

Yerel Örgülerin Minimum Yayılan Ağaçları ile Bilişsel Süreç Betimleme

Cognitive Processes Representation Using Minimum Spanning Tree of Local Meshes

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 çalışmada, bilişsel süreçlerin sınıflandırılması amacıyla, Bilişsel Süreç Çizgesi (BSC) adı verilen yeni bir grafiksel model önerilmektedir. Önerilen BSC’de öncelikle, her vokselle etrafında bir yerel örgü kurulmaktadır. İkinci olarak, doğrusal bağlanım modeli kullanılarak hesaplanan yerel örgüdeki vokseller ile komşularının ilişkileri, BSC’yi oluşturan vokseller (çizge düğümleri) arasındaki kenarları oluşturmak için kullanılmıştır. Ardından, oluşturulan BSC’nin minimum yayılan ağacı (MYA) ilgi bölgesindeki tüm vokselleri kapsayacak şekilde hesaplanmıştır. MYA üzerinde bulunan kenar ağırlıkları bilişsel süreci betimlemekte kullanılmıştır. Son olarak, hesaplanan kenar ağırlıklarından MYA üzerinde bulunanlar istatistiksel bir öğrenme makinasını eğitmekte kullanılmıştır. Kullanılan bu kenar ağırlıkları MYA-Öznitelikleri (MYA-Ö) olarak adlandırılmıştır. Önerilen yaklaşım, belleğe bilgi kaydı ve geri getirme işlemleri için 10 sınıflı bilgi tipinden oluşan bir kelime tanıma belleği deneyi verisi üzerinde test edilmiştir. Bellekten geri getirmeyi farklı kategorideki sınıflar için ayırt edebilmek amacıyla yaygın olarak kullanılan iki sınıflandırıcı eğitilmiştir. Bu sınıflandırıcılar k-En Yakın Komşu (k-EK) ve Destek Vektör Makinası (DVM) olup, belleğe bilgi kaydı esnasındaki aktifleşme örüntüsü kullanılarak eğitilmişlerdir. Önerilen yaklaşım, örnek sayısı karşılaştırıldığında oldukça yüksek boyutta olan fMRG ölçümlerinin boyutluluk sorununu azaltmakla beraber bilişsel süreç sınıflandırma başarımı klasik Çoklu Vokselle Örüntü Çözümleme (Multi Voxel Pattern Analysis-MVPA) yöntemlerinden daha yüksektir.

Anahtar Kelimeler —fMRG; örgü öğrenme; minimum yayılan ağaç; örüntü analizi.

Abstract—In this study, we propose a new graphical model, namely Cognitive Process Graph (CPG) for classifying cognitive processes. In CPG, first local meshes are formed around each voxel. Second, the relationships between a voxel and its neighbors in a local mesh, which are estimated by using a linear regression model, are used to form the edges among the voxels (graph nodes) in the CPG. Then, a minimum spanning tree (MST) of the CPG which spans all the voxels in the region of interest is computed. The arc weights of the MST are used to represent the

underlying cognitive processes. Finally, the arc weights computed over the path of the MST called MST-Features (MST-F) are used to train a statistical learning machine. The proposed method is tested on a recognition memory experiment, including data pertaining to encoding and retrieval of words belonging to ten different semantic categories. Two popular classifiers, namely k-Nearest Neighbor (k-NN) and Support Vector Machine (SVM), are trained in order to predict the semantic category of the item being retrieved, based on activation patterns during encoding. The proposed method reduces the curse of dimensionality problem that is caused by very large dimension of the feature space of the fMRI measurements, compared to number of instances. The classification performance is also superior to the classical multi-voxel pattern analysis (MVPA) methods for the underlying cognitive process.

Keywords — fMRI; mesh learning; minimum spanning tree; pattern recognition.

