

BEYİN DATASI MODELLEMESİNDE ÖRGÜ ÖĞRENME YAKLAŞIMI

A MESH LEARNING APPROACH FOR BRAIN DATA MODELING

Orhan Fırat¹, Mete Özay¹, İtir Önal¹, İlke Öztekin², Fatoş T. Yarman Vural¹

¹Bilgisayar Mühendisliği Bölümü
Orta Doğu Teknik Üniversitesi, Ankara
{ orhan.firat, mete.ozay, itir, vural }@ceng.metu.edu.tr

²Psikoloji Bölümü
Koç Üniversitesi, İstanbul
ioztekin@ku.edu.tr

ÖZETÇE

Bu çalışmanın amacı, beyinde gerçekleşen nöral aktivite verilerini kullanarak bellek işlemlerini modellemektir. Bu amaç için belleğe bilgi kaydı ve geri getirme süreçleri sırasında fonksiyonel Magnetik Rezonans Görüntüleme (fMRI: Functional Magnetic Resonance Imaging) yöntemi ile beyin verisinde edilir. Etiketleri bilinen fMRI verileri bir “ öğrenme sistemi” ile her sınıf için eğitilir. Bu öğrenme sisteminin en önemli bileşeni öznelik uzayıdır. Bu çalışmada fMRI verisi için özgün bir öznelik uzayı önerilmektedir. Bu öznelik uzayı vokseller arasındaki ilişkiyi modelleyen bir örgü (mesh) ağı ile belirlenmektedir. Önerilen örgü ağında, vokseller arasındaki mesafe uzamsal ve fonksiyonel komşuluk kavramları kullanılarak belirlenmektedir. Fonksiyonel komşuluk için voksellere elde edilen zaman serilerinin birbirlerine olan benzerlikleri ölçülmüştür. Önerilen yöntem ile belleğe bilgi kaydı ve geri getirme işlemleri için 10 sınıflı bilgi tipinden oluşan bir veri seti kullanılmıştır. Bu şekilde öğrenme algoritmaları ile fMRI datasının hangi sınıfa karşı geldiği belirlenmeye çalışılmış ve elde edilen performans ve başarı ölçütleri bu çalışmada sunulmaktadır.

ABSTRACT

The major goal of this study is to model the memory process using neural activation patterns in the brain. To achieve this goal, neural activation was acquired using functional Magnetic Resonance Imaging (fMRI) during memory encoding and retrieval. fMRI are known to be trained for each class using a learning system. The most important component of this learning system is feature space. In this project, an original feature space for the fMRI data is proposed. This feature space is defined by a mesh network which models the relationship between voxels. In the suggested mesh network, the distance between voxels is determined by using physical and functional neighborhood concepts. For the functional neighborhood, the similarities between the time series, gained from voxels, are measured. With the proposed method, a data set with 10 classes is used for the encoding and retrieval processes, and the classifier is trained with the learning algorithms in order to predict the class the data belongs.

1. GİRİŞ

Beynin bilgiyi, hem fiziksel hem kavramsal düzeyde, nasıl işlediği ve nasıl temsil ettiği önemli bir araştırma problemidir. Bilişsel süreçlerin fiziksel temelleri büyük ölçüde anlaşılmış olsa da bütün bir kavramsal model henüz ortaya

koyulamamıştır. Fonksiyonel MR verisi kullanılarak insan beynini ve bilişsel süreci modellemek, üzerinde yoğun olarak çalışılan ve oldukça zorlu bir alandır. Bilişsel süreçleri beyin verileri üzerinden modellemek amacıyla farklı teknikler geliştirilmiş ve halen geliştirilmektedir. Literatürde bu maksatla geliştirilmiş pek çok yaklaşım mevcuttur. Bu yaklaşımlar genellikle fMRI kullanılarak elde edilmiş olan voksel yoğunluk değerleriyle bir sınıflandırıcı eğitilmesine dayanmaktadır [1][2][3]. Doğrudan voksel yoğunluk değerini kullanan çalışmaların genel olarak gözardı ettikleri nokta, yoğunluk değerlerinin çevrelerinden bağımsız olarak değişmediğidir. Bir vokselin tanımlanmış olan komşuluğundaki yoğunluk değeri değişimini modelleyen çalışmaların daha başarılı olduğu görülmektedir [4]. Bu bildiride, Özay ve diğerlerinin önceki çalışmalarına dayanan [4] ve onu geliştiren bir yöntem sunulmaktadır. Özay ve diğerleri, çalışmalarında beyin belleğe bilgi kaydı ve geri getirme süreçlerini incelemişlerdir ve beyni eğitmeli bir öğrenme sistemi olarak modelleyen bir yaklaşım ortaya koymuşlardır. Belleğe bilgi kaydı sürecinde elde edilen fMRI datası öğrenme datası olarak kabul edilmiştir. Bu data, yerel ilişkisel öznelikler (local relational features-LRF) olarak adlandırılan özneliklerin çıkarılması için kullanılmıştır. Geliştirilmiş olan modelin amacı bellekten geri getirilen bilgiyi, aynı bilgi geri getirme sürecinde elde edilen fMRI verisini ve daha önce çıkartılan LRF kullanarak sınıflandırmaktır.

