

# Örüntü Analizi için Beyinde Bağlanırlık Kestirimi

## Estimating Brain Connectivity for Pattern Analysis

İtir Onal\*, Emre Aksan\*, Burak Velioglu\*, Orhan Fırat\*, Mete Ozay†, Ilke Oztekin‡, Fatos T.Yarman Vural\*

\*Bilgisayar Mühendisliği Bölümü, Orta Doğu Teknik Üniversitesi, Ankara, Türkiye

Email: {itir,emre.aksan,velioglu,orhan.firat,vural}@ceng.metu.edu.tr

† Bilgisayar Bilimleri, Birmingham Üniversitesi, Birmingham, Büyük Britanya

Email: m.ozay@cs.bham.ac.uk

‡Psikoloji Bölümü, Koç Üniversitesi, İstanbul, Türkiye

Email: ioztekin@ku.edu.tr

**Özetçe** —Bu çalışmada, fonksiyonel Manyetik Rezonans Görüntüleme (fMRG) verisinin temel elemanı olan vokselin komşu voksellerle olan bağlanırlık derecesi kestirilmiştir. Komşuluk sistemi uzamsal bağlanırlık metrikleri ile tanımlanır ve her voksel etrafında uzamsal komşuluk kullanılarak değişken boyutlu yerel örgü oluşturulur. Daha sonra, her voksel kendi yoğunluk değeri yerine *Örgü Yay Betimleyicileri* olarak adlandırılan örgü yay ağırlıkları ile ifade edilir. Sonuç olarak, her vokselin ideal örgü boyutu, çeşitli bilgi teoretik kriterler kullanılarak kestirilir. fMRG ölçümleri 10 anlamsal kategori içeren uyarılara maruz bırakılan bir katılımcıya uygulanan beyne bilgi kaydı ve beyinden bilgi geri getirme deneyi sırasında edinilmiştir. Değişken örgü boyutuna sahip *Örgü Yay Betimleyicileri* kullanılarak bir k-en yakın komşu sınıflandırıcısı eğitilmiştir. Sınıflandırma performansı gösterir ki, önerilen değişken boyutlu *Örgü Yay Betimleyicileri*, bilişsel süreçleri klasik çoklu-voksel örüntü betimleyicilerinden ve sabit boyutlu *Örgü Yay Betimleyicileri'nden* daha iyi ifade eder. Ek olarak, bağlanırlık derecesinin beyinde oldukça değişken olduğu gözlemlenmiştir.

**Anahtar Kelimeler**—beyindeki bağlanırlık derecesi, fMRG, ideal örgü boyutu, örgü yay betimleyicileri

**Abstract**—In this study, the degree of connectivity for each voxel, which is the unit element of functional Magnetic Resonance Imaging (fMRI) data, with its neighboring voxels is estimated. The neighborhood system is defined by spatial connectivity metrics and a local mesh of variable size is formed around each voxel using spatial neighborhood. Then, the mesh arc weights, called *Mesh Arc Descriptors (MAD)*, are used to represent each voxel rather than its own intensity value measured by functional Magnetic Resonance Images (fMRI). Finally, the optimal mesh size of each voxel is estimated using various information theoretic criteria. fMRI measurements are obtained during a memory encoding and retrieval experiment performed on a subject who is exposed to the stimuli from 10 semantic categories. Using the *Mesh Arc Descriptors (MAD)* having the variable mesh sizes, a k-NN classifier is trained. The classification performances reflect that the suggested variable-size *Mesh Arc Descriptors* represent the cognitive states better than the classical multi-voxel pattern representation and fixed-size *Mesh Arc Descriptors*. Moreover, it is observed that the degree of connectivities in the brain greatly varies for each voxel.

