

Denetimli Sınıflandırma Yöntemleri ile Retinal Kan Damarı Bölütleme

Retinal Blood Vessel Extraction with Supervised Classification Methods

Zafer YAVUZ¹, Cemal KÖSE²

¹Karadeniz Teknik Üniversitesi, Trabzon/TURKEY, zaferyavuz@ktu.edu.tr

²Karadeniz Teknik Üniversitesi, Trabzon/TURKEY, ckose@ktu.edu.tr

Öz

Retinal fundus görüntülerde kan damarı bölütleme işlemi, diyabetik retinopati, glukoma gibi bazı hastalıkların teşhisi ve ön tanısı için önemli bir aşamadır. Bu çalışmada renkli retinal fundus görüntülerde damar bölütleme amacıyla yeni öznelikler ile farklı denetimli sınıflandırma yöntemleri kullanılmış ve elde edilen sonuçlar süre ve sınıflandırma başarısı açısından değerlendirilmiştir. Sınıflandırma işleminden önce kan damarı ve retina arkaplan piksellerini birbirinden ayıracak şekilde damar iyileştirmeye dayalı piksel tabanlı öznelik çıkarma işlemi gerçekleştirilir. Daha sonra çıkarılan bu özellikler kullanılarak sınıflandırıcı yardımıyla piksellerin kan damarına ya da arkaplana ait olup olmadığına karar verilir. Denetimli sınıflandırma yöntemi olarak k en yakın komşular, Naive Bayes sınıflandırıcı ve destek vektör makineleri kullanılmaktadır. Performans değerlendirme için internet üzerinde erişilebilir olan STARE ve DRIVE veri tabanları kullanılmaktadır. Elde edilen başarımların değerleri ve işlem süreleri karşılaştırılmıştır. Sonuç olarak Naive Bayes sınıflandırma yönteminin en hızlı ve destek vektör makineleri yönteminin ise diğerlerine göre daha yüksek başarı sağladığı gözlenmiştir.

Anahtar Sözcükler: Denetimli sınıflandırma, k en yakın komşular, Naive Bayes, destek vektör makineleri, öznelik çıkarma, damar bölütleme, kan damarı iyileştirme.

Abstract

Blood vessel segmentation in retinal fundus images is the first step for the diagnosis and treatment of diseases such as diabetic retinopathy, glaucoma and age related macular degeneration. In this paper, several supervised classification methods with adapted features are used in order to extract blood vessels in color retinal fundus images. Furthermore, the obtained results are compared against each other in terms of computational durations and classification accuracy. Firstly, a pixel based feature extraction method is performed in which features are extracted from the enhanced images of the vessel. Afterwards, a classification stage is performed to decide whether a pixel belongs to a vessel or the retinal background using these features. K-nearest neighbors, Naive Bayes and support vector machines are used as supervised classification mechanisms. Retinal fundus images from two publicly available database STARE and DRIVE are used for performance evaluation. Obtained performance values and computation time results are compared. As a result, it is observed that Naive Bayes classifier is the fastest method and support vector machines method has the highest accuracy.

Keywords : Supervised classification, k nearest neighbors, Naive Bayes, support vector machines, feature extraction, blood vessel enhancement, vessel segmentation.

Gönderim ve kabul tarihi : 25.08.2015-29.09.2015

1. Giriş

Günümüzde bilgisayarlı görüntü işleme tekniklerinin medikal alanda kullanımı giderek artmaktadır. Retinal fundus görüntü analizi de bu alanlardan biridir. Retinal görüntülerdeki kan damarlarından elde edilen bazı bilgiler, sistematik bazı hastalıkların teşhis ve tedavisinde göz doktorlarına yardımcı olabilmektedirler. Örneğin diyabetik retinopati, glukoma, makula dejenerasyonu gibi bazı hastalıklar retinal kan damarlarının genişliği, rengi, yansıtma özelliği, eğriliği ve kan damarlarının anormal dallanması gibi sonuçlara neden olabilmektedirler. Ayrıca kan damarlarındaki kanamalı alanlar, damar çapı daralmaları veya genişlemeleri retinal hastalıklar hakkında önemli bilgiler içermektedir. Bu nedenle kan damarlarının otomatik bölütlenmesi geliştirilecek yardımcı tanı ve teşhis sistemi için ilk ve en önemli aşamadır [1].


Literatürde çeşitli retinal kan damarı bölütleme çalışmaları önerilmiştir. Bu çalışmalar genel olarak 6 kategori altında incelenmektedir: 1) örüntü tanımaya dayalı yöntemler, 2) uyum süzgeçleme yöntemleri (2B uyum süzgeci, Gabor süzgeci, Frangi süzgeci), 3) morfolojik yöntemler, 4) damar izlemeye dayalı yöntemler, 5) çok ölçekli yaklaşımlar, 6) model tabanlı yaklaşımlar [2].

Örüntü tanımaya dayalı yöntemler denetimli ve denetimsiz sınıflandırma yöntemleri olarak bilinirler. Retinal kan damarları ve retina arkaplanını birbirinden ayıracak şekilde görüntüdeki her bir piksel için öznitelik çıkarıldıktan sonra bir denetmen yardımıyla sınıflandırıcı eğitilir. Daha sonra bu öznitelikler kullanılarak her bir piksel damar ya da arkaplan olarak sınıflandırılır. Literatürde damar bölütleme amacıyla k-en yakın komşular [3] sınıflandırıcı, Bayesgil sınıflandırıcı [4], destek vektör makineleri [5], yapay sinir ağları [6] gibi yöntemler yaygın olarak kullanılan denetimli yöntemlerdir. Denetimsiz sınıflandırma yöntemlerinde ise her bir pikselin öznitelikleri çıkarıldıktan sonra herhangi bir eğitim işlemi gerçekleştirilmeden görüntü pikselleri kümeleme (öbekleme) işlemine tabi tutulur. Elde edilen kümeler değerlendirilerek damar ya da arkaplan pikselleri tespit edilir. K-ortalama ve Bulanık C-ortalama kümeleme yöntemleri [7] de denetimsiz örüntü tanıma yöntemleri olarak bilinmektedirler.

