

Anlambilimsel sınıflandırılmanın iMRG görüntülerinde konumlanması

Localization of semantic category classification in fMRI images

Sarper Alkan

Bilişsel Bilimler Ana Bilim Dalı; Mekatronik Mühendisliği Bölümü
Orta Doğu Teknik Üniversitesi; Çankaya Üniversitesi
sarper@cankaya.edu.tr

Fatoş T. Yarman-Vural

Bilgisayar Mühendisliği Bölümü
Orta Doğu Teknik Üniversitesi
vural@ceng.metu.edu.tr

Özetçe —Bu çalışmada beyin bölgelerini, anlambilimsel kategorilerin sınıflandırmasına dayanarak işaretleyen bir yöntem sunulmaktadır. Bu amaçla, öncelikle beyin görüntüleri izgesel kümeleme yöntemiyle bölütlenmiştir. Sonrasında örgübağı yöntemi ile her bölütün içerisinde bölgesel öznitelikler çıkarılmıştır. Son olarak da her bir bölgeden çıkarılan özniteliklerle sınıflandırıcı eğitilmiş ve sınıflandırma yapılmıştır. Her bir bölgenin sınıflandırma doğruluğu bizim önerdiğimiz bir önsav testi yöntemiyle değerlendirilmiştir. Bu yöntemler kullanılarak alınan sonuçlarda, özellikle mahmuz oluşunun ve angular girusun sınıflandırmada etken olduğu belirlenmiştir. Bu sonuçlar yapılan deneyin doğasıyla örtüşmekte ve sonuç olarak kullandığımız yöntemin geçerliliğini onaylamaktadır.

Anahtar Kelimeler—İşlevsel Manyetik Rezonans Görüntüleme (iMRG), öznitelik çıkarma, öznitelik kümeleme, beyin deşifresi, sınıflandırma, önsav testi, Çoklu Voksel Örüntü Çözümlemesi (ÇVÖÇ).

Abstract—In this study, we provide a methodology to localize the brain regions that contribute to semantic category classification. For this purpose we first cluster the data using spectral clustering. Then we extract local features within each cluster by using mesh-arc descriptors. Finally, we test the classification accuracy of each cluster against a hypothesis testing measure we provide here. We have found that, for the experimental task at hand, calcerine fissure and angular gyrus were most effective in classification. These results are shown to be match well with the nature of the experiment. Thus the validity of our approach is confirmed.

Keywords—Functional Magnetic Resonance Imaging (fMRI), feature extraction, feature clustering, brain decoding, classification, hypothesis testing, Multi Voxel Pattern Analysis (MVPA).

I. GİRİŞ

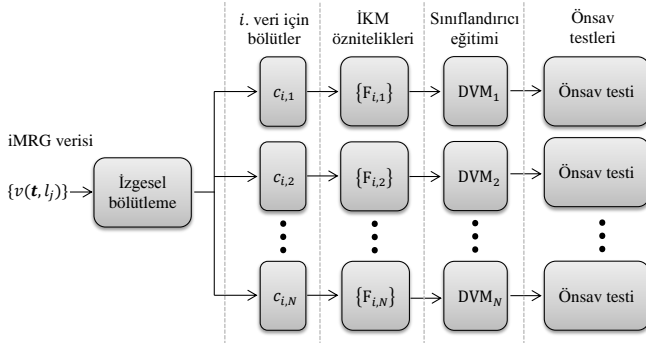
İşlevsel manyetik rezonans görüntüleme (iMRG), beyin işlevlerinin beyin bölgeleriyle ilişkilendirilmesinde kullanılagelen bir yöntemdir. Bu yöntemde beyin, milimetrik (3-5 mm) çözünürlükte voksellere (hacimsel piksel) bölünmekte, ve bu voksellerde bir saniye zamansal çözünürlükle bağlı kan oksijenlenme seviyesi ölçülmektedir. Burada kan oksijenlenme seviyesi o anki görev için,

dinlenme durumuna bağlı olarak ölçülmektedir. Buradan yola çıkılarak görevle ilgili beyindeki değişimler belirlenmeye çalışılmaktadır. Her ne kadar iMRG yıllardır kullanılıyor olsa da, görüntülerin değerlendirilmesi uzun süre, tekil vokselleri (ya da bunların grup ortalamalarını) kullanan varyans çözümlemesi yöntemleriyle yapılmıştır. Ancak, çoklu voksel örüntü çözümlemesi (ÇVÖÇ) yöntemleri bu yöntemin sınırlarını aşmıştır [1]–[3].

