

# Classification of ADHD Using Ensemble Algorithms with Deep Learning and Hand Crafted Features

## Derin Öğrenme ve Manuel Öznitelik Çıkarma Yöntemleri ile Topluluk Algoritmaları Kullanarak DEHB'nin Sınıflandırılması

Gülay ÇİÇEK<sup>1</sup>, Mesut ÇEVİK<sup>2</sup>, Aydın AKAN<sup>3</sup>

<sup>1</sup>Biyomedikal & Yazılım Mühendisliği Bölümü, İÜ-Cerrahpaşa&Beykent Üniversitesi, İstanbul, Türkiye  
gulaycicek@beykent.edu.tr

<sup>2</sup>Mekatronik Mühendisliği Bölümü, Kadir Has Üniversitesi, İstanbul, Türkiye  
mesut.cevik@khas.edu.tr

<sup>3</sup>Biyomedikal Mühendisliği Bölümü, İzmir Katip Çelebi Üniversitesi, İzmir, Türkiye  
aydin.akan@ikc.edu.tr

**Özetçe**— Çocukluk çağında sıklıkla görülebilen Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB) bir beyin hastalığıdır. Tanı için, geliştirilen yöntemler, farklı zamanlarda farklı sonuçlar vermektedir. Bu durum, hastalığın tanısında önemli bir engel teşkil etmektedir. DEHB teşhis modeli; özgün, nesnel ve güvenilir olmalıdır. Bu çalışmada, DEHB teşhis modelinde, yapısal manyetik rezonans görüntülerin sınıflandırılması için hem manuel hem de derin öğrenilmiş özniteliklerin karşılaştırılması bir değerlendirilmesi sunulmuştur. Bu amaçla, NPIstanbul NeuroPsikiyatri Hastanesi ve ADHD-200 veri tabanındaki manyetik rezonans görüntüleri(MRI) kullanılmıştır. MRI görüntülerini karakterize edilmesi için, Birinci mertebeden, İkinci mertebeden istatistiksel öznitelikler (First Order, Second Order) ve Alexnet mimarisi kullanılmıştır. İmgeler, topluluk yöntemiyle sınıflandırma(Ensemble Algorithm) algoritması ile sınıflandırılmıştır. Sınıflandırma başarımı tespit etmek amacıyla, doğruluk, duyarlılık, özgüllük, tp oranı, fp oranı ve f-ölçütü değerleri göz önüne alınmıştır. El ile çıkarılan üç veri kümesinin birleşiminin, verileri karakterize etmede daha başarılı sonuçlar verdiği gözlemlenmiştir.

**Anahtar Kelimeler** — manuel ve otomatik öznitelik çıkarımı, alexnet, evrimsel sinir ağları, dikkat eksikliği hiperaktivite bozukluğu.

**Abstract**— Attention Deficit Hyperactivity (ADHD) is a common neurodevelopmental disorder that typically appears in early childhood. Methods developed for diagnosing gives different results at different times. This is a major obstacle in the diagnosis of disease. Diagnosis model of ADHD must be unique, objective, and reliable. In this study, comparative evaluations of both manual and deep features for classification of structural magnetic resonance images is presented. For this purpose, datasets of NPIstanbul Neuropsychiatry Hospital and public datasets of ADHD-200 is used. In order to characterize MRI images First Order, Second Order statistical features and the Alexnet architecture is used. Images are classified with the ensemble algorithm. In order to determine classification performance, accuracy, sensitivity, specificity, tp rate, fp rate and F-measure

values are taken into consideration. It was observed that the combination of three manually extracted data sets yielded more successful results in characterizing the data.

**Keywords** — hand crafted and automated features, alexnet, convolutional neural network, attention deficit hyperactivity disorder.

