



EGE ÜNİVERSİTESİ

YÜKSEK LİSANS TEZİ

**RETİNA GÖRÜNTÜLERİNDE RADYAL TABANLI
FONKSİYON SINIR AĞLARI İLE DAMAR TİPİK
NOKTALARININ TESPİT EDİLMESİ**

Cihat ÇETİNKAYA

Tez Danışmanı: Yrd.Doç.Dr. Muhammed Gökhan CİNSDİKİCİ

Uluslararası Bilgisayar Anabilim Dalı

**Bilim Dalı Kodu: 619.02.04
Sunuş Tarihi: 12.08.2011**

Bornova-İZMİR

2011

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

(YÜKSEK LİSANS TEZİ)

**RETİNA GÖRÜNTÜLERİNDE RADYAL
TABANLI FONKSİYON SINIR AĞLARI İLE
DAMAR TİPİK NOKTALARININ TESPİT
EDİLMESİ**

Cihat ÇETİNKAYA

Tez Danışmanı: Yrd. Doç. Dr. Muhammed Gökhan CİNSDİKİCİ

Uluslararası Bilgisayar Anabilim Dalı

Bilim Dalı Kodu: 619.02.04

Sunuş Tarihi: 12.08.2011

Bornova-İZMİR

2011

Cihat ÇETİNKAYA tarafından YÜKSEK LİSANS tezi olarak sunulan “Retina Görüntülerinde Radyal Tabanlı Fonksiyon Sinir Ağları İle Damar Tipik Noktalarının Tespit Edilmesi” 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 12/08/2011 tarihinde yapılan tez savunma sınavında aday oybirliği/oyçokluğu ile başarılı bulunmuştur.

Jüri Üyeleri:

İmza

Jüri Başkanı : Yrd. Doç. Dr. Muhammed G. CİNSDİKİCİ

Raportör Üye : Yrd. Doç. Dr. Hasan BULUT

Üye : Yrd. Doç. Dr. Haldun SARNEL

ÖZET**RETİNA GÖRÜNTÜLERİNDE RADYAL TABANLI FONKSİYON SINİR AĞLARI İLE DAMAR TİPİK NOKTALARININ TESPİT EDİLMESİ**

ÇETİNKAYA, Cihat

Yüksek Lisans Tezi, Uluslararası Bilgisayar Enstitüsü
Tez Yöneticisi: Yrd. Doç. Dr. Muhammed Gökhan CİNSDİKİCİ
Ağustos 2011, 39 sayfa

Retina görme işleminin gerçekleştiği tabaka olduğundan dolayı, retinada oluşan hastalıklar doğrudan görme duyumuzu tehdit etmektedir. Bu sebeple retina üzerinde meydana gelen değişimlerin incelenmesi hastalıkların erken teşhis edilmesine olanak sağlar.

Aynı hastadan farklı zamanlarda alınan retina görüntülerinin karşılaştırılması ve aralarında meydana gelen değişimlerin izlenmesi görüntü çakıştırma yöntemiyle yapılmaktadır. Görüntü çakıştırma işlemi, referans görüntü ile hedef görüntüden seçilen tipik noktalarının birebir eşleştirilerek iki görüntü arasındaki farkın elde edilmesi prensibine dayanmaktadır.

Bu tez çalışması kapsamında, görüntü çakıştırma işleminde kullanılan retina damarlarının çatallanma ve kesişim noktalarının tespit edilmesine yönelik 3 aşamadan oluşan yeni bir yöntem önerilmektedir. İlk aşamada retina görüntülerinde görüntü temizlenmekte, daha sonra Temel Bileşenler Analizi ile öznitelik vektörleri çıkarılmakta ve son aşamada ise Radyal Tabanlı Fonksiyon Sinir Ağı kullanılarak sınıflandırma yapılmaktadır.

Anahtar sözcükler: retina görüntüleri, damar tipik noktaları, temel bileşenler analizi, radyal tabanlı fonksiyon sinir ağları

ABSTRACT**VASCULAR LANDMARK DETECTION IN RETINAL IMAGES USING RADIAL BASIS FUNCTION NEURAL NETWORKS**

ÇETİNKAYA, Cihat

MSc in International Computer Institute

Supervisor: Assist. Prof. Dr. Muhammed Gökhan CİNSDİKİCİ

August 2011, 39 pages

The diseases which have been developed within retina affect the sense of sight directly as retina is the layer where the process of vision takes place. Therefore, analyzing the changes occurring over retina enables pre-diagnosis of diseases.

Comparison of the various retinal images that are received at different times from the same patient and following the changes that occur between these various retinal images can be implemented via image registration method. Image registration method is based on the principle of obtaining the difference between two images by matching the landmark points that are chosen from the reference and target image.

This thesis aims at designating a new method which consists of three stages for detecting the bifurcation and crossover points of retinal vessels which are used in image registration. In the first stage of proposed method; noise is removed by using mean filter and uneven illumination is equalized by using background homogenization method, in the second stage; feature vectors are extracted by using principal component analysis and as for the final stage; classification is performed using radial basis function neural network.

Keywords: retinal images, vascular landmark, principal component analysis, radial basis function neural network

TEŞEKKÜR

Öncelikle bu tez konusu üzerinde bana çalışma imkânı sunan tez danışmanım Yrd. 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 ötürü Onur KILINÇÇEKER'e teşekkür ederim.

Bu çalışmamı, daima yanımda olan ve manevi desteğini benden esirgemeyen sevgili eşim Eda Burcu ÇETİNKAYA'ya adıyorum.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
ABSTRACT	vii
TEŞEKKÜR	ix
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xv
KISALTMALAR	xvii
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	5
2.1 Model Tabanlı Yaklaşımlar	5
2.2 Geometrik Tabanlı Yaklaşımlar	6
3. TEMEL KAVRAMLAR	11
3.1 Retina Görüntüleri	11
3.2 Görüntü Önışleme	12
3.3 Yapay Sinir Ağları	14

İÇİNDEKİLER (devam)

3.3.1 Radyal Tabanlı Fonksiyon Sinir Ağları	15
3.4 Retina Görüntü Veritabanı	17
3.5 ROC Eğrileri	18
4. ÖNERİLEN YÖNTEM	21
4.1 Görüntü Önışleme	21
4.1.1 Gürültü Temizleme	21
4.1.2 Aydınlatma Eşitleme	23
4.2 Öznitelik Çıkarımı	27
4.3 RTFSA ile ÇN ve KN Bölgesi Tespiti	29
4.4 Önerilen Yöntemin Genel İşleyişı	30
5. PERFORMANS	32
5.1 Görüntü Tabanlı Yaklaşım	32
5.2 Bölge Tabanlı Yaklaşım	35
6. SONUÇ ve TARTIŞMA	38
KAYNAKLAR DİZİNİ	40
ÖZGEÇMİŞ	43
EKLER	

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
2.1 3x3'lük 8-komşuluklu pencere	6
2.2 Örnek damar noktası sınıfları	7
2.3 KN'nin ÇN olarak sınıflandırılması.....	8
2.4 5x5'lük 16-komşuluklu pencere	8
2.5 3x3'lük ve 5x5'lik pencere	9
3.1 FFA ile elde edilen renkli retina görüntüsü.....	11
3.2 Gri ton retina görüntüsü	13
3.3 CLAHE sonucu elde edilen retina görüntüsü.....	13
3.4 RTFSA ağı tasarımı	15
3.5 Örnek bir ROC grafiği	20
4.1 İşlenmemiş Gri Ton Retina Görüntüsü	22
4.2 5x5'lik Aritmetik Ortalama Filtre Sonucu	23
4.3 Artalan retina görüntüsü.....	23
4.4 Gölge düzeltilmiş retina görüntüsü.....	25
4.5 Artalan homojenleştirilen retina görüntüsü.....	26

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
4.6 ÇN, KN ve damar içeren bölgeler.....	27
4.7 Yöntemde Kullanılan Üç Katmanlı RTFSA Mimarisi.....	29
4.8 Yöntem İşleyiş Şeması	31

ÇİZELGELER DİZİNİ

<u>Çizelge</u>	<u>Sayfa</u>
2.1 Cpn_{3x3} sınıflandırma tablosu	7
2.2 Cpn_{5x5} sınıflandırma tablosu	9
2.3 Cpn_{3x3} ve Cpn_{5x5} sınıflandırma tablosu	10
3.1 Sınıflandırıcıdan elde edilebilecek sonuçlar	19
4.1 RTFSA optimum parametreleri	30
5.1 5 boyutlu girdi vektörünün, görüntü tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	33
5.2 10 boyutlu girdi vektörünün, görüntü tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	33
5.3 15 boyutlu girdi vektörünün, görüntü tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	33
5.4 20 boyutlu girdi vektörünün, görüntü tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	34
5.5 En iyi performansın test görüntüler üzerindeki sonuç tablosu	35
5.6 5 boyutlu girdi vektörünün, bölge tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	36
5.7 10 boyutlu girdi vektörünün RTFSA'ya beslenmesiyle elde edilen sonuç tablosu	36

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
5.8 15 boyutlu girdi vektörünün, bölge tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	37
5.9 20 boyutlu girdi vektörünün, bölge tabanlı yaklaşımda RTFSA'ya beslenmesiyle elde edilen sonuç tablosu.....	37

KISALTMALAR

<u>Kısaltmalar</u>	<u>Açıklama</u>
ACC	Accuracy
ART	Adaptive Resonance Theory
CLAHE	Contrast Limited Adaptive Histogram Equalization
ÇN	Çatallanma Noktası
DRIVE	Digital Retinal Images for Vessel Extraction
FFA	<i>Fundus Floresin Anjiyografi</i>
FN	False Negative
FP	False Positive
FPR	False Positive Rate
KN	Kesişim Noktaları
LMS	Least Mean Square
LVQ	Learning Vector Quantization
RBF	Radial Basis Function
RBFNN	Radial Basis Function Neural Network
RLS	Recursive Least Square
ROC	Receiver Operating Characteristic
RTF	Radyal Tabanlı Fonksiyon
RTFSA	Radyal Temelli Fonksiyon Sinir Ağı
SOM	Self-Organizing Maps
TBA	Temel Bileşenler Analizi
TN	True Negative
TP	True Positive
TPR	True Positive Rate
YSA	Yapay Sinir Ağları

1. GİRİŞ

Retina veya diğerk adıyla ađ tabaka, göz küresinin en iç kısmını kaplayan ve görme işlemini gerçekleştiren sinirsel tabakadır. Retina tabakasında, retina dokusunu besleyen kan damarları, ışığa ve renge duyarlı görme hücrelerinden meydana gelen, keskin görüntü oluşmasını sağlayan sarı nokta (makula) ve görme hücrelerinde oluşan görüntüyü beyne ileten görme sinirleri (optik sinir) yer alır.

Cisimlerden yansıyan ışık demetleri retina tabakası üzerinde odaklandığında, sarı noktada yer alan görme hücreleri uyarılarak bir dizi kimyasal tepkime gerçekleştirilir. Bu tepkimeler sonucunda ışık enerjisinden elektriksel bir uyarı (görüntü) oluşur. Bu uyarı, görme hücrelerinden çıkan sinir lifleri vasıtasıyla görme sinirlerine iletilir. Görme sinirleri beyin ile doğrudan bağlantılı olup, retinada oluşan bu uyarıyı beyne taşıyarak görme işlemini tamamlamış olur.