ÇVÖÇ yöntemlerinde farklı deneysel kategorilere ait iMRG görüntüleri ile örüntü sınıflandırıcıları eğitilmekte ve bu sınıflandırıcılar kullanılarak özgün örnekler sınıflandırılmaktadır [1], [4]. Bu yöntemlerin başarısı yakın zamanda geliştirilen ve voksellerin uzamsal ve işlevsel komşuluklarını modelleyen örgübağı yöntemi [5] ve bunu geliştiren işlevsel komşuluk modeli (İKM) yöntemlerle daha da artırılmıştır [6], [7]. Bütün bu yöntemler çoğunlukla ya önceden belirlenmiş ilgili bölgeler kullanmakta ya da bir çeşit dengelilik ölçütünü baz alarak sınıflandırmada kullanılacak öznitelik vektörünü sınırlamaya çalışmışlardır.

Bunun yanında, diğer bir çalışma alanında beynin iMRG verisi kullanarak işlevsel olarak bölütlenmesi hedeflenmiştir. Bu alandaki çalışmalar, dinlenme durumunda çekilmiş iMRG verilerini kullanarak işlevsel beyin haritaları oluşturmayı amaçlamaktadır [8], [9]. Bunun için, her bir voksele ait sayısal değer, bütün deneylerden alınan değerlerle birleştirilerek bir zaman serisi oluşturulmaktadır. Bu zaman serileri de vokseller arasında korelasyon tabanlı bir benzeşim ölçütü oluşturmada kullanılmaktadır. Sonrasında bu ölçüte dayanarak da beyin işlevsel olarak bölütlenmektedir.

Bu bildiriye, beyin bölgelerinin sınıflandırmaya dayalı işaretlenmesi amacıyla geliştirilmiş, bu iki yöntemin birlikte kullanıldığı bir işlevsel bölütleme ve sınıflandırma algoritması sunulmaktadır. Bu algoritmanın sonuçları yine bizim önerdiğimiz önsav testi ile değerlendirilmiştir. Değerlendirme sonuçları, deneklerin beyin etkinliğini deney gereksinimleriyle ve beynin işlevsel bölgeleriyle ilgili yazın ile tutarlı bir şekilde belirleyebilmektedir.



Şekil 1: Algoritmanın akış şeması. İlk başta, tüm veri kullanılarak izgesel bölütleme yapılmıştır. Sonrasında her bir deney aşaması i için bölütlerin her birinde bağ ağırlıkları hesaplanmıştır. Ardından, tüm deney aşamalarından çıkarılan öznitelikler kullanılarak her bir bölüt için bir DVM sınıflandırıcısı eğitilmiştir. Bu sınıflandırıcısı ise

II. VERİ KÜMESİ

Kullandığımız veri, Mitchell ve diğerlerinin çalışmasından alınmıştır [10]. Veri, dokuz farklı deneye ait iMRG görüntülerini içermektedir. Her deney aşamasında deneklere bir nesnenin çizimi ve nesnenin cins ismi gösterilmektedir. Her gösterilen nesne ise, bir anlambilimsel kategoriye dahildir. Deneklerden bu gösterilen nesne hakkında düşünmesi istenmektedir. Nesne gösterilirken de deneyin beyninin iMRG görüntüsü alınmaktadır. Bu şekilde her deneye 12 anlambilimsel kategoriye ait 60 farklı nesne (her bir kategoriden 5 nesne) 6 farklı rasgele permutasyon ile gösterilmiş ve toplamda her bir denek için 360 iMRG görüntüsü oluşturulmuştur.

