

YEREL ÜÇLÜ DESEN İLE KULAK GÖRÜNTÜLERİNİN KİŞİ, YAŞ VE CİNSİYETE GÖRE SINIFLANDIRILMASI

Emrah Aydemir^{*ID}
Asaad Qais Shalal ABO SOOT^{**ID}

Alınma: 12.01.2022; düzeltme: 28.07.2022; kabul: 11.09.2022

Öz: Bireylerin kimliğini doğrulamaya yönelik ihtiyaç her geçen gün artmaktadır. Geleneksel olarak kimlik doğrulama sistemlerinde pasaportlar, kimlik kartları, anahtarlar kullanılır. Bu tür sistemler ile birlikte güvenliği arttırmak için şifreler de kullanılabilir. Maalesef bu tür güvenlik sistemlerinin dezavantajları arasında kimlik olarak kullanılan eşyanın kaybolması, kopyalanması, çalınması söz konusu olabilir. Şifrelerin ise unutulması ortaya çıkabilir. Bu tür durumlar kişiyi tehlikeye atabilir veya zor bir duruma sokabilir. Geleneksel kişi tanıma tekniklerinin bu tür eksiklikleri, herkes için büyük sorunlara neden olur. Bu tür durumlar ise araştırmacıları sağlam, güvenilir ve kusursuz bir kişisel tanımlama arayışına itmektedir. Bu arayış ise araştırmacıları biyometri sistemlerine itmektedir. Buradaki çalışma da 100 kişiye ait sağ ve sol kulak görüntüleri olan 2000 veri toplanmıştır. Toplanan bu dosyaların Yerel Üçlü Desen ile öznelikleri çıkarılmıştır. Her bir görüntü dosyası için 1x512 boyutlarında vektör üretilmiştir. Tüm dosyalar için bu işlemler yapılmış ve birçok farklı sınıflandırma algoritmaları ile görüntüler kişi, yaş ve cinsiyet için sınıflandırılmıştır. Kişi tanıma için % 90,2 oranında doğruluk oranı elde edilirken, cinsiyet için % 99,8 oranında başarı elde edilmiştir. Son olarak yaş için ise % 86,1 oranında sınıflandırma başarısına ulaşılmıştır.

Anahtar Kelimeler: Kulak görüntüsü, yerel üçlü desen, sınıflandırma

Classification of Ear Images According to Person, Age, and Gender with The Local Ternary Pattern

Abstract: The need to verify the identity of individuals is increasing day by day. Traditionally, passports, identity cards, keys are used in authentication systems. With such systems, passwords can also be used to increase security. Unfortunately, the disadvantages of such security systems include the loss, copying, and theft of the item used as an identity. Passwords can be forgotten. Such situations can endanger the person or put him in a difficult situation. Such shortcomings of traditional person recognition techniques cause major problems for everyone. Such situations push researchers to seek a solid, reliable and perfect personal description. This search pushes researchers to biometric systems. In this study, 2000 data, which are right and left ear images of 100 people, were collected. The attributes of these collected files were extracted with the Local Triple Pattern. For each image file, 1x512 vectors were produced. These processes were performed for all files and images were classified for person, age and gender with many different classification algorithms. While 90.2% accuracy rate was obtained for person recognition, 99.8% success was achieved for gender. Finally, the classification success rate was 86.1% for age.

Keywords: Ear image, local ternary pattern, classification

* Sakarya Üniversitesi, İşletme Fakültesi, Yönetim Bilişim Sistemleri, 54600, Sakarya, emrahaydemir@sakarya.edu.tr

** Kırşehir Ahi Evran Üniversitesi, Fen Bilimleri Enstitüsü, İleri Teknolojiler, 40100, Kırşehir, asaadalwasty32@gmail.com

İletişim Yazarı: Emrah Aydemir (emrahaydemir@sakarya.edu.tr)

1. GİRİŐ

Bireylerin kimliđini dođrulamaya ynelik ihtiya her geen gn artmaktadır. Geleneksel olarak kimlik dođrulama sistemlerinde pasaportlar, kimlik kartları, anahtarlar kullanılır. Bu tr sistemler ile birlikte gvenliđi arttırmak iin Őifreler de kullanılabilir. Maalesef bu tr gvenlik sistemlerinin dezavantajları arasında kimlik olarak kullanılan eŐyanın kaybolması, kopyalanması, alınması sz konusu olabilir. Őifrelerin ise unutulması ortaya ıkabilir. Bu tr durumlar kiŐiyi tehlikeye atabilir veya zor bir duruma sokabilir. Geleneksel kiŐi tanıma tekniklerinin bu tr eksiklikleri, herkes iin byk sorunlara neden olur. Bu tr durumlar ise araŐtırmacıları sađlam, gvenilir ve kusursuz bir kiŐisel tanımlama arayıŐına itmektedir. Bu arayıŐ ise araŐtırmacıları biyometri sistemlerine itmektedir. Biyometri, kimlik kanıtını bedenlerimize ve davranıŐ kalıplarımıza bađlayarak bu soruna cevap vermeyi amalamaktadır (Uddin ve diđ., 2011). Biyometrik sistemler aynı zamanda gzetim, adli tip ve farklı akıllı sistemler ierisinde de kullanılmaktadır (Omara ve diđ., 2016).

Biyometri insanları yz, iris, kulak, parmak izi, avu izi, el geometrisi, ses gibi fiziksel veya davranıŐsal zelliklerini kullanarak tanıma bilimidir (Jain ve diđ., 2004; Rakshit ve diđ., 2018). Bu veya buna benzer zelliklerin biyometrik bir zellik olduđunun kabul edilebilmesi iin ncelikle aŐađıdaki altı gereksinimi karŐılaması beklenir (Hassaballah ve diđ., 2019).

- Evrensellik: Her bireyin bu zelliđe sahip olması gerekir.
- Ayırt edicilik: Farklı bireyleri ayırt edebilmesi gerekir.
- Kalıcılık: YaŐa gre deđiŐmeyecek kadar yeterli olması gerekir.
- Performans: Gerekli tanıma dođruluđu ve hızının yanı sıra bunları etkileyen operasyonel ve evresel faktrlere karŐı dayanıklı olması gerekir.
- Toplanabilirlik: Kolayca ve nicel olarak elde edilebilir ve llebilir olmalıdır.
- Kabul edilebilirlik: Bireylerin bu karakteristik zelliđi belirli lde kabul etmesi gerekir.

Elektronik sistemlerin ve yazılım sistemlerin geliŐmesi sonucu biyometrik tanıma sınırları yalnızca yz tanımadan ibaret olmayıp retina tarama, avu ii tanıma vb. birok alana geniŐlemiŐtir. Biyometri, birok kiŐisel ve kurumsal gvenlik sisteminde geliŐmiŐ bir katman olarak ykseliyor. Biyolojinin ya da davranıŐların benzersiz olmasından hemen hemen kusursuz bir tanımlama sistemleri oluŐmaya baŐlamıŐtır. Tanımlama hususunda gvenirliđin artması iin eŐitlilik de gn getike artmaktadır. Son zamanlarda yz tanıma sistemlerine ek olarak gz tanıma, avu ii tanıma ve kulak tanıma sistemlerinde de geliŐmeler olmaktadır. Kulak grntleri de biyometrik zelliklerin taŐıması gereken tm niteliklere sahiptir (Rahman ve diđ., 2007). Bu nedenle kulak zerine yapılan tanıma alıŐmaları eskiye dayanmaktadır (Moreno ve diđ., 1999). zellikle kulak grntsnn kiŐilerin isteđi dıŐında uzaktan kolayca elde edilebilmesi, kulak yzeyinin tek tip renk dađılımına sahip olması, yz gibi farklı ifadeler iermemesi (Burge ve Burger, 2000) diđer biyometrik zelliklere kıyasla tanıma iin avantaj oluŐturmaktadır. Bu avantajlar bilgisayar sistemli tanıma alıŐmalarında araŐtırmacıları bu konulara ynlendirmektedir.