I. GİRİŞ

Bilginin insan beyinde nasıl işlendiğine dair birçok yöntem geliştirilmektedir. Özellikle fonksiyonel Manyetik Rezonans Görüntüleme (fMRG), beyindeki dağıtık aktivasyon örüntülerini kullanarak, bilişsel süreçlerle ilintili beyin durumunu öngörmek veya çözümlenmek amacı ile kullanılmaktadır[1–8]. Beynin aynı anda birçok ölçekte ve yüksek oranda bağlı dinamik etkileşimlerinin, sadece bireysel voksellerden kaydedilen ölçümlerden anlaşılması mümkün değildir. Bu yüzden, beyin bağlanabilirliğinin kullanımına ve çizge kuramsal (graph theoretic) yöntemlere ilgi giderek artmaktadır. Özellikle fonksiyonel ve yapısal fMRG verilerinin çizge kuramsal analizi, beyinde gerçekleşen karmaşık etkileşimlerin karakterize edilmesinde verimli bir araç olarak kullanılmaktadır [9–19].

Beyin veri analizi için grafik teorik taslak kullanımının tercih edilmesinin ana nedeni, insan beyinin küçük-dünya (small-world) özelliği göstermesidir [20]. Küçük-dünya özelliği gösteren bir ağ, rastgele ağlara göre daha yüksek

kümelenme katsayısına ve daha düşük karakteristik yol uzunluğuna sahiptir (kümelenme katsayısı, bölgesel gruplanmaların bir ölçütü olup, yüksek kümelenme katsayısı olan bölgelerde kenarlar yerel yoğunlaşma gösterir) [10],[19]. Bu nedenle, uygun çizge ölçütleri kullanımı, beyin karmaşık dinamiklerinin alt yapısını oluşturan iletişim ağlarının topolojisi ortaya çıkarılabilir.


Bu çalışmada, bilişsel süreci temsil etmek maksadıyla, ilgi bölgesindeki vokselleri kapsayan lokal aktivasyon desenlerinin, potansiyel çizge kuramsal yöntem uygulamaları araştırılmıştır. Buna ek olarak, geliştirilen yöntemin bilişsel süreci betimleme başarımını ölçmek maksadıyla çok sınıflı bir sınıflandırma testi gerçekleştirilmiştir. Önerilen çizge kuramsal yöntem şu aşamaları içermektedir: Her bir vokselin çevresinde (merkez voksel), en yakın komşularını (çevre vokseller) içerecek şekilde bir yerel örgü oluşturulur. Merkez voksel ve çevre vokseller arasındaki ilişki, bir doğrusal bağlanım modelinde yerel örgü üzerindeki kenar ağırlıkları hesaplanarak modellenir. Kenar ağırlıkları, 3 boyutlu fiziksel uzayda her bir vokselin en yakın komşuları ile olan ilişkisini göstermektedir. Önerilen modelde, Bilişsel Süreç Çizgesi (BŞÇ) olarak adlandırılan çizge kuramsal betimleme, her bir vokselin çevresinde oluşturulan yerel örgülerin bir araya getirilmesiyle oluşturulur. BŞÇ oluşturulmasının ardından, bu çizgenin minimum yayılan ağacı (MYA) kenar ağırlıkları kullanılarak hesaplanır. Son olarak, MYA tarafından seçilen yol üzerinde bulunan kenar ağırlıklarından çıkarılan Minimum Yayılan Ağaç Öznitelikleri (MST-F) olarak adlandırılan öznitelikler, bilginin ve/veya bilişsel sürecin tipini teşhis eden sınıflandırıcıyı eğitmek için kullanılır. Bu çalışmada önerilen çizge kuramsal model kullanılarak, kısa süreli hafıza işlemleri sırasında belleğe bilgi kaydı (encoding) ve bellekten geri getirilen (retrieval) bilgi tipinin sınıflandırılması üzerinde durulmuştur.