### I. GİRİŞ

Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB), çocuklarda öğrenme, duygu, sosyal ilişki ve uyum bozukluklarına yol açabilen dürtüsellik, dikkatsizlik ve hiperaktivite belirtileri ile karakterizedir [1]. Dünya nüfusunun %5 inin DEHB hastası olduğu tespit edilmiştir [2]. DEHB hastası çocukların %70 i yetişkinliklerinde de bu hastalığa sahip olmaya devam etmektedirler [3]. Yetişkin DEHB hastaları depresyon, anksiyete bozukluğu, madde bağımlılığı, trafik kazaları ve suçla ilişkilendirilmektedirler [4]. Bu nedenle günümüzde DEHB önemli bir halk sağlığı sorunu haline dönüşmüştür [5]. Ancak, DEHB çocukların ebeveynlerinin ve öğretmenlerinin görüşlerinin deneyimli çocuk psikiyatristleri tarafından klinik incelemeye alınmasıyla teşhis edilir. Tanılar ebevenler, öğretmenler ve hatta psikiyatristler arasında farklılık gösterebilir. Tanının öznel olmasının nedeni DEHB'nin psikopatolojisinin açık olmamasıdır. Şimdiye kadar DEHB ve diğer psikiyatrik hastalıkları teşhis etmek için hiçbir nesnel yaklaşım bulunamamıştır.

Son yıllarda Elektroensefalografi (EEG) ve Manyetik Rezonans Görüntüleme (MRG) nörobilimde yaygın olarak kullanılmaya başlanmıştır. Bu tıbbi görüntüler yüksek uzaysal ve zamansal çözünürlüğe sahip oldukları için DEHB ve diğer ruhsal bozukluklarda beyin yapısı ve işlevi araştırmalarında kullanılmaktadırlar [6]. Yapay zeka (YZ) nın gelişimi ile birlikte yardımcı tanı için kullanılan makine öğrenme algoritmalarının beyin görüntülerinin işlenmesinde oldukça yetenekli oldukları görülmüştür. Destek Vektör Makineleri(DVM), temel bileşenler analizi ve çoklu-çekirdek

öğrenmesi gibi makine öğrenmesi algoritmaları öznelik seçimi ve karar optimizasyonu yapabilmek için bilgisayar tarafından çıkarılan öznelikleri kullanırlar [7]. Tümör bölümlene ve hastalık desen tanıma gibi zorlu görevlerde uygulanan derin öğrenme modelleri ve özellikle de katlamalı sinir ağları insanüstü doğruluk ve etkinliğe ulaşmışlardır [8], [9]. Yukarıdaki teknolojilerin geliştirilme ve bütünleştirilmesi tıbbi görüntülerin otomatik analizi ve hastalıkların teşhisi için yeni bir fırsat sağlar.

2011 yılında, ADHD-200 Konsorsiyumu yayımlanan veri kümesinden DEHB olan bireyleri teşhis etmek amacıyla dünya çapında (ADHD-200 Küresel Yarışması isimli) bir yarışma düzenledi. ADHD veri kümesi sekiz bağımsız beyin görüntüleme tarama sitesinden dinlenme durumunda fMRI, yapısal MRI ve kalıtımla oluşan dış görünüş(fenotip) bilgilerini içerir. Bu yarışmanın birincisi DEHB hastalarını ve hasta olmayanları %61.5 doğruluk ile sınıflandırdı. Bu yarışmadan sonra, birçok araştırmacı sınıflandırma doğruluğunu arttırmak ve DEHB'nin beyin ağını anlamaya yardımcı olmayı amaçlayan yeni yöntemler önermeye devam ettiler. En geleneksel yaklaşımlar, DEHB hastalarını hasta olmayanlardan ayırt etmek için ham fMRI taramalarından el ile çıkarılan öznelikleri sınıflandırıcılara giriş olarak kullandılar. El ile çıkarılan öznelıklar ön bilgi ya da belli bir amaca dayanan insan tasarımı özneliklerdir, yani özneliğin kendisi doğrudan tasarlanır. Bu çıkarılan öznelikler arasında Kesirli Genlik Düşük Frekans Dalgalanması(Fractional Amplitude of Low-Frequency Fluctuation:fALFF) [10], Bölgesel Homojenlik(Regional Homogeneity:ReHO) [11], Bağımsız Bileşen Analizi Haritaları(Independent Component Analysis Maps:ICA) [12] en çok kullanılmış ve beyin görüntüleme analizi ve işlevsel beyin ağlarının anlaşılması üzerine anlamlı etkiler göstermiştir.

