

Cinsiyet Tanıma İçin Rastgele Karar Ormanlarına Dayalı Yüz Öznitelik Seçimi

Facial Feature Selection for Gender Recognition based on Random Decision Forests

Güney Kayım^{1,3}, Cihan Sari^{2,3}, Ceyhan Burak Akgül^{1,3}

Boğaziçi Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü¹, İstanbul
Boğaziçi Üniversitesi Sistem ve Kontrol Mühendisliği Bölümü², İstanbul
Vistek ISRA Vision³, İstanbul

(gkayim, csari, cbakgul)@vistek-isravision.com

ÖZETÇE

Bu çalışmada öncelikle, yaygın olarak kullanılan özniteliklerden Ayrık Kosinüs Dönüşüm katsayıları (DCT) ve Yerel İkili Örüntüler (LBP) kullanılarak Destek Vektörü Makinasına (SVM) dayalı standart bir sınıflandırıcının otomatik cinsiyet tanıma performansının gerçeğe uygun bir şekilde çıkarılması hedeflenmiştir. SVM sınıflandırıcısı, toplam 2720 örnekli FERET veri tabanında eğitilmiş ve çapraz geçirilmiş, test içinse 13000'den fazla örnek içeren LFW veri tabanı kullanılmıştır. FERET üzerinde %95'in olduğu görülen çapraz geçermeye dayalı performans kestirimini LFW üzerinde elde edilen %78'lik gerçek test performansıyla karşılaştırıldığında fazlasıyla iyimser olduğu gözlemlenmiştir. Çalışmamızda ek olarak, rastgele karar ormanları (RDF) ayrımsayıcı bir öznitelik seçim aracı olarak kullanılmış, bu sayede performans kaybına uğramadan hem öznitelik sayıları ciddi oranda düşürülmüş hem de cinsiyet tanımda etkili olan bölgesel yüz öznitelikleri ve bölgeleri belirlenmiştir.

ABSTRACT

In this work, we primarily aim at estimating the performance of SVM-based gender recognition using widely used DCT and LBP facial features, as faithful as possible. The SVM classifier has been trained and cross-validated on the FERET database containing 2720 instances, while for testing, the LFW database containing over 13000 instances has been used. We have observed that the over 95% cross-validation performance on FERET is overly optimistic as compared to the true test performance of %78 on LFW. Additionally, we have used random decision forests as a discriminative feature selection scheme and we have shown that similar performance can be maintained while reducing the original number of features significantly. As a by-product, the scheme can also be used to localize the most discriminative facial gender features.

¹Bu çalışma, Tübitak tarafından kısmen desteklenen 9090007 no'lu ViCoMo projesi kapsamında gerçekleştirilmiştir.

1. GİRİŞ

Yeni bir insanla tanışıldığında insanlar tarafından ilk fark edilen şey büyük olasılıkla karşısındakinin cinsiyetidir. Bir insan bu kararı çok kolay bir şekilde verebildiği halde, aynı iş yapay görme için oldukça zorlu bir görevdir [1]. Bu çalışmanın amacı, yapay görme teknikleri yardımıyla otomatik olarak cinsiyet tanımadır. Otomatik bir cinsiyet tanıma sisteminin insan-makina arayüzü, biyometrik, görsel içerikle arama, demografik bilgi toplama ve hedef odaklı pazarlama gibi alanlarda potansiyel uygulamaları bulunmaktadır [1].

Yüz bölgesinde gözlemlenen yüz ifadeleri, insanların cinsiyeti tanımasında belki en yaygın olarak kullandığı özelliklerdendir. Bu sebeple, pek çok araştırmacı, cinsiyeti belirlemek için yüz imgelerini kullanmıştır [2] [3] [4]. Gutta ve ark., FERET yüz veri tabanında etnik sınıflandırıcı ve poz sınıflandırıcı kullanmıştır [2]. Moghaddam ve ark. ise, doğrusal olmayan Destek Vektör Makineleri (SVM) aracılığıyla, yine FERET yüz veri tabanından imgelerin düşük çözünürlüklü hallerini kullanarak görünüme dayalı bir cinsiyet tanıyıcı geliştirmiştir [3]. Li ve ark.'ın çalışmasındaysa uzamsal Gauss karışım modelleri (SGMM) kullanılmıştır [4]. SGMM, Gauss karışım modellerinin (GMM) sahip olduğu tam görüntü açıklayıcılığıyla birlikte imgelerin yanlış hizalanmasına karşı dayanıklılık gibi avantajlara sahiptir.

