarının genel yapısı hakkında detaylı bilgi verilmiştir. Dördüncü bölümde, yüksek doğruluklu bir şekilde tipik nokta tespiti yapmak için tasarlanan bulanık radyal tabanlı fonksiyon sinir ağı yöntemi detayları ile anlatılmıştır. Son bölümde ise tasarlanan yapının performansı farklı kriterlere bakılarak incelenmiştir.

Geliştirilen yöntem, önişleme, öznitelik çıkarımı ve analiz olmak üzere üç aşamadan oluşmaktadır. Önişleme aşamasında görüntülere, inceltme gibi morfolojik işlemler uygulanmış ve üzerlerinden öznitelik çıkarmaya uygun hale getirilmişlerdir. İkinci aşama olan öznitelik çıkarımında, $r_1=3$ ve $r_2=6$ yarıçaplı iç içe çemberler çizilerek damarlardan 6 adet öznitelik çıkarsaması yapılmıştır. Böylelikle retina görüntülerinden damar ve tipik nokta bölgelerini ayırt edebilecek özellikler elde edilmektedir. Son aşamada ise, çıkarılan öznitelik vektörleri bulanık radyal tabanlı fonksiyon sinir ağı ile eğitilerek tipik nokta tespiti yapılmaktadır.

Bulanık radyal tabanlı fonksiyon sinir ağındaki gizli katman nöron sayısı, literatürde bulunan küme geçerlilik indeksleri çalıştırılarak bulunmuştur. Her bir yöntemin önerdiği katman sayısı test edilmiş ve herbirine karşılık gelen doğruluk değerleri hesaplanmıştır. Tasarlanan sistemin çalıştırılması sonucu oluşan yapının performansına bakmak için ROC eğrilerinden yararlanılmıştır. ROC eğrilerinde incelenen kriterler doğru pozitif oranı, yanlış negatif oranı, yanlış pozitif oranı, ve doğru negatif oranıdır. Bu kriterlere göre, retina damarlarında tipik noktaları otomatik olarak tespit eden yöntemin doğruluğu %98,07 olarak ölçülmüştür. Bu doğruluk oranının literatürde yer alan diğer metodlara oranla oldukça yüksek olduğu göze çarpmaktadır. Tipik nokta sınıflandırması için kullanılan şablon eşleme tabanlı yaklaşımda ise yöntemin başarısı %88,71 olarak hesaplanmıştır. Literatür incelendiğinde, bunun ortalamanın üzerinde bir başarı olduğu görülmektedir.

Önerilen yöntemin başarısını arttırmak için, tipik nokta bölgelerinden farklı özellikler çıkarmak için istatistiksel yöntemler veya yüksek doğrulukla tipik nokta sınıflandırması yapan yaklaşımlar kullanılabilir.

İlerisi için düşünülen, geliştirilen yöntemde ve bulanık c-ortalama (FCM) algoritmasında kullanılan öklit uzaklık metriği yerine Chamfer distance metriği kullanılmasıdır. Böylelikle yöntemin daha yüksek doğrulukla ve hassasiyetle çalışması hedeflenmektedir.