III. ALGORITMA

Bu çalışmada her bir denek için elde edilen iMRG verisi öncelikle aşağıda anlatılan izgesel kümeleme algoritmasıyla kümelendirilmiştir. Sonrasında her bir deney aşaması i için, her bir c_n kümesinde $F_{i,n}$ öznitelikleri çıkarılmıştır. Bu öznitelikler kullanılarak ve her doğrulama adımında, her anlambilimsel kategoriye ait rasgele bir deney aşaması dışarıda bırakılarak destek vektör makinaları (DVM) eğitilmiştir. Daha sonra, dışarıda bırakılan aşamalara ait öznitelikler kullanılarak doğrulama yapılmıştır. Toplamda doğrulama süreci bu şekilde 20 adımdan oluşmaktadır. Bu sürecin 20 adımdan oluşmasının nedeni, daha sonra uygulanacak önsav testi için yeterli örnek sayısı oluşturmakla beraber işlem süresini de uygulanabilir bir seviyede tutmasıdır. Son olarak da doğrulama adımlarında elde edilen sonuçlar önsav testi ile değerlendirilmiştir (Şekil 1).

Bu çalışmada $v(\mathbf{t}, l_j)$ ile ifade edilen her vokselle, beyindeki yeri $l_j, j = 1, 2, 3, \dots, J$ ve deney aşamaları $t_i, i = 1, 2, 3, \dots, I$ olan bir zaman serisini göstermektedir. Burada J toplam vokselle sayısı, I ise deney aşamalarının toplam sayısıdır. Öte yandan l_j konumundaki bir vokselin i . deneydeki değeri ise $v(t_i, l_j)$ ile ifade edilmektedir. Hem kümeleme algoritması hem de İKM algoritması vokseller arası benzerlik ölçütü olarak Pearson korelasyonunu kullanmaktadır. $v(\mathbf{t}, l_j)$ ve $v(\mathbf{t}, l_k)$ vokselleri arasındaki Pearson korelasyonu ρ_{jk} :

$$\rho_{jk} = \frac{cov_{jk}(v(\mathbf{t}, l_j), v(\mathbf{t}, l_k))}{\sqrt{var_j(v(\mathbf{t}, l_j)) \cdot var_k(v(\mathbf{t}, l_k))}} \quad (1)$$

olarak verilmiştir. Burada cov_{jk} vokseller arası kovaryansı, var_j ise varyansı ifade etmektedir.

A. Kümeleme

Kümeleme algoritması olarak Craddock ve diğerlerinin kullandığı izgesel kümeleme algoritması kullanılmıştır [8]. Bu yöntemde öncelikle voxel çiftleri arasındaki benzerlikler hesaplanarak bir bağlantı grafik oluşturulmuştur. Sonrasında, bu grafikte, her bir vokselin bağlantı sayısı üç boyutlu vokselle ızgarasındaki 26 en yakın komşusuyla sınırlanmıştır. Bu şekilde her bir vokselle, en uzağı kendisinden bir küpün köşegeni kadar uzakta olan voksellerle bağlantı sayılmıştır. Burada amaç oluşacak kümelerin bir dereceye kadar tıkmaz olmasını sağlamaktır [8]. Son olarak da bu grafik üzerinde normalize kesitler algoritması kullanılarak bölütleme yapılmış ve vokselle kümeleri (c) oluşturulmuştur.

Burada, bir G grafiğini A ve B olarak iki bölgeye ayıran bir kesme algoritması bu iki bölgeyi birbirine bağlayan voksellerdeki (v_j, v_k) bağlantı ağırlıkları $(w_{j,k})$ toplamının minimize edilmesiyle kurulabilir:

$$Kesit(A, B) = \sum_{v_j \in A, v_k \in B} w_{j,k}. \quad (2)$$

Ancak, bu davranışı gösteren bir algoritma tekrarlı uygulandığında tekil voksellerden oluşan bir grafik oluşmasına yol açacaktır [8]. Normalize kesitler algoritması ise bu soruna yol açmaz. Normalize kesitler algoritmasında her bir bölüt için kesit masrafı o bölüte dahil olan voksellerin, grafikteki tüm diğer voksellerle olan bağlantı ağırlıklarının toplamına bölünerek normalize edilir:

$$N_K(A, B) = \frac{Kesit(A, B)}{\sum_{v_j \in A, v_g \in G} w_{j,g}} + \frac{Kesit(A, B)}{\sum_{v_k \in B, v_g \in G} w_{k,g}}. \quad (3)$$

Sonuç olarak, hem bölütlerin kendi içinde bağlantı ağırlıkları toplamı maksimize edilirken hem de bölütler arası kesilen bağlantıların ağırlıkları toplamı minimize edilmiş olur.

