

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**SEFALOMETRİK RÖNTGEN GÖRÜNTÜLERİNDE HOG VE
KNN KULLANARAK ÖNEMLİ NOKTALARIN YER TESPİTİ**

YÜKSEK LİSANS TEZİ

Oğuz SÖZKESEN

**Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı**

Ağustos, 2021

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**SEFALOMETRİK RÖNTGEN GÖRÜNTÜLERİNDE HOG VE
KNN KULLANARAK ÖNEMLİ NOKTALARIN YER TESPİTİ**

YÜKSEK LİSANS TEZİ

**Oğuz SÖZKESEN
(Y1813.010017)**

**Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı**

Tez Danışmanı: Dr. Öğr. Üyesi Adem ÖZYAVAŞ

Ağustos, 2021

ONAY FORMU

ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduğum “Sefalometrik Röntgen Görüntülerinde HOG ve KNN Kullanarak Önemli Noktaların Tespiti” adlı çalışmamın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça 'da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim.
(12/08/2021)

Oğuz SÖZKESEN

ÖNSÖZ

Bu çalışmada, sefalometrik görüntüler üzerine manuel olarak yapılan yer işaretleri implantasyonu vakit alan ve beşerî hatalara açık bir yöntemdir. Bu nedenle görüntü işleme yöntemleri yardımı ile yer işareti implantasyonu esnasında geçen süreyi ve bu işlem sırasında oluşabilecek beşerî hata payını mümkün olan en aza indirmek için bir yöntem önerilmesi amaçlanmaktadır.

Bu bilimsel çalışmamın gerçekleştirilmesinde uzun süre boyunca değerli bilgilerini benimle paylaşan, kullandığı her cümlenin hayatıma kattığı önemini asla unutmayacağım saygıdeğer Dr. Öğr. Üyesi Adem ÖZYAVAŞ hocama ve ilim yolunda rotamızı çizen, başöğretmen, büyük devlet adamı Mustafa Kemal Atatürk'ün manevi şahsiyetine şükranlarımı sunmayı borç bilirim.

Ağustos,2021

Oğuz SÖZKESEN

SEFALOMETRİK RÖNTGEN GÖRÜNTÜLERİNDE HOG VE KNN KULLANARAK ÖNEMLİ NOKTALARIN YER TESPİTİ

ÖZET

Sefalometrik izleme, ortodontistler tarafından analiz ve tedavi planlaması için kullanılan standart bir tekniktir. Sefalometrik X-ray görüntülerindeki önemli noktalar uzmanlar tarafından işaretlenir. Bu yer işareti konumlarına dayalı ölçümler teşhis için kullanılmaktadır. Bu işlemi elle gerçekleştirmek sıkıcıdır ve bu nedenle uzmanlar için bile hataya açıktır. Bu nedenle, tam otomatik yer işareti yerelleştirme (FALL) yazılımı geliştirilmiştir. Bu çalışmanın amacı, yerelleştirme sürecini hızlandırmak için FALL yazılımı tarafından tespit edilecek yer işaretleri için arama alanını azaltmaya yardımcı olmaktır. Bu çalışma, Prn yer işareti tespiti üzerine odaklanmaktadır. Görüntünün Prn yer işaretini içerdiği kesin olan kısmı, 16x16 piksel boyutunda bloklara bölünmüştür. Her blok için, yönlendirilmiş gradyan histogramı hesaplanmıştır. Bu histogramlar, Prn yer işareti için histogramların pozitif ve negatif veri setini oluşturan daha önce elle oluşturulmuş olan histogramlarla karşılaştırılır. Prn içerip içermediğine bakılmaksızın blokların sınıflandırılması için K-en yakın komşular (KNN) algoritması kullanılmaktadır. Arama sonuçları, hiçbir doğru pozitifin kaçırılmadığı ve yanlış pozitiflerin sayısı en aza indirildiği için umut vericidir. Prn yer işaretini içeren blok %100 doğrulukla bulunmuştur. Po yer işaretini içeren blok %75 doğrulukla bulunmuştur. Pog işaretini içeren blok %87,5 doğrulukla bulunmuştur. Alt dudak yer işaretini içeren blok %87 doğrulukla bulunmuştur. N kemiği yer işaretini içeren blok %25 doğrulukla bulunmuştur. Daha sonra, yer işaretini belirlemek için hesaplama açısından daha zorlu bir algoritma kullanılabilir.

Anahtar Kelimeler: Özellik Çıkarma, HOG Algoritması, K-NN, Sefalometri, Görüntü İşleme

LOCALIZATION OF CERTAIN CEPHALOMETRIC LANDMARKS USING HOG AND KNN

ABSTRACT

Cephalometric tracing is a standard technique used by orthodontists for analysis and treatment planning. Important landmarks in cephalometric X-ray images are marked by experts. Measurements based on these landmark locations are used for diagnosis. Performing this process manually is tedious and hence error-prone even for experts. Therefore, fully automatic landmark localization (FALL) software has been developed. The aim of this study to help reduce the search area for landmarks to be detected by FALL software to speed up the process of localization. This study focuses on the Prn landmark detection. The portion of the image that is sure to contain the Prn landmark is divided into 16x16 pixels size windows. For each window, its histogram of oriented gradient is computed. These histograms are compared to the histograms created manually before that form the positive and negative dataset of histograms for Prn. K-nearest neighbors (KNN) algorithm is utilized for classification of the window whether it contains Prn or not. Search results are promising in that no true positives are missed and the number of false positives are minimized. The window that contains the Prn landmark is found with 100 % accuracy. The window that contains the Po landmark is found with 75% accuracy. Also, the window that contains the Pog landmark is found with 87.5% accuracy. The window that contains the lower lip landmark is found with 87.5% accuracy. The window that contains the N bone landmark is found with 25% accuracy. A computationally more demanding algorithm could then be used to pinpoint the landmark.

Keywords: Feature Extraction, HOG Algorithm, K-NN, Sephalometric, Image Processing

İÇİNDEKİLER

	<u>Sayfa</u>
ONUR SÖZÜ	i
ÖNSÖZ	ii
ÖZET	iii
ABSTRACT	iv
İÇİNDEKİLER.....	v
KISALTMALAR.....	vii
ÇİZELGE LİSTESİ.....	viii
ŞEKİLLER LİSTESİ	ix
I. GİRİŞ.....	1
II. GENEL BİLGİLER.....	3
III. METODLAR VE MATERYERLER.....	10
A. Bilinear Enterpolasyon.....	10
1. Verinin İşlenmesi (Processing)	14
2. Görüntülerin Gradyan Değerlerinin Hesaplanması.....	15
3. Gradyanların Histogramını 8×8 Hücrelerde Hesaplanması	16
B. K- En Yakın Komşular Algoritması	20
1. Manhattan Mesafesi	21
2. Minkowsky Mesafesi	21
3. Hamming Mesafesi	22
4. Öklid Mesafesi	22
5. Korelasyon Mesafesi	23

6. K-En Yakın Komşular Algoritması Nasıl Çalışır?	23
7. KNN Algoritmasında K Değerinin Belirlenmesi.....	25
IV. YÖNTEM.....	26
V. DENEYSEL SONUÇLAR.....	28
VI. GELECEKTE YAPILABİLECEK ÇALIŞMALAR.....	42
VII.SONUÇ.....	43
VIII. KAYNAKÇA.....	44
ÖZGEÇMİŞ	48

KISALTMALAR

- HOG** : Histogram of Oriented Gradients (Yönlendirilmiş Gradyanların Histogramı)
- KNN** : K-Nearest Neighbour (K-En Yakın Komşular)
- Po** : Alt çene kemiğinin uç kısmını temsil eden sefalometrik yer işareti
- Pog** : Çenenin ucundaki yumuşak dokusu temsil eden sefalometrik yer işareti
- Prn** : Burun ucunu temsil eden sefalometrik yer işareti
- SIFT** : Scale Invariant Feature Transform (Değişmez Ölçekli Özellik Dönüşümü)
- SURF** : Speeded-UP Robust Feature (Hızlandırılmış Güçlü Özellik Algoritması)

ÇİZELGE LİSTESİ

Sayfa

Çizelge 1. Mesafe metriklerine göre Knn sınıflandırmasının doğruluk değeri.....	3
Çizelge 2. SURF ve SIFT üzerinde sınıflandırıcı performanslarının karşılaştırılması.....	4
Çizelge 3. Yerel Özelliklerin Performansının Karşılaştırılması	4
Çizelge 4. PF01 yüz görüntüsü veri seti kullanılarak yapılan tanımının doğruluk dereceleri.....	6
Çizelge 5. Farklı yöntemlerin ALOI veri seti üzerinde kullanılarak elde edilen tanımının doğruluk dereceleri.....	6
Çizelge 6. Sefalometrik görüntüler üzerinde yer işaretlerinin bulunmasına yönelik literatürde yapılan çalışmaların avantajları ve dezavantajları.....	9
Çizelge 7. Bilinear enterpolasyon verilerinin genel gösterim tablosu	11
Çizelge 8. Algoritmanın yer işaretlerine göre sonuçlarının tablosu.....	41

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.	Bilinear enterpolasyonu alınacak noktanın temsili gösterimi	10
Şekil 2.	Doğrusal enterpolasyon ile değerleri belirlenecek noktaların temsili koordinatları.....	12
Şekil 3.	Doğrusal enterpolasyon hesaplanacak noktaların gösterimi.....	12
Şekil 4.	Doğrusal enterpolasyon sonucu elde edilecek görüntünün temsili görünümü	13
Şekil 5.	Genişletilmiş görüntü içerisinde orijinal görüntünün gösterimi	13
Şekil 6.	Bulunmak istenen noktanın bütün şekil üzerindeki yerinin hesaplanması.....	14
Şekil 7.	Orijinal fotoğraftan istenilen bölümün çıkarılıp yeniden ölçeklendirilmesi .	15
Şekil 8.	Gradyan değerleri hesaplanırken kullanılan çekirdek değerleri	15
Şekil 9.	Soldaki görüntü X gradyanının mutlak değerini ortadaki görüntü Y gradyanının mutlak değerini soldaki görüntü ise gradyanın büyüklüğünü göstermektedir.	16
Şekil 10.	8x8 HOG hücreleri. Görüntü, görüntülenmek üzere 4x ölçeklenmektedir...	17
Şekil 11.	Ortakdaki görüntüde: Oklarla temsil edilen RGB yaması ve gradyanları. Sağdaki görüntüde: Aynı yamadaki gradyanlara karşılık gelen sayılarla temsil edilir. ...	18
Şekil 12.	Histogram değerlerinin hesaplanması.....	19
Şekil 13.	Histogram değerlerinin hesaplanması-2.....	20
Şekil 14.	Örnek görüntünün histogramı.....	20
Şekil 15.	Bir veri setinde yeni bir verinin temsili görünümü	24
Şekil 16.	Öklid değerinin hesaplanması.....	24
Şekil 17.	Öklid mesafesi hesaplandıktan sonraki görünüm.....	25
Şekil 18.	Örnek bir sefalometrik görüntü.....	26

Şekil 19. (a). Histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler, (b). Ki-kare benzerlik ölçüsünü kullanan ve çok fazla yanlış pozitif içeren pozitif bloklar.	28
Şekil 20. (a, b). Prn yer işareti noktası için yanlış pozitiflerin histogramlar, (c-d). Prn yer işareti için doğru pozitiflerin histogramları.....	29
Şekil 21. Gerçek Prn yer işareti histogramına minimum Öklid mesafesine sahip histogram	29
Şekil 22. Po yer işareti için histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler	30
Şekil 23. (a,b). Po yer işaretinin yanlış pozitiflerinin histogramları, (c,d). Po yer işaretinin doğru pozitiflerinin histogramları.....	30
Şekil 24. Doğru Po yer işareti histogramına minimum Öklid mesafesine sahip histogram	31
Şekil 25. Minimum Öklid mesafesi histogramı bloğu	31
Şekil 26. Bir sefalometrik görüntü üzerinde yumuşak doku üzerindeki Po yer işaretinin gösterimi (Pog).....	32
Şekil 27. Pog yer işareti için histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler	33
Şekil 28. (a-c). Pog yer işaretinin yanlış pozitiflerinin histogramları, (d,e). Pog yer işaretinin doğru pozitiflerinin histogramları.....	34
Şekil 29. Minimum Öklid mesafesi histogramı bloğu	35
Şekil 30. Alt dudak için histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler.....	36
Şekil 31. (a,b). Alt dudak için doğru ve yanlış pozitiflerin histogramları, (c-ı). Alt dudak yer işaretinin doğru pozitiflerinin histogramları, (i,j). Alt dudak yer işaretinin doğru pozitiflerinin histogramları.....	37
Şekil 32. Doğru alt dudak yer işareti histogramına minimum Öklid mesafesine sahip histogram	38
Şekil 33. Minimum Öklid mesafesi histogramı bloğu	38

Şekil 34.	N kemiđi yer iřaretinin yanlış pozitif blođunun görünümü	40
Şekil 35.	N kemiđi yer iřareti için bulunan dođru pozitif bloklar	40

I. GİRİŞ

Sefalometri, genellikle lateral baş-boyun X-ışını görüntülerinden yapılan insan kafasının morfolometrik parametrelerini ölçmek için klinik bir prosedürdür. Morfolometrik parametreler esasasen anatomatik olarak ilgili noktalar, yani yer işaretleri (land mark) arasındaki mesafeler ve açılarla temsil edilir. Deneyimli bir klinisyen, yer işaretlerini tek bir görüntüye manuel olarak yerleştirmek için 20 dakikaya kadar zaman harcamaktadır (El-Fegh, I. vd, 2008), bu da prosedürü hem zaman alıcı kılmakta hem de hatalara maruz bırakabilmektedir. Bu sınırlamalar, ortodontik tedavi planlaması veya büyük görüntü verilerinin istatistiksel analizi için kullanılacak bilgisayarlı sefalometrik landmarking ile aşılabılır. Bilgisayarlı sefalometrinin erken evrelerinde, yer işaretlerini tespit etmek için yoğunluk ve Gradyan tabanlı yöntemler kullanılmış olup (Cardillo, J. vd, 1994; Forsyth, D.B. & Sid-Ahmed, M.A., 1996), aynı zamanda yer işaretlerinin etrafındaki çapa yapıları ve çizgileri de kullanılmıştır (Lévy-Mandel, A.D. vd, 1986). Ancak, bu yöntemler genellikle sefalometrik X-ışını görüntülerinin kalitesine güçlü bir şekilde güvendikleri için aykırı yer işareti (landmark) değerler üretmektedir. Bu nedenle sonuçlar, görüntü yapılarının projektif yer değiştirmesindeki görüntü eserleri, gölgeler ve farklılıklardan etkilenmektedir. Algılama sağlamlığı, daha sofistike görünüm özellikleri geliştirerek, her bir yer işareti için arama alanlarını kısıtlayarak ve/veya yer işaretleri arasındaki mekânsal ilişkileri (yani gözlemlenen yapıların şekli) dikkate alarak artırılmıştır.

