

# Lokalite Derecesinin Kestirimiyle fMRG ölçümlerindeki bilgi dağılımının analizi

## Information Distribution Analysis in the fMRI measurements with degree of locality estimation

İtir Önal<sup>1</sup>, Mete Özay<sup>1</sup>, Orhan Fırat<sup>1</sup>, İlke Öztekin<sup>2</sup>, Fatoş T. Yarman Vural<sup>1</sup>

<sup>1</sup>Bilgisayar Mühendisliği Bölümü  
Orta Doğu Teknik Üniversitesi, Ankara  
{itir, mete.ozay, orhan.firat, vural}@ceng.metu.edu.tr  
<sup>2</sup>Psikoloji Bölümü  
Koç Üniversitesi, İstanbul  
ioztekin@ku.edu.tr

**Özetçe**— Bu çalışmada, fonksiyonel manyetik rezonans görüntüleme (fMRG) verisinde örüntü analizi için ayrımsayıcı bilgi dağılımının analizi ve ifadesi amacıyla yeni bir metot önerilmektedir. Bu amaçla, her vokselin (tohum voksel) çevresinde değişken boyutlarda uzamsal yerel örgü oluşturulur. Her tohum voksel ve komşuları arasındaki ilişki, bir doğrusal bağlanım modeli kullanılarak, hatanın karesi minimize edilecek şekilde kestirilir. Daha sonra, her tohum vokseli çevresi arasındaki bağlantıları temsil eden ideal örgü boyutu, Akaike'nin son öngörü hatası örgü boyutuna göre minimize ederek kestirilir. Lokalite derecesi, ideal örgü boyutu ile temsil edilir. Eğer kestirilen örgü boyutu küçükse, tohum vokselin az sayıda diğer voksellerle bağlantılı olduğu, büyükse vokselin yoğun olarak diğer voksellerle bağlantılı olduğu varsayılır. En yüksek ayrımsayıcı güce sahip yerel örgü boyutunun bireye bağlı olduğu gösterilmiştir. Şaşırtıcı şekilde, ideal örgü boyutu farklı kategorileri tanıma görevlerinde aynı kalmaktadır. Önerilen metot, öge bilgisi ve zamansal sıra bilgisi görevlerinden oluşan bir bellek çalışması üzerinde test edilmiştir. Her özne için, farklı örgü boyutlarına sahip yerel ağların kestirilen yay ağırlıkları, beyinden getirilen iki tür bilgiyi (öge ve zamansal sıra bilgisi) sınıflandırmak için kullanılmıştır. Her özne için sınıflandırma doğruluğu, k-en yakın komşu metodu kullanılarak bulunmuştur. Sonuçlar, önerilen ideal örgü boyutuna sahip yerel örgü modelinin, başarılı bir şekilde ayrımsayıcı bilgiyi temsil edebildiğini göstermiştir.

**Anahtar Kelimeler** — Örgü Öğrenme; Son Öngörü Hatası; fMRG, örüntü analizi

**Abstract**— In this investigation, we propose a new method for analyzing and representing the distribution of discriminative information for pattern analysis of functional Magnetic Resonance Imaging (fMRI) data. For this purpose, a spatially local mesh with varying size, around each voxel (called seed voxel) is formed. The relationship among each seed voxel and its neighbors are estimated using a linear regression model by minimizing the square error. Then, the optimal mesh size which represents the connections among each seed voxel and its

surroundings is estimated by minimizing Akaike's Final Prediction Error (FPE) with respect to the mesh size. The degree of locality is represented by the optimum mesh size. If the estimated mesh size is small, then the seed voxel is assumed to be connected to few other voxels; if it is large, the voxel is assumed to be massively connected to other voxels. It is shown that, the local mesh size with highest discriminative power depend on the individual subjects. Surprisingly, the optimal mesh size remains the same for the recognition task of different categories. The proposed method was tested on a memory task, which requires retrieval of item and temporal order information from memory. For each participant, estimated arc weights of each local mesh with different mesh size are used to classify the two types of information retrieved from memory (i.e. item and temporal order). Classification accuracies for each subject are found using k-Nearest Neighbor (k-NN) method. The results indicate that the proposed local mesh model with optimal mesh size can successfully represent discriminative information.

