



**T.C.
İSTANBUL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



YÜKSEK LİSANS TEZİ

NEGATİF OLMAYAN MATRİS AYRIŞTIRMA (NOMA) ALGORİTMALARI VE UYGULAMALARI

İhsan KOÇAK

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

**DANIŞMAN
Yrd. Doç. Dr. Tolga ENSARİ**

**II. DANIŞMAN
Prof. Dr. Jacek M. ZURADA**

Kasım, 2016

İSTANBUL

Bu çalışma, 10.11.2016 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi


Yrd. Doç. Dr. Tolga ENSARİ(Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi



Prof. Dr. Ahmet SERTBAŞI
İstanbul Üniversitesi
Mühendislik Fakültesi



Doç. Dr. Atakan KURT
İstanbul Üniversitesi
Mühendislik Fakültesi



Doç. Dr. Fethullah KARABİBERİ
Yıldız Teknik Üniversitesi
Elektrik Elektronik Fakültesi



Yrd. Doç. Dr. Oğuzhan ÖZTAŞI
İstanbul Üniversitesi
Mühendislik Fakültesi





20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi’nin aboneli olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Bu çalışma İstanbul Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak hazırlanan “Negatif Olmayan Matris Ayırıştırma (NOMA) Algoritmaları ve Uygulamaları” isimli tezi içermektedir.

Yüksek Lisans tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımlarından dolayı çok değerli hocam Yrd. Doç. Dr. Tolga Ensari’ye ve Prof. Dr. Jacek M. Zurada’ya en içten dileklerimle teşekkür ederim.

Kasım 2016

İhsan KOÇAK



İÇİNDEKİLER

Sayfa No

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
ŞEKİL LİSTESİ.....	vii
TABLO LİSTESİ.....	viii
SİMGE VE KISALTMA LİSTESİ	ix
ÖZET.....	x
SUMMARY	xii
1. GİRİŞ.....	1
2. GENEL KISIMLAR	3
2.1. MAKİNE ÖĞRENMESİ VE VERİ MADENCİLİĞİ	3
2.2. YÜZ TANIMADA KULLANILAN YÖNTEMLER	5
2.2.1. Üç Boyutlu Yüz Tanıma (3D Face Recognition).....	5
2.2.2. Aktif Görünümle Yüz Tanıma	6
2.2.3. Özyüzler Yöntemi (Eigenfaces Method)	6
2.2.4. Aydınlanmaya Dayalı Gürbüz Yüz Tanıma.....	7
2.2.5. Gizli Markov Modeli (Hidden Markov Model)	7
2.2.6. Bağımsız Bileşen Analizi (Independent Component Analysis)	7
2.2.7. Temel Bileşen Analizi (Principal Component Analysis).....	8
2.2.8. Yapay Sinir Ağları (Artificial Neural Networks).....	8
2.3. NEGATİF OLMAYAN MATRİS AYRIŞTIRMA	10
2.3.1. NOMA Uygulamaları	12
2.3.1.1. Metin Madenciliği (Text Mining)	13
2.3.1.2. Spektral Veri Analizi	13
2.3.1.3. Ölçeklenebilir İnternet Mesafe Tahmini.....	13
2.3.1.4. Durağan Olmayan Ses Gürültüsüzleştirme	14
2.3.1.5. Biyoenformatik.....	14
2.3.1.6. Nükleer Görüntüleme	15
2.3.1.7. Yüz Tanıma	15
2.3.1.8. Robotik.....	16
2.3.1.9. Saldırı Tespiti(Intrusion Detection)	16

2.3.1.10. Gözetleme Türü Videolarda Arka Plan Modelleme	16
2.3.2. NOMA Araştırmaları	17
2.3.3. NOMA Türleri	17
2.3.3.1. Yaklaşık NOMA (Approximate NMF)	17
2.3.3.2. Yakınsak NOMA (Convex NMF)	17
2.3.3.3. Negatif Olmayan Derece Çarpanlarına Ayırma	17
2.3.3.4. Değişik Maliyet Fonksiyonları ve Düzenlemeler	18
2.3.3.5. Online NOMA	18
2.3.3.6. Kuadratik NOMA (Quadratic NMF)	18
2.3.3.7. Seyrek NOMA (Sparse NMF)	19
2.3.3.8. Korentropi Temelli NOMA (Correntropy-Based NMF)	19
2.3.3.9. Bayeşçi NOMA (Bayesian NMF)	19
2.3.3.10. Olasılıksal NOMA (Probabilistic NMF)	19
2.3.3.11. Düzgün Olmayan NOMA (Nonsmooth NMF)	20
2.4. KARŞIT TEMELLİ ÖĞRENME (OPPOSITION BASED LEARNING)	20
3. MALZEME VE YÖNTEM	23
4. BULGULAR	26
5. TARTIŞMA VE SONUÇ	32
KAYNAKLAR	34
ÖZGEÇMİŞ	37

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1: Veri madenciliği alt kategorileri.	3
Şekil 2.2: Enformasyon piramidi.	4
Şekil 2.3: Yapay sinir ağı modeli.	9
Şekil 2.4: Tek boyutlu eşitliğin çözülme adımları.	22
Şekil 3.1: AR yüz veri tabanından örnek 3 farklı kişinin 8 farklı pozunu.	23
Şekil 3.2: ORL yüz veri tabanından örnek 4 farklı kişi ve 7 farklı pozunu.	24
Şekil 3.3: Fotoğrafların vektörizasyonu.	25
Şekil 4.1: AR için tanıma yüzdeleri.	27
Şekil 4.2: AR için yüz tanıma süreleri.	28
Şekil 4.3: ORL için yüz tanıma süreleri.	29
Şekil 4.4: ORL için yüz tanıma oranları.	29

TABLO LİSTESİ

	Sayfa No
Tablo 4.1: AR yüz tanıma oranları.....	30
Tablo 4.2: AR yüz tanıma süreleri.	30
Tablo 4.3: ORL yüz tanıma süreleri.....	30
Tablo 4.4: ORL yüz tanıma oranları.	31



SİMGE VE KISALTMA LİSTESİ

Kisaltmalar	Açıklama
ÇGF	: Çarpımsal Güncelleme Formülü
KNOMA	: Karşıt Temelli NOMA
KTÖ	: Karşıt Temelli Öğrenme
NOMA	: Negatif Olmayan Matris Ayrıştırması
TBA	: Temel Bileşen Analizi
DVM	: Destek Vektör Makinesi
DNOMA	: Değişen Minimum Kareler Algoritması Tabanlı NOMA

ÖZET

YÜKSEK LİSANS TEZİ

NEGATİF OLMAYAN MATRİS AYRIŞTIRMA (NOMA) ALGORİTMALARI VE UYGULAMALARI

İhsan Koçak

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman : Yrd. Doç. Dr. Tolga ENSARİ

II. Danışman : Prof. Dr. Jacek M. ZURADA

Bu çalışmada, negatif olmayan matris ayrıştırması (NOMA), yaklaşık NOMA (Approximate NMF), yakınsak NOMA (convex NMF), online NOMA adlı NOMA türleri, metin madenciliği, spektral veri analizi, ölçeklenebilir internet mesafe tahmini (scalable internet distance prediction), durağan olmayan ses gürültüsüzleştirme (non-stationary speech denoising), biyoenformatik, nükleer görüntüleme ve yüz tanıma uygulama alanları; üç boyutlu yüz tanıma, aktif görünüm modeline dayalı yüz tanıma, öz yüzler yöntemi, aydınlanmaya dayalı gürbüz yüz tanıma, gizli markov modeli ile yüz tanıma, bağımsız bileşen analizi (independent component analysis), temel bileşen analizi (principal component analysis), yapay sinir ağları, destek vektör makineleri (support vector machine), nokta imza yöntemi (point signature), akıllı etkileşimler (smart interactions) olarak adlandırılan yüz tanıma yöntemleri ve NOMA ile ilgili diğer araştırmalardan bahsedildikten sonra karşıt temelli öğrenme (KTÖ) hakkında bilgi verilip yüz veritabanları üzerinde NOMA ve KTÖ senteziyle oluşturulan algoritma çalıştırılıp sonuçları grafikler üzerinde gösterilmiştir. Ayrıca DNOMA

(Değişen en küçük kareler (Alternating least square - ALS) tabanlı NOMA) ve Temel bileşen analizi (TBA) yöntemleri denenmiş ve elde edilen doğruluk sonuçları karşılaştırılmıştır. Veri sıkıştırma algoritmalarında aranan kriterlerden biri hızdır. Yüz Tanıma algoritmalarında ise aranan kriterlerden biri tanıma yüzdesinin yüksek olmasıdır. Bahsi geçen iki algoritma grubuna giren NOMA'ya KTÖ uygulanarak AR ve ORL yüz veritabanlarında bu iki kriterin iyileştirilmesi amaçlandı.

Kasım 2016, 50 sayfa.

Anahtar kelimeler: Karşıt temelli öğrenme, yüz tanıma, makine öğrenmesi.



SUMMARY

M.Sc. THESIS

NONNEGATIVE MATRIX FACTORIZATION (NMF) ALGORITHMS AND ITS APPLICATIONS

İhsan KOÇAK

İstanbul University

Institute of Graduate Studies in Science and Engineering

Department of Computer Engineering

Supervisor : Assist. Prof. Dr. Tolga ENSARİ

Co-Supervisor : Prof. Dr. Jacek M. ZURADA

In this study, after mentioning about nonnegative matrix factorization (NMF) types named approximate NMF, convex NMF, nonnegative rank factorization, application areas of NMF like text mining, spectral data analysis, scalable internet distance prediction, non-stationary speech denoising, bioinformatics, nuclear monitoring; how it is used in face recognition, 3D face recognition, active appearance model based face recognition, eigenfaces method, illumination based robust face recognition, hidden Markov model, independent component analysis, principal component analysis, artificial neural networks, support vector machine, point signature method, smart interactions, other methods used in face recognition and other researchs about NMF, it is mentioned about opposition based learning (OBL) and an algorithm composed of NMF and OBL synthesis has been run and the result of this algorithm has been shown on graphics. Moreover ANMF (Alternating leastsquares based NMF) and principal component analysis (PCA) methods were compared with the results. Speed is the

one of the desired criterias in data compressing algorithms. In recognition algorithms, however, one of the wanted criteria is the high percentage of recognition. It is aimed to speed up and increase the recognition rate of the Nonnegative Matrix Factorization (NMF) which is in the category of the both mentioned algorithms.

November 2016, 50 pages.

Keywords: Opposition based learning, face recognition, machine learning.