Literatürde yüz özniteliklerinden cinsiyet tanımda farklı birçok öznitelik tipi ve birçok istatistiksel sınıflandırma yaklaşımı kullanılmış olmakla birlikte, geliştirilen yöntemlerin performansı çoğu zaman çapraz geçermeye ya da imgelem yöntemi ve ışıklandırma açısından eğitim kümesindeki çok benzeyen ancak birkaç yüz örneklili kısıtlı test kümeleri üzerinde belirlenmiştir [1]. Bu bağlamda raporlanan performanslar, gerçek dünyada çalışacak gerçek zamanlı sistemlerde karşılaşılan değerlere kıyasla oldukça iyimserdir. Bu çalışmada öncelikle, yaygın olarak kullanılan özniteliklerden Ayrık Kosinüs Dönüşüm katsayıları (DCT) ve Yerel İkili Örüntüler (LBP) kullanılarak Destek Vektörü Makinasına (SVM) dayalı standart bir sınıflandırıcının otomatik cinsiyet tanıma performansının gerçeğe uygun bir şekilde çıkarılması hedeflenmiştir. SVM sınıflandırıcısı, toplam 2720 örnekli FERET [5] veri ta-

banında eğitilmiş, test içinse 13000'den fazla örnek içeren LFW [6] veri tabanı kullanılmıştır. Bildiğimiz kadarıyla otomatik cinsiyet tanıma alanında hem test kümesinin eğitim kümesine kıyasla sayıca ve içerikçe zenginliği hem de farklı bir alandan elde edilmiş olması yönüyle burada sunulan çalışmaya benzer bir çalışma bulunmamaktadır. Çalışmamızda ek olarak, rastgele karar ormanları (RDF) ayrırımsayıcı bir öznelik seçim aracı olarak kullanılmış, bu sayede performans kaybına uğramadan hem öznelik sayıları ciddi oranda düşürülmüş hem de cinsiyet tanımda etkili olan bölgesel yüz öznitelikleri ve bölgeleri belirlenmiştir.

Bildiri şu şekilde düzenlenmiştir. Bölüm 2'de cinsiyet tanıma sistemi genel hatlarıyla anlatılmış ve öznelik çıkarımının gerçekleştirme detayları açıklanmıştır. Bölüm 3'te RDF ile yapılan öznelik seçimi anlatılmıştır. Deneyler ve sonuçları Bölüm 4'te bulunmaktadır. Son olarak bölüm 5'te vurgular sunulmuştur.

2. CİNSİYET TANIMA SİSTEMİ

2.1. Sistem Akışı

Öncelikle verilen ham imgeden Viola & Jones yöntemi ile yüz bölgesi tespit edilir. Çıkarılan bölge saç, çene, kulaklar ve benzeri kısımları içerdiği için bölge daraltılır. Yüz bölgesinde önışleme ve arkasından öznelik çıkarımları (DCT, LBP) uygulanır. Eğitim kümesinden çıkarılan özneliklerle Destek Vektör Makineleri (SVM) modeli eğitilir. Opsiyonlu olarak bu özneliklerden ayırım gücü yüksek olanlar RDF yardımıyla seçilebilir. Test kümesindeki örneklerde, bu model kullanılarak cinsiyet tahmini yapılır.

2.2. Önışleme

Öznelikler çıkarılmadan önce bazı önışleme adımlarının gerçekleştirilmesi gereklidir. Önışlemede, çok karanlık ya da aydınlık imgelerin veya farklı imge hizalamalarının ya da boyutlarının yaratabileceği performans kayıplarının bir ölçüde engellenmesi hedeflenir. Viola&Jones sezicisi tarafından bulunan yüz imgeleri sırasıyla şu işlemlere tabi tutulur.