KAYNAKLAR DİZİNİ

- Aibinu A.M., Iqbal M.I., Shafie A.A., Salami M.J. and Nilsson M.,** 2010, Vascular intersection detection in retina fundus images using a new hybrid approach, *Comput Biol Med.* , 40(1), 81-89p.
- Akbilgiç O.,** 2004, Hibrit Radyal Tabanlı Fonksiyon Ağları ile Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İşletme ABD., Yayınlanmamış Doktora Tezi.
- Behloul F., Lelieveldt B.P.F., Boudraa A. And Reiber J.H.C.,** 2002, Optimal design of radial basis function neural networks for fuzzy-rule extraction in high dimensional data, *Pattern Recognition* (35), 659-675 p.
- Bevilacqua V., Cariello L., Introna F. and Mastronardi G.,** 2005, A genetic algorithm approach to detect eye fundus vessel bifurcation points, *Proceedings of Int. Conference, CIMED'2005, Lisbon* ISBN 0-86341-520-2, 355-360p.
- Bevilacqua V., Cambo S., Cariello L. and Mastronardi G.,** 2005, A Combined Method to Detect Retinal Fundus Features, *European Conference on Emergent Aspects in Clinical Data Analysis, Pisa, Italy.*
- Bezdek J.C.,** 1974, Numerical Taxonomy with Fuzzy Sets, *Journal of Mathematical Biology* 1, 57-71p. (a)
- Bezdek J.C.,** 1974, Cluster Validity with Fuzzy Sets, *Journal of Cybernetics* 3, 58-72p. (b)
- Bezdek J.C.,** 1975, Mathematical Models for Systematic and Taxonomy, 8th International Conference on Numerical Taxonomy, San Francisco, C.A., 143-165p.
- Bezdek J.C.,** 1981, *Pattern Recognition with Fuzzy Objective Algorithms,* Milenium Press, ISBN:0306406713.
- Bezdek J.C., Ehrlich R. and Full W.,** 1984, FCM: Fuzzy c-means Clustering Algorithm, *Computer and Geosciences*, 10(2,3), 191-203p.

KAYNAKLAR DİZİNİ (devam)

- Bhuiyan A., Nath B., Chua J. and Ramamohanarao K.,** 2008, Automatic Detection of Vascular Bifurcations and Crossovers from Color Retinal Fundus Images, Signal-Image Technologies and Internet-Based System, 2007. SITIS '07. Third International IEEE Conference on, Shanghai, China, 711-718p.
- Broomhead, D. S., and D. Lowe,** 1988, Multi-variable functional interpolation and adaptive networks. Complex Systems, 2, 321-355p.
- Calvo D., Ortega M., Penedo M.G. and Rouco J.,** 2010, Automatic detection and characterisation of retinal vessel tree bifurcations and crossovers in eye fundus images, Compututer Methods Programs Biomedical., 103(1), 28-38p.
- Can A., Shen H., Turner J.N., Tanenbaum H.L. and Roysam B.,** 1999, Rapid automated tracing and feature extraction from live high-resolution retinal fundus images using direct exploratory algorithms, IEEE Transaction on Information Technology in Biomedicine, 125-138p.
- Chanwimaluang T. and Fan G.,** 2002, An efficient blood vessel detection algorithm for retinal images using local entropy thresholding, ISCAS, 21-24p.
- Chanwimaluang T. and Fan G.,** 2006, Hybrid Retinal Image Registration, IEEE Transactions of Information Technology in Biomedicine, Vol.10-1, 129-142p.
- Chaudhuri S., Chatterjee S., Katz N., Nelson M. and Goldbaum M.,** 1989, Detection of blood vessels in retinal images using two-dimensional matched filters, IEEE Transaction on Medical Imaging, 8(3), 263–269p.
- Chutatape O., Zheng L. and Krishman S.,** 1998, Retinal blood vessel detection and tracking by matched Gaussian and Kalman filters, Proc.IEEE International Conference on Engineering Biol. Soc., 20, 3144–3149p.
- Chen S. and Cowan C.F.N., Grant P.M.,** 1991, Orthogonal least squares learning algorithm for radial basis function networks, IEEE Transaction on Neural Networks 2(2), 302-309p.

KAYNAKLAR DİZİNİ (devam)