Bu bildiride, önerilmiş olan örgü öğrenme yaklaşımını iyileştirmek için, örgüyü oluşturan vokseller arasındaki uzaklık metriği farklı yöntemler kullanılarak hesaplanmıştır. Bu yöntemler uzamsal yakınlığı ve fonksiyonel yakınlığı dikkate almaktadır. Fonksiyonel komşuluk için voksellerden elde edilen zaman serilerinin birbirlerine olan benzerlikleri ölçülürken, uzamsal komşuluk için vokseller arasındaki Öklid uzaklıkları göz önünde bulundurulmuştur. Bu sistem farklı sınıflandırıcılar kullanılarak test edilmiştir. Elde edilen sonuçlar göstermektedir ki, beyindeki nöral aktivite verilerini kullanarak bellek işlemlerini modelleme performansı, komşuluk tanımı ve seçimi ile iyileştirilebilmektedir.

Bildirinin devamı şu şekilde düzenlenmiştir. İkinci bölümde deney ve verinin nasıl toplandığı anlatılmış olup, üçüncü bölümde geliştirilen algoritmanın detayları tanıtılmıştır. Sonuç bölümünde ise test sonuçları sunulmuş, algoritmanın değerlendirilmesi yapılmıştır.

2. DENEY VE VERİNİN TOPLANMASI

fMRI verisinin toplandığı deney üç aşamadan oluşmaktadır. Birinci safha belleğe bilgi kaydı amacıyla, katılımcıya kısa

aralıklarla gösterilen, aynı sınıfa ait (örneğin hayvanlar veya meyveler) çeşitli kelimelerin gösterilmesinden oluşmaktadır. Bu aşama esasında toplanan beyin dataları, algoritmanın öğrenme safhasında kullanılmaktadır. İkinci aşama, üçüncü aşama olan bellekten bilgi geri getirme aşamasından önceki evre olup, bu aşamada deneye basit matematiksel problemler çözdürülmektedir. 14 saniyelik bu periyot, bilgi kaydı ve geri getirme süreçlerinin fMRI verileri kullanılarak birbirinden bağımsız ölçülmesine izin vermektedir. Son aşama olan üçüncü aşama ise, geri getirme aşaması olup birinci safhadaki sınıfa ait bir kelimenin test edilmesinden oluşmaktadır. Bu aşamada kaydedilen beyin verileri, algoritmanın test safhasında kullanılmaktadır. Belleğe bilgi kaydı ve geri getirme işlemlerini tetiklemek için, anlamsal yakınlığa göre oluşturulmuş 10 farklı kelime sınıfı kullanılmıştır. Her kelime bir bilgisayar ekranından kullanıcıya gösterilmiştir. Hayvan isimlerinden oluşan bir kelime grubu bu anlamsal sınıflara örnek olarak verilebilir [5][6][7].

Elde edilen fMRI verisi her bir vokselle için bir zaman serisi olacak şekilde kayıt edilmiştir. Voksel konumu \bar{s}_j ile belirtilmekte olup, her bir t_i zamanı için ölçülen voksel yoğunluk değeri $v(t_i, \bar{s}_j)$ olarak ifade edilir. Her bir t_i zamanında beynin bilişsel durumu, bir sınıf etiketi $c_i = 1, \dots, C$ ile ilişkilendirilir. Vokseller beyinde 3 boyutta tanımlandığından her bir $\bar{s}_j = (x_j, y_j, z_j)$ 3 boyutlu bir konum vektördür. Bütün bu ölçümler $D_{ij} = v(t_i, \bar{s}_j)$ olacak şekilde bir $N \times M$ tasarım matrisi D ile temsil edilmektedir. Burada N zaman ölçümlerinin M ise voksellerin sayısıdır.