Deney sırasında, katılımcılar önceden belirlenmiş olan 10 farklı kategoriden bir kelime üzerinde çalışmış (bilgi kaydı) ve ardından bu kelime ile ilgili bir bellek yargı testine (geri getirme) tabi tutulmuşlardır. Her iki safhada bilişsel aktivasyon fMRG tarafından kaydedilmiştir[21], [22]. Bu tasarıma göre, önerilen makine öğrenme algoritmasının, beyinde belirlenmiş bir zamanda sunulan bilgi tipini (örneğin kelimenin ait olduğu semantik kategori) tanımlama ve ayrıştırmadaki başarısı test edilmiştir. Standart MVPA yöntemleri ile karşılaştırıldığında, önerilen çizge kuramsal yöntemin sınıflandırma başarımında gözlemlenen iyileşme ve algoritmanın verimliliği ve kolaylığı, bilişsel süreçleri modellemedeki potansiyelini göstermektedir.

II. GEREÇLER VE YÖNTEMLER

A. fMRG deneyi ve ön-işleme

fMRG verisinin toplandığı deney üç aşamadan oluşmaktadır [21], [22]. Birinci safha belleğe bilgi kaydı amacıyla, katılımcıya kısa aralıklarla gösterilen, aynı sınıfa ait (örneğin hayvanlar veya meyveler) çeşitli kelimelerin gösterilmesinden oluşmaktadır. Bu aşama esnasında toplanan fMRG verileri, algoritmanın öğrenme safhasında kullanılmaktadır. İkinci aşama, üçüncü aşama olan bellekten bilgi geri getirme aşamasından önceki evre olup, bu aşamada katılımcıya basit matematiksel problemler çözdürülmektedir. 14 saniyelik bu periyot, bilgi kaydı ve geri getirme süreçlerinin fMRG verileri kullanılarak birbirinden bağımsız ölçülmesine



Şekil 1. BŞÇ oluşturularak 6-komşulu bir sistemde örnek MYA sunulmuştur. Vokseller siyah noktalarla gösterilmiş olup MYA oluşturan kenarlar kırmızı ile belirtilmiştir.

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, önerilen yöntemin test safhasında kullanılmaktadır. Belleğe bilgi kaydı ve geri getirme işlemlerini tetiklemek için, anlamsal yakınlığa göre oluşturulmuş 10 farklı kelime sınıfı kullanılmıştır. Bu sınıflar hayvanlar, renkler, eşyalar, vücut bölgeleri, meyveler, bitkiler, kıyafetler, kimyasal elementler, sebze ve aletler dir.

fMRG verileri örüntü analizi safhasından önce standart ön-işleme safhalarından geçirilmiştir. Görüntü işleme ve veri analizi SPM5 araç takımı kullanılarak gerçekleştirilmiştir (<http://www.fil.ion.ucl.ac.uk/spm/>). Fonksiyonel görüntüler dilim-tarama zaman düzeltmesi uygulanarak, ilk dilime göre düzeltilmiştir. Sonrasında tüm oturumlarda 3 boyutlu hareket düzeltmesi yapılmıştır (sinc enterpolasyon kullanılarak). Fonksiyonel veri kosinüs taban fonksiyonlarla doğrusal-olmayan, 12 parametreliliğin dönüşümü ile MNI uzayına göre normalize edilmiştir. Tüm görüntüler 2-mm voksellere yeniden örneklenmiş ve sonrasında 8-mm FWHM izotropik Gauss maskesiyle uzamsal olarak düzeltilmiştir. Sonrasında, fonksiyonel veriler oturumlar arasındaki taban hizası kayması ve tarayıcı sapmasının önüne geçmek maksadıyla eğilim-yoketmeye (detrending) tabi tutulmuştur. Literatürdeki çalışmalarla tutarlı olarak, uyarım başlangıçları hemo-dinamik tepki gecikmesi durumu dikkate alacak şekilde 3 nokta ileri kaydırılmıştır [23].

