

Süper Piksel Tabanlı Otomatik Kanlı Bölge Tespit Sistemi

Super Pixel Based Automatic Bloody Region Detection System

Ömer Faruk DURSUN¹ , H. İrem TÜRKMEN^{1*} 

¹Yıldız Teknik Üniversitesi, Elektrik-Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34220, Esenler/İstanbul

Öz

İnternet kullanımının gittikçe yaygınlaşması daha fazla insanın şiddet ve korku barındıran içeriğe erişme riskini arttırmıştır. Bu durum internet üzerindeki içeriğin diğer medya araçlarına göre daha az denetlenmesi ile birleştiğinde, bu tip içeriğe karşı hassas olan kişiler ve özellikle çocuklar için önlemler alınması gereği ortaya çıkmıştır. Bu çalışmada, her bir süper pikselden çıkartılmış renk ve doku özellikleri kullanarak görüntülerde kan içeren bölgelerin tespitini yapabilecek süper piksel tabanlı bir yöntem önerilmiştir. Öncelikle kan görüntüsü içeren ve içermeyen fotoğraflardan oluşan bir veri seti hazırlanmış ve bu veri setindeki resimlere süper piksel bölütleme metodu uygulanarak, renk ve doku özellikleri bakımından benzer olan anlamlı parçaların elde edilmesi amaçlanmıştır. Sistemin başarısına süper piksel sayısının etkisinin ölçülmesi amacı ile, bölütleme algoritmasının oluşturacağı süper piksel sayısı üç farklı üst sınır ile denenmiştir. Bölütleme algoritmasından elde edilen parçalardan renk ve doku özellikleri çıkartılmış ve destek vektör makinesi (DVM) yardımı ile kanlı bölge tespiti yapabilecek modeller oluşturulmuştur. Oluşturulan modellerin başarıları karşılaştırmak amacı ile çeşitli çekirdek fonksiyonları denenmiştir. Önerilen sistemde ortalama %97 doğruluk elde edilmiştir.

Anahtar Kelimeler: Otomatik Kanlı Bölge Tespiti, Süper Piksel Bölütlemesi, Renk Özellikleri, Gri Seviye Eş Oluşum Matrisi, Destek Vektör Makinesi.

Abstract

The widespread use of the Internet has increased the risk of more people accessing content that may contain violence. When this situation is combined with the fact that the web is less inspected compared to other media tools, it has become necessary to take precautions for people who are sensitive to this type of content and especially for children. In this study, we propose a super pixel-based method for detecting bloody regions on images, using color and texture features extracted from individual super pixels. We first collected a data set consisting of images with and without bloody regions and applied super pixel segmentation to the images in the data set to obtain meaningful segments that are similar in terms of color and texture features. The number of super pixels created by the segmentation algorithm has been tested with three different upper limits in order to measure the effect of the numbers of super pixels on the success of the system. We extracted color and texture information from the segments obtained by segmentation algorithm, and constructed bloody region detection models exploiting Support Vector Machine (SVM) classifier. We used various kernel methods to test the effectiveness of the constructed models. The proposed system achieved an accuracy rate of 97%.

Keywords: Automatic Bloody Region Detection, Super Pixels Segmentation, Color Features, Gray Level Cooccurrence Matrix, Support Vector Machine.

I. GİRİŞ

Tüm dünyada ve ülkemizde internet kullanımı sürekli artmaktadır. Son yıllarda internet kullanım yaşı düşmekte ve çevrimiçi çocuk sayısı artmaktadır. Bununla birlikte internetin diğer medya türlerine göre daha az denetim altında olması bazı sorunları beraberinde getirmektedir. İnternet üzerindeki uygunsuz görüntüler kullanıcıları ve özellikle çocukları olumsuz etkilemektedir.

Dijital görüntü işleme yöntemleri kullanılarak sakıncalı görüntülerin tespiti üzerine yapılmış birçok çalışma bulunmaktadır. W.Hu ve arkadaşları pornografik görüntülerin tespiti için öne sürülen yama bazlı (patchbased) ten rengi tanıma algoritması kullanmışlardır [1]. Lopes ve arkadaşları Bag-of-Features yöntemini kullanarak çıplaklık içeren görüntülerin tespiti üzerine çalışmışlardır [2]. BOF yönteminde görüntüler görsel tanımlayıcıların histogramları şeklinde ifade edilmiştir. Çalışmada daha öncesinde sadece gri seviye bilgiye sahip görsel tanımlayıcılara renk özelliklerinin de eklenmesi sağlamak için Ölçekten Bağımsız Öznitelik Dönüşümü (ÖBÖD, Scale Invariant Feature Transform-SIFT) tanımlayıcısının bir uzantısı olan renk ÖBÖD (hue SIFT) tanımlayıcılarını kullanmışlardır.

R.Guermazi ve arkadaşları, şiddet içeren görüntülerin tespitinde renk açıklayıcıları ve sınıflandırıcı kombinasyonlarına odaklanmışlardır. Çalışmaları sonucunda MPEG7 renk açıklayıcılarını önermişlerdir [3].

Durağan görüntülerde şiddet içeriğinin bulunup bulunmadığının tespiti için yapılmış başka bir çalışmada Kelime Çantası (Bag-of-Words) yöntemini kullanmışlardır [4]. Kelime Çantası yöntemi bir görüntüyü özellikler ve bunların ortaya çıkma sıklığı şeklinde ifade eder. Li ve arkadaşları tarafından web üzerindeki korku ve şiddet içerikli görüntülerin tespiti amacı ile geliştirilen çalışmada bağlam-bilinçli çoklu örnek öğrenme algoritması (context-aware multi instance learning) kullanılmıştır [5]. Çalışmalarında geleneksel çoklu öğrenme algoritmasını, örnekler arasındaki bağlamsal ilişkileri temsil eden yönsüz bir graf kullanarak geliştirmiş ve böylece bağlam-bilinçli çoklu öğrenme algoritması sunmuşlardır.