B. İşlevsel Komşuluk Modeli

İKM algoritması, her bir vokseli, o vokselin Pearson korelasyonu ile hesaplanan işlevsel komşuluğunda oluşturulan bir örgü ile modeller. Bu sayede bilişsel durumların modellenmesinde voksellerin kendileri değil vokseller arasındaki ilişkiler kullanılır. Bir $v(t_i, l_j)$ vokseli için aynı kümede bulunan ve o vokselin p işlevsel komşuluğundaki vokseller kullanılarak örgü oluşturulur.

Örgü modeli kullanılarak her deney aşaması i deki her voksel $v(t_i, l_j)$ o vokselin η_p komşuluğunda bulunan voksellerle arasındaki bağlantı ağırlıkları $a_{i,j,k}$ tarafından temsil edilir. Bağ ağırlıkları, aşağıdaki doğrusal regresyon denklemindeki hata terimi $\varepsilon_{i,j}$ en aza indirgenerek hesaplanır [5]:

$$v(t_i, l_j) = \sum_{l_k \in \eta_p} a_{i,j,k} v(t_i, l_k) + \varepsilon_{i,j}. \quad (4)$$

Bu çalışma dahilinde her bir i . deney aşamasında her bir $c_{i,n}$, $n = 1, 2, 3, \dots, N$ kümesindeki tüm voksellere ait bağ ağırlıkları bir vektör halinde birleştirilerek öznitelik vektörleri $F_{i,n}$ oluşturulur. Burada $N = \{5, 10, 50, 100, 200\}$ bölütlemedeki toplam küme sayısını belirtmektedir. Ayrıca, yapılan tüm deneylerde $\eta_p = 22$ olarak alınmıştır. Bu sayı empirik olarak bulunmuş en yüksek başarıyı veren komşuluk değeridir.

C. Ayırıcı kümeler için önsav testi

Bir anlambilimsel kategoriye diğerlerinden şans düzeyinden yüksek olasılıkla kesinlikle ayıran kümeleri bulmak için bir önsav testi önerilmiştir. Bu teste göre bir kümenin bir semantik kategoriye ayırıcı bir şekilde sınıflandırması için bu sınıfı tüm doğrulama adımları içerisinde en az T kere doğru sınıflandırmış olması gerekmektedir. Ayırıcılık eşiği T şu şekilde hesaplanmaktadır: $X_{m,n}$, c_n kümesinde m ($m = 1, 2, 3, \dots, M$) sınıfı için sınıf değeri üreten bir rastsal değişken olsun. Burada M , toplam anlambilimsel kategori sayısını ifade etmektedir. Bu değişken, bir Bernoulli rastsal değişkeni olarak $X_{m,n} \sim \text{Bernoulli}(p = 1/M)$ aşağıdaki biçimde ifade edilebilir:

$$X_{m,n} = \begin{cases} 1, & \text{sınıf doğru tahmin edilmiş,} \\ 0, & \text{sınıf yanlış tahmin edilmiş.} \end{cases} \quad (5)$$

Bu durumda, tüm doğrulama adımları (R) içerisinde, m sınıfı için c_n kümesinde, s ya da daha az sayıda doğru tahmin yapma olasılığı, $Z_{m,n} = \sum_{r=1}^R X_{m,n,r} \sim \text{Binom}(R, p = 1/M)$ Binom rastsal değişkeninin olasılık dağılımı şeklinde ifade edilebilir:

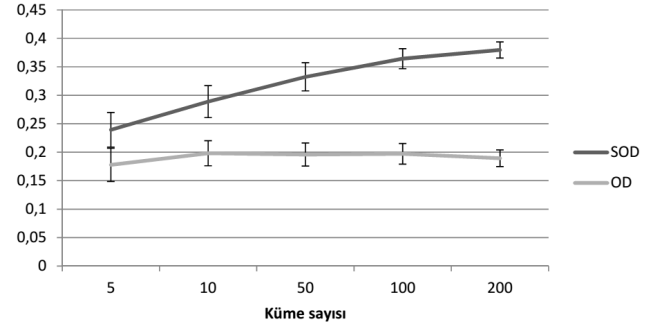
$$P(Z_{m,n} \leq s) = \sum_{r=1}^s \binom{R}{r} p^r (1-p)^{(R-r)}. \quad (6)$$

Buna göre, tüm adımlarda toplam doğru tahminin en az bir kategori ve en az bir küme için s 'ten fazla olma ihtimali aşağıdaki gibidir:

$$P(Z > s) = 1 - P(Z_{m,n} \leq s)^{MN}, \quad (7)$$

Burada N , bölütlemedeki toplam küme sayısını ifade etmektedir. Her ne kadar bu hesaplamada $Z_{m,n}$ değişkenlerinin bağımsız ve aynı olması varsayıldıysa da, böyle olmaması durumu bu olasılığın sadece artmasına yol açmaktadır. Dolayısıyla bu elde ettiğimiz olasılık değeri bir önsav testi olarak kullanılabilir. Bu önsav testine göre $P(Z > s) < 0.05$ olasılığını veren $T > s$ değeri hesaplanabilir.

Bu çalışmada, yukarıdaki belirtildiği gibi hesaplanan T değerleri kullanılarak, bu T değerinden daha yüksek başarı gösteren kümeler, ayırıcı küme olarak işaretlenmiştir.



Şekil 2: Sınıfsal ortalama doğruluk (SOD) ve ortalama doğruluk (OD) değerlerinin bölütlemedeki küme sayısına göre değişimleri grafikte verilmiştir. Hata çizgileri standart hatayı göstermektedir.

IV. DENEYLER VE SONUÇLAR

Bu bildiri kapsamında bölütlemenin sınıflandırma başarımına etkisini görmek için Mitchell ve diğerlerinin veri kümesinde iki tür deney yapılmıştır. İlkinde, her sınıfta her bir bölüt sayısında en iyi doğruluğu veren kümelerin doğrulukları alınmış ve bunların tüm sınıflar için ve tüm denekler için ortalaması alınmıştır (SOD). İkincisinde ise, tüm sınıflar için ortalama en iyi başarıyı veren kümeler seçilmiş ve bunların doğruluklarının tüm denekler için ortalaması alınmıştır (OD). Bu veriler göstermektedir ki, tüm sınıfları yüksek başarıyla bulan kümeler her kümeleme içerisinde bulunmakla beraber, ancak küme sayısı arttıkça (ortalama küme boyutu küçüldükçe) her bir kategoriye daha yüksek doğrulukla sınıflandıran kümeler ortaya çıkmaktadır. Buna dayanarak söyleyebiliriz ki sınıflandırmaya dayalı bir konumlandırma mümkündür ve ancak ancak kategori bazında bu konumlandırma yapılabilir (Şekil 2).

Bu deneylere ek olarak, sınıflandırma kullanılarak bulunan ayırıcı kümelerin beyin bilinen anatomik bölgeleri ile ilişkileri de Tablo I'de verilmiştir. Bu tabloda her bir etiketlenmiş bölgenin kaç kez, bir ayırıcı küme ile % 50'den daha yüksek oranda örtüştüğü gösterilmektedir. Burada sayılar, herhangi bir ayırıcı kümenin, herhangi bir etiketlenmiş bölgenin %50'sinden fazlasını kapsamaması durumunu ya da tersi durumu sayarak hesaplanmıştır. Oran ise bir etiketle örtüşme sayısının toplam örtüşme sayısına oranını vermektedir. Sayıların hesaplanmasında tüm deneklerden çıkarılan sonuçlar kullanılmıştır.

Tablo I'de görüldüğü üzere, en yüksek ayırıcılığa sahip bölgeler beynin sol kısmında yer almaktadır. Yapılan deneyin dil ile ilgili doğası gereği bu, beklenen bir sonuçtur. Diğer taraftan, beynin hem sağ hem de sol yarımküredeki simetrik alanlarının yüksek ayırıcılık gösterecek biçimde ortaya çıkmaları da kullandığımız yöntem için bir doğrulayıcıdır.