**Keywords** — Mesh Learning; Final Prediction Error; fMRI; pattern analysis.

### I. GİRİŞ

Beyinde bilginin nasıl dağıldığı ve temsil edildiği bilişsel nörobilimde temel bir sorudur. Bu soruya hitap etmek için, fonksiyonel manyetik rezonans görüntüleme (fMRG) yaygın olarak kullanılmaktadır. Son günlerde, voksel aktivasyon örüntülerindeki gizli bilgiyi ortaya çıkarmayı amaçlayan çok değişkenli örüntü çözümleme (Multivariate pattern analysis (MVPA)) çalışılmaktadır [1-8]. Bu yaklaşımda, fMRG verisinden edinilen voksellerin aktivasyonları, öznelik vektörü olarak bir makine öğrenme algoritmasını eğitmek için kullanılır. Algoritmanın performansı, modelin bilişsel süreci temsil etmedeki doğruluğunun göstergesidir.

Genel olarak MVPA yaklaşımlarında, ham veri işlendikten sonra voksel aktivasyon değerleri Nöral Ağ, Bayes sınıflandırıcı, Kernel makinesi ya da topluluk sınıflandırıcılar gibi bilinen sınıflandırıcı ya da gruplandırma algoritmasına verilir [9]. MVPA metotları, yüksek-uzamsal-

frekans örüntülerine odaklandıkları için, metotlar her bir özne için kendi içinde uygulanmaktadır [10]. Genellikle her özne için aynı önışleme adımları uygulanır ve edinilen çoklu voksel yoğunluk değerleri bir sınıflandırıcıya verilir.

Bu çalışmada, insan beynindeki ayrımsayıcı bilginin dağıtılmış doğasını, özneye ve anlamsal kategoriye göre araştıran bir metot önerdik. Bunun için vokseller arasındaki uzamsal ilişkileri temsil eden ve ayrımsayıcı gücünün voksel yoğunluk değerlerinden daha fazla olduğu ispatlanan [8] yerel örgü modelini kullandık. Her vokselin (yerel örgünün tohum vokseli) çevresinde uzamsal en yakın komşularıyla bir yerel örgü oluşturduk. Tohum voksel ile komşuları arasındaki ilişkiyi temsil eden yay ağırlıklarını, her örgüde doğrusal bağlanım modeli kullanılarak kestirdik. Bu bağlanım sırasında oluşan hata, her özne için, örgüde bulunan komşu sayısına göre (örgü boyutu) değişir ve özneye özgü ideal örgü boyutunun belirlenmesinde önemli rol oynar. Bu çalışmada, örgü boyutuna, Akaike tarafından önerilen Son Öngörü Hatası (*Final Prediction Error* - FPE) [11] ölçütü kullanılarak karar verildi. FPE'yi yerel örgü modelimizde benimseyerek, doğrusal bağlanım modelinin derecesine karşılık gelen ideal örgü boyutunu hesapladık [11, 12]. Önerilen çalışmada örgü boyutu, son öngörü hatasını bağlanım modelinin derecesine göre minimize ederek kestirildi. İdeal örgü boyutunu belirleyen FPE'nin minimum değeri, her özne için tek olmasına karşın, deneysel kategorilere göre değişiklik göstermemektedir. Ek olarak, değişken örgü boyutlarına sahip yerel örgü modeli, her özneye özgü bilişsel süreçler için fMRG ölçümlerindeki voksel bağlanırlığı temsil eden etkili bir araç sağlamaktadır.