1. GİRİŞ

Negatif olmayan matris ayrıştırma (NOMA), çok boyutlu verilerdeki fazlalıklardan kurtularak önemli bileşenleri ortaya çıkarmak için kullanılan içerik analiz yöntemlerindeki önemli adımlardan birisidir. Temel bileşen analizi (TBA) başta olmak üzere birçok ayrışım (decomposition) yöntemi işlenen veri boyutunu küçülterek ve önemli bilgi bileşenlerini açığa çıkararak bu işlevi yerine getirmeyi amaçlar. Bu yöntemlere ek olarak, döngülü (iterative) bir şekilde matris çarpanlarına ayırma işlemi gerçekleştirerek verinin özneliliklerini (feature) çıkarmayı amaçlayan negatif olmayan matris ayrıştırma (NOMA) da çok boyutlu veriler üzerinde kullanılmak üzere önerilen yeni tekniklerden birisidir. Negatif olmayan matris ayrıştırma, orijinal veri matrisini iki tane çarpan matrisine ayırarak boyut azaltır ve yararlı gösterimler (representation) oluşturur. NOMA sonucunda elde edilen çarpan matrislerin orijinal veri içersindeki gizli ve önemli bileşenleri barındırmaları beklenir. Diğer birçok yöntemin aksine, NOMA'da bu çarpan matrisler üzerinde negatif olmama koşulu vardır ve bu koşul neden olduğu toplanabilirlik ilkesi sebebiyle sezgisel ve parça tabanlı (parts based) gösterimlerin oluşturulması sağlanır [1].

Negatif olmayan matris ayrıştırma problemine çözüm olarak sunulan daha erken çalışmalar mevcut olsa da NOMA ününü daha çok Lee ve Seung'un 1999 yılında yayımladıkları çalışmalarına borçludur. Söz konusu çalışmada NOMA için döngüsel ve çarpımsal güncelleme kuralları önerilmiş ve NOMA'nın başarılı bir makine öğrenmesi (machine learning) tekniği olduğu gösterilmiştir. Daha sonraları NOMA araştırmalarındaki yeni trend elde edilen çarpanların seyreklilik (sparseness) özelliklerini arttırarak oluşturulacak gösterimlerin parça tabanlı olma olasılığını arttırmak olmuştur. Bunun için NOMA'nın klasik maliyet fonksiyonuna ek terimler eklenerek en iyileme sürecindeki kısıtlamalar arttırılmış, bunun neticesinde seyrekliliği daha yüksek çarpanlar oluşturulmaya çalışılmıştır.


NOMA için önerilen yöntemler genelde döngüseldir ve bu yüzden algoritma yakınsaklığı önemli bir konudur. Yakınsama hızının arttırılması için farklı izdüşürülmüş gradyan azaltma (projected gradient descent) yöntemleri sunulmuştur. Döngüsel ve çarpımsal güncellemeli tekniklere alternatif olarak, Newton türü sayısal yöntemler de önerilmiştir.

Öğrenme, optimizasyon ve arama makine öğrenmesi araştırmalarında çözümü araştırılan temel konulardandır. Algoritmalar geçmiş verilerden öğrenir, çözümleri optimize ederler ve bir çözüm için geniş uzaylarda arama yaparlar. Problemler değişik doğaya sahiptirler ve algoritmalar çeşitli biyolojik, davranışsal ve doğal fenomenlerden ilham alırlar [2]. KTÖ'de verilen bir problemin çözümüne (x) bakılırken bir yaklaşımda (x') bulunulur. Bu yaklaşım kesin çözüm değildir ve tecrübeye dayanabilir ya da tamamen rastgele bir tahmin olabilir. KTÖ, x' çözümüne bakılırken aynı anda bu x' çözümünün karşısına (x'') bakılmasını önerir. Bu çalışmada NOMA'ya KTÖ uygulanarak NOMA'nın hızlandırılması ve tanıma oranının yükseltilmesi amaçlanmıştır. Yapılan yüz tanıma uygulamasında elde edilen sonuçlar, tez içerisinde sunulmuştur.



2. GENEL KISIMLAR

NOMA makine öğrenmesi ve veri madenciliği alanında kullanılmaktadır. Veri madenciliği bankacılık, pazarlama, sigortacılık, sağlık gibi değişik alanlarda uygulanmaktadır. Veri madenciliğinin kullanılmasında sektör farkı gözetilmemekle beraber geniş veri ambarlarının oluşumuna olanak veren, perakende satış, sigortacılık, sağlık gibi alanlarda kullanılması daha yaygındır [3].



Şekil 2.1: Veri madenciliği alt kategorileri.

Şekil 2.1’de görüldüğü gibi veri madenciliği pek çok konuyu kapsayan disiplinler arası bir yaklaşımdır. Bu nedenle uygulama alanı oldukça geniştir. Günümüzde tüm işletmeler sahip oldukları müşterilerin davranışlarını tahmin etmek istemektedirler. Veri madenciliği bu amaçla kullanılabilecek olan bir tekniktir. Bu nedenle veri madenciliği günümüzde pazarlama, perakendecilik, bankacılık ve finans, ulaşım, tıp ve daha birçok farklı alanda kullanılmaktadır [4].

Bu çalışmada veri olarak yüz görüntüleri kullanılacaktır. Yüz tanımada kullanılan yöntemler 2.2. bölümünden itibaren başlıklar halinde verilmiştir.

2.1. MAKİNE ÖĞRENMESİ VE VERİ MADENCİLİĞİ

NOMA, makine öğrenmesi ve veri madenciliğinin zorlu problemlerini çözme kabiliyetine sahiptir. Veri madenciliği, doküman ya da veritabanı kaydı şeklinde depolanmış çok büyük

miktardaki veri içinde saklı faydalı şablonları ve eğilimleri keşfetmek için makine öğrenmesi, istatistik, yapay zeka kavramlarını ve tekniklerini dokümanlara uygular. Veri madenciliği, istatistiksel ve yapay zeka analizlerini içerir ve büyük ölçekli veri setlerine uygulanır.



Şekil 2.2: Enformasyon piramidi.

Veriden bilgiye giden yolda aşamalar genel olarak enformasyon piramidi ile gösterilir. Bu piramit Veri (Data), enformasyon (Information), bilgi (Knowledge) ve bilgelik (Wisdom) bileşenlerinden oluştuğu için piramit DIKW piramidi olarak da adlandırılmaktadır [6].

Veri analizinde geliştirilen yöntemlerde ana fikir geleceğin geçmişin bir yansıması olduğudur. Bu temel fikre göre geçmişe ilişkin veri dizilerinin etkin yönetimi, uygun yöntemlerin kullanılmasıyla geleceğin de tahmin edilmesini sağlayacaktır. Günümüzün olağanüstü dinamik koşullarında bu yaklaşımın geçerliliği tartışmaya açıktır. Geçmişin verilerini toplamak, analiz etmek veya güncel olayların analizi kısmen mümkün olsa da geleceğin bilinmesi mümkün değildir.

Bilgi ve iletişim teknolojilerinde yaşanan gelişmeler, özellikle elektronik ortamda depolanan veri miktarındaki artış ve bu veriyi yorumlamanın insan kapasitesini aşması, araştırmacıları veri madenciliği alanındaki çalışmalara yöneltmiştir. Fazla miktardaki veri arasından işe yarar bilginin elde edilmesi bu sayede mümkündür. Bu nedenle, büyük veri (big data) üzerindeki araştırmalar artarak devam etmektedir.

Makine öğrenmesi, yapay zekadaki örüntü tanıma ve hesaplamalı öğrenme teorisi çalışmalarının sentezlenmesi sonucu oluşmuş olup bilgisayar biliminin bir alt alanıdır. Bilgisayarlara, açıkça programlama yapmadan öğrenme kabiliyeti verme çalışmaları olarak tanımlanabilir. Verilerden öğrenme ve tahmin edebilmeyi mümkün kılan algoritmaları keşfetme çalışmaları da makine öğrenmesi alanına girer. Bu tür algoritmalar örnek girdilerden hareketle veri merkezli tahminlerde bulunmak veya karar vermek için bir model oluşturmak şeklinde çalışır [7].

Makine öğrenmesi, hesaplamalı bilgisayarlarla tahmin etmeye odaklanan hesaplamalı istatistikle ilişkilidir. Ayrıca, matematiksel optimizasyonla sıkı bir ilişkisi vardır. Makine öğrenmesi sıradan algoritmaların yetersiz olduğu hesaplama dayalı geniş bir alanda devreye girer. Optik karakter tanıma, bilgisayarlı görü, spam filtreleme, arama motorları makine öğrenmesinin çalışma alanlarıdır. Makine öğrenmesi bazen veri madenciliğiyle birleştirilse de veri madenciliği daha çok veri analiziyle ilgilenir ve denetimsiz öğrenme olarak bilinir.

2.2. YÜZ TANIMADA KULLANILAN YÖNTEMLER

Yüz tanıma en çok kullanılan yöntemler aşağıda alt başlıklar halinde sıralanmıştır. Kullanılan sınıflandırma yöntemleri kısaca anlatılmış ve çalışmalar hakkında bilgi verilmiştir.

2.2.1. Üç Boyutlu Yüz Tanıma (3D Face Recognition)

Üç Boyutlu (3D) yüz tanıma sistemleri, temel olarak iki kısımdan oluşmaktadır. Önce, üç boyutlu görüntüde yüz ve yüz üzerindeki bazı önemli noktalar bulunur. Sonra, bulunan yüz bölgesi standart bir boy ve poza getirilir, 3 boyutlu yüz betimlenmesi yapıldıktan sonra yüz tanıma işlemine başlanır. İlgili yüzün ID numarasıyla yapılacak eşleştirmeler sonunda, sınıflandırma başarısı hesaplanır.

2.2.2. Aktif Görünümle Yüz Tanıma

Aktif görünüm modeli kullanılırken, yüze ait önemli noktaların koordinatları saptanır, eğitim resimleri ile eğitilerek kurulan model yardımı ile yeni insan yüzleri birleştirilir. Giriş resmi ile birleştirilen resim arasındaki farkı minimize eden model parametreleri bulunmaya çalışılır. Eğitim kümesindeki insan yüzlerinin önemli noktaları elle belirlenir.

