

Year (Yıl) : 2019
Volume (Cilt) : 6
Issue Number (Sayı) : 2
Doi : 10.5455/JNBS.1553607558

Received/Geliş 26.03.2019
Accepted/Kabul 24.04.2019
JNBS, 2019, 6(2):108-124

Çağlar Uyulan {ORCID:0000-0002-6423-6720}
Türker Tekin Ergüzel {ORCID:0000-0001-8438-6542}
Nevzat Tarhan {ORCID:0000-0002-6810-7096}

ELEKTROENSEFALOGRAFİ TABANLI SİNYALLERİN ANALİZİNDE DERİN ÖĞRENME ALGORİTMALARININ KULLANILMASI

THE USE OF DEEP LEARNING ALGORITHMS ON EEG BASED SIGNAL ANALYSIS

Çağlar Uyulan¹, Türker Tekin Ergüzel², Nevzat Tarhan³

Öz

Geleneksel makine öğrenimi algoritmaları, literatürde; biyomedikal verilerin işlenmesi ve sınıflandırılmasında yaygın olarak kullanılmaktadır. Bununla birlikte, son yıllarda, verilerin çözünürlüğünde ve miktarındaki artış nedeniyle çok katmanlı bir öğrenme ağının kullanılması zorunlu hale gelmektedir. Derin öğrenme, özellikle çok-boyutlu verilerin varlığı ve insan karar verme süreçlerinin yetersiz olması durumunda, ilgili alt-sınıfları, yüksek performansla ayıran tüm uygulama alanlarını kapsar. Bu yöntemler, verilerin bölümler arası etkileşimlerini derinlemesine inceleme yeteneğine sahiptir. Derin öğrenme, karmaşık gözlemlere dayanan, yüksek boyutlu gözlemsel verileri kullanarak öğrenmesinden dolayı, geleneksel makine öğrenimi yöntemlerinden üstündür.

Elektroensefalografi (EEG) verileri yüksek boyutlu ve karmaşık mekansal alanlar (spatial domain) üzerinden ifade edilebilir. Büyük veri setleriyle çalışma potansiyeline sahip olduklarından dolayı, derin öğrenme tabanlı ağlar kullanılarak yapılan analizler için uygundur. EEG sinyallerinin analizi için geliştirilen derin öğrenme modellerinin birçok tekrarlayıcı bilişsel görevi otomatikleştirmesi beklenmektedir.

Bu derleme makalesinde; biyomedikal ve nörobilim alanında kullanılan derin öğrenme mimarilerinin genel tanıtımı, bu mimarilerin EEG tabanlı analitik görevler üzerindeki uygulamaları, karşılaşılan olası zorluklar ve geliştirilen olası çözümler ele alınmaktadır. Ayrıntılı bir çalışmanın sonucunda, derin öğrenme yöntemlerinin klinik veya bilişsel verilerdeki karmaşık kalıpları çıkardığı ve farklı veri türleri arasındaki soyut ilişkileri saptamak için güçlü bir yöntem sunduğu görülmüştür. Bu çalışma, klinik ve nörobilimsel araştırmalarda, derin öğrenmeye dayalı uygulamaların gereksinimlerini tartışmakta ve aynı zamanda araştırmacılara, EEG sinyallerinin derin öğrenme temelli analiz metodolojisine ve araştırmalarda karşılaşılabilecek potansiyel zorluklara genel bir bakış sunmayı amaçlamaktadır.

Anahtar Kelimeler: derin öğrenme, makina öğrenmesi, elektroensefalografi, sınıflandırma

¹ Mekatronik Mühendisliği Bölümü, Bülent Ecevit Üniversitesi, Zonguldak, Türkiye.

² Yazılım Mühendisliği Bölümü, Üsküdar Üniversitesi, İstanbul, Türkiye.

³ İnsan ve Toplum Bilimleri Fakültesi Psikoloji Bölümü, Üsküdar Üniversitesi, İstanbul, Türkiye.

*Sorumlu Yazar: Türker Tekin Ergüzel, Yazılım Mühendisliği Bölümü, Üsküdar Üniversitesi, İstanbul, Türkiye. E-mail: turker.erguzel@uskudar.edu.tr

Abstract

Standard machine learning algorithms are widely used in the processing and classification of biomedical data in the literature. However, in recent years, it becomes a necessity to use a multi-layered learning network due to the increase in the resolution and quantity of the data. The concept of deep learning comprises the whole set of applications that separate sub-classes with high performance, especially in the case of the existence of multi-dimensional data and insufficient human-decision making processes. These methods can examine the inter-departmental interactions of data in depth. Deep learning is superior to conventional machine learning methods because too many observational data are learned based on increasingly complex patterns. Also, when the data size is enhanced, superiority difference over conventional machine learning methods is remarkably increased. Electroencephalography (EEG) data can be expressed in high-dimensional, and complex spatial domains. It is suitable for analysis using deep learning-based networks as they have the potential to work with large datasets. Deep learning models developed for the analysis of EEG signals are expected to automate many repetitive cognitive tasks. This review article covers the general introduction of deep learning architectures used in the field of biomedical and neuroscience, the applications of these architectures on EEG-based analytical tasks, possible difficulties encountered and possible solutions. As a result of a detailed study, it has been seen that deep learning methods extract intricate patterns in the clinical or cognitive data and present a powerful method to determine the abstract relationships between different types of data. This study addresses the needs of deep learning-based applications in clinical practice and neuroscientific research and aims to provide researchers with an overview of the deep learning-based analysis methodology of EEG signals and potential challenges in future research.

Keywords: deep learning, machine learning, electroencephalography, classification

1. Giriş

Makina öğrenmesine dayalı metotlar, veri birimleri arasındaki etkileşimi hesaba katarken aynı zamanda istatistiksel çıkarımlarda da bulunarak teşhis ve öngörüye dayalı kararları alır. Bu yöntemler, denetimli ve denetimsiz öğrenme (supervised and unsupervised) olmak üzere ikiye ayrılırlar [Tsang, 2003 ; Pattanayak, 2017]. Denetimli öğrenme; iki veya daha fazla kümeyi, önceden tanımlanmış kategorilere veya değerlere eşleyen bir fonksiyon geliştirmeye çalışırken, denetimsiz öğrenme; operatör tarafından sağlanan herhangi bir ön bilgi kullanılmadan verilerin nasıl düzenlendiğini ve organize olduğunu belirlemeye çalışır. Buradaki temel amaç, bilinmeyen yapıların keşfedilmesine yöneliktir [Wu vd., 2017; Nie vd., 2018].

Derin öğrenme ise; doğrudan veri üzerinden optimal gösterimin belirlenebilmesini sağlayan bir temsil-öğrenme (feature learning) yöntemidir. Bu yöntem, veri üzerinde ardışık ve doğrusal olmayan dönüşümlerin yapılmasını sağlayan, farklı seviyelerde karmaşıklığa sahip hiyerarşik yapıların kullanılması aracılığı ile yürütülür. Bu dönüşümler, üst düzey soyutlama seviyelerini gerektirmekle birlikte, daha yüksek seviyeli öznitelikler, giriş verilerinde mevcut olan gürültü ile karşılaştırıldığında, alt seviyedeki özniteliklerden daha az değişkendir [Yu & Chu, 2017 ; Suk vd., 2014]. Derin öğrenmede; çok-katmanlı bir öğrenme yapısı sergileyen insan beyninin çalışma mekanizmasından esinlenilmiştir. Bir Derin Sinir Ağı (DSA) (Deep Neural Network) genellikle, giriş katmanı, üç veya daha fazla gizli katman ve bir çıkış katmanından meydana gelir. Giriş katmanı; modele beslenen ve biyolojik belirteç değeri olan veriyi toplarken, gizli katmanlar ise verinin soyut özniteliklerini öğrenir ve kaydederler. Bu öznitelikler, daha sonra çıktı katmanına gönderilir ve model çıkışları olarak belirli sınıflara atanırlar. Öğrenme; veri üzerindeki dağınık, örtük ve kompleks bilginin tespit edilmesi ve ağ içerisinde gömülü yapay nöronlar arasındaki bağlantıların ağırlıklarının ayarlanması işlemine dayanan tekrarlı ve döngüsel bir süreçtir. Model eğitimi, önceden tanımlanmış durdurma kriterlerinden en az birisi sağlanıncaya kadar devam eder. Derin öğrenme temel olarak yüksek seviyede

soyutlamanın başarılmasına ve karmaşık yapıların öğrenilme kapasitesine sahip olan Çok Katmanlı Yapay Sinir Ağ'larının (Multi-layer Neural Network) eğitilmesi ve test edilmesi süreçlerini içerir [Razavian vd., 2014]. Bilginin ağ boyunca nasıl yayıldığı ile ilişkili olarak iki tür derin öğrenme modeli vardır. Bunlardan ilki, girdi katmanından çıktı katmanına doğru bilginin tek yön boyunca hareket ettiği ileri beslemeli ağlar (feedforward nets) olurken, diğeri de geçmiş girdilerin mevcut çıktıyı etkilemesine izin veren geri besleme (feedback) bağlantılarından oluşan yinelemeli sinir ağlarıdır (recurrent networks) [Graves, 2017].