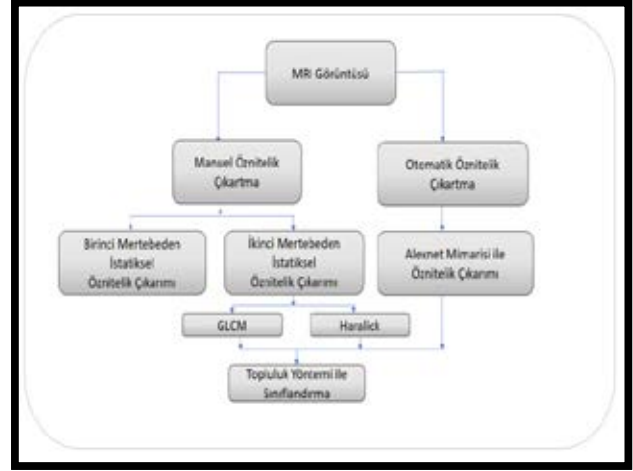
Dai ve arkadaşları [13] kortikal kalınlık(cortical thickness:CT), gri madde olasılığı(gray matter probability:GMP), ReHo ve fonksiyonel MRI da dahil olmak üzere hem yapısal ve fonksiyonel bağlantıdan (functional connectivity:FC) çıkarılan çoklu öznelikleri kullanmışlardır. Her bir özneliğin etkilerini incelemiş ve bu öznelikleri çoklu çekirdek öğrenmesi(multi-kernel learning:MKL) ile birleştirerek %61.5 sınıflandırma doğruluğu elde etmişlerdir. Guoa ve arkadaşları, MRI verilerini kullanarak sosyal ağ yöntemini araştırdı [14].

Bu çalışmada, DEHB sınıflandırma modeli için, manyetik rezonans görüntülerini karakterize edecek özneliklerin bulunmasında, manuel ve otomatik öznelik çıkartım yöntemlerinden yararlanılmıştır.

## II. YÖNTEM

Bu çalışmada, NPIstanbul NeuroPsikiyatri Hastanesi ve ADHD-200 veri setinden alınan manyetik rezonans görüntüleri DEHB sınıflandırma modeli için kullanılmıştır. ADHD -200 veri tabanı 7 farklı merkezden alınan manyetik rezonans görüntülerini içermektedir. Şekil 1. Önerilen yöntem için genel bir bakış açısı sunmaktadır. Önerilen yöntem, MRI görüntüsünü girdi olarak alıp, iki ayrı öznelik çıkartma tekniğine göndermektedir. Manuel ve Otomatik öznelik çıkartma teknikleri ile verileri karakterize edecek öznelik belirlenmiştir.


Manuel öznelik çıkartma tekniği ile görüntünün dokusunu temsil edecek üç ayrı öznelik çıkartma tekniği uygulanmıştır. Bunlar, Birinci Mertebeden İstatiksel yöntem ile İkinci mertebeden istatistiksel yöntemleri (GLCM ve Haralick) içermektedir. Görüntüden özneliklerin otomatik öğrenilmesi için de AlexNet mimarisi kullanılmıştır. Görüntüler, topluluk yöntemi ile sınıflandırılmıştır.



Şekil 1. Beyin MRI İmgeleri

### A. Görüntü Edinimi

NPIstanbul NeuroPsikiyatri Hastanesinden alınan 25 görüntünün, 9'u DEHB li, 11'i sağlıklı bireylere ait görüntülerden oluşmaktadır. Her bir MRI görüntüsü 256 kesitten oluşmaktadır. Erişimi herkese açık olan ADHD-200 veri kümesinde 139 DEHB'li ve 154 si sağlıklı bireylere ait görüntüler kullanılmıştır. Gri ve Beyaz Maddenin net gözüktüğü dilimler kullanılmıştır. Dilimlerin toplamından elde edilen görüntüler, yöntemimize girdi olarak kabul edilmiştir. Şekil 2. de, DEHB ve Sağlıklı bireylere ait örnek girdi görüntüleri verilmiştir.