**Keywords**—degree of connectivity in brain, fMRI, optimal mesh size, mesh arc descriptors

### I. GİRİŞ

fMRG verisinin modellenmesi ve analizi alanında son zamanlarda yapılan çalışmalarda, beyin aktivitelerinin uzamsal örüntüleri kullanılmıştır ve bilişsel süreçte gizli bilgiyi çözümlmek amacıyla örüntü tanıma algoritmaları uygulanmıştır [1]. Bilişsel süreçleri tahmin etmede kullanılacak örüntülerin tanımlanması ve bu örüntülerin sınıflandırılma kullanılması Çoklu-voksel Örüntü Analizi (ÇVÖA) olarak adlandırılmaktadır. ÇVÖA metodlarını kullanan öncü çalışma Haxby ve dig. [2] tarafından yürütülmüştür ve sonrasında pek çok çalışma [1], [3]–[7] ÇVÖA metodlarını bilişsel süreç sınıflandırmada kullanmıştır. Klasik ÇVÖA yaklaşımlarında, genellikle bilişsel süreçleri sınıflandırmada kullanılacak öznitelik vektörleri, voksel yoğunluk değerlerinden oluşturulur ve bu öznitelikler ile k-en yakın komşu (k-EK), Destek Vektör Makinası (DVM), Naive Bayes gibi sınıflandırıcılar eğitilir. Son zamanlarda örüntü tanıma topluluğunda da bilişsel süreçlerin çözülmesine ilgi duyulmaya başlanmıştır ve bu amaca yönelik çeşitli örüntü tanıma yaklaşımları kullanılmıştır [8]–[10].

Ozay ve dig. [11], *fiziksel olarak yakın* vokseller arasındaki ilişkiyi temsil eden *Örgü Yay Betimleyicileri'ni* öznitelik olarak kullanan yerel örgü modelini ortaya koymuştur ve bilişsel süreçleri sınıflandırmada bu özniteliklerin voksel yoğunluk değerlerinden daha ayrımsayıcı olduğunu göstermiştir. Sonraki çalışmada Fırat ve dig. [12] *fonksiyonel olarak yakın* komşular arasındaki ilişkiyi modelleyerek elde ettiği öznitelikleri sınıflandırmada kullanmıştır. Bu çalışmalar, bilişsel süreç sınıflandırma performansında ciddi bir artış sağlamıştır. İki çalışmada da örgü boyutu sabittir ve her voksel aynı sayıda komşu ile bağlıdır. Onal ve dig. [13], [14] bilgi teoretik kriterleri kullanarak her katılımcı ve her örnek için ideal örgü boyutunu kestirmiştir. Bu çalışmalarda beyindeki bilgi dağılımının katılımcıya ve örneğe göre nasıl değiştiği gösterilse de, bir örneğe ait her voksel için aynı boyuta sahip yerel örgüler oluşturulmuştur. Ancak Baldassano ve dig. [15], beyinde farklı alt bölgelerin, vokseller arasında farklı bağlanırlık derecesine sahip olduğunu göstermiştir. Ek olarak, Zalesky ve dig. [16], de bağlantıların topolojilerinin ve güçlerinin beyinde farklı bölgelere göre değiştiğini göstermiştir.

Bu çalışmada, bilişsel süreç sırasında beyinde vokseller arası bağlanırlığı fiziksel komşulukta modelleyen, bilgi teoretik bir yaklaşım önerilmektedir. Bağlanırlık derecesi her voksel için değişken olup, voksel etrafında oluşturulan yerel örgünün

ideal boyutu ile ifade edilmektedir. İdeal örgü boyutunu bulmak için üç popüler model derecesi bulma yöntemi olan Akaike Bilgi Kriteri (ABK) [17], Bayes Bilgi Kriteri (BBK) [18] ve Minimum Betimleme Uzunluğu (MBU) [19] kullanılmıştır. Önceki yaklaşımların aksine bu çalışmada bilişsel sürecin sınıflandırılmasında değişken boyutlu örgüler oluşturulması amaçlanmıştır.

Değişken boyutlu örgülerden edinilen *Örgü Yay Betimleyicileri* ile k-EK sınıflandırıcısı eğitilmiştir. Edinilen sınıflandırma performansları, önerilen metodun klasik ÇVÖA yöntemlerinden ve sabit boyutlu örgü modelinden daha başarılı olduğunu göstermektedir.

## II. FMRG VERİSETİ VE ÖNİŞLEME

Deneyimizde *meyve, sebze, hayvan, mobilya, bitki, kıyafet, kimyasal element, renk, araç ve vücut bölümleri* olmak üzere 10 sınıfa ait kelimeler kullanılmaktadır. Beyne bilgi kaydı sırasında katılımcıya belirli bir sınıfa ait kelimeler gösterilmektedir. Daha sonra katılımcıdan basit matematik problemleri çözmesi beklenir. Son olarak beyinden bilgi geri getirme sırasında katılımcıya yine aynı kategoriden bir kelime gösterilir ve katılımcıdan bu kelimeyi daha önce görüp görmediğini hatırlaması beklenir [20], [21]. Deney, 8 inceleme serisinden oluşmaktadır. ayrı Veriseti yalnızca beynin *lateral temporal korteks* bölgesindeki 8142 vokal kullanılarak oluşturulmuştur.