Retina tabakası, görme işleminin gerçekleştiği yer olduğundan, sarı noktada meydana gelen bir bozukluk görüntünün oluşmamasına, görme sinirlerinde meydana gelen bir bozukluk ise görüntünün beyne iletilmemesine veya eksik iletilmesine neden olur. Retina tabakasında oluşan bozukluğun türüne ve büyüklüğüne göre ışık çakması, görüntü kırılması, görme alanında daralma ve uçuşan siyah cisimler gibi kısa süreli görme kayıplarının yanında görme duyusunun tamamen yitirilmesi de (körlük) söz konusu olabilir. Şeker hastalığı ve hipertansiyona bağlı retina kanamaları, retina yırtılmaları (retina dekolmanları), sarı nokta dejenerasyonları retina tabakasında bozulmalara yol açan hastalıkların başında gelmektedir.

Diyabetik retinopati, şeker hastalığına bağlı olarak kan şekerinin yükselmesi sonucu retina kılcal damarlarının etkilenmesi ile başlayan ve ilerleyen evrelerde görme duyusunun tamamen yitirilmesiyle sonuçlanabilen bir hastalıktır. Hastalığın başlangıç evresinde kılcal damarların tıkanması ve damar duvarlarının bozulması sonucunda damarlarda küçük genişlemeler (mikro anevrizma) meydana gelir. İlerleyen evrelerde genişlemelerden sızan kan, birikintiler (eksuda) oluşturarak sarı nokta üzerinde tahribatlara yol açar. Bu tahribatların erken

teşhisinin ve tedavisinin yapılmaması durumunda ise görme duyusu tamamen yitirilebilir. Bu sebeple şeker hastalarının düzenli olarak doktor tarafından muayene edilmeleri ve retina yapısında meydana gelen değişimlerin takip edilmesi gerekmektedir.

Fundus Flöresin Anjiyografi (FFA), muayene için gerekli retina görüntülerinin elde edilmesinde kullanılan en yaygın yöntemdir. Bu yöntemde, hastaya damardan verilen flöresin maddesi birkaç dakika içinde dolaşım yoluyla retina damarlarına ulaşır ve bu sırada anjiyografi cihazı ile retinanın fotoğrafları çekilir. Bu teknikle, kişinin gözüne ait farklı zamanlarda çekilmiş retina görüntüleri bir veritabanında depolanarak retina tabakasında meydana gelen değişimler doktor tarafından incelenmektedir.

Hastalardan farklı zamanlarda elde edilen retina görüntülerinde hastalığa bağlı değişiklikler dışında, görüntünün elde edilmesi sırasında meydana gelen sapmalar (dönme, öteleme, açısal kayma/eğrilik, kesme, ölçekleme, ışıklandırma, vb...) ve retina görüntüsünü elde eden cihazdan kaynaklanan sapmalar oluşmaktadır. Hastadan elde edilen retina görüntülerinin bu tür etkilerden kaynaklanabilecek sapmalar sebebiyle karşılaştırılması güçleşmektedir. Bu etkiler sonucu meydana gelen sapmaların ortadan kaldırılması ve retina yapısı üzerindeki hastalığa bağlı olarak gelişen değişimlerin tespit edilmesi “görüntü çakıştırma (kayıtlama)” yöntemiyle yapılmaktadır. Görüntü çakıştırma işlemi, referans görüntü ile hedef görüntüden seçilen referans noktalarının birebir eşleştirilerek iki görüntü arasındaki farkın elde edilmesi prensibine dayanmaktadır. Bu yüzden çakıştırma yapılacak görüntülerde yer alan referans noktalarının önceden çıkarılması gerekmektedir. Referans noktalarının fazla sayıda ve yüksek doğrulukla çıkarılması, çakıştırma işleminin başarısını arttırmaktadır.

Retina görüntülerinde yer alan referans noktaları; retina damarlarının çatallanma ve kesişim noktaları, sarı nokta bölgesi doku/reng bilgisi, görme sinir yapısı/reng bilgisi olarak karşımıza çıkmaktadır. Literatürde, retina görüntülerini çakıştırmak için en yaygın olarak kullanılan referans noktaları damarların çatallanma noktaları (ÇN) ve kesişim noktalarıdır (KN). ÇN, retina tabakası üzerine yayılan retina damarlarının birbirinden bağımsız iki kola ayrıldığı

noktalardır. KN ise, retina tabakasında gerçekte var olmayıp retina görüntülerinin iki boyutlu elde edilmesinden dolayı bağımsız iki retina damarının birbirlerinin içerisinde geçiyormuş gibi görünen noktalardır.

Bu tez çalışması kapsamında retina damarlarındaki ÇN ve KN tespit edilmesine yönelik, Temel Bileşenler Analizi (TBA) (Principal Component Analysis,(PCA)) ve Radyal Temelli Fonksiyon Sinir Ağı (RTFSA) (Radial Basis Function Neural Network, (RBFNN)) kullanılarak yeni bir yöntem önerilmektedir.

İkinci bölümde, retina damarlarındaki ÇN ve KN tespit edilmesine yönelik daha önce yapılan çalışmalar hakkında bilgi verilmektedir. Bu çalışmalarda sunulan çözüm yöntemlerine değinilmekte ve elde edilen sonuçlar tartışılmaktadır.

Üçüncü bölümde, tez kapsamında yararlanılan ve geliştirilen yöntemde kullanılan temel bilgiler yer almaktadır. İlk olarak, retina görüntüleri hakkında ön bilgi verilmekte daha sonra önerilen yöntemde kullanılan görüntü önışleme teknikleri ve RTFSA hakkında bilgiler yer almaktadır. Ayrıca bu bölümde önerilen yöntemde kullanılan retina görüntülerinden oluşan veritabanı ve yöntemin performansını ölçmek için kullanılan ROC (Receiver Operating Characteristic) eğrilerinden bahsedilmektedir.

Dördüncü bölümde, tez çalışması kapsamında retina damarlarındaki ÇN ve KN tespit edilmesine yönelik önerilen yöntem anlatılmaktadır. Yöntemde ilk olarak retina görüntüleri, gürültülerin ortadan kaldırılması ve işlenmeye hazır hale gelmesi için önışlemeden geçirilmektedir. Önışlemeden geçirilen retina görüntülerinde yer alan ÇN ve KN içeren bölgelerde TBA kullanılarak öznitelik vektörleri elde edilmektedir. Bu öznitelik vektörleri kullanılarak RTFSA eğitilmekte ve test edilmektedir.

Beşinci bölümde, önerilen yöntemde ait deneysel çalışmalar yer almaktadır. TBA ile elde edilen farklı boyutta öznitelik vektörlerine ve RTFSA tasarımında yer alan gizli katman sinir hücresi sayısına, merkezlerin seçimine ve öğrenme

algoritmasına göre önerilen yöntemin performansı incelenmektedir. Sonuçlara ait tablolar ve grafikler sunulmaktadır.

Son bölümde, önerilen yöntemin bilim dünyasına katkılarına değinilmekte ve gelecekte yapılabilecek geliřtirmelerden bahsedilmektedir. Kaynaklar dizini ve ekler, bu bölümü takip etmektedir.

2. LİTERATÜR ÖZETİ

Bu bölümde, retina damarlarındaki ÇN ve KN tespit edilmesine yönelik önceki çalışmaların sunduğu çözümler ana hatlarıyla anlatılmaktadır. Önceki çalışmaların konuyu hangi noktalardan ele aldığından bahsedilmektedir.

Retina damarlarındaki ÇN ve KN tespiti için yapılan önceki çalışmaları model tabanlı yaklaşımlar ve geometrik özellik tabanlı yaklaşımlar olmak üzere iki grupta toplanmaktadır. Model tabanlı yaklaşımlarda genelde, retina damarlarının izlenmesi veya modellenmesi söz konusudur. Geometrik özellik tabanlı yaklaşımlar ise genellikle retina görüntüsündeki damarların elde edilmesi (vessel extraction), damar iskeletinin çıkartılması (skeletonization) ve çıkarılan iskeletin analizinin yapılması aşamalarından oluşur. Model tabanlı yaklaşımlarda, gri ton retina görüntüsü kullanılmakta olup düşük işlem karmaşıklığına sahiptir. Geometrik tabanlı yaklaşımlar da ise ikili görüntü (binary image) kullanılmakta olup görüntüdeki tüm pikseller işlendiğinden yüksek işlem karmaşıklığına sahiptir. (Bhuiyan et al., 2008)

2.1 Model Tabanlı Yaklaşımlar

Model tabanlı yaklaşımlar, gri tondaki retina görüntüsündeki damarların izlenmesi (vessel tracking) ve keşfedilmesi (exploring) esasına dayanmaktadır. Bu yaklaşımlarda, damar üzerinde bir başlangıç noktası belirlenerek, damar özyineli olarak (recursive) izlenir. Bu yaklaşımlarda, sadece damara yakın pikseller işlendiği için işlem karmaşıklığı düşüktür.


Mortensen et al. (1992) ÇN ve KN tespit edilmesine yönelik çalışmasında, damarların başlangıç, bitiş, genişlik ve yön parametrelerini manuel olarak belirleyerek damar izleme yapmıştır. Zhou et al. (1994) ise çalışmasında, damarlar üzerinde sadece başlangıç ve bitiş noktalarını belirleyerek damar izleme yapmıştır. Her iki çalışmada da damarlar izlenirken farklı kollara ayrıldıkları yerlerde ve kesiştikleri yerlerde ÇN ve KN tespit edilmektedir. Çalışmaların performansları yüksek olmasına rağmen manuel veri girişine sahip olduklarından gerçek zamanlı işlemlerde kullanılması mümkün değildir.

Can et al., (1999) ÇN ve KN tespit edilmesine yönelik çalışmasında, damarların başlangıç noktalarını otomatik olarak belirleyerek damar izleme metodu ortaya atmıştır. Görüntüyü ızgaralara bölerek, ızgara içerisinde kalan bölgede kontrast ve parlaklık yoğunluk değerlerinden minimuma sahip noktalar damar başlangıç noktaları olarak seçilmiştir. Damarlar izleme esnasında eğer başka damarla karşılaşılırsa, damarlara ait karşılaşma sayısına ve açılara göre ÇN ve KN ayrımı yapılmaktadır.

Model tabanlı yaklaşımlarda kullanılan damar izleme ve keşif metotları, retina damar ağının karmaşık yapısından dolayı her zaman iyi sonuçlar vermemektedir. Ayrıca damarları izlemek için başlangıç ve bitiş noktası gibi manuel bilgi gerektirdiğinden gerçek zamanlı uygulamalar için uygun değildir.