2.2.3. Özyüzler Yöntemi (Eigenfaces Method)

Özyüzler yaklaşımı, temel bileşen analizinin (TBA) geliştirilmiş halidir. Veriyi kodlama ve kodunu çözmede iyi bilinen bir tekniktir. Yüz resimleri gruplarından başlanarak bu resimlerin temel bileşenlerinin hesaplanmasıdır. Daha sonra da öz vektörün sadece küçük parçalarının ağırlıklı birleşimini kullanılarak yüz resminin yeniden oluşturulmasıdır. Matthew A. Turk ve Alex P. Pentland, 1991 yılında yayınladıkları “Face Recognition Using Eigenfaces” başlıklı makale ile ilk kez özyüzler yöntemini kullanmışlardır [5]. Turk ve Pentland, denetimsiz bir öğrenme olan temel bileşenler analizini kullanarak, önemli noktaların çıkarılmasını uygulamaya bırakıyorlar. Özyüzler için, temel bileşenler analizinde kullanılan vektörler yerine elimizde iki boyutlu görüntüler bulunmaktadır. Bu görüntüler tek boyutlu bir vektör haline getirilerek, her bireyin görüntüsü ayrı bir değer kümesi olarak düşünülebilir. Her bireyin, gri ölçeğe aktarılmış, histogramı eşitlenmiş ve yeniden boyutlandırılmış görüntüleri tek bir vektör haline getirilir. Böylece m yüksekliğinde ve n genişliğinde bir görüntü, $(mn) \times 1$ uzunluğunda bir vektör olmaktadır. Birey sayısı kadar vektör birleştirilip, görüntü matrisi elde edilir. Bu matris, (mn) 'lik görüntülerden ve k kadar bireyden oluşuyorsa, boyutları $(mn) \times (k)$ olur. Bu büyük matrisin satırları görüntülere, kolonları da bireylere denk gelmektedir. Eigenfaces kümesi oluşturma algoritması şu şekildedir:

- Her sütunu vektörize edilmiş bir fotoğraf içeren T matrisi oluşturulur.
- Bu T matrisindeki fotoğrafların ortlamsıyla elde edilen ortalama fotoğraf, T matrisindeki her bir fotoğraftan çıkartılır (subtract)
- Kovaryans matrisinin özvektörleri (eigenvectors) ve özdeğerleri (eigenvalues) hesaplanır.

- Her bir özvektör ilgili fotoğrafla aynı boyuta sahiptir dolayısıyla bir fotoğraf olarak düşünülebilir. Bu yüzden kovaryans matrisinin özvektörleri özyüzler olarak da adlandırılır.

2.2.4. Aydınlanmaya Dayalı Gürbüz Yüz Tanıma

Normal aktif görünüm modelinde farklı aydınlatma koşullarına sahip görüntülerde hatalı sonuçlar alınmaktadır. Bu ise normal AGM'nin aydınlanmadan kaynaklanan gri seviye değişimlerinden etkilenmesinden kaynaklanmaktadır. Bu sorunu gidermek için ayırt temelli bu yöntem kullanılmaktadır.

2.2.5. Gizli Markov Modeli (Hidden Markov Model)

Gizli Markov Modelinde bir sinyalin istatistiksel yönleri tanı olarak ele alınır. Bir işareti karakterize etmek için kullanılır. Bu modelde tanıma işlemi yapılırken resimden bazı kesitler alınır. Bu kesitlere göre tanıma işlemi yapılır. Gizli Markov Modeli kullanılarak yapılan yüz tanımda örnekleri oluşturmak için gereken zaman uzun olduğu için yüz tanımda tutulan bir metot haline gelememiştir. Markov Analizi terimi, sistemin şu anki davranışını dikkate alarak, ileriye yönelik davranışlarını tahmin etmek için kullanılan bir tekniği ifade eder. Markov özelliğine sahip olmak, mevcut durum verildiğinde, gelecek durumların geçmiş durumlara bağlı olması anlamına gelir. Bir başka deyişle, mevcut durumun açıklaması, sürecin gelecekteki durumunu etkileyebilecek tüm bilgiyi kapsar.

Günümüzde, belirsizlik altında karar alma ve ileriye yönelik tahminde bulunma birey, firma ve devlet gibi iktisadi karar birimlerinin karşı karşıya olduğu en temel sorunlardandır. Bir sistemin belirsizliği konu alması, sözü edilen sistemin tamamen kontrol altına alınamamasından kaynaklanır.

Saklı Markov Modeli sinyal işlemede sınıflandırıcı (classifier) olarak, çoklukla ses, el yazısı, vücut hareketleri tanıma gibi akıcı örnekleri tanıma, müzik notasyonu izleme, kısmi yük boşalımı, biyoinformatik (biyolojik bilgi), gen tahmini ve kriptanaliz alanlarında kullanılır.

2.2.6. Bağımsız Bileşen Analizi (Independent Component Analysis)

Bu yöntem, çok değişkenli veri kümesinde saklı olan yapıları belirleyen istatistiksel bir yöntemdir. Bağımsız bileşen olarak tanımlanan saklı faktörler, bilinmeyen bir karıştırma

matrisi ile karıştırılarak gözlem verilerini oluşturulmuş. Bu amaç kaynaklar arasındaki istatistiksel bağımlılığı minimize edecek şekilde matrisin bulunmasıdır.

2.2.7. Temel Bileşen Analizi (Principal Component Analysis)

Bu algoritmanın temel amaçları; verilerin boyutunu azaltmak, tahminlerde bulunmak, veri setini bazı analizlerde görüntülemektir. Temel bileşen analizi algoritması kimya, istatistik, anatomi, biyoloji gibi birçok bilim dalında kullanılmaktadır. Kısaca TBA, p boyutlu bir uzaydan (veri p tane değişken ile ifade ediliyorsa) $k < p$ boyutlu bir uzaya dönüşümü sağlamaktadır.

Çok değişkenli verilerin analizinde, verilerin tamamıyla ilgili istatistiksel sonuçlar elde etmenin yanında çok değişkenli veri yapısını tanımlama yöntemleri de bulunmaktadır. Temel bileşen analizi bu yöntemlerden biridir. TBA (Temel Bileşenler Analizi) bazı koşullar altında, korelasyonlu değişkenlere doğrusal dönüşüm uygulayan bir yöntemdir. Bu dönüşüme de ana bileşenler dönüşümü denilmektedir.


Ana bileşenler dönüşümü; aralarında yüksek korelasyon bulunan çok değişkenli verileri, aralarında korelasyon olmayan yeni bir koordinat sistemine dönüştüren doğrusal bir dönüşümdür. Dönüşümden sonra, veriler arasında korelasyon ortadan kalkar. Sayısal görüntülerde ana bileşenler dönüşümü, görüntünün geometrik özellikleri üzerinde yapılan konumsal bir dönüşüm değil, görüntünün radyometrik (spektral ya da renk) özellikleri üzerinde yapılan istatistiksel bir dönüşümdür.

Ana bileşenler dönüşümü, fotogrametri ve uzaktan algılamada; görüntü sıkıştırma (image compression), görüntü iyileştirme (image enhancement), üçten fazla bandla algılanmış görüntülerin ekranda gösterilmesinde, değişim belirlemede (change detection), görüntü çakıştırılmasında (image merging), sınıflandırma öncesinde sınıflandırmaya sokulacak bant sayısının azaltılmasında, yapay sinir ağlarında özellik çıkarımında vs. kullanılmaktadır.

2.2.8. Yapay Sinir Ağları (Artificial Neural Networks)

Yapay sinir ağları, insan beyninin çalışma mekanizmasını taklit ederek beynin öğrenme, hatırlama genelleme yapma yolu ile yeni bilgiler türetebilme gibi temel işlevlerini gerçekleştirmek üzere geliştirilen mantıksal yazılımlardır. Yapay sinir ağları modelleri ile

istatistiksel modeller benzer ya da özdeş olmasına rağmen kullanılan terminolojiler farklılık göstermektedir. YSA biyolojik sinir ağlarını taklit eden sentetik yapılardır. İlk yapay sinir ağı modeli 1943 yılında bir sinir hekimi olan Warren McCulloch ve bir matematikçi olan Walter Pitts tarafından Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap (A Logical Calculus of Ideas Immanent in Nervous Activity) başlıklı makale ile ortaya çıkarılmıştır. Yapay sinir ağlarında bilgi, ağdaki sinirlerin bağlantılarının ağırlıklarında tutulur. Bu nedenle ağırlıkların nasıl belirleneceği önemlidir. Bilgi tüm ağda saklandığı için bir düğümün sahip olduğu ağırlık değeri tek başına bir şey ifade etmez. Tüm ağdaki ağırlıklar optimal değerler almalıdır. Bu ağırlıklara ulaşılabilmesi için yapılan işleme “ağın eğitilmesi” denir. Buna göre bir ağın eğitilebilir olabilmesi için ağırlık değerlerinin belirli bir kural dahilinde dinamik olarak değiştirilebilir olması gerekmektedir.



Şekil 2.3: Yapay sinir ağı modeli.

Şekil 2.3'te görüldüğü gibi, $X_1, X_2, \dots, X_m$ girdi değerleri $W_1, W_2, \dots, W_m$ ağırlıklarına atandıktan sonra bu ağırlıklar bir toplama fonksiyonunda işleme girer. İşlem sonucu eşik değerinden (bias) büyükse aktivasyon fonksiyonuna girerek bir çıktı üretir.

Bilgisayarda resimleri anlamlı hale getirmek için, sayı kümeleri halinde tanımlanır ve resimler üzerinde yapılacak her iş, bu sayı kümesi üzerindeki matris operasyonları sayesinde yapılır. Bilgisayara tanıtılan bir resim yeniden gördüğünde bunun ilk gördüğü nesne olduğunu

anlayabiliyor, o nesneyi hafızaya kaydediyor, yeni bir görüntü aldığı anda ise elektrik sinyallerinden oluşan bu görüntüyü hafızasındakilerle karşılaştırıyor. Bu karşılaştırma değişik hesaplamalarla yapılmaktadır. Yüz tanıma işlemi sırasında insan yüzünün tamamı kullanılarak gerçekleştirildiği gibi, alınan bu yüze çeşitli teknikler uygulayarak da gerçekleştirilebilmektedir. Bu teknikler, temel olarak, yüzün tanımayı kolaylaştıran kritik bölgelerini ortaya çıkararak öğrenmeyi kapsamaktadır.

2.3. NEGATİF OLMAYAN MATRİS AYRIŞTIRMA

Temel bileşen analizi ve vektör nicemlemesi gibi danışmansız öğrenme algoritmaları değişik kısıtlamalara sahip bir veri matrisinin çarpanlarına ayrılması şeklinde düşünülebilir. Kısıtlamalara bağlı olarak çarpanlar çok değişik gösterimsel özelliklere sahip olabilir. Temel bileşen analizi zayıf bir ortogonalite kısıtlaması ile dağıtık gösterimle sonuçlanır. Öte yandan vektör niceme "kazanan hepsini alır" kısıtlamasıyla ayrık küme prototipleri oluşturur.

Negatif olmama durumu matris ayrıştırmasında kullanışlı bir kısıtlamadır ki verinin kısmi gösterimlerini öğrenmeye yarar. Öğrenilen negatif olmayan temel vektörler dağıtık ve seyrek kombinasyonlarda kullanılarak yeniden oluşturmada anlamlılık üretir.