- Cinsdikici M.G. and Aydın D.**, 2009, Detection of blood vessels in ophthalmoscope images using MF/ant (matched filter/ant colony) algorithm, Compututer Methods Programs Biomedical, 96, 85–95p.
- Cinsdikici M.G., Uğur A. and Tunalı T.**, 2007, Automatic Number Plate Information Extraction and Recognition for Intelligent Transportation System, Imaging Science Journal, 102-113p.
- Cover T.M.**, 1965, Geometrical nad Statistical properties of systems of linear inequalities with applications in pattern recognition, IEEE Transactions on Electronic Computers, 14, 326-334p.
- Çetinkaya C.**, 2011, Retina Görüntülerinde Radyal Tabanlı Fonksiyon Sinir Ağları ile Damar Tipik Noktalarının Tespit Edilmesi, Ege Üniversitesi Uluslararası Bilgisayar Enstitüsü, Yüksek Lisans Tezi.
- Dunn J.C.**, 1974, Well separated clusters and optimal fuzzy partitions, Journal of Cybernetics, 4, 95-14p.
- Fausett L.**, 1994, Fundamentals of Neural Networks. Prentice Hall.
- Fawcett T.**, 2006, An introduction to ROC analysis, Pattern Recognition Letters 27, 861-874p.
- Fukuyama Y. and Sugeno M.**, 1989, A new method of chhosing the number of clusters fort he fuzzy c-means method, In Proceedings of 5th Fuzzy System Symposium, Japanese, 247-250p.
- Gagnon L., Lalonde M., Beaulieu M. and Boucher M.C.**, 2001, Procedure to detect anatomical structures in optical fundus images, Proc. SPIE Medical. Imaging, Image Process., 4322, 1218–1225p.
- Gonzalez RC and Woods RE.**, 2008, Digital image processing , 3rd ed., Upper Saddle River (NJ): Prentice Hall; ISBN:9780131687288
- Grey D.R. and Morgan B.J.T**, 1972, Some aspects of ROC curve-fitting: Normal and logistic models. [Corrections and improvements to Dorfman-Alf; minimum chi-square bilogistic]. Journal of Mathematical Psychology, 9, 128-139p.

KAYNAKLAR DİZİNİ (devam)

- Grisan E., Pesce A., Giani A., Foracchia M. and Ruggeri A.,** 2004, A new tracking system for the robust extraction of retinal vessel structure, in Proceedings of the International Conference of the IEEE Engineering in Medicine and Biology Society, 1620-1623p.
- Grisan E., Foracchia M. and Ruggeri A.,** 2008, A novel method for the automatic grading of retinal vessel tortuosity, IEEE Transactions on medical imaging, 27(3), 310-319p.
- Gökçen, H.,** 2007, Yönetim Bilgi Sistemleri, Palme Yayıncılık, Ankara.
- Haddadnia J., Faez K., and Ahmadi M.,** 2002,, A fuzzy hybrid learning algorithm for radial basis function neural network with application in human face recognition, Pattern Recognition, 36, 1187-1202p.
- Haykin S.,** 1994, Neural Networks. A Comprehensive Foundation. Macmillan, New York, NY.
- Hebb D.O.,** 1949, The organization of behavior, New York:Wiley&Sons.
- Höppner F., Klawonn F., Kruse R., Runkler T.,** 1999, Fuzzy Cluster Analysis – Methods for Classification, Data Analysis and Image Recognition, John Wiley & Sons, Ltd, NY, ISBN: 0 471 98864 2.
- Hu Y., Zuo C., Yang Y., Qu F.** 2011, A Cluster Validity Index for fuzzy c – means clustering. International Conference on System Science, Engineering Design and Manufacturing Informatization, Guiyang, China.
- Iqbal M.I., Aibinu A.M., Nilsson M., Tijani B., and Salami M.J.E.,** 2008, Detection of vascular intersection in retina fundus image using modified cross point number and neural network technique, Proceedings of the International Conference on Computer and communication Engineering, Malaysia.
- Jain, A. K., Duin, R. P. W. Ve Mao, J.,** 2000, “Statistical Pattern Recognition : A Review”, IEEE Trans. Pattern Analysis and Machine Intelligence, 22(1), 4-37p.