Beyindeki elektriksel faaliyetlerin ölçülmesi Elektroensefalografi (EEG) sayesinde mümkün olmaktadır. EEG sinyallerinin analiz edilmesi; EEG sinyallerinin durağan olmayan (nonstationary) yapısı (sinyal karakteristiklerinin zamanla değişmesi), gürültü (noise) seviyelerinin yüksek olması ve yüksek veri boyutlarına sahip olması gibi faktörler yüzünden oldukça zordur. Bu zorlukların üstesinden gelinebilmesi için, filtreleme ve boyut indirgeme (dimension reduction) teknikleri geliştirilmiş olsa da, gözlemlenen zaman serilerinin örüntülerinden gelen sinyal dinamiğinin altında yatan sürecin klinik olarak kabul edilebilir doğrulukta ve görev-bağımsız, dayanıklı (robust) bir şekilde modellemesi, aynı zamanda algoritmaların gerekli yürütme süresi, bellek verimliliği ve gerçek zamanlı uygulamalarda kullanılabilirliği da, klasik makina öğrenmesi ve sinyal işleme yöntemleri (öznitelik çıkartma (feature extraction) , öznitelik seçimi (feature selection)) ile tatmin edici düzeyde olmamaktadır. Otokodlayıcı (OK)'lar (Autoencoders), Konvolüsyonel Sinir Ağları (KSA) (Convolutional Neural Networks), Derin Kanı Ağları (DKA) (Deep Belief Network) vb. çeşitli derin öğrenme mimarileri çoklu zihinsel durumları birbirinden ayırt etme amacıyla, EEG sinyallerinin analizinde kullanılmıştır. Genel olarak bir DSA, basit bir sinir ağına yüzeyel olarak benzer. Çok sayıda gizli katman ile ayrılmış bir giriş katmanı ve bir çıkış katmanı içerir. Ancak, bu ağların nasıl eğitildiği konusunda, yöntemsel farklılıklar mevcuttur [Roux & Bengio, 2008]. Spesifik olarak, DSA gizli katmanlar (hidden layers) arasındaki ağırlıkları ayarlamak için denetimsiz öğrenme tekniklerini

kullanır ve ağı girişlerine ilişkin en iyi özneteliklerin belirlenmesini sağlar. DSA'nın bu özelliği sayesinde, ağı girişi ve çıkışı arasındaki karmaşık ve doğrusal olmayan bağlantıların, esnek ve yüksek mertebede soyutlamayı içeren modellenme işlemi gerçekleştirilir. DSA'ların eğitilmesi gereken ve çok sayıda parametresi olan birçok gizli katmanı vardır. Ağı eğitilmesinde, genellikle geri yayılım algoritması (backpropagation algorithm) kullanılır. Birçok gizli katmanı olan DSA'nın hesaplama karmaşıklığı ve geniş alan parametreleri arttıkça, daha düşük bir eğitim hızına sahip olur ve buna ek olarak, yerel minimumda (local minimum) takılma problemleri meydana gelir. Öte yandan, makina öğrenmesi literatüründe, daha etkili öğrenme mimarilerinin gerçekleştirilmesi için, denetimsiz bir ön-eğitim prosedürünün verimli bir düzenleyici olarak kullanıldığı yarı-denetimli (semi-supervised) algoritmalar önerilmiştir [Weston vd., 2008]. Ön-eğitim (Pre-train) yöntemleri arasında; DKA, Kısıtlı Boltzmann Makinası (KBM) (Restricted Boltzmann Machine) ve Derin Boltzmann Makinası (Deep Boltzmann Machine) yer alır. Öğrenme özellikleri ve sınıflandırmada, DSA'nın etkinliği; konuşma, görme ve doğal dil işleme gibi farklı uygulamalar üzerinde kanıtlanmıştır [Park vd., 2017; Lee vd., 2017; Huang vd., 2016; Graves & Schmidhuber, 2005; Cho vd., 2014; Scalzo & Piater, 2005; Ciresan vd., 2012; Wen vd., 2017; Mellouli vd., 2017]. Bu çarpıcı sonuçlar, derin öğrenme teknikleri kullanılarak otomatik örüntülerin tanınması (pattern recognition) alanında yeni bir eğilime yol açmıştır. Dolayısıyla, veri setlerine ait öznetelikleri doğrudan veri üzerinden öğrenen, gelişmiş derin öğrenme yaklaşımları, EEG sinyallerinin analizinde daha cazip bir yöntem olarak karşımıza çıkar [Sinha & Ayush, 2018]. Bu yöntemin birincil avantajı pratik olmasıdır; çünkü bu yöntem ile öznetelikler; otomatik, akıllı ve hiyerarşik olarak derin katmanlar aracılığı ile doğrudan ham veri setinin beslenmesi ile öğrenilmektedir. Gizli katmanların sayısının yüksek olması, derin öğrenmenin yüksek soyutlamaya dayalı özneteliklerinin ve bu öznetelikler arasındaki ilişkilerin hesaba katılması anlamına gelir; öyle ki, düşük seviyeli katmanlardan çıkartılan basit, somut bilgilerden başlanarak, yüksek karmaşıklıkta ki soyut kavramlar, yüksek seviyeli katmanlarda öğrenilir [Bengio, 2009]. İkincil avantajı ise; etiketsiz (unlabeled) verilerin denetimsiz yöntemler [Golovko & Kroshchanka, 2016], kullanılarak sınıflandırılabilmesidir, bu da onu, etiketsiz bol miktarda EEG verisi için uygulanabilir bir yöntem haline getirir. EEG verilerini etiketleme işlemi (labeling process), zaman ve uzmanlık gerektirirken, denetimsiz yöntemler hem zaman hem de maliyet açısından daha verimli olmaktadır. Derin öğrenme sayesinde; geçmiş veri setlerine dayalı eğitim modelleri kurularak veri kaynaklarının doğası hakkında tahminler yapılır ve gelecek veri setleri bu modellere bağlı olarak analiz edilir. Bunun sağlık hizmetlerine olan yansımaları arasında; profesyonel insan kaynağından yoksun olan alanlarda erken, yüksek doğrulukta ve hızlı teşhis ve tıbbi harcamaların azalması yer almaktadır. Tıbbi teşhis aracı olarak kullanılan derin öğrenme yöntemleri, giderek artan düzeyde ilgi görmektedir. Örneğin; KSA, farklı tiplere sahip cilt kanserlerinin tanısında insan dermatologlardan daha iyi bir performans göstermiştir [Esteva vd., 2017], başka bir KSA ise, retinal damarları uzmanlara göre daha doğru şekilde bölümlendirmiştir [Du vd., 2018].

EEG tabanlı uygulamalarda (epilepsi nöbeti tespiti [Cilasun & Yalcin, 2016], nörodejeneratif hastalıkların teşhisi, uyku durumlarının ya da duygudurumların sınıflandırılması, beyin-makine arayüzleri vb.) derin öğrenme algoritmaları, yaygın olarak kullanılmaktadır. Çoklu-sınıf sınıflandırması problemine yönelik çalışmalar da literatürde yer bulmuştur [Fei & Liu, 2006]. Çoklu-sınıf sınıflandırması, aktif bir araştırma alanıdır [Kumar & Gopal, 2011]. Karar destek makinasını kullanan çoğu nöro-görüntüleme (neuro-imaging) çalışmasında, birden çok ikili sınıflandırma yapılmıştır [Kuang & He, 2014]. Bununla birlikte derin öğrenme algoritmaları, çoklu-sınıf sınıflandırmasını (multi-class classification) daha yüksek performans ile yapabilmektedir.

