



Derin Öğrenmeyi Kullanarak Veri Artırımının DEHB Tanı Modeline Etkisi

The Effect of Data Augmentation on ADHD Diagnostic Model using Deep Learning

Gülay ÇİÇEK¹, Atilla ÖZMEN², Aydın AKAN³

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

²Elektrik-Elektronik Mühendisliği Bölümü, Kadir Has Üniversitesi, İstanbul, Türkiye
aozmen@khas.edu.tr

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

Özetçe — Dikkat Eksikliği hiperaktivite bozukluğu (DEHB) nöro-davranışsal hiperaktivite bozukluğudur. Özellikle, çocuklukta ve gençlikte sıklıkla görülüp, tedavi edilmediği takdirde ömür boyu sürmektedir. DEHB sınıflandırma modeli nesnel ve sağlam olmalıdır. Doğru teşhis, genellikle sağlık uzmanlarının bilgi ve tecrübesine bağlıdır. Bu açıdan, DEHB teşhis modeli için geliştirilecek otomatik bir yöntem, klinisyenler için büyük önem taşımaktadır. Bu çalışmada, veri artırımının derin öğrenme ile DEHB teşhis modeline olan etkisi incelenmiştir. Bu amaçla, NPIstanbul NeuroPsikiyatri Hastanesi ve ADHD-200 veri tabanından manyetik rezonans görüntüleri alınmıştır. Alınan görüntülerin eğitim açısından yeterli olmaması nedeniyle veri artırma yöntemleri uygulanmış ve evrimsel sinir Ağ (CNN) mimari ile bu veriler sınıflandırılarak hastalığın teşhisinin sağlık uzmanlarının nesnel olmayan deneyimlerinden bağımsız olarak ortaya konulmasına çalışılmıştır.

Anahtar Kelimeler — sınıflandırma; çevrimiçi veri artırma; evrimsel sinir ağları; dikkat eksikliği hiperaktivite bozukluğu.


Abstract— Attention Deficit Hyperactivity Disorder (ADHD) is a neuro-behavioral hyperactivity disorder. It is frequently seen in childhood and youth, and lasts a lifetime unless treated. The ADHD classification model should be objective and robust. Correct diagnosis usually depends on the knowledge and experience of health professionals. In this respect, an automated method to be developed for the ADHD classification model is of great importance for clinicians. In this study, the effect of data augmentation on ADHD classification model with deep learning was investigated. For this purpose, magnetic resonance images were taken from NPIstanbul NeuroPsychiatry Hospital and ADHD-200 database. Since the images were not sufficient in terms of training, data augmentation methods were applied and by convolutional neural network (CNN) architecture, these data were classified and tried to reveal the diagnosis of the disease independently from the non-objective experiences of the health professionals.

Keywords — classification; online data augmentation; convolutional neural network; attention deficit hyperactivity disorder.

I. Giriş

Dikkat Eksikliği Hiperaktivite Bozukluğu (DEHB) ciddi sosyal ve psikiyatrik sorunlara yol açabilen ve daha çok çocuklarda olmak üzere toplumun yaklaşık % 7'lik bir dilimini etkileyen nöro-davranışsal bir hastalıktır. Bu hastalığın teşhisi çoğunlukla doktorların nesnel olmayan deneyimlerine ve klinik teşhis kriterlerine dayanmaktadır [1] [2]. Son yıllarda DEHB'nin otomatik olarak teşhisine yönelik farklı verilerden faydalanılarak makine öğrenmesi tabanlı yöntemler geliştirilmektedir. Örneğin [3] te Olaya ilişkin potansiyel verilerinden elde edilen zaman frekans özelliklerinin öznitelik olarak kullanıldığı ve bu özniteliklerin Destek Vektör Makinaları ile sınıflandırıldığı bir çalışma yapılmıştır. Burada deneysel ve klinik olarak elde edilen EEG kayıtlarından faydalanılmıştır. [4] te DEHB teşhisi konusunda kişilerin sosyal medya içeriklerinden faydalanılmıştır. [5] te DEHB hastalarının madde bağımlılığına yakalanma olasılığının kestirimi konusunda çalışılmış ve burada yinelemeli bir derin öğrenme sinir ağı türü olan uzun-kısa süreli bellek (LSTM) kullanılmıştır. Beynin Kaudat nukleus adı verilen kısmının MR görüntülerinin bölütlenmesi temeline dayanan bir method [6] da analiz edilmiştir. [7] de kişilerin davranışlarının renk ve derinlik bilgisi içeren görselleri kullanılarak DEHB'nin tanısı yapılmaya çalışılmıştır. [8] de ADHD-200 veri seti kullanılarak, öznitelik seçme algoritmaları ile uygun öznitelikler belirlenmiş ve daha sonra Destek Vektör Makinaları ile sınıflandırma yapılmıştır. [9] da ise DEHB'nin Obstrüktif uyku apnesinden ayırt edilmesine yönelik farklı makine öğrenme algoritmalarından faydalanılmıştır. Ortaya konan makine öğrenmesi tabanlı tüm bu yöntemlerde %70-%90 aralığında başarımlar elde edildiği görülmektedir.