2.1 Geometrik Tabanlı Yaklaşımlar

Geometrik tabanlı yaklaşımlarda, retina damarları çıkarsanarak geometrik olarak incelenmektedir. Zhang et al. (2002) önerdiği çalışmada, ilk olarak gri-seviyedeki retina görüntüsü birtakım ön işlemlerden geçirilerek gürültüden arındırılmaktadır. Daha sonra bu görüntüye eşikleme (thresholding) uygulanarak retina damarları elde edilmektedir. Damarlar, inceltme (thinning) yöntemiyle bir piksel kalınlığa dönüştürülerek damar iskeleti çıkartılmaktadır. İskelette yer alan her bir damar pikselinin etrafına Şekil 2.1'de görüldüğü gibi 3x3'lük bir pencere çizilerek, 8 adet komşu piksellerin değerleriyle kesişme nokta sayısı (cross point number, cpn) (1) formülü ile hesaplanmakta ve Tablo 2.1'deki gibi sınıflandırılmaktadır. Şekil 2.2'de olası sınıflandırma örnek durumları yer almaktadır. (Zhang et al.,2002)

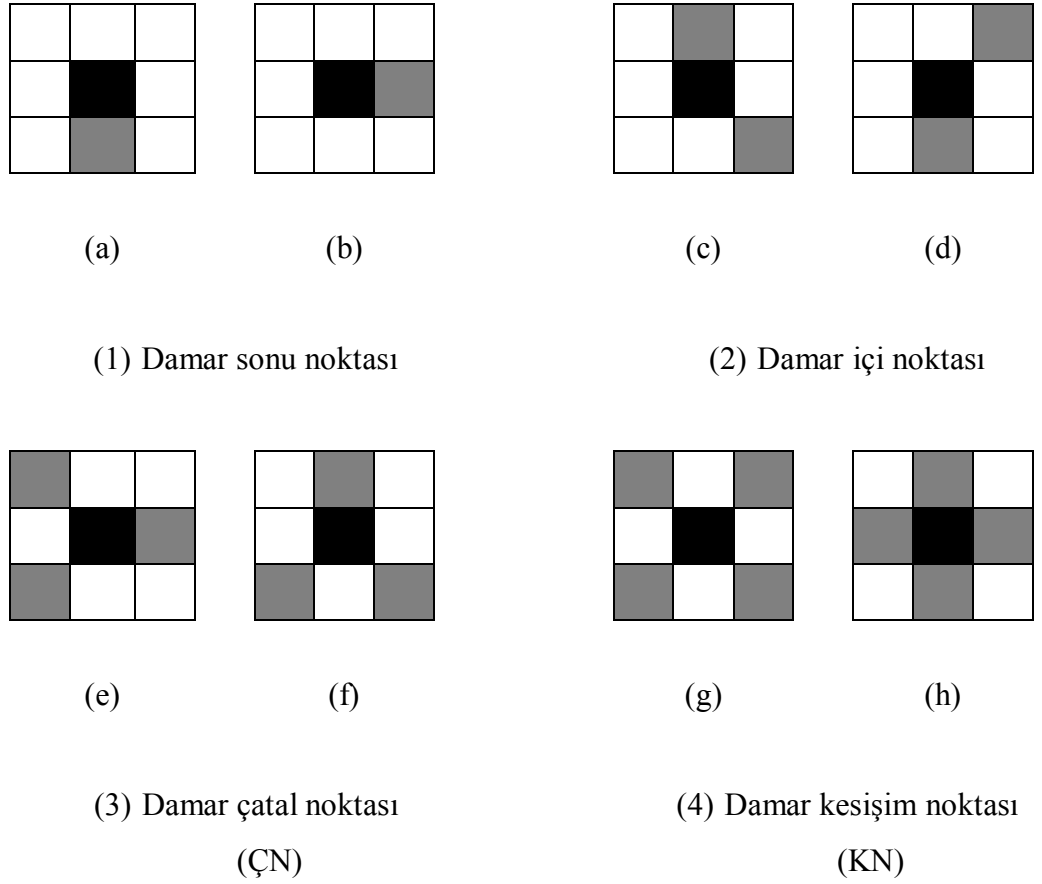


Şekil 2.1 3x3'lük pencere (Zhang et al,2002)

$$cpn_{3 \times 3} = \frac{1}{2} \left(\sum_{i=1}^8 |P_i - P_{i+1}| \right) : P_9 = P_1 \quad (1)$$


$cpn_{3 \times 3}$	Sınıf
1	Damar sonu noktası
2	Damar içi noktası
3	Damar çatallanma noktası (ÇN)
4	Damar kesişim noktası (KN)

Tablo 2.1 $cpn_{3 \times 3}$ sınıflandırma tablosu (Zhang et al,2002)




Şekil 2.2 Örnek damar noktası sınıfları (Zhang et al., 2002)

Zhang'ın çalışmasında da görüldüğü üzere, geometrik tabanlı yaklaşımlarda damarların doğru bir şekilde çıkartılması, ÇN ve KN tespit edilmesinin performansını arttırmaktadır. Literatürde, farklı damar çıkarsama metotları ile damar çıkarsayan (Chanwimaluang et al., 2003) , (Bevialcqua et al, 2005) , (Bhuiyan et al., 2008) ve daha sonra cpn formülü ile ÇN ve KN tespit eden çalışmalar yer almaktadır. Damar iskeletinin çıkarılması sırasında, Şekil 2.3'de görüldüğü üzere damarların birbirlerini eğik açılarla kestiği bölgelerde yer alan kesişim noktaları, 2 farklı çatallanma noktası olarak sınıflandırılmaktadır.



Şekil 2.3 KN'nin ÇN olarak sınıflandırılması. (a) Damar görüntüsü. (b) İskelet çıkarılmış damar görüntüsü

İskelet çıkarma işlemi sonucunda oluşacak yanlış sınıflandırmayı en aza indirmek için farklı çalışmalar ortaya atılmıştır. Iqbal et al. (2008), Şekil 2.4'de görüldüğü üzere pencere boyutunu 5x5'lik olacak şekilde alarak pencere etrafında en dışta yer alan 16 adet piksel değerlerine göre (2) Tablo 2.2'deki gibi sınıflandırma yapmaktadır.




Şekil 2.4 5x5'lik pencere (Iqbal et al, 2008)

$$cpn_{5 \times 5} = \frac{1}{2} \left(\sum_{n=1}^{16} |P_n - P_{n+1}| \right) : P_{17} = P_1 \quad (2)$$

$cpn_{5 \times 5}$	Sınıf
1	Damar sonu noktası
2	Damar içi noktası
3	Damar çatallanma noktası (ÇN)
≥ 4	Damar kesişim noktası (KN)

Tablo 2.2 $cpn_{5 \times 5}$ Sınıflandırma Tablosu (Iqbal et al., 2008)

Aibinu et al., (2010) çalışmasında, pencere boyutunu Şekil 2.5'de görüldüğü üzere hem 3x3'lük hem de 5x5'lik olarak almaktadır. Bu pencereler yardımıyla sırasıyla 8 ve 16 adet piksel değerlerini kullanarak, $cpn_{3 \times 3}$ (3) ve $cpn_{5 \times 5}$ (4) olmak üzere iki farklı cpn değeri hesaplamaktadır. Hesaplanan cpn değerlerine göre ÇN ve KN sınıflandırması Tablo 2.3'de yer almaktadır.



Şekil 2.5 3x3'lük ve 5x5'lik pencere (Aibinu et al., 2010)

$$cpn_{3 \times 3} = \frac{1}{2} \left(\sum_{i=1}^8 |R_n - R_{n+1}| \right) : R_9 = R_1 \quad (3)$$

$$cpn_{5 \times 5} = \frac{1}{2} \left(\sum_{n=1}^{16} |P_n - P_{n+1}| \right) : P_{17} = P_1 \quad (4)$$

$cpn_{3 \times 3}$	$cpn_{5 \times 5}$	Sınıf
3	3	Damar çatallanma noktası (ÇN)
≥ 4	≥ 4	Damar kesişim noktası (KN)

Tablo 2.3 $cpn_{3 \times 3}$ ve $cpn_{5 \times 5}$ Sınıflandırma Tablosu

Calvo et al. (2010) çalışmasında ilk olarak, Zhang'ın yaptığı sınıflandırma ile aday ÇN ve KN tespiti yapmaktadır. Daha sonra bu aday noktaları sırasıyla yerel ve topolojik yönden inceleyerek sınıflandırmaktadır. Yerel özellik incelemesinde, aday noktalar etrafına 3 farklı boyutta pencereler çizerek ÇN ve KN sınıflandırması yapmaktır. Topolojik özellik incelemesinde ise, sınıflandırılan noktaların etrafına daire çizerek iskelet çıkarma işlemi sonucu oluşan, birbirlerine yakın olan ÇN'lerin KN olarak ve birbirlerinden uzak olan KN'lerin 2 farklı ÇN olarak yanlış sınıflandırmasını azaltmaktadır. (Calvo et al., 2010)


Geometrik tabanlı yaklaşımlar, model tabanlı yaklaşımlara göre daha iyi sonuçlar vermektedir. Geometrik tabanlı yaklaşımlarda dezavantajı, görüntü yer alan tüm piksellerin işlenmesinden dolayı işlem karmaşıklığının yüksek olmasıdır.

3. TEMEL KAVRAMLAR

Bu bölümde, öncelikle retina görüntüleri hakkında bilgiler verilerek tez kapsamında kullanılan birtakım temel kavramlardan ana hatlarıyla anlatılmaktadır. Ayrıca bu bölümde, önerilen yöntemde kullanılan retina görüntülerinden oluşan veritabanı ve yöntemin performansını ölçmek için kullanılan Alıcı İşletim Karakteristiği (Receiver Operating Characteristics, ROC) eğrilerinden bahsedilmektedir.

3.1 Retina Görüntüleri

FFA yöntemi kullanılarak elde edilen retina görüntüsüne ait örnek Şekil 3.1'de görülmektedir. Retina tabakasında, retina tabakasını besleyen kan damarları, ışığa ve renge duyarlı görme hücrelerinden meydana gelen, keskin görüntü oluşmasını sağlayan sarı nokta ve görme hücrelerinde oluşan görüntüyü beyne ileten görme sinirleri (optik disk) yer alır.



Şekil 3.1 FFA ile elde edilen renkli retina görüntüsü

Retina damarları optik diskten çıkmakta ve retina tabakası üzerine karmaşık bir şekilde yayılmaktadır. Bu tez kapsamında ele alınan, damarların iki kola ayrılarak çatallandığı ÇN bölgelerine ve üst üste gelerek çakıştığı KN bölgelerine ait örnekler de Şekil 3.1’de gösterilmektedir.