3. METODLAR

Bu bölümde öncelikle örgü öğrenme algoritması anlatılmış, ardından ise yapılan iyileştirmeler sunulmuştur. Örgü öğrenme algoritmasında, t_i anında, \bar{s}_j voksel koordinatındaki fMRI ölçümlerinin $v(t_i, \bar{s}_j)$, voxel yoğunluk dağılım fonksiyonuna göre çıkarılmış bir veri seti $D = \{v(t_i, \bar{s}_j)\}$ oluşturduğu varsayılmaktadır. Öncelikle veri seti D üzerinde p -komşuluk sistemi tanımlanır. Buna göre bir vokselin örgüyü oluşturan komşuluğu, bir t_i anındaki fiziksel koordinatlarına göre en yakın mesafedeki p tane komşusu olarak belirlenir. Bir voksel $v(t_i, \bar{s}_j)$ için komşuluk şu şekilde tanımlanmaktadır:


$$\eta_1[v(t_i, \bar{s}_j)] = \left\{ \begin{array}{l} v(t_i, \bar{s}_j) : \|\bar{s}_j - \bar{s}_k\| \leq \|\bar{s}_j - \bar{s}_l\|, \\ \forall v(t_i, \bar{s}_j) \in D \end{array} \right\} \quad (1)$$

Bu formülde $\|\cdot\|$ L2 normunu (Öklit normu) göstermektedir. Komşuluk tanımı yapıldıktan sonra, bir voksel için p -komşuluğu yinelemeli olarak ($p-1$)-komşuluktan üretilir. Buna göre vokselin en yakın komşusu $\eta_{p-1}[v(t_i, \bar{s}_j)]^c$ setinden seçilerek o voksel için örgüyü oluşturacak olan komşuluk seti tanımlanmıştır. Her bir voksel $v(t_i, \bar{s}_j)$ için o vokselin en yakın komşuları $\eta_{p-1}[v(t_i, \bar{s}_j)]$ kümesindeki voksellere η_p 'deki en yakın komşu eklenerek (2) numaralı denklemdeki gibi elde edilir:

$$\eta_p[v(t_i, \bar{s}_j)] = \left\{ \begin{array}{l} v(t_i, \bar{s}_j) \cup \eta_{p-1}[v(t_i, \bar{s}_j) : \|\bar{s}_j - \bar{s}_k\| \leq \|\bar{s}_j - \bar{s}_l\|, \\ \forall v(t_i, \bar{s}_j) \in \eta_{p-1}[v(t_i, \bar{s}_j)]^c \end{array} \right\} \quad (2)$$

Bu aşamadan sonra her voksel $v(t_i, \bar{s}_j)$ için p -komşuluk (η_p) üzerinden bir yerel örgü tanımlanır. Tanımlanmış olan bu yerel-örgü, $M(\eta_p[v(t_i, \bar{s}_j)]) = (v(t_i, \bar{s}_j) \in \eta_p, a_{i,j,k} \in A)$, η_p

setindeki vokselleri içermekte olup, şekil 1'de örnek bir yerel-örgü sunulmaktadır.



Şekil 1- Voksel $v(t_i, \bar{s}_j)$ ve yerel komşuluğunu gösteren örgü diyagramı, en yakın 4 komşu ile oluşturulmuştur.

Yerel-örgü üzerindeki $a_{i,j,k}$ 'ler örgüdeki kenar ağırlıkları olup (3) numaralı doğrusal bağlanım denklemine göre hesaplanmıştır,

$$v(t_i, \bar{s}_j) = \sum_{\bar{s}_k \in \eta_p} a_{i,j,k} v(t_i, \bar{s}_k) + \varepsilon_{ij} \quad (3)$$