Görüntülerin sınıflandırılması izleme, teşhis etme ve tıbbi görüntü alma gibi birçok alanda önemli rol oynar. Bilgisayar görüşündeki çoğu problem bir görüntü sınıflandırması olarak yeniden tanımlanabilir (Rong Zhang, 2006). Bu nedenle, görüntü sınıflandırması multi-medya içerik analizinin hayati bir adımıdır. Son yıllarda, kümeleme, karar ağacı yöntemi, gizli Markov modelleri ve sinir ağları gibi birçok gelişmiş multimedya içerik analizi teknolojisi yaygın olarak kullanılmaktadır.

Görüntü işleme algoritmalarından biri olan Gradient Histogramı (HOG) algoritması, sınıflandırıcı nesne tanıma oluşturmak için piksel renklerinden öznitelik çıkarmanın etkili bir yoludur. HOG algoritması genel olarak 4 adımdan oluşur: gradyan görüntülerin işlenmesi, 8x8 hücrelerde gradyanların histogramının hesaplanması ve 16x16 Blok Normalleştirme (Pedro F. Felzenszwalb & Daniel P. Huttenlocher, 2004).

İlk adımda, bir görüntünün 64x128 yaması üzerinde HOG öznitelik tanımlayıcısı hesaplanır. Bir görüntü herhangi bir boyutta olabilir. Tipik olarak, çoklu ölçekteki yamalar, birden çok görüntü konumunda analiz edilir. Tek kısıtlama, analiz edilen yamaların sabit bir en boy oranına sahip olmasıdır. Bir sonraki adımda, bir HOG tanımlayıcısı hesaplamak için öncelikle yatay ve dikey gradyanlar hesaplanmalıdır. Yatay ve dikey gradyanlar için sobel filtresi uygulanarak aynı sonuçlar elde edilebilir. Daha sonra, eğimlerin büyüklüğü ve yönü hesaplanmalıdır. Daha sonra görüntü 8x8 hücreye bölünür ve her 8x8 hücre için bir gradyan histogramı hesaplanır, böylece kompakt bir temsil sağlanır. 8x8 hücre yamasının kullanılmasının nedeni, istenilen özelliklerin skalalarına göre düzenlenmiş bir tasarım seçimidir. Son adımda, bir görüntünün gradyanları genel aydınlatmaya duyarlıdır. Bu nedenle, tanımlayıcının aydınlatma değişikliklerinden bağımsız olması gerekir. Tüm bu adımlardan sonra gradyan algoritmasının histogramı, histogram olarak sonuçlar üretebilir (Dalal, N., 2005).

K-Nearest Neighbor algoritması, Denetimli Öğrenme tekniğine dayalı Makine Öğrenimi algoritmalarından biridir. KNN algoritması, bir veri kümesindeki veriler ile bu veri kümesine yeni eklenen veriler arasındaki benzerliği, seçilen “K” komşularına göre bulur ve yeni verileri mevcut kategorilerden hangisi uygunsa ona yerleştirir. KNN algoritması daha çok sınıflandırma problemlerinin çözümü için kullanılmaktadır (Short RD & Fukunaga K., 1981).

Bu makalede sefalometrik görüntüler üzerinde insan yüzünün belirli bölgelerini hata payını en aza düşürecek şekilde saptayabilmek amacı ile görüntü işleme ve sınıflandırma yöntemlerinden Yönlendirilmiş Gradyanların Histogramı (HOG) ve K- En Yakın Komşular algoritmalarının bir kombinasyonundan oluşan hızlı, etkili çalışan bir yöntem önerilmesi amaçlanmaktadır.

II. GENEL BİLGİLER

Vishad D. Bharate ve arkadaşları, Literatürde yaptıkları çalışmada, HOG ve Gobar Filtresi kullanarak insanların çeşitli durumlarda verdiği tepkiler sonucunda insan yüzlerindeki duygu değişimlerinin verilerini elde etmişler ve bu verilere KNN algoritmasını uygulamışlardır. KNN algoritması en iyi sonucu %80 doğruluk oranı ile elde etmiştir (Vishal D. Bharate, 2019).

Knn algoritması Gobar Filter için Korelasyon Mesafesi ölçümü kullanılarak %68, Öklid Mesafesi ölçümü kullanılarak %69 ve Manhattan Mesafe ölçümü kullanılarak %80 doğruluk oranı ile duyguları birbirinden ayırmayı başarmıştır.

Çizelge 1. Mesafe metriklerine göre Knn sınıflandırmasının doğruluk değeri

Mesafe / Özellik	Korelasyon Mesafesi	Öklid Mesafesi	Manhattan Mesafesi
Gobar Filtresi	68%	69%	80%
HOG Dönüşümü	69%	65%	82%

Gökhan Şengül ve Tariq Khalifa, yüz görüntülerinden cinsiyet tahmini üzerine yaptıkları çalışmada, özellik çıkarımı için Yerel İkili Model (LBP) ve Yönlendirilmiş Gradyan Histogramı (HOG) algoritmalarını kullanmışlardır (Şengül, G., Khalifa A., 2018). Sınıflandırma için KNN ve Destek Vektör Makinesi (SVM) algoritmalarını kullanılmıştır. Sonuç olarak, görüntüye HOG algoritması uygulandıktan sonra KNN sınıflandırma algoritmasının doğruluk oranının K=11 için gri tonlamalı (grey scale) versiyonda %98,60 ve renkli versiyonda %98,30 doğrulukla hesaplandığını gözlemlemişlerdir.

Ayrıca görüntülere HOG ve LBP algoritmaları uygulandıktan sonra KNN algoritması uygulandığında cinsiyet tahmininin K=21 için FERET veri setinden alınan görüntüler üzerindeki doğruluk derecesi hem grey scale hem de renkli versiyonları için %100 olduğunu gözlemlemişlerdir.

Mohd Norhisham bin Razali ve arkadaşları fotoğraflardan gıda ürünlerini tanımak için yaptıkları çalışmada SURF ve SIFT algoritmalarını karşılaştırdılar ve SURF'nin SIFT'den daha az anahtar nokta tespit ettiğini ve işlem süresi

açısından SIFT'den daha iyi performans gösterdiğini tespit etmişler (Mohd Norhisham bin Razali vd, 2017).

Ayrıca SURF ve SIFT üzerinde diğer sınıflandırma algoritmalarını kullandıktan sonra en iyi sınıflandırmanın KNN algoritması ile SURF ve SIFT algoritmaları görüntülere birlikte uygulandıktan sonra elde edildiğini gözlemlemişlerdir.

Çizelge 2. SURF ve SIFT üzerinde sınıflandırıcı performanslarının karşılaştırılması

Classifiers	Performance Rate	SURF	SIFT	SIFT+SURF
LIBSVM	Training(sec.)	779,58	1234,04	2007,22
	Tp Rate (%)	54,71%	28,87%	41,87%
Linear SVM	Training(sec.)	30.24	96.23	111.83
	Tp Rate (%)	62.08%	64.65%	82.38%
KNN	Training(sec.)	0.01	0	0
	Tp Rate (%)	33.94%	50.67%	45.22%
Naive Bayes	Training(sec.)	0.95	0.86	3.53
	Tp Rate (%)	33.53%	32.24%	39.04%

Yerel Özelliklere göre yiyecek tanıma üzerine yapılan araştırmalarda uygulanan yöntemlerin doğruluklarının karşılaştırılması şu şekilde yer almaktadır.

Çizelge 3. Yerel Özelliklerin Performansının Karşılaştırılması

Özellik Temsil Yöntemi	Sınıflandırma Doğruluğu
SIFT+CSIFT+HOG+Gabor Filter (4 özellik)	68.90%
HOG+ Color (2 özellik)	79.20%
SURF+SIFT (önerilen metod)	82.38%

Joutou ve Yanai, SIFT Torbası, Gabor filtresi ve renk histogram özelliklerini kullanarak gıda çeşitliliğini uyarlamalı olarak öğrenmek için Çoklu Çekirdek Öğrenme (MKL) tekniğini uygulamışlardır ve 50 gıda kategorisinde %61,34 sınıflandırma doğruluğu elde etmişler (T. Joutou & K. Yanai, 2009). Hoashi ve arkadaşları, özellikle Gradyan Histogramı (HOG) özelliğini ekleyerek, bu çalışmayı artırılmış bir dizi özellik ile geliştirdi ve 85 gıda kategorisinde %62,52'lik hafifçe iyileştirilmiş sınıflandırma doğruluğu sağlamıştır (H. Hoashi vd, 2010). Kawano ve arkadaşları iki ayrı özellik kombinasyonu kullandılar, burada ilk olarak Bag of SURF ve renk yaması, ardından HOG yaması ve renk yaması denenmiştir (K. Y. Yoshiyuki Kawano, 2015; Y. Kawano & K. Yanai,

2013). Son kombinasyon, son görüntü sunumunda etkili olduğu bilinen balıkçı vektörünü kullandığı için 100 gıda kategorisinde %79,2 tanıma doğruluğu ile en iyi sonuçları vermiştir. Ancak, SIFT yerelleştirme sırasında daha fazla anahtar nokta hesapladığından, HOG kullanan özellik gösterimi SIFT ile karşılaştırıldığında daha az kompakttır. Buna ek olarak, HOG, nesneyi tanımlamak için daha az yeterli olan, köşelerin etrafındaki yerel bölgeden oldukça seyrek özellikler yaratır (Y. Li vd, 2015).

Mevcut kenar çıkarma yöntemleri, disk benzeri nesnelerdeki gürültü ve iç ayrıntılar nedeniyle genellikle çok sayıda yanlış kenar piksel üretir. Xiqi Yang ve arkadaşları Cassini Astronomi görüntüleri üzerinde kenar belirleme üzerine yaptıkları çalışmada Ekstrem Öğrenme Makinesi temelli bir kenar algılama algoritması önermişlerdir (Xiqi Yang vd, 2018). Xiqi Yang ve arkadaşları bu sayede şu anda kullanılan Sobel, Canny, Roberts gibi kenar tespit algoritmalarının çok fazla detay ve gürültü içerdiğini ve kenar tespit algoritmalarının deneysel sonuçlarına göre Cassini astronomi görüntülerinde %93 doğrulukla çalıştıklarını göstermişlerdir.

Zhaoquan Cai ve arkadaşları Gelişmiş HOG Özelliğine dayalı görüntü sınıflandırması üzerine SVM ve KNN algoritmalarının kombinasyonunda oluşan bir yöntem önermektedir (Zhaoquan Cai vd, 2016). Önerilen bu yaklaşıma göre, nesne özelliklerinin yerel özelliklerini tanımlamak ve bunları güçlendirmek için HOG'u kullanılabilir, aynı zamanda, sınıflandırmayı daha belirgin hale getirmek için SVM ve KNN algoritmasının mükemmel performansını birleştirmiştir.

Gelişmiş HOG Özelliğini Asian Face Database PF01 ve renkli görüntülerden oluşan Amsterdam Library of Object Images (ALOI), ALOI database'deki fotoğraflar üzerinde üzerinde kullanabilmek amacı ile Zhaoquan Cai ve arkadaşları öncelikle görüntüleri CLAHE ile işlemiş olup elde ettikleri çıktılarını Gelişmiş HOG Özelliği algoritmasına girdi olarak kullanmışlardır. CLAHE'nin temel fikri, görüntüyü birkaç çakışmayan bölgeye bölmektir. Her blok, histogram eşitleme ile işlenir ve komşu bloklar, blok etkisini azaltmak için çift doğrusal enterpolasyon ile optimize edilir.