KAYNAKLAR DİZİNİ (devam)

- Jiang X. and Mojon D.**, 2003, Adaptive local thresholding by verification based multithreshold probing with application to vessel detection in retinal images, IEEE Transaction on Pattern Analysis Machine Intelligence., 25(1), 131–137p.
- Kim D.W., Lee K.H. and Lee D.**, 2005, On cluster validity index for estimation of the optimal number of fuzzy clusters, Pattern Recognition, 37, 2004-202p.
- Kwon S.H.**, 1998, Cluster validity index for fuzzy clustering, Electronics Letters, 34(22), 2176-2177p.
- Lazzerini B., Jain L.C. and Dumitrescu D.**, 2000, Fuzzy sets and their application to clustering and training, CRC Press, Inc. FL, USA, ISBN:0-8493-0589-6
- Lippmann R.P.**, 1987, An introduction to computing with neural nets, IEEE ASSP Magazine, 4, 4-22p.
- Lusted L.B.**, 1971, Decision-making studies in patient management, New Engl. J Med, 284, 416-24 p.
- Marin D., Aquino A., Arias M.E.G., Bravo J.M.**, 2011, A New Supervised Method for Blood Vessel Segmentation in Retinal Images by Using Gray-Level and moment Invariants-Based Features, IEEE Transactions on Medical Imaging, 30(1), 146-158 p.
- Martinez-Perez M.E., Hughes A.D., Stanton A.V., Thom S.A., Chapman N., Bharath A.A. and Parker K.H.**, 2002, Retinal Vascular Tree Morphology: A Semi-Automatic Quantification, IEEE Transactions on Biomedical Engineering, 49(8), 912 – 917 p.
- Mendonca A.M. and Campilho A.**, 2006, Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction, IEEE Trans.Med.Imag., 25(9), 1200–1213p.
- Mitra S. and Basak J.**, 2001, FRBF: A Fuzzy radial basis function network, Neural Computing and applications, 10(3), 244-252p.

KAYNAKLAR DİZİNİ (devam)

- Moody, J. and Darken, Ch.**, 1989, Fast learning in networks of locally-tuned processing units, Neural Computation, 1, 281-294p.
- Mortensen E., Morse B., Barrett W. and Udupa J.**, 1992, Adaptive boundary detection using live-wire two dimensional dynamic programming, Computers in Cardiology, 635-638p.
- Niemeijer M., Dumitrescu A.V., Ginneken and Abramoff M.D.**, 2011, Automatic localization of bifurcations and vessel crossings in digital fundus photographs using location regression, Medical Imaging: Biomedical Applications in Molecular, Structural and Functional Imaging, Vol.7965 796507-1.
- Orr M.J.L.**, 1996, Introduction to Radial Basis Function Network, University of Edinburg, Scotland.
- Pedrycz W.**, 1998, Conditional Fuzzy Clustering in the design of Radial Basis Function Neural Networks, IEEE Transactions on Neural Networks, 9(4), 601-612p.
- Powell M.J.D.**, 1985, Radial Basis Functions for Multivariable Interpolation: A Review in IMA Conference on Algorithms for the Approximation of Functions and Data, RMCS, Shirvenham, UK, 143-16p.
- Poggio T. and Girosi F.**, 1990, Regularization algorithms for learning that are equivalent to multilayer networks, Science, 247 (1990), 978-982p.
- Renals S.**, 1988, Radial basis functions network for speech pattern classification, Electronics Letters, 25, 437-439p.
- Rezaee B.**, 2010, A cluster validity index for fuzzy clustering, Fuzzy Sets and Systems, 161,3014-3025p.
- Rosenblatt F.**, 1958, The Perceptron:A Probabilistic Model for Information Storage and Organization in the Brain, Psychological Review, 65(6), 386-407p.

KAYNAKLAR DİZİNİ (devam)