B. Yerel Örgü Oluşturma ve Kenar Ağırlıkları Hesaplanması

Elde edilen fMRG verisi her bir voksel için bir zaman serisi olacak şekilde kayıt edilmiştir. Bu çalışmada, BOLD sinyalleri $v(t_i, \bar{s}_j)$ her bir zaman örneği t_i , $i = 1, 2, 3, \dots, N$, ve her bir voksel koordinatı \bar{s}_j , $j = 1, 2, 3, \dots, M$ için ölçümü ifade etmektedir. Burada N toplam zaman örneği sayısı, M ise toplam voksel sayısını belirtmektedir. Veri seti $D = \{v(t_i, \bar{s}_j)\}$ beyinde üç boyutta dağıtılmış voksellere ait BOLD sinyallerinden $v(t_i, \bar{s}_j)$ oluşmaktadır. Dolayısıyla, t_i anında bir vokselin $v(t_i, \bar{s}_j)$, pozisyonunu belirten $\bar{s}_j = (x_j, y_j, z_j)$, 3-boyutlu bir vektör olarak temsil edilebilir. Her t_i anında, katılımcı belli bir anlamsal sınıfa ait bir kelimeyi işlemekte (kodlama ya da geri çağırma) olduğundan, her örneğin

$v(t_i, \bar{s}_j)$, bir sınıf etiketi vardır. Anlamsal sınıflar, her bir merkez voksel için oluşturulan yerel örgüler kullanılarak modellenmiştir. Yerel örgüler uzamsal olarak tanımlanmış olan bir komşuluk sisteminde η_p , oluşturulmuştur. Bir yerel örgüde, merkez voksel $v(t_i, \bar{s}_j)$, p -en yakın komşu voksele $\{v(t_i, \bar{s}_k)\}_{k=1}^p$, ağırlıkları $\{a_{i,j,k}\}_{k=1}^p$ olan kenarlarla bağlıdır. Böylece her vokselde ölçülen BOLD sinyalleri arasındaki ilişki kenar ağırlıklarıyla temsil edilebilmektedir. p -en yakın komşu seti, η_p , vokseller arasındaki mesafenin beyindeki voksellerin uzamsal koordinatları \bar{s}_j arasındaki Öklit uzaklıkları (MNI koordinatları) kullanılarak hesaplanmakta olup, *uzamsal-en yakın komşuluk* olarak adlandırılmıştır[24]. Örgünün kenar ağırlıkları $a_{i,j,k}$ aşağıdaki doğrusal bağlanım denklemi ile hesaplanmıştır :

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

Bu denklemde $\varepsilon_{i,j}$, t_i zamanında, \bar{s}_j konumundaki voksel $v(t_i, \bar{s}_j)$ için hata payı olup, $\eta_p(\bar{s}_j)$ ise \bar{s}_j konumundaki vokselin p -en yakın komşularının kümesini gösterir. Kenar ağırlıkları $a_{i,j,k}$ hata payının karesi $\varepsilon_{i,j}^2$ minimuma indirgenerek elde edilmiş olup bu maksatla Levinson-Durbin özyineleme yöntemi kullanılmıştır [25]. Her t_i anında ki merkez voksel için hesaplanmış kenar ağırlıklar $a_{i,j,k}$, örgü kenar ağırlıkları vektörü olan $\bar{a}_{i,j} = [a_{i,j,1} a_{i,j,2} \dots a_{i,j,p}]$ oluşturmak için kullanılmıştır. Kenar ağırlıkları vektörleri bir sonraki bölümde anlatılacak olan Bilişsel Süreç Çizgesi (BSC) oluşturmak için kullanılacaktır.