Çizelge 4. PF01 yüz görüntüsü veri seti kullanılarak yapılan tanımanın doğruluk dereceleri

K	KNN	HOG+KNN	IHOG+KNN
1	50.10%	82.80%	87.40%
2	41.20%	76.40%	87.40%
3	39.50%	76.20%	86.20%
4	38.40%	73.10%	81.50%
5	39.10%	71.90%	79%
6	37.90%	68.80%	76.40%
7	36.20%	66.60%	73.80%

Çizelge 5. Farklı yöntemlerin ALOI veri seti üzerinde kullanılarak elde edilen tanımanın doğruluk dereceleri

Metod	SVM	KNN	SVM+KNN	LM+N	IHOG+KNN	IHOG+SV	IHOG+SVM+KNN	IHOG+LM+N
			NN	N	NN	M	NN	NN
Tanıma Oranı	26.83%	61.10%	58.27% (K=2)	59.40%	82.60% (K=2)	86.38%	86.72% (K=10)	81.22% (K=2)
		(K=1)		(K=2)				

Firmanda Al Islama Achyunda Putra ve arkadaşları otonom araç sürüş güvenliğini sağlamak için HOG ve KNN algoritmalarının bir kombinasyonunu önermişlerdir (F. Putra vd, 2020). Çalışmalarında aracın önünde araba olup olmadığını tespit etmek için HOG algoritmasını kullanmışlar ve HOG ile elde ettikleri bu verileri sınıflandırmak için KNN algoritmasını kullanmışlardır. Aynı şekilde, sonuçları sınıflandırmak ve karşılaştırmak için DVM'yi de kullandılar. Bu sayede güvenli otonom sürüş için en iyi algoritmanın %84 doğruluk oranıyla HOG ve KNN algoritmaları olduğunu gözlemlədiler. Önerdikleri algoritma ile otomobil veya otomobil dışı gibi araçları tespit etmeyi amaçlamaktadırlar.

S. Yu ve arkadaşları derin öğrenme yöntemlerini kullanarak sefalometrik görüntüler üzerinde yer işaretlerini otomatik olarak bulmak için yaptıkları çalışmada, 2 farklı veri setinden test verisi olarak kullanılan sefalometrik ortodonti görüntüleri üzerinde yer işaretlerini belirlemek için bir ilgi alanı (ROI) oluşturur (S. Yu vd., 2020). Daha sonra yer işaretlerini bulmak için evrişimli bir sinir ağı olan ResNet50'yi kullandılar ve sinir ağının yer işaretlerinin koordinatlarını verdiğini gözlemlədiler.

S. H. Kang ve arkadaşları, gölgeli 2d görüntü tabanlı makine öğrenme yöntemlerini kullanarak 3D sefalometrik görüntülerin otomatik yorumlanması üzerine yaptıkları çalışmada, VGG ağı kullanarak çeşitli aydınlatma ve gölgelerle 2D görüntüleri kullanan 2D görüntüler ve 3D görüntüler arasındaki boyut farkını ele alan bir makine öğrenme tekniği önermişlerdir (S.H. Kang vd., 2018).

Önerilen bu yöntem, 7 ana yer işareti için 1.5 nokta mm'lik bir ortalama noktadan noktaya hata göstermektedir.

Claudia Lindner ve arkadaşları sefalometrik görüntülerde yer işaretlerini doğru bir şekilde tespit etmek için tam otomatik bir yer işareti açıklama sistemi (FALA) geliştirdi. Geliştirdikleri sistem, 1,2 milimetrelilik ortalama noktadan noktaya hata ve yer işaretlerinin %84,7'sine ulaştı (C. Lindner vd, 2016).

C. Chu ve meslektaşları, X-ışını görüntülerinde yer işareti tespiti için bir rastgele orman algoritması kullanarak tam otomatik bir yer işareti tespiti yöntemi önerdiler. Bu algoritma, seyrek şekil kompozisyon modeline dayalı yer işareti düzeltmesini birleştirerek çalışır ve %77,79 doğruluk oranıyla yer işaretlerini tespit edebilir (C. Chu vd, 2014).

Claudia Lindner ve Tim F. Cootes, sefalometrik görüntülerde yer işaretlerini tam otomatik olarak bulmak ve otomatik sefalometrik değerlendirme yapmak için bir rastgele orman regresyon oylama uygulaması geliştirdi. Geliştirilen uygulama, otomatik sefalometrik değerlendirme için %77 ile %79 arasında bir doğruluk göstermektedir (C. Lindner & T.F. Cootes, 2015).

Bulat Ibragimov ve arkadaşları sefalometrik görüntüler üzerinde yer işaretlerinin (landmark) belirlenmesine yönelik yapmış oldukları çalışmada Haarlike Features (Haar benzeri Özellikler) algoritmasını yer işaretlerini tanımlamak için kullanmıştır (Bulat Ibragimov vd., 2014). Belirledikleri bu aday yer işaretlerini hedef görüntüdeki belirlenmek istenen yer işareti ile birleştirmek için ise rastgele orman (Random Forest) algoritmasını kullanmışlardır. Rastgele orman algoritması ile modellenen işaretler arasındaki mekansal ilişkiler ve olası yer işareti adayı olan noktaları belirlemek için oyun teorisi kavramlarından da yararlanmışlardır. Toplam 200 sefalometrik görüntüden oluşan veri setinde 100 görüntü üzerinde geliştirdikleri algoritmayı eğitmiş ve 100 görüntü üzerinde algoritmayı test etmişlerdir. Önerdikleri yöntemin bilgisayarlı sefalometri açısından başarılı tespit oranı ise %72,70'tir.

Chen ve Zheng'in yer işareti tespit çerçevesi çalışmasında eğitim adımında, yer işareti konumu çevresinde rastgele bir dizi kare görüntü yamasını örneklemektedir. Bu yamaların görsel özellikleri ve yer değiştirmeleri eğitim verilerini oluşturur (C. Chen and G. Zheng, 2014). Daha sonra, yeni bir görüntü

verildiğinde, bir dizi görüntü yamasını rastgele örnekler ve özelliklerini hesaplarlar. Her bir yamanın yer değiştirmesini tahmin etmek için, aşağıdaki kısıtlamaları uygulamak için yer değiştirmeler üzerinde bir amaç fonksiyonu tanımlayarak veriye dayalı bir yaklaşım benimserler: (1) Benzer özelliklere sahip yamaların benzer yer değiştirmelere sahip olması gerekir. (2) Test yamalarının yer değiştirmeleri üçgen yapısı ile tutarlı olmalıdır (yani, iki yamadaki ilgili merkezlerden nirengi noktasına olan yer değiştirmeler arasındaki fark, iki yama merkezinin koordinat farkına yakın olmalıdır). Bu şekilde, her yama, yer işaretinin konumu üzerinde bir oylama yapar. Chen ve Zheng, her oyu küçük bir Gauss dağılımı olarak ele alıyor ve onları, modu tespit edilen yer işareti konumu olarak döndürülen bir olasılık haritasında topluyor.

Mirzaalian ve Hamarneh'in sefalometrik görüntülerde yer işareti tespitini bir optimizasyon problemi olarak ele almış ve bir yöntem önermişlerdir. Önerdikleri yöntemin iki aşaması vardır: bir eğitim ve bir test aşaması. Eğitim aşamasında, doğru pozitif örnekler olarak yer işaretlerinin konumu etrafında ortalanmış bir dizi bloktan ve doğru negatif numuneler olarak yer işaretlerinin konumuna yakın olmayan bir dizi rastgele seçilmiş bloktan yukarıda belirtilen özellikleri çıkarırlar (H. Mirzaalian & G. Hamarneh, 2014). Bu pozitif ve negatif örnekler, 22 derinliği 10 olan bir RF sınıflandırıcıyı eğitmek için kullanılır. Yeni bir görüntü için Mirzaalian ve Hamarneh, maliyet fonksiyonunu küresel olarak optimize etmek için resimsel yapı algoritmasını uygular. Resimsel yapının, yer işaretlerini bağlamak için bir döngüsel grafik (ağaç) üzerinde ilk terimin hesaplanmasını gerektirdiğini unutmayın. Problem, minimum yayılan ağacı, köşeler olarak 19 yer işareti ve kenarların kovaryans değerleri olarak ayarlanmış kenar ağırlıkları ile tam bir grafik üzerine uygulayarak çözülebilir.

Vandaele ve arkadaşları, sefalometrik görüntüler üzerinde yer işaretinin belirlenmesini her bir yer işareti için bir tane olmak üzere 19 ayrı ikili piksel sınıflandırma problemi olarak ele almıştır (R. Vandaele vd., 2014). Bir piksel, yer işareti konumuna olan mesafesi R'den küçükse pozitif sınıfa aittir, burada R bir yöntem parametresidir. Aksi takdirde, negatif sınıfa aittir. Vandaele ve arkadaşları, piksel sınıflandırıcı olarak son derece rastgele ağaçlar kullanmıştır. Eğitim pikselleri, yer işaretine en fazla 4 cm'lik bir yarıçap içinde rastgele çıkarılır. En yüksek güvenilirlikle pozitif olarak sınıflandırılan piksellerin

medyan konumu daha sonra son yer işareti konumu olarak döndürülür. Tüm yöntem parametreleri, 10 kat çapraz doğrulama yoluyla ayarlanır.

Çizelge 6. Sefalometrik görüntüler üzerinde yer işaretlerinin bulunmasına yönelik literatürde yapılan çalışmaların avantajları ve dezavantajları


Metod	Avantajı	Dezavantajlar
İbragimov ve diğerleri [25]	<ul style="list-style-type: none"> • Hesaplamalı olarak verimli ve doğru yoğunluk modeli, güçlü şekil modeli 	<ul style="list-style-type: none"> • Yoğunluk modeli, yerel yer işareti görünümüne dayalıdır
Chu ve diğerleri [23]	<ul style="list-style-type: none"> • Herhangi bir kullanıcı müdahalesi olmadan yer işareti tespiti için tam otomatik bir yöntem. • Aykırı değerleri işlemek için rastgele orman gericiler tarafından hesaplanan yerel olabilirlik ile seyrek şekil kompozisyon modeli tarafından kodlanan global şekil bilgisinin birleştirilmesi. 	<ul style="list-style-type: none"> • Yama sayısı arttıkça hesaplama karmaşıklığı artar. • Yalnızca küresel alan bilgisini, çift yönlü kara işareti bağımlılığı olmadan dikkate alır ve bu da daha az doğru sonuçlara yol açar.
Chen ve Zheng [26]	<ul style="list-style-type: none"> • Farklı yamalar arasındaki geometrik ilişkiyi dikkate alır. • Küresel optimumu bulma eğiliminde olan dışbükey optimizasyon formülasyonu. 	<ul style="list-style-type: none"> • Yama sayısı arttıkça hesaplama karmaşıklığı artar.
Mirzaalian ve Hamarneh [27]	<ul style="list-style-type: none"> • Hızlı: çalışma süresi, yer işaretlerinin olası konumlarının doğrusal bir işlevidir. • Düzenli: ikili düzenleme terimi, öğrenilmiş bir grafik modele uyan yer işaretlerinin tespit edilmesini teşvik eder. • Global olarak optimize edilmiş: amaç fonksiyonu, resimsel yapı algoritması kullanılarak global olarak optimize edilmiştir. 	<ul style="list-style-type: none"> • Eğitilmesi gerekiyor: hiperparametreleri ayarlamak için eğitim verisi gerektirir. • Ölçekleme ve döndürme için değişmez değil: yer işareti algılama amacı işlevi, ölçek ve yönelimdeki küçük değişikliklere duyarlı değildir.
Vandaele ve arkadaşları [28]	<ul style="list-style-type: none"> • Ayıklanan özellikler (yani ham pikseller) çok basittir, bu da hem çıkarmayı hem de algılamayı hızlandırır. • Translasyon parametrelerinin tanıtılması nedeniyle, belirli bir pikseldeki algılama, yakındaki yapılar bazında yapılabilir. Bu, yer işareti düşük varyanslı bir bölgede konumlandırıldığında faydalıdır. • Birden fazla çözünürlükte özelliklerin çıkarılması, yer işareti konumunun bağlamını daha iyi kavramaya ve böylece aynı çözünürlükte piksel komşuluk benzerliklerinden kaynaklanan hataların önlenmesine olanak tanır. • Yer işaretleri, tüm yer işareti değişkenliğine dayanmadan veya ek yer işaretleri gerektirmeden, birbirinden bağımsız olarak ele alınır. Bu nedenle sisteme yeni bir yer işareti eklemek kolaydır. 	<ul style="list-style-type: none"> • Yöntem, çapraz doğrulama ile ayarlanması gereken birkaç parametreye bağlıdır. • Her piksel çok sayıda özellik ($6 \times 16 \times 16$) ile tanımlanır ve her bir yer işareti çok sayıda eğitim örneğinden (50000) ayrı bir ağaç topluluğu eğitmeyi gerektirir. • Yer işaretlerinin tek tek tespit edilmesi, aralarında var olabilecek ilişkilerden tam olarak yararlanılmasına izin vermez.

III.METODLAR VE MATERYERLER

A. Bilinear Enterpolasyon

Bilinear enterpolasyon, eksik olan her pikseli, bir dikdörtgen oluşturan 4 komşu noktanın en yakın piksellerin ağırlıklı ortalaması ile değiştirir. Kullanılan ağırlıklar, kaynak ve hedef piksellerin mesafesi ile ters orantılıdır (www.theailearner.com, 2021). Yani, bilinmeyen bir fonksiyonun değerlerinin bir dikdörtgen oluşturan dört noktada bilindiği varsayılmaktadır. Bu noktaların (x_1,y_1) , (x_1,y_2) , (x_2,y_1) ve (x_2,y_2) olarak düşünüldüğünde fonksiyonun değerleri; (x_1,y_1) ' deki değer Q_{11} ; (x_1,y_2) ' deki değer Q_{12} ; (x_2,y_1) ' deki değer Q_{21} ve, (x_2,y_2) deki değer Q_{22} olur.