Bu çalışmada ise dikkat eksikliği hiperaktivite bozukluğu (DEHB) na sahip kişiler, manyetik rezonans (MR) görüntülerinden, CNN tabanlı derin yapay sinir ağları (DYSA) öğrenme ile tespit edilmeye çalışılmıştır. Eğitim için görüntü sayısı yeterli olmadığından, sınıf bilgisi korunarak veri artırma yöntemleri ile veri sayısı çoğaltılmıştır. Yapay sinir ağları insan



Şekil 1. Yöntem


beyni ve sinir sisteminden esinlenilerek ortaya konan makine öğrenme yöntemlerinden biridir ve görüntü işleme, sınıflandırma, bilgisayarlı görü, regresyon, kestirim, tahmin, doğal dil işleme gibi oldukça geniş alanlara yayılmış uygulama alanları bulunmaktadır. Temel olarak giriş, gizli ve çıkış katmanlarından meydana gelmektedir. Bu yapıda her bir katman, nöron adı verilen farklı sayıda temel işleme birimlerinden oluşmaktadır. Nöronlar kendilerine bir önceki katmandan veya girişten belli bir ağırlık ile çarpılarak gelen bilgilerin toplamını almakta ve daha sonra aktivasyon fonksiyonu adı verilen bir fonksiyondan geçirilerek bir başka nörona veya çıkışa aktarılmaktadır. Aktivasyon fonksiyonu olarak çoğunlukla sigmoid, tanjant hiperbolik ve düzeltilmiş doğrusal birim (ReLU) fonksiyonları kullanılmaktadır.

Derin yapay sinir ağları (DYSA) ise çok katmanlı bir yapay sinir ağı çeşididir. Derin öğrenmeyi klasik anlamdaki YSA'lerden ayıran en önemli özelliği çok sayıda katman içermesi ve buna bağlı olarak elcil yöntemlere göre otomatik olarak öznitelik çıkarma konusunda oldukça yüksek performans göstermeleridir. problemlerin çözümü için farklı türde ve yapıda DYSA lar geliştirmiştir. Bunlardan evrimsel Sinir Ağları (Convolutional Neural Networks, CNN) özellikle görüntü işlemedeki problemlerin çözümünde kullanılırken, Yinelemeli Yapay Sinir Ağları ise (Recurrent Neural Networks, RNN) ise zaman serisi şeklindeki veriler içeren problemlerin çözümünde sıklıkla kullanılmaktadır [10][11].