Bu çalışmada,  $\bar{s}_j = (x_j, y_j, z_j)$  koordinatlarındaki vokselin  $t_i$  anında ölçülen yoğunluk değeri  $v(t_i, \bar{s}_j)$  ile ifade edilmektedir.  $N$  örnek sayısı ve  $M$  voksel sayısı olmak üzere  $i = 1, 2, \dots, N$  ve  $j = 1, 2, \dots, M$  değerlerini almaktadır. Tüm  $t_i$  anlarında, tüm voksellerden ölçülen yoğunluklar  $N \times M$  boyutlu bir matris haline getirilerek veriseti  $D\{v(t_i, \bar{s}_j)\}$  oluşturulur. Deneyde tek bir  $t_i$  anı için tüm voksel yoğunluklarının vektörüne *örnek* adı verilmektedir ve her bir örnek bir sınıfa  $c_i$  atanmıştır.

fMRG verisi SPM aracındaki standart teknikler kullanılarak bir dizi ön-işleme işlemleri ile zenginleştirilmiştir. Ön-işleme tekniklerinin detayları [11]'de anlatılmıştır. Sonrasında, standart z-skorlar ile veri normalize edilmiştir. 22 sütundan (1 sütun bias, 1 sütun tarayıcı-sapması, 20 sütun da 10 anlamsal kategorinin beyne bilgi kaydı ve beyinden bilgi geri getirme aşamaları için) oluşan dizayn matrisi kullanılarak GLM (Genel Lineer Model) analizi yürütülmüştür. Dizayn matrisinin son 20 sütunu çift-gamma hemodinamik tepki fonksiyonu ile eviştirilmiştir. GLM beta ağırlıkları ile betamap değerleri kestirilmiştir. GLM modelinin oluşturulmasında ve betamap değerlerinin kestirilmesinde libORF ([www.ceng.metu.edu.tr/~e1697481/libORF.html](http://www.ceng.metu.edu.tr/~e1697481/libORF.html)) kullanılmıştır. Bu çalışmada, ham voksel yoğunluk değerleri yerine betamap parametreleri kullanılmıştır.

## III. ÖRGÜ YAY BETİMLEYİCİLERİ (ÖYB)

Ozay ve dig. [11] bilişsel süreçleri sınıflandırmak için her bir merkez vokselin  $v(t_i, \bar{s}_j)$  etrafında  $p$ -en yakın komşular ile örgü oluşturulan yerel örgü modelini önermiştir. Çalışmamızda en yakın komşular *fiziksel olarak yakın* vokseller, başka bir deyişle, merkez voksele Öklit uzaklığı en az olan vokseller olarak seçilmiştir.

Şekil 1 merkez voksel etrafında 4 komşusu ile kurulan bir yerel örgüyü göstermektedir. Bu örgünün düğümleri voksel



Şekil 1: Merkez voksel  $v(t_i, \bar{s}_j)$  ile komşuları  $\{v(t_i, \bar{s}_k)\}_{k=1}^p$  arasındaki ilişkiyi  $a_{i,j,k}$  ifade eden yerel örgü modeli

yoğunluk değerlerine karşılık gelirken, *Örgü Yay Betimleyicileri* olarak adlandırılan örgünün yay ağırlıkları  $a_{i,j,k}$  merkez voksel ile komşuları arası ilişkiyi temsil etmektedir ve aşağıdaki regresyon denkleminin çözülmesiyle elde edilir:

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

Denklemden  $v(t_i, \bar{s}_j)$  merkez vokseli,  $\{v(t_i, \bar{s}_k)\}_{k=1}^p$  textitp-en yakın komşuları temsil ederken  $\varepsilon_{i,j}(p)$  ile ÖYB özniteliklerinin kestirimi sırasında oluşan hata temsil edilir. ÖYB'lerin kestirimi için en küçük kareler kestiricisi ya da doğrusal tahmin metotları gibi pek çok yöntem kullanılabilir. Bu çalışmada ise Levinson - Durbin yinelemesi [22] kullanılarak hata varyansının karesi minimize edilerek ÖYB'ler kestirilmiştir.