Bilinear enterpolasyon kullanarak, bu fonksiyonun değerini bu dikdörtgenin içindeki herhangi bir noktada (x, y) tahmin edebiliriz. Bu bilinmeyen değer P ile gösterilmiştir.



Şekil 1. Bilinear enterpolasyonu alınacak noktanın temsili gösterimi

Bu enterpolasyon şeması yaygındır ve özellikle görüntü işleme alanında birçok uygulamaya sahiptir. Bilinear enterpolasyon için gerekli veriler genellikle aşağıdaki tabloda olduğu gibi toplanmaktadır.

Çizelge 7. Bilinear enterpolasyon verilerinin genel gösterim tablosu

		x_1	x	x_2
y	y_1	Q_{11}	P	Q_{21}
	y_2	Q_{12}		Q_{22}

Bilinear interpolation formülünü inceleyecek olursak;

İlk olarak x yönünde (yatay) önce (x, y_1) , ardından (x, y_2) noktası için iki doğrusal enterpolasyon değeri hesaplanmaktadır.

Daha sonra, y yönünde (dikey) doğrusal enterpolasyon gerçekleştirilir: (x, y_1) ve (x, y_2) 'deki enterpolasyonlu değerleri kullanarak (x, y) noktasındaki son enterpolasyonu elde edilmektedir.

P değeri 3 adımda hesaplanmaktadır;

- Adım: Sırasıyla Q_{11} ve Q_{21} olan (x_1, y_1) ve (x_2, y_1) 'deki f değerlerini kullanarak f fonksiyonunun (x, y_1) 'deki lineer enterpolasyonunu hesaplanmalıdır:

$$R_1 = \frac{x_2 - x}{x_2 - x_1} Q_{11} + \frac{x - x_1}{x_2 - x_1} Q_{21} \quad (1)$$

- Adım: Sırasıyla Q_{12} ve Q_{22} olan (x_1, y_2) ve (x_2, y_2) 'deki f değerlerini kullanarak f 'nin (x, y_2) 'deki lineer enterpolasyonu hesaplanmalıdır;

$$R_2 = \frac{x_2 - x}{x_2 - x_1} Q_{12} + \frac{x - x_1}{x_2 - x_1} Q_{22} \quad (2)$$

- Adım: Son olarak, (x, y_1) ve (x, y_2) 'deki f 'nin enterpolasyonlu değerlerini kullanarak (x, y) 'deki doğrusal enterpolasyonu hesaplanmalıdır;

$$P = \frac{y_2 - y}{y_2 - y_1} R_1 + \frac{y - y_1}{y_2 - y_1} R_2 \quad (3)$$

Adım 1 ve 2'deki R_1 ve R_2 ifadelerini değiştirerek, P için aşağıdaki formülü elde edilmektedir:


$$P = \frac{(x_2 - x)(y_2 - y)}{(x_2 - x_1)(y_2 - y_1)} Q_{11} + \frac{(x - x_1)(y_2 - y)}{(x_2 - x_1)(y_2 - y_1)} Q_{21} + \frac{(x_2 - x)(y - y_1)}{(x_2 - x_1)(y_2 - y_1)} Q_{12} + \frac{(x - x_1)(y - y_1)}{(x_2 - x_1)(y_2 - y_1)} Q_{22} \quad (4)$$

Vektörleri ve matrisleri kullanarak, P için yukarıdaki çift doğrusal enterpolasyon formülünü aşağıdaki biçimde yeniden yazabiliriz:

$$P = \frac{1}{(x_2-x_1)(y_2-y_1)} [x_2 - x \quad x - x_1] \begin{bmatrix} Q_{11} & Q_{12} \\ Q_{21} & Q_{22} \end{bmatrix} \begin{bmatrix} y_2 - y \\ y - y_1 \end{bmatrix} \quad (5)$$

Bilinear enterpolasyon yöntemi bir örnek üzerinden açıklayacak olursak;


(0,0), (1,0), (0,1) ve (1,1)'de 4 pikselimiz olduğunu ve (0.3,0.4) değerinin bulunması istenmektedir.



Şekil 2. Doğrusal enterpolasyon ile değerleri belirlenecek noktaların temsili koordinatları


İlk olarak doğrusal enterpolasyon ile satır boyunca A:(0,0.4) ve B: (1,0.4) değerleri hesaplanmalıdır.

A ve B'deki değerleri aldıktan sonra, A ve B arasındaki (0.3,0.4) noktasına doğrusal enterpolasyon uygulayın ve bu nihai sonuçtur.



Şekil 3. Doğrusal enterpolasyon hesaplanacak noktaların gösterimi

Bu işlemin bir görüntü üzerine uygulanması istenirse, örneğin. Aşağıdaki gibi 2 katına büyütülmek istenmekte olan bir resim için;



Şekil 4. Doğrusal enterpolasyon sonucu elde edilecek görüntünün temsili görünümü

Yukarıdaki görüntüde P1'i hesaplamak için İlk olarak, giriş görüntüsünde P1 pikselinin konumu hesaplanmaktadır. 4x4'lük bloktaki görüntüyü 2x2'lik blok üzerine yansıtarak P1'in koordinatları (0.25,0,25) olarak elde edilmektedir.


P1 kenar pikseli olması sebebiyle ve sol tarafında hiçbir değer bulunmadığından kenar pikseli çoğaltılır. Bu, orijinal görüntünün en kenarındaki satır veya sütunun daha geniş bir kenara çoğaltıldığı anlamına gelir yani dolgu işlemi ile eksik pikseller doldurulmuştur.

Bu işlemden sonra elde edilen yeni görüntü aşağıdaki gibi olacaktır. Burada kırmızı ile gösterilen pikseller orijinal görüntüyü göstermektedir.

10	10	20	20
10	10	20	20
30	30	40	40
30	30	40	40

Şekil 5. Genişletilmiş görüntü içerisinde orijinal görüntünün gösterimi

P1'in değerini bulmak için önce giriş görüntüsünde P1'in nerede olduğu gösterilmelidir. Aşağıdaki şekil, elde edilen 4x4'lük genişletilmiş görüntünün sol üst 2x2'lik bölgesini ve buradaki P1'in yerini göstermektedir.



Şekil 6. Bulunmak istenen noktanın bütün şekil üzerindeki yerinin hesaplanması

```

1 fx = (float)((dx+0.5)*scale_x - 0.5);
2 sx = cvFloor(fx);
3 fx -= sx;

```

“dx” bilinmeyen pikselin sütun indeksi ve fx sağ piksele atanan ağırlıktır. Sol piksele 1-fx verilir. Scale_x, giriş genişliğinin çıkış genişliğine oranıdır. Benzer şekilde, y için dy satır indeksidir ve scale_y yüksekliklerin oranıdır. 4 noktanın ağırlıkları bu şekilde hesaplanmaktadır.

P1 için, satır ve sütun indeksi, yani dx ve dy = 0, fx = 0.75 ve FY = 0,75 olarak hesaplanmaktadır.

Yukarıdaki algoritmaya göre A ve B için fx ağırlıkları ile doğrusal enterpolasyon uygulandığında $0.75 \cdot 10(\text{sağ}) + 0.25 \cdot 10 = 10$ olmaktadır.


B. Yönlendirilmiş Gradyanların Histogramı (HOG)

Yönlendirilmiş Gradyanların Histogramı (HOG), bir nesne tanıma sınıflandırıcısı oluşturmak için piksel renklerinden özellikleri ayıklamanın etkili bir yoludur. HOG algoritması genel olarak 3 adımdan oluşmaktadır;

1. Verinin İşlenmesi (Processing)

Daha önce bahsedildiği gibi, yaya algılama için kullanılan HOG özellik tanımlayıcısı, bir görüntünün 64×128 'lik bir yamasında hesaplanır. Tabii ki, bir görüntü herhangi bir boyutta olabilir. Tipik olarak çoklu ölçeklerdeki yamalar birçok görüntü konumunda analiz edilir. Tek kısıtlama, analiz edilen yamaların sabit bir en boy oranına sahip olmasıdır. HOG özellik tanımlayıcımızı

hesaplamak için 100×200 boyutunda bir yama seçilir. Bu yama bir görüntüden kırılır ve 64×128 olarak yeniden boyutlandırılır.




Şekil 7. Orijinal fotoğraftan istenilen bölümün çıkarılıp yeniden ölçeklendirilmesi

Dalal ve Triggs'in makalesin de bir ön işleme adımı olarak gama düzeltmesinden bahsediyor, ancak performans kazançları önemsenmeyecek kadar az olduğu için bu adım atlanabilir.

2. Görüntülerin Gradyan Değerlerinin Hesaplanması

Gradyanların histogramı hesaplamak amacıyla, bir HOG tanımlayıcısını hesaplamak için önce yatay ve dikey gradyanların hesaplanması gerekmektedir. Bu, görüntü aşağıdaki çekirdeklerle filtrelenerek kolayca elde edilebilmektedir.



Şekil 8. Gradyan değerleri hesaplanırken kullanılan çekirdek değerleri

Yukarda bahsedilen bu gradyan değerlerini hedef resmin üzerine Sobel Filtresi uygulayarak da elde etmek mümkündür. Daha sonra, aşağıdaki formülü kullanarak gradyanın büyüklüğünü ve yönünü bulabiliriz;

$$g = \sqrt{g_x^2 + g_y^2} \quad (6)$$

$$\theta = \arctan \frac{g_y}{g_x} \quad (7)$$



Şekil 9. Soldaki görüntü X gradyanının mutlak değerini ortadaki görüntü Y gradyanının mutlak değerini soldaki görüntü ise gradyanın büyüklüğünü göstermektedir.

Yukarıdaki şekilden de fark edildiği üzere, x-Gradyan dikey çizgiler üzerindeki değer farklılıklarına göre çalışır ve y-Gradyan yatay çizgiler üzerindeki değer farklılıklarına göre çalışmaktadır. Gradyan büyüklüğü, yoğunluğun keskin bir şekilde değiştiği yerlerde tetiklenirken, bölge pürüzsüz olduğunda hiçbiri değişim olmamaktadır.


Gradyan görüntüsü, resimdeki ana hatları vurgulamakta olup, çok sayıda önemli olmayan bilgiyi (örn. sabit renkli arka plan gibi) kaldırmıştır, yani, gradyan resmine bakabilir ve yine de resimde bir kişi olduğu kolayca söylenebilir.

Her pikselde gradyanın bir büyüklüğü ve yönü vardır. Renkli görüntüler için, üç kanalın gradyanları değerlendirilir (X-gradyanı, Y-gradyanı ve Gradyanın büyüklüğü). Bir pikseldeki gradyan büyüklüğü, üç kanalın gradyan büyüklüğünün maksimumudur ve açı, maksimum gradyan'a karşılık gelen açıdır.

3. Gradyanların Histogramını 8×8 Hücrelerde Hesaplanması

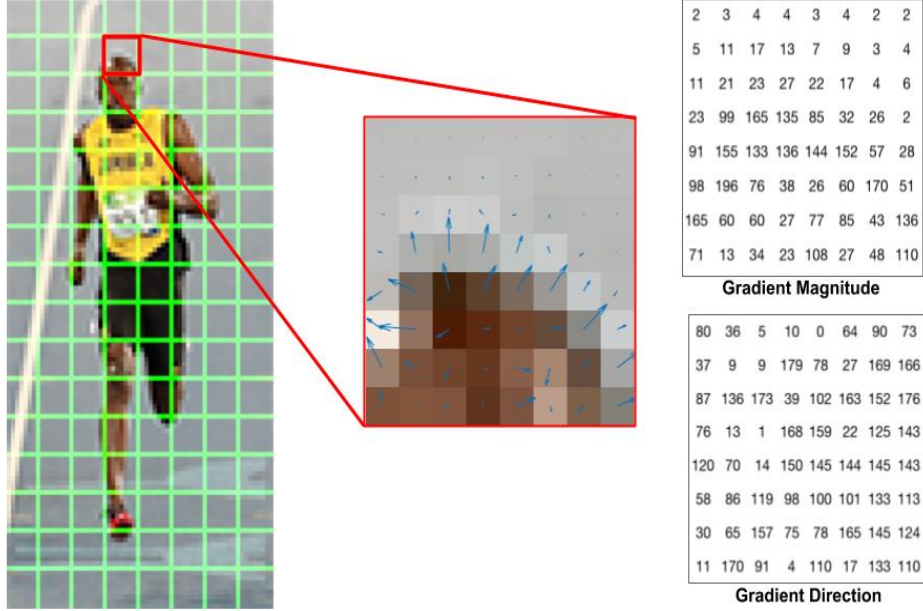
Bu adımda, görüntü 8×8 hücreye bölünür ve her 8×8 hücre için bir gradyan histogramı hesaplanmakta olup, bu sayede kompakt bir temsil sağlanmaktadır. Oluşturulan bu görüntü yaması, 8x8x3=192 piksel değeri içermekte olup, bu

yamanın gradyanı her piksele $8 \times 8 \times 2 = 128$ 'e kadar sayı ekleyen 2 değer (büyüklük ve yön) içermektedir. Bu eklenen 128 sayı 9 sayıdan oluşan bir dizi olarak 9 bölmeli bir histogram ile temsil edilmektedir. Bu sayede elde edilen temsil daha kompakt olmakla kalmaz, yama üzerinde histogramın hesaplanması gürültüye karşı daha sağlam hale getirir.



Şekil 10. 8×8 HOG hücreleri. Görüntü, görüntülenmek üzere 4x ölçeklenmektedir.