Bu denklemde ε_{ij} , t_i anında voksel $v(t_i, \bar{s}_j)$ için hata payıdır ve kenar ağırlıklarını, $a_{i,j,k}$, hesaplayabilmek için hata payı olan ε_{ij} minimuma indirgenmelidir. Hatayı minimuma indirmek için beklenen hata karesi, $E(\cdot)$ beklenti operatörü olmak üzere, (4) numaralı eşitlik kullanılarak en aza indirgenmiştir,

$$E(\varepsilon_{ij}^2) = E \left(\left(v(t_i, \bar{s}_j) - \sum_{\bar{s}_k \in \eta_p(\bar{s}_j)} a_{i,j,k} v(t_i, \bar{s}_k) \right)^2 \right) \quad (4)$$

Beklenen kenar ağırlıkları $a_{i,j,k}$ $k=1,2,\dots,p$ voksel $v(t_i, \bar{s}_j)$ 'nin p -komşuluğundaki vokseller ile olan doğrusal ilişkisini gösterir. Bu şekilde ifade edilen örgü ağırlıkları $a_{i,j,k}$, vokseller arası ilişkinin p -komşuluk sisteminde derli toplu bir şekilde ifade edilmesini sağlar. Komşuluk sayısı olan p 'nin artması durumunda, örgü boyutu da bununla beraber artmaktadır. İdeal durumda, p toplam voksel sayısı olarak seçilebilir, böylece tüm beyin üzerinden nöral aktivite ilişkisi modellenmiş olur, p 'nin 0 olduğu durumda ise örgü, fMRI datasının tek bir vokseline denk gelir. Örgünün boyutu modellenecek mental durumların türüne bağlı olmakla beraber, çeşitli tekniklerle (örn. çapraz geçerlilik sınaması) bulunabilir. Buna rağmen p arttıkça, mevcut formülsayon ile öznel vektörünün boyutu üstel olarak katlanmakta ve uygulanabilirliği azalmaktadır.

Bu adıma kadar hesaplanan kenar ağırlıkları, her bir t_i anı için $N \times p$ boyutlu örgü kenar ağırlıkları matrisi olan, $A_j = [\bar{a}_{1,j} \bar{a}_{2,j} \dots \bar{a}_{N,j}]^T$, oluşturmada kullanılmaktadır. Her voksel $v(t_i, \bar{s}_j)$ için $\bar{a}_{i,j} = [a_{i,j,1} a_{i,j,2} \dots a_{i,j,p}]$ örgü kenar ağırlıkları vektörüdür. Son aşama olarak, bilişsel durumu sınıflandırmak amacıyla kullanılacak olan $N \times (pM)$ boyutlu öznel matrisi $F = [A_1 A_2 \dots A_p]$ oluşturulmuştur.

Bu çalışmada örgü öğrenme algoritması performansını geliştirmek amacıyla, komşuluk seçimi ve kenar ağırlıkları belirlenmesi üzerinde iyileştirmeler yapılmıştır. Yapılan değişikliklerdeki temel amaç vokseller arasındaki uzamsal ve

fonksiyonel uzaklıkların bilişsel sürecin modellenmesi üzerindeki etkisini anlamaktır. Bu maksatla, ilk önce kenar ağırlıklarının hesaplanması üzerine yoğunlaşmış, ikinci olarak da komşuluk seçiminde fonksiyonel yakınlığın önemi dikkate alınmıştır. Her iki yöntemle elde edilen öznelik matrisleri, k-en yakın komşu ve bulanık k-en yakın komşu algoritmalarıyla sınıflandırmada kullanılmışlardır.

3.1. Kenar Ağırlıklarının Uzamsal Olarak Düzenlenmesi

Mevcut örgü öğrenme algoritmasına ilk iyileştirme olarak, kenar ağırlıklarının uzamsal uzaklığa göre tekrar düzenlenmesi üzerinde durulmuştur. Buna göre, hesaplanmış olan kenar ağırlıklarının $a_{i,j,k}$, voksel ile p -komşuluğundaki vokseller arasındaki uzaklıklarla orantılı katsayılar $b_{i,j,k} \in (0,1)$ ile çarpılması denetlenmiştir. Bu maksatla Öklid uzayında, iki farklı uzaklık metriği kullanılmıştır.