- İmgenin sağ ve sol kenarlarından sütunlardan içeriye doğru %16'sı, üst kenarındaki satırlardan içeriye doğru %22'si atılır. Bu sayede ayrırımsayıcı olmayan, hatta sınıflandırıcıyı yanıltabilen saç ve kulak bölgeleri atılmış olur. Atılma miktarları, örnek bir küme üzerinde Viola&Jones yüz bulma sonuçlarının gözle değerlendirilmesiyle belirlenmiştir.
- İmge yüksekliğinin 12'de biri boyutta bir Gauss süzgeciyle yumuşatılır (bu değer deneme-yanılma yöntemiyle bulunmuştur),
- İmge 64x64 boyutuna getirilerek boyutsal olarak düzgelendir. 64x64 boyutunun saniyede 15-20 imge işleyebilen gerçek zamanlı bir sistem için ideal olduğu gözlemlenmiştir.
- Aydınlık farklarını dengelemek adına imgeye histogram eşitleme uygulanır.

2.3. Öznelik Çıkarımı

DCT öznelik çıkarımında öncelikle yüz imgeleri 8x8 bloklara bölünür, böylelikle her blok yüzün belli bir kısmını tanımlar. Sonrasında, her blokta DCT katsayıları hesaplanır. Sıfır frekanslı o blok için ortalama imgeyi temsil ettiği için atılır ve sonraki 5 katsayı alınır. Her blokta çıkarılan katsayılar ayrı ayrı düzgeleme uygulanır ve yüz imgesini ifade etmesi için yan yana eklenir. Son olarak, birleştirilmiş vektörde birim düzgeleme uygulanır ve 320 boyutlu DCT öznelik vektörü elde edilir.

LBP öznelik çıkarımında, yüz imgesinin üzerinde 3x3 boyutlarında bir pencere doluşturılır ve pencerenin merkezindeki piksele etrafındaki komşuların değerine göre ikili tabanda bir sayı etiket olarak atanır. Bu şekilde LBP etiket imgesi oluşturulur. Bu etiket imgesi, LBP öznelik histogramlarına yerellik katmak amacıyla DCT'de olduğu gibi 8x8 bloklara bölünür. Her blokta 8 kutulu histogramlar çıkarılır ve düzgeleme uygulanır. Son olarak bu bloklardan çıkarılan öznelikler birleştirilerek 512 boyutlu LBP öznelik vektörü elde edilir.

2.4. Sınıflandırma

Sınıflandırma için literatürde de oldukça sık kullanılan doğrusal olmayan (Gauss çekirdekli) SVM kullanılmıştır. SVM parametreleri çapraz geçiremeye dayalı eniyilemeyle belirlenmiştir. Sınıflandırmaya ilgili daha detaylı açıklama deneyler bölümünde bulunmaktadır.

3. ÖZNEİİK SEÇİMİ

SVM gibi ayrırımsayıcı bir sınıflandırıcı, sınıflar arasındaki farklılıkları özneliklerin işlevi olan matematiksel bir modeldir. Sınıflandırıcıların karmaşıklığı, doğal olarak kullanılan öznelik sayısı ile artar. Bu bağlamda, yalnızca ayırt edici özneliklerden oluşan bir öznelik alt kümesi seçilebilirse sınıflandırıcının karmaşıklığı azaltılmış, dolayısıyla genelleştirme yeteneği artırılmış olur. Buna ek olarak daha az sayıda öznelik, gerçek zamanlı işlem için de avantajlıdır. Sıradaki bölümlerde, kendi başına sınıflandırıcı olarak da kullanılabilen RDF'lerin veri açınısına özelliklerinden yararlanan bir öznelik seçimi yaklaşımı tanıtılmıştır.

