



FUNDUS FLORESEİN ANJIOGRAFI GÖRÜNTÜLERİNDE YENİ KANAMA BÖLGELERİN BELİRLENMESİNE YÖNELİK YENİ BİR YAKLAŞIM : HIZLI YAPAY ARI KOLONİ ALGORİTMASI (Q-ABC)

Mehmet Bahadır ÇETİNKAYA^{1,*} 

¹Erciyes Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, 38039, KAYSERİ

ÖZET

Diyabetik retinopati (DR) gözün arka kısmında ışığa duyarlı retina tabakasındaki kan damarlarının zarar görmesi sonucu ortaya çıkan ilerleyici bir hastalıktır. Kan damarlarının zarar görmesi kan sızıntılarına neden olabilir. Zarar görmüş kan damarlarının doğru bir şekilde tespit edilmesi hastalığın teşhisi ve tedavisi açısından son derece önemlidir. Zarar görmüş kan damarlarından dolayı göz üzerinde oluşan yeni kanamalı bölgelerin tespiti ve belirginleştirilmesi için Fundus Floresein Anjiyografi (FFA) görüntüleme yöntemi kullanılmaktadır. Bu çalışmada, FFA görüntüler üzerinde DR hastalığı sonucu oluşan yeni kanamalı bölgelerin alanları bulunarak hastalığın seviyesini ve ciddiyetini tanımlamaya yardımcı olacak veriler elde edilmiştir. Göz görüntüleri üzerindeki yeni kanamalı bölgelerin tespitine yönelik hızlı yapay arı koloni algoritması (Q-ABC) kümeleme tabanlı olarak geliştirilmiş ve elde edilen sonuçlar kümeleme tabanlı temel yapay arı koloni (ABC) algoritması ile mukayese edilmiştir.

Anahtar Kelimeler : Diyabetik retinopati, Fundus floresein anjiyografi, Yapay arı koloni algoritması, Hızlı yapay arı koloni algoritması.

A NEW APPROACH FOR DETECTION OF HEMORRHAGIC REGIONS IN THE FUNDUS FLUORESCEIN ANGIOGRAPHY RETINAL IMAGES: QUICK ARTIFICIAL BEE COLONY ALGORITHM (Q-ABC)

ABSTRACT

Diabetic retinopathy (DR) is a progressive disease that occurs due to the vascular damage in the light sensitive retina at the back of the eye. Vascular pathology may cause bleeding. Correct detection of damages is critical for diagnosis and treatment of the disease. For the detection and the enhancement of these hemorrhagic regions, Fundus Fluorescein Angiography (FFA) imaging method is used. In this work, the total area of new hemorrhagic regions resulting from DR is calculated on the FFA images in order to obtain data that represents the level and seriousness of the illness. A clustering based quick artificial bee colony algorithm (Q-ABC) is improved in order to identify new hemorrhagic regions on the retinal images and its performance is compared to that of clustering based basic artificial bee colony (ABC) algorithm.

Keywords : Diabetic retinopathy, Fundus fluorescein angiography, Artificial bee colony algorithm, Quick artificial bee colony algorithm.

1. GİRİŞ

İnsülin hormonunun salgılanmasındaki düzensizliklerden dolayı kandaki şeker miktarının kontrol edilememesi sonucunda diyabet hastalığı ortaya çıkmaktadır. Diyabet hastalığı kontrol altına alınmazsa kan şekeri yükselerek yüksek tansiyon problemini ortaya çıkarır ve vücuttaki kan akış hızı artar. Diyabet hastalığı retina tabakasındaki kılcal damarların yapısını bozarak hücre kayıplarına yol açar ve mevcut damarların geçirgenliği bozulur. Göz damarlarındaki tıkanmanın sonucunda retina tabakasında ortaya çıkan hasarlı hücreler kendiliğinden kanayabilen yeni damarlar oluşturur. Diyabet hastalığından dolayı retina içinde yapısı bozulan kan damarları mikro düzeyde kas tabakasız damar genişlemelerine, kanamalara, sert eksuda ve pamuk noktalar gibi çeşitli istenmeyen etkilere neden olabilir [1,2]. Diyabetik retinopati sonucunda oluşan çeşitli seviyelerdeki görme bozuklukları tedavi edilmezse sürekli olarak ilerler ve ileri seviyede veya tamamen görme kaybı ile

* Sorumlu yazar / Corresponding author, e-posta / e-mail: cetinkaya@erciyes.edu.tr


Geliş / Recieved: 01.01.2019 Kabul / Accepted: 01.03.2019 doi: 10.28948/ngumuh.777803