Burada bölgelerin sıralamasına bakıldığında en üstte mahmuz oluşu (calcarine fissure) bulunmaktadır. Deneylerde her nesne için nesne adıyla beraber nesnenin çiziminin de deneklere gösterildiğini biliyoruz. Mahmuz oluşu'nun birincil görme sisteminin bulunduğu yer olması, aslında burası ile eşleşmiş ayırıcı kümelerin doğrudan nesnelerin beyindeki görüntülerini ayırt ettiği sonucunu doğurmaktadır. Deneyler sırasında denekler çizime bakarken iMRG görüntüsünün alınmış olması bu

Tablo I: 117 anatomik olarak etiketlenmiş bölge arasından en yüksek ayırıcılığa sahip bölgeler.

Anatomik etiket	Sayı	Oran
Calcarine_Sol	71	16,44%
Angular_Sol	46	10,65%
Angular_Sağ	40	9,26%
Calcarine_Sağ	34	7,87%
Amygdala_Sol	31	7,18%
Cerebelum_4_5_Sağ	26	6,02%
Amygdala_Sağ	22	5,09%
Frontal_Inf_Oper_Sol	15	3,47%
Frontal_Inf_Oper_Sağ	13	3,01%
Precentral_Sol	12	2,78%
Fusiform_Sol	12	2,78%
Cerebelum_4_5_Sol	12	2,78%
Cerebelum_6_Sağ	12	2,78%
Cingulum_Ant_Sol	11	2,55%
Cerebelum_6_Sol	11	2,55%
Sol yarımküre	264	61%
Sağ yarımküre	168	39%

sonucu desteklemektedir.

Deneyler sırasında denekler nesne adını yazılı olarak görmüşlerdir. Angular ve Fusiform bölgelerinde yüksek ayırıcılık ortaya çıkması ve bu bölgelerin özellikle yazılı kelimeleri okumada işlev görmesi [11]–[13] sonuçlarımızın doğruluğunu destekler niteliktedir.

Deneyler sırasında deneklerden, gördükleri nesnenin özelliklerini düşünmeleri istenmiştir. Bu, deneklerin örneklerle bağlantılı kelimeleri türetmesi sonucunu doğuracaktır. Bu, Broca alanındaki (Frontal Inferior) yüksek ayırıcılığı da açıklar niteliktedir. Bilindiği üzere Broca alanı kelime ve dil üretiminde kullanılmaktadır [14], [15].

Son olarak, Mitchell ve diğerlerinin sonuçları göz önüne alındığında, anlambilimsel olarak temel, duyuyla ve motor hareketlerle ilgili kelimelerin, diğer kelimelerin anlamlarını üretmekte çok etkin olduğu ortaya konulmuştur [10]. Bu bulgu aslında anlambilimsel kategorilerin dağıtık olarak beyinde çeşitli temel duyu ve motor işlevlerle ilgili bölgelerde ifade edilmesi durumunu desteklemektedir. Bizim sonuçlarımız da temel duyu ve motor hareketlerle ilgili bölgelerin (amygdala, calcarine, cerebelum) anlambilimsel kategoriler için yüksek ayırıcılıkta olduğunu göstermiştir.

V. SONUÇ

Yaptığımız çalışmada iki önemli sonuç ortaya çıkmıştır. Birincisi, beyinde daha dar alanlara odaklandıkça her anlambilimsel kategoriyi diğerlerinden çok daha iyi ayıran bölgelere ulaşma ihtimali artmaktadır. Bu, tüm beyni değil ama dar bölgeleri içine alıp daha sonra bunları birleştiren beyin analizlerinin en azından anlambilimsel kategorileri ayırtmede daha ekten olacağını göstermektedir. İkincisi ise, kelimelerin anlamlarının aslında beynin tek bir bölgesinde değil, temel işlevlerle ilgilenen birden çok bölgesinde dağıtık olmasıdır. Bu bulguyu destekler nitelikte yayınlar da ayrıca mevcuttur [16], [17].