NMF şu şekilde çok değişkenli verilerin istatistiksel analizi için uygulanabilir: Verilen bir n boyutlu çoklu veri vektörü kümesi için m örnek sayısı olmak üzere vektörler $n \times m$ matrisinin sütunlarına yerleştirilir. Bu matris $n \times r$ boyutlu W ve $r \times m$ boyutlu H matrislerine yaklaşık bir şekilde ayrılır. r genellikle n veya m 'den küçük seçilir böylece W ve H matrisleri V matrisinden küçük olur. Bu da orijinal veri matrisinin sıkıştırılmış versiyonunun oluşmasını sağlar. Yukarıdaki eşitliği v , V matrisinin; h ise H matrisinin her bir sütununu belirtmek üzere $v \sim Wh$ şeklinde yazılabilir. Diğer bir ifadeyle her bir data vektörü v 'nin yaklaşık değeri h vektörü ile ağırlıklandırılmış W sütunlarının lineer bir kombinasyonu şeklinde ifade edilir. Böylece W matrisi V 'deki veri için yaklaşık bir değer bulmak için optimize edilmiş bir temel matris olarak düşünülebilir. Burada çok sayıda veri vektörü az sayıda temel vektörlerle temsil edildiği için, iyi bir yaklaşık değer bulmak ancak verideki gizli yapıyı barındıran bir temel matrise sahip olmaya bağlıdır.

Lee ve Seung'un geliştirdiği NOMA algoritması kodlanmasının kolay olması ve yakınsama özelliklerinin garanti edilmesi özellikleriyle ön plana çıkar [1,27]. Diğer algortimalar

hesaplama zamanında başarılı olsa da kodlanmaları zordur ve değişik maliyet fonksiyonlarına genelleştirilemezler.

Lee ve Seung algoritmalarının her iterasyonunda W veya H 'nin yeni değeri, o anki değeri ile denklem 2.1'deki yaklaşıklık kalitesine bağlı olan bir katsayıyla çarpılarak bulunur. Bu ÇGF altında yaklaşıklık sürekli artmaktadır. Pratikte bu tekrarlanan güncelleme kuralları yerel optimal matris ayrıştırmasına yakınsamayı garantilediği anlamına gelir.

Çok boyutlu verilerdeki önemsiz verileri eleyerek, hesaplama yapılacak verinin azaltılmasını (sıkıştırma) sağlayan bir matris ayrıştırma yöntemidir. Boyut küçültme ve sezgisel gösterimler oluşturma yetileri nedeniyle NOMA çeşitli uygulama alanlarında kullanılmıştır. Bunlara örnek olarak yüz tanıma, çeşitli biyomedikal uygulamalar, nota tanıma, biyoinformatik, ses ayrıştırma alanları verilebilir. NOMA'nın bu alanlarda uygulanmasındaki sebeplerinden en önemlisi, kullanılan verilerin doğasına uygun olmasıdır. Bu tür uygulamalarda negatif olmayan elemanlardan oluşan veriler bulunmaktadır. Bu da negatif olmayan veriler şartı koşan NOMA'nın uygulanmasını mümkün kılar. Toplanabilir ve sezgisel gösterimler oluşturma yetisinin yanında, seyreklik de NOMA'nın değişik uygulamalarda fayda sağlayabilecek özelliklerinden biridir. Bu yöntemle veri iki matrise ayrışır.

$$V = WH \quad (2.1)$$

Yukarıdaki ifadede V ayrıştırılacak veri, W ve H ise ayrıştırmadan sonraki bileşenlerdir.

V matrisinin boyutu $n \times m$; W matrisinin boyutu $n \times r$; H matrisinin boyutu ise $r \times m$ 'dir. r ayrıştırma rankı olarak adlandırılır. Rank değerinin seçimi çarpan matrislerine ayırma işlemindeki boyut küçültme miktarını belirler. NOMA belli bir hata karşılığında belli bir yaklaşıklık ile ayrıştırma yaptığı için küçük rank seçimi ile artan boyut küçültme miktarı yeniden oluşturma hatasını (reconstruction error) arttırır. Dolayısıyla, rank küçüldükçe çarpanlara ayırma işlemi sırasındaki bilgi kaybı artar.

Yaklaşık $V \sim WH$ çarpımını bulmak için öncelikle yaklaşıklığın kalitesini ölçen maliyet fonksiyonları tanımlanmalıdır. Böyle bir maliyet fonksiyonu iki negatif olmayan A ve B matrisleri arasındaki uzaklık ölçüsü kullanılarak oluşturulabilir. Bu ölçülerden biri iki matris arasındaki öklit uzaklığının karesidir.

$$||A - B||^2 = \sum (A, B)^2 \quad (2.2)$$

Bir başka ölçü ise;

$$D(A||B) = \sum A \log \frac{A}{B} - A - B \quad (2.3)$$

Öklit uzaklığı gibi bu eşitliğin de alt sınırı 0'dır ve yalnızca A=B ise 0 olur. Ama uzaklık olarak nitelendirilemez çünkü simetrik değildir, A'nın B'ye göre diverjansı olarak adlandırılabilir.

NOMA $W, H > 0$ olmak şartıyla W ve H'a bağlı olarak $||V - WH||^2$ ve $D(V||WH)$ değerlerini minimize etme probleminin çözümü olarak karşımıza çıkmaktadır.

Yukarıdaki öklit uzaklığının karesi olarak bilinen maliyet fonksiyonunun fark fonksiyonunun istenilen hata değerine eşitleninceye kadar çarpımsal güncelleme kuralı ÇGF (multiplicative update rule) iteratif bir şekilde işleme konulur:

$$H_{ab} \rightarrow H_{ab} \frac{(W^T V)_{ab}}{W^T W H_{ab}} \quad (2.4)$$

$$W_{ia} \frac{(V H^T)_{ia}}{(W H H^T)_{ia}} \rightarrow W_{ia} \quad (2.5)$$

İkinci maliyet fonksiyonu için:

$$H_{ab} \frac{\sum_i W_{ia} V_{ib} / (W H)_{ib}}{\sum_k W_{ka}} \quad (2.6)$$

$$W_{ia} \frac{\sum_i H_{ab} V_{ib} / (W H)_{ib}}{\sum_v H_{av}} \quad (2.7)$$

kurallarıyla güncelleme işlemleri yapılmaktadır.

2.3.1. NOMA Uygulamaları

Lee ve Seung tarafından önerilen NOMA yöntemi aşağıdaki alanlarda uygulanmakta olup, daha farklı disiplinler üzerinde de gerçekleştirilmektedir [1, 27]. NOMA'nın kullanıldığı başlıca alanlar aşağıda alt başlıklar halinde belirtilmiştir.

2.3.1.1. *Metin Madenciliği (Text Mining)*

Veri boyutunun büyük olması, veri analizi araştırmalarındaki temel sorunlardan biridir [30]. NOMA metin madenciliği uygulamalarında kullanılabilir. Bu tür uygulamalarda bir doküman kümesinden bir doküman matrisi ağırlıklı kelime sıklığı bilgisiyle oluşturulur. Bu matris, terim ve doküman matrisleri olmak üzere dokümanların içeriğinden oluşturulan iki matrise ayrıştırılır.

Doküman matrisi ilişkili dokümanların veri kümelerini ifade eder. PubMed arama motorundaki bilimsel makalelerin bir kısmına hiyerarşik NOMA uygulanmaktadır. Başka bir araştırma grubu 65000 mesaj ve 91000 ifadeyi 50 kümeye ayırmıştır [8].

NOMA aynı zamanda dış bilimsel alıntılara dayanarak wikipedia makaleleri ve bilimsel dergilerini sınıflandırılmasında kullanılmıştır [9]. Bunların dışında NOMA kullanılarak konu modeli (topic model) öğrenme algoritmaları geliştirilmiştir. Bu algoritma konu matrisinin ayrışabilirlik (separability) şartını sağladığını varsayar [10].

Ayrıca uzaklık ölçüsü olarak correntropy fonksiyonu V ve WH matrisleri arasındaki element bazında benzerliğinin ölçüsü olarak correntropy fonksiyonu kullanılmıştır [29].

2.3.1.2. *Spektral Veri Analizi*

NOMA uzay cisimlerinin sınıflandırılmasında olduğu gibi spektral veri analizinde de kullanılmaktadır [11].

2.3.1.3. *Ölçeklenebilir İnternet Mesafe Tahmini*

NOMA internet mesafesi (round trip time) tahmininde de kullanılabilir. N kullanıcıları bir ağda, NOMA yardımıyla tüm ikili N makinaları mesafesi $O(n)$ ölçümle bulunabilir. Bu metot, ilk defa İnternet Uzaklığı Tahmin Servisi (İnternet Distance Estimation Service (IDES))'te kullanılmıştır. Sonrasında, tam merkeziyetçi olmayan yaklaşımla Phoenix ağ koordinat sistemine uygulanmıştır [12]. Bu yaklaşım "ağırlık" kavramını kullanarak tahmin doğruluğunu yükseltmiştir.

2.3.1.4. Durağan Olmayan Ses Gürültüsüzleştirme

Ses gürültüsüzleştirme, ses sinyali işlemede uzun süredir varolan bir problemdir. Gürültü durağansa bunu çözmek için birçok algoritma bulunmaktadır. Örnek olarak, Wiener filtresi eklemeli Gauss gürültüsü için uygundur. Ancak eğer gürültü durağan değilse klasik gürültüsüzleştirme algoritmaları düşük performans göstermektedir. Çünkü durağan olmayan gürültünün istatistiksel bilgisini kestirmek zordur.

NOMA kullanılarak durağan olmayan gürültülü sesin gürültüsüzleştirilmesi, klasik gürültüsüzleştirme algoritmalarından farklıdır [13]. Ana fikir, temiz sesin ses sözlüğü (speech dictionary) tarafından temsil edilip durağan olmayan gürültünün temsil edilemeyeceğidir. Benzer şekilde, durağan olmayan gürültü de bir gürültü sözlüğüyle (noise dictionary) temsil edilebilir ama ses temsil edilemez. Algoritma şu şekildedir:

Biri ses biri gürültü için olmak üzere iki sözlük hazırlanır. Gürültülü ses verildiğinde, önce kısa zamanlı fourier transformunun (short time fourier transform) büyüklüğü hesaplanır. Sonra NOMA vasıtasıyla bu değer biri ses sözlüğüyle temsil edilebilen diğeri gürültü sözlüğüyle temsil edilen olmak üzere ikiye ayrılır. Son olarak, ses sözlüğüyle temsil edilen bölüm temiz ses olacaktır.