Uyum süzgecine dayalı yöntemlerde kan damarı profiline uygun 2 boyutlu bir çekirdek uyum süzgeci oluşturulur. Bu süzgeç farklı yönlerde tüm görüntü

ile evrişim işlemine tabi tutulur ve her piksel için maksimum değer seçilerek kan damarlarının iyileştirildiği uyum süzgeç tepkisi elde edilir. Bu yaklaşımla yapılan ilk çalışma Chaudhuri ve arkadaşları tarafından 1989 yılında Gauss fonksiyonu kullanılarak gerçekleştirilmiştir. Kullanılan süzgeç 15^0 aralıklarla 12 farklı yönde uygulanmış ve her bir piksel için maksimum değer seçilmiştir. Süzgeç çıktısı Otsu algoritması kullanılarak siyah-beyaz görüntüye dönüştürülür ve bu şekilde damar bölütlemesi gerçekleştirilmiştir [1]. Benzer bir süzgeci Hoover ve arkadaşları kullanmış ve siyah-beyaz görüntüye dönüşüm için özel bir bölge büyütme yöntemi uygulamışlardır [8]. Benzer yöntemi kullanan ve damar profiline modellemek için Gauss fonksiyonu yerine parametreleri ayarlanabilen Gabor süzgeci kullanan çalışmalar da mevcuttur [7], [9]. Morfolojik yöntemler bir dizi matematiksel morfolojik yöntemlerin görüntü işleme teknikleri ile uygulanması ve kan damarlarının iyileştirilmesi esasına dayanır [10], [11]. Damar izlemeye dayalı yöntemlerde yerel damar özellikleri kullanılarak kan damarlarının izlenmesi gerçekleştirilir. Bu tür yöntemlerde tüm damarları izlemek yerine bir ya da iki damar parçasının izlenmesi esas alınmaktadır. Damar bölütlemenin ötesinde damar özelliklerinin (damar kalınlığı, yönü gibi) ölçülmesi amacıyla bu yöntemler kullanılmaktadır [12], [13]. Çok ölçekli yaklaşımlar kan damarlarının kalınlıklarının değişiklik göstermesi nedeniyle kullanılan yöntemlerdendir. Farklı kalınlıklardaki damarları iyileştirme amacıyla farklı süzgeç ya da yöntemler geliştirilmektedir [14], [15]. Model tabanlı yaklaşımlarda kan damarlarına ilişkin modeller kullanılarak damar bölütleme işlemi gerçekleştirilmektedir. Bu yöntemlerde damar profili modellenenmekte ya da aktif sınır modeli gibi yaklaşımlar kullanılmaktadır [16], [17].

Bu çalışmada örüntü tanımaya dayalı yöntemler olan denetimli sınıflandırma yöntemleri kullanılarak damar bölütleme işlemi gerçekleştirilmektedir. Sınıflandırıcı için kullanılan öznitelikler farklı damar iyileştirme yöntemleri ile elde edilmektedir. Performans değerlendirme adımıyla sınıflandırma başarımları değerleri karşılaştırılmakta ve elde edilen damar bölütleme sonuçları verilmektedir.



Şekil-1: Retinal fundus kamera (solda) ve DRIVE veri tabanından alınan örnek bir görüntü (sağda)

2. Yöntem

Çalışmada renkli retinal fundus görüntüleri kullanılarak denetimli sınıflandırma yöntemleri ile kan damarı bölütleme işlemi gerçekleştirilmektedir. Sınıflandırıcı olarak k-en yakın komşular, Naive Bayes ve destek vektör makineleri kullanılmaktadır. Sınıflandırma işlemi için kullanılacak öznitelik vektörleri öznitelik çıkarma adımında damar iyileştirme süzgeçleri (uyum süzgeci, Gabor süzgeci, Frangi süzgeci, vs...) sonucunda elde edilmektedir. Performans iyileştirmek amacıyla yalıtılmış pikseller elenmekte ve damarlar arasında kalan boşluklar belli bir kıstasa göre doldurulmaktadır. Son durumda elde edilen siyah-beyaz damar görüntüsünde performans değerlendirilmesi yapılmaktadır. Sistemin çalışma şeması Şekil 2'de verilmektedir.

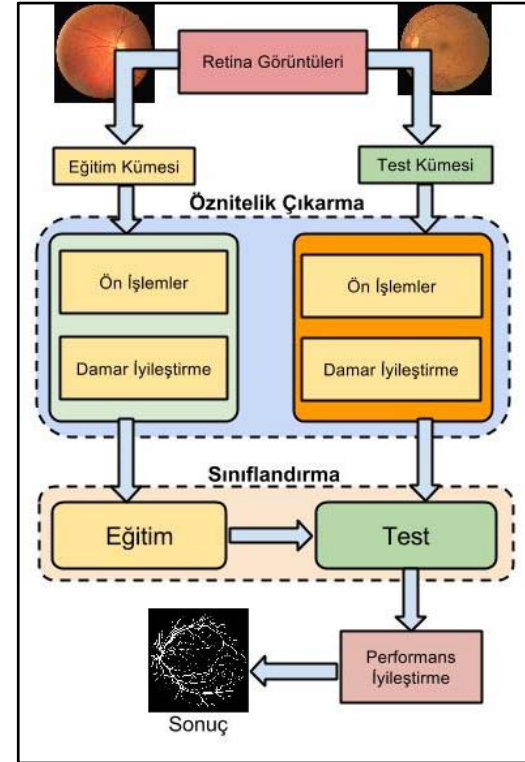
2.1. Kullanılan Materyal

Çalışmada, internet ortamında erişilebilir olan **ST**ructured Analysis of the **RE**tina (STARE) [18] ve **D**igital Retinal Images for Vessel Extraction (DRIVE) [19] veri tabanlarından elde edilen retinal fundus görüntüleri kullanılmıştır. STARE veri tabanında 605x700 çözünürlükte TopCon TRV-50 fundus kamerası ile 35° görüş açısı ile elde edilmiş 400 adet görüntü bulunmaktadır. Bu görüntülerden 20 adet retinal görüntü seçilerek damar bölütleme amacıyla kullanılması için özel bir görüntü kümesi oluşturulmuştur. Seçilen 20 adet görüntünün 10 adedi hastalıklı ve 10 adedi de sağlıklı bireylere ait fundus görüntülerden oluşmaktadır. STARE veri tabanında performans değerlendirilmesi yapmak için iki uzman gözlemci tarafından manüel olarak etiketlenmiş ikili damar görüntüleri (hedef görüntüler) de bulunmaktadır. DRIVE veri tabanında ise Canon CR5 fundus kamerası ile 45° görüş açısı ile elde edilmiş 768x584 çözünürlükte 40 adet görüntü

bulunmaktadır. Bu görüntüler 20 adet eğitim için ve 20 adet test için olmak üzere iki görüntü kümesine bölünmüştür. DRIVE veri tabanında kan damarı bölütleme performansını ölçmek için iki uzman gözlemci tarafından manüel olarak etiketlenmiş ikili damar görüntüleri (hedef görüntüler) ve retina bölgesini maskeleyerek kullanılacak maske görüntüleri bulunmaktadır. Şekil 1'de DRIVE veri tabanından alınan örnek bir görüntü verilmiştir.

2.2. Öznitelik Çıkarma 2.2.1. Ön İşlemler

Damar iyileştirme işleminde kan damarları ve arkaplanın birbirinden daha iyi ayırt edilebilmesi amacıyla bir takım ön işlemler yapılmaktadır. Bu adımda sırasıyla retina bölgesi seçme, retina bölgesi genişletme, gri seviye dönüşüm ve damar orta-şerit yansımaları eleme işlemleri uygulanmaktadır.



Şekil-2: Geliştirilen sistemin çalışma şeması.