I. YÖNTEM

NIstanbul NöroPsikiyatri Hastanesinden alınan 25 MRI görüntüsünün, 11 tanesi sağlıklı bireylere, 9 tanesi ise DEHB'li bireylere aittir. Çalışmaya ait, araştırma protokolü Üsküdar Üniversitesi Klinik Araştırmalar Etik Kurulu tarafından onaylanmıştır. Derin öğrenme yöntemleri ile DEHB teşhis modeli oluşturmak, sınırlı sayıda MRI görüntüleri ile mümkün değildir. Bu amaçla, herkes tarafından erişilebilen, yedi farklı merkezden alınan MRI görüntülerini içeren ADHD-200 veri tabanından 293 MRI görüntüsü alınmıştır. Alınan görüntülerin 139 tanesi DEHB'li, 154 tanesi ise sağlıklı

bireylere aittir. Her bir MRI verisi 256 farklı görüntü katmanından oluşmaktadır. MRI verisi CNN tabanlı derin öğrenme ağına verilmeden önce, tamamen siyah ve beyazdan oluşan ve herhangi anlamlı veri içermeyen katmanları dışındaki görüntülerin toplamı alınmış ve böylece bu görüntü dizisi tek katmana indirgenmiştir. Bu çalışmada, derin öğrenmenin sınıflandırma başarısının ortaya konması ve aynı zamanda veri artırımının başarıma olan etkisinde araştırılması da amaçlanmaktadır. Şekil 1. de önerilen yöntemin işleyiş aşamaları gösterilmiştir. Şekil 2. de ise DEHB'li ve sağlıklı bireylere ait örnek MRI görüntülerini yer almaktadır.



Şekil 2. Beyin MRI İmgeleri

A. Veri Artırımı

Veri artırımı (data augmentation), mevcut veri setininin sınıf bilgisi korunarak, yeni yapay veriler elde edilmesidir. Görüntüler; veri artırma teknikleri ile çoğaltılır. Bu çalışmada, döndürme, yeniden ölçeklendirme ve kaydırılma geometrik yöntemleri uygulanarak imgeler çoğaltılmış ve bu şekilde veri kümesindeki sınırlı veri problemi ortadan kaldırılarak, overfitting riski en az seviyeye düşürülmeye çalışılmıştır. Veri artırımı Çevrimiçi (Online) ve Çevirimdışı (Offline) şeklinde gerçekleştirilmektedir. Artırım çevirim içi ise, eğitim sırasında veri artırılmakta ve eğitim sonrasında artırılmış veri

bulunmamaktadır. Artırım çevirim dışı ise, eğitim başlamadan veri artırılır. Her iki yöntemin avantajları ve dezavantajları bulunmaktadır. Çevirim dışı veri artırımında daha fazla depolama alanına sahip olmak gerekir. Bunun yanı sıra, eğitim süreci daha hızlıdır. Çevirim dışı artırım yönteminde sabit sayıda artırılmış veri üretilirken, çevrimiçi eğitim daha fazla sayıda veri üretebilmektedir. Bu çalışmada, çevrimiçi veri artırım yöntemi uygulanarak, MRI görüntüleri eğitim sırasında çoğaltılmıştır.

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & a \\ 0 & 1 & b \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (1)$$

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} a & 0 & 0 \\ 0 & b & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (2)$$

$$\begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} \cos a & -\sin a & 0 \\ \sin a & \cos a & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (3)$$

Örneğin; (x,y) noktasını, x yönünde a kadar, y yönünde b kadar hareket ettirmek (1), ölçeklemek (2) ya da döndürmek (3) için, yukarıdaki eşitliklerde ifade edilen 3×3 lük matrislerle çarpılıp, yeni koordinat noktaları (u,v) bulunabilir.

B. Öznitelik Çıkartma ve Sınıflandırma

Sınıflandırma algoritmaları ile amaç, öznitelikleri bilinen verilerin sınıflarını tespit etmektir. CNN mimarisi ile görüntüden otomatik olarak öznitelikler çıkarılmış veriler sınıflandırılmıştır.