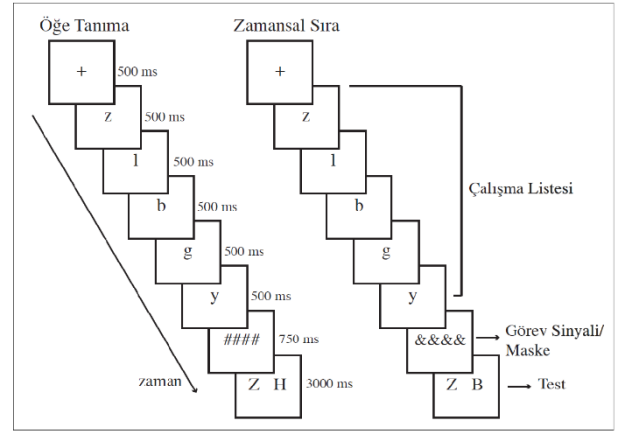
Deneylerimizde, 8 katılımcı, fMRG çekimleri sırasında çalışma belleğinden öge ve zamansal sıra bilgisi geri getirmek üzere iki ayrı görev yürütmüştür. Her iki görevde de katılımcılar birer birer (500 ms boyunca) gösterilen beş adet sessiz harften oluşan bir liste çalışmış ve bunu takiben 2 sessiz harften oluşan bir test ile çalışma belleklerinden öge bilgisi ve zamansal sıra bilgisi geri getirmeleri istenmiştir. Öge tanıma (ÖT) görevinde, katılımcılardan bu 2 harften hangisinin listede yer aldığını tanımları beklenirken, zamansal sıra (ZS) görevinde bu iki harften hangisinin listede daha sonra yer aldığını tanımları beklenmiştir. Bu işlemler sırasında, beyindeki nöral aktivasyonlar fMRG ile kaydedilmiştir. fMRG verisi üzerinde yerel örgü modeli oluşturularak ve sistemimizin sınıflandırma performansı kullanılarak (sınıflar ÖT ve ZS), metodumuzun beyindeki bilgi dağılımını her özne için başarıyla temsil edip etmediği test edilmiştir.

Bildiğimiz kadarıyla bu çalışmada ilk kez son öngörü hatası uzamsal-alanda yerel ilişkisel yapılarla birlikte kullanılmıştır. İdeal örgü boyutuna karşılık gelen sınıflandırma performansı, hem farklı örgü boyutlarının ortalamaya performansı ile hem de [1], [2] ve [3]'te önerilen klasik MVPA metodunun performansı ile karşılaştırılmıştır. Önerilen metodun basitliği ve etkinliği, farklı zihin okuma görevlerinde de kullanılacak bir potansiyele sahiptir.

## II. MATERYALLER VE METOTLAR

### A. fMRG deney ve önışleme

fMRG deneylerinde, nöral aktivasyon, öge tanıma ve zamansal sıra olmak üzere iki işleyen bellek görevinde



Şekil 1. Öge Tanıma ve Zamansal Sıra görevlerinden oluşan deneyden bir örnek [13].


incelenmiştir [13]. Her iki görevde de beş sessiz harfi (küçük harf) içeren bir çalışma listesi, 8 katılımcıya 500 ms süreyle gösterilmiştir. Daha sonra ÖT görevi için "####" içeren mavi bir maske, ZS görevi için ise "&&&&" içeren kırmızı bir maske, 750 ms. boyunca gösterilmiştir. Maske gösteriminden sonra, büyük harfle yazılmış iki sessiz harf, 3000 ms süreyle gösterilmiştir. ZS görevinde, her iki sessiz harf de çalışma listesinde yer almaktadır ve katılımcılardan hangisinin listede diğerinden daha sonra yer aldığını seçmeleri istenmiştir. ÖT görevinde ise harflerden biri listede yer alırken diğeri yenidir ve katılımcıdan listede yer alanı seçmesi beklenir ( Fig. 1).

Görüntü işleme ve veri analizi SPM2 ([www.fil.ion.ucl.ac.uk/spm/](http://www.fil.ion.ucl.ac.uk/spm/)) kullanılarak yapılmıştır. Önışleme fazında öncelikle kesitler arası kesit edinim zamanlaması düzeltilmiştir. Daha sonra, baş hareketini düzeltmek için görüntüler ilk hacme göre yeniden hizalanmıştır. Sonrasında fonksiyonel ve anatomik görüntüler standart bir taslak üzerinden standartlaştırılmıştır. Son olarak, 6-mm FWHM izotropik Gauss kernel kullanılarak, görüntüler yumuşatılmıştır.

### B. Voksellerin yerel bağlanırlığının temsili: Yerel ilişkisel Öznitelikler

Bu çalışmada her bir zaman anında  $t_i$ ,  $\bar{s}_j$  konumundaki voksel yoğunluk değerleri  $v(t_i, \bar{s}_j)$  ölçülür ve her  $t_i$  anı bir görev etiketi  $c_i$  ile ilişkilendirilir. Bu deneyde görev etiketi öge bilgisi ya da zamansal sıra bilgisidir. fMRG ölçümleri, bir  $N \times M$  matrisiyle ifade edilir. Bu matriste  $N$  zaman örneklerinin sayısı ve  $M$  voksel sayısıdır. Vokseller beyinde üç boyutta dağıldıkları için, konumları  $\bar{s}_j = (x_j, y_j, z_j)$  üç boyutlu bir vektördür.