Retinal görüntüler çoğunlukla dikdörtgen biçimindedir. Retina bölgesi ise dairesel yapıya yakın biçimde olduğundan retinaya ait olmayan alanlardaki

piksellerin tespit edilerek elenmesi gerekmektedir. Bu işlem fazladan yapılacak işlemleri azaltabileceği gibi retina çevresinde oluşacak hatalı tespitlerin önüne geçmek için de kullanılabilir. Renk kanalları (Kırmızı-K, Yeşil-Y, Mavi-M) arasındaki hata farkından ve bu renk kanallarının ortalamasından yararlanılarak retina bölgesi için bir maske oluşturulabilmektedir [20]. Kullanılan DRIVE veri tabanında eğitilmiş bir uzman tarafından manuel olarak oluşturulan maske görüntüleri yer almaktadır. Ancak STARE veri tabanları için bu şekilde manuel olarak oluşturulmuş maske görüntüleri bulunmamaktadır. Bu yöntem STARE veri tabanında bulunan görüntüleri uygulanarak maske görüntüleri elde edilmiştir. Ayrıca yöntemin doğruluğunu test etmek için DRIVE veri tabanındaki görüntüler için de yöntem uygulanmıştır. Elde edilen maske görüntüleri ile veri tabanında bulunan manuel maske görüntüleri karşılaştırılmış ve ortalama %99 un üzerinde bir doğruluk değeri elde edilmiştir.

Retina bölgesi seçiminden sonra retina çevresindeki hatalı tespitleri elemek için retina bölgesi genişletme işlemi gerçekleştirilir. Bu amaçla öncelikle retina kenarındaki pikseller kümesi elde edilir. Bu küme retina kenarı olarak isimlendirilir. Daha önce çıkarılan maske kullanılarak elde edilen bu kümedeki her bir pikselin retina bölgesindeki piksellere ve retina dışındaki piksellere komşuluğu vardır. İlk olarak yatay genişletme yapılır. Retina kenar pikselleri merkez kabul edilerek her bir pikselin sağ ya da solundaki n adet pikselin yansıyan değerleri alınır. İkinci olarak benzer işlemlerle düşey genişletme yapılır. Burada $n = 3$ piksel olarak seçilmiştir. Bu işlem retina kenarlarındaki hatalı tespitleri retina dışına itmek amacıyla uygulanmaktadır.

Retina bölgesi genişletmeden sonra gri seviye dönüşüm işlemi gerçekleştirilmektedir. Görüntü işleme ve bilgisayarla görme alanlarında kullanılan birçok gri seviye dönüşüm yöntemleri vardır. Bu yöntemler genelleştirildiğinde Kırmızı (K), Yeşil (Y) ve Mavi (M) bileşen değerlerinin belli katsayılarla çarpılıp toplanması ile gri seviye değeri elde edilebilir. Bu işlem Eşitlik 1'de verilen bağıntı ile temsil edilebilir.


$$P = c_k * K + c_y * Y + c_m * M \quad (1)$$

Burada P gri seviye parlaklık değerini, K, Y ve M renk bileşen değerlerini, c_k , c_y ve c_m değerleri ise sırasıyla KYM renk kanallarının çarpılacağı katsayıları göstermektedir. Gri seviye değeri

normalleştirilmiş olarak elde edilmesi için renk kanalları katsayılarının toplamının 1 olmasına dikkat edilmelidir ($c_k + c_y + c_m = 1$).

Retinal kan damarı bölütleme çalışmalarında damar ve arkaplan arasında en yüksek karşıtlık sağladığı için çoğunlukla renkli görüntünün yeşil bileşeni kullanılmaktadır. Bunun anlamı Eşitlik 1'de yer alan c_k ve c_m katsayılarının 0 olarak ve c_y katsayısı ise 1 olarak alınmıştır ($c_k=0$, $c_y=1$ ve $c_m=0$). Ancak uygulamada elde edilen başarımların daha da arttıracak şekilde damar ile arkaplan arasındaki karşıtlık oranı daha da artırılabilir. Bu çalışmada önerilen yöntemde daha yüksek karşıtlık sağlamak için yeşil bileşen yerine KYM bileşenleri özel katsayılarla çarpılıp toplanarak elde edilen parlaklık değeri kullanılmaktadır. En iyi performans verdiği için $c_k=0.1$, $c_y=0.7$ ve $c_m=0.2$ olarak seçilmiştir.

Retinal kan damarlarının ışığı düşük yansıtma özelliğinden dolayı retina arkaplanına göre daha koyu görünürler. Ancak bazı durumlarda kan damarlarının tam ortasında açık renkte bir ya da iki piksel kalınlığında yansımadan kaynaklanan parlak şeritler gözlenmektedir. Bu duruma damar orta-şerit yansıma etkisi denir. Damar orta-şerit yansıma etkisini kaldırmak için görüntünün gri seviye parlaklık değerlerinden oluşan P görüntüsü, r piksel çapında disk biçiminde bir yapı elemanı kullanılarak gri seviye morfolojik açma işlemine tabi tutulur. Burada r değerinin büyük tutulması birbirine yakın kan damarlarını birleştirme riski doğurması sebebiyle minimum seçilerek $r = 3$ olarak alınmıştır. Şekil 3'te, damar orta yansımalarının giderilmesine bir örnek verilmiştir.



Şekil-3: Damar orta yansımalarının giderilmesi.

2.2.2. Damar İyileştirme

Sınıflandırma işlemi için kullanılacak veri kümesi (eğitim ve test) öznel çıkarma işlemi ile elde edilmektedir. Çalışmada kullanılan öznel çıkarmalar farklı dönüşüm ve süzgeçlerle elde edilen iyileştirilmiş damar görüntülerinin parlaklık değerleri olarak alınmaktadır. Bu amaçla 2 boyutlu uyum süzgeci, Gabor süzgeci, Frangi süzgeci, adaptif histogram eşitleme ve top-hat dönüşüm yöntemleri kullanılmaktadır.

Görüntü iyileştirme amacıyla sıkça kullanılan yaklaşımlardan biri histogram eşitleme yöntemidir. Histogram eşitleme yönteminde görüntünün tüm piksel parlaklık dağılımı dikkate alınarak kontrast iyileştirme yapılmaktadır. Ancak histogram eşitlemede tüm görüntünün parlaklık dağılımı dikkate alındığından yerel özelliklerin farklılık gösterdiği bazı görüntüler için beklenen iyileştirme sağlanamamaktadır. Bu amaçla görüntünün yerel özelliklerini de dikkate alan histogram eşitleme teknikleri geliştirilmiştir. Adaptif histogram eşitleme yerel veri üzerinde işlem yapan değiştirilmiş bir histogram eşitleme yöntemidir [21]. Çalışmada ön işlem sonucunda elde edilen görüntü üzerinde adaptif histogram eşitleme yöntemi uygulanmıştır. Elde edilen görüntü sonraki aşamalarda uygulanacak süzgeç ve görüntüler için girdi olarak kullanılmaktadır. Adaptif histogram eşitleme yönteminin sonucu Şekil 4.a'da verilmektedir.