RDF, bağımsız olarak rastgele örneklenmiş ve aynı dağılıma sahip karar ağaçlarının birleşiminden oluşur. Her ağaçta karar düğümleri bulunur. Her düğümden, o düğüme gelen eğitim kümesi, koşulları sağlıyorsa daha derin düğümlere veya koşulları sağlıyorsa yapraklara ayrılır. Bu işlem, bütün dalların yapraklara ulaşması ile sonlanır. Her yaprak, kendine kadar gelen örneklerdeki en yaygın sınıfı gösterir. Daha önce bahsedildiği üzere, ağaçlardaki her düğüm bir ayırımdır. Bu ayırımlar, saflık ölçütüne göre belirlenir. Ancak bütün olası ayırımlar için saflığı hesaplamak pahalı olduğu için, rastgele seçilmiş bir alt kümede, çocuk düğümlerin ya da yaprakların saflığı hesaplanır. Bu alt küme seçimi ile hem hesaplama süresi düşer, hem de her ağacın gürültüye olan duyarlılığı azalır.

Model öğrenilmesiyle, RDF düğümlerinde kullanılmayan öznelikler otomatik olarak ayrılmış olur. Bu yöntemde aşılması gereken temel sorun, en uygun RDF modelinin belirlenmesidir. Bu çalışmada, RDF eğitiminde devreye giren toplam ağaç sayısı, her düğümden kaç öznelik üzerinden seçim yapılacağı ve de maksimum ağaç derinliği parametreleri çapraz

geçerlemeyle seçilmektedir. En iyi çapraz geçerleme performansına sahip RDF modelinin seçtiği öznitelikler, daha sonra bu çalışmada olduğu gibi SVM gibi bir sınıflandırıcıyla kullanılabilir.

4. DENEYLER

Bu çalışmada, beş ana performans deneyi yapılmıştır:

1. DCT özniteliklerini kullanarak SVM ile sınıflandırma,
2. LBP özniteliklerini kullanarak SVM ile sınıflandırma,
3. DCT ve LBP özniteliklerini birlikte kullanarak SVM ile sınıflandırma,
4. DCT ve LBP özniteliklerini birlikte kullanarak RDF ile sınıflandırma,
5. DCT ve LBP öznitelikleri arasından RDF kullanarak öznitelik seçimi yapıldıktan sonra SVM ile sınıflandırma.

Deneylerde farklı veri tabanları eğitim ve test kümesi olarak kullanılmıştır. Yani, aynı veri tabanı eğitim ve test kümesi olarak ayrılmamıştır. Böylece, sınıflandırıcı modelimizin, veri tabanına bağlı özellikleri öğrenmesinden kaçınılmış, ölçülen performansların gerçek dünyada çalışma performansına yakın bir şekilde çıkartılması hedeflenmiştir.

4.1. Veri Tabanı

FERET yüz tanıma algoritmalarının test edilmesi için yaygın bir şekilde kullanılan açık bir veri tabanıdır [5]. Ayrıca birçok araştırmacı tarafından yüz imgelerinden cinsiyet kestirimi için de kullanılmıştır. Veri tabanında 994 farklı kişiye ait toplam 2728 adet önden çekilmiş yüz imgesi bulunmaktadır. Bu imgelerden yüz bölümleri çıkarılırken ufak bir kayıp yaşanmasından ötürü 2720 adet yüz imgesi ile çalışabildik. Bu 2720 imgenin 1715 adedi erkeklere 1005 adediye kadınlara aittir.

Vistek Yüz Veri Tabanı, çalışma arkadaşlarımızın webcam ile toplanmış görüntülerinden oluşmaktadır. Toplamda 104 imgeden oluşan bu veri tabanında 70 erkek 34 kadın yüz imgesi vardır ve bir kişinin en fazla 10 farklı yüz imgesi bulunmaktadır.