8×8 hücre yamasının kullanılmasının sebebi aranan özelliklerin ölçeklerine göre düzenlenmiş bir tasarım seçimidir. HOG başlangıçta yaya tespiti için kullanıldı. 64×128 olarak ölçeklendirilmiş bir yaya fotoğrafındaki 8×8 hücreler, ilginç özellikleri (örneğin yüz, başın üstü vb.) yakalamak için yeterince büyüktür. Histogram esas olarak açılara karşılık gelen 9 kutudan (sayı) oluşan bir vektördür (veya bir dizi) 0, 20, 40, 60 ... 160.



Şekil 11. Ortadaki görüntüde: Oklarla temsil edilen RGB yaması ve gradyanları. Sağdaki görüntüde: Aynı yamadaki gradyanlara karşılık gelen sayılarla temsil edilir.


Yukarıdaki şekle bakıldığında gradyanı gösteren oklarla kaplanmış görüntünün yamasını gösterir. Ok, gradyanın yönünü ve uzunluğu da büyüklüğü gösterir. Okların yönünün yoğunluktaki değişim yönünü nasıl gösterdiğine ve büyüklüğün farkın ne kadar büyük olduğu görülmektedir.

Sağda, 8×8 hücrelerindeki gradyanları temsil eden ham sayıları küçük bir farkla görülmektedir. Açılar 0 ila 360 derece yerine 0 ila 180 derece arasındadır. Bunlara "imzasız" negatif gradyan denir, çünkü bir gradyan ve negatif aynı sayılarla temsil edilir. Başka bir deyişle, bir degrade ok ve bunun tersi 180 derece aynı kabul edilir. 0-360 derece kullanılmamasının sebebi, ampirik olarak, negatif gradyanların pozitif gradyanlardan daha iyi çalıştığı gösterilmiştir.

Bir sonraki adım, bu 8×8 hücrelerde gradyanların histogramını oluşturmaktır. Histogram, 0, 20, 40... 160 açılara karşılık gelen 9 bölme içerir.


Önceki şekilde olduğu gibi aynı 8×8 yamasının gradyanının büyüklüğüne ve yönüne bakıyoruz. Yönüne göre bir bölme seçilir ve oylama (bölmeye giren değer) büyüklüğe göre seçilir. Önce mavi ile çevrili piksele odaklanalım. Açısı (yönü) 80 derece ve büyüklüğü 2'dir. Yani 5. bölmeye 2 ekler. Kırmızı ile çevrelenmiş pikseldeki gradyan 10 derecelik bir açıya ve 4 büyüklüğe sahiptir. 10

derece 0 ile 20 arasında yarı yolda olduğundan, pikselin oyu iki bölmeye eşit olarak bölünür.




Şekil 12. Histogram değerlerinin hesaplanması

Dikkat edilmesi gereken bir ayrıntı daha var. Açı 160 dereceden büyükse, 160 ile 180 arasındadır ve açının 0 ile 180 eşdeğerini çevrelediğini biliyoruz. Dolayısıyla aşağıdaki örnekte 165 derecelik açıya sahip piksel, 0 derecelik bölme ve 160 derecelik bölme orantılı olarak katkıda bulunur.



Şekil 13. Histogram değerlerinin hesaplanması-2

8×8 hücrelerdeki tüm piksellerin katkıları, 9 bölmeli histogramı oluşturmak için toplanır. Yukarıdaki yama için sonuç aşağıdaki gibidir.



Şekil 14. Örnek görüntünün histogramı

Temsilimizde y eksenini 0 derecedir. Histogramın 0 ve 180 dereceye yakın çok fazla ağırlığa sahip olduğu görülmektedir, bu da yama gradyanlarının yukarı veya aşağıyı gösterdiğini söylemenin başka bir yoludur.

B. K- En Yakın Komşular Algoritması

Sınıflandırma yöntemlerinden biri olan K-En Yakın Komşular (KNN) algoritması hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılabilen bir denetimli makine öğrenme algoritmasıdır. Denetimli bir makine

öğrenimi algoritması (denetimsiz bir makine öğrenimi algoritmasının aksine), yeni etiketlenmemiş veriler verildiğinde uygun bir çıktı üreten bir işlevi öğrenmek için etiketli giriş verilerine dayanan bir algoritmadır. Denetimli makine öğrenimi algoritmaları, sınıflandırma veya regresyon problemlerini çözmek için kullanılır.

K-NN algoritması yeni vaka / veriler ile mevcut vakalar arasındaki benzerliği varsayar ve yeni vakayı mevcut kategorilere en çok benzeyen kategoriye koyar. Bu, yeni veriler görüldüğünde, K-NN algoritması kullanılarak kolayca uygun bir kategoriye sınıflandırılabileceği anlamına gelir. K-NN algoritması hem regresyon hem de sınıflandırma için kullanılabilir gibi, çoğunlukla sınıflandırma problemleri için kullanılmaktadır. KNN parametrik olmayan bir algoritmadır, bu da temel veriler üzerinde herhangi bir varsayım yapmadığı anlamına gelir.

Aynı zamanda tembel bir öğrenci algoritması olarak da adlandırılır, çünkü eğitim setinden hemen öğrenmez, bunun yerine veri kümesini saklar ve sınıflandırma sırasında veri kümesi üzerinde bir eylem gerçekleştirir. Eğitim aşamasında, KNN algoritması sadece veri kümesini saklar ve yeni veriler geldiğinde, bu verileri yeni verilere çok benzeyen bir kategoriye sınıflandırır.

KNN sınıflandırıcısı aşağıdaki mesafe metriklerini kullanır (K. Chomboon vd., 2015).

1. Manhattan Mesafesi

Bu mesafe taksi mesafesi veya blok mesafesi olarak da bilinir, iki nokta arasındaki uzaklık, Kartezyen koordinatlarının mutlak farklarının toplamıdır.

$$d = \sum_{i=1}^n |x_i - y_i| \quad (8)$$

Formülü ile hesaplanmaktadır.

2. Minkowsky Mesafesi

Gerçek değerli vektör uzayları için tasarlanmış bir metriktir. Minkowski mesafesini yalnızca normlu bir vektör uzayında hesaplayabiliriz, yani mesafelerin uzunluğu olan bir vektör olarak temsil edilebileceği ve uzunlukların negatif olamayacağı bir uzayda hesaplanmaktadır.

Mesafe metriğinin karşılması gereken birkaç koşul vardır:

Negatif olmama: $d(x, y) \geq 0$

Kimlik: $d(x, y) = 0$ ancak ve ancak $x = y$ ise

Simetri: $d(x, y) = d(y, x)$

Üçgen Eşitsizliği: $d(x, y) + d(y, z) \geq d(x, z)$

$$\left(\sum_{i=1}^n |x_i - y_i|^p\right)^{1/p} \quad (9)$$

Yukarıdaki Minkowski mesafesi formülü genelleştirilmiş formdadır ve farklı mesafe ölçümleri elde etmek için onu değiştirebiliriz.

Formüldeki p değeri, bize aşağıdaki gibi farklı mesafeler verecek şekilde değiştirilebilir:

$p = 1$, p 1'e ayarlandığında Manhattan mesafesini elde ederiz.

$p = 2$, p 2'ye ayarlandığında Öklid mesafesini elde ederiz.

3. Hamming Mesafesi

Hamming mesafesi, iki ikili veri dizisini karşılaştırmak için kullanılan bir ölçüdür. Eşit uzunluktaki iki ikili diziyi karşılaştırırken, Hamming mesafesi, iki bitin farklı olduğu bit konumlarının sayısıdır. Hamming mesafesi yöntemi tüm verilere bakar ve veri noktalarının birer birer benzer ve farklı olduğunu bulur. Hamming mesafesi, kaç özelliğin farklı olduğunu sonucunu verir.

Bu, çoğunlukla veriler tek tuşla kodlandığında ve iki ikili vektör arasındaki mesafelerin bulunması gerektiğinde kullanılır.

4. Öklid Mesafesi

Bu uzaklık ölçüsü, bir noktanın Kartezyen koordinatı ile aynı noktanın Kartezyen koordinatının transpoze edilmesi arasındaki farkların çarpımı olarak hesaplanır.

$$d_{st}^2 = (p_s - q_t)(p_s - q_t)' \quad (10)$$

p ve q kartezyen koordinatlardır. Öklid Mesafesi yukarıdaki formül ile hesaplanmaktadır.

5. Korelasyon Mesafesi

Bu metrik, iki vektör arasındaki istatistiksel bağımlılığın korelasyonu kullanılarak hesaplanır.

$$d_{st} = \left(1 - \frac{(p_s - \bar{p}_s)(q_t - \bar{q}_t)'}{\sqrt{(p_s - \bar{p}_s)(p_s - \bar{p}_s)'} \sqrt{(q_t - \bar{q}_t)(q_t - \bar{q}_t)'}} \right) \quad (11)$$

O halde

$$\bar{p}_s = \frac{1}{n} \sum_j p_{sj} \quad \text{ve} \quad \bar{q}_t = \frac{1}{n} \sum_j q_{tj} \quad (12)$$

Korelasyon mesafesi yukarıdaki formül kullanılarak hesaplanır.

Örüntü tanımanın araştırıldığı araştırma alanında, bir sınıflandırıcının etkinliği, bir örnek test görüntüsünün sınıflandırılması için gerekli olan karmaşıklık matrisi sınıflandırma doğruluğu ve zaman gibi çeşitli ölçümlerle değerlendirilir. Karışıklık matrisi, yanlış sınıflandırma yüzdesini sağlar. Sınıflandırma doğruluğu aşağıdaki formül ile hesaplanır.

$$\text{Doğruluk(Accuracy)} = \frac{P_T + N_T}{P_T + N_T + P_F + N_F} \quad (13)$$

P_T = Doğru Pozitif

N_T = Doğru Negatif

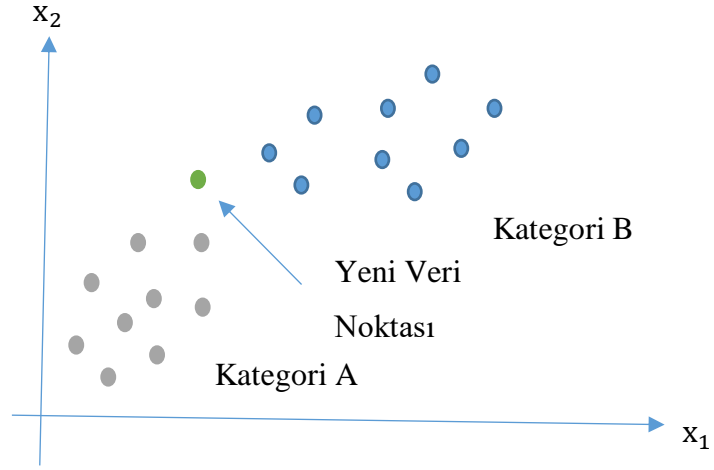
P_F = Yanlış Pozitif

N_F = Yanlış Negatif

Her sınıflandırma algoritması, test görüntüsünü sınıflandırmak için sınırlı bir süre gerektirir. Bu süre, test aşamasında algoritmanın sınıflandırma hızını sağlamaktadır. Bir sınıflandırma algoritmasının verimli çalışması için bu süre mümkün olduğunca kısa olmalıdır.


6. K-En Yakın Komşular Algoritması Nasıl Çalışır?

Bir veri setine eklenecek yeni bir veri noktası olduğu ve gerekli kategoriye koyulması gerekmektedir.



Şekil 15. Bir veri setinde yeni bir verinin temsili görünümü

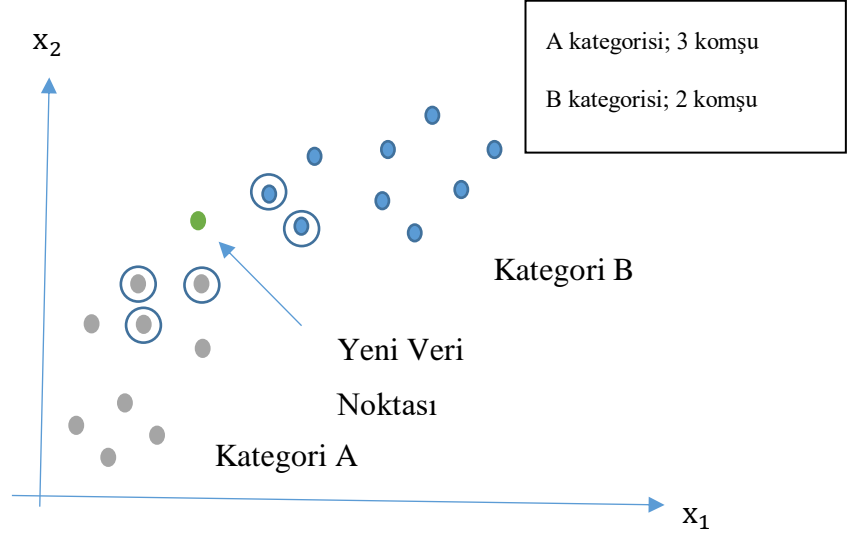
İlk olarak, komşu sayısını seçilir, komşu sayısı genellikle $k=5$ olarak seçilmektedir. Sonra, veri noktaları arasındaki Öklid mesafesini hesaplanır. Öklid mesafesi, geometride daha önce incelediğimiz iki nokta arasındaki mesafedir. Şu şekilde hesaplanabilir:



$$A \text{ ve } B \text{ arasındaki Öklid Mesafesi: } \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

Şekil 16. Öklid değerinin hesaplanması

Öklid mesafesini hesaplayarak, en yakın komşuları, Kategori A'daki en yakın üç komşu ve kategori B'deki en yakın iki komşu olarak alınması ile birlikte;



Şekil 17. Öklid mesafesi hesaplandıktan sonraki görünüm

Görüldüğü üzere, en yakın 3 komşu a kategorisindedir, bu nedenle bu yeni veri noktası a kategorisine ait olmalıdır.