Retinal kan damarı profili Gauss fonksiyonuna benzetilmektedir. Bu nedenle Gauss fonksiyonu kullanılarak 15x15 boyutunda uyum süzgeci için bir çekirdek oluşturulmaktadır. Kullanılan çekirdek 15 derece aralıklarla döndürülerek 12 farklı çekirdek kümesi elde edilmiştir. Elde edilen kümesinin 12 farklı yöndeki her bir elemanı yukarıda bahsi geçen adaptif histogram eşitleme sonucu üzerinde evrişim (katlama) yapılarak 12 farklı katlanmış görüntü elde edilir. Dolayısıyla her bir piksel için 12 farklı değer elde edilmiş olur. Kan damarına en iyi uyum sağladığından bu değerlerden maksimum olanı seçilir. Şekil 4.b'de uyum süzgecinin evrişim sonucu verilmektedir.

Gabor süzgeci, görüntü işleme ve örüntü tanıma gibi alanlarda özellik çıkarma, görüntü iyileştirme gibi amaçlarla kullanılan yaygın bir yöntemdir. İki boyutlu Gauss fonksiyonun trigonometrik kosinüs fonksiyonu ile çarpılması sonucu elde edilir. Gabor çekirdeği, istenen açı ve dalga boyu ayarlanarak retinal fundus görüntülerdeki kan damarları

iyileştirilebilmektedir. Eşitlik 2'de Gabor çekirdeğinin genel denklemi verilmektedir.

$$g(x, y) = \exp\left(-\frac{x'^2 + y'^2}{2\sigma^2}\right) \cdot \cos\left(2\pi \cdot \frac{x'}{\lambda}\right) \quad (2)$$

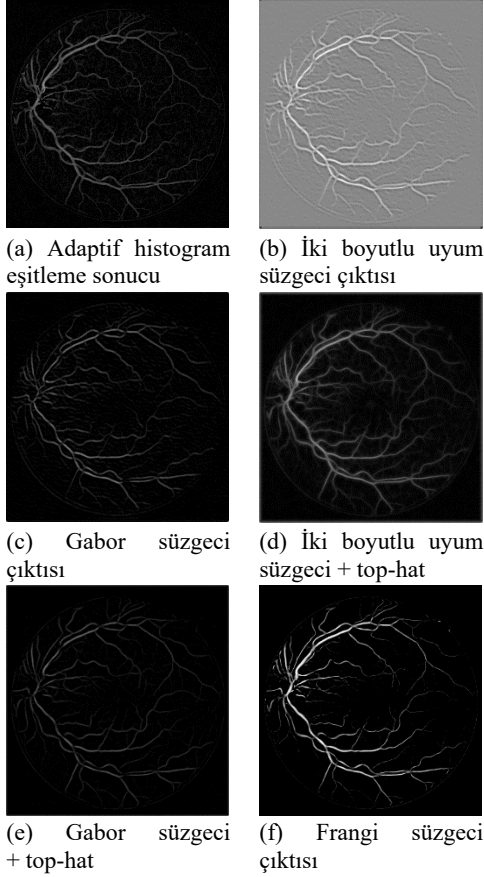
Burada $x' = x \cdot \cos\theta + y \cdot \sin\theta$ ve $y' = -x \cdot \sin\theta + y \cdot \cos\theta$ şeklinde hesaplanmaktadır. g Gabor çekirdek fonksiyonunu, θ dönme açısını, λ Gabor çekirdeğinin dalga boyunu ve γ Gabor çekirdeğinin en/boy oranını vermektedir. σ ise aranan örüntünün ölçeğini (genişliğini) temsil etmektedir. Gabor çekirdeği de 15 derece aralıklarla döndürülerek 12 farklı Gabor çekirdek kümesi elde edilir. Uyum süzgecinin uygulanmasına benzer şekilde Gabor çekirdek kümesindeki her bir çekirdek adaptif histogram eşitleme sonucuna uygulanır ve her piksel için elde edilecek değerlerin maksimumu Gabor süzgeç çıktısı olarak elde edilir. Şekil 4.c'de Gabor süzgeci çıktısı verilmektedir.

Top-hat dönüşümü, görüntü işlemede parlaklık seviyeleri arasındaki karşıtlığı arttırmak için kullanılan morfolojik bir yöntemdir. Orijinal görüntüden morfolojik açma işlemine tabi tutulmuş görüntünün çıkarılması sonucu elde edilir. Bu dönüşüm iki boyutlu uyum ya da Gabor süzgecinden sonra uygulanarak damar bölütleme performansı önemli ölçüde arttırılmaktadır. Eşitlik 3 top-hat dönüşümünün genel denklemini göstermektedir.

$$\text{top}(g) = g - (g \circ nB) \quad (3)$$

Burada g görüntüyü, B yapı elemanını ve n top-hat dönüşümünün ölçek seviyesini göstermektedir. Uygulamada $n = 5$ ve disk biçimli yarıçapı 5 piksel olarak seçilen yapı elemanı kullanılmıştır. Şekil 4.c ve Şekil 4.d sırasıyla uyum süzgeç çıktısının ve Gabor süzgeç çıktısının top-hat dönüşüm sonuçlarını göstermektedir.

Damar iyileştirme işlemi için kullanılan bir diğer yöntem Frangi ve arkadaşları tarafından önerilmiştir [14]. Yöntemde kan damarlarının damar olma yerel olasılığını belirlemek için çok ölçekli bir yöntem önermişlerdir. Yöntemde görüntünün kısmi 2. türev bileşenlerinden oluşan Hessian matrisin öz değerleri kullanılmaktadır. Böylece görüntüde damara benzeyen yapılar iyileştirilmektedir. Eşitlik 4'te Hessian matrisin yapısı verilmektedir.



Şekil-4: Damar iyileştirme işlemi (öznitelik çıkarımı) sonuçları.

$$H = \begin{bmatrix} I_{xx} & I_{xy} \\ I_{yx} & I_{yy} \end{bmatrix} \quad (4)$$

Burada H, hessian matrisi, I_{xx} , I_{xy} , I_{yx} ve I_{yy} bileşenleri ise görüntünün kısmi 2. türevlerini göstermektedir. Bir görüntünün 2. türevinin alınması, o görüntüyü s ölçeğindeki (standart sapma) Gauss fonksiyonunun 2. türevi ile evrişim (katlama) işlemine sokularak gerçekleştirilebilir. Hessian matriste yer alan kısmi 2. türev bileşenleri de bu yöntemle hesaplanmaktadır. Daha sonra Hessian matrisin öz değerleri λ_1 ve λ_2 hesaplanır. Hesaplanan öz değerler $|\lambda_1| < |\lambda_2|$ şeklinde sıralanır. Kan damarlarının λ_2 öz değerinin işaretine göre hesaplanan damarlılık değeri Eşitlik 5'te verilen bağıntı ile hesaplanarak frangi süzgeç çıktısı elde edilmektedir [14].