Nievas ve arkadaşları ulusal hokey ligi maç videolarında oluşan verisetleri üzerinde şiddet içerikli çerçeveleri tespit edebilmek için Uzamsal-zamansal ilgi noktaları (Space-Time Interest Points - STIP) ve Hareketli Ölçekten bağımsız öznelik dönüşümünden yararlanarak (Motion - Scale invariant feature transform - MoSIFT) özellik çıkarmışlar ve sınıflandırma için DVM kullanmışlardır [6].

2018 yılında yapılan bir çalışmada güvenlik kameralarından gelen görüntülerin düşük seviyeli özelliklerini çıkarmak için Yerel Yönlü Gradyan Histogramı (Local Histogram of Oriented Gradient - LHOG) ve Optik Akı Yön Histogramı (Local Histogram of Optical Flow - LHOF) tabanlı betimleyiciler kullanılmış ve şiddet içeren görüntüler DVM tabanlı bir model ile sınıflandırılmıştır [7].

Şiddet içerikli video görüntülerinin analizi hakkında yapılan çalışmalardan biri Ullah ve arkadaşları tarafından yayınlanmıştır [8]. Önerilen sistemde diğer çalışmalardan farklı olarak videonun tamamını işlemek yerine, ilk önce insan içeren çerçeveler tespit edilmiş, ardından bu çerçeveler Evrişimsel Sinir Ağları (Convolutional Neural Networks) kullanılarak şiddet içeren ve içermeyen olarak iki sınıfa ayrılmıştır. Araştırmacılar önerdikleri sistemi hokey ligi maç videoları [6], 246 youtube videosundan oluşan Violent Crowd veri seti [9] ve kavga sahneleri içeren film görüntüleri [6] üzerinde denemişler ve ortalama %97 doğruluk oranı ile şiddet içerikli sahneleri tespit ettiklerini kaydetmişlerdir.

Video görüntülerde şiddet içeriği tespitine yönelik en son çalışmalardan biri Peixoto ve arkadaşları tarafından yapılmıştır [10]. Bu çalışmada videolar içinde kan, silah, patlama ve yangının da olduğu yedi kategoride değerlendirilerek şiddet içeren ve içermeyen olarak sınıflandırılmaktadır.

Son yıllarda yapılan çalışmalara bakıldığında özellikle derin öğrenme mimarilerinin kullanılması ile şiddet içerikli görüntülerin tespitinde oldukça başarılı sonuçlar elde edildiği gözlenmektedir. Bu çalışmalar temel olarak videolardaki hareket özelliklerinden yararlanmaktadır. Ancak hareketlilik göstermediği halde özellikle kan içeren görüntüler yüksek oranda şiddet içerebilmektedirler. Bu sebeple kanlı görüntülerin tespiti ve kanlı bölgenin bölütlenerek otomatik olarak filtrelenmesi üzerinde durulması gereken başka bir problem olarak karşımıza çıkmaktadır ve kendine has bazı zorluklar içermektedir. Kanın yayılma şekli ve görüntü içerisinde kapladığı alan görüntüden görüntüye önemli farklılar arz etmektedir. Kan olmayan kırmızı renkli bölgelerin kanlı bölgeler ile karıştırılması oldukça olasıdır. Literatürde kanlı bölgelerin tespiti ve bölütlenmesi üzerine yapılmış çok az çalışma bulunmaktadır. Kan içeren bölgelerin bulunması için başvurulan yaklaşımlardan biri piksel bazlı modeller kullanmaktır. Fakat kan görüntüsünün bazı özellikleri, doku gibi, bölgeye dayalı bir yaklaşım ile kullanılabilir duruma gelmektedir.

Tıbbi amaçlarla çeşitli tıbbi görüntüleme cihazları ile alınmış görüntülerde kanama ve kan damarı bulma çalışmaları [11] ve adli bilimlere yönelik kan lekesi analiz etme çalışmaları bulunmakla birlikte [12], şiddet tespitine yönelik olarak multimedia kaynaklardan alınmış görüntüler üzerinde kanlı bölgelerin bölütlenmesine ait çok az sayıda çalışma bulunmaktadır. Bunlardan en güncel ve yüksek başarıyla olanı Yan Gao ve arkadaşları tarafından geliştirilmiştir [13]. Bu çalışmada görüntüler üzerinde bölgeye dayalı (region based) kan rengi tespiti üzerine çalışılmıştır. Görüntüden özelliklerin çıkarılması sırasında sabit boyutlu, 16x16 boyutundaki bir pencere resim üzerinde gezdirilerek her bir alandan renk ve doku özellikleri çıkartılmıştır. Bu özelliklerin sınıflandırılmasında DVM algoritmasından yararlanılmıştır.

Bu çalışmada girdi olarak verilen resim dosyalarındaki kanlı kısımları otomatik olarak tespit ederek filtreleyen, bölge tabanlı bir sistem tasarlanmış ve gerçekleştirilmiştir. Ancak kanlı bölgeler düzgün bir geometrik şekle sahip alanlar değildir. Bu sebep ile sistemde resmin bölütlenmesi sırasında, kanın yayılma şekli ile uyumlu ve doğal bölgeler elde etmek amacı ile diğer çalışmalardan farklı olarak süper piksel yöntemi kullanılmıştır. Süper piksel bölütleme algoritmasının kullanılması ile kan bölgesi gibi düzgün bir geometrik şekle sahip olmayan alanların sınırlarının bulunmasında ve incelenmesinde daha yüksek başarıya ulaşılması hedeflenmiştir.