1) Evrimsel Sinir Ağları

Yapay sinir ağları, ileriye dönük bir sinir ağıdır. Bu algoritmalar birbirine bağlı katmanlardan oluşmaktadır. Her katman, farklı sayıdaki düğümleri içerir. Giriş, gizli ve çıkış katmanından oluşmaktadır. Giriş katmanındaki düğümler, gizli katmandaki her düğüm ile bağlantılıdır. CNN'ler ise özel ileri beslemeli sinir ağıdır. Bu ağlar çok katmanlı bir yapıya sahiptir. Bu katmanlar; evrimsel, ReLU, havuzlama ve tam bağlantılı katmandan ibarettir. CNN mimarisinde yer alan bu katmanların işlevleri şu şekildedir;

Giriş katmanı: Bu katmanda MRI görüntüleri ağa girdi olarak verilmektedir. MRI görüntüleri 256 dilimden oluşmaktadır. Gri ve beyaz maddenin net görüldüğü dilimlerin toplamı, sinir ağı yapısına girdi olarak verilmektedir.

Evrimsel katmanı: İki boyutlu filtreleme katmanıdır. Burada giriş görüntü matrisi farklı boyutlarda iki boyutlu filtre şablonu ile filtrelenerek çıkış görüntüsü elde edilir. Böylece, belirtilen alanlar içerisinde kalan öznitelikler tespit edilir.

ReLU katmanı: Aktivasyon fonksiyonu katmanıdır. Evrimsel katmanındaki değerlerin negatif olması durumunda sayı değeri sıfıra çekilir. Eşitlik 4 teki formül uygulanır.

$$f(x) = \{ 0 \text{ eğer } x < 0, x \text{ eğer } x \geq 0 \} \quad (4)$$

Havuzlama katmanı: Evrimsel işleminin ardından elde edilecek görüntünün küçültülmesi bu katmanda sağlanır. Görüntüde belirtilen alan içerisindeki sayı, seçilen havuzlama parametresi dikkate alınarak, bir sonraki matrise taşınır. Maksimum havuzlamada (max pooling) belirtilen alan içerisindeki en büyük sayı dikkate alınırken, ortamala havuzlamada belirtilen alan içindeki sayının ortalaması dikkate alınarak, sayı yeni matrise taşınır. Bu çalışmada, maksimum havuzlama ile görüntü küçültülmüştür.

Tam bağlantılı katman: Yapay sinir ağı katmanıdır. Her bir nöron, diğer katmanda yer alan bütün nöronlar ile tam bağlı olması nedeniyle, bu katman tam bağlantılı katman olarak adlandırılır.

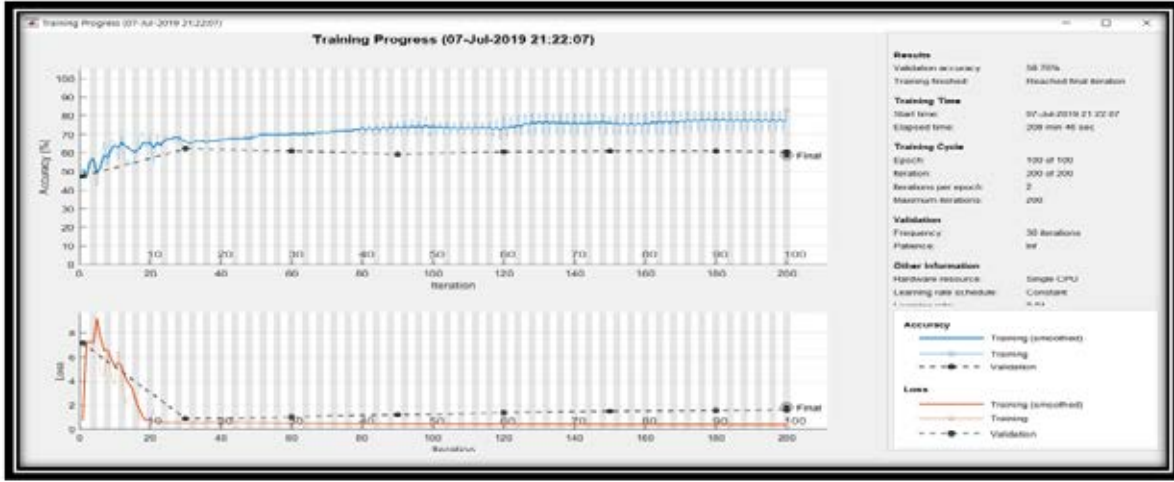
Dropout Katman: Ağın ezberlemesini önleyerek, ağın performansının artırılmasını sağlandığı katmandır.. Bu katmanda, ağın ezberlemesi önlemek için, bazı düğümlerin bağlantıları kaldırılır.