a) DEHB b) SAĞLIKLI

Şekil 2. Örnek beyin İmgeleri

### B. Öznelik Çıkartımı

Öznelik çıkartımı, verilerin boyutlarını azaltmada önemli bir adımdır. DEHB teşhis modelinde, MRI görüntülerinin boyutlarını azaltarak, verileri en iyi bir biçimde karakterize etmek için iki ayrı yöntem uygulanmıştır. Bunlar; el ile özneliklerin belirlenmesi ve otomatik olarak özneliklerin belirlenmesi şeklindedir.

### 1. Manuel Öznitelik Çıkarma Yöntemi

El ile öznitelik çıkarma yönteminde, üç ayrı öznitelik çıkartma tekniği uygulanmıştır. Birinci mertebeye istatistiksel öznitelik (First Order Statistical) ve İkinci Meriteden istatistiksel öznitelik (Second Order Statistical) yöntem kullanılmıştır. Her piksel değerinin bitişik piksel değeri ile ilişkisine bakılmaksızın, birinci meriteden istatistiksel öznitelikler çıkarılır. Çıkarılan öznitelikler şunlardır; Varyans, ortalama, çarpıklık ve kurtosisdir. İkinci Meriteden istatistiksel yöntemde ise, her pikselin bitişik piksel ile olan ilişkisi göz önüne alınarak öznitelik çıkarılır. GLCM ve Haralick öznitelik çıkartma tekniği uygulanmıştır. GLCM, belirli bir uzamsal ilişkide belirli piksel çiftlerinin frekans bilgisinden yararlanılarak imgelerden enerji(Energy), zıtlık (Contrast), korelasyon (Correlation) ve homojenlik (homogeneity) öznitelikleri çıkarıldı. Her pikselin diğer piksel ile olan ilişkisi dikkate alınarak, görüntüleri karakterize edecek şu öznitelikler çıkarıldı. Açısıl İkinci Moment (Angular Second Moment), Zıtlık(Contrast), Korelasyon (Correlation), Kareler Toplamı (Sum of Squares), Varyans (Variance), Ters Fark Momenti (Inverse Difference Moment), Toplam Ortalama (Sum Average), Toplam Varyans (Sum variance), Entropi (Entropy), Fark Varyansı (Difference Variance), Fark Entropisi (Difference Entropy), Korelasyon Bilgi Ölçümü (Information Measure of Correlation I), Korelasyon Bilgi Ölçümü 2 (Information Measure of Correlation II) ve Maximum Korelasyon Katsayısı (Maximal Correlation Coefficient).

### 2. Otomatik Öznitelik Çıkarma Yöntemi

Derin öğrenme ağları, klasik sinir ağlarından, öncelikle katman sayısı yönüyle ayrılmaktadır. Klasik sinir ağlarının, derin öğrenme yöntemlerine yaklaşmasının zor olma nedenleri arasında, bu ağların sadece giriş katmanı, tek gizli katman ve çıktı katmanından oluşmasıdır. CNN modeli, kullanıcıya sunduğu mimari ile klasik sinir ağlarından daha iyi performans sergiler. Bu çalışmada Alex net CNN modeli kullanılmıştır. AlexNet CNN modelinde girdi boyutları, 227\*227\*3 şeklinde olmalıdır. AlexNet mimarisi 25 katmandan oluşmakta ve görüntüden otomatik öznitelikler çıkartmaktadır. Mimarinin katman sayıları şöyledir. 5 adet konvolusyon, 2 adet dropout, 3 adet tam bağlı katman, 7 adet relu katmanı, 2 adet normalizasyon katmanı, softmax katmanı, giriş ve çıkış katmanından oluşmaktadır. Derin öğrenme mimarisinde yer alan katmanların işlevleri şöyledir. Konvolusyon katmanı, görüntü matrisi üzerindeki matrisin gezdirilmesiyle görüntüden öznitelik çıkarılır. Havuzlama katmanı ile görüntü matrisi küçültülür. Örneğin; görüntü üzerinden, 2X2 parametresi ve max değeri girildiğinde, görüntünün her 2X2 lik alanından en büyük değer, yeni matrise aktarılır. Tam bağlı katman, nöronlar bu katmanda tam bağlı olarak yer alır. Katmanlardaki nöronlar, mutlaka kendinden sonraki katman ile bağlantılıdır. Relu katmanı, aktivasyon fonksiyonunu içerir. Genellikle kullanılan aktivasyon şu şekildedir. Piksel değerleri negatif ise sıfır olarak değiştirilir, eğer değilde piksel değeri değiştirilmez. Ağda, aşırı öğrenmeyi ve ezberlemeyi kaldırmak için drop out katmanı, önemli bir görev üstlenir. Böylece, ağır performansı yükselir. Ağın performansını artmayı sağlayan katmanlardan biri de