1.1. Kulak Yapısı

İnsanların kulak grnts diđer organlarına kıyasla zellikler bakımından zengindir. Bir kulak grnts 10'dan fazla temel zellik ve yaklaşık 37 alt zelliđe ayrılabilir. İnsan kulađının temel yapısı aŐađıdaki Őekil 1.1.'de gsterilmiŐtir. Kulak grnts en temel Őekliyle bir dıŐ ember, paralel ıkıntılar, lob ve tragus denilen kıkırdak kk ıkıntısından oluŐur. Bunlar kulak Őeklini oluŐturan temel unsurlardır. Ayrıca dıŐ sarmala kabaca paralel uzanan ancak st uta iki kola ayrılan bir sarmal (antiheliks) vardır. İ sarmal bu iki ayırımın altı kısmından oluŐur.



Şekil 1.1.:
Kulak temel yapısı

Bazı kulaklarda loblar çok iyi bir şekilde biçimlendirilmişken bazılarında ise yok denecek gibidir. Ekli loblar denilen bu nokta kulağın uzunluğunun ölçülmesini sağlar. Aşağıdaki Şekil 1.2’de kulak genişlik ve uzunluğunu belirleyen noktalar gösterilmiştir.



Şekil 1.2.:
Kulak genişliği ve uzunluğu ölçümü

Erkekler ve kadınlar arasında kulak şekilleri bakımından farklılıklar vardır. Erkeklerin kadınlardan ortalama olarak daha büyük kulaklara sahip olduğu çeşitli araştırmalarda tespit edilmiştir (Jung ve Jung, 2003; Yoon ve Jung, 2002). Bir insanın kulağı anne karnındaki dördüncü ayda nihai şeklini alır (Iannarelli, 1964) ve bir yaşına gelince yetişkin bir kişinin %76,4 ölçülerine, beş yaşına gelince ise %86,6 ölçüsüne ulaşır (Farkas ve diğ., 1992). Erken çocukluk döneminde asıl büyümesini gerçekleştiren dış kulak sonrasında kademeli olarak büyür ve yaşlılık ile derinin elastik özelliğinin azalması sonucu lobu aşağı doğru uzaması sonucu dış kulak uzamış olur (Ahmed ve Omer, 2015). Bunun yanı sıra ırklar da dış kulağın şeklini ve boyutunu etkiler (Ban ve Jung, 2020; Lee ve diğ., 2018). Dış kulağın şekillerine göre gruplandırılmış hali aşağıdaki Şekil 1.3’te verilmiştir (Broer ve diğ., 2018; Krishan ve diğ., 2019). Bazı kulak şekilleri erkeklerde daha yaygın görülürken bazı kulak şekilleri ise kadınlarda daha yaygın görülebilmektedir (Rani ve diğ., 2020).



Şekil 1.3.:
Şekilleri göre dış kulak çeşitleri

1.2. Amaç ve nem

zellikle gvenlik personellerinin çeřitli uygulamalarla bireyleri tanımak iin gvenilir ve hızlı bir yntem arayışları her zaman olmuřtur. Geleneksel olarak kullanılan kimlik kartları ve parolalar birok sınırlılığa sahiptir. Bunların eksikliklerini gidermek iin parmak izi, yz, iris, el, ses veya davranışsal zellikleri tanıma alıřmaları vardır. Bu tr alıřmalar sonucu geliřtirilen otomatik sistemler kiřisel bir bilgisayarın aılmasından basit bir kapı sistemine ve hatta sınır gvenliklerine kadar yaygın olarak kullanılmaktadır. İnsan tanımda kullanılan yz, el, parmak izi gibi sistemlerde dvme, yara izi ya da bir kısmının grnmemesi kaynaklı nedenler tanımayı zorlařtırmaktadır. Bu nedenle de ek tanıma sistemlerine ihtiya her geen gn artmaktadır. Boy ve vcut řekli, yrme dinamięi bunlardan bazılarıdır. Kulak ise bireyler arasında boyut, renk ve doku olarak nemli lde farklılık gstermesi nedeniyle biyometrik tanıma sistemlerinde kullanılabilir (Ross ve Abaza, 2011). zellikle yz tanıma ile birlikte kulak tanımının da kullanılarak yapılan oklu model tanımının daha yksek sonulara ulařıldığını gstermiřtir (Chang ve dię., 2003). El yordamı ile zellik ıkararak kulak tanıma alıřmaları (Chorař, 2008; Naseem ve dię., 2008) varsa da makine ęrenmesi yntemleri ile yapılan alıřmalarda daha yksek bařarılar elde edilmiřtir (Alshazly ve dię., 2019). Bu amala yola ıkılan bu alıřmada kiřilerin kulak fotoęraflarından kiřinin kendisini, cinsiyetini ve yařını tahmin etmek iin fotoęraflar toplanmıřtır. Bunun iin fotoęraflardan znitelik ıkarma yntemi uygulanıp sonrasında sınıflandırma iřlemi yapılmıřtır. Ayrıca bu alıřma ile literatre yeni bir veriseti kazandırmak da amalanmaktadır.

1.3. Yapılan alıřmalar

Kulağın dıř grnts üzerinden insanları tanıma ilk defa Alphonse Bertillon (1890) tarafından yapılmıřtır. Bu alıřma Alfred Lannarelli tarafından test edilmiř ve doęrulanmıřtır (Lannarelli, 1989). Fakat kulağı sekiz paraya ayırıp 12 lme teknięi kullanmıř olan bu yntem anatomik noktadaki lokalizasyon nedeniyle uygun deęildir. Burge ve Burger (2000), kulak grntlerindeki, eęri segmentlerinin Voronoi diyagramı kullanılarak oluřturulabilecek bir kořuluk grafięi olarak modellenebileceğini ne srd. Kulak tanımda sadece pasif tanımlama iin uygun olan grafik eřleřtirme algoritması nerilmiřtir. Lu ve ark. (2006) tarafından kulağın řeklini ve lokal grnmn istatistiksel olarak modellemek iin aktif řekil modelleri uygulanmıřtır. Attalla ve ark. da hah Alam'daki Malezya poplasyonunda dıř kulak ve kulak memesinin morfometrik ve biyometrik zelliklerindeki yař, ırk ve cinsiyete gre istatistiksel olarak ayırt etmeye alıřmıřtır (Hussain ve dię., 2020). Kulak grntsnn benzersiz olmasının yanı sıra deęiřmez olması da kiři tanımlamada kullanılması iin byk bir avantaj saęlamaktadır. Kulak grntlerinin sınıflandırılması zerine farklı alıřmalar yapılmıř olması nedeniyle literatrde bu konuda verisetleri oluřturulmuřtur. Tariq ve Akram (2012) tarafından USTB kulak grnt veritabanı ve IIT Delhi kulak grnt veritabanı kullanılarak sınıflandırma yapılmaya alıřılmıřtır. Bunun iin ncelikle grntlerden kontrast artırımı ve boyut normalizasyonu yapılmıř ve ardından Haar dalgacıkları ıkarılmıřtır. Son olarak ise normalleřtirilmiř apraz korelasyon ile kulak tanıma yapılmıřtır. %97,2 oranında sınıflandırma bařarısı elde etmiřlerdir. Yine IIT Delhi veritabanı zerindeki 100 kiřiye ait 500 grnt zerinde yapılan bir bařka kulak sınıflandırmada ise %94 doęruluk oranı elde edilmiřtir (Benzaoui ve dię., 2015). Omara ve ark. (2016) da USTB alt kmelerinden birincisinde ve IIT Delhi veritabanı zerinde alıřma yrtmř ve %99,6 oranında sınıflandırma bařarısı elde etmiřlerdir. Benzaoui ve ark. (2016) ise yerel doku tanımlayıcısı adlı yntem ile znitelik ıkarımı yapmıř (local texture descriptor) ve destek vektr makineleri ile sınıflandırma yaparak %97,31 oranında sınıflandırma bařarısı elde etmiřlerdir.