Bu makalenin amacı, EEG verileri için derin öğrenme modellerinin sistematik bir gözden geçirilmesini yapmak ve hedef uygulamaları analiz etmek için kullanılan çeşitli derin öğrenme mimarilerini ve veri modellemede karşılaşılan zorlukları tanıtmaktır. Ayrıca, bu yöntemlerin EEG sinyallerinin analizine olan katkılarını daha anlaşılır hale getirme maksadı ile, ilgili yöntemler tanıtılarak EEG sinyallerinin sınıflandırmasında nasıl uygulandıkları, genel hatlarıyla gösterilecektir. EEG sinyallerine ilişkin uygulamalar ekseninde, derin öğrenme yöntemlerinin güncel literatüre olan katkıları incelenecektir. Sağlık analitiğinde, derin öğrenmenin kullanılması başariya rağmen, ele alınması gereken birtakım sorunlar bulunmaktadır. Bu sorunlar; veri ve etiket kullanılabilirliği, modelin yorumlanabilirliği, şeffaflığı ve uygulanabilirliği vb. şeklinde karşımıza çıkmaktadır. Bu tür sorunların tanımlanması yapılarak, temel çözüm önerileri tartışılacaktır.

2. Derin Öğrenme Mimarilerinin Tanıtılması

Literatürde derin öğrenme yöntemlerine ilişkin uygulamalar sırasıyla; OK, Yığılmış OK (Stacked Autoencoders), Tam Bağlı Kaskad Ağları (Fully-connected Cascade Networks), DKA, Derin Bayeşçi Ağ (Deep Bayesian Network), KSA, Derin OK, KBM, Tekrar Derin Ağırlıklandırılmış Altsınıf-tabanlı Yaygın Çoklu-görev Öğrenme (Deep Weighted Sparse Mult-task Learning), Çekişmeli Üretici Ağlar (ÇÜA) (Generative Adversarial Networks), Tekrarlayan (Recurrent) Sinir Ağları (TSA) vb. temelinde olacak şekildedir [Yu & Chu, 2017; Suk vd., 2014]. Bu incelemede, özellikle EEG sinyallerinin analizinde kullanılan yöntemler üzerinde durulacaktır.


2.1 Tekrarlayan Sinir Ağları

TSA'lar; zaman serileri, olay dizileri ve doğal dil metni gibi sıralı verileri modellemek için ileri beslemeli sinir ağlarının bir türevidir. Özellikle, tekrarlanan yapıları sayesinde, boylamsal EEG verilerindeki karmaşık zamansal dinamikleri yakalayabilir ve böylece, sıralı klinik olay öngörüsü, hastalık sınıflandırması ve sayısal fenotipleme dahil olmak üzere birçok sağlık verisinin modellenmesi görevi için tercih edilirler. Gizli katmanın mevcut durumu; gizli katmanın önceki durumuna ve mevcut zamandaki girdiye bağlı olduğundan; TSA'nın gizli durumları, bellek olarak çalışırlar. Bu özellik, ayrıca TSA'nın değişken uzunluklarda dizi girişini işlemesini sağlar. Geçit (Gate) mekanizmalarına sahip iki belirgin TSA varyantı (Uzun Kısa Dönem Bellek (UKDB) (Long-Short Term Memory) birimi ve Kapılı Tekrarlayan Birim (KTB) (Gated Recurrent

Unit)) yaygın olarak kullanılmaktadır. Gradyan kaybolma (Gradient vanishing) probleminin üstesinden gelmek ve uzun vadeli bağımlılıkların etkilerini yakalamak için tasarlanmıştır [Tang vd., 2018].


2.2 Derin Kanı Ağı

DKA'lar, KBM olarak bilinen, sıgı yığılmış (stacked) öznetelik çıkartıcılarından oluşur. Görünür katman ve gizli katman şeklinde ayrıştırılmış iki stokastik katmana sahiptir. Girdi verisinin gizli öznetelikler cinsinden stokastik gösterimini bulmak amacı ile, maksimum olasılık kestirimini (maximum likelihood estimation) kullanırlar. Bu amaçla; KBM'ler, zıt ıraksama (contrastive divergence) olarak bilinen yaklaşıma dayalı olasılık eğimlerini kullanan eğim çöküş (gradient descent) algoritmasına göre eğitilirler. Giriş verisi, görünür katmanda tutulur ve daha sonra ileri beslemeli ağ aracılığı ile gizli katmana yönlendirilir. Ağırlıklı girişlerin toplam sonucu, nöron aktivasyon olasılığının bir ölçümünü ifade eder. Gizli nöronların aktivasyon örüntüsü, görünür katmana geri yayılarak girdi verilerinin yeniden kurulmasını sağlayan ağı içsel gösterimi olarak düşünülebilir. Ağ, gerçek ve yeniden yapılandırılmış veriler arasındaki tutarsızlık temelinde ağırlıklarının ayarlayarak öğrenir. OK'lara benzer şekilde, bir KBM'nin gizli katman gösterimi, bir sonraki KBM'ye giriş katmanı olarak eklenilerek derin ağlar oluşturmak üzere öbeklenir ve bu ağ, verilerin daha soyut temsillerinin elde edilmesini sağlamak amacı ile, düşük seviyeli özneteliklerden yüksek seviyeli özneteliklere doğru yinelemeli olarak öğrenir [Janod vd., 2016 ; Ren & Wu, 2014]. Bir Boltzmann Makinası, en basit ifade ile, ayırık katmanlar olmadığı ve her nöronun bir diğer nöron ile çift-yönlü bağlandığı bir stokastik sinir ağıdır [Hinton vd., 2006]. KBM'ler, bu yapıyı daha geleneksel bir forma dönüştürerek, tek yönlü bağlantıları olan ve aynı katmanın nöronları arasında bağlantı olmayan, özel giriş ve çıkış katmanlarını içerir. Böyle bir sistemin modeli, Şekil 1'de sunulmuştur.



Şekil 1: KBM: gizli katmanlar ve bir görünür katmanı içeren yönlendirilmemiş (undirected) grafiksel modeli

Ağın, giriş ve çıkış katmanları arasındaki ilişki, ağın daha hızlı eğitilmesine olanak tanır. KBM'nin bir başka avantajı, bir KBM'den gelen nöronların çıkış katmanının, bir başka KBM için giriş katmanı olarak hizmet etmesine izin verilerek kolaylıkla genişletilebilmesidir. Birden fazla KBM'nin kademeli şekilde birleştirilmesi, Şekil 2'de gösterilen ve bir DKA olarak adlandırılan, birden çok gizli katmana sahip bir sinirsel ağ meydana getirir.



Şekil 2: DKA: tek görünür katman ve üç tane gizli katman. EEG sınıflandırılmasında kullanılan model [Movahedi vd., 2018].

Bu, yüzeysel olarak çok katmanlı ileri beslemeli bir sinir ağına benzese bile, ağın nasıl eğitildiği konusunda farklılık gösterir [Gibson vd., 2017]. Spesifik olarak; her KBM bir defada bir katmana eklenir ve denetimli öğrenme ve geri yayılımın tüm ağa uygulanmasından önce, denetimsiz bir şekilde eğitilir. Bu yöntemde, bir DKA, hem analiz için ilgili öznetelikleri kendisi seçebilir, hem de birçok katman arasındaki ağırlıkların değiştirilmesi için sadece geri-yayılımı kullanan ağların pratik olmayan uzun birleşme sürelerine tabi değildir. Bu bağlamda; yaygın olarak kullanılan denetimsiz öğrenme yöntemi, karşıtıklı ayrışma algoritmasıdır [Gomez-Silva vd., 2017].