Oluşturulan süper piksellerden çıkarılan özelliklerin sınıflandırılmasında DVM algoritması kullanılmıştır. “Süper piksel ile Kanlı Bölgelerin Tespiti” ve “Sistem Arayüzü” bölümlerinde sırasıyla önerilen sistemin

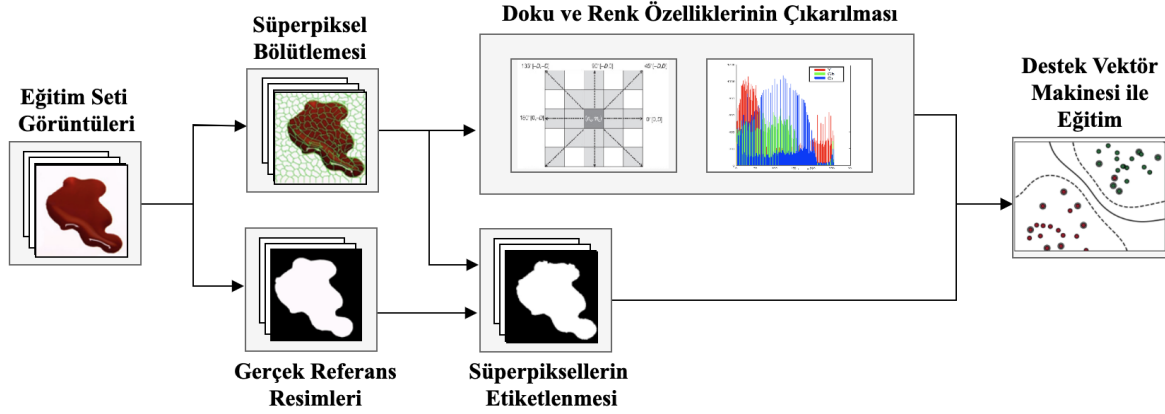
detayları verilmiş ve gerçekleştirilen kullanıcı arayüzü anlatılmıştır. “DeneySEL Sonuçlar” kısmında süper piksel sayısı, çekirdek fonksiyonu gibi parametrelerin sonuçlara etkisi incelenmiş, sistemin genel performansının karşılaştırmalı analizine yer verilmiştir.

II. SÜPER PİKSEL İLE KANLI BÖLGELERİN TESPİTİ

Önerilen süper piksel tabanlı kanlı bölge tespit sisteminin eğitimi aşaması, eğitim kümesindeki resimlerin süper piksel algoritması ile bölütlenmesi ile başlamaktadır. Elde edilen süper pikseller, el ile

oluşturulmuş gerçek referans resimleri ile birlikte değerlendirilerek kan içeren ve içermeyen süper pikseller olarak işaretlenmiştir. Ardından her bir süper pikselin kendi içerisinde renk ve doku olmak üzere iki ana grup özelliği çıkartılmıştır. Elde edilen özellik vektörleri, etiket bilgileri ile birlikte kullanılarak DVM ile eğitim modeli oluşturulmuştur. Eğitim aşamasına ait blok diyagram Şekil 1’de görülmektedir.

Test edilecek resim sırasıyla süper piksel bölütlemesi ve özellik çıkarma aşamalarından geçerek DVM’ye aktarılmakta ve kanlı bölge içeren süper pikseller filtrelenmektedir.



Şekil 1. Süper piksel tabanlı kanlı bölge tespit sisteminin eğitimi aşaması

2.1. Veri Setinin Oluşturulması

Literatürde kanlı bölgelerin işaretlenmiş olduğu açık bir veri seti bulunmamaktadır. Bu sebeple kanlı bölge bölütlemesi yapan az sayıda çalışmada da yazarlar kendi oluşturdukları veri setlerini kullanmışlardır. Bu çalışmada kullanılan veri seti, içerisinde şiddet içerikli film sahnelerinin bulunduğu Violent Scenes Dataset [6]’ten alınan düşük, orta ve yüksek miktarda kan içeren sahnelerden ve hiç kan barındırmayan görüntülerden oluşan 160 adet fotoğraf içermektedir.

Veri setindeki fotoğraflarda kan içeren bölgeler el ile işaretlenmiştir. Fotoğrafların çözünürlükleri 500*334 ile 1200*1080 arasında değişmektedir.

Veritabanında bulunan ve kan görüntüsü içeren örnekler Şekil 2’de ilk satırda verilmiştir. Orijinal görüntü üzerinde el ile işaretleme yapılarak elde edilen gerçek referans resimleri ise ikinci satırda yer almaktadır. Kan içeren bölgeler beyaz renk ile işaretlenmiştir.



Şekil 2. Veri setinden kan görüntüsü içeren örnekler ve kan içeren bölgelerin el ile işaretlenmesi ile elde edilen gerçek referans resimleri



Şekil 3. Veri setinden kan görüntüsü içermeyen örnekler

2.2. Süper Piksel Bölütlemesi

Dijital görüntü işlemede bir görüntü yansıyan ışığın ayrık olarak örneklenmesinin sonucudur. h yüksekliğine ve w genişliğine sahip bir I görüntüsü ayrık ve $i \in H = \{1, \dots, h\}$ ile $j \in w = \{1, \dots, w\}$ aralığındaki P_{ij} pikselleri üzerinde, c adet kanala ve her kanalın D değer kümesine sahip olduğu $I = W \times H \rightarrow D^c$ şeklindeki bir vektör fonksiyonudur. Verilen bir P piksel kümesine sahip I görüntüsünün $S = \{S_1, \dots, S_m\}$ olacak şekilde ayrık alt kümelere ayrılması resim bölütleme olarak isimlendirilir [14].

Var olan pek çok bilgisayarla görme algoritması, resim üzerindeki objelerin aranması için obje tespit pencereleri (detection windows) kullanmaktadır [15]. Fakat tespit pencereleri doğal bir gösterim şekli değildir. Düşük seviye gruplama kullanılarak elde edilen anlamlı parçalar ile çalışmak daha doğal ve daha etkili olacaktır.

Alan bölütlemesindeki genel yaklaşımlar yoğunluk eşliğine dayalıdır ve homojen nesnelerin bulunduğu görüntülerde iyi sonuçlar üretirler. Fakat birçok görüntü gürültü, doku, parazit, yankı içerir ve bunların herbiri alan bölütlemesi uygulamalarının etkinliğini azaltır. Homojen olmayan nesnelerin bulunduğu görüntülere yoğunluk eşliğine dayalı tekniklerin uygulanması bölütlemenin çok yüzeysel veya çok detaylı olması ile sonuçlanabilir. Bu iki sonuç sırası ile az bölütleme (under segmentation) ve fazla bölütleme (over segmentation) olarak adlandırılır. Fazla bölütleme önemli sınırların elde edilmesi şansını artırırken bunun yanında birçok önemsiz sınır oluşturma riskini de artırır.