Fahmi ve ark. (2012) tarafından bir arama sırasında akıllı telefon kamerası kullanılarak ekilen kulak grnts yerel ikili model (local binary pattern – LBP) kullanılarak kimlik doęrulaması yapılmıřtır. %92,5 oranında bařarılı sınıflandırma elde edilmiřtir. Othman, Alizadeh ve Sutherland (2018) ise yz grntlerinden Haar benzeri zellikleri kullanarak kulak algılama yapıp ardından řekil Baęlam tanımlayıcı (Shape Context descriptor) ile znitelik ıkarımı yapmıřtır. Kulağın hem sa hem de kpe tarafından kapatıldığı grntlerde doęruluk %57 iken, tıkalı olmayan grntlerde %100 tanıma elde edilmiřtir (Othman ve dię., 2018). Alshazly ve ark. (2021) ise AMI, AMIC, WPUT ve AWE kulak veritabanlarından kısıtlı ve kısıtsız grntleme kořulları altında elde edilen kulak

görüntülerini kullanarak belirli görsel tanıma görevlerinde önceden eğitilmiş modeller kullanmışlardır. ResNet modeli olarak bilinen bu yöntemdeki ağ değerleri kullanılarak destek vektör makineleri (SVM) ile sınıflandırma işlemi yapılmıştır. En iyi performans, AMI, AMIC, WPUT ve AWE veritabanlarında sırasıyla %99,64, %98,57, %81,89 ve %67,25 olarak elde edilmiştir. Sibai ve ark. (2013) ise yedi kulak özelliği belirleyerek ileri beslemeli yapay sinir ağını eğitmişlerdir. 51 kişiye ait sağ kulak görüntüleri üzerinde yapılan bu çalışma farklı katman sayısı, katman başına nöron sayısı ve gürültü eklenip eklenmediği gibi çeşitli eğitim ve test seti boyutları ve çeşitli ağ konfigürasyonları ile denenmiştir. Böylece en yüksek doğruluk oranı olarak %95 elde edilmiştir. Sajadi ve Fathi (2020) ise global öznitelik çıkarımı için Gabor-Zernike operatörü (Gabor-Zernike operator) ve yerel özellik çıkarımı için yerel faz niceleme (LPQ) yöntemini kullanmışlardır. Global ve yerel özellikler daha sonra optimum özellik kombinasyonunu bulmak için genetik bir algoritma kullanılarak birleştirilmiştir. Canberra mesafesi ile en yakın komşu sınıflandırıcısı kullanılarak USTB, IIT Delhi-1 ve IIT Delhi-2 ve veritabanları da test edilmiştir. Sırasıyla %100, %99,2 ve %97,13 oranında doğruluk elde edilmiştir. Yaman ve ark. (2018) da 270 kulak görüntüsünden yaş ve cinsiyet tanıma çalışması yapmıştır. AlexNet, VGG-16, GoogLeNet ve SqueezeNet gibi önceden eğitilmiş ağları ile öznitelikler üretilmiş ve cinsiyet sınıflandırmasında %94, yaş sınıflandırmasında ise %52 doğruluk elde edilmiştir. Yan ve Bowyer (2005) tarafından ise kulak deliği ölçümleri için referans noktası olarak kullanılır. Maskeli kulak görüntülerinden tespit edilen kulak deliği ile kulağın yedi özelliği arasındaki Öklid mesafeleri hesaplanır. Deneyler için 342 örnek içeren dahili bir veri tabanı kullanmışlardır. Bayes sınıflandırıcı, KNN sınıflandırıcı ve sinir ağları ile yapılan testlerden en iyi performans %90,42 sınıflandırma doğruluğu ile KNN ile elde edilmiştir. Alkababji ve Mohammed (2021) tarafından kulak algılama için daha hızlı bölge tabanlı evrişimli sinir ağları (Faster R-CNN) adlı yöntem kullanılmıştır. Özellik çıkarımı için ise evrişimsel sinir ağı (CNN) kullanılmış ve %97,8 oranında başarı elde edilmiştir.


Abaza ve ark. (2010) kulak biyometrisine dayalı gerçek zamanlı görüntü bölütlemesi problemini araştırmışlardır. Haar ile üretilen öznitelikler Adaboost ile sınıflandırılmıştır. Yaklaşık 460 kişilik veri seti ile 80 kat daha hızlı eğitim performansı ve yaklaşık % 95 doğruluk elde etmişlerdir. Priyadharshini ve ark. (2020) kulak tanıma için altı katmanlı derin evrişimli sinir ağı (CNN) mimarisi ile IIT Delhi-1 ve AMI veritabanlarındaki görseller için sırasıyla %97,36 ve %96,99 doğruluk elde etmişlerdir. Kumar ve Wu (2012) ise yeni bir öznitelik çıkarma yaklaşımı ile 125 ve 221 denekten oluşan bir veriseti için sırasıyla %96,27 ve %95,93 doğruluk elde etmişlerdir. Said ve ark. (2008) da 3750 yüz görüntüsünden kulak tespiti ve kulak tanıma çalışması yapıp %90 üzerinde doğruluk elde etmişlerdir. Yuan ve Mu (2014) kulak tanıma için öncelikle karmaşık arka plandan Adaboost algoritması ile kulak algılama işlemi yapıp sonrasında farklı birçok yöntem ile öznitelik çıkarımı yapılmış ve USTB ile UND veritabanlarında test edilmiştir. Sonuçlar sırasıyla %96,46 ve %94 olarak elde edilmiştir. Said ve ark. (2008) tarafından da yine yerel ikili model (LBP) ile öznitelik çıkarımı USTB veritabanında uygulanmış ve %94,34 başarı oranı elde edilmiştir. Sharm ve ark. (2019) ise kulak görüntülerini öncelikle 128x256 boyutlarına getirip gri tonlamalı yapmış ve Ayrık Dalgacık Dönüşümü ile %86 doğruluk elde etmişlerdir. Chen ve ark. (2015) ise 415 kişiye ait UND veritabanındaki iki boyutlu ve üç boyutlu kulak görüntülerinden %96,4 başarılı sınıflandırma elde etmişlerdir. Mayya ve Sai (2016) ise 12-60 yaş aralığındaki 55 kişiye ait 460 yan yüz görüntüsünden kulak tespiti yapıp hibrit PCA_Wavelet algoritması ile öznitelik çıkarmıştır. Ardından birçok farklı sınıflandırma yöntemi ile yapılan testler sonucu en yüksek %98,9 oranında başarı oranı elde etmişlerdir. Tian, Wang ve Li (2018) ise derin evrişimli sinir ağı ile %98,56 başarı oranına ulaşmıştır. Mangayarkarasi, Raghuraman ve Nasreen (2019) de toplamış oldukları 545 kulak görüntüsü üzerinde kulak görüntüsü bölümlenerek özellik eşleştirme teknikleri ile %89 tanıma başarısına ulaşmışlardır. Jiddah ve Yurtkan (2018) da AMI kulak veritabanı üzerinde yerel ikili desen (LBP) ve laplacian filtresi kullanarak %80 doğruluk oranı elde etmiştir.

2. MATERYAL VE METOT

2.1. Verilerin Toplanması

100 kişiye ait kulak görüntüleri bu çalışmada toplanmıştır. Fotoğraf çekimi öncesinde görüntüsü alınacak kişilere yapılacak bilimsel çalışma kısa bir bilgilendirme yapılmıştır. Çalışmaya katılım

göstermek istemeyenlerden fotoğraf çekimi yapılmamıştır. Fotoğraflarda yüzünün belirli olmayacağını öğrenen kişiler çoğunlukla çalışmaya katılma konusunda gönüllü olmuşlardır. Xiaomi Poco F2 PRO telefonu 8 GB işlemci ve 2+13+5+64 mega piksel kamera kullanarak görüntüler toplanmıştır. Fotoğraflar bizzat araştırmacı tarafından çekilmiştir. Çekim sırasında görüntünün net olmasına ve kulak görüntüsünün açıkla belli olmasına özen gösterilmiştir. Aşağıdaki şekilde bir kadın ve bir erkek için örnek kulak görüntüleri verilmiştir.