LFW [6] oldukça zengin bir veri tabanı olup serbest yüz tanıma problemi üzerinde çalışmak için yüz fotoğrafları kullanılarak tasarlanmıştır. Webden toplanan toplam 13.000'den fazla yüz imgesinden oluşmaktadır. Veri tabanı bizim kullandığımız haliyle 10.103 erkek 2.927 kadın yüz imgesinden oluşmaktadır. Kullanılmayan imgeler önden çekilmemiş, oklüzyon olan veya yüz bulucu tarafından bulunamayan yüz imgeleridir. Bu çalışmada FERET veri tabanı yalnızca eğitim ve çapraz geçerleme amaçlı kullanılmıştır. Vistek ve LFW veri tabanlarıysa yalnızca test amaçlı kullanılmıştır.

4.2. Parametreler

SVM sınıflandırıcısı eğitilirken en doğru sonuca ulaşmak için farklı farklı parametreler kullanarak çapraz doğrulama yapmak gerekir. Bu bağlamda doğrusal olmayan SVM'in parametreleri olan düzenleştirme parametresi c ve Gauss işlevi parametresi g belli bir aralıktaki birçok değer ile denenmiş, en iyi 5-katlı çapraz geçerleme performansı verenler bulunmuştur.

Başlangıçta c için değerler 0,01 - 100 arasından 10 farklı değer olarak seçilmiştir, g için ise 0,03125 - 4 arasından 8 farklı değer olarak seçilmiştir. Uzayda parametre arama 3 seviye boyunca devam ettirilmiştir ve ilk seviye sonunda en yüksek performans elde edilen parametrelerin etrafında daha dar yeni bir bölge oluşturulup yeni aramalar orada yapılmıştır.

RDF modeli oluşturulmasında ayırım kıstası (saflık ölçütü) olarak Gini katsayısı kullanılmıştır. Ormanı oluşturan ağaçların kurulmasında, bütün eğitim kümesi ve bütün öznitelikler kullanılmıştır. RDF'e özgü rastgeleliğin iki ayrı mekanizması bulunmaktadır: (i) her bir ormana beslenecek olan eğitim altkümelerinin rastgele seçimi, (ii) her bir düğümde yalnızca belirli bir sayıda rastgele öznitelikle saflık ölçütü eniyilemesi yapılması. Bu çalışmada ilk mekanizma kullanılmamış, rastgelelik yalnızca ikinci mekanizmada devreye sokulmuştur. Çapraz geçerlemeye dayalı RDF model eniyilemesi şu şekilde denemiştir: (i) Ağaç sayısı ormanın kaç adet ağaçtan oluşturulacağını belirtir ($M=10, 50, 200$), en küçük yaprak büyüklüğü ayırım yapılacak en küçük örnek sayısını belirtir ($L = 200, 100, 10$), ayırım öznitelik sayısı her bir düğümde ayırım kıstasını eniyilemek için seçilecek rastgele öznitelik sayısını belirtir ($K = 10, 40, 100$).

4.3. Sonuçlar

Tablolarda yer alan çapraz doğrulama performansları FERET veri tabanını kullanarak sınıflandırıcı eğitildiğinde elde edilen sonuçlardır (Kullandığımız SVM yazılımındaki çapraz geçerleme işlevinin kısıtları nedeniyle kadın ve erkek sınıfları için ayrı ayrı çapraz geçerleme sonucu veremiyoruz). Test 1 performansları Vistek veri tabanını kullanarak elde edilen sonuçlardır. Test 2 performansları LFW veri tabanını kullanarak elde edilen sonuçlardır. Tablo 1'de deney 1-2-3'ü ince-