Süper piksel bölütlenmesi bir görüntünün fazla bölütlenmesi olarak tanımlanabilir. Diğer bir deyiş ile piksellerin anlamlı bir biçimde gruplanmasıdır. Nesnelere karşılık gelen birkaç adet ön plan bölgesinin bulunması yerine süper piksel algoritmaları görüntüyü genellikle 25 ile 2500 adet bölgeye ayırırlar. Bu fazla bölütlemenin amacı görüntüyü hiçbir süper pikselin bir nesne sınırı tarafından kesilmeyecek şekilde bölmektir. Fakat bir nesne birden çok süper piksele bölünmüş olabilir. Bu şekilde nesnelerin sınırları, oluşturulan süper piksel sınırları kullanılarak elde edilebilecektir. Bu çalışmada elde edilen süper pikseller SEEDS algoritması ile oluşturulmuştur [16]. Süper piksel bölütlemesi SEEDS yönteminde bir enerji maksimizasyonu problemi olarak ele alınmıştır. N

resimdeki piksel sayısı, K istenilen süper piksel sayısı olarak kabul edilirse resme uygulanacak süper piksel bölütlemesi **Eşitlik (1)**'deki gibi ifade edilebilir.

$$s: \{1, \dots, N\} \rightarrow \{1, \dots, K\} \quad (1)$$

$s(i)$, i pikselinin bulunduğu süper pikseli gösterir. k süper pikselinde bulunan tüm pikseller A_k , **Eşitlik (2)** ile gösterilir.

$$A_k = \{i: s(i) = k\} \quad (2)$$

Geçerli bir süper piksel, uzamsal olarak bağlantılı pikseller içeren bir öbek şeklinde olmalıdır. S geçerli süper piksellerin oluşturduğu bölütlemeler kümesi, \bar{S} geçersiz süper piksellerin oluşturduğu bölütlemeler kümesi ve C olası tüm bölütlemelerin toplam kümesi olarak tanımlanırsa, süper piksel probleminin hedefi $s \in S$ olan ve belirli bir fonksiyonu maksimize eden s bölütlemesini bulmaktır. Bu belirli fonksiyon bu durumda enerji fonksiyonudur. Enerji fonksiyonu $E(s, I)$ şeklinde ifade edilebilir. Bu ifadede I girdi resim dosyasını göstermektedir.

Enerji fonksiyonunun I parametresine bağımlılığı notasyon kolaylığı sağlaması için göz ardı edilirse, enerji fonksiyonunu maksimize eden s^* bölütlemesi **Eşitlik (3)** ile gösterilir.

$$s^* = \operatorname{argmax} E(s) \quad (3)$$

Optimize edilmesi gereken enerji fonksiyonu $E(s)$, **Eşitlik (4)**'deki gibi ifade edilir.

$$E(s) = H(s) + \gamma G(s) \quad (4)$$


Bu denklemde γ terimlerin etki ağırlıklarını göstermek üzere $H(s)$ süper pikselin renk dağılımını değerlendirirken, $G(s)$ ise süper pikselin şeklini belirler.

Optimum süper piksel bölütlemesine ulaşmak için tepe tırmanma algoritması kullanılmıştır. Tepe tırmanma algoritması her bir iterasyonda küçük yerel değişimler uygulayarak çözümü güncelleyen bir optimizasyon algoritmasıdır. Bu örnekte önerilen bölütlemenin enerji fonksiyonu artar ise çözüm güncellenir.

Tepe tırmanışı algoritmasında global optimum çözüm olan s^* ulaşmak için iyi bir başlangıç bölütlenmesi

belirlenmesi önemlidir. SEEDS algoritmasında ilk bölütleme olarak eşit büyüklükte düzgün parçalar kullanılmaktadır. Şekil 5a'da verilen görüntü için 600

ve 900 süper piksel bölütlemesi sonuçları sırasıyla Şekil 5b ve c'de görülmektedir.



Şekil 5. a) Kan görüntüsü b) 600 c) 900 süper piksel üst sınırı için oluşturulan bölütleme sonuçları

2.3. Özelliklerin Çıkarılması

Kanlı bölgelerin tespit edilmesinde bu bölgelere ait renk ve doku özelliklerinden yararlanılmıştır.

2.3.1. Renk özelliklerinin çıkarılması

Renk özelliklerin çıkarılması sırasında süper pikseli oluşturan tüm piksellerin renk değerleri RGB renk uzayından YCbCr renk uzayına dönüştürülmüştür. YCbCr renk uzayında Y değeri siyah-beyaz, Cb mavi ve Cr kırmızı renk bilgilerini temsil etmektedir. Daha sonra bu piksellerin her bir bileşeni için ortalama, standard sapma ve varyans değerleri hesaplanmıştır.

2.3.2. Doku özelliklerinin çıkarılması

Doku özelliklerinin çıkarılması sırasında Gri Seviye Eş Oluşum Matrisi (GSEOM) yöntemi kullanılmıştır [17]. GSEOM yöntemi iki piksel arasındaki komşuluk ilişkisini inceler. Piksellerden bir tanesi referans diğeri ise komşu olarak isimlendirilir. Belirli bir yönde (sağ, sol, yukarı veya aşağı) belirli bir ikilinin kaç kez ortaya çıktığı bir tabloda kayıt altına alınır.

GSEOM'nin belirli özellikleri sağlaması gerekmektedir. Bunlar;

1. Matris kare şeklinde olmalıdır. Referans pikseli ve komşu piksel aynı değer aralığında olduğu için matrisin satır ve sütun sayıları aynı olmalıdır.
2. Matrisin satır ve sütun sayısı görüntünün kuantalama (quantization) seviyesi ile aynı sayıda olmalıdır.
3. Matris köşegenine göre simetrik olmalıdır.

GSEOM'den doku ölçülerinin çıkarılması için son olarak matrisin normalizasyonu gereklidir. q , görüntünün kuantalama seviyesi ve $N=q*q$ olmak üzere elde edilen N boyutundaki GSEOM V ile gösterilmişken, normalize edilmiş GSEOM P , Eşitlik (5) ile elde edilir.