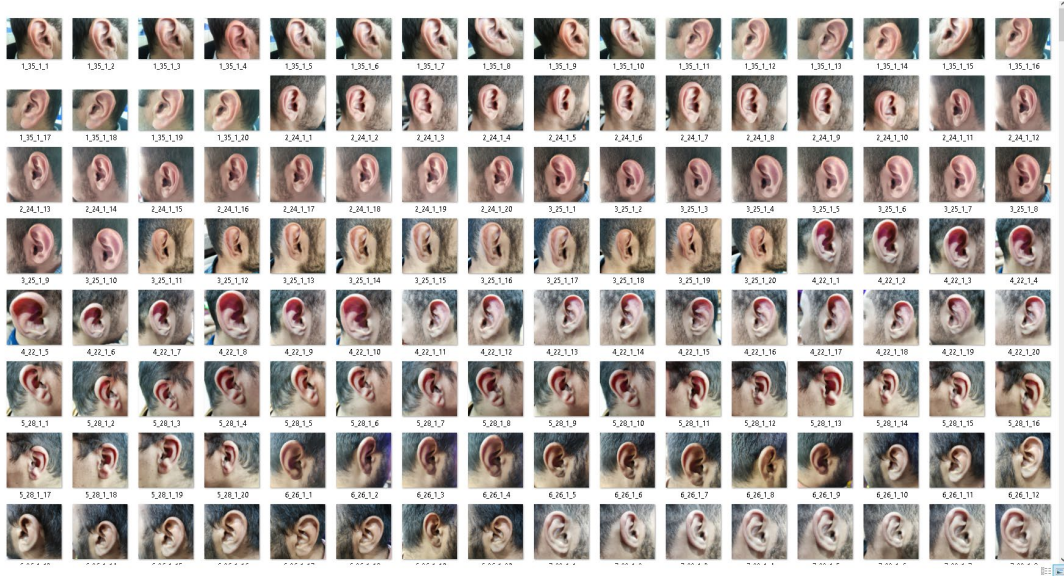


Şekil 2.1.:
Örnek kulak görüntüleri

Toplam 100 kişiden fotoğraf elde edilmiştir. Her kişinin sağ kulak görüntüsünden 10 tane ve sol kulak görüntüsünden 10 tane olmak üzere toplam 20 fotoğraf elde edilmiştir. Bu şekilde toplam 2000 fotoğrafın olduğu bir veritabanı oluşturulmuştur. Her bir fotoğrafın farklı açılardan çekilmesine özen gösterilmiştir. Kişilerden yalnızca cinsiyet ve yaş bilgileri istenmiş bunun dışında onları tanımlayacak hiçbir veri istenmemiştir. Her bir fotoğrafın bir başka fotoğraf ile karışmaması için kişiyi, yaşını, cinsiyetini ve çekilen fotoğraf numarasını ifade edecek şekilde bir isimlendirme kuralı geliştirilmiştir. Her bir ifade arasına alt çizgi (“_”) karakteri eklenmiştir. İsimlendirme kuralında kullanılan her bir ifade sıralı olarak aşağıda verilmiştir.

- 1. Kişi ID:** Fotoğraf çekimi yapılan her bir kişi için tekil olan bir kod değeridir. Bu değer 1-100 arasında değişmektedir.
- 2. Yaş:** Kişinin kaç yaşında olduğunu ifade etmek için doğrudan yaşı sayı olarak yazılmıştır.
- 3. Cinsiyet ID:** Fotoğrafi çekilen kişi erkek ise 1 değeri ile kadın ise 2 değeri ifade edilmiştir.
- 4. Fotoğraf ID:** Her kişiye ait birden fazla fotoğraf çekimi yapılmış olması nedeniyle her fotoğraf 1-20 arasında sıralı bir şekilde numaralandırılmıştır.

Yukarıda sayılan kurallar ile dosyaların isimlendirilmesi fotoğrafların çekilmesi sonrasında karışıklıkları önlemesinin yanı sıra analizlerin yapılmasında da kolaylıklar sağlamıştır. Aşağıdaki şekilde görüntü dosyalarının bir kısmı klasör içinde verilmiştir.



Şekil 2.2.:
Fotoğraf dosyalarının klasör içindeki görüntüsü

Çalışma içerisinde elde edilen bu fotoğraflardan oluşan veriseti herkesin kullanımına açık olması ve ücretsiz olarak indirilebilmesi için Kaggle veriseti deposuna yüklenmiştir.

www.kaggle.com/dataset/1c62e5e9afa2ab68495f097e6c517969c57dc0cf80067e4e15a18b25be2f2bc4 adresinde kullanıma açılan bu veriseti aynı zamanda farklı araştırmacılar tarafından yeni çalışmalarda kullanılabilir olacaktır.

2.2. Verilerin Analizi

Toplanan veriler öncelikle basit istatistiksel analizler ile incelenmiştir. Bunun için Python programı aracılığıyla tüm dosya adları elde edilmiş ve dosya adlarında alt çizgi karakteri ile ayrılan bölümler parçalanmıştır. Veriler analiz edilirken Windows işletim sistemine sahip 16 GB RAM ve Intel (R) Core (TM) i5-1035G1 CPU, 3.70 GHz işlemcili bir bilgisayar kullanılmıştır. Verilerin cinsiyet, yaş ve kişilere göre dağılımları basit istatistiksel bulgular olarak analiz edilmiş ve verilerde yığılma olup olmadığı tespit edilmiştir. Sonrasında her bir görüntüden öznitelik çıkarımı için yerel üçlü model (Local Ternary Pattern-LTP) kullanılmıştır. Böylece her bir görüntü dosyası için 1x512 boyutlarında vektör üretilmiştir. Bu işlem tüm dosyalar için yapılmıştır. İlk olarak ayak görüntülerinden kişileri tanımlamak için bu dosyalarda sınıflandırma etiketi olarak kişi ID değerleri yazılmıştır. Ardından bir başka öznitelik dosyası daha oluşturulup sınıf etiketi olarak cinsiyet ve bir başka dosya daha oluşturularak sınıf etiketi olarak yaş yazılmıştır. Böylece üç farklı öznitelik dosyası elde edilmiştir. Veriler 10 katlı çapraz doğrulama yöntemi kullanılarak eğitim ve test olarak ayrıştırılmıştır. Ardından bu öznitelik dosyaları Python programı içerisindeki 29 farklı sınıflandırma algoritması ile test edilmiştir. En yüksek sınıflandırma başarısı elde edilmeye çalışılmıştır. Sınıflandırma işlemleri için yalnızca bir kere öğrenme ve test işlemi yapılmıştır. Daha yüksek başarı oranı elde etmek için tekrar tekrar denemeler yapılmamıştır. Bulgular başlığında her bir sınıflandırma algoritması ve elde edilen başarı oranı verilmiştir. Kullanılan sınıflandırma algoritmaları aşağıda listelenmiştir.