## IV. VOKSEL BAĞLANIRLIK DERECESİNİN KESTİRİMİNDE BİLGİ TEORETİK KRİTERLER

Örgünün boyutu,  $p$  merkez vokselin kaç komşusu ile bağlantı kurduğunu gösterir. Başka bir deyişle,  $p$  spesifik bir bölgedeki bağlantırlığın derecesini belirler. Eğer  $p$  büyükse, merkez vokselin bağlantıları yoğun iken, küçük  $p$  değerleri seyrek bağlantılar anlamına gelir.  $p$  arttıkça hata terimi  $\varepsilon_{i,j}(p)$  (1) azalır ve model veriye daha uygun olur. Öte yandan  $p$ , çıkarılan ÖYB özniteliklerinin boyutuna eşittir. Sistemimizde ÖYB'ler öznitelik olarak kullanıldığından,  $p$  arttıkça karmaşıklık artar. Uygunluk derecesi ve karmaşıklık arasındaki ödünleşim, bilgi kriterleri kullanılarak optimize edilir. Bu çalışmada ideal örgü boyutunu bulmak amacıyla, Akaike Bilgi Kriteri (ABK) [17], Bayes Bilgi Kriteri (BBK) [18] ve Minimum Betimleme Uzunluğu (MBU) [19] kullanılmıştır.

Bahsedilen bilgi kriterlerini optimize etmek için yerel örgü denkleminde (1) elde edilen hatanın karesi, her voksel için ve her örgü boyutu için aşağıdaki gibi hesaplanır:

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

Bu çalışmada bir vokselle için edinilen hatanın karesinin beklenti değeri, o vokselle için her  $t_i$  anında edinilen tüm hataların ortalaması ile aşağıdaki gibi yaklaşılır:

$$\hat{E}_j(p) = E_i(\varepsilon_{i,j}(p)^2) \cong \frac{1}{N} \sum_{i=1}^N \varepsilon_{i,j}(p)^2, \quad (3)$$

$E_i(\cdot)$  bir vokselle için tüm  $t_i$  anları üzerinden ortalama alan beklenti operatörüdür. Amacımız, (3) ile ideal örgü boyutunu kestirmektir. Daha sonra, değişken boyutlu yerel örgüler her vokselle etrafında bilgi dağılımı hakkında bilgi verecektir.

#### A. Akaike Bilgi Kriteri (ABK)

Beyindeki bilgi dağılımı bilinmediği için doğru model ile geliştirdiğimiz yerel örgü modeli arasındaki Kullback - Leibler yakınsaması hesaplanamaz ve yerel örgü modelinin kullanımından doğan bilgi kaybı ölçülemez. Ancak, ABK ile doğru modele en çok yaklaşan ideal boyutlu model kestirilebilir. İdeal örgü boyutunun kestirimi için, (4) örgü boyutuna ( $p$ ) göre minimize edilir.  $M$  vokselle sayısını temsil eder.

$$ABK_j(p) = \ln(\hat{E}_j) + \frac{2p}{M} \quad (4)$$

#### B. Bayesian Information Criterion (BBK)

BBK, veriyi üretme olasılığı en yüksek olan modeli belirlemede kullanılır. Farklı örgü boyutlarına sahip modeller arasından doğru model olma olasılığı en büyük olan modeli bulmayı sağlar. Bir vokselle için,  $p$  örgü boyutunda BBK (5) ile hesaplanır.  $M$  vokselle sayısını temsil eder.

$$BBK_j(p) = \ln(\hat{E}_j(p)) + \frac{p \ln(M)}{M}, \quad (5)$$

#### C. Minimum Betimleme Uzunluğu (MBU)


MBU en iyi modelin, büyük bir bilgi kaybına yol açmadan olabilecek en kısa betimleme uzunluğu ile ifade edilen model olduğunu varsayar ve kompakt temsile önem verir. Bir vokselle için,  $p$  örgü boyutunda MBU aşağıdaki gibi hesaplanır:

$$MBU_j(p) = \hat{E}_j(p) \left( 1 + \left( \frac{p+1}{M} \right) \ln(M) \right), \quad (6)$$

$ABK_j(p)$ ,  $BBK_j(p)$  ve  $MBU_j(p)$  belirli bir aralıktaki tüm örgü boyutları için hesaplanır. Sonrasında  $ABK_j(p)$ ,  $BBK_j(p)$  ve  $MBU_j(p)$  yi minimize eden  $p$ 'ler ideal örgü boyutları olarak belirlenir.