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i,j=0}^{N-1} V_{i,j}} \quad (5)$$

Normalize edilmiş simetrik GSEOM'yi işe yarar şekilde özetlemek amacı ile doku ölçüleri hesaplanır. Birçok doku ölçüsü matrisin çeşitli şekillerde ağırlıklı ortalamasının alınması şeklinde elde edilir.

$$\sum_{i,j=0}^{N-1} P_{i,j} |i,j|^2 \quad (6)$$

Kontrast ölçüsü Eşitlik (6) ile hesaplanır. Formülde verilen i ve j değerleri matrisin satır ve sütunlarının indeks değerleri, N belirlenen matris boyutu olmak üzere, i ve j değerleri birbirlerine eşitken seçilen hücre, matrisin köşegeni üzerindedir. Hiçbir kontrast oluşturmadıkları için kontrast ağırlıkları sıfırdır. Kontrast, i ve j değerlerinin farkı arttıkça (matrisin köşegeninden uzaklaştıkça), üstel olarak artmaktadır [18].

$$\sum_{i,j=0}^{N-1} P_{i,j} |i-j| \quad (7)$$

Benzeşmezlik ölçüsü Eşitlik (7) ile hesaplanır. Benzeşmezlik ölçüsünde köşegenden uzaklaştıkça ağırlık üstel olarak artarak yerine doğrusal olarak artmaktadır.

$$\sum_{i,j}^{N-1} \frac{P_{i,j}}{1-(i-j)^2} \quad (8)$$

Homojenlik ölçüsü Eşitlik (8) ile hesaplanır ve GSEOM üzerinde sıfırdan farklı hücrelerin homojenliğini göstermektedir. Yüksek homojenlik görüntü üzerinde tekrarlı yapıların azlığına işaret etmektedir.


Süper piksel bölütlemesi sonrasında oluşan süper pikseller düzgün bir şekle sahip olmadıklarından doku özellikleri çıkarılacak her bir süper piksel ayrı ayrı ele alınır. İlk adımda her süper pikselin ağırlık merkezi hesaplanmıştır. Ardından bu ağırlık merkezinin çevresinden $8*8$ boyutunda örnek bir kare pencere alınarak bu karenin doku özellikleri hesaplanmış ve ilgili süper piksel ile ilişkilendirilmiştir.

2.4. Süper Piksellerin Etiketlenmesi

Her bir süper piksel için renk ve doku özellikleri çıkarılmasının ardından, eğitim aşamasında kullanılmak üzere her süper pikselin kan görüntüsü içerip içermediğini etiketlemek gerekmektedir. Bunun için orjinal resimlerde kanlı bölgeleri el ile işaretleyerek elde edilen referans resim kullanılır. Bölütleme sırasında her bir süper piksel için süper pikselin sınırlarını belirleyen bir kontur maskesi oluşturulmaktadır. Bu maske ve orjinal resimde kan içeren bölgeyi gösteren referans resmin

karşılaştırılması ile süper piksel pozitif veya negatif olarak etiketlenir.

Bu aşamada her iki görüntü ikili tabana dönüştürüldükten sonra aralarında mantıksal VE işlemi uygulanır. Sonuçta oluşan bölgenin alanının süper pikselin alanına oranı alınarak belirlenen sınırın üstündeki değerlerde süper piksel pozitif, diğer durumda ise negatif olarak etiketlenir. Veri setinden bir örnek, bu örnek için gerçek referans resmi ve süper piksellerin etiketlenmesi ile oluşturulmuş resim sırasıyla Şekil 6-a, b ve c'de verilmiştir.



Şekil 6. a) Veri setinden bir resim b) Gerçek referans resmi c) Eğitim için kullanılacak etiketlenmiş resim

2.5. Sınıflandırma

Özellik çıkartma sonucunda elde edilen eğitim veri kümesinin sınıflandırılmasında DVM kullanılmıştır.

DVM datayı en optimum şekilde iki sınıfa ayırarak karar yüzeyini (decision surface) bulmayı hedefler [19]. Bir DVM'nin karar fonksiyonu, eğitim verisi içinden karar yüzeyinin pozisyonunu belirleyen küçük bir alt kümenin seçilmesi ile belirlenir. Bu alt kümedeki örnekler destek vektörleri olarak adlandırılmaktadır. Karar yüzeyi ile bu yüzeye en yakın eğitim örneklerinin uzaklığı sınıflandırıcının marjı olarak adlandırılır. Destek vektörler, eğitim kümesi içinden maximum marja sahip karar yüzeyini belirleyecek şekilde seçilir. Bir DVM'nin karar fonksiyonu **Eşitlik (9)** ile verilmiştir. Karar fonksiyonunun işareti sınıflandırılacak test örneği x 'in ait olduğu sınıfı göstermektedir.

$$f(x) = \sum_{i=1}^M y_i a_i(x_i \cdot x) + b \quad (9)$$

Burada M , eğitim setindeki örnek sayısı ve $i=1..M$ olmak x_i i. eğitim örneği, y_i ilgili örneğin sınıf bilgisi, b (bias - düzeltme katsayısı) ve a_i ise eğitim esnasında tahmin edilen scalar bir değerdir. Yalnızca destek vektörleri olarak kullanılacak eğitim örneklerinin a_i katsayıları 0'dan farklıdır.

DVM çekirdek (kernel) olarak tanımlanan bir grup matematiksel fonksiyon kullanır. Çekirdek fonksiyonlarının amacı, doğrusal olarak ayrılamayan veriyi yeni bir uzaya geçirerek ayrılabilir forma çevirmektir. Farklı DVM algoritmaları farklı çekirdek fonksiyonları kullanabilir. Doğrusal ve radyal tabanlı çekirdek fonksiyonları bunlara örnek olarak verilebilir

[20]. Geliştirilen sistemde doğrusal ve radyal tabanlı çekirdek fonksiyonları kullanılmıştır.

III. SİSTEM ARAYÜZÜ

Veri setinden elde edilen modeller kullanılarak Python programlama dilinde bir masaüstü uygulama geliştirilmiştir. Geliştirilen uygulamanın arayüzünden bir ekran görüntüsü Şekil 7'de verilmiştir. Bu uygulama, veri setinden elde edilen modelleri kullanarak girdi olarak verilen resim dosyalarındaki kanlı bölgeleri tespit etmektedir.