Birinci metrikte uzamsal olarak yakın olan komşunun ağırlığını artırmak ve uzak olanı ağırlığını azaltmak için katsayılar $b_{i,j,k}$, uzaklık ile ters orantılı olarak belirlenmiştir. Örneğin sözkonusu voksel $v(t_i, \bar{s}_j)$ ve en yakın p komşuları $v(t_i, \bar{s}_k) \in \eta_p[v(t_i, \bar{s}_j)]$ olsun. Bu durumda her $d_{j,k}$, $v(t_i, \bar{s}_j)$ ile her $v(t_i, \bar{s}_k) \in \eta_p[v(t_i, \bar{s}_j)]$ arasındaki öklid uzaklık olmakla beraber, ilgili $b_{i,j,k}$ katsayıları aşağıdaki gibi uzaklıkla ters orantılı olarak hesaplanmaktadır:

$$b_{i,j,k} = \left(\sum_{v_k} \frac{1}{d_{j,k}} \right)^{-1} \cdot \frac{1}{d_{j,k}} \quad (5)$$

İkinci metrik ilkine benzemekle beraber, katsayılar $b_{i,j,k}$, uzaklıkların kareleriyle ters orantılı (6) olacak şekilde hesaplanmaktadır:

$$b_{i,j,k} = \left(\sum_{v_k} \frac{1}{d_{j,k}^2} \right)^{-1} \cdot \frac{1}{d_{j,k}^2} \quad (6)$$

Her iki yöntem kullanılarak, örgü kenar ağırlıkları matrisi A_j ve öznelik matrisi F tekrar oluşturulmuş ve sınıflandırma işlemi buna göre gerçekleştirilmiştir. Yerel-örgü üzerindeki ağırlıklar, voksel uzamsal mesafeleri ile ters orantılı şekilde tekrar ağırlıklandırıldığında, tablo 1 üzerinde de görüldüğü gibi, sınıflandırma sonuçlarında Özay ve diğerlerinin orjinal algoritmasına göre kayda değer bir iyileşme gözlemlenmemiştir. Uzamsal mesafe ile ağırlıklandırma algoritmasının detayları Yöntem 1 'de sunulmuştur.

3.2. Komşuluk Seçiminde İşlevsel Yakınlık

Uygulanan diğer bir yöntem ise komşuluk kavramını uzamsal uzaklığa bağlı komşuluktan, fonksiyonel uzaklığa bağlı komşuluğa taşımaktır. İnsan beyninin karmaşık bir ağ şeklinde çalıştığı bilinmekle beraber, bilişsel sürece göre bu ağ yapısının değişimi, biliş biliminde oldukça yoğun çalışılan bir konudur [8][9]. Bu alandaki çalışmalar, farklı bilişsel süreçlerde beynin ilintili bölgelerini bularak, *bağlantı haritaları* çıkarmakta ve kullanılmaktadırlar.

Bağlantı haritaları, her bir düşünsel süreç için beyin bölgeleri arasındaki ilinti oranını ifade eden *bağlantı matrisleri* ile ifade edilmektedirler. Bu matrisler, beynin ilgili alanındaki voksellerin, zaman serilerine göre birbirleriyle olan *karşılıklı-ilinti*, *uyuşum*, *karşılıklı-entropi* vb. fonksiyonları ile hesaplanmaktadır.

Yöntem 1: Yerel İlişkisel Özneliklerin Uzamsal Mesafe ile Ağırlıklandırılarak Çıkarılması

Girdi: Veri seti $D = \{v(t_i, \bar{s}_j)\}$

Yerel İlişkisel Öznelik derecesi : p

BAŞLANGIÇ: $F = []$

1. **for** $j=1:M$
2. **for** $i=1:N$
3. voksel $v(t_i, \bar{s}_j)$ için p -komşuluğunu elde et
4. $\bar{a}_{i,j}$ leri hesapla (4)
5. $b_{i,j}$ leri hesapla (5) veya (6)
6. **endfor**(i)
7. $(\bar{a}_{i,j}, b_{i,j})$ kullanarak A_j 'yi oluştur
8. **endfor**(j)
9. A_j 'yi kullanarak F 'i oluştur