2.3.1.5. Biyoenformatik

Biyoenformatik, biyolojinin çeşitli dalları, ancak özellikle moleküler biyoloji ile bilgisayar teknolojilerini ve bununla ilişkili veri işleme aygıtlarını bünyesinde barındıran bilimsel disiplindir. Bir diğer tanımla, karmaşık biyolojik verilerin derlenmesi ve analiz edilmesi bilimidir.

1960'larda başlayan bilgisayar uygulamalarının biyolojide kullanılması girişimi, her iki alandaki teknolojik gelişime paralel olarak hızla ilerlemiş ve böylelikle ortaya çıkan Biyoenformatik dalı, bugün en popüler akademik ve endüstriyel sektörlerin başına geçmiştir.

Bilgisayarların moleküler biyolojide kullanımı; üç boyutlu moleküler yapıların grafik temsili, moleküler dizilimler ve üç boyutlu moleküler yapı veritabanları oluşturulması ile başlamıştır. Kısa sürede çok yüksek miktarlarda veri üreten, endüstri düzeyinde gen ekspresyonu, protein-protein ilişkisi, biyolojik olarak aktif molekül araştırmaları, bakteri, maya, hayvan ve insan

genom projeleri gibi biyolojik deneylerin doğurduğu talep sonucunda, bu alandaki bilişim uygulamaları neredeyse takip edilemez bir hızda gelişmiştir.

2.3.1.6. Nükleer Görüntüleme

Canlılara verilen radyoaktif maddelerin yaydıkları ışınların, özel yöntemler veya aygıtlarla dışarıdan sayımı ya da görüntü olarak izlenmesi ya da tanımlanması ile tanı konulmasını sağlayan tekniktir. NOMA, bu alanda etmen analizinde (factor analysis) kullanılır. 1980'lerden beri tek foton ışımasıyla hesaplanmış tomografi (Single-photon emission computed tomography -SPECT) ve pozitron ışımalı tomografi (Positron emission tomography -PET) dinamik medikal görüntülemeindeki görüntü dizilerinin analizinde kullanılmaktadır.

2.3.1.7. Yüz Tanıma

Biyometri, kişilerin fiziksel ve davranışsal özelliklerini göz önüne alarak yürütülen kimlik belirleme çalışmaları olarak tanımlanır. Bu kişi özelliklerine örnek olarak, retina ve iris görüntüleri, el geometrisi, aya ve parmak izleri, elin damar görüntüsü, konuşma sesi, yüz özellikleri, kulak memesi, yürüyüş, klavye kullanım, konuşma devinimleri örüntüleri verilebilir. Daha genel anlamda, biyometri bilişim teknolojilerinin bir parçası olup, insanların fiziksel özelliklerini ve davranış biçimlerini irdeleyip kişiyi tanıma amaçlı ipuçları çıkaran bir bilim dalıdır. Yüz tanıma da bu biyometrikin içinde yüz özelliklerine bağlı insan tanıma metodlarından biridir. Yüz tanımadaki üç temel unsur şöyle tanımlanır:

Kişi tanılama: Bir nüfus dağarcığı içinde bir kişinin kim olduğunu anlamak.

Kişi doğrulama: Belirli bir kimlik savıyla başvuran kişinin savının doğru olup olmadığını anlamak.

Kişi onaylama: Kişinin önceden kayıtlı kişi olup olmadığını, kayıtlı ise bu kaydın güncellenmesini sağlamak.

NOMA ile diğer bazı yüz tanıma algoritmalarından farklı olarak, yüzün bir kısmı kapalı olsa bile yüz tanınabilir. NOMA, bütüncül gösterimleri öğrenebilen vektör nicemleme (vector quantization) ve temel bileşenler analizinin (principal component analysis) aksine yüzlerin parça tabanlı gösterimlerini öğrenebilir [27]. Böylece gözlüklü, şapkalı vs. gibi yüzün bir kısmını örten nesneler barındıran yüzlerin öğrenilip tanınması mümkün olmaktadır [28].

Yüz kendine has özelliklere, girinti ve çıkıntılara sahiptir. Yüz tanıma yazılımları, bu noktaları düğüm noktaları olarak adlandırır ve bu düğüm noktalarına göre yüz tanıma işlemi gerçekleştirir. İnsan yüzünde yaklaşık 80 tane düğüm noktası vardır. Yazılım tarafından işlenen bu noktaların bazıları gözlerin birbirine olan uzaklığı, burnun genişliği, göz çukurunun derinliği, elmacık kemiğinin şekli, çene kemiğinin uzunluğunu tespit etmede kullanılır.

2.3.1.8. Robotik

Demografik değişikliklerden dolayı evde bakım hizmetleri ve huzur evlerinde yardımcı sistemlere sahip olmak önemli hale gelecektir. Robot sistemleri belli çözümler sunmaktadır ve doğal insan yüzü robotlar kullanıcılar tarafından kabul edilmek için önemli bir özelliktir. Bu yüzden, otomatik ses tanıma bu tür yardımcı sistemler için gelecek vadeden bir modeldir. Ancak hareket esnasında çıkardıkları seslerden dolayı otomatik ses tanıma performansını düşürmektedir. NOMA kullanılarak robotların hareket ederken çıkardıkları ses, tanınmak istenen insan sesinden ayrılmaktadır ve robot insan konuşmalarını anlayabilmektedir [38].

2.3.1.9. Saldırı Tespiti (Intrusion Detection)

Bir bilgisayar sistemine saldırı tesbitinin verimli yollarından biri program ve kullanıcı davranışlarını tespit etmektir. Bu yeni metotta, veri kaynağı sistem çağrılarıdır. Veri, sabit boyutlu segmentlere ayrılır. Program ve kullanıcı davranışları bireysel sistem çağrısı sıklığına ve her veri segmentinin içine gömülmüş komutların sıklığına göre ölçülür.

NOMA, normal davranışların ait olduğu veri segmentlerine uygulanarak özellik çıkarmada (feature extraction) kullanılır. Program ve kullanıcıların normal davranışlarını tanımlayan model bu özellikler kullanılarak inşa edilir. Önceden belirlenmiş bir eşik noktası üzerinde özellik gösteren kullanıcı ve programlar, anormal davranışlı olarak tanımlanır [45,46].

2.3.1.10. Gözetleme Türü Videolarda Arka Plan Modelleme

Videolarda arka plan modelleme problemi, günümüzde birçok uygulama için önemli bir bileşen olarak ortaya çıkmaktadır. Başarılı bir arka plan modeli sayesinde sabit bir kamera ile çekilmiş video sahnelerindeki hareketli ön plan nesnelerinin ayrıştırılması mümkün olmakta, bu sayede de sahnenin önemli bileşenleri daha detaylı ve verimli işlenebilmektedir. Arka plan modelleme, trafik kontrolü başta olmak üzere günümüzde birçok alanda kullanılmaktadır [41].

2.3.2. NOMA Arařtırmaları

NOMA'da arpanların global minimumunun bulunması [18], büyük miktarda veriye uygulanabilir olacak şekilde öleklenebilir olması [19], yeni veri geldiğinde bařtan hesaplama yapmaya gerek duymadan arpana ayırma iřleminin güncellenmesi [20], birleřik arpanlara ayırma (Joint Factorization) olarak adlandırılabilcek oklu iliřkili matrislerin (multiple interrelated matrices) oklu görüntülü öğrenme (multiple-view learning) için arpanlarına ayrılması [21] için alıřmalar yapılmaktadır.

2.3.3. NOMA Türleri

Bazı farklı özelliklerinden dolayı, literatürde alıřılmış olan NOMA türleri, bařlıca beř gruba ayrılır.

2.3.3.1. Yaklařık NOMA (Approximate NMF)

Genellikle W 'nin sütun sayısı ve H 'nin satır sayısı WH arpımı V 'ye yakın olacak şekilde seilir. V 'nin ayrılması sonucu W ve H arpanlarına ve bir kalana ayrılır: $V = WH + U$. U adı verilen kalan matrisinin elemanları negatif ya da pozitif olabilir. W ve H V 'den küçük oldukları zaman depolaması ve kullanılması kolaylařır. V 'yi küçük W ve H arpanlarına ayırmanın bir bařka nedeni ise V daha küçük matrislere ayrıldığında verideki gizli bilginin saptanması kolaylařır.

2.3.3.2. Yakınsak NOMA (Convex NMF)

Standart NOMA'da, W 'nin elemanları pozitif reel sayıların herhangi bir üyesi olabilir. Yakınsak NOMA, W 'nin sütunlarını veri vektörü $(v_1, \dots, v_n)$ girdilerinin yakınsak kombinasyonları olması řartını kullanarak kısıtlar [22]. Bu, W matrisinin veri temsili (data representation) kalitesini büyük ölüde arttırır. Dahası, H matrisi daha seyrek (sparse) ve ortogonal hale gelir.

2.3.3.3. Negatif Olmayan Derece arpanlarına Ayırma

V 'nin negatif olmayan derecesinin (rank) gerek derecesine eřit olması durumunda $V = WH$ denklemi negatif olmayan derece arpanlarına ayırma olarak adlandırılır [23]. V 'nin negatif olmayan derece arpanlarına ayırma deėerini bulma problemi deterministik olmayan polinom zamanlı zorlukta (non-deterministic polynomial-time hard (NP-hard)) bir problemdir.

2.3.3.4. Değişik Maliyet Fonksiyonları ve Düzenlemeler

V ve W arasındaki ıraksaklığın (divergence) ölçülmesi için kullanılan maliyet fonksiyonları V ve W matrislerinin düzenlenmesine (regularization) bağlı olarak değişik NOMA türleri vardır [24]. Hatanın karesi (squared error) ve Kullback-Leibler ıraksaklığının genişletilmiş hali olan iki basit ıraksaklık fonksiyonu Lee ve Seung tarafından önerilmiştir. Bu iki metodun her biri iteratif güncelleme kurallarıyla ıraksaklığı minimize eden iki değişik NOMA algoritmasına öncülük eder. NOMA'nın "hatanın karesi" algoritmasındaki problemi verilen bir V matrisinden öyle 2 matris bulunsun ki

$$F(W, H) = ||V - WH||_F^2 \quad (2.8)$$

denklemini minimize etsin.

Bir başka görüntü için NOMA türü toplam varyasyon normudur [25]. L1 düzenlemesi hatanın karesi maliyet fonksiyonunu kullanan NOMA'ya eklendiğinde ortaya çıkan problem, NOMA olarak adlandırılrsa da, seyrek kodlama (sparse coding) problemine benzediği için negatif olmayan seyrek kodlama (non-negative sparse coding) olarak da adlandırılır.