#### V. BEYİNDE BAĞLANIRLIK DERECESİ

Her vokselin etrafında farklı boyutlu yerel örgü oluşturularak beyinde bir bağlantırlık modeli öne sürülmüştür. Önerilen yaklaşımın bilişsel bilimlere perspektifinden kapsamlı bir çalışmayla doğrulanması gereklidir. Bu çalışmada önerilen metod yalnızca bilişsel süreçlerin sınıflandırmasında kullanılarak, sabit boyutlu örgü modeliyle ve klasik ÇVÖA yöntemleriyle karşılaştırılmıştır. Modelin sınıflandırmadaki performansı, beyindeki bilgi dağılımını temsil etmedeki başarısının bir göstergesi olarak düşünülmektedir.



Şekil 2: Voksellerin uzamsal komşulukta kestirilen ideal örgü boyutlarının temsili [23].

Şekil 2 voksellerin uzamsal komşulukta kestirilen ideal örgü boyutlarını göstermektedir. Düğümler, *lateral temporal korteks* bölgesindeki voksellere karşılık gelmektedir. Renkler ise voksellerin bağlantırlık derecesini gösterir. Şekilde en koyu kırmızı en büyük ideal örgü boyutunu, en koyu mavi ise en küçük ideal örgü boyutunu temsil eder ve diğer renkler de bağlantırlık derecelerine göre voksellere atanmıştır. [23]. Görüldüğü üzere, bağlantırlık dereceleri benzer olan vokseller kümelenmiştir ve kümeler arası fark açıkça görülebilir.

#### VI. ÖYB ÖZNETELİKLERİNİN OLUŞTURULMASI VE SINIFLANDIRMA

İdeal örgü boyutu, eğitim veriseti kullanılarak ABK, BBK ve MBU için kestirilmiştir. Her vokselle için çıkarılan, değişken boyutlu ÖYB öznitelikleri ile verisetindeki her örnek için  $1 \times D_{ABK}$  boyutlu ( $D_{ABK} = \sum_{j=1}^M \hat{p}_j^{ABK}$ ),  $1 \times D_{BBK}$  boyutlu ( $D_{BBK} = \sum_{j=1}^M \hat{p}_j^{BBK}$ ) ve  $1 \times D_{MBU}$  boyutlu ( $D_{MBU} = \sum_{j=1}^M \hat{p}_j^{MBU}$ ) öznitelik vektörleri ABK, BBK ve MBU kullanılarak çıkarılır. Eğitim öznitelik vektörleri ve karşılık gelen sınıf etiketleri kullanılarak k-EK sınıflandırıcısı eğitilir. Yeni bir test verisi geldiğinde, eğitim örnekleriyle aynı öznitelik vektörü formuna dönüştürülür ve test örneğine k-EK sınıflandırıcısı ile bir sınıf etiketi atanır. Verisetimiz 8 run içermektedir, bu nedenle sınıflandırıcı hem tüm eğitim veriseti kullanılarak ( $S_1$ ) hem de her run için ayrı ayrı ( $S_2$ ) eğitilmiştir.

#### VII. SONUÇLAR

Bu çalışmada, her vokselle için ideal örgü boyutlarının da içinde bulunduğu örgü boyutlarının aralığı deneysel olarak [2, 100] olarak belirlenmiştir. Her vokselle için değişken boyutlu yerel örgüler oluşturulduğundan, ideal örgü boyutlarının ortalaması kestirilebilir (7):

$$\mu_{IC} \cong \frac{1}{M} \sum_{j=1}^M \hat{p}_j^{IC}. \quad (7)$$

IC üç bilgi kriteri ABK, BBK ya da MBU olmak üzere  $M$  vokselle sayısını,  $\hat{p}_j^{IC}$  ise  $\bar{s}_j$  koordinatlarındaki vokselle için kestirilen ideal örgü boyutunu temsil eder. Benzer şekilde ideal örgü boyutlarının standart sapması hesaplanabilir (8):

$$\sigma_{IC} \cong \sqrt{\frac{1}{M} \sum_{j=1}^M (\hat{p}_j^{IC} - \mu_{IC})^2} . \quad (8)$$