M. B. Çetinkaya

sonuçlanabilir [3]. Son yıllarda göz hastalıklarının teşhisine yönelik biyomedikal görüntü işleme alanında literatür incelendiğinde, sert ve yumuşak eksuda tespitine yönelik yaklaşımların analiz edildiği [4-8], retina görüntülerini otomatik algılayarak retina hastalıklarının tanımlanmasına yönelik yapay sinir ağlarının kullanıldığı [9], diyabetik retina hastalarında gözbebeğini genişletmeden tanı koyulmasına yönelik yöntemlerin kullanıldığı [10], retina hastalıklarının sınıflandırılmasına yönelik yaklaşımların kullanıldığı [11] ve yaşa bağlı makula dejenerasyonunun tespitine yönelik [12], çalışmaların yapıldığı görülmektedir.

Diyabet hastalığının neden olduğu ölümlerin düşük ve orta gelirli ülkelerdeki oranı %80'dir [13]. Diyabet hastalarının sayısı nüfus artışı, yaşlılık, kentleşme ve fiziksel hareketlerdeki azalmalara bağlı olarak günden güne artmaktadır. Diyabet hastalarının toplam sayısının 2030 yılında 36 milyona yükselmesi beklenmektedir [14]. Diyabet hastalarının yaklaşık %40'ında diyabetik retinopatiye yakalanma riski vardır ve bu risk altındaki hastaların %5'inin görme kaybıyla karşılaşabilmesi olasıdır [15].

Bu çalışmada, diyabetik retinopati hastalığı bulunan bir retinal görüntü üzerinde yeni kanamalı bölgelerin tespitine yönelik ABC ve Q-ABC algoritmaları kümeleme tabanlı olarak geliştirilmiştir. Benzetimlerde, retinal görüntü üzerindeki yeni kanamalı bölgelerin hekim tarafından görülebilmesini kolaylaştırmak amacıyla bu bölgelerin çevreleri çizdirilmiş ve daha belirgin hale getirilmiştir. Daha sonra, hekimlere yeni kanamalı bölgelere ait matematiksel ve doğruluğu net veriler sağlayabilmek amacıyla alansal hesaplar yapılmış ve elde edilen sonuçlar veri tabanına kaydedilmiştir. Elde edilen veritabanları sayesinde hekimler hastalık ve hastalığın seyri hakkında daha objektif ve matematiksel değerlendirmeler yapabilecektir. Ayrıca, yeni kanamalı bölgelerin göz üzerindeki toplam alanlarının matematiksel olarak hesaplanabilmesi ile belirli H skorları tanımlanabilecektir. Elde edilen H skorları ile kanama miktarının yayını, yeni kanamalı bölgelerdeki atağın takibi yapılabilecektir. Sonuç olarak, hekimlerin uygulanması gereken tedavi yöntemleri hakkında nitel gözlemler yaparak karar vermek yerine nicel gözlemler yaparak karar verebilmesine olanak sağlanmış olacaktır. Benzetimler, High-Resolution Fundus (HRF) Image Database [16] veri tabanından alınan Kırmızı-Yeşil-Mavi (Red-Green-Blue, RGB) formatında ve FFA yöntemi kullanılarak elde edilmiş diyabetik retinopati hastalığı görülen bir göz görüntüsü üzerinde gerçekleştirilmiştir. Diyabetik retinopati hastalığı görülen ve görülmeyen retinalara ait FFA görüntüleri Şekil 1 ile gösterilmiştir.



a) Sağlıklı Retina

b) Hastalıklı Retina

Şekil 1. Sağlıklı retina ve diyabetik retinopati hastalığı bulunan retinalar

2. TEMEL ABC ALGORİTMASI

Yapay arı koloni algoritması, problemlerin çözümünde arı kolonilerinin ortak hareketlerinden esinlenerek geliştirilmiş sürü zekasına dayalı sezgisel bir algoritmadır. Karaboğa tarafından 2005 yılında önerilmiş olan ABC algoritması [17] özellikle çok boyutlu problemlerin optimizasyonunda etkin bir performansa sahiptir. ABC algoritmasında popülasyon 3 grup arıdan oluşmaktadır. Bunlar, görevli arılar, gözcü arılar ve kaşif arılardır. Başlangıç popülasyonu yarısı görevli arılardan diğer yarısı ise gözcü arılardan oluşacak şekilde oluşturulmaktadır. Bir yiyecek kaynağının pozisyon bilgisi olası bir çözümü temsil ederken, nektar miktarı ise o yiyecek kaynağının temsil ettiği çözümün kalite değerini belirlemektedir. Her bir görevli arı rasgele üretilmiş bir yiyecek kaynağına atanmaktadır, yani görevli arı sayısı yiyecek kaynağı sayısına eşit olmaktadır. Böylece, görevli arıların veya gözcü arıların sayısı popülasyondaki çözüm sayısına eşit olmaktadır. Diğer görevli ve gözcü arılar tarafından yiyecek kaynağı tüketilen görevli arılar ise kaşif arı haline dönüşmekte ve yeni yiyecek kaynakları bulmak için araştırma uzayında rasgele araştırma yapmaktadır.