C. Bilişsel Süreç Çizgesini Oluşturma ve Minimum Yayılan Ağaçları Hesaplama

Yönsüz ve ağırlıklı bir çizgenin yayılan ağacı, hiç bir döngü oluşturmadan çizgedeki tüm düğümleri içeren bir alt çizgedir (bkz. Şekil 1). Bu çizgenin en düşük toplam kenar ağırlıklı yayılan ağacına, Minimum Yayılan Ağaç (MYA) denir. Dolayısıyla, MYA'nın herhangi iki düğümünü bağlayan yalnızca tek bir yol (kenar) vardır ve bir MYA düğümünün iki komşu düğümü birbiri ile bağlanamaz. İnsan beyni ağlarının maliyet etkin olduğu görüldüğünden [26] dolayı, MYA'lar çizge kuramsal modeller için beyin ağının omurgası olarak düşünülebilir. İkinci olarak MYA'lar, ağ bağlanım bilgisini korurken, sınıflandırma problemleri için öznitelik vektörlerinin boyutunu azaltarak daha kompakt bir bilişsel durum temsili sunmaktadırlar. MYA'lar fonksiyonel beyin ağlarının inceleme, dinlenme durumu (resting state) varsayılan durum ağlarının değerlendirilme ve tıbbi rahatsızlıkların keşfi gibi geniş kullanım alanına ulaşmıştır [9], [10], [19], [27].

fMRG verisi kullanılarak oluşturulan bilişsel süreç ve/veya bilgi tiplerinin sınıflandırması doğası gereği zor bir görevdir. Bunun sebepleri girdi öznitelik uzayının yüksek boyutlu olması (8.000 ile 80.000 boyut arasında) ve sınıf başına düşük sayıda örneğin var olmasıdır. Bu problem, yerel örgüdeki bir vokselin komşu sayısı yükseltildiğinde tümüyle ön plana çıkmaktadır (örneğin yerel örgülerde 10 komşu olması toplam 8.000 voksel için öznitelik vektörünü kolaylıkla 80.000 boyuta ulaştırmaktadır). Literatürde boyutluluk sorunu [28] olarak geçen bu problemin üstesinden gelmek için, bu çalışmada,

yerel örgülerdeki kenar ağırlıkları Bilişsel Süreç Çizgesi (BSC) adı verilen bir çizgede toplanmakta, ardından da bu BSC için Minimum Yayılan Ağaç çıkarılmaktadır.

BSC, yönsüz bir çizge olup $G_i = (S, E_i)$, t_i anında bilişsel süreci temsil etmektedir. BSC üzerinde çizge düğümleri $\bar{s}_j \in S$ voksel koordinatları ile, kenar ağırlıkları ise $\{a_{ijk}, a_{ikj}\} \in E_i$, yerel örgü üzerindeki doğrusal bağlanım katsayıları ile tanımlanmıştır. Voksel pozisyonlarının zaman içinde değişmemesi nedeniyle düğüm kümesi S üzerindeki zaman indeksi olan i çıkartılmıştır. BSC kenar ağırlıkları, merkez vokselin her bir yerel komşusu için hesaplanmaktadır. Bu sebeple, t_i anındaki bir voksel için, kenar ağırlıklarını $\bar{a}_{i,j} = \{a_{i,j,k}\}_{k=1}^p$, (1) kullanılarak hesaplamak için p -sayıda en yakın komşu kullanılır. Kullanıcı tanımlı komşuluk parametresi olan (p) her vokselin uzamsal olarak bitişiğindeki voksel sayısı ile sınırlıdır ve 6, 18 veya 26 olarak alınabilir. Düğümler ve kenar ağırlıkları tanımlandıktan sonra her t_i anı için BSC'lere ait MYA hesaplama oldukça kolaydır. Dikkat edileceği gibi, yerel komşuluktaki her bitişik voksel çifti için (örneğin \bar{s}_j ve \bar{s}_k konumlarında), farklı ağırlıklı iki kenar mevcuttur. Biri merkez voksel \bar{s}_j ve komşusu \bar{s}_k vokseli arasında diğeri ise tam tersi istikamettir. Bu kenar ağırlıklarından daha küçük kenar ağırlığı MYA hesaplama sırasında kullanılmıştır. Bu husus minimum yayılan ağacın ana esasına uymaktadır. Her t_i anı için hesaplanan MYA'lar kullanılarak bir set $\{T_i\}_{i=1}^N$ oluşturulmuştur.