2.3.3.5. Online NOMA

Birçok standard NOMA algoritması, tüm veriyi birlikte analiz eder. Bir başka ifadeyle bütün matris verisi başlangıçta vardır. Bu durum, belleğe aktarılacak verinin çok olduğu durumlarda ya da veri bir akışla (stream) sağlandığı durumlarda yetersizdir. Bu tür bir durum birçok kullanıcı ve önerilecek kayıt olduğu öneri sistemlerinde olabilir. Bu tür bir sistemde yeni bir kullanıcı ya da önerilecek kayıt eklendiğinde herşeyi baştan hesaplamak verimsiz olacaktır. Bu durumlarda optimizasyon için maliyet fonksiyonu NOMA ile aynı olabilir ya da olmayabilir ama algoritmaların değişik olması gerekmektedir [26].

2.3.3.6. Kuadratik NOMA (Quadratic NMF)

NOMA'da negatif olmayan bir matris düşük ranklı çarpan matrislerinden yakınlştırılır (approximate). Çoğu NOMA metodu, her çarpan matrisin yakınlştırmada (approximation) sadece bir kere belireceğini varsayar ve böylece yakınlştırma çarpan matrislerinde lineerdir. Kuadratik NOMA'da ise bazı çarpan matrislerin yakınlştırmada iki kere belirdiği yeni bir

yaklaşık NOMA metotları sunulmuştur. Çeşitli metriklerle göre yakınlaştırma hatasını monoton bir şekilde azaltan çarpımsal algoritmalar bu çalışmada türetilmiştir [31].

2.3.3.7. Seyrek NOMA (*Sparse NMF*)

NOMA, bazı uygulamalarda parça tabanlı gösterimler bulsa da her zaman bu gerçekleşmeyebilir. Seyrek NOMA ile seyreklik kavramından dolaysız bir şekilde yararlanmanın, parça tabanlı gösterimler bulmayı artırmıştır [32].

2.3.3.8. Korentropi Temelli NOMA (*Correntropy-Based NMF*)

Korentropi, iki rastgele değişkenin benzerliğini ölçen, lineer olmayan yerelleştirilmiş benzerlik ölçütüdür. Korentropi temelli NOMA'da önerilen genel çarpımsal faktörizasyon algoritması, veri matrisi ve çarpan matrisleri arasındaki korentropi benzerliğini artırmak için gradyan azaltma metodu kullanılır [28, 33].

2.3.3.9. Bayeşçi NOMA (*Bayesian NMF*)

Normal benzerlikler ve üstel önceliklere dayanılarak NMF'nin Bayeşçi versiyonu sunulmuştur. NOMA çarpanlarının ardıl yoğunluğunu yakınlaştırmak için verimli bir Gibb örnekleyicisi türetilmiştir. Beyin resmi veri setlerinde belirsizlik tahminlerini vererek yorumlanabilirliğin arttığı gözlemlenmiştir [34]. İlgili çalışmada Gibbs örnekleyicisi model ve sıra seçiminde marjinal benzerliğin tahminiyle nasıl kullanılabileceği tartışılmış ve Bayeşçi bilgi kriteri ile karşılaştırılmıştır. Maksimum "a posteriori" tahmini hesaplamak için hali hazırdaki NOMA algoritmalarına rakip olabilecek bir döngüsel koşullu modlar (iterated conditional modes) algoritması sunulmuştur.

2.3.3.10. Olasılıksal NOMA (*Probabilistic NMF*)

NOMA, deterministik bir çerçevenin olduğunu varsayar. Özelde, veri gürültüsünün faktörizasyonun stabilitesine etkisi ve algoritmanın yakınsaması bilinmez. Toplanan veri ise ölçüm gürültüsünden dolayı olasılıksal (stochastic) bir doğaya sahiptir ve bazen fiziksel süreç içerisinde değişkenliği (variability) beraberinde getirebilir. Olasılıksal NOMA'da bu probleme yeni teorik ve uygulamalı geliştirmeler sunulmuştur [35].

2.3.3.11. Düzgün Olmayan NOMA (Nonsmooth NMF)

Düzgün olmayan NOMA'da çok değişkenli verilerin yerel, parça temelli gösterimlerini bulmayı amaçlayan bir NOMA modeli önerilmiştir. Klasik NOMA tekniklerinin aksine bu yeni model dolaysız bir şekilde seyrekliği (sparseness) temsil eden ve belirsiz olmayan maliyet fonksiyonlarının, tek bir parametre tarafından kontrol edilen düzgün olmayan bir şekilde (nonsmooth) bir şekilde optimizasyonunu amaçlar [36]. Genelde bu metot sadece orijinal verinin gösterimiyle kalmayıp aynı zamanda kendini gelişmiş yorumlanabilirlik (interpretability) olarak gösteren yüksek seviyede yerleştirilmiş örüntüler ortaya çıkarır.

2.4. KARŞIT TEMELLİ ÖĞRENME (OPPOSITION BASED LEARNING)

Öğrenme, optimizasyon ve arama makine öğrenme araştırmalarındaki temel kavramlardır. Algoritmalar geçmiş verilerden öğrenir, tahmini çözümleri optimize eder ve geniş bir çözüm kümesinde varolan çözümü arar. Problemler çeşitli disiplinlerden; çözüm ise çeşitli biyolojik, davranışsal ve doğal fenomenlerden esinlenilerek oluşturulur.

Ne zaman bir problemin bir x çözümüne bakılıyorsa genelde x' gibi bir tahmin yapılır. Bu tahmin kesin çözüm değildir ve bu tahmin genelde tecrübeye bağlı olabilir ya da tamamen rastgele seçilebilir. Karmaşık problemlerde genelde rastgele bir çözüm seçilir. Rastgele değer atama problemi yapay sinir ağları gibi karmaşık problemlerin bağlamına girmektedir [37].

Yapay sinir ağlarında ağırlıklara rastgele ilk değer atanması problemi bazı durumlarda x' çözümü yeterlidir ya da optimal çözüm biliniyorsa çözüm iyileştirilmeye devam edilir. Bu bağlamda eğer problem bir fonksiyon yaklaşıklarıyla problemiye hesaplama karmaşıklığı gözönünde bulundurulmalıdır. Bir çözüm bulunabilir ancak kabul edilebilir bir hesaplama zamanı sağlamıyor olabilir.

Bir çok durumda öğrenme rastgele bir noktadan başlar ve varolan bir çözüme doğru ilerlemesi umulur. Bir yapay sinir ağının ağırlıkları rastgele ilk değer alır. Genetik algoritmalarındaki parametre popülasyonu rasgele olarak ayarlanır. Rastgele tahmin eğer optimum çözümden uzakta değilse hızlı bir yakınsamayla sonuçlanabilir. Ancak optimum çözümden uzaktaysa ya da en kötü durum olarak optimum çözümün tam zıttıysa, arama ya da optimizasyon süresi farkedilir bir şekilde artabilir. Ön bilgi yokluğunda en iyi tahmin yapılamaz. Mantık olarak tüm yönler aynı anda bakmak ya da daha somut olmak gerekirse zıt yöne bakılmalıdır. Sözelimi

bir x çözümü aranıyorsa ve zıt yönde arama faydalı olduğu düşünülüyorsa ilk adım olarak x 'in zıttındaki x' hesaplanır.

$[a,b]$ aralığındaki bir x noktası nın zıttı şöyle tanımlanır:

$$x' = a + b - x \quad (2.9)$$


Bu eşitlik çok boyutlu bir durumda da geçerlidir:

$P(x_1, \dots, x_n$ ve $x_i [a_i, b_i]$ aralığında) noktasının zıttı:

$$x'_i = a_i + b_i - x_i \quad (i = 1, 2, \dots, n) \quad (2.10)$$

Bu bilgi ışığında karşıt temelli öğrenme matematiksel olarak şöyle tanımlanır:

$f(x)$ ele alınan fonksiyon, $g(.)$ bu fonksiyona uygun bir değerlendirme fonksiyonu (evaluation function) olsun. $X [a, b]$ aralığında bir başlangıç değeri ve x' bu değerin zıttı olduğunda her iterasyonda $f(x)$ ve $f(x')$ hesaplanır. $g(f(x)) \geq g(f(x'))$ ise KTÖ x ile devam eder, değilse x' ile devam eder. Bir optimumluk ölçüsü olarak $g(.)$ fonksiyonu sonuçların uygunluğunu karşılaştırır.



Şekil 2.4: Tek boyutlu eşitliğin çözülme adımları.

Şekil 2.4'teki $[a_1 b_1]$ çözüm aralığı için çözüm tekrarlı bir şekilde tahmin ve karşı tahminin incelenmesiyle bulunabilir. Başlangıç çözümü x_0 'ın zıttı x üretilir. Varolan çözüme yakınlıklarına göre 2'ye bölünen çözüm aralığının ilgili yarısından devam edilir ve varolan çözüme yeteri kadar yaklaşılan kadar devam edilir.

3. MALZEME VE YÖNTEM

Yukarıda bahsedilen NOMA algoritmasının hızlandırılması amacıyla bu algoritmaya KTÖ algoritması uygulanacaktır. Test için kullanılan sistem Ubuntu 14.04 64 bit, Intel Core i7 1.90 GHz. 4 GB Ram özelliklerine sahiptir. Yazılan MATLAB kodu MATLAB R2015a versiyonunda çalıştırılmıştır. Test etmek amacıyla AR ve ORL yüz veritabanı kullanılmıştır. AR Face (kırılmış versiyonu) veritabanı 50 kadın 50 erkeğin çeşitli şekillerde (güneş gözlüklü, ağzı açık, gözü kapalı vs.) 26 pozunu içermektedir. Resim numarasına göre:

1 nötr, 2 gülümseyen, 3 kızgın, 4 bağırarak, 5 soldan ışık, 6 sağdan ışık, 7 her yönden ışık, 8 güneş gözlüklü, 9 güneş gözlüklü soldan ışık, 10 güneş gözlüklü sağdan ışık, 11 atkılı, 12 atkılı soldan ışık, 13 atkılı sağdan ışık olacak şekilde ayarlanmış fotoğraflar içerir.

Diğer 13 fotoğraf ise farklı bir günde ve aynı özellikleri taşıyan fotoğraflar içerir. Matlab kodlarında bu fotoğraflar 56 x 26'lık fotoğraflara dönüştürülmüştür.



Şekil 3.1: AR yüz veri tabanından örnek 3 farklı kişinin 8 farklı pozunu.