3.2 Görüntü Önışleme

Görüntü önışleme (image preprocessing), sayısal görüntülerin işlenmesi aşamasının ilk basamağında yer almaktadır. Bu basamakta görüntüler, daha iyi sonuçlar elde edilebilmesi için birtakım işlemlerden geçirilmektedir. Gürültü temizleme (noise removal), kontrast iyileştirme (contrast enhancement) ve görüntüdeki bölgelerin birbirinden ayırt edilmesi (image segmentation) görüntü önışleme basamağında kullanılan yaygın yaklaşımlardandır. (Gonzalez and Woods, 2008)

Retina görüntülerinin çekilmesi sırasında retina tabakası üzerine düşen ışığın farklı yoğunlukta olmasından dolayı, elde edilen retina görüntüleri üzerinde birtakım gürültüler ve eşit olmayan aydınlatma (uneven illumination) meydana gelmektedir. Şekil 3.2’de gri tondaki retina görüntüsünde, eşit olmayan aydınlatma sonucu damarlar ile arkaplan arasında oluşan düşük kontrast görülmektedir. Görüntüdeki gürültüleri temizlemek için Ortalama Filtresi (Mean Filter), Medyan Filtresi (Median Filter) ve Gaussian Filtresi gibi bazı filtreleme yöntemleri kullanılmaktadır. Damarlar ile arkaplan arasındaki eşit olmayan aydınlanmayı ortadan kaldırarak, görüntüyü iyileştirmek (image enhancement) ise çeşitli histogram eşitleme (histogram equalization) metotlarından yararlanılmaktadır. (Hoover, 2001)

Şekil 3.3’de, Şekil 3.2’de yer alan gri ton retina görüntüsüne kontrast kısıtlı adaptif histogram eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE) uygulanarak elde edilen retina görüntüsü yer almaktadır. CLAHE uygulanan görüntüde görüldüğü üzere damarlar ve arkaplan arasındaki kontrast artmakta ve damarlar daha belirgin bir şekilde görülmektedir. (Karel, 1994)



Şekil 3.2 Gri ton retina görüntüsü



Şekil 3.3 CLAHE sonucu elde edilen retina görüntüsü

3.3 Yapay Sinir Ağları (YSA)

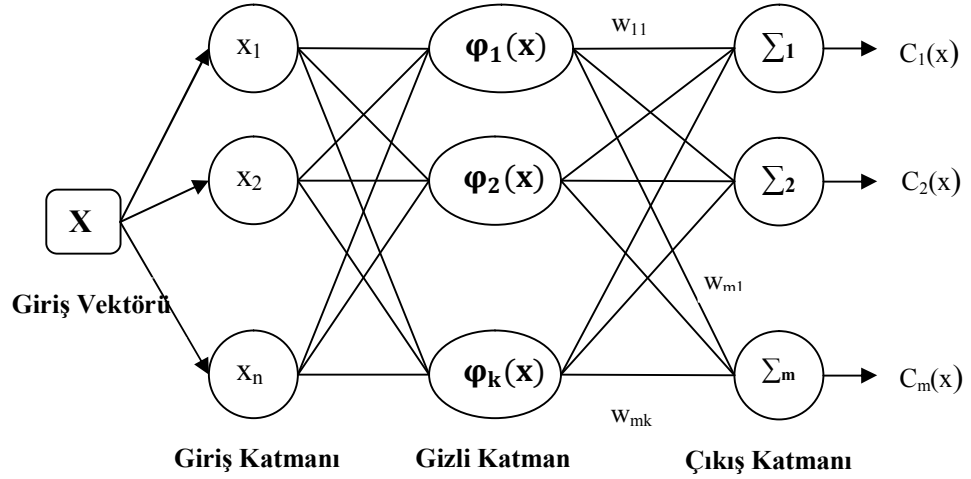
YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer bir şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadırlar. Örneklerden elde ettikleri bilgiler ile kendi deneyimlerini oluşturarak benzer konularda benzer kararları verirler.

YSA birbirine bağlı proses elemanlarından (yapay sinir hücrelerinden) oluşur. Her bağlantının bir ağırlık değeri vardır. YSA'nın sahip olduğu bilgi bu ağırlık değerlerinde saklı olup ağa yayılmıştır. Bir YSA'nın temel görevi, kendisine gösterilen bir girdi setine karşılık gelebilecek bir çıktı seti belirlemektir. Bunu yapabilmesi için ağırlık, kendisine gösterilen girdiler için doğru çıktıları üretecek hale gelmesi gerekmektedir. Ağırlık, girdiler için doğru çıktı üretebilmesi doğru ağırlık değerlerinin bulunmasına bağlıdır. Doğru ağırlıkların bulunması işleme ağırlık eğitilmesi denmektedir. Bu değerler başlangıçta rastgele olarak atanmaktadır. Eğitim sırasında ağa gösterilen her bir örnek için öğrenme kuralına göre ağırlıklar değiştirilerek en doğru değerler bulunmaya çalışılır. Eğitim aşaması bittikten sonra test setindeki örnekler ağa gösterilir. Eğer ağ test setindeki örnekler için doğru cevaplar verirse ağ eğitilmiş kabul edilmektedir.

Ağın bir olayı öğrenmesi o olay için en doğru YSA modelini seçmekle mümkündür. Bir YSA modelinde; ağın topolojisi, kullanılan toplama fonksiyonu, kullanılan aktivasyon fonksiyonu, öğrenme stratejisi ve öğrenme kuralı gibi parametreler yer almaktadır. Günümüze kadar birçok YSA modeli geliştirilmiştir. Çok katmanlı algılayıcı (Multilayer Perceptron, MLP), Öğrenme Vektör Nicelendirmesi (Learning Vector Quantization, LVQ), Adaptif Rezonans Teori (Adaptive Resonance Theory, ART), Özdüzenleyici Haritalar (Self-Organizing Maps, SOM) ve Radyal Tabanlı Fonksiyon (Radial Basis Function, RBF) gibi ağlar en çok kullanılan YSA modellerindedir. (Öztemel, 2003), (Fausett, 1994)

3.3.1 Radyal Tabanlı Fonksiyon Sinir Ağları (RTFSA)

Radyal Tabanlı Fonksiyon (RTF), ilk olarak çok değişkenli gerçek bir interpolasyon probleminin çözümünde ortaya atılmıştır. Bu konudaki ilk çalışmalar Powell (1985) tarafından yapılmıştır. RTF, YSA tasarımında ilk olarak Broomhead ve Lowe (1988) tarafından kullanılmıştır. Moody ve Darken (1989), Renals (1989) ve Poggio ve Grosi (1990) yaptıkları çalışmalar ile RTFSA teorisi, tasarımı ve uygulamaları hakkında önemli katkılarda bulunmuşlardır. RTFSA tasarımı çok boyutlu uzayda eğri uydurma (curve fitting) yaklaşımıdır. Bu nedenle RTFSA'nın eğitimi, çok boyutlu uzayda verilere en iyi uyumu sağlayan uygun bir yüzey bulma problemi olarak ele alınır. RTFSA Şekil 3.4'de görüldüğü üzere üç katmandan oluşmaktadır. İlk katman giriş katmanı olup kaynak düğümlerden (source nodes) oluşur. İkinci katman, yeteri kadar yüksek boyuta sahip ve aktivasyon olarak RTF kullanan gizli katmandır. Üçüncü katman ise giriş katmanından ağa gösterilen bir girdi vektörüne göre ağın çıktısının üretildiği çıkış katmanıdır. RTFSA'da giriş katmanından gizli katmanına doğrusal olmayan, gizli katmandan çıkış katmana doğrusal bir dönüşüm söz konusudur. (Haykin, 1994)



Şekil 3.4 RTFSA ağı tasarımı

RTFSA'nın çalışma ilkesi, giriş katmanından ağa gösterilen girdi vektörüne göre, gizli katmanda uygun genişlik ve merkez değerlerine sahip RTF'ları belirleyerek, çıkış katmanında bu fonksiyonların ürettiği çıktılarının uygun

ağırlık değerleriyle doğrusal birleşimlerini oluşturup girdi vektörüyle çıktı vektörü arasındaki ilişkiyi belirleme süreci olarak açıklanabilir. (Kaynar, 2010) RTFSA ağının çıktısı, ağa gösterilen bir girdi vektörü ile gizli katman merkezleri arasındaki uzaklığın aktivasyon fonksiyonundan geçirilmesi sonucu oluşan çıktının, gizli katman ile çıkış katmanı arasındaki ağırlıklarla çarpılmasıyla oluşan toplamla (5) elde edilir.

$$c_j(x) = \sum_{i=1}^k W_{ji} \varphi(\|x - \mu_i\|) \quad (5)$$

Burada,

- x** : Girdi Vektörü
- $c_j(x)$** : Çıkış katmanındaki j. nöronun çıkışı
- W_{ji}** : i. nöron ile j.nöron arasındaki ağırlık
- μ_i** : Gizli katmandaki i. nöronun merkez vektörü
- σ_i** : Gizli katmandaki i. nöronun yayılım parametresi
- $\varphi()$** : Gizli katman aktivasyon fonksiyonu

Girdi vektörü ile merkez vektörü arasındaki uzaklık genelde öklit mesafesi ile ölçülmektedir. Gizli katmanda; Gaussian, Multi-Quadric, Generalized Multi-Quadric ve Thin Plate Spline gibi farklı RTF aktivasyon fonksiyonları önerilmesine karşın en çok Gaussian fonksiyonu aktivasyon fonksiyonu olarak kullanılmaktadır. Chen et al, (1991), RTF seçiminin ağın performansı üzerinde önemli bir etkisinin olmadığını belirtmişlerdir. (5)'deki aktivasyon fonksiyonu Gaussian fonksiyonu olarak yazılırsa (6) denklemini elde edilir.

$$c_j(x) = \sum_{i=1}^k W_{ji} e^{-\left(\frac{\|x - \mu_i\|^2}{2\sigma_i^2}\right)} \quad (6)$$

RTFSA eğitimi iki aşamada yapılmaktadır. Birinci aşamada gizli katmandaki merkez vektörlerinin ve yayılım parametrelerinin bulunması söz konusudur. İkinci aşamada ise, gizli katman ile çıkış katmanı arasındaki uygun

ağırlık değerlerinin ayarlanması yapılmaktadır. Literatürde her iki aşama için önerilen farklı yaklaşımlar mevcuttur.

Merkez vektörleri ve yayılım parametrelerini tespit etmek için:

- Rastgele seçim
- Öz örgütlemeli merkez seçimi
 - K-ortalama kümeleme (K-Means Clustering)
 - Öz uyarlamalı özellik haritalı kümeleme (SOM)
- Eğiticili seçim (supervised selection)

Gizli katman ile çıkış katmanı arasındaki ağırlıkları ayarlamak için ise

- Sözdere Ters Metodu (Pseudoinverse)
- En küçük ortalama kareler metodu (Least Mean Square, LMS)
- Özyineli en küçük kareler metodu (Recursive Least Square, RLS)
- Ortogonal ortalama kareler metodu (Orthogonal Least Square, OLS)
- En dik iniş metodu (Steepest Descent)
- Hızlı yayılım algoritması (Quick Propagation)

gibi çeşitli yöntemler kullanılmaktadır. (Montazer et al., 2007)

3.4 Retina Görüntü Veritabanı

Literatürde, retina damarlarında ÇN ve KN tespiti için geliştirilen yöntemlerin performanslarını değerlendirmek için hâlihazırda bir veritabanı bulunmamaktadır. Bu sebeple, tez çalışması kapsamında önerilen yöntemin eğitim ve test aşamalarında, literatürde retina damar çıkarsama yöntemlerinde kullanılan DRIVE (Digital Retinal Images for Vessel Extraction) veritabanı kullanılmaktadır. (Staal et al., 2004)

DRIVE veritabanı, 584x565 piksel içeren 40 adet RGB (Red-Green-Blue) retina görüntüsünden oluşmakta olup, retina görüntüleri 20 adet eğitim ve 20 adet

test olmak üzere iki gruba ayrılmıştır. Ayrıca RGB retina görüntülerine ait retina damar çıkarsama metodlarının performansını ölçmede kullanılan, uzmanlar tarafından elle çizilmiş altın standart (gold standart) retina görüntüleri de yer almaktadır. Bu tez çalışmasında, DRIVE veritabanında bulunan retina görüntülerinde ÇN ve KN bölgeleri el yordamıyla işaretlenmiştir. İşaretlenen 40 adet retina görüntüsünden, 30 adet retina görüntüsü RTFSA'yı eğitmek için geriye kalan 10 adet retina görüntüsü ise test etmek üzere iki gruba ayrılmıştır.