- Tree
 - Fine Tree
 - Medium Tree
 - Coarse Tree
- Linear Discriminant
 - Linear Discriminant
- Quadratic Discriminant
 - Quadratic Discriminant
- Naive Bayes
 - Gaussian Naive Bayes
 - Kernel Naive Bayes
- SVM
 - Linear SVM
 - Quadratic SVM
 - Cubic SVM
 - Fine Gaussian SVM
 - Medium Gaussian SVM
 - Coarse Gaussian SVM
- KNN
 - Fine KNN
 - Medium KNN
 - Coarse KNN
 - Cosine KNN
 - Cubic KNN
 - Weighted KNN
- Ensemble
 - Boosted Trees
 - Bagged Trees
 - Subspace Discriminant
 - Subspace KNN
 - RUSBoosted Trees
- Neural Network
 - Narrow Neural Network
 - Medium Neural Network
 - Wide Neural Network
 - Bilayered Neural Network
 - Trilayered Neural Network

2.3. Yerel Üçlü Desen (Local Ternary Pattern-LTP)

Yerel ikili desen (local binary pattern-LBP), doku analizinde kullanılan popüler bir özelliktir ve nesne izleme, görüntü sınıflandırma, yüz tanıma gibi çok çeşitli uygulamalarda kullanılır. LBP'den türetilmiş birçok farklı model tabanlı öznitelik çıkarma yöntemi vardır. Bu yöntem görüntüdeki her pikselin yerel çevresindeki yoğunluk dalgalanmalarını yakalar. Bir pikseli merkezi bir piksel olarak kabul eder ve 3x3 boyutlarındaki bir parçanın LBP değerlerini aşağıdaki gibi hesaplamak için komşularıyla karşılaştırma yapar.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (1)$$

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & \text{otherwise} \end{cases}$$

R = Yarıçap

P = Komşu piksel sayısı

g_p = Komşu piksel

g_c = Merkez piksel

Komşu pikselin p indeksi, merkez pikselin sağındaki piksel için $p = 1$ 'den başlayarak saat yönünün tersine 1'den 8'e yükselir. 3×3 komşuluk için LBP'nin hesaplanması aşağıdaki şekilde gösterilmektedir. Son olarak ise her bir LBP değerinin histogramı hesaplanır.

Piksel değeri			LPB			İkili ağırlıklar			LPB değeri		
17	25	78	0	0	1	8	4	2			
80	40	55	1	1	1	16		1		51	
60	8	12	1	0	0	32	64	128			


Şekil 2.3.:
LBP değerleri hesaplama

LBP yöntemi, yoğunluk farkını ikili değerler olan 1 ve 0 olarak kodlar. Yoğunluk farklarını kodlamak için 1, 0 ve -1 olarak üçlü değerler göz önüne alındığında, yerel üçlü desen (local ternary pattern-LTP) yöntemi ortaya çıkar (Tan ve Triggs, 2010). Yoğunluk değerlerini karşılaştırırken, üçlü değerleri atamak için bir eşik sabiti olan t değeri belirlenir. LTP değerinin hesaplanması aşağıdaki formül ile yapılabilir.

$$LTP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (2)$$

$$s(x) = \begin{cases} 1, & x \geq t, \\ 0, & -t < x < t, \\ -1, & x < -t \end{cases}$$

Bu üçlü desenler daha sonra 1 ve -1'e karşılık gelen iki ayrı ikili desene dönüştürülür (Agarwal ve diğ., 2019). Ardından tıpkı LBP yönteminde olduğu gibi bu değerlerin histogramı çıkartılır. Aşağıdaki şekilde bu işlemler görsel olarak anlatılmıştır.



Şekil 2.4.:
Görüntüden öznitelik çıkarımı

2.4. Başarı Ölçütleri

Bir sınıflandırma modelinin performansını tanımlayan en iyi tablo karışıklık matrisidir. Bu tablo sınıflandırma modelinin gerçek ve tahmin değerleri hakkında bilgi verir ve performansı

değerlendirmek için kullanılır. Eğer cinsiyet sınıflandırması yapılan ve iki sınıftan oluşan bir veri seti tahmin edilmeye çalışılıyor ise aşağıdaki gibi bir tablo ortaya çıkacaktır.

Tablo 2.1. Örnek karışıklık matrisi

		Tahmin	
		Kadın	Erkek
Gerçek	Kadın	a (TN)	b (FP)
	Erkek	c (FN)	d (TP)

Yukarıdaki örnek karışıklık matrisinde verilen a, b, c, d sayıları kavram olarak incelenecek olursa aşağıdaki gibi ifade edilebilir.

- **Gerçek Pozitifler (TP):** Bunlar kadın olarak tahmin edilen ve gerçek cinsiyetleri de kadın olan yani doğru tahmin edilen değerlerdir.
- **Gerçek Negatifler (TN):** Bunlar erkek olarak tahmin edilen ve gerçek cinsiyetleri de erkek olan yani doğru tahmin edilen değerlerdir.
- **Yanlış Pozitifler (FP):** Bunlar erkek olarak tahmin edilen fakat gerçek cinsiyetleri kadın olan yani yanlış tahmin edilen değerlerdir. Tip I hatası olarak da bilinir.
- **Yanlış Negatifler (FN):** Bunlar kadın olarak tahmin edilen fakat gerçek cinsiyetleri erkek olan yani yanlış tahmin edilen değerlerdir. Tip II hatası olarak da bilinir.

Yukarıda ifade edilen değerlerin iyi anlaşılması sonrası bu değerlerin kullanılması ile bir sınıflandırıcının başarısının ölçülmesinde başka ölçütler de kullanılmaktadır. Bunlar aşağıda verilmiştir.

- **Doğruluk:** Genel olarak sınıflandırıcının ne sıklıkta doğru tahmin ürettiğini gösterir.

$$\frac{TP+TN}{TP+FP+FN+TN} \quad (3)$$

- **Yanlış Sınıflandırma Oranı:** Genel olarak sınıflandırıcının ne sıklıkta yanlış tahmin ürettiğini gösterir. Hata oranı olarak da bilinir ve 1 sayısından doğruluk değerinin çıkarılması ile de bulunabilir.

$$\frac{FP+FN}{TP+FP+FN+TN} \quad (4)$$

- **Gerçek Pozitif Oranı (Sensitivity/Recall):** Gerçek değeri evet iken ne kadar evet tahmin edildiğini gösterir. Hassasiyet (Sensitivity) ya da hatırlatma (Recall) olarak da bilinir.

$$\frac{TP}{TP+FN} \quad (5)$$

- **Yanlış Pozitif Oranı:** Gerçek değeri hayır iken ne kadar evet tahmin edildiğini gösterir.

$$\frac{FP}{FP+TN} \quad (6)$$

- **Gerçek Negatif Oranı:** Gerçek değeri hayır iken ne kadar hayır tahmin edildiğini gösterir. Özgüllük (Specificity) olarak da bilinir.

$$\frac{TN}{TN+FP} \quad (7)$$

- **Yanlış Negatif Oranı:** Gerçek değeri evet iken ne kadar hayır tahmin edildiğini gösterir.

$$\frac{FN}{FN+TP} \quad (8)$$

- **Kesinlik (Precision):** Evet tahminlerinin ne kadar doğru olduğunu gösterir.

$$\frac{a+d}{a+b+c+d} \quad (9)$$

- **Yaygınlık:** Evet koşulunun gerçek sıklığını gösterir.


- **F Skoru:** Gerçek Pozitif Oranın ve Kesinlik değerinin ağırlıklı ortalamasıdır.

$$2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (10)$$

3. BULGULAR

3.1. Verilere Genel Bir Bakıř

Dosya adları Python programı aracılıęıyla ncelikle bir dosyaya yazılmıř ve alt izgi karakterine gre paralanarak analiz yapılmıřtır. Cinsiyet deęerlerine gre yapılan basit bir analizde verilerin byk oęunluęunun erkeklerden oluřtuęu grlmřtir. 100 kiřiden 90 tanesi erkek ve 10 tanesi kadınlara ait verilerdir. Verilerin cinsiyete gre daęılımı yzdesel olarak ařaęıdaki grafikte gsterilmiřtir.



■ Erkek ■ Kadın

řekil 3.1.:


Verilerin cinsiyete gre yzdesel daęılımı

Verilerin yařlara gre daęılımı incelendięinde ise 2-55 yař arası farklılık gsterdięi grlmektedir. Bu kiřiler ise oęunlukla 11-30 yař aralıęındadır. Yařların beřerli olarak gruplanmıř haline ait kiři sayıları ařaęıdaki tabloda gsterilmiřtir. 0-10 ile 31-55 yař arası kiři sayısı daha az olduęu grlmektedir.