KAYNAKÇA

[1] D. D. Cox and R. L. Savoy, "Functional magnetic resonance imaging (fmri) "brain reading": detecting and classifying distributed patterns of fmri activity in human visual cortex," *Neuroimage*, vol. 19, no. 2, pp. 261–270, 2003.

[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. 424–430, 2006.

[3] J.-D. Haynes and G. Rees, "Decoding mental states from brain activity in humans," *Nature Reviews Neuroscience*, vol. 7, no. 7, pp. 523–534, 2006.

[4] A. J. O'toole, F. Jiang, H. Abdi, and J. V. Haxby, "Partially distributed representations of objects and faces in ventral temporal cortex," *Journal of Cognitive Neuroscience*, vol. 17, no. 4, pp. 580–590, 2005.

[5] M. Ozay, I. Öztekin, U. Öztekin, and F. T. Yarman Vural, "Mesh learning for classifying cognitive processes," *arXiv preprint arXiv:1205.2382*, 2012.

[6] I. Onal, M. Ozay, O. Firat, I. Oztekin, and F. T. Yarman Vural, "Analyzing the information distribution in the fmri measurements by estimating the degree of locality," in *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*. IEEE, 2013, pp. 6772–6775.

[7] O. Firat, M. Ozay, I. Onal, I. Oztekin, and F. T. Y. Vural, "Functional mesh learning for pattern analysis of cognitive processes," in *Cognitive Informatics & Cognitive Computing (ICCI* CC), 2013 12th IEEE International Conference on*. IEEE, 2013, pp. 161–167.

[8] R. C. Craddock, G. A. James, P. E. Holtzheimer, X. P. Hu, and H. S. Mayberg, "A whole brain fmri atlas generated via spatially constrained spectral clustering," *Human brain mapping*, vol. 33, no. 8, pp. 1914–1928, 2012.

[9] T. Blumensath, S. Jbabdi, M. F. Glasser, D. C. Van Essen, K. Ugurbil, T. E. Behrens, and S. M. Smith, "Spatially constrained hierarchical parcellation of the brain with resting-state fmri," *NeuroImage*, 2013.

[10] T. M. Mitchell, S. V. Shinkareva, A. Carlson, K.-M. Chang, V. L. Malave, R. A. Mason, and M. A. Just, "Predicting human brain activity associated with the meanings of nouns," *science*, vol. 320, no. 5880, pp. 1191–1195, 2008.

[11] N. Geschwind *et al.*, *Language and the brain*. WH Freeman, 1972.

[12] B. Horwitz, J. M. Rumsey, and B. C. Donohue, "Functional connectivity of the angular gyrus in normal reading and dyslexia," *Proceedings of the National Academy of Sciences*, vol. 95, no. 15, pp. 8939–8944, 1998.

[13] B. D. McCandliss, L. Cohen, and S. Dehaene, "The visual word form area: expertise for reading in the fusiform gyrus," *Trends in cognitive sciences*, vol. 7, no. 7, pp. 293–299, 2003.

[14] R. M. Hinke, X. Hu, A. E. Stillman, S.-G. Kim, H. Merkle, R. Salmi, and K. Ugurbil, "Functional magnetic resonance imaging of broca's area during internal speech," *Neuroreport*, vol. 4, no. 6, pp. 675–678, 1993.

[15] J. H. Brannen, B. Badie, C. H. Moritz, M. Quigley, M. E. Meyerand, and V. M. Haughton, "Reliability of functional mr imaging with word-generation tasks for mapping broca's area," *American Journal of Neuroradiology*, vol. 22, no. 9, pp. 1711–1718, 2001.

[16] L. Tyler, E. Stamatakis, E. Dick, P. Bright, P. Fletcher, and H. Moss, "Objects and their actions: evidence for a neurally distributed semantic system," *Neuroimage*, vol. 18, no. 2, pp. 542–557, 2003.

[17] D. Kemmerer, J. G. Castillo, T. Talavage, S. Patterson, and C. Wiley, "Neuroanatomical distribution of five semantic components of verbs: evidence from fmri," *Brain and language*, vol. 107, no. 1, pp. 16–43, 2008.