$$V(s) = \begin{cases} 0 & \lambda_2 > 0, \\ \exp\left(-\frac{R_B^2}{2\beta^2}\right)\left(1 - \exp\left(-\frac{s^2}{2c^2}\right)\right) & \lambda_2 \leq 0, \end{cases} \quad (5)$$

$$R_B = \frac{|\lambda_1|}{|\lambda_2|}, \quad S = \sqrt{\lambda_1^2 + \lambda_2^2} \quad (6)$$

Burada $V(s)$ değeri, s ölçeğinde Gauss fonksiyonu kullanılarak elde edilen öz değerlerle hesaplanan damarlılık değeri olarak ele alınmaktadır. β ve c sırasıyla R_B ve S değerlerinin hassasiyetlerini ayarlamak için kullanılan parametre değerleridir. Uygulamada $s = 1, 2, 3, 4, 5$ olarak seçilmiştir. Her piksel için maksimum $V(s)$ değeri seçilerek iyileştirilmiş kan damarı görüntüsü elde edilmektedir. Şekil 4.f'de Frangi süzgeci ile elde edilen iyileştirme sonucu gösterilmektedir.

2.3. Sınıflandırma

Önceki bölümde öznitelik çıkarım işlemleri gerçekleştirilmiştir. Bu bölümde çıkarılan öznitelikler kullanılarak test görüntülerindeki her bir pikselin damar ya da arkaplan olarak sınıflandırılması işlemi gerçekleştirilmektedir. Sınıflandırma işlemi için STARE ve DRIVE veri tabanlarında hedef görüntüler kullanılarak eğitim kümesi oluşturulmaktadır. Eğitim kümesi her bir örneğin damar veya arkaplan olarak işaretlendiği öznitelik vektöründen oluşur. Çalışmada üç sınıflandırma yöntemi uygulanmış ve sonuçlar karşılaştırmalı olarak verilmiştir.

Uygulanan ilk sınıflandırma yöntemi k en yakın komşular (k-EYK) sınıflandırma yöntemidir. Yöntemde sınıflandırılacak örneklerin eğitim kümesindeki örneklere benzerlikleri hesaplanarak en yakın k tane komşu örneğe bakılır. Hangi sınıfa ait (damar ya da arkaplan) örnekler daha fazla ise test örneğinin o sınıftan olduğuna karar verilir. Burada k değeri ikili sınıflandırma için tek olarak seçilmelidir. Yöntemin performansı k en yakın komşu sayısı, benzerlik ölçütü ve eğitim kümesindeki örneklerin sayısına bağlı olarak değişebilmektedir [3]. Çalışmada kullanılan k -en yakın komşular sınıflandırıcısının eğitim aşaması k (en yakın komşu sayısı) parametresinin ve en uygun uzaklık ölçütünün belirlenmesi aşamasıdır. Bu amaçla en iyi sonucu veren k değerinin ve uzaklık ölçütünün ne olduğunu bulmak amacıyla yapılan çapraz doğrulama testlerinde k en yakın komşular değeri 11 ve uzaklık ölçütü de öklit uzaklık ölçütü olarak belirlenmiştir. Bu değerler kFold doğrulama tekniği ile elde

edilmiştir. kFold doğrulama tekniğinde kullanılan k değeri ise geleneksel olarak 10 alınmıştır.

Çalışmada kullanılan ikinci sınıflandırma yöntemi örüntü tanıma, veri madenciliği gibi alanlarda yaygın olarak kullanılan Naive Bayes sınıflandırma yöntemidir. Yöntem, koşullu olasılıklar arasında bağıntı kuran Bayes teoremine dayanır [22]. Bir C sınıfının bilinmesi koşulunda x özneliğinin var olma olasılığı ile x özneliğinin bilinmesi koşulunda C sınıfının var olma olasılığı arasında Bayes teoremine göre Eşitlik 7'deki gibi bir bağıntı mevcuttur.

$$P(C_k|x) = \frac{P(C_k) \cdot P(x|C_k)}{P(x)} \quad (7)$$

Naive Bayes sınıflandırıcıda öznelikleri birbirinden bağımsız olduğu kabul edilmektedir. Damar ve arkaplan için iki ayrı koşullu olasılık hesap edilir. Test örneğinin hangi sınıfa ait olduğu Eşitlik 8'de verildiği gibi maksimum koşullu olasılık seçilerek belirlenir.

$$C = \begin{cases} C_1 & P(C_1|x) > P(C_2|x), \\ C_2 & P(C_2|x) > P(C_1|x) \end{cases} \quad (8)$$

Burada C test örneğinin karar verildiği sınıfı, C_1 ve C_2 damar ve arkaplan sınıflarını, $P(C_k|x)$ ise x özneliğinin bilinmesi koşulunda C sınıfının var olma olasılığını temsil etmektedir.

Destek vektör makinesi (DVM), çalışmada uygulanan diğer bir sınıflandırma yöntemidir. DVM, Vapnik tarafından 1995 yılında ortaya atılan denetimli bir sınıflandırma yöntemidir [23]. Yöntemde test örneklerini iki sınıfa ayırmak amacıyla en uygun hiperdüzlemin bulunması amaçlanmaktadır. Eğitim aşamasında sınıfları birbirinden ayıran hiperdüzlemin eğitim örneklerine uzaklığı mümkün olan maksimum düzeyde tutulmaya çalışılır. Yöntemde seçilen öznelilikler ağırlıklı olarak doğrusal karakteristiğe sahip olduğundan ve denemelerde daha yüksek performans elde edildiği için doğrusal çekirdek fonksiyonu kullanılmıştır.

2.4. Performans İyileştirme

Sınıflandırma işleminden sonra çıkarılan siyah-beyaz damar görüntüsü üzerinde hatalı tespit edilen izole damar pikselleri olabilmektedir. Ayrıca gerçekte damara ait olan bazı pikseller de arkaplan olarak işaretlenmektedir.

Elde edilen siyah-beyaz görüntüde toplam piksel alanı küçük bağımsız bölgeler oluşabilmektedir. Bu

bölgeler damar bölütleme performansını etkilediğinden ve damarın bir parçası olma ihtimalleri düşük kabul edildiğinden elenmesi gerekmektedir. Toplam piksel alanı b değerinden az olan bölgeler hatalı tespit edilen bölgeler olarak kabul edilmekte ve bu bölgeler elenmektedir. b değerinin tespit etmek için farklı eşik değerleri uygulanmış ve en iyi performans sonucu $b=14$ olacak şekilde seçilmiştir.

Damar bölütleme işleminden sonra bazı damar bölütleri arasında hatalı tespit nedeniyle aslında damar yapısına ait ancak arkaplan olarak işaretlenen boşluklar olabilmektedir. Yapılacak bir takım sıralı işlemlerden sonra bu boşluklar doldurulmaktadır. Bu işlemde, arkaplan olarak işaretlenmiş bir pikselin komşu piksel sayısı eğer 4 değerinin üzerindeyse bu piksel damar pikseli olarak kabul edilmektedir. Bu işlemlerden sonra nihai damar görüntüsü elde edilmiş olur.