Kenar ağırlıkları $a_{i,j,k}$, farklı komşuluk boyutlarına göre 6, 18 ve 26 hesaplanarak deneyler gerçekleştirilmiştir. Bu prosedür hem eğitime hem de test verisetinde MYA kümelerinin çıkarılması şeklinde yürütülmüştür. Eğitim ve test verisetlerinde hesaplanan MYA setleri daha sonrasında, sadece MYA'lar tarafından seçilen yollarda bulunan kenar ağırlarını dikkate alınara, nihai öznitelikleri oluşturmakta kullanılmıştır. Bu özniteliklere MYA-Ö adı verilmiştir. Şekil 1 6-komşulu bir sistemde ki BSC için hesaplanan MYA'nın şematik çizimini göstermektedir.

III. SONUÇLAR

MYA-Ö yönteminin amacı, BSC'ler için hesaplanan MYA'ların 10 ayrı anlamsal kategoriye net bir şekilde sınıflandırıp sınıflandıramayacağı test etmek ve bu modeli voksel yoğunluk değerlerinin sınıflandırmada doğrudan öznitelik olarak kullanıldığı klasik MVPA metotlarıyla kıyaslamaktır. Deneylerde kullanılan ilgi alanımız beynin *lateral temporal korteks* bölümünü içermektedir. MYA-Ö sonuçları k -en yakın komşu (k -EK) ve Destek Vektör Makinası (DVM) yöntemleri kullanılarak oluşturulmuştur. k -EK yönteminde bulunan k parametresi ve DVM sınıflandırıcısındaki Gauss çekirdek parametreleri, eğitim kümesinde çapraz doğrulama yapılarak seçilmiştir. Sınıflandırma doğruluğu, doğru tahmin edilmiş test örneklerinin, test kümesindeki toplam örneklere olan oranı olup, her bir BSC'nin minimum yayılan ağacı Kruskal algoritması [29] ile hesaplanmıştır. DVM [30] uygulanmasında LIBSVM (<http://www.csie.ntu.edu.tw/~cjlin/libsvm/>) kütüphanesi kullanılmıştır.

TABLO I. HER BİR YÖNTEM İÇİN SINIFLANDIRMA BAŞARIMI

Uygulanan Yöntem	Öz nitelik Sayısı	Sınıflandırıcı Doğruluğu	
		k-EK	DVM
Klasik MVPA Yöntemi*	8142	44.77%	39.75%
MYA-Ö (6 komşulu)	8141	54.39%	58.16%
MYA-Ö (18 komşulu)	8141	58.16%	59.83%
MYA-Ö (26 komşulu)	8141	59.83%	61.09%

*Voksel yoğunluk değerleri sınıflandırıcıya doğrudan öz nitelik olarak verilmiştir.

MYA-Ö yöntemi başarımını değişen boyuttaki komşuluklarda değerlendirmek için, farklı boyutta örgüler oluşturularak ve kenar ağırlıkları buna göre hesaplanmıştır. Diğer bir deyişle, bir merkez voksele 6, 18 ve 26 komşuluk düşünülerek farklı boyutlarda örgüler oluşturulmuş ve sonra bütün örgüleri kullanarak MYA'lar hesaplanmıştır. MYA-Ö yöntemi ve MVPA yöntemi [2] kullanılarak sınıflandırıcı performansları Tablo I de verilmiştir. Klasik MVPA yöntemi, 10 sınıflı sınıflandırma görevimizde k-EK ile %45 ve DVM ile %40 doğruluğa ulaşmıştır. BŞÇ ile beraber MYA kullanarak, özellik uzayı boyutunu artırmadan sırasıyla %10 ve %18 gelişme gözlemlenmiş olup k-EK ve DVM için %54 ve %58 sınıflandırma doğruluklarına ulaşılmıştır. Komşuluk büyüklüğünü arttırdıkça daha fazla performans gelişimi gözlemlenmiştir. Bu iyileşmenin sebebi daha geniş bir alanda daha fazla sayıda voksel ilişkisinin modellenmesi olarak yorumlanabilir. Diğer taraftan, Gauss çekirdeği ile DVM'in sonsuz boyutlu uzaylarda çalıştığı bilinmektedir [30]. DVM'nin bu özelliği, k-EK'e kıyasla boyutluluk probleminde daha az hassas olmasına yol açmakta olup, MYA-Ö kullanılan deneylerde k-EK metodundan daha yüksek performans elde edimi sağlamıştır.