FUNDUS FLORESEİN ANJİOGRAFİ GÖRÜNTÜLERİNDE YENİ KANAMA BÖLGELERİN BELİRLENMESİNE YÖNELİK YENİ BİR YAKLAŞIM : HIZLI YAPAY ARI KOLONİ ALGORİTMASI (Q-ABC)

Araştırmanın ilk aşaması başlangıç popülasyonundaki rasgele üretilmiş olası çözümler üzerinde gerçekleştirilmektedir. Bir çözüm belirli sayıda denemeye rağmen geliştirilememiş ise tükenmiş bir çözüm olarak kabul edilerek popülasyondan atılır ve yerine kaşif arılar tarafından bulunan yeni bir çözüm popülasyona dahil edilir. Bir çözümün tükenmiş çözüm olarak kabul edilebilmesi için "limit" parametresi sayısınca denemeye rağmen geliştirilememiş olması gerekir.

ABC algoritmasının adımları aşağıdaki gibidir:

Algoritma 1. ABC algoritması
1. <i>Başlangıç aşaması</i>
2. REPEAT
3. <i>Görevli arı aşaması</i>
4. <i>Gözcü arı aşaması</i>
5. <i>Kaşif arı aşaması</i>
6. <i>En iyi çözümün hafızaya kaydedilme aşaması</i>
7. UNTIL (<i>sonlandırma kriteri sağlanıncaya kadar</i>)

Başlangıç aşamasında Eşitlik (1) kullanılarak rasgele bir başlangıç popülasyonu üretilir, ,

$$x_{m,i} = l_i + rand(0,1) \cdot (u_i - l_i) \quad (1)$$

burada, $x_{m,i}$ ifadesi, m . çözümün i . boyutunu göstermektedir. u_i ve l_i , sırasıyla, $x_{m,i}$ çözümünün alt ve üst sınırlarıdır. Rasgele üretilmiş SN adet çözüm içeren bir başlangıç popülasyonu $P(c) = \{x_{m,i} \mid m=1, 2, \dots, SN\}$ şeklinde gösterilebilir.

Daha sonra, başlangıç popülasyonundaki her bir çözümün kalite değeri bir minimizasyon problemi olarak Eşitlik 2 ile en düşük hata değeri elde edilecek şekilde hesaplanarak hafızaya kaydedilir.

$$fit(x_m) = \frac{1}{1 + |f(x_m)|} \quad (2)$$

Görevli arı aşamasında öncelikle başlangıç aşamasında hafızaya kaydedilmiş olan en yüksek kalite değerli çözümlerin komşuluğunda yeni çözümler Eşitlik 3 kullanılarak üretilir.

$$v_{m,i} = x_{m,i} + \phi_{m,i} (x_{m,i} - x_{k,i}) \quad (3)$$

burada, x_k rasgele seçilmiş bir çözümü ve i ise bu çözümün yeni çözüm üretmek amacıyla değişiklik yapılacak boyutunu temsil etmektedir. $\phi_{m,i}$ katsayısı ölçekleme faktörüdür ve $[-1,+1]$ aralığında değerler alabilmektedir. Komşu çözüm v_m üretildikten sonra x_m ve v_m arasında açgözlü seçme (greedy selection) prosedürü uygulanarak kalite değeri daha yüksek olan çözüm bir sonraki jenerasyona aktarılır. Eğer üretilen yeni çözüm sınır değerleri dışında ise ilgili çözümün değeri en yakın sınır değerine eşitlenir.

Gözcü arı aşamasında öncelikle görevli arı aşamasında üretilmiş olan çözümlerin bir kısmı kalite değerlerine bağlı olarak seçilirler. Bu olasılıksal seçme prosedürü aşağıda Eşitlik 4 ile verilmiştir,

$$p_m = \frac{fit(x_m)}{\sum_{m=1}^{SN} fit(x_m)} \quad (4)$$

Bu aşamadan sonra, görevli arı aşamasındaki benzer şekilde Eşitlik 3 kullanılarak komşu çözümler üretilir ve x_m çözümü ile komşu çözümü olan v_m arasında açgözlü seçme prosedürü uygulanarak yüksek kalite değerli olan çözüm bir sonraki jenerasyona aktarılır.