Tablo 3.1. Yař aralıklarına gre kiři sayıları

Yař Aralıęı	Kiři Sayısı
0-5	7
6-10	7
11-15	11
16-20	21
21-25	22
26-30	19
31-35	7
36-40	3
41-45	0
46-50	2
51-55	1
Toplam	100

Her bir yařtan ka kiři olduęu ise ařaęıdaki grafikte gruplanmadan gsterilmiřtir. Genlerin bilimsel alıřmalara katılma isteklilięinin daha fazla oluřu belirli bir yař grubundan daha ok kiřinin oluřmasına neden olduęu dřnlmektedir.



Şekil 3.2.:
Yaşlara göre kişi sayıları

3.2. Kişi Sınıflandırma Bulguları

100 kişinin her birine ait 20 görüntüden toplam 2000 görüntü dosyası vardır. Tüm bu görüntülerin yerel üçlü desen (LTP) algoritması ile öznitelikleri çıkarılmıştır. Bu öznitelik dosyaları üzerinden görüntünün kime ait olduğunu belirlemek için sınıflandırma algoritmaları kullanılmıştır. Sınıflandırma algoritmalarına ait doğruluk oranları ve gruplanmış halleri aşağıdaki tabloda verilmiştir. En yüksek doğruluk oranı Matlab programı içerisinde Ensemble grubu altında yer alan Subspace Discriminant algoritması ile %90,3 oranında elde edilmiştir. Burada bazı algoritmalar yüksek doğruluk oranı gösterirken bazı algoritmalar düşük doğruluk oranı göstermiştir. Bir kısım algoritmalar sonuç üretmemiş olması nedeniyle kişi tanıma için toplam 26 algoritma kullanılabilmiştir. Algoritmalar her denemede farklı sonuçlar üretebilmekte olup bu sonuçlar kimi zaman daha yüksek kimi zaman daha düşük olabilmektedir. Fakat buradaki çalışmada her algoritma bir kez çalıştırılmıştır ve yalnızca varsayılan parametreler kullanılmıştır.


Tablo 3.2. Kişi sınıflandırma sonuçları

Algoritma Grubu	Algoritma Adı	Doğruluk Oranı (%)
Tree	Fine Tree	33,3
	Medium Tree	13,2
	Coarse Tree	4,9
Naive Bayes	Kernel Naive Bayes	67,3
SVM	Linear SVM	74,9
	Quadratic SVM	79,3
	Cubic SVM	79,7
	Fine Gaussian SVM	8,9
	Medium Gaussian SVM	79,5
	Coarse Gaussian SVM	45,9
KNN	Fine KNN	85,8
	Medium KNN	78
	Coarse KNN	27,9
	Cosine KNN	69,3
	Cubic KNN	76,2
	Weighted KNN	79,7
Ensemble	Boosted Trees	22,5
	Bagged Trees	76
	Subspace Discriminant	90,3
	Subspace KNN	83,5
	RUSBoosted Trees	12,7
Neural Network	Narrow Neural Network	57,2
	Medium Neural Network	80
	Wide Neural Network	85
	Bilayered Neural Network	46,3
	Trilayered Neural Network	36

Kişi sayısının 100 olması nedeniyle hata matrisi (confusion matrix) burada okunaklı olamayacağı için gösterilememiştir. Fakat 2000 örnekleme içinden yalnızca 194 tanesi yanlış sınıflandırılmıştır. Geri kalan 1804 tanesi doğru sınıflandırılmıştır.

3.3. Cinsiyet Sınıflandırma Bulguları

Kulak görüntüleri üzerinden cinsiyetin erkek ya da kadın olduğunu belirlemek için 27 farklı algoritma kullanılmış ve en yüksek doğruluk oranı KNN grubu altındaki Fine KNN yöntemi ile %99,8 oranında elde edilmiştir. Bu yöntemin ürettiği hata matrisi aşağıdaki şekilde verilmiştir. Toplam 200 kadın verisinden yalnızca 3 tanesi yanlış olarak erkek sınıfında tahmin edilirken 1800 erkek verisinden yalnızca 2 tanesi kadın yanlış olarak kadın sınıfında tahmin edilmiştir.

**Şekil 3.3.:***Cinsiyet sınıflandırması hata matrisi*

Tüm algoritmaların sonucu aşağıdaki Tablo 3.3'te verilmiştir. Tablodaki değerler incelendiğinde birçok algoritmanın %90 üzerinde ve hatta %99 civarında bir sonuç verdiği görülecektir. En yüksek algoritma sarı renkle tabloda işaretlenmiştir. En düşük sonucu Kernel Naive Bayes algoritması %72,7 ile bulmuştur. Bu değere en yakın sonuç üreten sınıflandırma algoritması ise Fine Gaussian SVM algoritması olup %90,1 sonuç üretmiştir.

Tablo 3.3. Cinsiyet sınıflandırma sonuçları

Algoritma Grubu	Algoritma Adı	Doğruluk Oranı (%)
Tree	Fine Tree	94,9
	Medium Tree	95
	Coarse Tree	93
Logistic Regression	Logistic Regression	97,5
Naive Bayes	Kernel Naive Bayes	72,7
SVM	Linear SVM	97,9
	Quadratic SVM	99,5
	Cubic SVM	99,5
	Fine Gaussian SVM	90,1
	Medium Gaussian SVM	99
	Coarse Gaussian SVM	95,1
KNN	Fine KNN	99,8
	Medium KNN	99
	Coarse KNN	92,3
	Cosine KNN	98,4
	Cubic KNN	99
	Weighted KNN	99,3
Ensemble	Boosted Trees	97
	Bagged Trees	96,9
	Subspace Discriminant	97,9

	Subspace KNN	99,5
	RUSBoosted Trees	97,3
Neural Network	Narrow Neural Network	99
	Medium Neural Network	99
	Wide Neural Network	99,2
	Bilayered Neural Network	99,1
	Trilayered Neural Network	98,9

3.4. Yař Sınıflandırma Bulguları

Kiřilerin yařları 32 farklı değere sahiptir. Bunlar daha önceki başlıklarda verildiđi üzere 2-55 aralıđında farklı sayılardadır. Yař dađılımları birbirine yakın sayılarda olmamasına rađmen Matlab sınıflandırma algoritmalarından KNN grubu altındaki Fine KNN algoritması %86,1 oranında başarılı tahmin üretmiřtir. Bařka sınıflandırma algoritmalarından bu değere yakın bařarı gösterenler de olmuřtur. Toplam 26 farklı algoritmanın ürettiđi sonuçlar ařađdaki tabloda verilmiřtir.

Tablo 3.4. Yař sınıflandırma sonuçları

Algoritma Grubu	Algoritma Adı	Dođruluk Oranı (%)
Tree	Fine Tree	34,9
	Medium Tree	21,5
	Coarse Tree	13,8
Naive Bayes	Kernel Naive Bayes	33,3
SVM	Linear SVM	51,5
	Quadratic SVM	79,1
	Cubic SVM	79
	Fine Gaussian SVM	13,3
	Medium Gaussian SVM	55,5
	Coarse Gaussian SVM	19,9
KNN	Fine KNN	86,1
	Medium KNN	75,3
	Coarse KNN	28,5
	Cosine KNN	69,7
	Cubic KNN	75,3
	Weighted KNN	79,5
Ensemble	Boosted Trees	29,2
	Bagged Trees	72
	Subspace Discriminant	64,8
	Subspace KNN	83,5
	RUSBoosted Trees	24,1
Neural Network	Narrow Neural Network	42,3
	Medium Neural Network	68,6
	Wide Neural Network	79,9
	Bilayered Neural Network	39,3
	Trilayered Neural Network	34,4

32 farklı değer hata matrisi içerisindeki sayılarının okunamayacağı nedeniyle gösterilememiştir. 2000 örneklemden toplam 278 tanesi yanlış sınıflandırılmış ve geriye kalan 1722 tanesi doğru sınıflandırılmıştır.