- Shen H., Roysam B., Stewart C., Turner J., Tanenbaum H.L.,** 2001, Optimal Scheduling of Tracing Computations for Real Time Vascular Landmark Extraction from Retinal Fundus Images, IEEE Transactions on Information Technology in Biomedicine, 5(1), 77-91p.
- Tolias Y. A. and Panas S. M.,** 1998, A fuzzy vessel tracking algorithm for retinal images based on fuzzy clustering, IEEE Transactions on Medical Imaging , 17(2), 263–273p.
- Tsai C.L., Stewart C.V., Tanenbaum H.L. and Roysam B.,** 2004, Model-Based Method for Improving the Accuracy and Repeatability of Estimating Vascular Bifurcations and Crossovers From Retinal Fundus Images, IEEE Transactions on Information Technology in Biomedicine 8(2), 122-130p.
- Walter T. and Klein J. C.,** 2001, Segmentation of color fundus images of the human retina: Detection of the optic disc and the vascular tree using morphological techniques, Medical Data Analysis, ser. Lecture Notes in Computer Science, J. Crespo, V. Maojo, and F. Martin, Eds. Berlin, Germany: Springer-Verlag, 282–287p.
- Wikipedia,** http://en.wikipedia.org/wiki/Gaussian_function#Properties, Erişim Tarihi: 25.03.2012.
- Wild S. Roglic G., Green A., Sciree R. and King H.,** 2004, Global prevalence of diabetes: Estimates for the year 2000 and projections for 2030, Diabetes Care, 27, 1047-1053p.
- Wu K.L. and Yang M.S.,** 2004, A Cluster validity index for fuzzy clustering, Pattern Recognition Letters, 26, 1275-1291p.
- Xie X.L. and Beni G.,** 1991, A validity measure for fuzzy clustering, IEEE Transactions on PAMI, 4, 357-363p.
- Zadeh L.A.,** 1965, Fuzzy Sets, Information and Control, 8, 338-353p.
- Zadeh L.A.,** 1978, Fuzzy Sets as a basis for a theory of possibility, Fuzzy Sets and Systems, 1, 3-28p.
- Zadeh L.A.,** 1994, The Fuzzy Systems Handbook, Academic Press Inc., London, United Kingdom.

KAYNAKLAR DİZİNİ (devam)

- Zana F., Klein J.C.,** 1999, A Multimodal Registration Algorithm of Eye fundus Images Using Vessels Detection and Hough Transform, IEEE Transactions on Medical Imaging, 18(5), 419-428p.
- Zhang E., Zhang Y. and Zhang T.,** 2002, Automatic retinal image registration based on blood vessels feature point, Proceedings of the First International Conference on Machine Learning and Cybernetics, Beijing.
- Zhou L., Rzeszutarski M.S., Singerman J. and Chokreff J.M.,** 1994, The detection and quantification of retinopathy using digital angiograms, IEEE Transaction On Medical Imaging, 619-626p.
- Ziyang Z., Zhisheng W., Yong H. and Mingzhi G. ,** 2008, Learning Method of RBFNetwork Based on FCM and ACO, IEEE Control and Decision Conference, Chinese, 102-105p.

ÖZGEÇMİŞ

Cemre CANDEMİR

Adres: Uluslararası Bilgisayar Enstitüsü 35100 Bornova/İZMİR

e-mail: cemre.candemir@ege.edu.tr, cemre.candemir@gmail.com

Kişisel Bilgiler

Uyruk : T.C.

Doğum Yeri : Tokat

Doğum Tarihi : 10.10.1987

Eğitim Durumu

Yüksek Lisans : 2009 - ,Ege Üniversitesi, Uluslararası Bilgisayar Enstitüsü, Bilgi Teknolojileri ABD Tezli Yüksek Lisans

Lisans : 2005 – 2009, Ege Üniversitesi, Fen Fakültesi, Matematik Bölümü, Uygulamalı Matematik ABD

2007- , Anadolu Üniversitesi, İşletme Fakültesi, İşletme Bölümü

Lise : 2001 – 2005, Ahmet Altan Anadolu Lisesi, Alaşehir / Manisa, Matematik – Fen Bölümü

Yabancı Dil

İngilizce : İyi Derecede

İş Deneyimi

2011 – :Ege Üniversitesi, Uluslararası Bilgisayar Enstitüsü, Araştırma Görevlisi

2010 : Sözleşme ve Araştırma İstatistik Müdürlüğü, Vadeli İşlem ve Opsiyon Borsası (VOB), Bahar Dönemi Staj

Alınan Eğitimler

2010 : Netsis Proficiency Program (NPP), Netsis A.Ş.