Kaşif arı aşaması ise *limit* parametre değeri kadar denemeye rağmen geliştirilemeyen çözümlerin yerine Eşitlik 1 kullanılarak rasgele üretilmiş yeni çözümlerin popülasyona dahil edildiği bir aşamadır. Kaşif arı aşaması sayesinde bir sonraki jenerasyona tükenmiş çözümler değil, onların yerine üretilen yeni çözümler aktarılmaktadır.

3. HIZLI ABC ALGORİTMASI

Temel ABC algoritmasında, bir gözcü arı doğrudan ve sadece görevli arı tarafından kendisine aktarılan konum bilgisindeki ilgili çözümü değerlendirmektedir. Bu araştırma yönteminde tek bir çözüm üzerinde odaklanıldığı için o çözümün etrafındaki olası daha iyi çözümler göz ardı edilmekte, bu ise algoritmanın yakınsama hızını düşürmektedir. Temel ABC algoritmasının bu dezavantajının üstesinden gelmek için, Karaboğa ve Görkemli tarafından Q-ABC algoritması önerilmiştir [18,19]. Önerilen yaklaşımda, gözcü arı aşamasında, sadece görevli arıların konum bilgisini verdiği kaynak değil aynı zamanda bu kaynağın belirli bir yarıçapındaki bölge de araştırılmakta ve bu bölge dahilinde en yüksek kalite değerli çözüm seçilerek bir sonraki jenerasyona aktarılmaktadır. Önerilen algoritmada, gözcü arıların davranışı aşağıda Eşitlik 5 ile modellenmektedir,

$$v_{N_m, i}^{best} = x_{N_m, i}^{best} + \phi_{m, i} (x_{N_m, i}^{best} - x_{k, i}) \quad (5)$$

burada $x_{N_m}^{best}$ ifadesi, x_m çözümünün kendisi (N_m) ile komşuluğundaki tüm çözümler arasındaki en yüksek kalite değerine sahip çözümü temsil etmektedir. Yani, gözcü arı, görevli arı tarafından konum bilgisi aktarılmış olan x_m çözümünü hafızasına kaydettikten sonra bu çözümün merkezinde olduğu bir bölgede yeni komşu çözümleri araştırmaktadır. Araştırma bölgesi içerisinde en yüksek kalite değerine sahip $x_{N_m}^{best}$ çözümü bir sonraki jenerasyona aktarılır. Yani, S adet çözümden oluşan bir çözüm uzayındaki en yüksek kalite değerine sahip $x_{N_m}^{best}$ çözümü aşağıdaki gibi tanımlanmaktadır,

$$fit(x_{N_m}^{best}) = \max [fit(x_{N_m}^1) \quad fit(x_{N_m}^2) \quad \dots \quad fit(x_{N_m}^S)] \quad (6)$$

ABC algoritmasına ilave olarak, Q-ABC algoritması, *komşuluk yarıçapı* (r) olarak adlandırılan ve x_m çözümünün merkezde olduğu araştırma bölgesinin yarıçapını tanımlayan bir kontrol parametresine daha sahiptir. r parametresinin değeri $r=0$ olarak seçildiğinde Q-ABC algoritması ABC algoritmasına dönüşeceği için bu parametrenin değeri $r \geq 0$ olarak seçilmelidir [19].

Q-ABC algoritmasının akış kodu aşağıdaki gibidir,


Algoritma 2. Q-ABC algoritması
1. Başlangıç Aşaması
2. Kontrol parametre değerlerini tanımla
3. x_m çözümlerinden oluşan rasgele başlangıç popülasyonu oluştur
4. Her bir çözümü değerlendir ve en iyi çözümü hafızaya al
5. Çevrim = 0
6. REPEAT
7. Görevli Arı Aşaması
8. x_m çözümünün komşuluğunda bir v_m çözümü üret ve bu çözümü değerlendir
9. x_m ve v_m arasında aç gözlü seçme prosedürü uygula
10. Popülasyondaki her bir çözüm için kalite ve olasılık değerlerini hesapla
11. Gözcü Arı Aşaması
12. p_m olasılığına bağlı olarak bir x_m çözümü seç
13. En yüksek kalite değerine sahip $x_{N_m}^{best}$ komşu çözümünü bul ($x_{N_m}^{best} = x_m$ olabilir)
14. $x_{N_m}^{best}$ çözümünün komşuluğunda bir $v_{N_m}^{best}$ çözümü üret ve bu çözümü değerlendir
15. $x_{N_m}^{best}$ ve $v_{N_m}^{best}$ arasında aç gözlü seçme prosedürü uygula
16. Şu ana kadar bulunan en iyi çözümü hafızaya al
17. Kaşif Arı Aşaması
18. Tükenmiş çözümleri tespit et ve onların yerine bir sonraki jenerasyon için yeni çözümler üret
19. Çevrim = Çevrim + 1;
20. UNTIL (sonlandırma kriteri sağlanıncaya kadar)