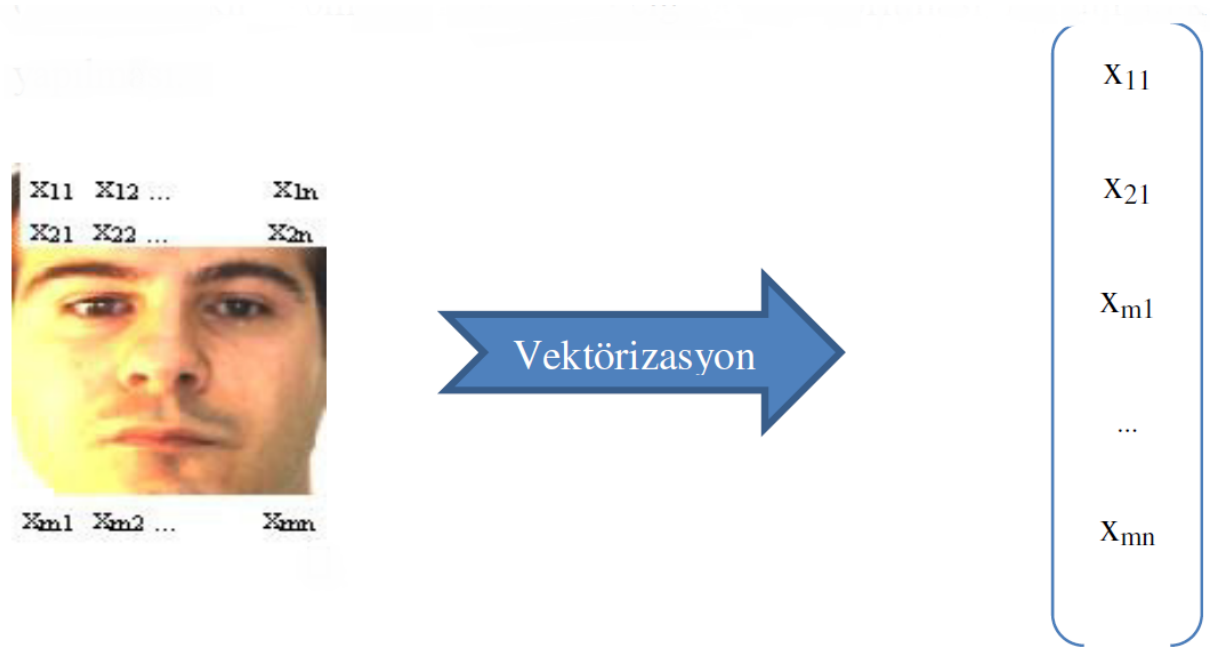
ORL yüz veritabanı ise 40 kişinin 10 farklı cepheden çekilmiş fotoğraflarını içerir. Fotoğraflar Nisan 1992 – Nisan 1994 tarihleri arasında farklı zamanlarda, değişik ışık şiddetleri altında, değişik yüz ifadeleri (açık/kapalı göz, gülen/gülmeyen) ve detayları (gözlüklü/gözlüksüz) fotoğraflar barındırır. Fotoğrafların hepsinin arka planı koyu ve homojendir. NOMA ve KTÖ sentezi algoritması MATLAB programlama dilinde gerçekleştirilmiştir.



Şekil 3.2: ORL yüz veri tabanından örnek 4 farklı kişi ve 7 farklı poz.

Algoritma aşağıdaki süreçlerden oluşur:

1. Fotoğrafların okunup vektörize edilmesi
2. NOMA eşitliğindeki V matrisinin oluşturulması
3. Başlangıç W matrisinin rastgele değerlerle oluşturulması
4. ÇGF'nin W ve H matrisine ve KTÖ uygulanmış hallerine uygulanması
5. Adım 4 sonunda W ve H matrisi ve KTÖ uygulanmış halleri için uygulanan ÇGF'de oluşan hata değerlerinden herhangi biri istenen hata değerinden küçükse uygulamanın sonlandırılması; değilse 4. adımın güncel W ve H değerleriyle tekrarlanması.
6. 1-en yakın komşu (1-nearest neighbor) algoritması kullanılarak kişi tahmininin yapılması.



Şekil 3.3: Fotoğrafların vektörizasyonu.

Şekil 3.3'te $m \times n$ boyutlu bir fotoğrafın yüz tanıma sürecinin 1. adımındaki vektörizasyonu gösterilmektedir. Vektörizasyon sonrası $m \times n$ boyutlu fotoğraf $mn \times 1$ boyutlu bir vektöre çevrilmiştir.

Karşılaştırma için kullanılan algoritmalarından DNOMA, değişen en küçük kareler (alternating least squares) algoritmasının NOMA'ya uygulanmış halidir [42]. Grafiklerde belirtilen NOMA ise güncelleme fonksiyonu olarak ÇGF kullanılan NOMA'dır.

NOMA'dan farklı olarak bir de TBA karşılaştırma için kullanılmıştır. TBA ile ilgili açıklama bölüm 2.2.7'de görülebilir.

NOMA ve KNOMA, NOMAA ve PCA algoritmaları her resim veritabanı üzerinde, 10 defa çalıştırılarak çıktıların ortalaması alınarak grafikleri oluşturan değerler elde edilmiştir. Doğruluk (accuracy), her iki yüz veritabanındaki kişilerin toplam pozunun yarısı olan test resimlerinin doğru tahmin edilme sayısının yüzde cinsinden ifade edilmektedir.

4. BULGULAR

NOMA, KNOMA, DNOMA ve TBA algoritmalarının MATLAB'da gerçeklenip AR ve ORL yüz veritabanları üzerinde çalıştırılması sonucu aşağıdaki sonuçlar elde edilmiştir.

Grafikler incelendiğinde genel olarak bazı baz imajlarda KNOMA'nın yüz tanıma oranı ve süresinde NOMA ve DNOMA ve TBA'ya üstün geldiği görülmüştür.

Yüz tanıma grafiklerinde AR yüz veritabanında 64, 100 ve 144 baz imajlı yüz tanıma KNOMA NOMA'ya üstün gelirken diğer baz imaj sayılarında tersi gözlemlenmiştir.


Özellikle 100 baz imajda KNOMA'nın açık bir şekilde diğer algoritmalarından daha yüksek bir yüz tanıma doğruluk oranına (accuracy) sahip olduğu görülmektedir. Bu nedenle doğruluk oranının yüksek istendiği uygulamalarda bu nokta kullanılabilir.

Yüz tanıma sürelerinde ise AR yüz veritabanında NOMA daha kısa sürerken, ORL yüz veritabanında ise 49, 64 ve 100 baz imajlarda KNOMA'nın daha kısa sürdüğü gözlemlenmiştir. Ayrıca en yavaş algoritma bu grafiklere göre DNOMA'dır. KNOMA'nın uzun işlem yaptığı k noktalarında çözüm uzayını taradığı ve lokal ekstremum kaldığı saptanmıştır.

Bu bilgilere göre 64 baz imaj kullanılarak gerçekleştirilen yüz tanıma işleminde KNOMA hem yüz tanıma oranında hem de yüz tanıma süresinde NOMA'ya göre daha iyi çalışırken; DNOMA ve TBA'ya göre sadece yüz tanıma oranı bakımından daha iyi sonuçlar vermektedir.


Yapılan deneysel çalışmaların yüz tanıma süreleri ve doğruluk oranları Şekil 4.1, Şekil 4.2, Şekil 4.3, Şekil 4.4, Tablo 4.1, Tablo 4.2, Tablo 4.3, Tablo 4.4'te sunulmuştur.

Tablo 4.1'de görüldüğü gibi $k = 100$ 'e kadar bazı k değerlerinde KTÖ üstünlük sağlasa da $k = 100$ 'den sonra tanıma oranı düşmektedir.




Şekil 4.1: AR için tanıma yüzdeleri.

NOMA ve KNOMA algoritmalarının MATLAB'da gerçekleştirilip ORL yüz veritabanı üzerinde çalıştırılması sonucu aşağıdaki sonuçlar elde edilmiştir.




Şekil 4.2: AR için yüz tanıma süreleri.

Tablo 4.4'te görüldüğü gibi $k = 81$ 'e kadar KNOMA üstünlük sağlarken $k = 81$ 'den sonra NOMA daha iyi çalışmaktadır.



Şekil 4.3: ORL için yüz tanıma süreleri.



Şekil 4.4: ORL için yüz tanıma oranları.

Tablo 4.1: AR yüz tanıma oranları.

Baz imaj (k)	49	64	81	100	121	144
NOMA	83.45	83.35	83.75	83.75	83.2	82.45
KNOMA	83.25	83.8	83.55	84.15	82.3	82.55
DNOMA	83.2	83.56	83.09	83.45	83.14	82.21
TBA	83.68	83.49	83.27	83.61	83.35	82.82

Tablo 4.2: AR yüz tanıma süreleri.

Baz imaj (k)	49	64	81	100	121	144
NOMA	12.64	6.20	4.76	4.67	4.98	5.04
KNOMA	23.89	11.15	9.22	8.83	9.69	9.98
DNOMA	16.59	10.18	13.36	9.71	11.42	12.43
TBA	10.19	5.21	6.12	4.67	5.04	4.46

Tablo 4.3: ORL yüz tanıma süreleri.

Baz imaj (k)	49	64	81	100	121	144
NOMA	62.5	69.1	77.8	107	94.4	105.6
KNOMA	64.2	69.8	78	103	96.4	106.4
DNOMA	69.76	81.23	82.99	118.1	100.23	109.94
TBA	60.16	70.98	79.47	100.06	88.58	100.62

Tablo 4.4: ORL yüz tanıma oranları.

Baz imaj (k)	49	64	81	100	121	144
NOMA	82.25	80.8	80.10	83	77.4	75.9
KNOMA	82.8	81.75	80.25	82.5	76.2	75.45
DNOMA	81.83	80.19	81.64	80.72	75.93	75.04
TBA	82.96	79.52	81.01	79.98	78.23	74.91

5. TARTIŞMA VE SONUÇ

AR yüz veri tabanı için $k = 49$ noktasında TBA en iyi yüz tanıma oranına ve süresine sahipken, $k = 64$ noktasında DNOMA en iyi tanıma oranı ve TBA en iyi süreye sahiptir. $k = 81$ noktasında ise NOMA en iyi tanıma oranı ve süresine sahipken, $k = 100$ noktasında KNOMA en iyi tanıma oranı ve NOMA da en iyi süreye sahiptir. 83,35 ile TBA $k = 121$ noktasında en iyi tanıma süresine ve NOMA en iyi süreye sahiptir. $k = 144$ noktasında ise KNOMA tanıma oranında birinciyken TBA en iyi süreye sahiptir.