Bilgisayar dilleri ve program deneyimi

C/C++, Java, OpenGL (C/C++), PHP

MatLab, Eclipse IDE, DevC++, Microsoft Office Programs

Projeler

Enstitü Öğrenci İşleri Bilgi Sistemi Simülasyonu

Ürün-Müşteri İlişkileri Yönetim Web Sitesi Tasarımı

Symbian İşletim Sistemi Projesi

Long Range Wifi

MyLibrary – Kütüphane Bilgi Sistemi Web Projesi

OpenGL ile araba oyunu programı

İMKB Verilerine Dayalı Regresyon ve Korelasyon Analizleri

Uzaktan Eğitimde Moodle Platformunun Kullanımının Araştırılması (BAP, 2011)

Hastaların Retina Damar Görüntülerindeki Zamansal Farklılıkların İzlenmesi için Tipik Noktaların Bulanık Radyal Tabanlı Fonksiyon Sinir Ağları ile Otomatik Çıkarsanması (BAP, 2012 -)

EKLER

EK - 1 TÜRKÇE - İNGİLİZCE SÖZLÜK

Adaptif Rezonans Teorisi	Adaptive Resonance Theory
Aktivasyon Fonksiyonu	Activation Function
Algılayıcı	Perceptron
Alıcı İletim Karakteristiği	Receiver Operating Characteristic
Arkaplan	Background
Ayrılma İndeksi	Seperation Index
Bölünme Entropisi	Partition Entropy
Bölünme Katsayısı	Partition Coefficient
Bulanık c-ortalama	Fuzzy c-means
Bulanık Kümeleme	Fuzzy Clustering
Bulanık Mantık	Fuzzy Logic
Bulanık Radyal Tabanlı Fonksiyon	Fuzzy Radial Basis Function
Bulanık Radyal Tabanlı Fonksiyon Ağı	Fuzzy Radial Basis Function Network
Çan Şeklinde	Bell shaped
Çatallanma Noktası	Bifurcation Point
Çok Katmanlı Algılayıcı	Multilayer Perceptron
Damar Çıkarsama	Vessel Extraction
Destekleyici Öğrenme	Reinforcement Learning
Diyabetik Retinopati	Diabetic Retinopathy
Dik Ortalama Kareler	Orthagonal Least Square
Doğru Negatif	True Negative
Doğru Pozitif	True Positive
Doğrusal Olarak Ayrıştırılabilirlik	Linearly Seperable
Eğiticili Öğrenme	Supervised Learning
Eğiticili Seçim	Supervised Selection
Eğri Uydurma	Curve Fitting
En Dik İniş Metodu	Steepest Descent
En Küçük Kareler	Least Mean Square
Eşikleme	Thresholding
Görüntü Bölütleme	Image Segmentation
Görüntü Çakıştırma, Kayıtlama	Image Registration
Göz Tansiyonu	Glokom
Gürültü Temizleme	Noise Removal

EK – 1 (devam)

Hassasiyet	Accuracy
Izgara	Grid
İkili Görüntü	Binary Image
İkili Sınıflandırma	Binary Classification
İkizkenar Yamuk Şeklinde	Trapezoidal
İlişkiye Dayalı Kümeleme	Relation-based Clustering
İnceltme	Thinning
İskelet Çıkarsama	Skeletonization
Karınca Kolonisi Optimizasyonu	Ant Colony Optimization
Katı Kümeleme	Hard Clustering
Kesişim Noktası	Cross point
Keskin Geçiş	Sharp Transition
Küme Geçerliliği	Cluster Validity
Küme Geçerlilik İndeksi	Cluster Validity Index
Medyan Filtresi	Median Filter
Mükemmel Sınıflandırma	Perfect Classification
Ortalama Filtresi	Mean Filter
Öğrenme Vektör Nicelendirmesi	Learning Vector Quantization
Öğretmensiz Öğrenme	Unsupervised Learning
Önişleme	Preprocess
Örnek	Instance
Özdüzenleyici Haritalar	Self Organizing Maps
Öznitelik	Feature
Özyinelemeli	Recursive
Özyineli En küçük Kareler	Recursive Least Square
Piksel İşleme	Pixel Processing
Radyal Tabanlı Fonksiyon Sinir Ağı	Radial Basis Function Neural Network
Radyal Tabanlı Fonksiyon	Radial Basis Function
Sarı Nokta (gözde)	Makula
Sert İzli Doku	Scar Tissue
Sinir Ağı	Neural Network
Şablon	Template
Şablon Eşleme	Template Matching