7. KNN Algoritmasında K Değerinin Belirlenmesi

"K" için en iyi değeri belirlemenin özel bir yolu yoktur, bu yüzden bunlardan en iyisini bulmak için bazı değerleri denemeliyiz. K için en çok tercih edilen değer genellikle 5'tir. K=1 veya K=2 gibi K için çok düşük bir değer gürültülü olabilir ve modeldeki aykırı değerlerin etkilerine yol açabilir. K için büyük değerler iyidir, ancak bazı zorluklarla karşılaşılabilir.

IV. YÖNTEM

Önerilen yöntem, ilgilenilen yer işaretini içeren 16x16 piksel boyutunda bir bloğun sefalometrik görüntü üzerindeki yerini bulmaktadır. Bu çalışmada seçilen yer işaretleri yüzün ön bölgesindeki yüz silüeti üzerinden seçilmiştir. Yer işaretlerini daha kesin ve hızlı bir şekilde bulmak için arama alanının küçültülmesi ve böylece aramanın daha hızlı olması sağlanmıştır.

Şekil 18 örnek bir sefalometrik röntgen görüntüsünü göstermektedir. Görüntünün bulunmak istenen hedef yer işareti bölgesini içeren üçte birlik alanı yer işaretinin bulunduğu düşünülen bölge olarak seçilmiştir. Bu bölgede, her blok 8x8 piksellerden oluşacak şekilde 2x2'lik bloklara bölünmüştür. Böylece, her blok 16x16 piksel boyutundadır. Seçilen bölgede yaklaşık 300 adet blok bulunmaktadır.



Şekil 18. Örnek bir sefalometrik görüntü

Önerilen yöntemin ilk adımı, yeniden ölçeklendirmeden sonra hiçbir bozulma olmaması için sefalometrik görüntü hangi boyutta olursa olsun 400 piksel genişlik ve görüntünün yüksekliğini de bu genişlik ile orantılı olacak şekilde yeniden ölçeklendirmektir. Bu şekilde bütün sefalometrik görüntülerin aynı boyutta ve bozulmamış bir şekilde olması sağlanmaktadır. Yeniden ölçeklendirme için çift-doğrusal ölçekleme (bilinear enterpolasyon)

kullanılmıştır. Kullanılan yöntemde histogram oluşturmada aynı boyutta bloklar kullanıldığından, benzer şekil ve dokuların benzer HOG'a sahip olması için ölçeklendirme yapılmıştır. Ayrıca aydınlatma değişmezliği için histogram değerleri de normalleştirilmiştir.


Sonraki adım, ilgilenilen her bir yer işareti için veri kümesi oluşturmaktır. Bu, pozitif ve negatif veri noktaları için bloklar (pencereler) elle seçilerek veri kümesi oluşturulmuştur. Her pozitif blok için oran olarak yaklaşık 5 negatif blok seçilmiştir. Ortalama olarak, her bir yer işareti için veri seti 96 pozitif veri noktası ve 476 negatif veri noktası içermektedir. Pozitif bir blok, yer işaretini içeren bir bloktur. Negatif bir blok ise, yer işaretini içermeyen bir bloktur. Her bir yer işareti için bu yer işaretinin veri seti pozitif ve negatif veri noktaları olarak bir dosyada saklanmıştır. İlgilenilen her bir yer işaretinin veri kümesini oluşturmak için yaklaşık 100 sefalometrik görüntü kullanılmıştır.

Bir yer işaretinin aranması, o yer işaretini içeren bölgenin seçilerek arama bölgesinin daraltılması ile gerçekleştirilir. Bu bölgenin boyutu genellikle tüm sefalometrik görüntünün dörtte biri kadardır. Arama bloğu, blok boyutu olan 16x16 ile aynı büyüklüktedir. Arama bloğu bu bölgede soldan sağa ve yukarıdan aşağıya taşınır. Yanlış ve doğru pozitif ve negatiflerin sayısını azaltmak için arama blokları 8 piksel 8 piksel olarak kaydırılmıştır. İlgilenilen bütün yer işaretlerinin aranması yapıldığında doğru pozitiflerin hepsi tespit edilmiştir. Yaklaşık 300 adet blok bulunan arama bölgesinde ortalama 7-8 adet blok pozitif olarak tespit edilmiştir. Bunlardan doğru pozitiflerin içerisinde aradığımız bölge kesinlikle bulunmaktadır. Blok sayısını yaklaşık 300' den 10' dan daha aza düşürmek, yer işaretini daha doğru bir şekilde bulabilen ve daha çok hesaplama zamanı gerektiren bir algoritma için çok yararlı olabilir. İki histogram arasındaki benzerlik ölçüsü olarak Öklid mesafesi kullanılarak burun ucu Prn yer işareti için %100 doğruluk elde edilmiştir. İkinci en iyi sonuç, aynı Prn yer işareti için %87,5 doğruluk oranı ile Manhattan mesafesi kullanılarak elde edilmiştir. Öklid mesafesi, genel olarak bütün histogramlar arasındaki benzerlik ölçümünde en iyi sonuçları vermiştir.

Histogram benzerlik ölçümü için Öklid mesafesi, doğru pozitifleri tespit etme ve asgari yanlış pozitiflerin sayısını bulma açısından en iyi sonuçları vermiştir.

V.DENEYSEL SONUÇLAR

Önerilen yöntem, çeşitli yer işaretlerinin tespiti için uygulanmıştır. Elde edilen sonuçlar metnin geri kalan kısmında tartışılmıştır. Burun ucu Prn yer işareti için yöntem uygulandığında elde edilen bulgularda Şekil 19.(a), Prn yer işaretinin yanlış ve doğru pozitiflerini göstermektedir. Şekilde görüldüğü gibi üç doğru pozitif ve iki yanlış pozitif (dudak çevresi) vardır. İki histogram arasındaki benzerlik ölçüsü olarak Öklid mesafesi kullanılarak Prn yer işareti için %100 doğruluk elde edilmiştir. İkinci en iyi sonuç, aynı Prn yer işareti için %87,5 doğruluk oranı ile Manhattan mesafesi kullanılarak elde edilmiştir. Öklid mesafesi, genel olarak bütün histogramlar arasındaki benzerlik ölçümünde en iyi sonuçları vermiştir.



(a)

(b)


Şekil 19. (a). Histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler, (b). Ki-kare benzerlik ölçüsünü kullanan ve çok fazla yanlış pozitif içeren pozitif bloklar.

Şekil 19.(b), iki histogram arasındaki benzerlik için Ki-kare (Chi-square) kullanan aynı sefalometrik görüntüyü göstermektedir. Görüldüğü gibi çok fazla yanlış pozitif içermesi açısından Öklid mesafesinden çok daha kötü bir performans sergilemiştir. Ki-kare söz konusu benzerlik ölçüsü kullanan ve Prn

yer işaretini içeren bölge olarak seçilen bölgedeki 210 yanlış pozitif olduğu tespit edilmiştir.


KNN algoritmasının uygulanması, en yakın 5 komşuyu kullanmıştır ve komşuların sınıfının çoğunluğu, incelenen bölgenin sınıfını belirlemektedir.

Hem doğru hem de yanlış pozitif blokların histogramları Şekil 20'de (a-d) gösterilmektedir.




Şekil 20. (a, b). Prn yer işareti noktası için yanlış pozitiflerin histogramları, (c-d). Prn yer işareti için doğru pozitiflerin histogramları

Şekil 21, Şekil 20 (d)' de de gösterilen gerçek Prn landmark histogramının



Şekil 21. Gerçek Prn yer işareti histogramına minimum Öklid mesafesine sahip histogram


Şekil 21'de gösterilen en küçük mesafe histogramının sefaometrik görüntü üzerindeki yeri Şekil 22'de gösterilmiştir.



Şekil 22. Po yer işareti için histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler


KNN algoritmasının uygulanması, en yakın 5 komşuyu kullanmıştır ve komşuların sınıfının çoğunluğu, incelenen bloğun sınıfını belirlemektedir.

Doğru ve yanlış pozitif blokların histogramları Şekil 23.(a-d)'de gösterilmektedir.




Şekil 23. (a,b). Po yer işaretinin yanlış pozitiflerinin histogramları, (c,d). Po yer işaretinin doğru pozitiflerinin histogramları

Şekil 24, Şekil 23 (d)' de de gösterilen doğru Po yer işaretinin histogramına minimum mesafeye sahip histogramı göstermektedir.



Şekil 24. Doğru Po yer işareti histogramına minimum Öklid mesafesine sahip histogram

Histogramı Şekil 24'te gösterilen en küçük mesafe histogramı Şekil 25'te gösterilmiştir.



Şekil 25. Minimum Öklid mesafesi histogramı bloğu

Bir diğer sefalometrik yer işareti olan çene ucu yumuşak dokusu Pog'un bulunması metnin geri kalanında tartışılmıştır. Şekil 26 çene ucu yumuşak dokusu Pog işaretinin örneğini göstermektedir. Görüntünün çene bölgesini içeren üçte birlik alanı Pog içeren alan olarak seçilmiştir. Bu bölgede, her blok 8x8 piksellerden oluşacak şekilde 2x2'lik bloklara bölünmüştür. Böylece, her blok 16x16 piksel boyutundadır.



Şekil 26. Bir sefalometrik görüntü üzerinde yumuşak doku üzerindeki Po yer işaretinin gösterimi (Pog)

Burun ucu işareti Prn'nin tespiti için uygulanan adımları Pog'nun tespiti için uygulanır. İlk adım olarak sefalometrik görüntü üzerinde histogramların değerlerinin doğru hesaplanması için aynı boyutta blokların kullanılması gerekmektedir. Bu nedenle sefalometrik görüntü üzerinde benzer şekil ve dokulara sahip bölgelerin benzer HOG değerlerine sahip olması amacıyla, çift-doğrusal ölçekleme yöntemi kullanılarak yeniden ölçeklendirme uygulanmıştır. Daha sonra görüntünün ışıktan etkilenmemesi ve bozulmaması amacıyla aydınlatma değişmezliğinin sağlanması için histogram değerleri normleştirilmiştir.

Daha sonra Pog yer işaretinin veri kümesi, pozitif ve negatif veri noktaları için elle bloklar seçilerek oluşturulmuştur. Pozitif veri noktaları oluşturulurken 100 adet sefalometrik görüntü kullanılmıştır. Bu görüntüler üzerinde daha önceden uzmanlar tarafından işaretlenmiş olan 100 adet çene ucu yumuşak dokusu yeri işareti bulunmaktadır. Bu görüntülerden yer işaretleri alınmış olup, bu yer işaretlerinin histogramları oluşturulmuştur. Oluşturulan bu histogramlar pozitif veri noktası olarak kaydedilmiştir.

Pog yer işareti çene bölgesindeki yumuşak dokulu alanı göstermektedir. Bu bölgenin, sefalometrik görüntüye göre oldukça küçük bir bölge olduğu görülmektedir. Pog işaretinin sefalometrik görüntü üzerinde aranacağı bölgeyi

daraltmak önemli ölçüde zaman kazandırmaktadır. Arama yapılacak bölge sefalometrik görüntünün üçte biri büyüklüğünde olarak seçilmiştir. Daha sonra 100 sefalometrik görüntünün her birinde Pog yer işaretini içine almayacak şekilde arama bloğunun kaydırıldığı görüntünün üçte biri kadar olan alan içerisinde Po işaretine benzeyen veya benzemeyen yerler elle seçilmiştir. Her bir pozitif değer için 5-6 adet negatif nokta seçilerek negatif veri noktası olarak kaydedilmiştir.

Pog yer işaretinin tespiti için kullanılan arama bloğu blok boyutu olan 16x16 ile aynı büyüklüktedir. Arama bloğu bu bölgede, soldan sağa ve yukarıdan aşağıya taşınmaktadır. Yanlış ve doğru pozitif ve negatiflerin sayısını azaltmak için arama blokları 8 piksel 8 piksel olarak kaydırılmıştır. Yaklaşık 300 adet blok bulunan arama bölgesinde ortalama 7-8 adet blok pozitif olarak tespit edilmiştir. Bunlardan doğru pozitiflerin içerisinde aradığımız bölge kesinlikle bulunmaktadır. Şekil 27 sefalometrik görüntü üzerinde Pog yer işareti için bulunan yanlış ve doğru pozitifleri göstermektedir. İki histogram arasındaki benzerlik ölçüsü olarak Öklid mesafesi kullanılarak Pog yer işareti için %87,5 doğruluk oranı ile bloklar doğru yerleştirilmiştir. Manhattan mesafesi ile yer işaretinin konumlandırılmadığı gözlemlenmiştir.




Şekil 27. Pog yer işareti için histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler

Kutular sadece önemli noktaları ihtiva etmektedir. Başarılı tespitlerde önemli noktaların kutuların merkezinde olması gerekmemektedir. Önemli olan

kutuların herhangi bir yerinde önemli noktanın bulunmasıdır. Bu durum bütün başarılı kutu yerleřtirilmelerinde geçerlidir.