FUNDUS FLORESEİN ANJİOGRAFİ GÖRÜNTÜLERİNDE YENİ KANAMA BÖLGELERİN BELİRLENMESİNE YÖNELİK YENİ BİR YAKLAŞIM : HIZLI YAPAY ARI KOLONİ ALGORİTMASI (Q-ABC)

4. METOT VE BENZETİM SONUÇLARI


Görüntü işleme metodolojisinde bazı ön işlemler uygulanarak görüntü zenginleştirilmekte ve daha sonra kümeleme tabanlı görüntü analizi gerçekleştirilmektedir. Görüntü zenginleştirme için kullanılan en temel yaklaşımlar süzgeçleme ve morfolojik işlemlerdir. Süzgeçleme görüntüyü netleştirmekte ve hastalıklı bölgeleri daha belirgin hale getirmektedir. Ancak, çok küçük yarıçaplı hastalıklı bölgeler ile sağlıklı bölgelerin piksel değerleri genellikle birbirine çok yakındır ve süzgeçleme işlemi bu bölgelerin belirginleştirilmesinde yetersiz kalmaktadır. Bu nedenle, çok küçük yarıçaplı hastalıklı bölgeler öncelikle morfolojik işlemler ile genişletilmekte ve daha sonra süzgeçleme işlemi uygulanmaktadır.

Süzgeçleme ve morfolojik işlemlerden sonra elde edilen RGB retinal görüntü Şekil 2 ile gösterilmiştir. Görüldüğü gibi, hastalıklı bölgeler ile sağlıklı bölgelerin piksel değerleri arasındaki fark artarak hastalıklı bölgeler daha belirgin hale gelmiştir.




Şekil 2. Süzgeçleme ve morfolojik işlemler sonrasında elde edilen retinal görüntü

Biyomedikal görüntüleme cihazlarından elde edilen retinal görüntüler genellikle RGB formatındadır fakat bu görüntüler farklı renk uzayları kullanılarak ta analiz edilebilirler. Literatürde sık kullanılan bir diğer renk uzayı *parlaklık (L)*, *kırmızı-yeşil (a)* ve *sarı-mavi (b)* katmanlarından oluşan Commission Internationale de l'Eclairage Lab (CIE Lab) renk uzayıdır [20]. Bu çalışmada, retinal görüntüler üzerinde yapılan benzetimlerde CIE Lab uzayında daha yüksek kümeleme performansının elde edildiği görülmüştür. Bu nedenle analizler CIE Lab renk uzayı kullanılarak gerçekleştirilmiştir. Şekil 2 ile verilen RGB renk uzayındaki retinal görüntünün CIE Lab renk uzayına dönüştürülmüş formu ve her bir katmana ait görüntüler, sırasıyla, Şekil 3 ve Şekil 4 ile gösterilmiştir.




Şekil 3. CIE Lab renk uzayında elde edilen retinal görüntü


M. B. Çetinkaya



a.) *L* katmanı



b.) *a* katmanı



c.) *b* katmanı

Şekil 4. CIE Lab renk uzayındaki retinal görüntünün katmanları

Yapılan benzetimlerde en iyi kümeleme performansının *a* katmanı üzerinde elde edildiği görülmüştür. Bu nedenle kümeleme tabanlı retinal görüntü analizi *a* katmanı üzerinde gerçekleştirilmiştir. Kümeleme analizi, *n* adet birimi *p* adet değişkene göre mümkün olduğu kadar kendi içinde benzer ve kendi aralarında farklı alt gruplara ayırmak için kullanılır. Bu çalışmada, retinal görüntüde sağlıklı bölgeleri temsil eden piksel değerleri için bir küme merkezi ve hastalıklı bölgeleri temsil eden piksel değerleri için farklı bir küme merkezi olmak üzere toplam iki küme merkezi etrafında kümeleme işlemi gerçekleştirilmiştir. Kümeleme işleminde uygulanan temel adımlar aşağıda verilmiştir.