EK – 1 (devam)

Şekil, Örüntü

Pattern

Temel Bileşenler Analizi

Principal Component Analysis

Uzaklığa Dayalı Kümeleme

Distance-based clustering

Üyelik

Membership

Üyelik Fonksiyonu

Membership Function

Yanlış Negatif

False Negative

Yanlış Pozitif

False Positive

Yanlış Pozitif Oranı

False Positive Rate

Yapay Sinir Ağı

Artificial Neural Network

Yumuşak Kümeleme

Soft Clustering

EK - 2 KARŞILAŞTIRMA SONUÇLARI

Bu bölümde farklı parametrelerle yapılan test sonuçları ve karşılaştırmaları yer almaktadır. Bölüm 4.2.3 de anlatıldığı gibi, küme geçerlilik indeksleri ile belirlenen bulanık radyal tabanlı fonksiyon sinir ağındaki gizli katman nöron sayıları bu bölümde bulanık c-ortalama algoritmasındaki farklı bulanıklık katsayıları ile test edilmiştir.

Çizelge A.1 $m = 1.5$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	43,61	19,87	62,02	80,13	56,39	61,40	61,87	38,13	61,71
12	77,29	8,93	84,24	91,07	22,71	80,17	84,18	15,82	82,21
58	84,68	8,14	88,30	91,86	15,32	87,69	88,27	11,73	87,99
64	85,18	8,60	88,32	91,40	14,82	88,32	88,29	11,71	88,32

Çizelge A.2 $m = 1.6$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	43,83	20,39	61,87	79,61	56,18	60,74	61,72	38,28	61,31
12	79,00	9,28	84,91	90,72	21,00	84,55	84,86	15,14	84,73
58	83,40	7,94	87,76	92,06	16,60	87,75	87,73	12,27	87,76
64	84,22	8,25	88,02	91,75	15,78	86,84	87,99	12,01	87,43

Çizelge A.3 $m = 1.7$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	84,22	8,25	88,02	91,75	15,78	85,79	87,99	12,01	86,91
12	78,90	7,50	85,76	92,50	21,10	84,71	85,70	14,30	85,25
58	87,19	9,73	88,74	90,27	12,81	85,54	88,73	11,27	87,14
64	84,33	7,73	88,33	92,27	15,68	88,33	88,30	11,70	88,33

Çizelge A.4 $m = 1.8$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	43,66	20,98	61,49	79,02	56,34	61,16	61,34	38,86	61,33
12	78,91	8,27	85,37	91,73	21,09	85,21	85,32	14,68	85,29
58	85,87	9,03	88,44	90,97	14,13	88,68	88,42	11,58	88,56
64	86,19	10,09	88,07	89,91	13,81	87,52	88,05	11,95	87,80

Çizelge A.5 $m = 1.9$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	43,71	20,80	61,60	79,20	56,29	61,07	61,45	38,55	61,34
12	80,03	8,93	85,60	91,07	19,97	85,60	85,55	14,45	85,60
58	83,21	8,93	87,17	91,07	16,79	87,11	87,14	12,86	87,14
64	87,90	10,39	88,76	89,61	12,10	88,60	88,76	11,24	88,68