4. TARTIŞMA VE SONUÇ

Bu çalışmada kişilerin kulak görüntülerinden kim olduğunu, kaç yaşında olduğunu ve hangi cinsiyette olduğunu belirlemek amaçlanmıştır. Bunun için 100 farklı kişiden her bir kulağına ait 10 görüntü içeren toplam 2000 adet görüntü toplanmıştır. Bu görüntülerin yerel üçlü desen (LTP) yöntemi ile öznelikleri çıkarılmış ve Matlab programı içerisindeki birçok farklı algoritma ile sınıflandırma işlemi yapılmıştır. Kişi tanıma için %90,3 oranında doğruluk oranı elde edilirken, cinsiyet için %99,8 oranında başarı elde edilmiştir. Son olarak yaş için ise %86,1 oranında sınıflandırma başarısına ulaşılmıştır. Tüm bu sonuçlar buradaki yöntem ile kulak görüntülerinden kişi, yaş ve cinsiyet tanıma yapmanın yüksek başarı ile mümkün olduğunu göstermektedir. Aşağıdaki tabloda farklı yazarlar tarafından kulak görüntüleri üzerinde yapılan çalışmalar ve sonuçları verilmiştir. Burada bulunan sonuçlar bazı yazarların çalışmasından daha yüksek iken bazı yazarların çalışmasından daha düşük sonuçlardır. Bunun başlıca nedenler arasında kullanılan veriseti, öznelik çıkarma yöntemi ve sınıflandırma algoritmasındaki farklılıklar gelmektedir.

Tablo 4.1. Kulak görüntüleri üzerine yapılan farklı çalışmalar ve sonuçları

Yazar	Yöntem	Veriseti	Doğruluk Oranı (%)
(Fahmi ve diğ., 2012)	Yerel ikili desen (LBP)	Özel veriseti	92,5
(Othman ve diğ., 2018)	Şekil Bağlam tanımlayıcı (Shape Context descriptor)	Özel veriseti	100
(Alshazly ve diğ., 2021)	ResNet, SVM	AMI	99,64
(Alshazly ve diğ., 2021)	ResNet, SVM	AMIC	98,57
(Alshazly ve diğ., 2021)	ResNet, SVM	WPUT	81,89
(Alshazly ve diğ., 2021)	ResNet, SVM	AWE	67,25
(Sajadi ve Fathi, 2020)	Yerel faz niceleme (LPQ)	USTB	100
(Sajadi ve Fathi, 2020)	Yerel faz niceleme (LPQ)	IIT Delhi-1	99,2
(Sajadi ve Fathi, 2020)	Yerel faz niceleme (LPQ)	IIT Delhi-2	97,13
(Yaman ve diğ., 2018)	AlexNet, VGG-16, GoogLeNet ve SqueezeNet	Özel Veriseti	Cinsiyet:94 Yaş: 52
(Yan ve Bowyer, 2005)	Öklid mesafeleri hesaplama	Özel Veriseti	90,42
(Alkababji ve Mohammed, 2021)	Daha hızlı bölge tabanlı evrişimli sinir ağları (Faster R-CNN)	Özel Veriseti	97,8

Buradaki söz konusu çalışma ile yüz tanıma çalışmalarının geliştirileceği düşünülmektedir. İleride yapılacak çalışmalarda kulak görüntülerinin yüzden ayrı değerlendirilmesi ile yüz tanıma doğruluğunun geliştirilmesinin mümkün olacağı düşünülmektedir. Yapılacak yeni çalışmalarda kulak görüntülerinin şapka, atkı ya da kulaklık nedeniyle tam görünmediği durumlar da dikkate alınarak yeni çalışmaların yapılması faydalı olacaktır.

ÇIKAR ÇATIŞMASI

Yazar(lar), bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar. Bu çalışma Kırşehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü İleri Teknolojiler Anabilim Dalında yüksek lisans tezi olarak sunulmuştur.

YAZAR KATKISI

Emrah Aydemir çalışmanın kavramsal ve tasarım süreçlerinin belirlenmesi ve yönetimi, Asaad Qais Shalal ABO SOOT veri toplama ve veri analizi

KAYNAKLAR

1. Abaza, A., Hebert, C., Harrison, M. A. F. (2010). Fast learning ear detection for real-time surveillance. 2010 Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS). doi:10.1109/BTAS.2010.5634486
2. Agarwal, M., Singhal, A., Lall, B. J. P. A., Applications. (2019). Multi-channel local ternary pattern for content-based image retrieval. 22(4), 1585-1596. doi:10.1007/s10044-019-00787-2
3. Ahmed, A. A. and Omer, N. (2015). Estimation of sex from the anthropometric ear measurements of a Sudanese population. *Legal Medicine*, 17(5), 313-319. doi:10.1016/j.legalmed.2015.03.002
4. Aishna Sharma, N. L., Mani Roja M. Edinburgh. (2019). Biometric Identification using Human Ear. *International Journal of Engineering and Advanced Technology (IJEAT)*, 9. doi:10.35940/ijeat.A2027.109119
5. Alkababji, A. M. and Mohammed, O. H. (2021). Real time ear recognition using deep learning. *Telkomnika*, 19(2), 523-530. doi:10.12928/telkomnika.v19i2.18322
6. Alshazly, H., Linse, C., Barth, E., Idris, S. A., Martinetz, T. (2021). Towards Explainable Ear Recognition Systems Using Deep Residual Networks. *IEEE Access*. doi:10.1109/ACCESS.2021.3109441
7. Alshazly, H., Linse, C., Barth, E., Martinetz, T. (2019). Handcrafted versus CNN features for ear recognition. *Symmetry*, 11(12), 1493. doi:10.3390/sym11121493
8. Ban, K. and Jung, E. S. (2020). Ear shape categorization for ergonomic product design. *International Journal of Industrial Ergonomics*, 102962. doi:10.1016/j.ergon.2020.102962
9. Benzaoui, A., Adjabi, I., Boukrouche, A. (2016). Person identification based on ear morphology. 2016 International Conference on Advanced Aspects of Software Engineering (ICAASE). doi:10.1109/ICAASE.2016.7843851
10. Benzaoui, A., Kheider, A., Boukrouche, A. (2015). Ear description and recognition using ELBP and wavelets. 2015 International Conference on Applied Research In Computer Science And Engineering (Icar). doi:10.1109/ARCSE.2015.7338146
11. Bertillon, A. (1890). *La photographie judiciaire: avec un appendice sur la classification et l'identification anthropométriques*. Paris: Gauthier-Villars.
12. Broer, P. N., Thiha, A., Ehrl, D., Sinno, S., Juran, S., Szpalski, C., Ng, R., Ninkovic, M., Prantl, L., Heidekrueger, P. I. (2018). The ideal ear position in Caucasian females. *Journal of Cranio-Maxillofacial Surgery*, 46(3), 485-491. doi:10.1016/j.jcms.2017.12.017
13. Burge, M. and Burger, W. (2000). Ear biometrics in computer vision. Proceedings 15th International Conference on Pattern Recognition. ICPR-2000. doi:10.1109/ICPR.2000.906202