Tablo 1: Deney 1-5'in sonuçları

(1) DCT + SVM	Genel	Erkek	Kadın
Çapraz Doğrulama Performansı	95,8	-	-
Test 1 Performansı	96,2	97,1	94,1
Test 2 Performansı	76,6	77,4	73,4
(2) LBP + SVM	Genel	Erkek	Kadın
Çapraz Doğrulama Performansı	95,9	-	-
Test 1 Performansı	94,2	94,3	94,1
Test 2 Performansı	75,2	72,3	85,1
(3) DCT + LBP + SVM	Genel	Erkek	Kadın
Çapraz Doğrulama Performansı	96,8	-	-
Test 1 Performansı	96,2	97,1	94,1
Test 2 Performansı	78,0	76,2	84,3
(4) DCT + LBP + RDF	Genel	Erkek	Kadın
Çapraz Doğrulama Performansı	93,2	-	-
Test 1 Performansı	92,3	98,6	79,4
Test 2 Performansı	78,7	83,0	64,1
(5) DCT + LBP + RDF + SVM	Genel	Erkek	Kadın
Çapraz Doğrulama Performansı	96,5	-	-
Test 1 Performansı	97,1	98,6	94,1
Test 2 Performansı	76,8	75,0	82,8

lediğimiz zaman her 3 deney için de oldukça yüksek çapraz

doğrulama sonuçlarına ulaştığımızı görebiliyoruz. DCT öznitelikleri kullandığımız deneye bakarsak hem Test 1 hem Test 2 için erkek performansının kadın performansından, LBP özniteliklerinin kullanıldığı deneydeyse kadın performanslarının erkek performanslarından daha yüksek olduğunu görüyoruz. Yani bir DCT erkekler, LBP ise kadınlar için daha ayırt edici özellik taşıyor. Bu bağlamda ikisini birleştirerek yaptığımız 3. deneyde özniteliklerinin birleştirilmesinin performansa olumlu bir etkisi olduğunu söyleyebiliriz. Her 3 deneyde de Test 2'nin genel performansı Test 1'in genel performansından daha düşük, bunun sebebi Test 1'de kullanılan Vistek veri tabanındaki imgelerin eğitim sırasında kullanılan FERET veri tabanındaki gibi kontrollü bir ortamda alınmış olmasıdır. Test 2'de kullanılan LFW veri tabanında gerçek ortam görüntülerinden toplanan imgelerden oluşmaktadır ve gerçek bir uygulama için bu yöntem kullanılmak istenildiği durumda elde edilecek sonuçtur.

Tablo 1, deney 4'te görüldüğü gibi RDF performansları, SVM performanslarına oranla düşük çıkmıştır. Bunun ana sebebi, değişimlerde kullanılan tek değişkenli arama yöntemi yerine iki değişkenin doğrusal birleşimi kullanılabilir. Ancak bu çalışmada, RDF performansına değil, seçmiş olduğu özniteliklere odaklanılmıştır.

Tablo 1, deney 5'i incelediğimiz zaman elde edilen sonuçların DCT ve LBP özniteliklerinin tamamının kullanıldığı deneye çok yakın olduğunu görüyoruz. RDF kullanarak seçilen özniteliklerin gerçekten ayırt edici öznitelikler olduğunu söyleyebiliriz. Özgün öznitelik kümesinde 320 DCT ve 512 LBP olmak üzere toplam 832 öznitelik değeri bulunmaktadır. RDF ile seçilen kümedeyse 445 öznitelik bulunmaktadır. Buna göre, özniteliklerin sayısı neredeyse yarısına düşürülmesine karşın benzer ve sınıflar arasında dengeli performans edilebilmektedir.