Tablo I: ABK, BBK ve MBU kullanılarak kestirilen ideal örgü boyutlarının ortalaması ve standart sapması

ABK		BBK		MBU	
$\mu_{ABK}$	$\sigma_{ABK}$	$\mu_{BBK}$	$\sigma_{BBK}$	$\mu_{MBU}$	$\sigma_{MBU}$
38.16	18.84	32.71	15.46	32.96	15.67

Tablo I ABK, BBK ve MBU kullanılarak kestirilen ideal örgü boyutlarının ortalamasını ve standart sapmasını gösterir. Tablo II ise tüm eğitim verisi ile eğitilen ve tüm test verisi ile sorgulanan ( $S_1$ ) sınıflandırma performansı ile her run için ayrı ayrı eğitilen ve sorgulanan sınıflandırma performanslarının ortalamasını ( $S_2$ ) göstermektedir. Ek olarak, ideal örgü boyutunun her voksel için sabit alındığı, katılımcı için tek bir ideal örgü boyutunun kestirildiği yöntem [13] ile yine tüm veri kullanılarak ( $F_1$ ) ve her run için ayrı ayrı ( $F_2$ ) yapılan sınıflandırma sonuçları da Tablo II’de gösterilmiştir. Tüm veri kullanılarak elde edilen klasik ÇVÖA yöntemlerinin performansı **45%** iken run bazında ÇVÖA yöntemlerinin ortalama performansı **57%**’dir. Tablo II’den görüleceği üzere, yöntemimizin performansı klasik ÇVÖA performansından oldukça yüksektir. Ek olarak, değişken örgü boyutu kullanımının ( $S_1$  ve  $S_2$ ), sabit örgü boyutu kullanımına ( $F_1$  ve  $F_2$ ) göre daha iyi performansa sahip olduğu da görülebilir.

Tablo II: ABK, BBK ve MBU kriterlerinin sabit ve değişken örgü boyutlu modellerde kullanım performansı

	ABK	BBK	MBU
$S_1$	75%	74%	74%
$F_1$	74%	71%	71%
$S_2$	78%	75%	75%
$F_2$	75%	71%	71%

### VIII. VARGI

Bu çalışmada, beyindeki bağlantılılığı modellemek için bilgi teoretik bir yöntem önerilmiştir. İlk olarak, her voksel etrafında uzamsal komşuluk kullanılarak yerel örgü oluşturulmuştur. Daha sonra, *Örgü Yay Ağırlıkları* bir regresyon modeliyle kestirilmiş ve her voksel için ideal örgü boyutu bilgi kriterleri minimize edilerek bulunmuştur. Çalışmanın temel katkısı, bilişsel süreç esnasında beyinde bölgeler arası bağlantılılık farkının gösterilmesidir. Bağlantılılık derecesi her voksel için ideal örgü boyutuyla ifade edilmiştir. Çalışmanın diğer bir katkısı ise değişken boyutlu ideal örgülerden oluşturulan ÖYB özneliklerinin bilişsel süreçleri sınıflandırmada hem klasik ÇVÖA metotlarından hem de sabit boyutlu ideal örgü kullanımından daha başarılı olduğunun gösterilmesidir. Gelecek çalışmalarda önerilen modelin anatomik ve bilişsel modellere uyumu araştırılacaktır.

### IX. TEŞEKKÜR

Zahide Pamir, Pınar Boyacı ve Ömer Faruk Gülban’a fMRG ön-işleme ve GLM analizi kısımlarındaki destekleri

için teşekkür ederiz. Bu proje TÜBİTAK 112E315 tarafından desteklenmektedir. Mete Ozay Avrupa Birliği Projesi PaCMan EU FP7-ICT, 600918 tarafından desteklenmektedir.