KNN algoritmasının uygulanması, en yakın 5 komřuuyu kullanılmıřtır ve komřuların sınıfının çoęunluęu, incelenen bloęun sınıfını belirlemektedir.

Doęru ve yanlış pozitif blokların histogramları Őekil 28'de (a-e) gsterilmektedir.



Őekil 28. (a-c). Pog yer iřaretinin yanlış pozitiflerinin histogramları, (d,e). Pog yer iřaretinin doęru pozitiflerinin histogramları

Őekil 29, Őekil 28 (e)' de de gsterilen doęru Pog yer iřaretinin histogramına minimum mesafeye sahip histogramı gstermektedir.



Şekil 29. Minimum Öklid mesafesi histogramı bloğu

Alt dudak yer işareti metnin geri kalanında tartışılmıştır. Görüntünün dudak bölgesini içeren üçte birlik alanı alt dudak yer işaretini içeren alan olarak seçilmiştir. Bu bölgede, her blok 8x8 piksellerden oluşacak şekilde 2x2'lik bloklara bölünmüştür. Böylece, her blok 16x16 piksel boyutundadır. Seçilen bölgede yaklaşık 300 adet blok bulunmaktadır.


Aynı yöntem alt dudak yer işaretinin tespiti içinde uygulanmıştır. İlk adım olarak sefalometrik görüntü üzerinde histogramların değerlerinin doğru hesaplanması için aynı boyutta blokların kullanılması gerekmektedir. Bu nedenle sefalometrik görüntü üzerinde benzer şekil ve dokulara sahip bölgelerin benzer HOG değerlerine sahip olması amacıyla, çift-doğrusal ölçekleme yöntemi kullanılarak yeniden ölçeklendirme uygulanmıştır. Daha sonra görüntünün ışıktan etkilenmemesi ve bozulmaması amacıyla aydınlatma değişmezliğinin sağlanması için histogram değerleri normalleştirilmiştir.

Daha sonra alt dudak yer işaretinin veri kümesi, pozitif ve negatif veri noktaları için elle bloklar seçilerek oluşturulmuştur. Pozitif veri noktaları oluşturulurken 100 adet sefalometrik görüntü kullanılmıştır. Bu görüntüler üzerinde daha önceden uzmanlar tarafından işaretlenmiş olan 100 adet alt dudak yer işareti bulunmaktadır. Bu görüntülerden yer işaretleri alınmış olup, bu yer işaretlerinin histogramları oluşturulmuştur. Oluşturulan bu histogramlar pozitif veri noktası olarak kaydedilmiştir.

Alt dudak yer işaretinin sefalometrik görüntü üzerinde aranacağı bölgeyi daraltmak önemli ölçüde zaman kazandırmaktadır. Arama yapılacak bölge sefalometrik görüntünün üçte biri büyüklüğünde olarak seçilmiştir. Daha sonra 100 sefalometrik görüntünün her birinde alt dudak yer işaretini içine almayacak şekilde arama bloğunun kaydırıldığı görüntünün üçte biri kadar olan alan içerisinde alt dudak yer işaretine benzeyen veya benzemeyen yerler elle

seçilmiştir. Her bir pozitif değer için 5-6 adet negatif nokta seçilerek negatif veri noktası olarak kaydedilmiştir.

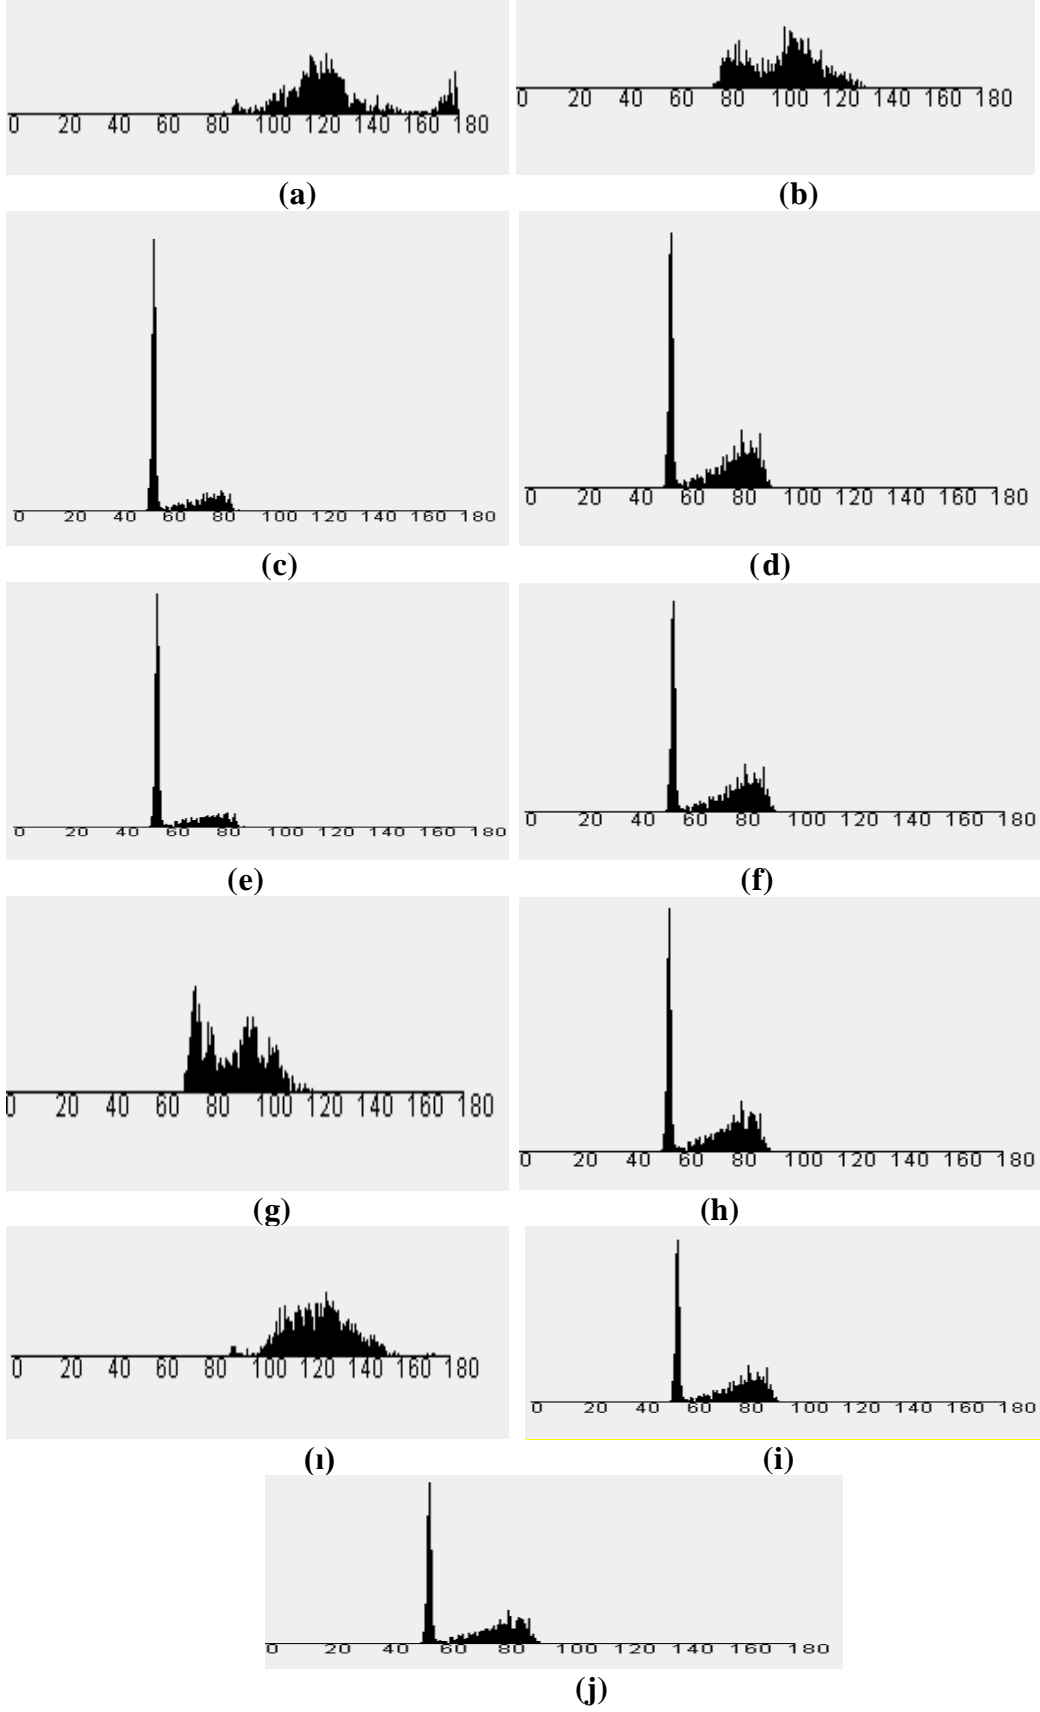
Alt dudak yer işaretinin tespiti için kullanılan arama bloğu blok boyutu olan 16x16 ile aynı büyüklüktedir. Arama bloğu bu bölgede, soldan sağa ve yukarıdan aşağıya taşınmaktadır. Yanlış ve doğru pozitif ve negatiflerin sayısını azaltmak için arama blokları 8 piksel 8 piksel olarak kaydırılmıştır. Şekil 30 sefalometrik görüntü üzerinde alt dudak yer işaretinin yanlış ve doğru pozitiflerini göstermektedir. İki histogram arasındaki benzerlik ölçüsü olarak Öklid mesafesi kullanılarak alt dudak yer işareti için %87,5 doğruluk oranı ile bloklar doğru yerleştirilmiştir. Manhattan mesafesi kullanılarak alt dudak yer işareti için %25 doğruluk oranı ile blokların yerleştirildiği gözlemlenmiştir.



Şekil 30. Alt dudak için histogramlar arasındaki benzerlik ölçüsü olarak Öklid mesafesini kullanan yanlış ve doğru pozitifler


KNN algoritmasının uygulanması, en yakın 5 komşuyu kullanır ve komşuların sınıfının çoğunluğu, incelenen bloğun sınıfını belirler.

Doğru ve yanlış pozitif blokların histogramları Şekil 31. (a-j) gösterilmektedir.



Şekil 31. (a,b). Alt dudak için doğru ve yanlış pozitiflerin histogramları, (c-i). Alt dudak yer işaretinin doğru pozitiflerinin histogramları, (i,j). Alt dudak yer işaretinin doğru pozitiflerinin histogramları

Şekil 32, Şekil 31 (j) ' de gösterilen doğru Pog yer işaretinin histogramına minimum mesafeye sahip histogramı göstermektedir.



Şekil 32. Doğru alt dudak yer işareti histogramına minimum Öklid mesafesine sahip histogram

Şekil 32'de gösterilen en küçük mesafe histogramının sefaometrik görüntü üzerindeki yeri Şekil 33'te gösterilmiştir.



Şekil 33. Minimum Öklid mesafesi histogramı bloğu

N kemiği alın bölgesinde yer almaktadır. N kemiği yer işareti metnin geri kalanında tartışılmıştır. Görüntünün alın bölgesini içeren üçte birlik alanı N kemiği yer işaretini içeren alan olarak seçilmiştir. Bu bölgede, her blok 8x8 piksellerden oluşacak şekilde 2x2'lik bloklara bölünmüştür. Böylece, her blok 16x16 piksel boyutundadır. Seçilen bölgede yaklaşık 300 adet blok bulunmaktadır.


Aynı yöntem N kemiği yer işaretinin tespiti içinde uygulanmıştır. İlk adım olarak sefalometrik görüntü üzerinde histogramların değerlerinin doğru hesaplanması için aynı boyutta blokların kullanılması gerekmektedir. Bu nedenle sefalometrik görüntü üzerinde benzer şekil ve dokulara sahip bölgelerin benzer HOG değerlerine sahip olması amacıyla, çift-doğrusal ölçekleme yöntemi

kullanılarak yeniden ölçeklendirme uygulanmıştır. Daha sonra görüntünün ışıktan etkilenmemesi ve bozulmaması amacıyla aydınlatma değişmezliğinin sağlanması için histogram değerleri normalleştirilmiştir.

Daha sonra N kemiği yer işaretinin veri kümesi, pozitif ve negatif veri noktaları için elle bloklar seçilerek oluşturulmuştur. Pozitif veri noktaları oluşturulurken 100 adet sefalometrik görüntü kullanılmıştır. Bu görüntüler üzerinde daha önceden uzmanlar tarafından işaretlenmiş olan 100 adet N kemiği yer işareti bulunmaktadır. Bu görüntülerden yer işaretleri alınmış olup, bu yer işaretlerinin histogramları oluşturulmuştur. Oluşturulan bu histogramlar pozitif veri noktası olarak kaydedilmiştir.

N kemiği yer işaretinin sefalometrik görüntü üzerinde aranacağı bölgeyi daraltmak önemli ölçüde zaman kazandırmaktadır. Arama yapılacak bölge sefalometrik görüntünün üçte biri büyüklüğünde olarak seçilmiştir. Daha sonra 100 sefalometrik görüntünün her birinde N kemiği yer işaretini içine almayacak şekilde arama bloğunun kaydırıldığı görüntünün üçte biri kadar olan alan içerisinde N kemiği yer işaretine benzeyen veya benzemeyen yerler elle seçilmiştir. Her bir pozitif değer için 5-6 adet negatif nokta seçilerek negatif veri noktası olarak kaydedilmiştir.