IV. VARGI

Bu çalışmada, vokseller ve onların *p-en yakın komşuları* arasındaki yerel örgüleri tanımlamak maksatlı Minimum Yayılan Ağaç (MYA)'ları içeren, Bilişsel Süreç Çizgesi(BŞÇ) adı verilen bir çizge modeli öneriyoruz. Mevcut veri kümesi kullanılarak, önerilen model kısa süreli hafıza görevi sırasında test edilmiştir ve geleneksel MVPA yöntemlerine göre daha yüksek başarımler gözlemlenmiştir. Bu çalışmada, yalnızca belleğe bilgi kaydı ve bellekten geri getirme modelleme üzerine odaklanılmıştır. İlerideki çalışmalarda, farklı bilişsel süreçler modellenerek, önerilen algoritmanın başarımının genel geçerliği üzerinde çalışılacaktır. Ayrıca BŞÇ ve MYA hesaplamalarında fonksiyonel bağlanabilirlik kullanarak, algoritmamızı geliştirmeyi umuyoruz.

KAYNAKÇA

- [1] I. Oztekin and D. Badre, "Distributed patterns of brain activity that lead to forgetting," *Front. Hum. Neurosci.* 5:86, 2011.
- [2] 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.
- [3] J.-D. Haynes and G. Rees, "Decoding mental states from brain activity in humans.," *Nature reviews. Neuroscience*, vol. 7, pp. 523-34, Jul. 2006.
- [4] A. Battle, G. Chechik, and D. Koller, "Temporal and cross-subject probabilistic models for fmri prediction tasks.," 2006.