Bir KBM'nin; v ve h arasındaki bağlantı ile ilişkili W ağırlık matrisi ile $\langle v|h \rangle$ görünür ve gizli vektör çifti için enerji fonksiyonunun genel bir formu, Denklem 1'de gösterilmiştir.

$$E(v, h) = -a^T v - b^T h - v^T W h \quad (1)$$

Burada; a ve b , görünür ve gizli birimler için yanlılık ağırlıklarıdır. v ve h 'a ait olasılık dağılımları; $E(v, h)$ enerji fonksiyonu cinsinden Denklem 2'deki gibi ifade edilir.

$$P(v, h) = \frac{1}{Z} e^{-E(v, h)} \quad (2)$$

Burada; Z normalize eden sabittir ve Denklem 3'de verilmiştir.

$$Z = \sum_{v, h} e^{-E(v, h)} \quad (3)$$

v vektörünün olasılığı; Denklem 2'nin gizli katmanlar üzerinden toplamına eşittir [$P(v, h) = \frac{1}{Z} \sum_h e^{-E(v, h)}$]

Eğitim verisinin log-olasılığının W 'ya göre olan türevini alırsak, Denklem 4 elde edilir.

$$\sum_{n=1}^N \frac{\partial \log(P(v^n))}{\partial W_{ij}} = \langle v_i | h_j \rangle_{veri} - \langle v_i | h_j \rangle_{model} \quad (4)$$

Burada; $\langle \cdot | \cdot \rangle_{veri}$, $\langle \cdot | \cdot \rangle_{model}$ operatörü, veri ya da model dağılımının beklenen değerlerine işaret eder.

Log-olasılık tabanlı eğitim verisi üzerindeki ağa ait ağırlıklar için öğrenme kuralı, Denklem 5'teki gibidir.

$$\Delta W_{ij} = \varepsilon (\langle v_i | h_j \rangle_{veri} - \langle v_i | h_j \rangle_{model}) \quad (5)$$

Burada; ε öğrenme oranıdır.

Buna ek olarak; gizli ya da görünür birimlerin aktivasyonları, görünür veya gizli birimlere koşullu olarak bağlı olabilir. Örneğin; h 'nin v 'ye bağlı koşullu olasılığı, Denklem 6'daki gibi tanımlanır.

$$P(h|v) = \prod_j P(h_j|v) \quad (6)$$

Burada; $h_j \in \{0,1\}$ ve olasılığı $h_j = 1$ 'dir.


$P(h_j = 1|v) = \sigma(b_j + \sum_i v_i W_{ij})$, $P(v_i = 1|h) = \sigma(a_i + \sum_j W_{ij} h_j)$; $\sigma(x) = (1 + e^{-x})^{-1}$ lojistik fonksiyondur.

2.3. Konvolüsyonel Sinir Ağları

KSA, biyolojiden esinlenilmiş, görsel korteksin görüntü işlemlerini taklit etmek amacı ile tasarlanmıştır. Girdi ve çıktı katmanlarına ek olarak; konvolüsyonel katman, havuz katmanı, tam-bağlantılı (fully-connected) katman şeklinde ifade edilen üç tip katmandan meydana gelirler. Konvolüsyonel katman; birçok öznetelik haritası üzerinden organize edilir. Öznetelik haritasındaki her nöron, bir önceki katmanın yerel bölgesindeki sabit nöron kümesine bağlanmıştır. Kavrayıcı alanlar (receptive field) olarak adlandırılan bu yerel kümeler, yerel bağlantısallık sayesinde tüm sistemi kapsar. Aynı öznetelik haritasında; her bir nörona karşılık gelen kavrayıcı alan arasındaki bağlantılar, aynı ağırlıkları paylaşırlar, farklı öznetelik haritaları, farklı ağırlık gruplarını kullanır. Bu mimariye göre, bir öznetelik haritası, aynı örüntü için tüm sistemi tarayan bir "öznetelik detektörü" şeklinde düşünülebilir. Bu örüntü, çekirdek olarak tanımlanır. KSA'lar içindeki çekirdekler (kernel) eğitim işlemi boyunca öğrenirler. Birçok konvolüsyonel katman ile çalışan bir ağ üzerindeki her katman, çok sayıda artan soyut özneteliğin elde edilmesi amacı ile (örneğin; çizgi→kenar→gözler→yüz), kodlama işlemi yapar. Havuz katmanı, bir önceki konvolüsyonel katmana ait nöron sayılarını indirir. Tam-bağlantılı katmanlar ise, konvansiyonel çoklu katmanlı algılayıcıdaki gizli katmanlara benzerler. Yerel bağlantısallık (local connectivity), ağırlık paylaşımı ve havuzlama özelliklerine sahip konvolüsyonel sinir ağları, hesaplama işlemini hafifleten ve aşırı uyum olasılığını düşüren hiperparametreleri (hyperparameters) içinde barındırır [Zhang vd., 2017]. Gürültüden ve denek içi-arası farklılıklara karşı dayanıklı bilişsel model gösterimlerinin oluşturulması, biyomedikal ve nöro-görüntüleme alanında oldukça önemlidir. Zihinsel-bilişsel durumların, ölçümlenen beyin aktivitesi üzerinden tespit edilmesi amacı ile, zaman, frekans ve uzaydaki sinyal iletim modeli kurulur. Standart EEG analizi teknikleri genellikle, bilginin, spektral ve temporal alan üzerindeki gösterimini dikkate alırken, kortikal bölgelerin yerlerine ilişkin uzaysal alan üzerindeki bilgiyi göz ardı etmektedirler. Ancak, derin öğrenme uygulamalarında, EEG sinyalleri topolojik bağımlı (tensörel) çoklu-spektral görüntülerinin sekansı cinsinden ifade edilirler. Bu sayede bilginin uzaysal, spektral ve temporal nitelikleri ve yapısı korunur. Girişlerin, derin öğrenme ağları tarafından çözümlenebilmesi için, EEG zaman serisi verilerinden görüntü benzeri verilerin türetilmesi gereklidir. EEG, korteks üzerinde farklı uzaysal konumlardaki ölçümlere karşılık gelen çoklu zaman serilerini içerir.

Sinyale ilişkin belirgin özellikler, genellikle, sinyalin spektrogramı kullanılarak incelenen frekans alanı üzerinden bulunur, ancak daha önce de belirtildiği üzere,

EEG sinyali ek bir uzamsal boyuta sahiptir. Her bir deneme üzerinden, sinyale ait güç spektrumlarının tahmin edilmesi için, zaman serilerine Hızlı Fourier Dönüşümü uygulanır. Beyin fonksiyonlarına ilişkin salınımsal kortikal aktivite, θ (4 – 7 Hz.), α (8 – 13 Hz.), β (13 – 30 Hz.) olmak üzere üç temel frekans bandında gerçekleşir [Bashivan vd., 2014]. Bir öznetelik vektörü oluşturmak için tüm elektrotlar üzerinden toplanan spektral ölçümler, EEG veri analizinde gerçekleştirilen standart yaklaşımdır. Bununla birlikte, bu yaklaşım, verinin doğasındaki, zamansal ve uzaysal yapıyı açıkça göz ardı etmektedir. Bunu yerine, uzaysal yapıyı korumak ve spektral boyutu temsil etmek için, çoklu renk kanalları kullanmak ve ölçümleri 2-boyutlu bir görüntü-benzeri veriye dönüştürmek uygun olur. Daha sonra, beyin aktivitesindeki zamansal evrelerin hesaba katılmasına imkan tanıyan ardışık zaman pencerelerinden elde edilen görüntü dizisi kullanılır. Her deneme, küçük bir zaman aralığı değerine sahip zamansal pencerelere bölünür. EEG elektrotları, 3-boyutlu bir alanda kafa derisi üzerinde dağılmıştır. Uzaysal olarak dağıtılmış aktivite haritalarını, 2-boyutlu görüntülere dönüştürmek için, öncelikle 3-boyutlu bölgedeki elektrotların yerinin, 2-boyutlu projeksiyonunun yapılması gerekir. Bununla birlikte, böyle bir dönüşüm, komşu elektrotlar arasındaki göreceli mesafeyi de korumalıdır. Bu amaçla, haritalama uygulamalarından esinlenilen, polar projeksiyon olarak da bilinen, Azimutsal Eş-mesafeli Projeksiyon (Azimuthal Equidistant Projection) kullanılır. EEG nöro-başlığının şekli, bir küreye yakınlştırılabilir ve aynı yöntem, kafanın üst noktasına teğet olan bir 2-boyutlu yüzey üzerindeki elektrot konumlarının projeksiyonunu hesaplamak için kullanılabilir. Bu yöntemin dezavantajı, haritadaki noktalar arasındaki mesafelerin, sadece tek bir noktaya (orta nokta) göre korunmuş olmasıdır ve bu nedenle, tüm elektrot çiftleri arasındaki nispi mesafeler tam olarak korunmaz. Görüntü-benzeri yapıların genişliği ve yüksekliği korteks üzerindeki etkinliklerin uzaysal dağılımını temsil eder. Kafatası üzerinde yayılmış güç ölçümlerinin interpolasyonu yapılır ve boyutları elektrot sayısı kadar olan (n), $n \times n$ 'lik mesh matrisleri üretilir. Bu prosedür, her bir frekans bandı için tekrarlanır ve her bir frekans bandına karşılık gelen üç temel topografik aktivite haritası elde edilir. Üç uzamsal harita, daha sonra üç farklı rengi temsil eden kanal ile görüntü-benzeri yapı oluşturmak için birleştirilir. Bu üç kanallı görüntü, derin öğrenme yapısına sahip sinir ağına girdi olarak verilir.