normalizasyon katmanıdır. Normalizasyon katmanı ile değerlerin belirli aralıklara çekilmesi sağlanarak, ağır performansı artırılmış olur. Softmax katmanı ile önceki katmandan gelen parametrelere göre sınıflandırma için olasılıksal değer üretilir.

### III. SINIFLANDIRMA


Sınıflandırma algoritması ile amaç öznitelikleri bilinen görüntülerin hangi sınıfa ait olduğunu tespitidir. Bu çalışmada, bir önceki aşamada, görüntüden elde edilen manuel ve otomatik öznitelikler topluluk öğrenme yöntemi ile sınıflandırıldı. Topluluk yöntemleri çok sayıda sınıflandırıcı modellerini birleştirerek, daha güçlü ve yüksek başarılı sonuçlar üretmeyi amaçlar. Boosted, Bagged, Subspace Discriminat, Subspace KNN, RUSBoosted Trees topluluk yöntemi sınıflandırma algoritmaları kullanılmıştır.

### IV. DENEYSEL SONUÇLAR


Görüntüler iki farklı öznitelik algoritmasına girdi olarak gönderilmiştir. El ile öznitelik çıkartma tekniğinde; dört ayrı veri kümesi oluşturulmuştur. Birinci meriteden istatistiksel öznitelik veri kümesi(FirstOrder DataSet) ile İkinci meriteden İstatistiksel Öznitelik(GLCM, Haralick,) veri kümeleri oluşturulmuştur. Bunun yanı sıra, üç veri kümesinden elde edilen öznitelikler birleştirilerek, (FirstOrder\_GLCM\_Haralick\_) yeni bir veri kümesi de oluşturulmuştur. Alexnet yardımıyla, görüntüden otomatik öznitelikler çıkarılmıştır. Toplamda 5 ayrı veri kümesi oluşturulmuş ve her bir veri kümesinin DEHB tanı modelindeki performansı 10 kaz çapraz doğrulama ile gerçekleştirilmiştir. Her bir modelin, doğruluk, duyarlılık, özgüllük ve f-ölçütü değerleri hesaplanmıştır.