Önerilen yerel örgü modelinde, her vokselin  $(t_i, \bar{s}_j)$   $p$ -en yakın komşuluğu  $\eta_p$  başlıca iki yaklaşımla belirlenir. İlk yaklaşımda, komşuluk sistemi uzamsal olarak tanımlanır [8] ve  $p$ -en yakın komşular tohum voksele olan Öklit uzaklığı en küçük olan voksellerden seçilir. İkinci yaklaşımda fonksiyonel komşuluk tanımlanır [14] ve  $p$ -en yakın komşular, tohum voksele diğer vokseller arasındaki fonksiyonel bağlanırlığa göre seçilir. Yaygın kullanılan fonksiyonel bağlanırlık ölçümü, [14]'da tanımlandığı gibi Pearson korelasyonudur. Yerel örgü modelinde, tohum voksel  $p$ -komşularına  $\{v(t_i, \bar{s}_k)\}_{k=1}^p$  yay ağırlıklarıyla  $a_{i,j,k}$



**Şekil 2.** Tohum vokseli  $v(t_i, \bar{s}_j)$ ,  $t_i$  anındaki  $p$ -en yakın komşularını  $\{v(t_i, \bar{s}_k)\}_{k=1}^p$  ve kestirilen yay ağırlıklarını  $a_{i,j,k}$  gösteren örgü şeması.

bağlanır (Fig. 2) ve bu  $p$  değerine örgü boyutu adı verilir. Yay ağırlıkları, doğrusal bağlanım denklemi ile kestirilir:

$$v(t_i, \bar{s}_j) = \sum_{\bar{s}_k \in \eta_p} a_{i,j,k} v(t_i, \bar{s}_k) + \varepsilon_{i,j,p}. \quad (1)$$

Denklem (1)'de yay ağırlıkları, hatanın karesinin  $\varepsilon_{i,j,p}^2$ , Levinson – Durbin özyinelemesi [15] kullanılarak minimize edilmesiyle kestirilir. Bu yay ağırlıkları  $a_{i,j,k}$ , voksel  $v(t_i, \bar{s}_j)$  ile  $\eta_p$ 'deki vokseller arasındaki ilişkiyi ifade eder. Her voksel için, her  $t_i$  anında yay ağırlıkları  $a_{i,j,k}$  kestirilir ve  $1 \times p$ 'lik örgü yay vektörü  $\bar{a}_{i,j} = [a_{i,j,1} \ a_{i,j,2} \ \dots \ a_{i,j,p}]$  oluşturulur. Daha sonra her voksel  $v(t_i, \bar{s}_j)$ , bu örgü yay vektörü  $\bar{a}_{i,j}$  ile ifade edilir. Böylece her voksel, kendi yoğunluk değerleri yerine komşularıyla arasındaki ilişki cinsinden ifade edilir. Her zaman anı için örgü yay vektörleri birleştirilerek,  $N \times p$ 'lik örgü yay vektörü  $A_j = [\bar{a}_{1,j} \ \bar{a}_{2,j} \ \dots \ \bar{a}_{N,j}]^T$  oluşturulur. Son olarak, her voksel için  $A_j$ 'ler birleştirilerek  $N \times p \times M$ 'lik öznitelik matrisi  $F = [A_1 \ A_2 \ \dots \ A_M]$  oluşturulur.

### C. Akaike'nin Son Öngörü Hatası (Final Prediction Error FPE)

Önerilen yerel örgü modelini tasarlarırken en önemli adım, sınıflandırıcının performansını maksimuma çıkaran ideal örgü boyutuna karar vermektir. Yerel örgünün boyutu aynı zamanda voksel ve komşuları arasındaki bağlantının derecesini ifade eder. Bu çalışmada Akaike tarafından önerilen bilgi kuramsal ölçüt [11] benimsenmiştir. Önerilen metotta, ilk olarak  $t_i$  anında, her bir örgü ve her bir örgü boyutu için hatanın karesi aşağıdaki gibi hesaplanmıştır:

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

Her  $t_i$  anı için ve her tohum voksel  $v(t_i, \bar{s}_j)$  için hataların karelerinin ortalaması alınarak, örgü boyutu  $p$  için hata değişintisi aşağıdaki gibi yaklaşmıştır:

$$E(\bar{\varepsilon}_p^2) \cong \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M \varepsilon_{i,j,p}^2, \quad (3)$$

Burada  $E(\cdot)$  beklenti operatörüdür. Hatanın karesinin beklentisi, FPE'yi uzamsal-alanda bulmak için kullanılır:

$$FPE_p = E(\bar{\varepsilon}_p^2) \left( \frac{M+p+1}{M-p-1} \right). \quad (4)$$

Yukarıdaki formülde, ilk terim  $E(\bar{\varepsilon}_p^2)$ ,  $p$ 'nin monoton olarak azalan bir fonksiyonudur ve ikinci terim monoton olarak artan bir fonksiyondur. Sonuç olarak FPE,  $p$  açısından konveks ve tek minimuma sahip bir fonksiyondur. Akaike'nin öncü çalışmasına [11] göre, bu fonksiyon bize model niteliği hakkında bir ölçüt verir. FPE'yi model derecesi  $p$ 'ye göre minimize etmek bize ideal örgü boyutunu verir.  $FPE_p$  çeşitli örgü boyutları için hesaplanır ve  $FPE_p$ 'nin minimum olduğu  $p$  değeri örgü boyutu olarak seçilir.

### III. SONUÇLAR

Önerilen metot, 18-28 yaşları arasındaki 8 katılımcının verilerinden oluşan bir veri seti üzerinde incelendi. Her katılımcı için 240 eğitim örneği (ÖT ve ZS görevlerinden 120'şer örnek) ve 80 test örneği (ÖT ve ZS görevlerinden 40'ar örnek) kullanıldı. Tüm deneylerde, bütün beyni kapsayan fMRG verileri kullanılmıştır.

İdeal örgü boyutu, her özne için [2-25] aralığında değişen  $p$  değerlerine karşılık gelen FPE'lerin hem eğitim setinde hem de test setinde hesaplanmasıyla kestirildi. FPE'nin minimum değeri bu aralıkta ulaştığı gözlemlendi. Ek olarak, her  $p$  değeri için çıkarılan yay ağırlık vektörleri sınıflandırmada kullanıldı ve sınıflandırma doğruluğu  $k$ -en yakın komşu ( $k$ -NN) metodu ile hesaplandı. Tablo I'de bir öznenin sonuçları bulunmaktadır. Tablodan görüleceği gibi, [2-25] aralığındaki örgü boyutları için FPE bir noktaya kadar ( $p = 23$ ) azalmakta, sonrasında artmaktadır ve metodumuz örgü boyutunu bu öznde 23 olarak kestirir. Bu örgü boyutuna karşılık gelen sınıflandırma performansı 67% olup, bu değer farklı örgü boyutlarına karşılık gelen performans değerlerinin en yükseğidir. Bu özne için örgü boyutu [2-25] arasında olan sınıflandırıcıların ortalama performansı 61%'dir.

Her özne için ortalama performans aynı şekilde hesaplanmıştır. Ayrıca yay ağırlıkları kullanmanın, klasik MVPA metoduna göre performansı artırdığını göstermek için, önışleme sonrası elde edilen öznitelikler, direkt sınıflandırıcıya verilmiş ve sınıflandırma performansı hesaplanmıştır. Önerilen metodun ve klasik MVPA metodunun performansları Tablo II'de karşılaştırılmaktadır. Her özne için kestirilen örgü boyutu 16 ile 25 arasında değişmektedir. Bu değerler test verisinde FPE'nin minimum olduğu yerlere denk gelir. Kestirilen örgü boyutundaki yay ağırlıkları kullanıldığında, 8 katılımcıdan 6'sında performans