2.5. Deney Sonuçları ve Karşılaştırma

Çalışmada eğitim ve test görüntüleri STARE ve DRIVE veri tabanlarından elde edilmiştir. Öznelik olarak her bir piksel için bölüm 2.2'de anlatılan yöntemlerle 6 adet öznelik çıkarılmıştır. Çıkarılan özneliklerin farklı kombinasyonları daha önce eğitilmiş sınıflandırıcılara sunularak yeni bir damar bölütleme sistemi önerilmiştir. Sınıflandırıcı için gerekli eğitim verisi, eğitim için kullanılacak görüntülerden damar üzerinde olan pikseller seçilerek elde edilmektedir. Burada her bir görüntüdeki damar ve arkaplan piksel sayısı çok fazladır. Bu nedenle bir görüntüden rasgele damar ve arkaplan pikselleri seçilmiştir. Bu şekilde tüm eğitim kümesindeki görüntülerden belirli miktarlarda damar ve arkaplan pikselleri seçilerek sınıflandırıcı için gerekli eğitim verisi oluşturulmaktadır. Sınıflandırmanın adil olması için eğitim verisi rasgele olarak karıştırılmaktadır. Uygulamada her bir görüntüden 100 adet damar pikseli ve 200 adet arkaplan pikseli seçilmiştir. Böylece STARE veri tabanı için 1000 adet damar pikseli ve 2000 adet arkaplan pikseli eğitim örneği olarak alınmıştır. Benzer şekilde DRIVE veri tabanı için 2000 adet damar pikseli ve 4000 adet arkaplan pikseli eğitim örneği olarak alınmıştır. Her bir veri tabanında test için alınan görüntüler eğitim örnekleri kullanılarak sınıflandırılmıştır.

Sınıflandırma performansını ölçmek için farklı öznelik grupları oluşturulmuştur. Bölüm 3.1’de verilen öznelikler şu şekilde temsil edilmektedir.

- F1 : Adaptif histogram eşitleme
- F2 : Uyum süzgeç çıktısı
- F3 : Uyum süzgeci + top-hat dönüşümü
- F4 : Gabor süzgeci
- F5 : Gabor süzgeci + top-hat dönüşümü
- F6 : Frangi süzgeç çıktısı

Performans değerlendirmesi doğruluk (accuracy, DOG), duyarlılık (sensitivity, DUY) ve özgüllük (specificity, OZG) değerlerinin hesaplanması ile yapılmaktadır. Ayrıca sınıflandırma performansını ölçmek için Kappa değeri kullanılmıştır. Eşitlik 9-13’te bu değerlerin hesaplanması gösterilmektedir. Hedef görüntü olarak kullanılan veri tabanlarından (STARE ve DRIVE) elde edilen manuel etiketlenmiş görüntüler (hedef görüntüler) kullanılmıştır. Hedef görüntüde damar üzerinde olan ve tespit sonucunda da damar olarak sınıflandırılan piksellerin sayısı gerçek pozitif (GP), hedef görüntüde arkaplana ait olan ve tespit sonucunda da arkaplan olarak sınıflandırılan piksel sayısı gerçek negatif (GN), hedef görüntüde arkaplana ait olan ancak damar olarak sınıflandırılan piksellerin sayısı yanlış pozitif (YP) ve hedef görüntüde damar üzerinde olan ancak tespit sonucunda arkaplan olarak sınıflandırılan piksellerin sayısı yanlış negatif (YN) olarak ölçüldüğünde performans kıstasları Eşitlik 9-12’de verilmektedir.

$$DUY = \frac{GP}{GP+YN} \times 100 \quad (9)$$

$$OZG = \frac{GN}{GN+YP} \times 100 \quad (10)$$

$$DOG = \frac{GP+DN}{GP+GN+YP+YN} \times 100 \quad (11)$$

$$Kappa = \frac{P(A)-P(E)}{1-P(E)} \quad (12)$$

Burada $P(A)$ değeri, elde edilen sonucun manüel bölütleme ile uyuşma oranını (doğruluk değerini) göstermektedir ve Eşitlik 13’e göre hesaplanmaktadır. $P(E)$ değeri ise beklenen uyuşma olasılığını vermektedir ve Eşitlik 14’e göre hesaplanmaktadır.

$$P(A) = \frac{GP+GN}{P+N} \quad (13)$$

$$P(B) = P_1 * P_2 + (1 - P_1)(1 - P_2) \quad (14)$$

Eşitlik 14’te yer alan oransal değerler

$$P_1 = \frac{((GP + YP)/(P + N))}{((GP + YN)/(P + N))} \quad \text{ve}$$

şeklinde hesaplanmaktadır. Eşitlik 12 ile hesaplanan kappa değeri bölütlenmiş görüntü ile hedef görüntü (manüel etiketlenmiş görüntü) arasındaki benzerlik hakkında bilgi verir ve -1 ile +1 arasında değerler alır. -1 değeri tamamen yanlış sınıflandırma yapıldığını, 0 değeri sınıflandırma işleminin tamamen şans ederi olduğunu ve +1 değeri ise sınıflandırmanın mükemmel yapıldığını gösterir.

Oluşturulan farklı öznelik grupları ayrı ayrı sınıflandırıcılarda test edildiğinde elde edilen performans sonuçları ve test işlemi için görüntü başına geçen işlem zamanı sırasıyla Çizelge 1’de ve Çizelge 2’de verilmektedir. Uygulamada test işlemi STARE veri tabanında test için ayrılan 10 adet görüntü piksellerinin sınıflandırılması için geçen zamanın 10’a bölünmesi ile elde edilmektedir. Yine aynı şekilde DRIVE veri tabanında test için ayrılan 20 adet görüntü piksellerinin sınıflandırılması için geçen zamanın 20’ye bölünmesi ile elde edilmiştir. Çizelge 1’de verilen duyarlılık (DUY), özgüllük (OZG) ve doğruluk (DOG) performans değerleri hem STARE hem de DRIVE veri tabanlarındaki görüntülerden elde edilen ortalama performans değerlerini göstermektedir. Denemelerde farklı öznelik grupları oluşturularak her bir sınıflandırıcıya sunulmuştur. Çizelge 1’de elde edilen en yüksek ortalama performans sonuçları koyu font ile işaretlenmiştir. Buna göre STARE veri tabanında en yüksek doğruluk değeri DVM sınıflandırıcısı ile, DRIVE veri tabanındaki en yüksek doğruluk değeri Naive Bayes yöntemi ile elde edilmektedir.

Sınıflandırma işlemini eğitim ve test olarak birlikte düşündüğümüzde hesaplanan işlem zamanları Çizelge 2’de saniye cinsinden verilmektedir. Uygulama Matlab® 2014a programı ile geliştirilmiştir. Programın çalıştırıldığı bilgisayar Intel® i3-3220 3.3Ghz çift çekirdek işlemciye, 4GB belleğe ve 64 bit Windows® 8.1 işletim sistemine sahiptir. Çizelge 2’de test için verilen süre görüntü başına elde edilen ortalama süredir. Buna göre Naive Bayes sınıflandırma algoritmasının hem eğitim hem de test işleminde en hızlı çalışan yöntem olduğu görülmektedir.