N kemiği yer işaretinin tespiti için kullanılan arama bloğu blok boyutu olan 16x16 ile aynı büyüklüktedir. Arama bloğu bu bölgede, soldan sağa ve yukarıdan aşağıya taşınmaktadır. Yanlış ve doğru pozitif ve negatiflerin sayısını azaltmak için arama blokları 8 piksel 8 piksel olarak kaydırılmıştır. Şekil 34 sefalometrik görüntü üzerinde N kemiği yer işaretinin yanlış ve doğru pozitiflerini göstermektedir. İki histogram arasındaki benzerlik ölçüsü olarak Öklid mesafesi kullanılarak N kemiği yer işareti için %25 doğruluk oranı ile bloklar doğru yerleştirilmiştir. Manhattan mesafesi ile yer işaretinin konumlandırılmadığı gözlemlenmiştir.



Şekil 34. N kemiği yer işaretinin yanlış pozitif bloğunun görünümü

Yöntemin uygulanması sonucunda 2 doğru pozitif ve 3 ü bulunmak istenen N kemiği işaretini hiç bulamamış olup, 3' ü yanlış yerde pozitif blok bulmuştur. Bu nedenle 6 yanlış pozitif blok olarak bulunmuştur. Şekil 35 N kemiği yer işaretinin doğru pozitiflerini göstermektedir.



Şekil 35. N kemiği yer işareti için bulunan doğru pozitif bloklar

Algoritmanın N kemiği yer işaretinin tespiti için kötü bir performans sergilemiş olmasının sebebi, aranan hedef bölgenin çok fazla gürültü içermesinden kaynaklanmaktadır. Algoritmanın, sefalomerik görüntüler üzerinde

daha az gürültüye sahip bölgelerdeki yer işaretlerinin tespiti için yüksek doğrulukla sonuç ürettiği gözlemlenmiştir.

Algoritmanın HOG + KNN (Öklid Mesafesi) ve HOG + KNN (Manhattan Mesafesi) için doğruluk oranlarının karşılaştırması aşağıdaki çizelgede yer almaktadır. Öklid mesafesinin genel olarak iki histogram arasındaki benzerlik ölçüsü olarak daha yüksek doğruluk oranı ile yer işaretlerini doğru konumlandığı gözlemlenmiş olup, algoritmanın sefalometrik görüntülerde gürültünün az olduğu bölgelerdeki yer işaretlerini daha yüksek doğruluk ile konumlandığı gözlemlenmiştir.

Çizelge 8. Algoritmanın yer işaretlerine göre sonuçlarının tablosu

Yer işareti	HOG+ KNN (Öklid Mesafesi)	HOG+KNN(Manhattan Mesafesi)
Burun ucu (Prn)	% 100	% 87,5
Alt çene kemiğinin ucu (Po)	% 75	% 0
Çenenin ucundaki yumuşak doku (Pog)	% 87,5	% 0
Alt dudak	% 87,5	% 25
N kemiği	% 25	% 0

VI.GELECEKTE YAPILABİLECEK ÇALIŞMALAR

Sefalometrik görüntülere gri tonlama (grey scale) uygulanarak görüntülerde çok gürültü içeren bölgelerdeki yer işaretlerinin yerlerinin bulunmasını kolaylaştıracak bir ön görüntü işleme işlemlerinin daha sonraki çalışmalarda uygulanabileceği düşünülmektedir. Bu sayede kemik yoğunluğunun çok olduğu bölgelerdeki yer işaretlerinde yüksek doğruluk oranları ile bulunması sağlanabilir.

VII. SONUÇ

Bu çalışma, HOG kullanarak sefalometrik görüntülerden öznitelikler çıkarmayı ve belirli yer işaretlerini verimli bir şekilde tespit etmek için KNN sınıflandırma algoritmasını kullanmayı amaçlamaktadır. Tespit için yalnızca birkaç çevreleyen yer işareti seçilir ve bunların bulunması, aramayı sefalometrik görüntülerde minimum bir alanla sınırlayacaktır. Eğer bu işlem yeterince hızlıysa, yer işaretlerinin tam yerini saptamak için daha fazla zaman gerektiren algoritmalar kullanılabilir. Bu çalışmada Prn yer işareti örnek olarak kullanılmıştır. Veri kümesi manuel olarak üretildikten sonra, Prn işaretini içeren blok 1044 milisaniye içinde %100 doğrulukla konumlandırılmıştır.

Alt çene kemiği yer işareti olan Po'yu içeren blok %75 doğruluk oranı ile konumlandırılmıştır. Çenenin ucundaki yumuşak doku Pog işaretini içeren blok %87,5 doğruluk oranı ile konumlandırılmıştır. Alt dudak yer işaretini içeren blok %87,5 doğruluk oranı ile konumlandırılmıştır. N kemiği yer işaretini içeren blok %25 doğruluk oranı ile konumlandırılmıştır. Algoritmaların uygulaması Java ile yapılmakta ve kod, Intel i7 ikinci nesil CPU ve 8GB belleğe sahip 2.67 GHz bir platformda yürütülmektedir. Bu çalışmada kullanılan sefalometrik görüntüler araştırma amacıyla www-o.ntust.edu.tw/~cweiwang/ISBI2015/challenge1/ adresinde ücretsiz olarak mevcuttur.

VIII. KAYNAKÇA

MAKALELER

- BHARATE, V., CHAUDHARI, D., & CHAUDHARI, M. (2019). Use of KNN Classifier for Emotion Recognition. *International Journal of Engineering and Advanced Technology (IJEAT)*, 9(1), 1294-1298.
- CAI, Z., YU, P., LIANG, Y., LIN, B., & HUANG, H. (2016). SVM-KNN Algorithm for Image Classification Based on Enhanced. *The 4th IIAE International Conference on Intelligent Systems and Image Processing 2016*. 510006, P.R. China.
- CARDILLO, J., & SID-AHMED, M. (1994). An Image Processing System For Locating Craniofacial Landmarks. *IEEE Transactions on Medical Imaging*, 13(2), 275–289.
- CHEN, C., & ZHENG, G. (2014). Fully- Automatic Landmark Detection in Cephalometric X-Ray Images by Data-Driven Image Displacement Estimation. *Proc. ISBI International Symposium on Biomedical Imaging 2014: Automatic Cephalometric X-Ray Landmark Detection Challenge*.
- CHOMBOON, K., TEERASSAMEE, P., KERDPRASOP, K., & KERDPRASOP, N. (2015). An Empirical Study of Distance Metrics for k- Nearest Neighbour Algorithm. *International Conference on Industrial Application Engineering*.
- CHU, C., CHEN, C., NOLTE, L., & ZHENG, G. (2014). Fully Automatic Cephalometric X-ray Landmark Detection Using Random Forest Regression and Sparse Shape Composition. *Automatic Cephalometric X-ray Landmark Detection Challenge*.
- DALAL, N., & TRIGGS, B. (2005). Histograms of Oriented Gradients For Human Detection. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. 1, s. 886-893. San Diego: IEEE.

- EL-FEGH, I., GALHOOD, M., SÍD-AHMED, M., & AHMEDÍ, M. (2008). Automated 2-D Cephalometric Analysis of X-ray By Image Registration Approach Based On Least Square Approximator. 30th International Congerence of The IEEE Engineering in Medicine and Biology Society-EMBS (s. 3949-3952). Vancouver, Canada: International Conference of the IEEE Engineering in Medicine and Biology Society.
- FELZENSZWALB, P., & HUTTENLOCHER, D. (2004). Efficient Graph-Based Image Segmentation. *International Journal of Computer Vision*, 59(2), 167–181.
- FORSYTH, D., & DAVÍS, D. (1996). Assessment of an automated cephalometric analysis system. *European Journal of Orthodontics*, 18(5), 471-478.
- HOASHÍ, H., JOUTOU, T., & YANAÍ, K. (2010). Image Recognition of 85 Food Categories By Feature Fusion. 2010 IEEE International Symposium on Multimedia (s. 296-301.). Taichung: IEEE.
- İBRAGİMOV, B., LİKAR, B., PERNUS, F., & VRTOVEC, T. (2014). Automatic Cephalometric X-ray Landmark Detection By Applying Game Theory and Random Forests. *adfa*, 1-8.
- JOUTOU, T., & YANAÍ, K. (2009). A Food Image Recognition System With Multiple Kernel Learning. 16th IEEE International Conference on Image Processing (ICIP'09), (s. 285-288).
- KANG, S., JEON, K., SEO, J., & LEE, S. (2019). Automatic 3D Cephalometric Annotation System Using Shadowed 2D Image-Based Machine Learning. *Physics in Medicine and Biology*, 64(5).
- KAWANO, Y., & YANAÍ, K. (2013). Rapid Mobile Object Recognition Using Fisher Vector. 2nd IAPR Asian Conference on Pattern Recognition, (s. 476-480.).
- KAWANO, Y., & YANAÍ, K. (2014). FoodCam: A Real-time Food Recognition System On A Smartphone. *Multimedia Tools and Applications* volume, 5263–5287.

- LÉVY-MANDEL, A., VENETSANOPOULOS, A., & TSOTSOS, J. (1986). Knowledge-Based Landmarking of Cephalograms. *Computers and Biomedical Research*, 19(3), 282-309.
- LINDNER, C., & COOTES, T. (2015). Fully Automatic Cephalometric Evaluation Using Random Forest Regression-Voting. *IEEE International Symposium on Biomedical Imaging (ISBI) 2015 – Grand Challenges in Dental X-ray Image Analysis – Automated Detection and Analysis for Diagnosis in Cephalometric X-ray Image*.
- LINDNER, C., WANG, C.-W., HUANG, C.-T., LI, C.-H., CHENG, S.-W., & COOTES, T. (2016). Fully Automatic System for Accurate Localisation and Analysis of Cephalometric Landmarks in Lateral Cephalograms. *Scientific Reports*, 20(6).
- MIRZAALIAN, H., & HAMARNEH, G. (2014). Automatic Globally-Optimal Pictorial Structures with Random Decision Forest Based Likelihoods For Cephalometric X-Ray Landmark Detection. *Proc. ISBI International Symposium on Biomedical Imaging 2014: Automatic Cephalometric X-Ray Landmark Detection Challenge*.
- PUTRA, F., UTAMININGRUM, F., & MAHMUDY, W. (2020). HOG Feature Extraction and KNN Classification for Detecting Vehicle in The Highway. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 14(3), 231-242. doi:<https://doi.org/10.22146/ijccs.54050>
- RAZALI, M., MANSOR, N., HALIN, A., MUSTAPHA, N., & RAZALI, Y. (2017). Analysis of SURF and SIFT Representations to Recognize Food Objects. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 9(2-12), 81-88.
- RONG, Z. (2006). *Image and Video Classification*. New Brunswick: Rutgers University.
- SHORT, R., & FUKUNAGA, K. (1981). The Optimal Distance Measure For Nearest Neighbor Classification. *IEEE Transactions on Information Theory*, 27(5), 622-627.

- SONG, Y., QUÍANO, X., IWAMOTO, Y., & CHEN, Y. (2020). Automatic Cephalometric Landmark Detection on X-ray Images Using a Deep-Learning Method. *Applied Sciences*, 10(7). doi:<https://doi.org/10.3390/app10072547>
- ŞENGÜL, G., & KHALİFA, T. (2018). Gender Prediction From Facial Images Using Local Binary Patterns and Histograms of Oriented Gradients Transformations. *Omer Halisdemir University Journal of Engineering Sciences*, 7(1), xx-xx.
- VANDAELE, R., MARE, R., JODOGNE, S., & GEURTS, P. (2014). Automatic Cephalometric X-Ray Landmark Detection Challenge 2014: A Tree Based Approach. in *Proc. ISBI International Symposium on Biomedical Imaging 2014: Automatic Cephalometric X-Ray Landmark Detection Challenge*.
- YALİ, L., WANG, S., TIAN, Q., & DİNG, X. (2015). Feature Representation For Statistical-Learning-Based Object Detection: A Review. *Pattern Recognition*, 48(11), 3542-3559.
- YANG, X., ZHANG, Q., YANG, X., PENG, Q., Lİ, Z., & WANG, N. (2018). Edge Detection in Cassini Astronomy Image Using Extreme Learning Machine. *2nd International Conference on Material Engineering and Advanced Manufacturing Technology (MEAMT 2018)*, 189. doi:0.1051/mateconf/201818906007.

ELEKTRONİK KAYNAKLAR

- URL-1 “Image Processing – Bilinear Interpolation”, <https://theailearner.com/2018/12/29/image-processing-bilinear-interpolation/>, (Erişim Tarihi: 20 Haziran 2021).
- URL-2 “Grand Challenges in Dental X- Ray Images Analysis”, <http://www-o.ntust.edu.tw/~cweiwang/ISBI2015/challenge1/>, tezde kullanılan sefalometrik görüntüler bu web sitesinden alınmıştır. (Erişim Tarihi: 17 Ocak 2021).

ÖZGEÇMİŞ

Ad- Soyad : Oğuz SÖZKESEN

Öğrenim Durumu:

- **Lisans:** 2016, İstanbul Aydın Üniversitesi Mühendislik ve Mimarlık Fakültesi Mekatronik Mühendisliği
- **Yüksek Lisans:** 2021, İstanbul Aydın Üniversitesi Bilgisayar Mühendisliği

TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- Sözkese O. & Özyavaş A., 2021, Localization of Certain Cephalometric Landmarks Using HOG and KNN, International Journal of Advances in Engineering and Management (IJAEM) Volume 3, Issue 6 June 2021, pp: 842-847.