3.5 ROC Eğrileri

ROC eğrileri, sınıflandırıcıları performanslarına dayalı olarak görselleştirmek, düzenlemek ve seçmek için kullanılan bir tekniktir. Genellikle tıbbi karar alma süreçlerinde kullanılmasının yanında, son yıllarda makine öğrenmesi ve veri madenciliği gibi araştırma konularında da etkin bir şekilde kullanılmaktadır. (Fawcett, 2006)

Pozitif sınıf p , negatif sınıf ise n ile temsil edilmek üzere sadece iki sınıftan oluşan bir ikili sınıflandırma problemi (binary classifier) göz önünde bulundurulduğunda, problemde yer alan örnekler (instance) p veya n sınıflarından birine haritalanmaktadır. İkili sınıflandırmada, verilen bir örnek için Tablo 3.1'de de görüldüğü gibi dört farklı durum söz konusudur. Verilen örneğin gerçek değerinin pozitif olduğu (p) durumda; eğer sınıflandırma sonucu da pozitif (p') ise sonuç doğru pozitif olarak (True Positive, TP), sınıflandırma sonucu negatif (n') ise sonuç yanlış negatif (False Negative, FN) olarak adlandırılır. Örneğin gerçek değerinin negatif (n) olduğu durumda; eğer sınıflandırma sonucu da negatif (n') ise sonuç doğru negatif (True Negative, TN) olarak, sınıflandırma sonucu pozitif (p') ise sonuç yanlış pozitif (False Positive, FP) olarak isimlendirilir. (Fawcett, 2006)

		Örnek Gerçek Değeri		Toplam
		p	n	
Sınıflandırma Sonucu Değeri	p'	True Positive (TP)	False Positive (FP)	P'
	n'	False Negative (FN)	True Negative (TN)	N'
Toplam		P	N	

Tablo 3.1 Sınıflandırıcıdan elde edilebilecek sonuçlar

ROC eğrisi, doğru pozitif oranı (True Positive Rate, TPR) ile yanlış pozitif oranı (False Positive Rate, FPR) kullanılarak çizilen iki boyutlu bir grafikdir. TPR, tüm pozitif örnekler arasından pozitif olarak sınıflandırılan (doğru sınıflandırma) örneklerin oranını (7) , FPR ise tüm negatif örnekler arasından pozitif olarak sınıflandırılan (yanlış sınıflandırma) örneklerin oranını (8) göstermektedir. Sınıflandırmanın doğruluk oranı ise (Accuracy, ACC) doğru olarak sınıflandırılan örneklerin tüm örneklere oranı (9) ile hesaplanmaktadır.


$$TPR = \frac{TP}{P} \quad (7)$$

$$FPR = \frac{FP}{N} \quad (8)$$

$$ACC = \frac{TP + TN}{P + N} \quad (9)$$

Şekil 3.5’de beş farklı sınıflandırma metoduna ait ROC eğrisi örneği yer almaktadır. ROC eğrisi üzerinde (0,1) noktası mükemmel sınıflandırmayı (perfect classification) göstermektedir. Bu noktada, tüm örnekler doğru olarak sınıflandırılmıştır. ROC uzayındaki köşegen çizgisinin üstünde kalan alanlar iyi sınıflandırmayı, altında kalan alanlar ise kötü sınıflandırmayı temsil etmektedir. Şekil 3.5’de yer alan beş farklı sınıflandırmadan D en iyi sınıflandırma, E en kötü

sınıflandırma ve C ise %50 başarı oranına sahip sınıflandırma olarak yer almaktadır.



Şekil 3.5 Örnek bir ROC grafiği (Fawcett, 2006)

4. ÖNERİLEN YÖNTEM

Bu bölümde, retina damarlarında ÇN ve KN tespit edilmesine yönelik, tez çalışması kapsamında geliştirilen yöntem detaylı bir şekilde anlatılacaktır. Öncelikle retina görüntülerinde yer alan gürültüleri ortadan kaldırmak ve damarlar ile arkaplan arasındaki aydınlatmayı eşitlemek için retina görüntüleri önışlemeden geçirilmektedir. Daha sonra, önışlemeden geçirilen retina görüntülerinde, ÇN ve KN içeren bölgelerden, TBA kullanılarak öznitelik vektörleri elde edilmektedir. Son olarak da elde edilen öznitelik vektörleri RTFSA'ya beslenerek ÇN ve KN tespit edilmektedir.

4.1 Görüntü Önışleme

Retina görüntülerinin elde edilmesi sırasında, retina tabakası üzerine düşen ışığın farklı yoğunlukta olmasından dolayı birtakım gürültüler ve damarlar ile arkaplan arasındaki eşit olmayan aydınlatma (uneven illumination) meydana gelmektedir. Bu çalışmanın görüntü önışleme aşamasında, gürültüleri ortadan kaldırmak için Ortalama Filtre (Mean Filter), retina damarları ile arkaplan arasındaki eşit olmayan aydınlatmayı eşitlemek için ise Arkaplan Homojenleştirme (Background Homogenization) yöntemi kullanılmaktadır. (2011)

4.1.1 Gürültü Temizleme


Sayısal görüntülerin alınması esnasında, cihazların görüntüyü hatalı bir şekilde kaydetmesinden veya aydınlatma gibi çevresel faktörlerden dolayı görüntülerde bazı gürültüler oluşmaktadır. Ortalama Filtresi, görüntü işleme uygulamalarında gürültü kaldırmak için kullanılan en basit ve en yaygın yöntemdir. Bu yöntemin genel amacı, görüntü üzerinde yer alan her bir pikselin değerini, önceden belirlenmiş bir pencere içerisinde yer alan komşu piksellere ait değerlerin ortalaması ile değiştirerek, pikseller arasında yer alan keskin geçişleri (sharp transition) yumuşatmaktır. Böylece pikseller arasında yer alan büyük parlaklık farkları azaltılarak gürültü temizlenmiş olur. Aritmetik ortalama, geometrik ortalama, harmonik ortalama ve kontraharmonik ortalama piksel

değerlerinin ortalamasını hesaplamak için kullanılan matematiksel ortalamalardır. (Gonzalez and Wood, 2008)

Bu çalışmada, retina görüntülerinde yer alan gürültüleri kaldırmak için 5x5'lik aritmetik ortalama filtresi kullanılmıştır. Bu işlemde, görüntüdeki her bir piksel 5x5'lik pencerenin merkezine yerleştirilmekte ve merkez pikselin yoğunluk değeri, pencere içerisinde yer alan 25 adet pikselin yoğunluk değerinin aritmetik ortalaması olacak şekilde değiştirilmektedir. Şekil 4.1'de işlenmemiş gri ton retina görüntüsü, Şekil 4.2'de bu görüntüye aritmetik ortalama filtresinin uygulanması sonucu elde edilen retina görüntüsü yer almaktadır.




Şekil 4.1 İşlenmemiş Gri Ton Retina Görüntüsü



Şekil 4.2 5x5'lik Aritmetik Ortalama Filtre Sonucu Elde Edilen Retina Görüntüsü

4.1.2 Aydınlatma Eşitleme

Retina görüntülerinde, damarlar ile artalan (background) arasında yer alan eşit olmayan aydınlatmayı ortadan kaldırmak için Marin et al. (2011) tarafından önerilen artalan homojenleştirme yöntemi kullanılmaktadır. İlk olarak bir önceki aşamada 5x5'lik aritmetik ortalama filtreden geçirilerek gürültü temizleme işlemi yapılan görüntü, 69x69'luk aritmetik ortalama filtreden geçirilerek Şekil 4.3'de görüldüğü üzere yeni bir artalan görüntüsü oluşturulmaktadır. Filtrenin sonucu olarak artalan görüntüsünde retina damarları kaybolmaktadır. Burada, filtrenin görüntü maskesinin dışına taşıdığı yerlerde aritmetik ortalama, sadece maske içerisinde kalan piksel yoğunluk değerleri kullanılarak hesaplanmıştır.



Şekil 4.3 Artalan retina görüntüsü

İkinci aşamada, gürültü temizleme işlemi yapılan retina görüntüsünden artalan retina görüntüsü çıkarılmaktadır. Çıkarılma sonucu elde edilen görüntüdeki piksel yoğunluk değerleri, [0-255] arası yoğunluk değerlerine doğrusal olarak dönüştürülerek, Şekil 4.4'de görüldüğü üzere gölge düzeltilmiş (shade-corrected) retina görüntüsü elde edilmektedir.



Şekil 4.4 Gölge düzeltilmiş retina görüntüsü

Artalan ile damarlar arasındaki eşit olmayan aydınlatma bir önceki aşamada eşitlenerek gölge düzeltilmiş retina görüntüsü oluşturulmasına rağmen, retina görüntülerinin elde edilmesi sırasında meydana gelen farklı ortam şartlarından dolayı, gölge düzeltilmiş retina görüntüleri de kendi aralarında farklı aydınlatmaya sahip olmaktadır. Bu farklılığı azaltmak için, gölge düzeltilmiş retina görüntüsüne (10) ve (11)'deki işlemler uygulanarak homojen retina görüntüsü elde edilmektedir.

$$g_{output} = \begin{cases} 0, & g < 0 \text{ ise} \\ 255, & g > 0 \text{ ise} \\ g, & \text{aksi takdirde} \end{cases} \quad (10)$$

$$g = g_{input} + 128 - g_{input_max} \quad (11)$$

G_{input} ve G_{output} sırasıyla gölge düzeltilmiş ve artalan homojenleştirilmiş retina görüntülerinde piksel değerlerinin yoğunluk değerlerini göstermektedir. G_{input_max} ise, gölge düzeltilmiş resimde en fazla sayıda bulunan gri seviye yoğunluk değerini göstermektedir. Bu işlemler sonucunda, gölge düzeltilmiş retina görüntüsü üzerinde artalana ait G_{input_max} yoğunluk değerine sahip pikseller 128 yoğunluk değerine sahip olacak şekilde ayarlanmaktadır. Böylece artalan homojenleştirilen retina görüntülerinde, aydınlatma nedeniyle farklılık gösteren artalan pikselleri bu yoğunluk değeri etrafında standartlaştırılmaktadır. Şekil 4.5'te görüntü önışleme sonucunda elde edilen artalan homojenleştirilmiş retina görüntüsü görülmektedir.