14. Chang, K., Bowyer, K. W., Sarkar, S., Victor, B. (2003). Comparison and combination of ear and face images in appearance-based biometrics. *IEEE transactions on pattern analysis and machine intelligence*, 25(9), 1160-1165. doi:10.1109/TPAMI.2003.1227990
15. Chen, L., Mu, Z., Zhang, B., Zhang, Y. (2015). Ear recognition from one sample per person. *PloS one*, 10(5), e0129505. doi:10.1371/journal.pone.0129505
16. Choraś, M. (2008). Perspective methods of human identification: ear biometrics. *Opto-electronics review*, 16(1), 85-96. doi:10.2478/s11772-007-0033-5
17. Fahmi, P. A., Kodirov, E., Choi, D.-J., Lee, G.-S., Azli, A. M. F., Sayeed, S. (2012). Implicit authentication based on ear shape biometrics using smartphone camera during a call. 2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC). doi:10.1109/ICSMC.2012.6378079
18. Farkas, L. G., Posnick, J. C., Hreczko, T. M. (1992). Anthropometric growth study of the head. *The Cleft Palate-Craniofacial Journal*, 29(4), 303-308. doi:10.1597/1545-1569_1992_029_0303_agsoth_2.3.co_2
19. Hassaballah, M., Alshazly, H. A., Ali, A. A. (2019). Ear recognition using local binary patterns: A comparative experimental study. *Expert Systems with Applications*, 118, 182-200. doi:10.1016/j.eswa.2018.10.007
20. Attalla, S. M., Kumar, K. A., Hussain, N. (2020). Study of the Ear Shape and the Lobule Attachment among the Adult Malaysian Population at Shah Alam. *European Journal of Molecular & Clinical Medicine*, 7(3), 5417-5425.
21. Iannarelli, A. V. (1964). *Ear identification*. Paramont Publishing Company.
22. Jain, A. K., Ross, A., Prabhakar, S. (2004). An introduction to biometric recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 4-20. doi:10.1109/TCSVT.2003.818349
23. Jiddah, S. M. and Yurtkan, K. (2018). Fusion of geometric and texture features for ear recognition. 2018 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT). doi:10.1109/ISMSIT.2018.8567044
24. Jung, H. S. and Jung, H. S. (2003). Surveying the dimensions and characteristics of Korean ears for the ergonomic design of ear-related products. *International journal of industrial ergonomics*, 31(6), 361-373. doi:10.1016/S0169-8141(02)00237-8
25. Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *Ijcai*,
26. Krishan, K., Kanchan, T., Thakur, S. (2019). A study of morphological variations of the human ear for its applications in personal identification. *Egyptian Journal of Forensic Sciences*, 9(1), 1-11. doi:10.1186/s41935-019-0111-0
27. Kumar, A. and Wu, C. (2012). Automated human identification using ear imaging. *Pattern Recognition*, 45(3), 956-968. doi:10.1016/j.patcog.2011.06.005
28. Iannarelli, A. (1989). *Ear Identification*. Paramount Publishing Company.
29. Larson, S. C. (1931). The shrinkage of the coefficient of multiple correlation. *Journal of Educational Psychology*, 22(1), 45. doi:10.1037/h0072400
30. Lee, W., Yang, X., Jung, H., Bok, I., Kim, C., Kwon, O., You, H. (2018). Anthropometric analysis of 3D ear scans of Koreans and Caucasians for ear product design. *Ergonomics*, 61(11), 1480-1495. doi:10.1080/00140139.2018.1493150

31. Lu, L., Zhang, X., Zhao, Y., Jia, Y. (2006). Ear recognition based on statistical shape model. First International Conference on Innovative Computing, Information and Control-Volume I (ICICIC'06). doi:10.1109/ICICIC.2006.445
32. Mangayarkarasi, N., Raghuraman, G., Nasreen, A. J. P. C. S. (2019). Contour Detection based Ear Recognition for Biometric Applications. *165*, 751-758. doi:10.1016/j.procs.2020.01.016
33. Mayya, A. M. and Saii, M. M. (2016). Human recognition based on ear shape images using PCA-Wavelets and different classification methods. *Medical Devices and Diagnostic Engineering*, *10*, 11-18. doi:10.15761/MDDE.1000103
34. Moreno, B., Sanchez, A., Vélez, J. F. (1999). On the use of outer ear images for personal identification in security applications. Proceedings IEEE 33rd Annual 1999 International Carnahan Conference on Security Technology (Cat. No. 99CH36303). doi:10.1109/CCST.1999.797956
35. Mosteller, F. and Wallace, D. L. (1963). Inference in an authorship problem: A comparative study of discrimination methods applied to the authorship of the disputed Federalist Papers. *Journal of the American Statistical Association*, *58*(302), 275-309. doi:10.1080/01621459.1963.10500849
36. Naseem, I., Togneri, R., Bennamoun, M. (2008). Sparse representation for ear biometrics. International Symposium on Visual Computing. doi:10.1007/978-3-540-89646-3_33
37. Omara, I., Li, F., Zhang, H., Zuo, W. (2016). A novel geometric feature extraction method for ear recognition. *Expert Systems with Applications*, *65*, 127-135. doi:10.1016/j.eswa.2016.08.035
38. Othman, R. N., Alizadeh, F., Sutherland, A. (2018). A novel approach for occluded ear recognition based on shape context. 2018 International Conference on Advanced Science and Engineering (ICOASE). doi:10.1109/ICOASE.2018.8548856
39. Priyadharshini, R. A., Arivazhagan, S., Arun, M. J. A. I. (2020). A deep learning approach for person identification using ear biometrics. 1-12. doi:10.1007/s10489-020-01995-8
40. Rahman, M., Islam, M. R., Bhuiyan, N. I., Ahmed, B., Islam, A. (2007). Person identification using ear biometrics. *International Journal of The Computer, the Internet and Management*, *15*(2), 1-8. doi:10.4038/sljip.v8i0.208
41. Rakshit, R. D., Nath, S. C., Kisku, D. R. (2018). Face identification using some novel local descriptors under the influence of facial complexities. *Expert Systems with Applications*, *92*, 82-94. doi:10.1016/j.eswa.2017.09.038
42. Rani, D., Krishan, K., Sahani, R., Baryah, N., Kanchan, T. (2020). Evaluation of Morphological Characteristics of the Human Ear in Young Adults. *Journal of Craniofacial Surgery*, *31*(6), 1692-1698. doi:10.1097/SCS.0000000000006394
43. Refaeilzadeh, P., Tang, L., Liu, H. (2009). Cross-Validation. In L. Liu & M. T. Özsu (Eds.), *Encyclopedia of Database Systems* (pp. 532-538). Springer US. doi:10.1007/978-0-387-39940-9_565
44. Ross, A. and Abaza, A. (2011). Human ear recognition. *Computer*, *44*(11), 79-81. doi:10.1109/MC.2011.344
45. Said, E. H., Abaza, A., Ammar, H. (2008). Ear segmentation in color facial images using mathematical morphology. 2008 Biometrics Symposium.

doi:10.1109/BSYM.2008.4655519

46. Sajadi, S. and Fathi, A. (2020). Genetic algorithm based local and global spectral features extraction for ear recognition. *Expert Systems with Applications*, 159, 113639. doi:10.1016/j.eswa.2020.113639
47. Sibai, F. N., Nuaimi, A., Maamari, A., Kuwair, R. (2013). Ear recognition with feed-forward artificial neural networks. *Neural Computing and Applications*, 23(5), 1265-1273. doi:10.1007/s00521-012-1068-1
48. Tan, X. and Triggs, B. (2010). Enhanced local texture feature sets for face recognition under difficult lighting conditions. *IEEE transactions on image processing*, 19(6), 1635-1650. doi:10.1109/TIP.2010.2042645
49. Tariq, A. and Akram, M. U. J. T. T. C. E. C. (2012). Personal identification using ear recognition. *10(2)*, 321-326. doi:10.12928/telkomnika.v10i2.801
50. Uddin, M. N., Sharmin, S., Ahmed, A., Hasan, E. (2011). A survey of biometrics security system. *IJCSNS*, 11(10), 16.
51. Yaman, D., Eyiokur, F. I., Sezgin, N., Ekenel, H. K. (2018). Age and gender classification from ear images. 2018 International Workshop on Biometrics and Forensics (IWBF). doi:10.1109/IWBF.2018.8401568
52. Yan, P., Bowyer, K. (2005). Empirical evaluation of advanced ear biometrics. 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)-Workshops. doi:10.1109/CVPR.2005.450
53. Ying, T., Shining, W., Wanxiang, L. (2018). Human ear recognition based on deep convolutional neural network. 2018 Chinese Control And Decision Conference (CCDC). doi:10.1109/CCDC.2018.8407424
54. Yoon, H.-Y. and Jung, S.-G. (2002). A study of measurement on the head and face for Korean adults. *IE interfaces*, 15(2), 199-208.
55. Yuan, L. and Mu, Z. (2014). Ear recognition based on Gabor features and KFDA. *The Scientific World Journal*, 2014. doi:10.1155/2014/702076