I. SONUÇLAR

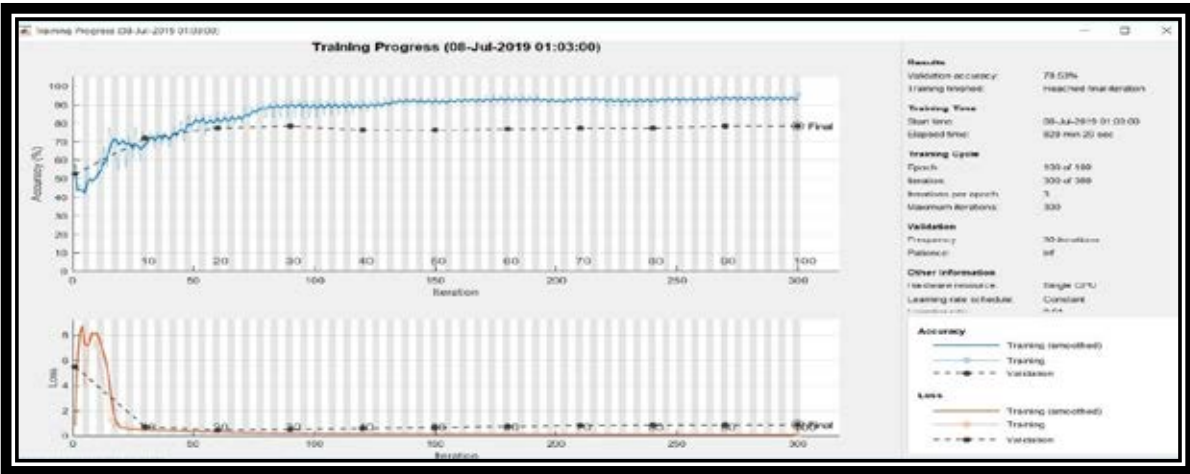
Derin öğrenme ile DEHB teşhis modelinde, MRI görüntülerini karakterize edecek yeterli sayıdaki görüntü olmaması nedeniyle, Çevrimiçi veri artırım yöntemine başvurulmuştur. Şekil 3.) de veri artırılmadan önceki CNN performansını gösterilmekte ve doğruluk oranı %58 dir. Şekil 4.) de veri artırıldıktan sonraki CNN performansını gösterilmekte ve doğruluk oranı % 78 dir. Modelin performans değerlendirilmesi için 10 Kat Çapraz geçişleme (10 Fold Cross validation) yöntemi kullanılmıştır. Şekil 4. de görüldüğü gibi veri artırma, sinir ağı gibi derin öğrenme yöntemini kullanarak, DEHB modeli için, manyetik rezonans imgelerini sınıflandırmada modelin sağlamlığını ve performansını artırmada önemli bir görev üstlenmektedir [12]. Sonuç olarak, sadece geometrik veri artırım tekniklerinden birkaç yöntem ile çalışılıp, performans üzerinde olumlu sonuçlar alınırken, diğer veri artırım teknikleri ve farklı parametrelerinde kullanılması ile veri sayısı daha da artacak, daha da sağlam bir model oluşumuna katkıda bulunacaktır.