Şekil 3: Yaklaşımın genel bakış: 1) Birden fazla konumdan alınan EEG zaman serileri elde edilir. 2) Üç temel frekans bandındaki spektral güç, her bir konum için çıkartılır ve topografik haritalar oluşturulur. 3) Topografik haritaların dizisi, temsil öğrenme ve sınıflandırma için tekrarlayan-konvolüsyonel bir ağı beslenen 3-kanallı görüntülerin dizisini oluşturmak üzere birleştirilir.

Şekil 3, EEG verilerinden zihinsel görev sınıflandırmasına yönelik çok aşamalı yaklaşımın genel görünümünü göstermektedir. Ham EEG sinyalleri, görüntü sekansı haline dönüştürülmüş ve bu tür dönüştürülmüş EEG verileri üzerinde tekrarlayan-KSA mimarisi uygulanmıştır [Bashivan vd., 2016 ; Majumdar & Ward, 2016].

Tüm konvolüsyonel ağların çıkışları ardışık kafesler olarak yeniden şekillendirilir ve haritalarda zamansal diziyi araştırmak için kullanılır. Aktivite haritalarının dizisinden, zamansal bilginin ayıklanması için üç temel yaklaşım uygulanabilir; 1) Zaman üzerinden maks-havuzlama (max-pooling) (boyut indirgeme) 2) Temporal konvolüsyon (çekirdek sayısı, kafes boyutu, öteleme adımı sayısı) 3) Doğrusal UKDB.

Derin TSA'lar, girdiyi $x = (x_1, \dots, x_T)$ sekans formunda alır ve gizli vektör sekansını $h = (h_1, \dots, h_T)$ ve çıkış vektörünü $y = (y_1, \dots, y_T)$, aşağıdaki denklemler üzerinden $t = 1$ 'den T 'ye kadar tekrarlayarak, Denklem 7'deki gibi hesaplar.

$$h_t = H(W_{xh}x_t + W_{hh}h_{t-1} + b_h), y_t = W_{hy}h_t + b_y \quad (7)$$

Burada; W terimi ağırlık matrislerine karşılık gelirken, b terimi yanlılık vektörlerine, $H(.)$ ise gizli katman fonksiyonlarına karşılık gelir.

Sinirsel tepkilerin dinamik doğası düşünüldüğünde, KSA'ların, beyin aktivitesinin zamansal evrimini modellemek için uygun olduğu görülür. KSA'lar, uzun süreli bağımlılıkları yakalamada daha verimli olduğu gösterilmiş bir dahili bellek ve kapılı giriş/çıkışları da kullanır. KSA'lar için gizli katman işlevi, Denklem 8'deki gibi hesaplanır.

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xf}x_t + W_{xc}x_t + W_{hc}h_{t-1} + b_c)$$


$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o)$$

$$h_t = o_t \tanh(c_t) \quad (8)$$

Burada; $\sigma(.)$, lojistik sigmoid fonksiyonudur.

KSA modelinin elemanları, giriş kapısı, unutma kapısı, çıkış kapısı ve hücre aktivasyon vektörü olarak, i, f, o, c notasyonları ile gösterilmiştir. Beyin aktivitesi, zamansal olarak dinamik bir süreç olduğundan, kafesler arasındaki varyasyonlar, zihinsel durumlar hakkında ek bilgiler içerir. Şekil 4'te, farklı çoklu-kafes mimarileri gösterilmiştir.


Son katmanın çıkışları, belirli sayıda nörona sahip tam-bağılantılı katman üzerinden yumuşak-maks (soft-max) katman aracılığı ile sınıflandırılır. %50 bırakma (dropout) işlemi, son iki tam-bağılantılı katmana uygulanır. Bu araştırmanın sonucunda; toplu normalizasyon (batch normalization), eksponansiyel doğrusal birimler vb. yöntemlerin, kırılmış eğitim stratejisi ile birleştirildiğinde, KSA'ların performansını arttırdığı gözlemlenmiştir. Bu yöntemler; öğrenilen özneteliklerin uzaysal haritalaması, farklı frekans bantlarındaki özneteliklerin nedensel katkılarına ilişkin topografyanın ortaya çıkartılması açısından fayda sağlamaktadır. Bu sayede, harekete ya da imgeleme ilişkin bilgiler, KSA'ların tasarlanıp eğitilmesi ile,



Şekil 4: Değişik çoklu-kafes mimarileri: *C*: Konvolüsyonel Ağ, *Max*: Zaman kafesleri öznetelikleri boyunca olan maks-havuz katmanı *FC*: Tam-bağılantılı katman, *SM*: Yumuşak-maks katmanı, *Conv*: Zaman kafesleri boyunca olan 1-B konvolüsyonel katman, *L*: UKDB katmanı.

doğrudan ham EEG verisi üzerinden, herhangi bir bağımsız öznetelik çıkartma algoritmasına gerek duyulmaksızın çözümlenmekte ve EEG-tabanlı beyin haritalaması için ileri görüntüleme tekniklerinin önünü açmaktadır. KSA'lar, öncelikle yerel, düşük seviyeli öznetelikleri, daha sonra da katmanlar derinleştikçe artan oranda küresel ve yüksek seviyeli öznetelikleri çıkartırlar ve böylece artan karmaşıklıkta öznetelikleri ham veri üzerinden, herhangi bir önsel öznetelik seçim işlemi olmaksızın, uçtan uca öğrenirler. Mimari yapıları, hesaplama kapasitesine göre binlerce katmana kadar çıkartılabilir. Yüksek doğrulukta ve etkinlikte, çok-kanallı EEG verisi çözümleyen KSA'ların, tasarım kriterleri (ağın genel mimarisi, boyutu, kullanılan doğrusal olmayan fonksiyonların türü vb.) ve eğitim stratejileri (tüm denemelerin eğitilmesi ya da denemelerin kırılması, optimizasyon algoritmalarının uygulanması, eğitim verisinin örneklenmesi vb.) oldukça önemlidir. Potansiyel performans iyileştirmeleri, bırakma ayarlama stratejileri, toplu normalleştirme ya da eksponansiyel doğrusal birimlere sahip aktivasyon fonksiyonları ile yapılır. Toplu normalleştirme, ağın ara çıkışlarını bir grup eğitim örneği için sıfır ortalama ve birim varyansa normalize eder. Bu işlemin amacı, eğitim sırasında, katmanların girdilerinin normal bir dağılıma daha yakın tutulması sayesinde, optimizasyonu kolaylaştırmaktır. Bırakma işlemi, her bir eğitim güncellemesindeki bazı girişleri sıfıra eşit olarak ayarlar. Bu işlem sonucunda farklı birimlerin, birlikte aşırı uyumunun önlenmesi amaçlanmıştır. Bağlı kayıp fonksiyonu da, kırılmış eğitimi daha düzenli hale getirmek için tasarlanır [Krizhevsky vd., 2017]. KSA'ların, Şekil 5'te gösterildiği gibi, çok sayıda kanala sahip EEG girişlerinin anlamlandırılması özelinde, konvolüsyonel-maks-havuzlama blokları ve onu takip eden standart konvolüsyonel-maks-havuzlama blokları ile birlikte yoğun yumuşak-maks sınıflandırma katmanları vardır. Her elektroda ait girdi kanalı, temel renklere ait [k (kırmızı) y(yeşil) m(mavi)]-görüntüleri/kafesleri şeklinde

ifade edilir. İlk konvolüsyon, zaman boyunca olurken, ikinci konvolüsyon ise uzam (elektrotlar) boyunca olur.