- [5] C.-J. Lin and M.-H. Hsieh, "Classification of mental task from EEG data using neural networks based on particle swarm optimization.," *Neurocomputing*, vol. 72, no. 4-6, pp. 1121-1130, Jan. 2009.
- [6] J. Richiardi, H. Eryilmaz, S. Schwartz, P. Vuilleumier, and D. Van De Ville, "Decoding brain states from fMRI connectivity graphs.," *NeuroImage*, vol. 56, no. 2, pp. 616-26, May 2011.
- [7] W. R. Shirer, S. Ryali, E. Rykhlevskaia, V. Menon, and M. D. Greicius, "Decoding subject-driven cognitive states with whole-brain connectivity patterns.," *Cerebral cortex*, vol. 22, no. 1, pp. 158-65, Jan. 2012.
- [8] M. Ramezani, S. Member, P. Abolmaesumi, K. Marble, H. Macdonald, and I. S. Johnsrude, "Classification of Individuals Based on Sparse Representation of Brain Cognitive Patterns: a Functional MRI Study.," no. 604, pp. 2688-2691, 2012.
- [9] K. Ciftçi, "Minimum spanning tree reflects the alterations of the default mode network during Alzheimer's disease.," *Annals of biomedical engineering*, vol. 39, no. 5, pp. 1493-504, May 2011.
- [10] A. F. Alexander-Bloch et al., "Disrupted modularity and local connectivity of brain functional networks in childhood-onset schizophrenia.," *Frontiers in systems neuroscience*, vol. 4, Jan. 2010.
- [11] S. L. Bressler and V. Menon, "Large-scale brain networks in cognition: emerging methods and principles.," *Trends in cognitive sciences*, vol. 14, no. 6, pp. 277-90, Jun. 2010.
- [12] B. Chai, D. B. Walther, D. M. Beck, and F.-F. L., "Exploring Functional Connectivity of the Human Brain using Multivariate Information Analysis.," *NIPS*, pp. 1-9, 2009.
- [13] S. L. Bressler and E. Tognoli, "Operational principles of neurocognitive networks.," *International journal of psychophysiology* : vol. 60, no. 2, pp. 139-48, May 2006.
- [14] F. Deligianni et al., "Relating brain functional connectivity to anatomical connections: Model Selection.," pp. 5-9.
- [15] M. Guye, F. Bartolomei, and J.-P. Ranjeva, "Imaging structural and functional connectivity: towards a unified definition of human brain organization?," *Current opinion in neurology*, vol. 21, no. 4, Aug. 2008.
- [16] M. Guye, G. Bettus, F. Bartolomei, and P. J. Cozzone, "Graph theoretical analysis of structural and functional connectivity MRI in normal and pathological brain networks.," *Magma* vol. 23, no. 5-6, Dec. 2010.
- [17] O. Sporns, G. Tononi, and G. M. Edelman, "Theoretical neuroanatomy: relating anatomical and functional connectivity in graphs and cortical connection matrices.," *Cerebral cortex* vol. 10, no. 2, Feb. 2000.
- [18] O. Sporns, "The human connectome: a complex network.," *Annals of the New York Academy of Sciences*, vol. 1224, pp. 109-25, Apr. 2011.
- [19] O. Sporns, "Networks of the Brain.," *MIT press*, Nov. 2010.
- [20] D. J. Watts and S. H. Strogatz, "Collective dynamics of 'small-world' networks.," *Nature*, vol. 393, no. 6684, pp. 440-2, Jun. 1998.
- [21] 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.," *Journal of cognitive neuroscience*, vol. 21, no. 10, pp. 1967-79, Oct. 2009.
- [22] I. Oztekin and D. Badre, "Distributed Patterns of Brain Activity that Lead to Forgetting.," *Frontiers in human neuroscience*, vol. 5, p. 86, Jan. 2011.
- [23] S. M. Polyn, V. S. Natu, J. D. Cohen, and K. A. Norman, "Category-specific cortical activity precedes retrieval during memory search.," *Science (New York, N.Y.)*, vol. 310, no. 5756, pp. 1963-6, Dec. 2005.
- [24] M. Ozay, I. Oztekin, and U. Oztekin, F. T. Yarman Vural. "A mesh learning model for pattern analysis of brain activity", under review.
- [25] P. P. Vaidyanathan, "The Theory of Linear Prediction.," *Synthesis Lectures on Signal Processing*, vol. 2, no. 1, pp. 1-184, Jan. 2007.
- [26] V. Latora and M. Marchiori, "Economic small-world behavior in weighted networks.," *The European Physical Journal B - Condensed Matter*, vol. 32, no. 2, pp. 249-263, Mar. 2003.
- [27] R. Baumgartner, R. Somorjai, R. Summers, and W. Richter, "Ranking fMRI time courses by minimum spanning trees: assessing coactivation in fMRI.," *NeuroImage*, vol. 13, no. 4, pp. 734-42, Apr. 2001.
- [28] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern Classification*, 2nd ed., New York, NY, USA: Wiley & Sons, Inc., 2001.
- [29] J. Kruskal, "On the Shortest Spanning Subtree of a Graph and the Traveling Salesman Problem.," *Proceedings of the American Mathematical Society*, vol. 7, no. 1, pp. 48 - 50, 1956.
- [30] R.-E. Fan, P.-H. Chen, and C.-J. Lin. Working set selection using second order information for training SVM. *JMLR*, 6, 1889-1918, 2005.