Çizelge-1 : STARE ve DRIVE veri tabanları kullanılarak elde edilen ortalama performans sonuçları.

	Öznitelikler	STARE				DRIVE			
		DUY	OZG	DOG	Kappa	DUY	OZG	DOG	Kappa
K En Yakın Komşuluk	F1	72,9	97,85	96,05	70,85	71,23	96,56	94,35	66,09
	F2	61,53	90,56	88,26	49,87	40,87	98,66	93,61	49,42
	F3	68,53	97,05	94,92	64,1	64,66	97,1	94,26	63,24
	F4	72	96,67	94,92	65,32	66,8	96,7	94,11	63,48
	F5	76,04	96,85	95,3	68,58	72,15	96,85	94,69	67,41
	F6	70,4	97,86	95,85	69,01	65,66	97,81	95,01	66,74
	F1-F6	72,32	97,81	95,96	70,18	66,66	97,72	95,01	67,21
	F1-F2-F3-F4-F5-F6	77,27	97,55	96,06	72,34	66,65	98,05	95,3	68,6
	F2-F4	77,12	96,9	95,43	69,16	63,35	98,07	95,03	66,15
	F3-F5	74,8	97,13	95,47	69	70,99	97,07	94,79	67,46
	F3-F5-F6	75,12	97,36	95,73	70,24	70,83	97,3	94,99	68,31
Naive Bayes	F1	68,21	98,4	96,22	70,03	61,9	98,43	95,26	66,81
	F2	56,51	98,29	95,05	60,93	34,62	99,69	94,02	46,56
	F3	62,01	98,28	95,57	64,91	57,68	98,38	94,83	63,19
	F4	65,77	98,04	95,73	66,53	59,69	98,13	94,8	63,65
	F5	68,7	98,3	96,09	70,24	63,73	98,37	95,35	67,73
	F6	56,36	99,17	96,01	64,22	49,2	99,33	94,98	59,98
	F1-F6	63,2	98,82	96,22	68,08	56,87	98,94	95,29	64,9
	F1-F2-F3-F4-F5-F6	71,46	98,25	96,28	71,84	64,57	98,46	95,5	68,9
	F2-F4	69,69	98,33	96,21	71,13	57,12	98,76	95,13	64,34
	F3-F5	69,66	98,04	95,93	69,65	65,15	98,14	95,26	67,87
	F3-F5-F6	68,31	98,37	96,15	70,13	63,16	98,5	95,42	67,94
Destek Vektör Makineleri	F1	81,45	95,7	94,7	67,24	71,74	96,57	94,4	66,47
	F2	73,55	87,7	86,51	54,29	49,36	98,14	93,85	55,9
	F3	73,39	96,07	94,38	63,27	69,95	96,1	93,8	63,15
	F4	78,7	95,36	94,21	64,85	74,46	95,33	93,52	63,95
	F5	78,44	96,58	95,23	68,99	75,07	96,57	94,69	68,28
	F6	67,51	98,32	96,06	69,05	62,1	98,31	95,16	66,16
	F1-F6	78,27	96,83	95,5	69,91	72,31	96,51	94,4	66,63
	F1-F2-F3-F4-F5-F6	63,69	99,1	96,4	70,88	48,21	99,49	95,03	59,98
	F2-F4	81,89	96,05	95,03	68,61	71,46	97,01	94,77	67,8
	F3-F5	78,36	96,56	95,21	68,86	75,04	96,57	94,68	68,27
	F3-F5-F6	77,69	96,97	95,55	70,21	74,16	96,96	94,96	69,22
ORTALAMALAR	71,24	97,00	95,10	67,35	63,56	97,71	94,73	64,60	

Çizelge-2: Sınıflandırma yöntemlerinin işlem zamanı olarak karşılaştırılması (saniye cinsinden).

	Naive Bayes	k-EYK	DVM
Eğitim	0,13	9,77	1,42
Test	0,79	2,82	3,59

Çalışmada önerilen yöntemin benzer çalışmalarla karşılaştırılması Çizelge 3'te verilmektedir. STARE veri tabanı için en iyi sonuç F1-F2-F3-F4-F5-F6 öznitelikleri ile Destek vektör makineleri

sınıflandırıcısının kullanılması ile elde edilmektedir. DRIVE tabanı için en iyi sonuç F3-F5-F6 öznitelikleri ile Naive Bayes sınıflandırıcısının kullanılması ile elde edilmektedir. Çizelge 3'te bu sonuçlar verilmektedir. Önerilen yöntem retina bölgesinin bulunması işlemi de içerdiğinden Çizelge 1'de tüm retina üzerindeki ölçümler verilmiştir. Literatürdeki birçok çalışmada retina maskesi kullanılarak ölçümler yapıldığından Çizelge 3'te ayrıca maske kullanılarak elde edilen ölçümler de verilmektedir. STARE ve DRIVE veri tabanlarında 2.

gözlemci tarafından manüel olarak etiketli hedef görüntülerin performansları da karşılaştırma yapmak için ayrıca eklenmiştir.

Çizelge-3: Önerilen yöntemin benzer çalışmalarla karşılaştırılması.

STARE			
	DUY	OZG	DOG
Uzman gözlemci	89,51	93,84	93,48
Önerilen yöntem - DVM (tüm görüntüde)	63,69	99,10	96,40
Önerilen yöntem - DVM (retinada)	63,69	98,72	95,08
Hoover vd. [8]	67,51	95,67	92,67
Staal vd. [3]	-	-	95,16
Soares vd. [4]	-	-	94,80
M.-Perez vd. [15]	75,06	95,69	94,10
Marin vd. [6]	69,64	98,19	95,26
DRIVE			
	DUY	OZG	DOG
Uzman gözlemci	77,63	97,23	94,70
Önerilen yöntem - Naive Bayes (tüm görüntüde)	63,16	98,50	95,42
Önerilen yöntem - Naive Bayes (retinada)	63,18	97,73	93,35
Chaudhuri vd. [1]	-	-	87,73
Staal vd. [3]	-	-	94,42
Soares vd. [4]	-	-	94,66
M.-Perez vd. [15]	72,46	96,55	93,44
Marin vd. [6]	70,67	98,01	94,52