SON


Çıktı: Öznelik matrisi F

Bu çalışmada, Özay ve diğerleri tarafından önerilmiş olan örgü öğrenme algoritmasına ikinci iyileştirme yöntemi olarak *bağlantı haritaları* kullanılmıştır. Bu maksatla yerel-örgü komşuluk seçiminde uzamsal olarak en yakın komşu yerine işlevsel olarak en yakın komşu seçilmiştir. Öncelikle beynin kısa süreli hafıza bölgesi, fiziksel konumuna göre ön tanımlı sayıda alt-kümeye bölünüp her bir alt-küme içerisindeki voksel yoğunluk değerlerinin zaman serileri incelenerek *karşılıklı-ilinti* matrisleri hesaplanmıştır. İki voksel $v(\cdot, \bar{s}_i)$ ve $v(\cdot, \bar{s}_j)$ zaman serileri arasındaki *karşılıklı-ilinti* $\rho_{ij}(h)$, h iki seri arasındaki gecikme olmak üzere formül (7) ile hesaplanmıştır, bu hesaplama için *İşlevsel Bağlılık Araç Takımı* [10] kullanılmıştır.

$$\rho_{ij}(h) = \frac{cov_{ij}(t, t+h)}{\sqrt{var_i(t) \cdot var_j(t+h)}} \quad (7)$$

Denklemler 7'de cov_{ij} , i ve j vokselleri arasındaki kovaryansı, var_i ise ilgili voksel için zaman içinde yoğunluk değişim varyansını belirtmektedir. Hesaplanan *karşılıklı-ilinti* matrisleri bilişsel süreçte benzer davranışlar sergileyen voksellerin ilişkisini vermekte olup şekil 2'de örnek iki farklı alt-küme için çıkarılan *karşılıklı-ilinti* matrisleri sunulmuştur.

Her voksel $v(t_i, \bar{s}_j)$ için p -komşuluk hesaplanırken, ilgili vokselin ait olduğu kümede kendisi ile en yüksek pozitif ilintide olan p -işlevsel-komşu seçilmiştir. İşlevsel komşu seçiminden sonra yerel ilişkisel öznelikler çıkartılarak, öznelik matrisi F oluşturulmuştur. İşlevsel komşuluk kullanarak yerel ilişkisel özneliklerin çıkarılma algoritması Yöntem 2 'de sunulmuştur.



Şekil 2- İki farklı alt-küme için hesaplanan karşılıklı-ilinti matrisleri. Bu matrislerde $+1$ 'e yakın değerler (sıcak renkler) pozitif ilintiyi, -1 'e yakın değerler (soğuk renkler) ise negatif ilintiyi ifade etmektedir.

Tablo 1: Yerel İlişkisel Özniteliklerin Uzamsal Mesafe ile Ağırlıklandırılması ve İşlevsel Yakınlık Kullanılarak Çıkarılması ile Elde Edilen Performans (%) Sonuçları – (Sınıflandırıcı olarak k-en yakın komşu algoritması kullanılmıştır)

Kullanılan Yöntem	LRF derecesi (p)								
	2	3	4	5	6	7	8	9	10
Özay ve diğerleri [4]	51,97	52,39	54,62	58,16	56,49	56,05	56	56	57
Uzamsal mesafe ile ağırlıklandırma-metrik 1	52,89	54,52	54,77	57,74	56,49	56,90	54,39	55,23	56,07
Uzamsal mesafe ile ağırlıklandırma-metrik 2	52,55	54,43	54,47	57,32	56,90	57,74	54,39	55,23	56,90
Komşuluk Seçiminde İşlevsel Yakınlık	61,94	62,37	62,36	64,46	62,79	64,04	60,27	61,94	61,11

Uzamsal yakınlığı doğrudan kullanmak yerine, bilişsel süreç incelenerek, işlevsel yakınlığı kullanmak, yerel ilişkisel özniteliklerle sınıflandırma algoritmasının performansını arttırmış olup tablo 1’de sonuçlar sunulmuştur. Tablo 2’de ise sınıf bazında işlevsel yakınlık ile elde edilen en yüksek performans sonuçları sunulmuştur.