Çizelge A.6 $m = 2.1$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	43,91	21,04	61,58	78,96	56,09	61,49	61,43	38,57	61,54
12	79,43	8,95	85,29	91,05	20,58	85,45	85,24	14,76	85,37
58	80,20	9,07	85,61	90,93	19,80	85,62	85,56	14,44	85,62
64	81,32	9,83	85,78	90,17	18,68	85,78	85,74	14,26	85,78

Çizelge A.7 $m = 2.2$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	47,33	26,94	60,30	73,06	52,67	60,32	60,20	39,80	60,31
12	80,59	10,30	85,19	89,70	19,41	85,30	85,15	14,85	85,25
58	80,44	10,21	85,15	89,79	19,56	86,03	85,11	14,89	85,59
64	82,71	10,90	85,93	89,10	17,29	85,87	85,90	14,10	85,90

Çizelge A.8 $m = 2.3$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	45,41	24,02	60,82	75,98	54,59	60,82	60,69	39,31	60,82
12	79,96	9,18	85,43	90,82	20,04	85,43	85,39	14,61	85,43
58	79,80	10,07	84,91	89,93	20,20	85,29	84,87	15,13	85,10
64	82,35	11,48	85,46	88,52	17,65	84,46	85,44	14,56	84,96

Çizelge A.9 $m = 2.4$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	42,92	20,75	61,23	79,25	57,08	60,08	61,08	38,92	61,66
12	81,03	9,94	85,58	90,06	18,97	85,29	85,55	14,45	85,44
58	77,75	11,52	83,16	88,48	22,25	83,40	83,11	16,89	83,28
64	778,04	10,99	82,37	89,01	21,96	83,57	83,52	16,48	83,40

Çizelge A.10 $m = 2.5$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	43,41	21,28	60,94	78,19	56,59	59,01	60,80	39,20	59,98
12	81,07	11,80	84,67	88,20	18,93	84,55	84,64	15,36	84,61
58	74,43	11,70	81,42	88,30	25,27	80,43	81,36	18,64	80,93
64	78,86	12,15	81,90	87,85	24,14	81,90	81,86	18,14	81,90

Çizelge A.11 $m = 3.0$ bulanıklık katsayısı için şablon eşleme yöntemi sonuçları.

Küme Sayısı	BP (%)			CO (%)			Ortalama (%)		
	TPR	FPR	Acc	TPR	FPR	Acc	TPR	FPR	Acc
2	47,11	28,17	59,57	71,83	52,89	59,34	59,47	40,53	59,46
12	56,81	11,48	72,79	88,52	43,19	72,31	72,66	27,34	72,55
58	50,68	12,92	69,03	87,08	49,32	69,03	68,88	31,12	69,03
64	48,63	11,23	68,87	88,77	51,37	68,87	68,70	31,30	68,87

Çizelge A.12 Farklı bulanıklık katsayılarına göre FRBF ağının ürettiği sonuçlar (m , bulanıklık katsayısı, n önerilen küme değerleri).

Görüntü	m = 1.8		m = 1.9		m = 2.0		m = 2.1	
	n=12	n=13	n=12	n=13	n=12	n=13	n=12	n=13
	Acc(%)	Acc(%)	Acc(%)	Acc(%)	Acc(%)	Acc(%)	Acc(%)	Acc(%)
1	97.33	96.49	97.36	96.86	97.20	97.32	97.34	96.55
2	98.31	95.03	98.32	94.33	96.73	98.26	97.55	94.06
3	97.44	94.64	97.46	94.87	96.78	97.41	97.45	93.78
4	97.71	97.70	97.71	97.70	97.77	97.70	97.70	97.70
5	98.82	98.05	98.84	98.41	97.87	98.83	98.81	98.09
6	97.82	97.78	97.86	97.84	97.87	97.86	97.87	97.83
7	98.25	98.25	98.28	98.27	98.28	98.27	98.28	98.27
8	98.64	97.44	98.64	97.37	98.12	98.62	98.63	96.91
9	98.08	98.06	98.11	98.09	98.11	98.10	98.11	98.10
ORT	98.04	97.05	98.07	97.08	97.73	98.05	97.97	96.81