3. Sonuç

Çalışmada retinal fundus görüntülerde kan damarı tespiti için yeni öznelikler ile farklı denetimli sınıflandırma yöntemleri kullanılmış ve elde edilen sonuçlar süre ve sınıflandırma başarısı açısından değerlendirilmiştir. Yöntemde öznelik çıkarma amacıyla kan damarlarını iyileştirme işlemi gerçekleştirilmiş, daha sonra da sınıflandırma yöntemleri ile siyah-beyaz damar görüntüsü elde edilmiştir. Hatalı tespitler azaltmak ve başarı oranını arttırmak için performans iyileştirme adımı uygulanmıştır. Performans değerlendirmesi yapılırken retinal görüntüde bulunan tüm pikseller dikkate alınarak ölçümler yapılmıştır. STARE ve DRIVE veri tabanları için elde edilen sınıflandırma sonuçları Çizelge 1’de, işlem zamanı karşılaştırma sonuçları Çizelge 2’de ve benzer çalışmalarla önerilen yöntemin karşılaştırma sonuçları Çizelge 3’te verilmiştir. Elde edilen sonuçlara göre Naive Bayes sınıflandırıcısının hem eğitim hem de test olarak

en hızlı çalışan yöntem olduğu gözlenmiştir. Sınıflandırma başarısı olarak STARE veri tabanı için en iyi sonuç F1-F2-F3-F4-F5-F6 öznelikleri ile Destek Vektör Mekikleri sınıflandırıcısının kullanılmasıyla, DRIVE veri tabanı için ise en iyi sonuç F3-F5-F6 öznelikleri ile Naive Bayes sınıflandırıcısının kullanılması ile elde edilmektedir. Gelecek çalışmalarda kullanılan öznelik çeşitliliği artırılarak performans iyileştirilmesi yapılması planlanmaktadır.

4. Kaynakça

- [1] S. Chaudhuri, S. Chatterjee, N. Katz, M. Nelson, and M. Goldbaum, “Detection of blood vessels in retinal images using two-dimensional matched filters”, *IEEE Trans. Med. Imaging*, vol. 8, pp. 263–269, 1989.
- [2] M. M. Fraz, P. Remagnino, A. Hoppe, B. Uyyanonvara, a R. Rudnicka, C. G. Owen, and S. a Barman, “Blood vessel segmentation methodologies in retinal images-a survey”, *Comput. Methods Programs Biomed.*, vol. 108, no. 1, pp. 407–433, Oct. 2012.
- [3] J. Staal, M. D. Abramoff, M. Niemeijer, M. A. Viergever, and B. Van Ginneken, “Ridge-based vessel segmentation in color images of the retina”, *IEEE Trans. Med. Imaging*, vol. 23, no. 4, pp. 501–509, 2004.
- [4] J. V. B. Soares, J. J. G. Leandro, R. M. Cesar Júnior, H. F. Jelinek, and M. J. Cree, “Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification”, *IEEE Trans. Med. Imaging*, vol. 25, no. 9, pp. 1214–1222, Sep. 2006.
- [5] E. Ricci and R. Perfetti, “Retinal blood vessel segmentation using line operators and support vector classification”, *IEEE Trans. Med. Imaging*, vol. 26, no. 10, pp. 1357–1365, Oct. 2007.
- [6] D. Marín, A. Aquino, M. E. Gegúndez-Arias, and J. M. Bravo, “A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features”, *IEEE Trans. Med. Imaging*, vol. 30, no. 1, pp. 146–158, 2011.
- [7] A. Bhuiyan, B. Nath, J. Chua, and R. Kotagiri, “Blood vessel segmentation from color retinal images using unsupervised texture classification” in *Image Processing, 2007. ICIP 2007. IEEE International Conference on*, 2007, vol. 5, pp. 521–524.

- [8] A. Hoover, V. Kouznetsova, and M. Goldbaum, "Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response", *IEEE Trans. Med. Imaging*, vol. 19, no. 3, pp. 203–210, 2000.
- [9] Z. Yavuz and C. Kose, "Blood vessel segmentation from retinal images based on enhancement methods" in *Signal Processing and Communications Applications Conference (SIU), 2014 22nd*, 2014, pp. 907–910.
- [10] M. M. Fraz, A. Basit, P. Remagnino, A. Hoppe, and S. A. Barman, "Retinal vasculature segmentation by morphological curvature, reconstruction and adapted hysteresis thresholding", in *2011 7th International Conference on Emerging Technologies*, 2011, pp. 1–6.
- [11] A. M. Mendonça and A. Campilho, "Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction", *IEEE Trans. Med. Imaging*, vol. 25, no. 9, pp. 1200–13, Sep. 2006.
- [12] O. Chutatape, L. Zheng, and S. M. Krishnan, "Retinal blood vessel detection and tracking by matched Gaussian and Kalman filters" in *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, 1998, vol. 6, pp. 3144–3149.
- [13] F. K. H. Quek and C. Kirbas, "Vessel extraction in medical images by wave-propagation and traceback", *Med. Imaging, IEEE Trans.*, vol. 20, no. 2, pp. 117–131, 2001.
- [14] M. Frangi, Alejandro F. and Niessen, Wiro J. and Vincken, Koen L. and Viergever, "Multiscale vessel enhancement filtering" in *Medical Image Computing and Computer-Assisted Intervention — MICCAI '98*, 1998, vol. 1496, pp. 130–137.
- [15] M. E. Martinez-Perez, A. D. Hughes, S. a Thom, A. a Bharath, and K. H. Parker, "Segmentation of blood vessels from red-free and fluorescein retinal images", *Med. Image Anal.*, vol. 11, no. 1, pp. 47–61, Feb. 2007.
- [16] L. Espona, M. Carreira, M. Ortega, and M. Penedo, "A snake for retinal vessel segmentation", *Pattern Recognition and Image Analysis*, pp. 178–185, 2007.
- [17] B. Al-Diri, A. Hunter, and D. Steel, "An active contour model for segmenting and measuring retinal vessels", *IEEE Trans. Med. Imaging*, vol. 28, no. 9, pp. 1488–97, Sep. 2009.
- [18] A. Hoover, "STRUCTURED ANALYSIS OF THE RETINA (STARE)", [Online]. Available: <http://www.ces.clemson.edu/~ahoover/stare/>.
- [19] J. Staal, "DRIVE: Digital Retinal Images for Vessel Extraction", [Online]. Available: <http://www.isi.uu.nl/Research/Databases/DRIVE/>.
- [20] Z. Yavuz and C. Kose, "Retinal Blood Vessel Segmentation Using Gabor Filter and Top-Hat Transform" in *19th Conference on Signal Processing and Communications Applications (SIU 2011)*, 2011, pp. 546–549.
- [21] S. M. Pizer, E. P. Amburn, J. D. Austin, R. Cromartie, A. Geselowitz, T. Greer, B. ter Haar Romeny, J. B. Zimmerman, and K. Zuiderveld, "Adaptive histogram equalization and its variations", *Comput. vision, Graph. image Process.*, vol. 39, no. 3, pp. 355–368, 1987.
- [22] Hand, David J., and Keming Yu. "Idiot's Bayes—not so stupid after all?." *International statistical review* 69.3 (2001): 385-398.
- [23] V. Vapnik, I. Guyon, and T. Hastie, "Support vector machines", 1995. [Online]. Available: <http://www.support-vector-machines.org>. [Accessed: 10-Jan-2014].