Program başlatıldığında kullanıcıdan girdi olarak bir görüntü dosyasını seçmesi istenmektedir. Bu görüntü dosyası ile birlikte kullanıcının kullanılacak modele ait hiperparametreleri de (süper piksel üst sınırı, kullanılacak çekirdek fonksiyonu ve DVM'nin C ceza parametresi değeridir) seçmesi gerekmektedir. Daha sonrasında sistem görüntünün işlenmesini başlatır ve çıktı olarak kanlı bölgelerin işaretlenmiş olduğu resim dosyasını ve bölütlenmiş görüntüyü üretir.



Şekil 7. Kullanıcı arayüzü

IV. DENEYSEL SONUÇLAR

DVM algoritmasının performansını belirleyen faktörler arasında kullanılan çekirdek fonksiyonu ve C ceza parametresi önemli bir yer tutar.


En uygun destek vektörleri ve düzeltme katsayısını bulmak için yapılan DVM optimizasyonunda bir eğitim verisinin daha doğru ayrılması ve karar fonksiyonunu marjının maximize edilmesi arasında seçim yapmak için C ceza parametresi kullanılır. Daha büyük C değerleri daha dar bir marjine sahip karar fonksiyonları üretir, bu da eğitim verisinin daha yüksek başarı ile sınıflandırılmasını sağlar. Daha küçük C değerleri kullanıldığında ise daha basit dolayısı ile aşırı öğrenme (overfitting) ihtimali daha düşük karar fonksiyonları üretilir [21].

DVM uygulanırken lineer ve radyal çekirdek fonksiyonları ve farklı C değerleri kullanılmış, elde edilen farklı modellerin başarı sonuçları karşılaştırılmıştır.

Bununla birlikte resimlerin ayrılabilmesi maksimum süper piksel sayısı da modelin başarısını

etkilemektedir. Bu parametrelerin sistemin başarısına etkisinin ölçülmesi amacı ile oluşturulacak süper piksellerin üst sınırı 600, 900, 1200 olmak üzere üç farklı şekilde denenmiştir. İçerisinde kan görüntüsü içeren ve içermeyen görüntülerin karışık bir şekilde bulunduğu veri seti, iki farklı çekirdek fonksiyonu, üç farklı üst süper piksel sayısı ve üç ayrı C değerinin kombinasyonları ile elde edilmiş toplamda 18 farklı model ile test edilmiştir.

Modellerin test edilmesi sırasında el ile oluşturulan maske ve programın oluşturduğu maske karşılaştırılarak elde edilen sonuç değerlendirilmiştir. Şekil 8'in ilk kolonunda veri setinde bulunan görüntülerden örnekler verilmiştir. 1200 süper piksel için elde edilen bölütleme sonuçları ortadaki kolonda görülmektedir. Süper piksel tabanlı kanlı bölge tespiti algoritması ile alınan sonuçlar ise en sağdaki kolonda verilmiştir. Yeşil alanlar kan içeren ve önerilen sistem ile doğru tahmin yapılan kısımları, kırmızı bölgeler kan içeren ancak sistem tarafından tespit edilememiş bölgeleri ve mavi kısımlar ise kan içermediği halde programın kan olarak tespit ettiği bölgeleri göstermektedir.



Şekil 8. (a) Veri setinden orijinal resim örnekleri (b) 1200 süper piksel için bölütleme sonucu (c) Süper piksel tabanlı kanlı bölge tespit etme sisteminin sonuçları. Yeşil bölgeler doğru kabulleri, kırmızı bölgeler yanlış redleri ve mavi bölgeler ise yanlış kabulleri göstermektedir.

Süper piksel üst sınırı 600, 900 ve 1200 iken farklı çekirdek fonksiyonları ve C parametreleri kullanılarak elde edilen başarı oranları sırasıyla Tablo 1, Tablo 2 ve Tablo 3'de verilmiştir. Kısıtlı bir veri seti ile yapılan

testlerin güvenilirliğini temin etmek adına K katlamalı çapraz doğrulama kullanılmıştır. K verinin bölüneceği parça sayısı olmak üzere, test sonuçları K=20 için hesaplanmıştır.

Tablo 1. Süper piksel üst sınırı 600 iken elde edilen başarı oranları

Doğrusal Çekirdek Fonksiyonu				
C Değeri	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
0.1	0.95	0.80	0.63	0.69
1	0.95	0.79	0.63	0.69
3	0.95	0.78	0.63	0.69
Radyal Tabanlı Çekirdek Fonksiyonu				
C Değeri	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
0.1	0.96	0.88	0.71	0.78
1	0.97	0.88	0.73	0.80
3	0.97	0.87	0.75	0.81

Tablo 2. Süper piksel üst sınırı 900 iken elde edilen başarı oranları

Doğrusal Çekirdek Fonksiyonu				
C Değeri	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
0.1	0.95	0.79	0.63	0.69
1	0.95	0.78	0.64	0.69
3	0.95	0.77	0.64	0.69
Radyal Tabanlı Çekirdek Fonksiyonu				
C Değeri	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
0.1	0.96	0.88	0.71	0.78
1	0.97	0.86	0.78	0.82
3	0.97	0.85	0.80	0.82

Tablo 3. Süper piksel üst sınırı 1200 iken elde edilen başarı oranları

Doğrusal Çekirdek Fonksiyonu				
C Değeri	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
0.1	0.94	0.80	0.48	0.57
1	0.94	0.79	0.55	0.64
3	0.94	0.79	0.56	0.64
Radyal Tabanlı Çekirdek Fonksiyonu				
C Değeri	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
0.1	0.97	0.89	0.72	0.79
1	0.97	0.87	0.78	0.82
3	0.97	0.86	0.79	0.82

Oluşturulan modellerden elde edilen sonuçlar süper piksel üst sınırı parametresine göre incelendiğinde, tüm süper piksel üst sınırları için radyal bazlı çekirdek fonksiyonu doğrusal çekirdek fonksiyonuna göre daha iyi sonuçlar ürettiği gözlemlenmiştir. C parametresinin değişimi ile doğruluk ve hassasiyette ciddi değişimler görülmemiştir. Tüm bu sonuçlar göz önüne alındığında süper piksel üst sınırı arttıkça modelin daha başarılı sonuçlar ürettiği söylenebilir. Ayrıca C parametresinin düşük değerleri daha başarılı sonuçlar vermektedir. En yüksek başarı oranı; 1200 süper piksel üst sınırı, radyal bazlı çekirdek fonksiyonu ve C=3 kombinasyonu ile elde edilmiştir (Tablo 3’de kırmızı ile işaretlenmiştir).