Rasgele küme merkezleri belirle

REPEAT

FUNDUS FLORESEİN ANJİOGRAFİ GÖRÜNTÜLERİNDE YENİ KANAMA BÖLGELERİN BELİRLENMESİNE YÖNELİK YENİ BİR YAKLAŞIM : HIZLI YAPAY ARI KOLONİ ALGORİTMASI (Q-ABC)

Mesafelere göre örnekleri kümele

Kümeleme sonrasında rasgele yeni küme merkezleri belirle

UNTIL (Tüm örneklerin ait olduğu küme değişmeyinceye kadar)

Kümeleme sürecince küme merkezleri ABC ve Q-ABC algoritmaları tarafından [0,255] piksel değerleri aralığında rasgele belirlenmekte ve bütün piksel değerleri algoritmalar tarafından kendisine en yakın küme merkezine gruplanmaktadır. Böylece hastalıklı bölgeler ile sağlıklı bölgeler arasındaki piksel değerleri arasındaki fark artmaktadır. Piksel değerlerinin en yakın küme merkezlerine gruplandırılması, aşağıda Eşitlik 7 ile verilmiş olan Ortalama Karesel Hata (MSE) kriterine göre gerçekleştirilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (f_i - y_i)^2 \quad (7)$$

burada, retinal görüntüdeki toplam piksel sayısı N ve i . piksele en yakın küme merkezi f_i olarak tanımlanmaktadır. y_i ise i . pikselin değerini temsil etmektedir. Görüldüğü gibi MSE değeri sıfıra ne kadar yakın olursa, kümeleme işlemi de o denli başarılı bir şekilde gerçekleştirilmiş olacaktır.


Bu çalışmada, retinal görüntülerde yeni kanamalı bölgelerin tespitine yönelik geliştirilmiş olan kümeleme tabanlı ABC ve Q-ABC algoritmaları için kontrol parametre değerleri aşağıda Tablo 1 ile verilmiştir.

Tablo 1. ABC ve Q-ABC algoritmaları için benzetimlerde kullanılan kontrol parametre değerleri

ABC	Q- ABC
Popülasyon boyutu = 20	Popülasyon boyutu = 20
	Komşuluk yarıçapı (r), $r= 0.5$
<i>limit</i> parametre değeri, popülasyon boyutuna ($nPop$) ve değişken sayısına ($nVar$) bağlı olarak aşağıdaki gibi adaptif şekilde alınmaktadır.	<i>limit</i> parametre değeri, popülasyon boyutuna ($nPop$) ve değişken sayısına ($nVar$) bağlı olarak aşağıdaki gibi adaptif şekilde alınmaktadır.
$limit = 0.6 * nVar * nPop$	$limit = 0.6 * nVar * nPop$
X_{max} ve X_{min} , sırasıyla, retinal görüntüdeki <i>max</i> ve <i>min</i> piksel değerleridir.	X_{max} ve X_{min} , sırasıyla, retinal görüntüdeki <i>max</i> ve <i>min</i> piksel değerleridir.


Kümeleme tabanlı ABC ve Q-ABC algoritmaları ile kümeleme sonucunda elde edilen retinal görüntüler aşağıda Şekil 5 ile verilmiştir. Görüldüğü gibi algoritmalar kümeleme açısından benzer performanslar göstermektedir. Retinal görüntü içerisindeki makula bölgesi ile sağlıklı ve kanamalı bölgelerin birbirine çok yakın renk yoğunluklarına sahip olduğu dikkate alındığında, ABC ve Q-ABC algoritmalarının başarılı bir kümeleme performansı gösterdikleri görülmektedir.

ABC algoritması ile kümeleme sonucunda elde edilen retinal görüntü



a.) ABC algoritması

Q-ABC algoritması ile kümeleme sonucunda elde edilen retinal görüntü



b.) Q-ABC algoritması

Şekil 5. ABC ve Q-ABC algoritmaları ile kümeleme sonrasında elde edilen retinal görüntüler

Yeni kanamalı bölgelerin tespit edilmesi hastalığın varlığı, seyri ve ciddiyeti hakkında hekimlere önemli bilgiler vermektedir. Bu çalışmada, yeni kanamalı bölgelerin tespit edilmesine ek olarak aşağıda verilen adımlar uygulanarak ABC ve Q-ABC algoritmaları ile çevreleri çizdirilmiş ve daha anlaşılır görüntüler elde edilmiştir.

Algoritma 3. Yeni kanamalı bölgelerin tespit edilmesi
--


- | |
|---|
| <ol style="list-style-type: none"> 1. Kanamalı bölgeler tespit edilir 2. Tespit edilen bölgelerin sınır bilgileri kaydedilir 3. REPEAT 4. Belirlenen sınır noktaları çizilir 5. UNTIL (tüm sınırlar tamamlanana kadar) |
|---|

ABC ve Q-ABC algoritmaları için benzetimler sonucunda elde edilen göz görüntüleri aşağıda Şekil 6 ile verilmiştir.