Yöntem 2: Yerel İlişkisel Özniteliklerin İşlevsel Yakınlık Kullanılarak Çıkarılması

Girdi: Veri seti $D = \{v(t_i, \bar{s}_j)\}$
 Yerel İlişkisel Öznitelik derecesi : p
 Karşılıklı-ilişim matrisleri : K

BAŞLANGIÇ: $F = []$

1. **for** $j=1:M$
2. **for** $i=1:N$
3. voksel $v(t_i, \bar{s}_j)$ için p -işlevsel-komşuluğunu K inceleyerek hesapla
4. $\bar{a}_{i,j}$ leri hesapla (4)
5. **endfor**(i)
6. $\bar{a}_{i,j}$ kullanarak A_j 'yi oluştur
7. **endfor**(j)
8. A_j 'yi kullanarak F 'i oluştur

SON

Çıktı: Öznitelik matrisi F


4. SONUÇ

Bu çalışmada bilişsel süreci sınıflandırmak amacıyla Özay ve diğerleri tarafından önerilmiş olan örgü öğrenme algoritması iyileştirilmeye çalışılmıştır [4]. Bu maksatla iki farklı yöntem geliştirilmiştir. İlk yöntem uzamsal mesafelerin yerel ilişkisel özniteliklerin ağırlıklandırılmasında dikkate alınması olup, bu yöntem iki farklı uzaklık metriği ile denenmiştir. Bu yöntem beklenen iyileştirmeyi sağlayamamıştır. İkinci yöntem olan yerel ilişkisel özniteliklerin işlevsel yakınlık kullanılarak çıkarılması, diğer yöntemlere göre performansı arttırmıştır. Bu iyileşmenin LRF derecesi (p) arttıkça daha da yükseldiği gözlemlenmiştir.

Bilişsel süreçleri sınıflandırma problemi oldukça yüksek hesaplama gücü gereksinimi ve hesaplama karmaşıklığı ile birlikte gelmektedir. İlerleyen çalışmalarda öznitelik matrisi F 'nin boyutunun azaltılması, LRF derecesinin (p) her bir voksel için farklı ve optimal olarak seçilmesi üzerinde yoğunlaşılacaktır.

5. KAYNAKÇA

- [1] F. De Martino, G. Valente, N. Staeren, J. Ashburner, R. Goebel and E. Formisano, "Combining multivariate voxel selection and support vector machines for mapping and classification of fMRI spatial patterns", *NeuroImage* 43, pp. 44 – 58, 2008.



Şekil 3- Yerel İlişkisel Özniteliklerin İşlevsel Yakınlık Kullanılarak Çıkarılması Sonucu Sınıf Bazında Elde Edilen En Yüksek Performans (%) Sonuçları.

- [2] F. Sun, D. Morris, W. Lee, M. J. Taylor, T. Mills and P. S. Babyn, "Feature-space-based fMRI analysis using the optimal linear transformation", *IEEE Transactions on Information Technology in Biomedicine* 14, 1279-1290, 2010.
- [3] C. Chu, Y. Ni, G. Tan, C. J. Saunders and J. Ashburner, "Kernel regression for fMRI pattern prediction", *NeuroImage* 56(2), 662-673, 2011.
- [4] Özay, M., Öztekin, İ., Öztekin, U. and Vural, F. Y., "Mesh Learning for Classifying Cognitive Processes", *Journal of Pattern Recognition'a gönderilmiştir*, 2011.
- [5] Öztekin, I., & McElree, B. "Retrieval dynamics of proactive interference: PI slows retrieval by eliminating fast assessments of familiarity". *Journal of Memory and Language*, 57, 126-149, 2007.
- [6] Öztekin, I, Curtis, C., & McElree, B.. "Medial temporal lobe and the left inferior prefrontal cortex jointly support interference resolution in verbal working memory". *Journal of Cognitive Neuroscience*, 21, 1967-1979, 2008.
- [7] Öztekin, I., & Badre, D. (2011). "Distributed patterns of brain activity that lead to forgetting", *Frontiers in Human Neuroscience*, 5, 2011.
- [8] Rubinov, M. And Sporns, O., "Complex network measures of brain connectivity: Uses and interpretations", *NeuroImage* 52, 1059–1069, 2010.
- [9] S.M. Smith, K.L. Miller, G. Salimi-Khorshidi, M. Webster, C.F. Beckmann, T.E. Nichols, J.D. Ramsey, and M.W. Woolrich. "Network modelling methods for FMRI". *NeuroImage*, 54:875-891, 2011.
- [10] Zhou, D., Thompson, W. K., and Siegle, G. "MATLAB toolbox for functional connectivity", *NeuroImage*, 47, 1590–1607, 2009.

6. İTİFAH

Bu çalışma, bizi değerli fikirleriyle motive eden arkadaşımız, Şehit Binbaşı Mithat Çolak'ın anısına adanmıştır.