Şekil 4.5 Artalan homojenleştirilen retina görüntüsü

Gürültü temizleme ve aydınlatma eşitleme metotları, retina görüntüleri veritabanındaki tüm görüntülere uygulanmaktadır. Böylelikle retina görüntü veritabanında yer alan resimler gürültüden arındırılmış ve artalan ile damarlar arasındaki aydınlatma eşitlenerek tüm görüntülerin standart bir yapıya sahip olmaları sağlanmıştır.

4.2 Öznitelik Çıkarımı (Feature Extraction)

Bu aşamada, önişlemeden geçirilen retina görüntülerinde damarlar üzerinde yer alan ÇN ve KN içeren bölgeleri temsil eden öznitelikler çıkarılmaktadır. Bu amaç doğrultusunda ilk olarak, görüntü veritabanında daha önceden işaretlenmiş olan ÇN ve KN içeren bölgeler Şekil 4.6'da görüldüğü üzere 25x25'lik boyutta olacak şekilde elde edilmektedir. Bölge boyutunun 25x25'lik seçilmesinin sebebi, retina damarlarının ortalama kalınlığının 13 piksel olmasıdır. Böylece bölge görüntüsünün merkezinde yer alan bir tipik nokta rahatlıkla tespit edilebilmektedir.

Elde edilen bu bölgelerden öznitelik çıkarmak için Temel Bileşenler Analizi (TBA) kullanılmaktadır. TBA veya diğer adıyla Karhunen-Loeve Transformu, birbirleriyle yüksek ilişkiye sahip çok değişkenli verilerin boyutunun, gerçek veriler içerisinde var olan ilişkinin mümkün olduğunca korunarak indirgenmesinde ve içerisindeki desenlerin ortaya çıkarılmasında kullanılan bir analiz yöntemidir. (Cinsdikici et al., 2007) Retina görüntülerinde ÇN ve KN tespit edilmesine yönelik TBA ile öznitelik çıkarımı ilk defa bu tez çalışmasında kullanılmakta olup öznitelik çıkarım işlemi aşağıda anlatılmaktadır.



Şekil 4.6 ÇN, KN ve damar içeren bölgeler. (a) ÇN bölgesi, (b) KN bölgesi, (c) Damar bölgesi

$N \times N$ 'lik boyuta sahip M adet ÇN ve KN içeren bölge görüntülerinin (B), ortalaması alınarak (12) ortalama bölge görüntüsü (μ) bulunur. Daha sonra her bir bölge görüntüsünden, ortalama bölge görüntüsü çıkarılarak (13) yeni bölge

görüntüleri (S) elde edilir. Çıkarılma işlemi sonucu, bölge görüntülerde yer alan ortak özelliklerin azaltılarak bölgeler arası farklılıkların yer alması sağlanmıştır.

$$\mu = \frac{1}{M} \times \sum_{i=1}^M B_i \quad (12)$$

$$S_i = B_i - \mu \quad (13)$$

Ortalama çıkartılan $N \times N$ 'lik bölge görüntüleri, $N^2 \times 1$ 'lik vektörlere dönüştürülerek her bir satırda bir bölge görüntüsü olacak şekilde (14) $M \times N^2$ 'lik bölge görüntü matrisi (I) oluşturulur.

$$I = \begin{bmatrix} S_1(1,1) & \cdots & S_1(N,N) \\ \vdots & \ddots & \vdots \\ S_M(1,1) & \cdots & S_M(N,N) \end{bmatrix} \quad (14)$$

I matrisinin, kovaryans matrisi hesaplanarak (15) özvektörler (V) ve özdeğerler (λ) elde edilir (16). Elde edilen özdeğerler büyükten küçüğe sıralanarak, sıralı özdeğerlere karşılık özvektörlerden ilk k tanesi seçilerek özvektörler matrisi (W) oluşturulur. (Deneysel çalışmalarda k 5, 10, 15 ve 20 olarak seçilmiştir.) Bu seçim işlemi sonucu giriş uzayının boyutu (N^2) düşürülmüş olur. (15 boyutlu girdi vektörü, giriş uzayının %85'ini kapsamaktadır. Böylece 625 boyutlu girdi vektörünün boyutu 15'e indirgenmektedir)

$$C = I^T I \quad (15)$$

$$C V = \lambda V \quad (16)$$

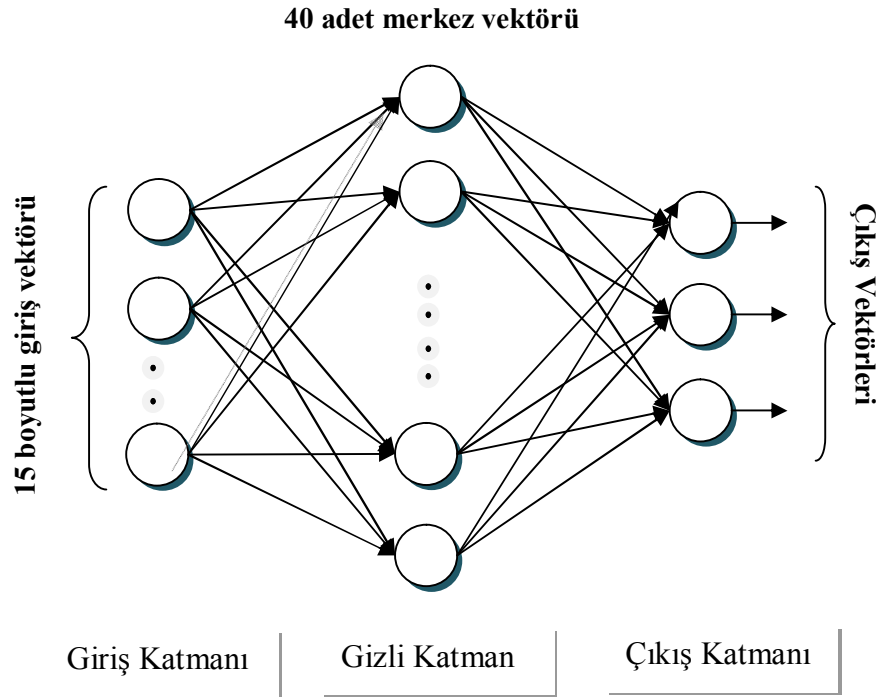
Son olarak, bölge görüntülerinin öznelikleri (Γ_i) boyutu indirgenmiş özvektörler (W) üzerine izdüşüm alınarak (17) hesaplanır.

$$\Gamma_i = W_i \times S_i \quad (17)$$

Bu basamak sonucunda RTFSA'ya beslemek üzere, retina görüntülerinden çıkarılan 25x25'lik bölge görüntülerine ait öznelik vektörleri elde edilmiştir.

4.3 RTFSA ile ÇN ve KN Bölgesi Tespiti

Bu basamakta, bir önceki basamakta elde edilen bölgelere ait öznelikler, RTFSA kullanılarak sınıflandırılmaktadır. Şekil 4.7'de görüldüğü üç katmanlı mimariye sahip RTFSA'da giriş katmanı 15, gizli katman 40, çıkış katmanı ise 3 düğümden oluşmaktadır. Bu düğüm sayıları, deneysel testlerde elde edilen sonuçlara göre seçilmiş olup bir sonraki bölümde kullanılan parametrelere göre yöntemin başarısı detaylı bir şekilde anlatılmaktadır. Tablo 4.1'de önerilen yöntemin en yüksek performansı gösterdiği optimum parametreler yer almaktadır.



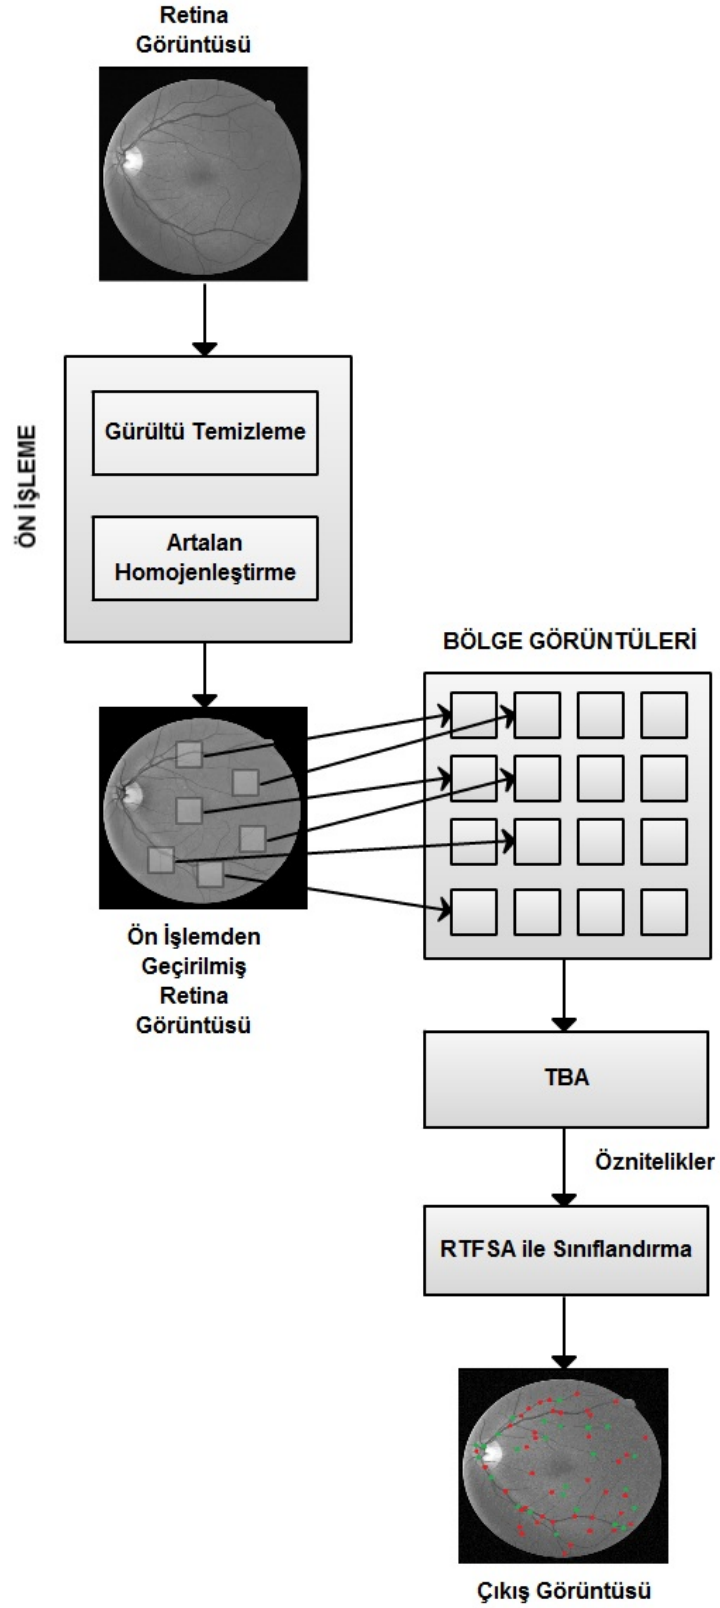
Şekil 4.7 Yöntemde kullanılan üç katmanlı RTFSA mimarisi

Parametre	Değer
Öznitelik Vektörü	15
Gizli Katman Sayısı	40
RTFSA merkez seçimi	K-Ortalama
RTFSA öğrenme algoritması	RLS

Tablo 4.1 RTFSA optimum parametreleri

4.4 Önerilen Yöntemin Genel İşleyişi

Yöntem, Şekil 4.8’de görüldüğü üzere üç aşamadan oluşmaktadır. Görüntü ön işleme aşaması olan ilk aşamada, eğitim ve test setinde bulunan retina görüntülerinde, aritmetik ortalama filtresi kullanılarak gürültü arındırılmakta ve artalan homojenleştirme metodu kullanılarak eşit olmayan aydınlatma azaltılmaktadır. İkinci aşamada, görüntü ön işlemden geçirilen ve eğitim setinde yer alan retina görüntülerinde daha önceden elle işaretlenen ÇN, KN ve retina artalan içeren 25x25’lik bölge görüntülerine TBA uygulanarak öznitelik vektörleri elde edilmektedir. Üçüncü aşamada ilk olarak, eğitim setindeki retina görüntülerinde yer alan bölge görüntülerine ait öznitelik vektörleri kullanılarak RTFSA eğitilmekte, daha sonra ise test setinde yer alan retina görüntüleri kullanılarak RTFSA test edilmektedir. Üçüncü aşamadaki RTFSA eğitimi ve testine ilişkin detaylar bir sonraki bölümde anlatılmaktadır.