**Tablo 1:** Farklı Örgü Boyutlarında FPE ve Sınıflandırma Performansı

Örgü boyutu	FPE	Yay vektörü ile sınıflandırma performansı	Örgü boyutu	FPE	Yay vektörü ile sınıflandırma performansı
2	95,57	63%	14	78,78	63%
3	91,99	63%	15	78,83	61%
4	86,76	63%	16	78,40	58%
5	86,25	62%	17	78,59	58%
6	85,55	57%	18	78,33	59%
7	82,96	65%	19	78,24	58%
8	81,87	65%	20	77,97	59%
9	80,59	65%	21	78,02	57%
10	80,05	61%	22	77,94	57%
11	79,94	62%	<b>23</b>	<b>77,63</b>	<b>67%</b>
12	79,34	58%	24	77,76	61%
13	78,99	62%	25	77,82	57%

klasik MVPA metoduna göre 1% - 9% artmaktayken, 2 katılımcıda 1% - 2% azalmaktadır. Bu iki katılımcıda da yay ağırlıklarını kullanmak klasik MVPA metodundan daha iyi performans vermesine rağmen, metodumuz bu ideal örgü boyutunu kestirememektedir.

**Tablo 2:** Kestirilen İdeal Örgü Boyutunda Yay Vektörlerinin ve Klasik MVPA Metodunun Sınıflandırma Performansı

Özneler	Kestirilen ideal örgü boyutu	k-NN Performansı		
		Klasik MVPA metot	Yay vektörlerinin kestirilen örgü boyutunda performansı	2-25 arası örgü boyutlarında ortalama performans
Özne 1	17	58%	66%	61%
Özne 2	23	58%	67%	61%
Özne 3	24	62%	60%	61%
Özne 4	25	53%	58%	57%
Özne 5	23	54%	59%	57%
Özne 6	16	53%	59%	57%
Özne 7	25	57%	56%	55%
Özne 8	17	57%	58%	57%

Ek olarak, [2-25] arasındaki örgü boyutlarından edinilen ortalama performanslar da Tablo II’de sağlanmış olup, kestirilen örgü boyutunun sınıflandırma performansının her zaman ortalama performanstan daha yüksek olduğu gözlemlenmiştir. Tablo II’de görüleceği gibi Özne 3 ve Özne 7’de metodumuz, en yüksek performansla denk gelen örgü boyutunu saptayamamıştır. Tablo III’te görülebileceği gibi Özne 3 için örgü boyutunu 25 seçmek, Özne 7 için ise örgü boyutunu 22 seçmek, performansı klasik MVPA yöntemlerine göre artırır.

**Tablo 3:** En Yüksek Performansı Veren Örgü Boyutunda Yay Vektörlerinin ve Klasik MVPA Metodunun Sınıflandırma Performansı

Özneler	En yüksek performansı veren örgü boyutu	k-NN Performansı	
		Klasik MVPA metot	Yay vektörlerinin en yüksek performansı veren örgü boyutunda performansı
Özne 3	25	62%	65%
Özne 7	22	57%	58%

Son olarak, örgü boyutunun belirli bir anlamsal kategori üzerindeki etkisini araştırdık. Bu amaçla, ideal örgü boyutunu yalnızca aynı sınıfa ait örnekleri kullanarak FPE’yi minimize ederek kestirdik. Şaşırtıcı biçimde, her iki sınıf için de ideal örgü boyutunun aynı olduğunu ve tüm örnekler kullanılarak elde edilen ideal örgü boyutuyla aynı olduğunu gözlemledik. Böylece bilgi dağılımının kişiden kişiye değişse de kategoriden kategoriye değişmediği sonucuna vardık.

#### IV. VARGI

Bu makalede, beyinde bilginin nasıl dağıldığını ve ifade edildiğini incelemek amacıyla bilişsel durum sınıflandırma görevi için yeni bir makine öğrenme yaklaşımı önerdik. Metodumuz, her vokseli komşularıyla olan ilişkisi cinsinden ifade eden, özneye özgü çeşitli boyutlardaki yerel örgü modeli kullanmayı tanıtmıştır. Yerel örgülerin boyutları son öngörü hatası olarak adlandırılan bir bilgi kuramsal ölçüt minimize edilerek bulunmuştur. İdeal örgü boyutu kişiden

kişiyi değiştiği için, yaklaşımımız ideal örgü boyutu seçimi için genel bir metot sağlamaktadır. Bu çalışmada, voksel sayısına, hatanın değişimine ve model derecesine bağlı FPE’nin, beyindeki bilişsel süreçleri modellemede kullanılan örgü boyutunu seçmede kullanılabilirliğini gösterdik.