Şekil 5: KSA mimarisi: EEG sinyalleri girişleri kademeli olarak aşağıya doğru dönüştürülmüş ve sınıflandırıcı çıkışı şeklinde ifade edilmiştir. Siyah küboidler; giriş/öznitelik haritaları, Kahverengi küboidler; konvolüsyon/havuz çekirdekleridir. Harita ve çekirdeklerin boyutları keyfi olarak seçilir. Ekspansiyon doğrusal birimler; $[x > 0 \text{ için } f(x) = x \text{ ve } x \leq 0 \text{ için } f(x) = e^x - 1]$ Aktivasyon fonksiyonları, Düzeltilmiş doğrusal birimler; $[f(x) = \max(x, 0)]$.

Bir KSA'nın eğitilmesi, tüm parametrelerinin (ağırlık ve yanlılıklar) ortaklaşa olarak eğitilmesine karşılık gelir. Denetimli öğrenme ayarında; KSA, giriş verisinden, sınıf başına gerçek bir sayı elde edene kadar karmaşık fonksiyon dizisini hesaplar, $f(X^j; \theta): \mathbb{R}^{E.T} \rightarrow \mathbb{R}^K$. Burada θ ; fonksiyona ilişkin parametreler, E ; elektrot sayısı, T ; zaman adımlarının sayısı ve K ; sınıflandırılan çıkış etiketlerinin sayısıdır. Çıktı, yumuşak-maks fonksiyonu kullanılarak;

$$p(l_k | f(X^j; \theta)) = \frac{e^{f_k(X^j; \theta)}}{\sum_{k=1}^K e^{f_k(X^j; \theta)}}; X^j \text{ girdisine karşılık}$$

gelen l_k etiketinin koşullu olasılıklarına dönüştürülür. Yumuşak-maks fonksiyonunun çıktısı, sınıf üzerinde, alan-spesifik koşullu dağılımı verir ve her örneklemdeki kayıpların toplamını en aza indirerek, doğru etiketlere, en yüksek olasılıkların atanması şeklinde, tüm KSA, Denklem 9'daki gibi eğitilir.

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \sum_{j=1}^N \text{kayıp} \left(y^j, p(l_k | f_k(X^j; \theta)) \right) \quad (9)$$

Burada; $\text{kayıp} \left(y^j, p(l_k | f_k(X^j; \theta)) \right) = \sum_{k=1}^K -\log \left(p(l_k | f_k(X^j; \theta)) \right) \cdot \delta(y^j = l_k)$ etiketlerin negatif logaritmik olasılığıdır.

Parametreler; geriyayılım yoluyla hesaplanan analitik eğimler kullanılarak mini-yığın stokastik eğim çöküş yöntemi (mini-batch stochastic gradient descent) ile optimize edilirler [Lecun vd., 2015]. EEG'de kaydedilen beyin dalgaları, çok düşük bir sinyal-gürültü oranına sahiptir ve gürültü, elektriksel çevre, kas aktivitesi, göz hareketleri veya göz kırpmaları gibi çeşitli kaynaklardan gelebilir. Genellikle, sadece belirli beyin aktivitesinin ayrıştırılması gerektiğinden, sinyalin arka plan süreçlerinden bağımsız olarak değerlendirilmesi şarttır. Sinyal-gürültü oranını iyileştirmek amacı ile, EEG kanalları tek bir dalga-formu şeklinde birleştirilerek konvolüsyonel filtreler kullanılır. Çok boyutluluk kavramını tanımlayacak olursak; n -kanallı (elektrotlu) bir EEG cihazı, f Hz. ile t sn. boyunca örneklenmiş olursa; toplam veri boyutu, " $n * f * t$ " olur.

2.4. Otokodlayıcı

Bir deney sırasında kaydedilen EEG denemeleri, bir sınıflandırıcıyı eğitmek için sınıf etiketleri olarak kullanılan farklı koşullara aittir. Aynı duruma ait olan denemelerin, benzer şekilde kodlanması, denemeler boyunca kararlı olan beyin aktivitesini temsil eden özniteliklerin öğrenilmesini kolaylaştırır. Sınıflandırma görevlerinde kullanılacak öznitelikler, ayrıca ilgili sınıflar arasında ayırım yapabilmelidir. Bu da, diğer sınıflara ait denemelerin, nasıl kodlandığını dikkate alan bir eğitim hedefi ile sağlanabilir. Bu yöntem; Benzerlik-kısıtlı Kodlama olarak adlandırılır ve OK'ların ön-eğitim aşamasından çıkartılır [Stober, 2017]. OK'lar; iki temel bileşenden oluşan ileri beslemeli ağların özel bir durumuna karşılık gelir. İlk bileşen olan kodlayıcı, girdi verisinin gizli bir gösterimini üretirken, ikinci bileşen olan çözümleyici ise, öğrenilmiş gizli ifadeleri kullanarak orijinal veriye çok yakın olacak şekilde girdi verisinin yeniden düzenlenmesinin nasıl yapılacağını öğrenir. OK'lar, doğrusal olmayan dönüşüm sistemini kullanan denetimsiz bir boyut azaltma modelidir [Hassanzadeh vd., 2017; Tewari vd., 2017]. Bir kodlayıcı yoluyla dahili bir kod temsiline girişler eşleştirilir ve daha sonra düşük boyutlu gösterim için bir çözücü vasıtası ile giriş uzayına geri eşlenir. Kodlayıcı ve kod çözücü bileşimi yeniden yapılandırma işlevi şeklinde tanımlanır. OK'lar, rekonstrüksiyon kaybını minimize eder ve böylece, verilerin temel özelliklerini yakalamaya odaklanırken, boyutunu azaltır. OK'lar, verilerde sabit yapıları ve düzenli kalıpları yakalamak için denetimsiz bir şekilde verileri modeller. Seyrek OK ve gürültü azaltıcı OK şeklinde varyantları vardır. Seyrek OK için, rekonstrüksiyon kaybı, iç kod temsili üzerinde bir kısıtlama cezası (restriction penalty) ile düzenlenir ve böylece seyrek temsiller öğrenilmiş olur. Gürültü azaltıcı OK'da ise, rekonstrüksiyon, eksik veri veya gürültüye karşı dayanıklılığın kazandırıldığı rastgele bozucu girdilere dayanır [Jha & Kwon, 2017; Mahto vd., 2017].

2.5. Çekişmeli Üretici Ağlar

ÇÜA, oyun-teorik bir süreç aracılığı ile veri üretimi için geliştirilmiş bir yaklaşımdır. Ana fikir, sinir ağını bir üretici ve bir ayırıcı ile eğitmektir. Üretici; girdi olarak rastgele gürültü alır ve örneklerini üretirken, ayırıcı; hem gerçek örnekleri, hem de üretilen örnekleri girdi olarak alır ve ikisi arasında ayırım yapmak için çabalar. Alternatif olarak, birbirleri ile rekabet eden iki farklı ağ, daha gerçekçi örnekler üretmek ve ayırıcının daha yüksek ayırım gücüne ulaşabilmesi için üreticiyi sürerler. Son zamanlarda, ÇÜA, sürekli tıbbi zaman serisi ve ayrık kodlar üretmek için sağlık alanında kullanılmıştır [Che vd., 2017 ; Choi vd., 2017 ; Yahi vd., 2017].

3. Derin Öğrenme Modellerinin Analitik Görevler Üzerindeki Dağılımları

3.1. Nörodejeneratif Hastalıkların Teşhisi

Derin öğrenmeye bağlı sınıflandırmaya ilişkin psikiyatrik ya da nörolojik bozuklukların, nöro-görüntüleme çalışmaları, literatürde önemli bir araştırma konusudur [Morabito vd., 2017]. Bu alandaki çalışmalar, genellikle aşağıdaki şekilde organize edilmişlerdir.

1) Hastaları sağlıklı deneklerden ayırma amacı ile yapılan teşhise dayalı çalışmalar;

2) Hastalığa geçiş evresini öngörmek için psikiyatrik veya nörolojik bir bozukluk geliştirme riski yüksek olarak tanımlanan bireylerden alınan temel taramaları kullanan hastalık öngörü çalışmaları;

3) Nörolojik veya psikiyatrik hastalık tanısına sahip bireylerden alınan temel taramaları takip eden tedavi yanıtını tahmin etmek için kullanılan öngörücü çalışmalar.