Şekil 4.8 Önerilen Yöntemin İşleyiş Şeması

5. PERFORMANS

Bu bölümde, önerilen yöntem üzerinde yapılan deneysel çalışmalar anlatılmakta ve bu çalışmaların performansları incelenmektedir. RTFSA'yı eğitmek ve test etmek için, Bölüm 3.4'te tanıtılan DRIVE veritabanı kullanılmıştır. DRIVE veritabanında yer alan 40 retina görüntüsünden 30 tanesi RTFSA'yı eğitmek, geriye kalan 10 tanesi ise test etmek için ayrılmıştır. Önerilen yöntem, görüntü tabanlı yaklaşım (image-based approach) ve bölge tabanlı yaklaşım (region-based approach) olmak üzere iki farklı şekilde eğitilerek test edilmiştir. Görüntü tabanlı testte, test görüntüleri tümüyle RTFSA'ya beslenerek ÇN, KN ve retina artalan bölgesi tespit edilmekte ve sınıflandırılmaktadır. Bölge tabanlı testte ise, eğitim görüntülerinden sadece ÇN ve KN içeren bölgeler RTFSA'ya beslenerek, ÇN ve KN sınıflandırması yapılmaktadır.

Tez çalışması kapsamında yapılan tüm yazılımlar Matlab (V.7.12.0.635) programı ile geliştirilmiş olup, Intel Core 2 Duo 2.4 GHz işlemciye ve 2 GB belleğe sahip kişisel bilgisayar üzerinde yapılmıştır.

5.1 Görüntü Tabanlı Yaklaşım

Görüntü tabanlı yaklaşımın eğitim aşamasında; eğitim setinde yer alan 30 adet retina görüntüsünde önceden elle işaretlenen 25x25'lik 1500 adet ÇN bölgesi, 1500 adet KN bölgesi ve 1500 adet retina artalan bölgesi olmak üzere toplamda 4500 adet bölge görüntüsüne ait öznitelik vektörleri ile RTFSA eğitilmektedir. Test aşamasında ise, test setinde yer alan 10 adet retina görüntüsü üzerinde 25x25'lik pencere pikseller üzerinde kaydırılarak ÇN, KN ve retina artalan bölge sınıflandırması yapılmaktadır.

Görüntü tabanlı yaklaşımda yapılan deneysel çalışmalarda, TBA işlemi sonucu büyükten küçüğe sıralanan özdeğerlere ait en büyük ilk 5, 10, 15 ve 20 adet özvektör seçilerek öznitelik vektörleri oluşturulmaktadır. Daha sonra bu öznitelikler, rastgele ve K-ortalama algoritması ile seçilen 20, 30, 40 ve 50 gizli katman merkez vektörüne sahip RTFSA'da, LMS ve RLS algoritmaları kullanılarak eğitilmektedir. TBA ile boyutları 5, 10, 15 ve 20'ye düşürülen girdi

vektörlerinin eğitilmesi ile oluşan sonuçlar (9) ile hesaplanmakta ve sırasıyla Tablo 5.1, Tablo 5.2, Tablo 5.3 ve Tablo 5.4'te verilmektedir.

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	71.98	73.82	73.24	73.41	73.22	71.38	72.14	74.78
	K-Ortalama	71.22	74.32	73.44	74.87	72.84	73.32	72.22	74.32

Tablo 5.1 TBA ile boyutu 5'e düşürülen girdilerin RTFSA'ya beslenmesiyle elde edilen sonuçlar

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	70.72	75.02	75.54	75.51	75.42	73.24	77.89	78.32
	K-Ortalama	76.22	78.20	74.42	76.69	74.32	78.08	76.32	72.67

Tablo 5.2 TBA ile boyutu 10'a düşürülen girdilerin RTFSA'ya beslenmesiyle elde edilen sonuçlar

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	70.22	74.41	74.35	76.04	75.09	77.82	74.41	76.22
	K-Ortalama	76.52	77.45	77.59	78.01	75.09	78.45	76.77	78.32

Tablo 5.3 TBA ile boyutu 15'e düşürülen girdilerin RTFSA'ya beslenmesiyle elde edilen sonuçlar

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	69.25	69.76	72.57	74.44	77.67	77.82	75.02	77.38
	K-Ortalama	69.72	71.44	75.42	77.32	77.92	77.32	77.41	78.32

Tablo 5.4 TBA ile boyutu 20'ye düşürülen girdilerin RTFSA'ya beslenmesiyle elde edilen sonuçlar

Tablolardaki veriler incelendiğinde görüntü tabanlı yaklaşımın en iyi performansı %78.45 olup, TBA ile elde edilen 15 boyutlu girdi vektörü ile K-Ortalama kullanılarak seçilen 40 adet gizli katman merkez vektörünün RLS algoritmasıyla eğitilmesi sonucu elde edilmiştir. Tablo 5.5'de en iyi performansa sahip deneysel çalışmanın test görüntüleri üzerindeki sonuçları yer almaktadır. Sonuçlar incelendiğinde ÇN bölgelerinin KN bölgelerine göre daha yüksek yüzdeyle tespit edildiği görülmüştür. Bunun sebebi, damar üzerinde yer alan KN bölgelerinin, ÇN bölgelerine göre çok daha farklı şekillerde yer almasıdır. Yine önerilen yöntemde FPR'nin TPR'ye göre daha düşük olduğu gözlemlenmektedir. Bunun anlamı damar üzerinde ÇN veya KN içermeyen bölgelerin de ÇN veya KN olarak (false positive) tespit edilmesidir.

Görüntü	ÇN			KN			ORTALAMA		
	TPR	FPR	ACC(%)	TPR	FPR	ACC	TPR	FPR	ACC(%)
1	0,85	0,21	81,86	0,83	0,27	76,91	0,84	0,24	79,33
2	0,83	0,20	80,9	0,78	0,26	75,29	0,81	0,23	78,06
3	0,80	0,21	79,63	0,77	0,27	74,67	0,79	0,24	77,07
4	0,81	0,20	80,62	0,81	0,26	76,69	0,81	0,23	78,56
5	0,83	0,22	80,32	0,81	0,28	75,47	0,82	0,25	77,82
6	0,85	0,21	81,8	0,83	0,27	77,21	0,84	0,24	79,44
7	0,82	0,24	78,6	0,79	0,30	73,47	0,81	0,27	75,95
8	0,84	0,21	81,1	0,81	0,27	76,38	0,83	0,24	78,67
9	0,84	0,20	82	0,82	0,25	77,45	0,83	0,22	79,66
10	0,84	0,19	81,97	0,83	0,25	78,17	0,83	0,22	79,99
ORTALAMA	0,83	0,21	80,88	0,81	0,27	76,17	0,82	0,24	78,45

Tablo 5.5 En iyi performansın test görüntüler üzerindeki sonuçları

5.2 Bölge Tabanlı Yaklaşım

Bölge tabanlı yaklaşımın eğitim aşamasında; eğitim setinde yer alan 30 adet retina görüntüsünde önceden elle işaretlenen 25x25'lik 1500 adet ÇN bölgesi ve 1500 adet KN bölgesi olmak üzere toplamda 3000 adet bölge görüntüsüne ait öznitelik vektörleri ile RTFSA eğitilmektedir. Test aşamasında ise, test setinde yer alan 10 adet retina görüntüsü üzerinde daha önceden elle işaretlenen 25x25'lik 600 adet ÇN bölgesi ve 600 adet KN bölgesi olmak üzere toplamda 1200 adet bölge görüntüsü kullanılarak ÇN ve KN sınıflandırması yapılmaktadır.

Bölge tabanlı yaklaşımda yapılan deneysel çalışmalarda, TBA işlemi sonucu büyükten küçüğe sıralanan özdeğerlere ait en büyük ilk 5, 10, 15 ve 20

adet özvektör seçilerek öznitelik vektörleri oluşturulmaktadır. Daha sonra bu öznitelikler, rastgele ve K-ortalama algoritması ile seçilen 20, 30, 40 ve 50 gizli katman merkez vektörüne sahip RTFSA’da, LMS ve RLS algoritmaları kullanılarak eğitilmektedir. TBA ile boyutları 5, 10, 15 ve 20’ye düşürülen girdi vektörlerinin eğitilmesi ile oluşan sonuçlar (9) ile hesaplanmakta ve sırasıyla Tablo 5.6, Tablo 5.7, Tablo 5.8 ve Tablo 5.9’da verilmektedir.

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	91.08	93.44	91.04	92.64	93.71	93.42	90.09	92.07
	K-Ortalama	93.44	93.78	92.74	93.09	93,51	92.78	91.09	92.71

Tablo 5.6 TBA ile boyutu 5’e düşürülen girdi vektörlerinin RTFSA’ya beslenmesiyle elde edilen sonuçlar

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	91.02	92.44	92.07	91.81	93.22	93.56	91.42	90.77
	K-Ortalama	90.44	93.65	91.97	92.73	91.24	93.27	92.71	93.01

Tablo 5.7 TBA ile boyutu 10’a düşürülen girdi vektörlerinin RTFSA’ya beslenmesiyle elde edilen sonuçlar

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	92.97	91.05	92.75	93.71	92.79	93.08	91.02	90.62
	K-Ortalama	92.44	93.65	90.44	93.27	91.23	93.51	90.55	91.27

Tablo 5.8 TBA ile boyutu 15'e düşürülen girdi vektörlerinin RTFSA'ya beslenmesiyle elde edilen sonuçlar

		Gizli Katman Merkez Sayısı							
		20		30		40		50	
		LMS	RLS	LMS	RLS	LMS	RLS	LMS	RLS
Merkez Seçimi	Rastgele	88.27	89.24	90.45	91.21	93.74	92.71	90.45	93.27
	K-Ortalama	90.57	92.34	92.78	93.45	91.71	92.05	92.33	91.01

Tablo 5.9 TBA ile boyutu 20'ye düşürülen girdi vektörlerinin RTFSA'ya beslenmesiyle elde edilen sonuçlar

Tablolardaki veriler incelendiğinde bölge tabanlı yöntemde en iyi performans %93.78 olup, TBA ile elde edilen 5 boyutlu girdi vektörü ile K-Ortalama kullanılarak seçilen 20 adet gizli katman merkez vektörünün RLS algoritmasıyla eğitilmesi sonucu elde edilmiştir.