Bu çalışmada odak noktamız, bilişsel görevin özneye bağlılığını araştırmak için farklı öznelere ideal örgü boyutunu bulmaktır. Voksellerin bağımlılık derecesinin, yüksek oranda özneye bağlı olduğunu ve her özne için geçerli genel bir  $p$  değerinin bulunamayacağını gözlemledik. Sonuçlar, 8 kişiden 6’sında (75%) ideal örgü boyutunu saptayabilen FPE ölçütünün oldukça umut verici olduğunu gösterdi. Metodumuz 2 kişide ideal örgü boyutunu saptayamamasına rağmen, bu kişilerde sınıflandırma performansı klasik MVPA metoduna göre yalnızca 1% - 2% azalmıştır. Bu çalışmada önerilen metot, çalışma belleğinden öge bilgisi ve zamansal sıra bilgisi geri getirilirken elde edilen fMRG verileri üzerinden test edilmiş ve başarılı bir şekilde sınıflandırma yapılabilmektedir. Bu metodu kullanarak daha genel bir başarıya ulaşmak için gelecekteki araştırmalarımız, aynı metodu çoklu öznelere başka bilişsel görevler üzerinde uygulamak üzerine olacaktır.

#### KAYNAKÇA

- [1] J. V. Haxby, M. I. Gobbini, M. L. Furey, A. Ishai, J. L. Schouten and P. Pietrini, “Distributed and overlapping representations of faces and objects in ventral temporal cortex,” *Science*, 293: 2425–2430, 2001.
- [2] D. D. Cox, R. L. Savoy, “Functional magnetic resonance imaging (fMRI) “brain reading”: detecting and classifying distributed patterns of fMRI activity in human visual cortex,” *Neuroimage*, 19: 261–270, 2003
- [3] J.-D. Haynes and G. Rees, “Decoding mental states from brain activity in humans,” *Nat. Rev. Neurosci.*, vol. 7, no. 7, pp. 523–34, Jul. 2006
- [4] J.-D. Haynes, “Decoding and predicting intentions,” *Ann. N.Y. Acad. Sci.*, 1224: 9–2, 2011
- [5] A. J. O’Toole, F. Jiang, H. Abdi, N. Penard, J. P. Dunlop and M. A. Parent, “Theoretical, statistical, and practical perspectives on pattern-based classification approaches to the analysis of functional neuroimaging data,” *J. Cogn. Neurosci.*, 19: 1735–1752, 2007.
- [6] N. Kriegeskorte, “Pattern-information analysis: from stimulus decoding to computational-model testing,” *Neuroimage*, 56:411–421, 2011
- [7] N. Kriegeskorte, R. Goebel and P. Bandettini, “Information-based functional brain mapping,” *Proc Natl Acad Sci USA*, 103: 3863–3868, 2006
- [8] I. Oztekin and D. Badre, “Distributed Patterns of Brain Activity that Lead to Forgetting,” *Frontiers in human neuroscience*, 5, doi:10.3389/fnhum.2011.00086.
- [9] M. Ozay, I. Oztekin, U. Oztekin, F. T. Yarman Vural, “A Mesh learning model for pattern analysis of brain activity”, under review
- [10] K. A. Norman, S. M. Polyn, G. J. Detre, and J. V. Haxby, “Beyond mind-reading: multi-voxel pattern analysis of fMRI data,” *Trends in cognitive sciences*, vol. 10, no. 9, pp. 424–30, Sep. 2006.
- [11] H. Akaike, “Fitting autoregressive models for prediction,” *Ann. Inst. Stat. Math.*, vol.21 pp. 243–247, 1969.
- [12] H. Akaike, “Statistical predictor identification,” *Ann. Inst. Stat. Math.* vol.22 pp. 203–217, 1970.
- [13] I. Oztekin, B. McElree, B. P. Staresina and L. Davachi, “Working Memory Retrieval: Contributions of the Left Prefrontal Cortex, the Left Posterior Parietal Cortex, and the Hippocampus,” *Journal of Cognitive Neuroscience* vol. 21 no. 3, pp. 581–593
- [14] O. Firat, M.Ozay, I. Onal, I. Oztekin, F. T. Yarman Vural, “A mesh learning approach for brain data modeling,” *IEEE 20th Conference on Signal Processing and Communications Applications (SIU)*, 2012
- [15] P. P. Vaidyanathan, “The Theory of Linear Prediction”, *Morgan & Claypool Publishers*, 2008