Literatürde yapılan çalışmaların pek çoğunda tek tip veri toplama yöntemi ile elde edilen veri analizi ile sınıflandırma yapıldığı gözlenmiştir. Bütün beyin incelenmesi yerine, beyin bölgeleri bazında parselizasyon yapılarak hangi bölgenin sınıflandırma performansı açısından en fazla ayırtırdığının araştırıldığı çalışmalar literatürde yer bulmuştur [Schirrmester vd., 2017a ; Schirrmester vd., 2017b].

Beyin araştırmaları yatırımlarında, esas katma değer sağlanacağı alan, kuşkusuz beyin hatalıklarının tedavisi ve bu tedavilerin makro ekonomiye olan maliyetidir. Örnek vermek gerekirse; dünya ile paralel olarak Türkiye nüfusu da yaşlanmaktadır. Yaşlanma, özellikle nörodejeneratif hastalıkların görülmesi açısından ciddi bir artışı da beraberinde getirmektedir. Türkiye'nin sağlık ekonomisi göz önüne alındığında, TÜİK'in verilerine göre 2017 yılı sağlık harcamaları, 120 milyar liraya ulaşmıştır ve bu miktarın önemli bir kısmına da nöroloji ve psikiyatri hastalıkları neden olmaktadır. Özellikle, Alzheimer hastalığı, şizofreni, bipolar bozukluk, depresyon vb. hastalıklar, kronik olmaları nedeniyle uzun dönemli maliyetleri artırmaktadır. Ülkemizde, 400 bin civarı Alzheimer hastası olduğu tahmin edilmekte ve 2023 yılında, 65 yaş üstü nüfusun, toplam nüfusun yüzde 10'unun üzerine çıkacağı tahmin edilirse, Alzheimer hastalığına sahip olanların sayısının da ciddi düzeyde artacağı görülebilir. Aynı şekilde, dünyada şizofreni hastalığı için harcanan miktar, ülkeler bazında 92 ile 102 milyar dolar arasında değişmektedir [Chaiyakunapruk vd., 2016].

10 yılı aşkın klinik uygulamalardan, yaklaşık 3000 kayıt, bir nörolog tarafından normal ve patolojik olarak etiketlenmiştir. KSA'lar, kayıtları, bu veri kümesi üzerinde yayınlanmış temel sonuçlardan daha büyük bir doğruluk ile (%79'a karşı %85 çözümleme doğruluğu) sınıflandırmıştır. Eğitim sürecinde her kayıt için sadece 1 dakika ve tanı koymak için ise 6 saniye kullanıldığında bile daha iyi doğruluklar elde edilmiştir. KSA tarafından öğrenilen sonuçlar görselleştirilmiş ve $\Delta=0-4$ Hz, $\theta=4-8$ Hz. frekansları arasındaki bant gücü değişikliklerinin, metinsel tıbbi raporlar ile uyum içinde olduğu sonucuna varılmıştır. Bu çalışma, klinik anlamda değerli olmakla birlikte, nörologlar arasında bir anlaşmazlık olduğunda, EEG kayıtları işaretlenerek, doğruluklarının daha da artırılmasına yönelik iyileştirmelerin yapılması potansiyelini de taşımaktadır. Örneğin, yeniden başlatılan stokastik eğitim çöküşü gibi optimizasyon yöntemlerinin kullanılması, KSA'nın performansını artırabilirken, TSA'lar da, daha uzun zaman ölçeğinde bilgilerin bütünleştirilmesini sağlar [Schirrmester vd., 2018]. Depresif ve normal deneklerden elde edilen EEG'leri ayırt etmek için geliştirilen KSA modeli, 15 normal denek ve 15 depresif hastadan elde edilen EEG'ler kullanılarak test edilmiştir. Algoritma, sırasıyla sol ve sağ hemisferden gelen EEG sinyalleri kullanılarak, %93,5 ve %96,0 doğruluk elde etmiştir. Bu çalışmada sağ hemisferden gelen EEG sinyallerinin, depresyonda sol hemisferdekenden daha belirgin olduğu keşfedilmiştir. Bu keşif, depresyonun, sağ hemisfer ile ilişkili olduğu son araştırmalar ile tutarlıdır. Bu araştırmanın heyecan verici bir çıktısı ise, farklı depresyon aşamalarını ve şiddetlerini tanımlayan Depresyon Önem Dizini'nin gelişimine katkıda bulunmasıdır [Acharya vd., 2018b].

3.2 Topografik Haritaların Çıkarılması ve Otomatik Görsel Sınıflandırma

841 sağlıklı denekten alınan EEG'ler, filtreleme, ortak ortalama referanslama ve bağımsız bileşenler analizi ile ön işlemlerden geçirilmiştir. Derin öğrenme algoritmalarına dayalı sınıflandırma için veri hacmi önemli olduğundan, veri üretimi, sinyallerin segmentasyonu ve bağımsız bileşenler için topografik haritaların ve güç spektrumlarının oluşturulması şeklinde gerçekleştirilmiştir. Bağımsız bileşenler analizinden elde edilen topografik haritalara, EEG'nin sınıflandırılması etkinliğinin artırılması amacı ile derin öğrenme tabanlı artefakt giderme işlemi uygulanmıştır. Bu işlem sonucunda; %91.01%5.12'lik bir doğruluk oranı ile elde edilmiş ve göz kırpmaları, en etkili şekilde %98.29%4.76'lık bir tanıma oranı ile sınıflandırılmıştır. Kayıp sinir sinyalleri ve artefaktlarının hata oranları sırasıyla; %9.19%1.23 ve %7.65%2.63'tür. Son olarak, gerçek zamanlı uygulanabilirlik için, sistemin yürütme süresi hesaplanmıştır. Sonuçlar, derin ağların, kas ve oküler artefaktların etkili bir şekilde otomatik olarak çıkarılabildiğini göstermektedir [Kang vd., 2018].

Diziye bağımlı görev sınıflandırması için derin öğrenmenin kullanılması, yakın geçmişte önemli bir gelişme göstermiştir. TSA algoritmasına bağlı derin öğrenme yoluyla, takip edilen dalgacık dönüşümü kullanılarak EEG alt-bant öznitelikleri çıkarılmıştır. Metodoloji, birleşik TSA mimarisi üzerinden görev tanımlamak için, lojistik regresyon yaklaşımını kullanarak, çeşitli EEG spektral bileşenleri arasındaki korelasyonun karşılaştırılmasına

dayanmaktadır. Mevcut EEG işlem yaklaşımlarının darboğazı, manifold alanındaki analizleri bozan gürültülü çalışmalar nedeniyle sinyal gücünün doğru bir şekilde analiz edilememesidir. Bu çalışma, gürültünün etkisini geçersiz kılmakla birlikte, bireysel denemelerin alt-bant spektrumları arasında bir benzerlik veya tutarlılık ilkesi geliştirmektedir. Önerilen yöntemi değerlendirmek için, dört farklı zihinsel görevi yerine getiren veri kümesi kullanılmıştır. Sonuçlar; çoklu-sınıf senaryosunda önerilen algoritmanın, literatürdeki diğer yöntemlerle uyumlu olduğunu gösterirken, ikili sınıf senaryosunda, önerilen algoritmanın rapor edilen sonuçların çoğunu geride bıraktığı görülmektedir [Patnaik vd., 2017]. Sinirsel veriden öğrenen KSA'nın, özneliliklerin görselleştirilmesi amacı ile, farklı sınıfların ayırt edilmesinde hangi güç özelliklerinin daha etkin rol oynadığının belirlenmesine ilişkin EEG bant güçleri yöntemi üzerinde yoğunlaşmıştır. Ayrıca, KSA üzerinde belirli bir öznelilik hakkında farklı katmanlarda ne kadar bilginin tutulduğu ve bu özneliliğin ağ çıkışlarını nedensel olarak etkileyip etkilemediği tespit edilmiştir. Bu sayede, eğitilmiş KSA'nın çıkışlarında, farklı frekans bantlarındaki (α , β , γ) motor hareketlerinin (sol el, sağ el, ayak vb.) hangi frekans bantları ile bağlantısının olduğu gösteren topografik kafa derisi haritaları türetilmiştir [Koenig vd., 2001 ; Li & Cichocki, 2014 ; Jiang vd., 2017].