Yeni kanamalı bölgelerin çevrelerinin çizdirilmesi ile elde edilen görüntüler incelendiğinde, her iki algoritmanın da benzer sonuçlar ürettiği fakat Q-ABC algoritmasının başarımının nispeten daha iyi olduğu görülmektedir. Çok sayıda göz görüntüsü üzerinde yapılan benzetimler sonucunda; yeni kanamalı bölgeler ile diğer bölgelerin renk yoğunlukları arasındaki

FUNDUS FLORESEİN ANJİOGRAFİ GÖRÜNTÜLERİNDE YENİ KANAMA BÖLGELERİN BELİRLENMESİNE YÖNELİK YENİ BİR YAKLAŞIM : HIZLI YAPAY ARI KOLONİ ALGORİTMASI (Q-ABC)

benzerliklere, resim işlenirken üzerinde oluşan renk tonlarındaki karartılara ve makula bölgesinin renk değerleri ile yeni kanamalı bölgelerin renk değerleri arasındaki benzerliğe rağmen, ABC ve Q-ABC algoritmalarının retinal görüntülerdeki kümeleme performansının oldukça yüksek olduğu görülmektedir.



a.) ABC algoritması



b.) Q-ABC algoritması

Şekil 6. Yeni kanamalı bölgelerin ABC ve Q-ABC algoritmaları kullanılarak tespiti


Görüntü üzerindeki yeni kanamalı bölgelerin toplam alanının (θ_i), retinal görüntünün toplam alanına (β_i) oranı da hastalığın durumu hakkında önemli bilgiler vermektedir. Bu nedenle bu çalışmada alanların piksel tabanlı hesaplanması üzerine de uygulamalar yapılmıştır. ABC algoritması ile elde edilen sonuçlarda piksel tabanlı alan oranı $\frac{\sum \theta_i}{\beta_i} = 0.034887$

olarak elde edilirken, Q-ABC algoritması ile elde edilen sonuçlarda piksel tabanlı alan oranı $\frac{\sum \theta_i}{\beta_i} = 0.034978$ olarak elde edilmiştir. Piksel tabanlı alan oranlarının yakın değerlerde çıkması her iki algoritmanın da çok benzer kümeleme performansına sahip olduğunun bir diğer göstergesidir. Bu uygulama hasta üzerinde periyodik olarak yapıldığında hastalığın

M. B. Çetinkaya

seyri ve olası riskler hakkında da bir veri tabanı oluşturarak tedavi süreci hakkında daha etkili kararların alınabilmesine olanak sağlayacaktır.

Sezgisel algoritmalar için en önemli performans ölçütlerinden birisi de en iyi çözümlere ulaşma hızını tanımlayan yakınsama hızıdır. ABC ve Q-ABC algoritmalarının retinal görüntü analizindeki yakınsama hızları 20 koşmanın ortalaması için Şekil 7’de mukayese edilmiştir. Görüldüğü gibi, Q-ABC algoritması daha düşük hata değerlerine daha hızlı yakınsamaktadır. Gözcü arı aşamasında önerilmiş olan yaklaşım hem hata performansını hem de yakınsama hızını artırmaktadır.



Şekil 7. ABC ve Q-ABC algoritmaları için yakınsama hızlarının mukayesesi

5. SONUÇ

Bu çalışmada, diyabetik retinopati hastalıklı FFA’lı retinal görüntüler üzerinde yeni kanamalı bölgelerin tespit edilmesine, belirginleştirilmesine ve piksel tabanlı alan hesaplamalarının yapılmasına yönelik kümeleme tabanlı ABC ve Q-ABC algoritmaları geliştirilmiştir. Benzetimler sonucunda, yeni kanamalı bölgelerin ABC ve Q-ABC algoritmaları ile yüksek doğrulukta ve netlikte tespit edilebildiği görülmüştür. Retinal görüntü üzerinde yeni kanamalı bölgelerin daha net görülebilmesi ve matematiksel olarak tanımlanabilmesi amacıyla, ABC ve Q-ABC algoritmaları, yeni kanamalı bölgelerin çevrelerini çizdirerek piksel tabanlı alan hesaplamalarını yapacak şekilde geliştirilmiş ve böylece hastalığın seyri hakkında daha objektif ve matematiksel değerlendirmeler yapılmasına olanak sağlayacak veriler elde edilmiştir. Elde edilen yakınsama grafikleri incelendiğinde, benzer kümeleme performansı göstermelerine karşın Q-ABC algoritmasının daha düşük MSE değerlerine daha hızlı yakınsadığı da görülmüştür.