### KAYNAKÇA

- [1] K. A. Norman, S. M. Polyn, G. J. Detre, and J. V. Haxby, “Beyond mind-reading: multi-voxel pattern analysis of fmri data,” *TRENDS COGN SCI*, vol. 10, no. 9, pp. 424 – 430, 2006.
- [2] 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*, vol. 293, no. 5539, pp. 2425 – 2429, 2001.
- [3] Y. Kamitani and F. Tong, “Decoding the visual and subjective contents of the human brain,” *Nat Neurosci*, vol. 8, no. 5, pp. 679 – 685, 2005.
- [4] J.-D. Haynes and G. Rees, “Predicting the orientation of invisible stimuli from activity in human primary visual cortex,” *Nat Neurosci*, vol. 8, no. 5, pp. 686 – 691, 2005.
- [5] C. Davatzikos, K. Ruparel, Y. Fan, D. G. Shen, M. Acharyya, J. W. Loughhead, R. C. Gur, and D. D. Langleben, “Classifying spatial patterns of brain activity with machine learning methods: Application to lie detection,” *NeuroImage*, vol. 28, no. 3, pp. 663 – 668, 2005.
- [6] T. M. Mitchell, R. Hutchinson, R. S. Niculescu, F. Pereira, X. Wand, M. Just, and S. Newman, “Learning to decode cognitive states from brain images,” *Mach Learn*, vol. 57, no. 1-2, pp. 145 – 175, 2004.
- [7] S. M. Polyn, V. S. Natu, J. D. Cohen, and K. A. Norman, “Category-specific cortical activity precedes retrieval during memory search,” *Science*, vol. 310, no. 5756, pp. 1963 – 1966, 2005.
- [8] C. Plumpton, L. Kuncheva, D. Linden, and S. Johnston, “On-line fmri data classification using linear and ensemble classifiers,” in *ICPR*, 2010, pp. 4312–4315.
- [9] C. Plumpton, “Online semi-supervised ensemble updates for fmri data,” in *Partially Supervised Learning*, 2012, vol. 7081, pp. 8–18.
- [10] A. Gramfort, G. Varoquaux, B. Thirion, and C. Pallier, “Decoding visual percepts induced by word reading with fmri,” in *PRNI*, 2012, pp. 13–16.
- [11] M. Ozay, I. Oztekin, U. Oztekin, and F. T. Y. Vural, “Mesh learning for classifying cognitive processes,” *arXiv:1205.2382v2*, 2013.
- [12] O. Firat, M. Ozay, I. Onal, İlke Oztekin, and F. T. Y. Vural, “Functional mesh learning for pattern analysis of cognitive processes,” in *ICCI\*CC*, 2013.
- [13] I. Onal, M. Ozay, O. Firat, I. Oztekin, and F. T. Y. Vural, “Analyzing the information distribution in the fmri measurements by estimating the degree of locality,” in *EMBS*, 2013.
- [14] —, “An information theoretic approach to classify cognitive states using fmri,” in *BIBE*, 2013.
- [15] C. Baldasano, M. C. Iordan, D. M. Beck, and L. Fei-Fei, “Discovering voxel-level functional connectivity between cortical regions,” in *Machine Learning and Interpretation in NeuroImaging Workshop, NIPS*, 2012.
- [16] A. Zalesky, L. Cocchi, A. Fornito, M. M. Murray, and E. Bullmore, “Connectivity differences in brain networks,” *NeuroImage*, vol. 60, no. 2, pp. 1055 – 1062, 2012.
- [17] H. Akaike, “Information theory and an extension of the maximum likelihood principle,” in *2nd International Symposium on Information Theory*, 1973, pp. 267 – 281.
- [18] G. E. Schwarz, “Estimating the dimension of a model,” *Ann Stat*, vol. 6, no. 2, pp. 461 – 464, 1978.
- [19] J. Rissanen, “Modeling by shortest data description,” *Automatica*, vol. 14, no. 5, pp. 465 – 471, 1978.
- [20] I. Oztekin, C. E. Curtis, and B. McElree, “The medial temporal lobe and the left inferior prefrontal cortex jointly support interference resolution in verbal working memory,” *J Cognitive Neurosci*, vol. 21, no. 10, pp. 1967–79, 2009.
- [21] I. Oztekin and D. Badre, “Distributed patterns of brain activity that lead to forgetting,” *Frontiers in human neuroscience*, vol. 5, p. 86, 2011.
- [22] P. P. Vaidyanathan, *The Theory of Linear Prediction*. Morgan and Claypool Publishers, 2008.
- [23] M. Xia, J. Wang, and Y. He, “Brainnet viewer: A network visualization tool for human brain connectomics,” *PLoS ONE*, vol. 8, no. 7, 2013.