6. SONUÇ ve TARTIŞMA

Bu tez çalışmasında, retina görüntülerinde damarların çatallanma ve kesişim noktalarının tespit edilmesine yönelik başarılı bir yöntem geliştirilmesi amaçlanmaktadır. Geliştirilen yöntem üç aşamadan oluşmakta olup her aşamada en etkin olduğu düşünülen algoritmalar ve parametreler seçilmektedir.

Görüntü ön işleme adı verilen ilk basamak, iki aşamadan oluşmaktadır. Birinci aşamada retina görüntüleri istenmeyen gürültüleri azaltmak için aritmetik ortalama filtreden geçirilmektedir. İkinci basamakta ise, retina görüntülerinin elde edilmesi sırasında ortam şartlarından dolayı görüntü üzerinde meydana gelen eşit olmayan aydınlatma artalan homojenleştirme yöntemiyle eşitlenmektedir. Ayrıca artalan homojenleştirme metodunun son basamağında uygulanan işlemler sayesinde, retina görüntülerinin artalan piksel yoğunlukları ortak bir nokta etrafında standartlaştırılarak retina görüntüleri arasındaki farklılıklar azaltılmaktadır. Öznitelik çıkarımı olarak adlandırılan ikinci basamakta, ön işlemden geçirilen retina görüntülerinde yer alan ÇN, KN ve diğer retina artalan bölgelerini ayırt edecek öznitelikler TBA kullanılarak elde edilmektedir. Son aşamada ise öznitelik vektörleri ile RTFSA ile eğitilerek bölge tespiti yapılmaktadır. Bu tez çalışmasında, ÇN ve KN bölgelerinden TBA kullanarak öznitelik çıkarımı ile RTFSA kullanarak sınıflandırma yapma ÇN ve KN tespit etme probleminde daha önce kullanılmamış yöntemlerdir.

Bu tez çalışmasında, ÇN ve KN bölgelerinin otomatik olarak tespit ederek sınıflandırmayı hedefleyen görüntü tabanlı yaklaşımın başarısı %78.45 olarak ölçülmüştür. Bu başarı oranı literatürde yer alan metotların başarıları ile karşılaştırıldığında ortalama bir başarı olarak yer almasına karşın, TPR oranı diğer önerilen metotlara göre daha yüksektir. Manuel olarak çıkarılmış ÇN ve KN bölgelerini sınıflandırmayı hedefleyen bölge tabanlı yaklaşımın başarısı ise %93.78 gibi yüksek bir orandır.

Bu tez çalışmasında, görüntü tabanlı yaklaşımın başarı oranını arttırmak için ÇN ve KN bölgelerinin yüksek doğrulukla sınıflandıran bölge tabanlı yaklaşımdan yararlanılabilir. Bu sebeple, retina görüntüleri üzerinde olası ÇN ve

KN bölgeleri tespit eden yöntemler geliştirilebilir. Bunun yanında, ÇN ve KN bölgelerinde öznitelik çıkarmak için farklı istatistiksel yöntemler veya şekil tabanlı yaklaşımlar kullanılabilir. Son olarak, farklı yapay sinir ağları kullanılarak sınıflandırma yapılabilir.

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), 81-89pp.
- 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*, 355-360pp.
- 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, 711-718pp.
- 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, *Comput Methods Programs Biomed.*, 103(1), 28-38pp.
- 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*, 125-138pp.
- Chanwimaluang T. and Fan G.,** 2002, An efficient blood vessel detection algorithm for retinal images using local entropy thresholding, *ISCAS*, 21-24pp.
- 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), 302-309pp.
- Cinsdikici M., Uğur A., Tunali T.,** 2007, **Automatic Number Plate Information Extraction and Recognition for Intelligent Transportation System**, *Imaging Science Journal*, 102-113pp.
- Fausett L.,** 1994, *Fundamentals of Neural Networks. Prentice Hall.*

KAYNAKLAR DİZİNİ (devam)

- Fawcett T.**, 2006, An introduction to ROC analysis, *Pattern Recognition Letters* 27, 861–874pp.
- 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 *Proc. Of the International Conference of the IEEE Engineering in Medicine and Biology Society*, 1620-1623pp.
- Gonzalez RC and Woods RE.**, 2008, Digital image processing , 3rd ed., *Upper Saddle River (NJ): Prentice Hall*; ISBN:9780131687288
- Haykin S.**, 1994, Neural Networks. A Comprehensive Foundation. *Macmillan, New York, NY*.
- Hoover A., Kouznetsova V. and Goldbaum M.H.**, 2001, Locating blood vessels in retinal images by piece-wise threshold probing of a matched filter response, *IEEE Transactions in Medical Imaging* 19 (3), 203–210pp
- Iqbal M.I., Aibinu A.M., Tijani I.B., Nilsson M. and Salami M.J.E.**, 2008 **Cross point detection using fuzzy logic and neural network**, in: *Proceedings of the International Conference on Computer and Communication Engineering, Malaysia, 2008*, 241-246pp.
- Karel Z.**, 1994, Contrast limited adaptive histogram equalization, *Graphics gems IV, Academic Press Professional, Inc.*, 474–485pp.
- Kaynar O., Taştan S. ve Demirkoparan F.**, 2010, Ham petrol fiyatlarının yapay sinir ağları ile tahmini, *Ege Academic Review*
- Marin D., Aquino A., Gegundez-Arias M.E. and 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 Transaction on Medical Imaging*, 146-158pp.
- Montazer G.A., Sabzevari R. and Khatir H.G.**, 2007, Improvement of learning algorithms for RBF neural Networks in a helicopter sound identification system, *In Proceedings of Neurocomputing*, 167-173pp.

KAYNAKLAR DİZİNİ (devam)

Mortensen E., Morse B., Barrett W. and Udupa J., 1992, Adaptive boundary detection using live-wire two dimensional dynamic programming, *Computers in Cardiology*, 635-638pp.

Öztemel E., 2003, Yapay Sinir Ağları, *Papatya Yayınları*, İstanbul

Staal J., Abramoff M.D., Niemeijer M., Viergever M.A. and van Ginneken B., 2004, Ridge-based vessel segmentation in color images of the retina, *IEEE Transactions on Medical Imaging*, 23(4), 501-509pp.

Zhang E., Zhang Y. and Zhang T., 2002, Automatic retinal image registration based on blood vessels feature point, *Machine Learning and Cybernetics, Proceedings 2002 International Conference on.*

Zhou L., Rzeszotarski M.S., Singerman J. And Chokreff J.M., 1994, The detection and quantification of retinopathy using digital angiograms, *IEEE Transaction On Medical Imaging*, 619-626pp.

ÖZGEÇMİŞ**Cihat ÇETİNKAYA**

Adres: Manavkuyu Mahallesi Dumlupınar Caddesi No:140/1

Bayraklı/İzmir

E-Posta: cihat.cetinkaya@ege.edu.tr, cetinkayacihat@gmail.com

Kişisel Bilgiler

Uyruk : T.C.
Doğum Yeri : Ankara
Doğum Tarihi : 17/10/1986

Eğitim Durumu

Yüksek Lisans : 2008 – , Ege Üniversitesi, Uluslararası, Bilgisayar Enstitüsü
Lisans : 2004 – 2008, Pamukkale Üniversitesi, Bilgisayar Mühendisliği
Lise : 1997 – 2004, Iğdır MEV Anadolu Lisesi

Yabancı Dil

İngilizce : Çok İyi
Almanca : Başlangıç

İş Denevimi

2010 - : Ege Üniversitesi, Uluslararası Bilgisayar Enstitüsü
Araştırma Görevlisi
2009 - 2010 : Muğla Üniversitesi, Bilgisayar Mühendisliği Bölümü
Araştırma Görevlisi
2007 - 2009 : Pamukkale Üniversitesi, Bilgi İşlem Daire Başkanlığı
Yazılım Geliştirme Uzmanı

EKLER

Ek -1 İngilizce – Türkçe Sözlük

Adaptive Resonance Theory	Adaptif Rezonans Teori
Background	Artalan
Background Homogenization	Artalan Homojenleştirme
Binary Classifier	İkili Sınıflandırma
Binary Image	İkili Görüntü
Contrast Enhancement	Kontrast İyileştirme
Contrast Limited Adaptive Histogram Equalization	Kontrast Kısıtlı Adaptif Histogram Eşitleme
Cross Point Number	Kesişme Nokta Sayısı
Curve Fitting	Eğri Uydurma
False Negative	Yanlış Negatif
False Positive	Yanlış Pozitif
False Positive Rate	Yanlış Pozitif Oranı
Gold Standart	Altın Standart
Histogram Equalization	Histogram Eşitleme
Image Enhancement	Görüntü İyileştirme
Image Preprocessing	Görüntü Ön işleme
Image Segmentation	Görüntü Bölütleme
Instance	Örnek
K-Means Clustering	K-Ortalama Kümeleme
Learning Vector Quantization	Öğrenme Vektör Nicelendirmesi
Least Mean Square	En Küçük Ortalama Kareler

EKLER (devam)

Mean Filter	Ortalama Filtresi
Median Filter	Medyan Filtresi
Multilayer Perceptron	Çok Katmanlı Algılayıcı
Noise Removal	Gürültü Temizleme
Orthogonal Least Square	Dik Ortalama Kareler
Perfect Classification	Mükemmel Sınıflandırma
Principal Component Analysis	Temel Bileşenler Analizi
Quick Propagation	Hızlı Yayılım Algoritması
Radial Basis Function	Radyal Tabanlı Fonksiyon
Radial Basis Function Neural Network	Radyal Temelli Fonksiyon Sinir Ağı
Receiver Operating Characteristic	Alıcı İşletim Karakteristiği
Recursive Least Square	Özyineli En Küçük Kareler
Self-Organizing Maps	Özdüzenleyici Haritalar
Shade-Corrected	Gölge Düzeltilmiş
Sharp Transition	Keskin Geçiş
Skeletonization	İskeleti Çıkarsama
Source Node	Kaynak Düğüm
Steepest Descent	En Dik İniş Metodu
Supervised Selection	Eğiticili Seçim
Thining	İnceltme
Thresholding	Eşikleme

EKLER (devam)

True Negative	Dođru Negatif
True Positive	Dođru Pozitif
True Positive Rate	Dođru Pozitif Oranı
Uneven Illumination	Eđit Olmayan Aydınlatma
Vessel Extraction	Damar ıkarsama