I. TARTIŞMA

Dikkat Eksikliği Hiperaktivite Bozukluğunun tespiti için geliştirilen yöntem özgün, nesnel ve sağlam olmalıdır. Bu amaçla, yapısal manyetik rezonans görüntüleri üzerinde elde edilecek parametreler, DEHB teşhis modeli için önemli bir bileşendir. Zihinsel becerilerin gelişmesi, düşünme ve öğrenme gibi faaliyetlerin artması ve azalması durumunda yapısal manyetik rezonans görüntüleri kullanılarak önemli bulgular elde edilebilir. Bu amaçla, DEHB teşhis modelinde yapısal manyetik rezonans görüntüleri kullanılmıştır. Verileri karakterize edecek özniteliklerin otomatik tespit edilmesi için, CNN derin öğrenme mimarisi seçilmiştir. Sınırlı sayıdaki örnek



Şekil 3. Veri artırılmadan önceki CNN Performansı



Şekil 4. Veri artırıldıktan sonraki CNN Performansı

sayısı ile oluşturulacak model de oluşabilecek olumsuzlukları engellemek için veri büyütme yöntemine gidilmiştir. Çalışmada, veri artırımının derin öğrenme ile DEHB teşhis modelinde olumlu etkileri gözlenmiştir.

KAYNAKLAR

- [1] P. Öner, Ö. Öner ve A. Aysev, «Dikkat Eksikliği Hiperaktifite Bozukluğu», *Sürekli Tıp Eğitimi Dergisi*, cilt 12, no. 3, pp. 97-99, 2003.
- [2] S. K. Özmen, «Okulda Dikkat Eksikliği ve Hiperaktivite Bozukluğu (DEHB)», *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, cilt 6, no. 2, pp. 1-10, 2010.
- [3] Toprak, Hüseyin; Toyman, Mehmet; Yaşar, Kemal Alp; Arıkan, Orhan; Doğutepe, Elvin; Karakaş, Sirel; «Makina Temelli Öğrenim Sistemi: DEHB Olan ve Olmayan Katılımcıların Sınıflandırılması», %1 içinde *Sinyal İşleme ve İletişim Uygulamaları (SİU'2017)*, Antalya, 2017.
- [4] P. Chatprecha ve S. Usanavasin, «Extracting Social Network Contents to Classify ADHD Types based on Behavioral Symptoms and Activities», %1 içinde *3rd International Conference on Computational Intelligence and Applications*, Hong Kong, 2018.
- [5] S. Fouladvand, E. R. Hankosky, D. W. Henderson, J. C. Bush ve L. P. Dvoskin, «Predicting Substance Use Disorder in ADHD Patients using Long-Short Term Memory Model», %1 içinde *2018 IEEE International Conference on Healthcare Informatics Workshop*, Newyork City, 2018.
- [6] L. Igual, J. C. Soliva, A. Hernández-Vela, S. Escalera, O. Vilarroya ve P. Radeva, «Supervised brain segmentation and classification in diagnostic of Attention-Deficit/Hyperactivity Disorder», %1 içinde *International Conference on High Performance Computing & Simulation (HPCS)*, Madrid, 2012.
- [7] S. Jaiswal, M. F. Valstar, A. Gillott ve D. Daley, «Automatic Detection of ADHD and ASD from Expressive Behaviour in RGBD Data», %1 içinde *12th IEEE International Conference on Automatic Face & Gesture Recognition (FG 2017)*, Washington, DC, USA, 2017.
- [8] B. Miao ve Y. Zhang, «A Feature Selection Method for Classification of ADHD», %1 içinde *4th International Conference on Information, Cybernetics and Computational Social Systems (ICCSS)*, Dalian, China, 2017.
- [9] K.-C. Chu, H.-J. Huang ve Y.-S. Huang, «Machine Learning Approach for Distinction of ADHD and OSA», %1 içinde *IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*, San Francisco, CA, USA, 2016.
- [10] A. Shrestha ve M. Ausif, «Review of Deep Learning Algorithms», *IEEE Access*, cilt 7, pp. 53040-53065, 2019.
- [11] M. Pak ve S. Kim, «Review of Deep Learning in Image Recognition», in *4th International Conference on Computer Applications and Information Processing Technology (CAIPT)*, Kuta Bali, Indonesia, 2018.
- [12] A. Erik ve R. Berglund, «Evaluation of Data Augmentation of MRI Images for Deep Learning», *Master Thesis*, Sweden, 2018.