KAYNAKLAR

- [1] R. N. Frank, “Diabetic retinopathy”, *Progress in Retinal and Eye Research*, vol.14, no. 1995, pp. 361–392. 1995.
- [2] H. Özçetin, *Pratik Göz Hastalıkları (2nci Baskı)*, F. Özsan Matbaacılık, 2000.
- [3] J. A. Olson, F. M. Strachana, J. H. Hipwell, K. A. Goatman, K. C. Mchardy, J. V. Forrester, and P. F. Sharp, “A comparative evaluation of digital imaging, retinal photography and optometrist examination in screening for diabetic retinopathy”, *Diabetic Medicine*, vol. 20, pp. 528–534, 2003.
- [4] T. Walter, J. C. Klein, P. Massin, and A. Erginay, “A contribution of image processing to the diagnosis of diabetic retinopathy-detection of exudates in color fundus images of the human retina”, *IEEE Transactions on Medical Imaging*, vol. 21, no. 10, pp. 1236–1243, 2002.

FUNDUS FLORESEİN ANJİOGRAFİ GÖRÜNTÜLERİNDE YENİ KANAMA BÖLGELERİN BELİRLENMESİNE YÖNELİK YENİ BİR YAKLAŞIM : HIZLI YAPAY ARI KOLONİ ALGORİTMASI (Q-ABC)

- [5] C. Jayakumari, and T. Santhanam, “An intelligent approach to detect hard and soft exudates using echo state neural network”, *Information Technology Journal*, vol. 7, no. 2, pp., 386–395, 2008.
- [6] A. G. Karegowda, S. Bhattacharyya, M. A. Jayaram, and A. S. Manjunath, , “Exudates detection in retinal images using KNNFP and WKNNFP classifiers”, *Artificial Intelligent Systems and Machine Learning*, vol. 3, no. 7, pp. 419–425, 2011.
- [7] A. Somasundaram, and J. Prabhu, “Detection of exudates for the diagnosis of diabetic retinopathy”, *International Journal of Innovation and Applied Studies*, vol. 3, no. 1, pp. 116–120, 2013.
- [8] A. Kaur, and, P. Kaur, “A comparative study of various exudate segmentation techniques for diagnosis of diabetic retinopathy”, *International Journal of Current Engineering and Technology*, vol. 46, no. 1, pp. 142–146, 2016.
- [9] F. D. Yağmur, “Yapay sinir ağları ile retinada hastalık teşhisi,” M. S. thesis, University of Haliç, İstanbul, 2008.
- [10] A. Sopharak, and B. Uyyanonvara, “Automatic exudates detection from diabetic retinopathy retinal image using fuzzy c-means and morphological methods”, In Poc. The Third Conference on IASTED International Conference: Advances in Computer Science and Technology, 2007, pp. 359-364.
- [11] A. Osareh, M. Mirmehdi, B. Thomas, and R. Markham, “Automatic recognition of exudative maculopathy using fuzzy c-means clustering and neural networks”, In Poc. Conference Proceedings of Medical Image Understanding and Analysis, 2001, pp. 49–52.
- [12] E. Çalık, “Retina görüntülerinde yaşa bağlı makula dejenerasyonunun bilgisayar destekli tespiti,” M. S. thesis, University of Marmara, İstanbul, 2013.
- [13] Available : http://www.who.int/healthinfo/global_burden_disease/en/ . [Accessed October 21, 2016].
- [14] S. Wild, , G. Roglic, A. Green, R. Sicree, and H. King, “Global prevalence of diabetes estimates for the year 2000 and projections for 2030”, *Diabetes Care*, vol. 27, no. 2004, pp. 1047-1053, 2004.
- [15] B. Antal, and A. Hajdu, “An ensemble-based system for automatic screening of diabetic retinopathy”, *Knowledge-Based Systems*, vol. 60, no. 2014, pp. 20-27, 2014.
- [16] High-Resolution Fundus (HRF) Image Database. [Online]. Available : <http://www5.cs.fau.de> [Accessed April 28, 2016].
- [17] D. Karaboga, “An idea based on honey bee swarm for numerical optimization,” University of Erciyes, Faculty of Engineering, Department of Computer Engineering, Tech. Report-TR06, 2005.
- [18] D. Karaboga, and B. Gorkemli, “A quick artificialbee colony - qabc – algorithm for optimization problems”, In Poc. International Symposium on Innovations in Intelligent Systems and Applications’12, 2012.
- [19] D. Karaboga, and B. Gorkemli, “A quick artificial bee colony (q-ABC) algorithm and its performance on optimization problems”, *Applied Soft Computing*, vol. 23, pp. 227-238, 2014.
- [20] A. K. Jain, *Fundamentals of Digital Image Processing*, Prentice Hall International Editions, 1989.