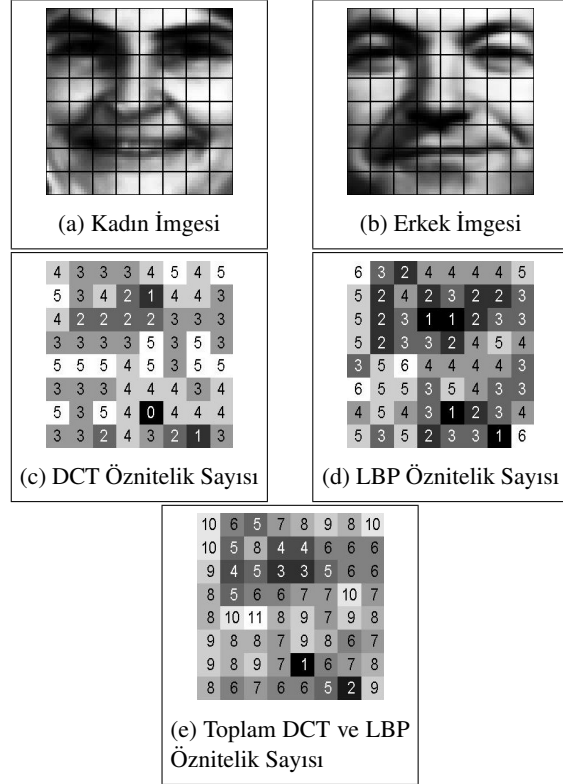
4.4. Seçilen Özniteliklerin Açıklanması

Şekil 1a ve 1b'de görüldüğü gibi DCT ve LBP öznitelikleri 8×8 'lik imge bloklarından, sırasıyla 5 ve 8 adet çıkartılmıştır. 13 boyutlu vektörden, RDF kullanılarak tanımlayıcı öznitelikler seçilmiştir. Bu işlem sonucunda her bloktan çıkartılmış 5 boyutlu DCT öznitelik değerlerinden seçilenlerin sayısı şekil 1c'de, 8 boyutlu LBP öznitelik değerlerinden seçilenlerin sayısı şekil 1d'de verilmiştir. Her bloktan oluşan 13 boyutlu vektörden toplam seçilen öznitelik sayısı ise şekil 1e'de görülmektedir. Seçilmiş öznitelik sayılarına bakıldığında, yüz imgelerinde burun üzerindeki ve alt dudaktaki blokların ayrırcılıklarının düşük, dudak üstü ve dudak yan bölgelerindeki blokların ayrırcılıklarında yüksek olduğu gözlemlenmektedir.

5. VARGILAR

Bu çalışmada ilk olarak DCT ve LBP gibi temel öznitelikler kullanarak cinsiyet tanımda kabul edilebilir performanslar elde edilebildiğini, bunların birleştirilmesiyle performansın artırılabilirdiğini gözlemledik. Raporlanan performanslar, nite

lik olarak eğitim kümesinden tamamen farklı, nicelik olarak eğitim kümesinin neredeyse 5 katı örnek içeren bir test kümesi üzerinde elde edildiğinden gerçeğe önemli ölçüde yakındır. Çalışmada aynı zamanda RDF ile öznitelik seçimi yapıp performansın korunabileceğini deneysel olarak gösterdik. Bu alanda gelecekte üzerinde seçim yapılacak ilk öznitelik



Şekil 1: RDF öznitelik seçimi algoritması sonucunda seçilen DCT ve LBP özniteliklerinin sayıları ve konumları

kümesini zenginleştirmeyi ve RDF ile öznitelik seçimini daha da etkili kılabilecek yöntemler geliştirmeyi hedefliyoruz.

6. KAYNAKÇA

- [1] C. Boon Ng, Y. Haur Tay, and B. M. Goi, "Vision-based Human Gender Recognition: A Survey," *ArXiv e-prints*, Apr. 2012.
- [2] S. Gutta, J.R.J. Huang, P. Jonathon, and H. Wechsler, "Mixture of experts for classification of gender, ethnic origin, and pose of human faces," *Neural Networks, IEEE Transactions on*, vol. 11, no. 4, pp. 948–960, 2000.
- [3] B. Moghaddam and M.H. Yang, "Learning gender with support faces," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 24, no. 5, pp. 707–711, 2002.
- [4] Z. Li, X. Zhou, and T.S. Huang, "Spatial gaussian mixture model for gender recognition," in *Image Processing (ICIP), 2009 16th IEEE International Conference on*. IEEE, 2009, pp. 45–48.
- [5] P.J. Phillips, P.J. Rauss, S.Z. Der, et al., *FERET (face recognition technology) recognition algorithm development and test results*, Defense Technical Information Center, 1996.
- [6] G.B. Huang, M. Mattar, T. Berg, E. Learned-Miller, et al., "Labeled faces in the wild: A database for studying face recognition in unconstrained environments," in *Workshop on Faces in 'Real-Life' Images: Detection, Alignment, and Recognition*, 2008.