ORL yüz veri tabanında $k = 49, k = 100, k = 121, k = 144$ noktalarında TBA; $k = 64$ ve $k = 81$ noktasında NOMA en iyi süreye sahiptir. ORL yüz veritabanında tanıma oranları incelendiğinde $k = 49$ ve $k = 121$ noktalarında TBA en iyi tanıma oranına sahipken; $k = 64$ noktasında KNOMA, $k = 81$ noktasında DNOMA, $k = 100$ ve $k = 144$ noktalarında NOMA en iyi tanıma oranına sahiptir.

NOMA, KNOMA, DNOMA ve TBA AR ve ORL yüz veritabanlarında çalıştırıldığında KNOMA'nın iterasyon sayılarında klasik NOMA'dan üstün olduğu görülse de, iterasyon içinde değerin karıştının alınması işlemi gerçekleştirildiği için çalışma zamanında klasik NOMA'dan geri kalmaktadır. Tanıma oranında ise KNOMA'nın bazı baz imaj sayılarında tanıma oranının yüksek olduğu gözlemlenmiştir. Böylece yüz tanıma işleminde belirli bir iyileşme sağlanmıştır.

NOMA'da başlangıç matrisi oluşturulurken verilen rastgele değerler yerine, yüz tanıma testinde kullanılan yüz veri tabanlarının fotoğraflarının ortalama değerinin atanması algoritmayı daha da hızlandırabilir.

İleride yapılacak araştırmalarda NOMA için farklı öğrenme yöntemleri kullanılarak daha iyi doğruluk oranları elde edilebilir. Ayrıca bu tez kapsamında yapılan yüz tanıma uygulama alanı dışında biyoenformatik, robotik, ses ve diğer görüntü verileri üzerine uygulanabilir.

Bunların dışında NOMA türlerinden Yaklaşık NOMA (Approximate NMF), Yakınsak NOMA (Convex NMF), Negatif Olmayan Derece Çarpanlarına Ayırma, Online NOMA, Kuadratik NOMA (Quadratic NMF), Seyrek NOMA (Sparse NMF), Korentropi Temelli NOMA (Correntropy-Based NMF), Bayesçi NOMA (Bayesian NMF), Olasılıksal NOMA

(Probabilistic NMF) ve Düzgün Olmayan NOMA (Nonsmooth NMF) algoritmalarından faydalanarak algoritmalarda iyileştirmeler yapılabilir.



KAYNAKLAR


- [1]. Lee, D. D. ve Seung, S. S., 1999, Algorithms for Non-negative Matrix Factorization, *Nature*, 401, 788-791.
- [2]. Rahnamayan, S. ve Tizhoosh, H.R., 2008, Opposition-based Differential Evolution, *IEEE*, (Cilt 12), 64-79.
- [3]. Balaban, M. E. ve Kartal, E., 2015, *Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları*, 1. Baskı, Çağlayan Kitabevi, İstanbul, ISBN: 978-975-436-089-9.
- [4]. Silahtaroglu, G., 2013, *Veri Madenciliği Kavram ve Algoritmaları*, 2. Baskı, Papatya Yayıncılık, İstanbul, ISBN: 978-975-6797-81-5.
- [5]. Turk, M.A., Pentland, A.P., 1991, Face recognition using eigenfaces, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*.
- [6]. Akpınar, H., 2014, *Data: Veri Madenciliği Veri Analizi*, 1. Baskı, Papatya Yayıncılık, İstanbul, ISBN: 978-605-4220-81-6.
- [7]. Özkan, Y., 2013, *Veri Madenciliği Yöntemleri*, 2. Baskı, Papatya Yayıncılık, İstanbul, ISBN: 978-975-6797-82-2.
- [8]. Berry, M. W., Browne, M., 2005, Email Surveillance Using Non-negative Matrix Factorization, *Computational and Mathematical Organization Theory* (Cilt 3), 249–264.
- [9]. Nielsen, F. A., 2008, *Clustering of scientific citations in Wikipedia* , Wikimania.
- [10]. Arora, S. ve diğerleri, 2013, *A practical algorithm for topic modeling with provable guarantees*.
- [11]. Michael W. B. ve diğerleri, 2006, *Algorithms and Applications for Approximate Nonnegative Matrix Factorization*, Elsevier, 52, 155-173.
- [12]. Yang C., ve diğerleri, 2011, Phoenix: A Weight-based Network Coordinate System Using Matrix Factorization, *IEEE Transactions on Network and Service Management*, 8, 334-347.
- [13]. Schmidt, M.N., ve diğerleri, 2007, Wind Noise Reduction Using Non-Negative SparseCoding, *Machine Learning for Signal Processing, IEEE Workshop*, 431 – 436.
- [14]. Devarajan, K., 2008, Nonnegative Matrix Factorization: An Analytical and Interpretive Tool in Computational Biology, *PLoS Computational Biology*, 7.
- [15]. Hyunsoo K. ve Haesun P., 2007, Sparse non-negative matrix factorizations via alternating non-negativity-constrained least squares for microarray data analysis, *Bioinformatics*, 12, 1495–1502.

- [16]. Taslaman, L. ve Nilsson B., 2012, A framework for regularized non-negative matrix factorization, with application to the analysis of gene expression data, *PLOS One* 7.
- [17]. Schwalbe, E., 2013, DNA methylation profiling of medulloblastoma allows robust sub-classification and improved outcome prediction using formalin-fixed biopsies, *Acta Neuropathologica* 3, 359–371.
- [18]. Boutsidis, C. ve Gallopoulos, E., 2008, SVD based initialization: A head start for nonnegative matrix factorization, *Pattern Recognition* 4, 1350–1362.
- [19]. Liu, C. ve diğerleri, 2010, *Distributed Nonnegative Matrix Factorization for Web-Scale Dyadic Data Analysis on MapReduce*, 19. Uluslararası WWW Konferansı.
- [20]. Wang, D. ve diğerleri, 2013, Online Non-Negative Convolutional Pattern Learning for Speech Signals, *IEEE Transactions on Signal Processing* 61, 44–56.
- [21]. He X. ve diğerleri, 2014, Comment-based Multi-View Clustering of Web 2.0 Items, 23, *Uluslararası WWW Konferansı*.
- [22]. Ding, C., ve diğerleri, 2010 , Convex and Semi-Nonnegative Matrix Factorizations, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32, 45-55.
- [23]. Berman, A., Plemmons R.J., 1974, *Inverses of nonnegative matrices*, *Linear and Multilinear Algebra*, 2, 161–172.
- [24]. Inderjit S. D., Suvrit S., 2005, Generalized Nonnegative Matrix Approximations with Bregman Divergences, *NIPS Konferansı*.
- [25]. Zhang, T. ve diğerleri, 2008, Total variation norm-based nonnegative matrix factorization for identifying discriminant representation of image patterns, *Neurocomputing* 71, 1824–1831.
- [26]. Guan, N. ve diğerleri, 2012, Online Nonnegative Matrix Factorization With Robust Stochastic Approximation, *IEEE Transactions on Neural Networks and Learning Systems*, 7, 1087-1099.
- [27]. Lee, D. ve Seung, H., Learning the parts of objects by non-negative matrix factorization, 1999, *Nature*, 401, 788-791.
- [28]. Ensari, T. ve diğerleri, Occluded Face Recognition Using Correntropy-based Nonnegative Matrix Factorization, 2012, *11. Uluslararası Makine Öğrenmesi ve Uygulamaları Konferansı*.
- [29]. Zurada, J. M. ve diğerleri, 2013, *Bilgisayar Bilimi ve Bilgi Sistemleri Konferansı Bildirileri*, 11-16.
- [30]. Han J. ve diğerleri, 2014, *Yirminci uluslararası Bilgi Keşfi ve Veri Madenciliği Konferansı bildirileri*, New York, 1968.

- [31]. Yank Z. Ve Oja E., 2012, *Quadratic Nonnegative Matrix Factorization*, *Pattern Recognition*, 45, 1500-1510.
- [32]. Hoyer P., 2004, Non-negative Matrix Factorization with Sparseness Constraints, *Journal of Machine Learning Research*, 5, 1457-1469.
- [33]. Asl, E. H. ve Zurada, J. M., 2013, *Journal of Applied Computer Science Methods*, 5, 89-104.
- [34]. Schmidt, M. N. ve diğerleri, 2009, Bayesian Non-negative Matrix Factorization In: Independent Component Analysis and Signal Separation, *Springer Berlin Heidelberg*, 540-547.
- [35]. Bayar, B. ve diğerleri, 2014, Probabilistic non-negative matrix factorization: theory and application to microarray data analysis, *Journal of Bioinformatics and Computational Biology*, 4, 12.01: 1450001.
- [36]. Pascual, A. ve diğerleri, 2006, Nonsmooth Nonnegative Matrix Factorization (nsNMF), *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 28 (3) 403-415.
- [37]. Tizhoosh, H. R., 2005, Opposition-Based Learning: A New Scheme for Machine Intelligence, *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce*, Vienna, 2005, 695-701.
- [38]. Cauchi, B. ve diğerleri, 2012, Reduction of non-stationary noise for a robotic living assistant using sparse non-negative matrix factorization, *Proceedings of the 1st Workshop on Speech and Multimodal Interaction in Assistive Environments*.
- [39]. Wang, W. ve diğerleri, 2004, Profiling Program and User Behaviors for Anomaly Intrusion Detection Based on Non-negative Matrix Factorization, *43rd IEEE Conference on Decision and Control*, 14-17 December 2004, Atlantis, Paradise Island, Bahamas.
- [40]. Guan, X. ve diğerleri, 2009, Fast Intrusion Detection Based on a Non-negative Matrix Factorization Model, *Journal of Network and Computer Applications* 32, 31– 44.
- [41]. Bucak, S. S. ve diğerleri, 2007, Incremental Nonnegative Matrix Factorization for Background Modeling in Surveillance Video, *IEEE 15th Signal Processing and Communications Applications*, 2007, Eskisehir, 1-4.
- [42]. Berry, M. W. ve diğerleri, 2007, Algorithms and Applications for Approximate Nonnegative Matrix Factorization, *Computational Statistics and Data Analysis*, Vol. 52, No. 1, 155–173.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	İhsan Koçak
Doğum Yeri	Payas
Doğum Tarihi	09.03.1983
Uyruğu	☒ T.C. ☐ Diğer:
Telefon	05055003353
E-Posta Adresi	ihsankocak@gmail.com
Web Adresi	



Eğitim Bilgileri	
Lisans	
Üniversite	İstanbul Teknik Üniversitesi
Fakülte	Elektrik-Elektronik Fakültesi
Bölümü	Bilgisayar Mühendisliği
Mezuniyet Yılı	22.08.2008

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Bilgisayar Mühendisliği Anabilim Dalı
Programı	Bilgisayar Mühendisliği Programı
Mezuniyet Tarihi	10.11.2016