Literatürde bölütlenmiş kanlı bölgeleri içeren açık bir veri seti bulunmamaktadır. Bu çalışmada önerilen süper piksel tabanlı kanlı bölge tespit sisteminin başarısının mevcut metotlar ile karşılaştırılabilmesi için, Yan Gao ve arkadaşlarının geliştirdiği sabit pencere boyutu ve DVM tabanlı sistem [13], bu çalışma kapsamında oluşturulan veri setine uygulanmış ve elde edilen sonuçlar değerlendirilmiştir. Yan Gao ve arkadaşlarının önerdiği çözüm aynı test kümesine uygulandığında elde edilen doğruluk, kesinlik, geri çağırma, F Skoru ve birleşimlerin kesişimi (IoU-Intersection Over Union) değerleri [22] ve önerilen süper piksel tabanlı yöntem ile elde edilen en iyi sonuçlar karşılaştırılmalı olarak Tablo 4’de verilmiştir.

Tablo 4. Yan Gao ve arkadaşlarının önerdiği çözüm ile önerilen süper piksel tabanlı yöntemin karşılaştırmalı sonuçları

Çalışma	Birleşimlerin Kesişimi	Doğruluk	Kesinlik	Geri Çağırma	F Skoru
Önerilen Süper piksel Tabanlı Yöntem	0.71	0.97	0.86	0.79	0.82
Yan Gao ve arkadaşları [13]	0,64	0.96	0.87	0.70	0.77

Bu sonuçlar göz önüne alındığında birleşimlerin kesişimi, doğruluk, geri çağırma ve F Skoru değerlerinde süper piksel bölütlemesi kullanılan modelin daha başarılı sonuçlar aldığı görülmektedir. Süper piksel tabanlı sistem ile sabit pencere tabanlı sistemin başarı oranlarındaki en büyük fark geri çağırma oranında kaydedilmiştir. Bu fark sabit pencere tabanlı sistemin yüksek yanlış negatif oranından

kaynaklanmaktadır. Düşük yanlış negatif oranına sahip olması, kanlı bölgeleri kaçırılmadan filtrelediği için süper piksel tabanlı sistemi pratik olarak daha kullanışlı hale getirmektedir. Önerilen yöntemin birleşimlerin kesişimi oranı da sabit pencere tabanlı sisteme göre oldukça yüksektir. Birleşimlerin kesişimi oranı özellikle arka plana ait piksel sayısının ilgi bölgesine ait alana göre oldukça fazla olduğu problemlerde

başarılı bir ölçüm metriği olarak karşımıza çıkmaktadır [23]. Önerilen sistem ile elde edilen yüksek birleşimlerin kesişimi oranı sistemin daha güvenilir bir yapıda olduğunu ortaya koymaktadır.

Şekil 9'da veri setinden örnek resimler için süper piksel tabanlı sistemin ürettiği ve Yan Gao ve arkadaşlarının önerdiği sistemin ürettiği sonuçlar verilmiştir.



Şekil 9. (a) Veri setinden örnek resimler (b) Süper piksel tabanlı sistemin ürettiği sonuçlar (c) Yan Gao ve arkadaşlarının önerdiği sistemin ürettiği sonuçlar

Verilen örneklerde görüldüğü üzere bir fazla bölütleme yöntemi olan süper piksel bölütlemesi sabit pencere yöntemine göre nesnelerin sınırlarını bulmada daha başarılıdır. Bu özellik özellikle daha organik ve düzenli olmayan sınırları tespit etmede başarı oranını arttırmaktadır.

V. SONUÇ ve GELECEK ÇALIŞMALAR

Gerçekleştirilen projenin amacı verilen bir görüntü dosyası içerisinde kan içeren bölgelerin tespit edilmesidir. Bu amaca yönelik olarak, toplanan çeşitli görüntü dosyalarından renk ve doku özellikleri çıkartılmıştır. Bu özellikler çıkartılırken alandaki diğer çalışmalardan farklı olarak görüntü dosyası süper piksellere ayrılmış ve daha doğal bir bölütleme elde edilmiştir. Böylece özellik çıkarma işleminin daha

etkili yapılması sağlanmıştır. Süper piksel bölütlemesi sonucunda oluşan her bir parçadan renk özellikleri, doku özellikleri ve kan içerip içermediği bilgisi alınarak her bir süper pikselden bir özellik vektörü elde edilmiştir. Elde edilen vektörlerden DVM algoritması yardımıyla ve farklı çekirdek fonksiyonları kullanılarak modeller oluşturulmuştur. Bu modeller kullanılarak test kümesi üzerinde deneyler yapılmıştır.

Deneyler sonucunda kullanılan süper piksel üst sınırı sayısı arttığında başarı oranının da arttığı gözlemlenmiştir. Radyal tabanlı çekirdek fonksiyonu doğrusal çekirdek fonksiyonundan daha başarılı sonuçlar üretmiştir.

Oluşturulan model Yan Gao ve arkadaşları tarafından geliştirilmiş olan algoritma ile karşılaştırıldığında

özellikle kesişimlerin birleşimi, geri çağırma ve F Skoru parametrelerinde daha başarılı sonuçlar elde edildiği gözlenmiştir. Ancak geliştirilen sistemin test kümesinde bulunan bazı görüntülerdeki kan ile benzer renk ve doku özellikleri gösteren nesnelere ayırmada istenilen başarıyı gösteremediği görülmüştür. Bu sorunun aşılması için gelecek çalışmalarda işaretlenen bölgenin renk ve doku özellikleri yanı sıra şekil özellikleri de değerlendirmeye alınabilir. Sınıflandırma için derin öğrenme mimarilerinin kullanılması da daha yüksek başarı oranlarının elde edilmesini sağlayacaktır. Oluşturdukları doğal sınırların bölütleme başarısına katkısından dolayı son yıllarda süper piksel tabanlı bölütlemeyi derin öğrenme metodları ile birleştiren çalışmalar yayınlanmaya başlamıştır [24, 25]. Bu yaklaşım kanlı bölge tespiti için kullanıldığında başarıyı önemli ölçüde arttıracaktır. Geliştirilen yöntem uygun veri seti ile eğitilmesi halinde sadece kanlı görüntülerin değil, pornografik görüntülerin tespiti için de kullanılabilir niteliktedir.