Şekil 3. First Order Veri kümesinin Detaylı Performans Sonuçları




Şekil 4. GLCM Veri kümesinin Detaylı Performans Sonuçları



Şekil 5. Haralick Veri Kümesinin Detaylı Performans Sonuçları



Şekil 6. AlexNet in Detaylı Performans Sonuçları



Şekil 7. Manuel Özniteliklerin birleşimin performans sonuçları

## V. TARTIŞMA VE SONUÇLAR

Dikkat eksikliği Hiperaktivite Bozukluğu bir beyin hastalığıdır. Tanı için geliştirilen yöntem, nesnel ve güvenilir olmalıdır. Bu çalışmada, DEHB teşhis modelinde, MRI görüntülerin sınıflandırılması için hem manuel hem de derin öğrenilmiş özniteliklerin karşılaştırılması bir değerlendirilmesi sunulmuştur. Bu amaçla, 5 farklı veri kümesi oluşturulmuş ve topluluk yöntemi ile sınıflandırılmıştır. Modellerin başarımları oranları incelendiğinde el ile çıkarılan öznitelikleri içeren üç veri kümesinin birleşiminin manyetik rezonans görüntülerini karakterize etmede daha iyi sonuçlar verdiği gözlemlenmiştir. Derin öğrenme yönteminde yüksek başarımları elde etmek için, fazla sayıda veriye ihtiyaç vardır. NPIstanbul NeuroPsikiyatri ve ADHD-200 veri kümesinden alınan 318 veri, AlexNet mimarisi ile DEHB teşhis modeli için yeterli olmadığı gözlemlenmiştir. Ancak, verileri karakterize edecek özniteliklerin iyi belirlenmesi halinde az miktardaki veri ile el

ile çıkarılan özniteliklerin DEHB teşhis modelinde başarılı sonuçlar verdiği gözlemlenmiştir.

## VI. KAYNAKÇA

- [1] American Psychiatric Association, "American Diagnostic and Statistical Manual of Mental Disorders," Washington, DC, 2013.
- [2] G., Polanczyk, M., Lima, B., Horta, J., Biederman, Rohde, L., "The World Wide Prevalence of ADHD: A systematic review and meta-regression analysis," *Am. J. Psychiatry*, cilt 164, no. 6, p. 942-948, 2007.
- [3] C., Lara, J., Fayyad and Graaf R., "Childhood predictors of adult attention deficit/hyperactivity disorder: results from the World Health Organization World Mental Health Survey Initiative," *Biol. Psychiatry*, cilt 65, no. 1, p. 46-54, 2009.
- [4] L., Klassen, M., Katzman, P. Chokka, "Adult ADHD and its comorbidities, with a focus on bipolar disorder," *Journal of Affective Disorders*, cilt 124, no. 1-2, p. 1-8, 2009.
- [5] T. Frodl, "Comorbidity of ADHD and substance use disorder (SUD): a neuroimaging perspective," *Attention Deficit Hyperactivity Disorder*, cilt 14, no. 2, p. 109-120, 2010.
- [6] Z., Mao, G., Xu, and X., Wang "Spatio-temporal deep learning method for ADHD fMRI classification," *Information Sciences*, cilt 499, pp. 1-11, 2019.
- [7] C., Parmar, P., Grossmann, J., Bussink, Lambin Aerts, "Machine Learning methods for quantitative radiomic biomarkers," *Sci. Rep.*, cilt 5, p. 13087, 2015.
- [8] H., Mohammed, D., Axel, Biard, A., C., Aoran, "Brain tumor segmentation with deep neural networks," *Med. Image Anal.*, cilt 35, p. 18-31, 2017.
- [9] L., Le, Jiamin L., Y., Jiahua "Improving computer-aided detection using convolutional neural networks and random view aggregation," *IEEE Trans. Med. Imaging*, cilt 35, p. 1170-118, 2016.
- [10] Y., Zang, Y., He., C., Zhu, Q., Cao, M., Sui, M., Liang, L., Tian, Jian T., Y., Wang., "Altered baseline brain activity in children with ADHD revealed by resting-state functional MRI," *Brain Dev.*, cilt 29, pp. 83-91, 2007.
- [11] Y., Zang, T., Jiang, Y., Lu, Y., He., L., Tian "Regional Homogeneity approach to fMRI data analysis," *Neuroimage*, cilt 22, p. 394-400, 2004.
- [12] S., Smith and P., Fox, "Correspondence of the brain's functional architecture during activation and rest," *Proc. Natl. Acad. Sci.*, cilt 106, no. 31, p. 13040-13045, 2009.
- [13] D. Dai, "Classification of ADHD children through multimodal magnetic resonance imaging," *Front. Syst. Neuroscience*, cilt 6, p. 63, 2012.
- [14] D., Dain, J., Wang, Hua, J, H., He, Wang, J., Hua, J., and H., "Discrimination of ADHD children based on Deep Bayesian Network," *International Conference on Biomedical Image & Signal Processing*, Springer, 2016.