KAYNAKLAR

- [1] Hu, W., Zuo, H., Wu, O., Chen, Y., Zhang, Z., & Suter, D. (2011). Recognition of adult images, videos, and web page bags. *ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)*, 7(1), 1-24.
- [2] Lopes, A. P., de Avila, S. E., Peixoto, A. N., Oliveira, R. S., & Araújo, A. D. A. (2009, August). A bag-of-features approach based on hue-sift descriptor for nude detection. In *2009 17th European Signal Processing Conference* (pp. 1552-1556). IEEE.
- [3] Guermazi, R., Hammami, M., & Hamadou, A. B. (2009, October). Violent web images classification based on MPEG7 color descriptors. In *2009 IEEE International Conference on Systems, Man and Cybernetics* (pp. 3106-3111). IEEE.
- [4] Wang, D., Zhang, Z., Wang, W., Wang, L., & Tan, T. (2012, September). Baseline results for violence detection in still images. In *2012 IEEE Ninth International Conference on Advanced Video and Signal-Based Surveillance* (pp. 54-57). IEEE.
- [5] Li, B., Xiong, W., Wu, O., Hu, W., Maybank, S., & Yan, S. (2015). Horror image recognition based on context-aware multi-instance learning. *IEEE Transactions on Image Processing*, 24(12), 5193-5205.
- [6] Nieves, E. B., Suarez, O. D., García, G. B., & Sukthakar, R. (2011, August). Violence detection in video using computer vision techniques. In *International conference on Computer analysis of images and patterns* (pp. 332-339). Springer, Berlin, Heidelberg.
- [7] Zhou, P., Ding, Q., Luo, H., & Hou, X. (2018). Violence detection in surveillance video using low-level features. *PLoS one*, 13(10), e0203668.
- [8] Ullah, F. U. M., Ullah, A., Muhammad, K., Haq, I. U., & Baik, S. W. (2019). Violence detection using spatiotemporal features with 3D convolutional neural network. *Sensors*, 19(11), 2472.
- [9] Hassner, T., Itcher, Y., & Kliper-Gross, O. (2012, June). Violent flows: Real-time detection of violent crowd behavior. In *2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops* (pp. 1-6). IEEE.
- [10] Peixoto, B., Lavi, B., Bestagini, P., Dias, Z., & Rocha, A. (2020, May). Multimodal Violence Detection in Videos. In *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 2957-2961). IEEE.
- [11] Obukhova, N., Motyko, A., Timofeev, B., & Pozdeev, A. (2019, April). Method of Endoscopic Images Analysis for Automatic Bleeding Detection and Segmentation. In *2019 24th Conference of Open Innovations Association (FRUCT)* (pp. 285-290). IEEE.
- [12] Arthur, R. M., Hoogenboom, J., Baiker, M., Taylor, M. C., & de Bruin, K. G. (2018). An automated approach to the classification of impact spatter and cast-off bloodstain patterns. *Forensic science international*, 289, 310-319.
- [13] Gao, Y., Wu, O., Wang, C., Hu, W., & Yang, J. (2015, July). Region-based blood color detection and its application to bloody image filtering. In *2015 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)* (pp. 45-50). IEEE.
- [14] Neubert, D. I. P. (2015). Superpixels and their application for visual place recognition in changing environments.
- [15] Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2020). Deep learning for generic object detection: A survey. *International journal of computer vision*, 128(2), 261-318.
- [16] Van den Bergh, M., Boix, X., Roig, G., de Capitani, B., & Van Gool, L. (2012, October). Seeds: Superpixels extracted via energy-driven sampling. In *European conference on computer vision* (pp. 13-26). Springer, Berlin, Heidelberg.
- [17] Marceau, D. J., Howarth, P. J., Dubois, J. M. M., & Gratton, D. J. (1990). Evaluation of the grey-level co-occurrence matrix method for land-cover classification using SPOT imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 28(4), 513-519.
- [18] Gebejes, A., & Huertas, R. (2013). Texture characterization based on grey-level co-occurrence matrix. *databases*, 9, 10.

-
- [19] Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE transactions on neural networks*, 10(5), 988-999.
- [20] Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293-300.
- [21] Ye, F., Zhang, Z., Chakrabarty, K., & Gu, X. (2016). Knowledge-driven board-level functional fault diagnosis. Springer.
- [22] Ali, S., Zhou, F., Daul, C., Braden, B., Bailey, A., Realdon, S., ... & Blondel, W. (2019). Endoscopy artifact detection (EAD 2019) challenge dataset. *arXiv preprint arXiv:1905.03209*.
- [23] van Beers, F., Lindström, A., Okafor, E., & Wiering, M. A. (2019). Deep Neural Networks with Intersection over Union Loss for Binary Image Segmentation. In *ICPRAM* (pp. 438-445).
- [24] Blanco, G., Traina, A. J., Traina Jr, C., Azevedo-Marques, P. M., Jorge, A. E., de Oliveira, D., & Bedo, M. V. (2020). A superpixel-driven deep learning approach for the analysis of dermatological wounds. *Computer methods and programs in biomedicine*, 183, 105079.
- [25] da Silva, G. L., Diniz, P. S., Ferreira, J. L., França, J. V., Silva, A. C., de Paiva, A. C., & de Cavalcanti, E. A. (2020). Superpixel-based deep convolutional neural networks and active contour model for automatic prostate segmentation on 3D MRI scans. *Medical & Biological Engineering & Computing*, 58(9), 1947-1964.