3.3. Beyin-Bilgisayar Arayüzü Tasarımı

Beyin Bilgisayar Arayüzleri (BBA), bilgisayarla doğrudan iletişim kurarak, nöral aktiviteyi kontrol sinyali şeklinde kullanmaktadır. Belirli bir BBA paradigması için, öznelilik çıkartıcılar, beklenen EEG kontrol sinyalinin farklı özelliklerini çıkartmada uzmanlaşmış olduğundan dolayı, uygulama bazında yöntemsel sınırlama problemi ortaya çıkmaktadır. Bu problemi gidermek amacı ile KSA'lar, EEG-tabanlı BBA'lara başarıyla uygulanmıştır [Zhang & Liu, 2018]. Farklı BBA paradigmalarından, EEG sinyallerini doğru bir şekilde sınıflandırmak için, tek bir KSA mimarisi tasarlanıp tasarlanamayacağı ve aynı anda, mümkün olduğu kadar kompakt (modeldeki hiper-parametrelerin sayısının net olarak belirlenmesi) olup olamayacağı tartışılmaktadır. Bu problemleri temelden inceleme amacı ile, EEG öznelilik çıkartma kavramlarını özümseyen bir meta-model oluşturmak için KSA-tabanlı EEGNet geliştirilmiştir. Hem konu-içi, hem de çapraz-konulu sınıflandırma için, dört farklı BBA paradigmasındaki (P300 görsel uyarılmış potansiyeller, hata-ilişkili negativite, hareket-ilişkili kortikal potansiyeller, duyuşal motor ritimleri) en güncel yaklaşımlar değerlendirilmiştir. EEGNet'in, paradigmalardan genel olarak daha iyi olduğu ve sadece sınırlı eğitim verilerinin mevcut olduğu durumlarda, referans algoritmalara kıyasla daha yüksek performans sağladığı gösterilmiştir. Ayrıca, EEGNet'in; hem hata-ilişkili negativite'ye, hem de salınım tabanlı BBA'lara genel olarak nüfuz ettiği doğrulanmıştır. Bununla birlikte, öğrenilen özneliliklerin yorumlanmasını sağlamak için, eğitilmiş bir EEGNet modelinin içeriği görselleştirilmiştir. EEGNet, çeşitli BBA görevleri üzerinde çok çeşitli yorumlanabilir öznelilikleri öğrenme potansiyeline sahiptir [Lawhern vd., 2016 ; Li vd., 2016a]. Son birkaç on yıl boyunca, motor imgelem tabanlı BBA için, EEG sinyallerinin kullanımı yaygın bir ilgi kazanmıştır [Chiarelli vd., 2018 ; Sakhavi vd., 2015 ; Tang vd., 2017 ; Yang vd., 2015].

3-B uzayda görsel olarak yönlendirilmiş erişim sırasında, harekete başlamadan önce, hedeflere ulaşmanın sınıflandırılması için yeni bir yaklaşım önerilmiştir. Bu yaklaşımda, kısa süreli 2-B EEG sinyallerinin gücü ile KSA-tabanlı derin öğrenme tekniklerinin öznelilik çıkartma ve sınıflandırma yetenekleri birleştirilmiştir. Hareketler, sol, sağ, yukarı ve aşağı olmak üzere sınıflandırılmıştır. Daha doğal hareketlere izin vermek için, ayakta dururken 3-B uzayda nesneye ulaşılmasını sağlayan, sanal gerçeklik destekli deney sistemi kurulmuştur. EEG sinyallerinin zamansal amplitütlerinden EEG görüntülerinin oluşturulmasının efektifliği, hareket başlangıcından önce 3-B alanda hedeflerin yönlerinin ayırt edilmesi problemi üzerinde tartışılmıştır. Bu çalışma; 3-B uzayda görsel olarak yönlendirilmiş erişim sırasında, kol yörüngelerinin erken kod çözülmesine dayalı BBA'ların, nöro-protez kontrolünde önemli uygulamalara sahip olduğunu göstermiştir [Carvalho vd., 2017]. Motor imgeleme dayalı EEG sinyal sınıflandırılmasının derin öğrenme tabanlı kullanımı, çeşitli çerçeveler üzerinden değerlendirilmiş ve diğer rakip metotlara göre iyi performans gösteren çerçeve ayrıntılı olarak sunulmuştur [Kumar vd., 2016 ; An vd., 2014].

Yaygın olarak kullanılan, Ortak Mekansal Desen (OMD) yöntemi, daha sonra sınıflandırma için derin sinir ağına beslenen, varyans tabanlı ortak mekansal özneliliklerin çıkartılması amacı ile kullanılır. Sistemin karmaşıklığını en düşük seviyede tutmak için, tek bir filtre bankası kullanımı hedeflenmiştir. Bununla birlikte, OMD-KSA tabanlı çoklu filtre bankalarının paralel kullanımı sayesinde sistemin performansı daha da arttırılmıştır [Kumar vd., 2016]. Sağ ve sol motor görüntülerinin sınıflandırılması için, öncelikle belirli tek bir kanala dayalı olarak DKA eğitilmiş ve daha sonra zayıf sınıflandırıcıları daha güçlü bir şekilde sentezlemek için Ada-destek algoritması kullanılmıştır. DKA'nın yapısal oluşturulma süreci sırasında, kontrastlı diverjans algoritması üzerinden çalışan birçok KBM birbiri üzerine yığılmış ve DKA'yı eğitmek için kullanılmıştır. Önerilen DKA'nın performansı, çoklu deneklerde, gizli birimlerin ve gizli katmanların farklı kombinasyonları ile test edilmiştir ve deney sonuçları; önerilen yöntemin 8 gizli katman ile daha iyi bir performans gösterdiğini kanıtlamıştır. Karar destek makinası ile kıyaslandığında, tüm durumlarda daha iyi performansın olduğu, hatta bazı durumlar için %4-%6 arasında gelişme olduğu saptanmıştır [An vd., 2014]. Öznelilik çıkartma işlemi için, geçici ve uzamsal bir konvolüsyon katmanı ve sınıflandırma için tam-bağlı bir katmandan oluşan KSA modeli uygulanmıştır. Global modeller, EEG verilerinin 3sn.'lik segmentlerinde eğitilmiştir. Denek-bağımsız bir global sınıflandırıcının eğitilmesi sonucunda; iki, üç ve dört sınıflı bir veri kümesi için, sırasıyla, 5-katlı çapraz doğrulama koşulu altında; %80.10, %69.72, %59.71'lik bir ortalama doğruluk elde edilmiştir [Dose vd., 2018a]. Bu bağlamda yeni bir yaklaşım olarak, küresel sınıflandırıcının, genel ortalama doğruluğunu sırasıyla; %86.49, %79.25 ve %68.51 olarak iyileştiren, transfer öğrenme yöntemi kullanılmıştır [Dose vd., 2018b].

Bir başka çalışmada; KBM'ye dayanan bir derin öğrenme şeması önerilmiştir. Spesifik olarak, Hızlı Fourier Dönüşümü ve Dalgacık Paket Ayrıştırması ile elde edilen EEG sinyallerinin frekans alanı temsilleri, üç adet KBM'yi eğitmek için kullanılmıştır. Bu KBM'ler, daha sonra, DKA

üzerine yığılır. Çıkış katmanı, sınıflandırma görevini gerçekleştirmek için yumuşak-maks regresyonu kullanır. Ayrıca, eşlenik eğitim yöntemi ve geri yayılım algoritması, ince ayarın gerçekleştirilmesinde kullanılmıştır [Lu vd., 2017]. Başka bir çalışmada ise, EEG motor imgelem sinyallerini sınıflandırmak için KSA ve yığılmış OK'ları birleştiren hibrit bir öğrenme modeli kullanılmıştır. EEG sinyallerinden çıkarılan zaman, frekans ve pozisyon bilgisini birleştirmek için, yeni bir giriş formu geliştirilmiştir. Bu modelde, KSA ile çıkartılan öznitelikler, yığılmış OK üzerinde sınıflandırılmıştır. Yöntemin, BBA rekabet IV veri seti 2'de kappa değeri açısından elde ettiği sınıflandırma performansı 0.547'dir [Tabar & Halıcı, 2016]. P300 imla kılavuzu, iki sınıflandırma probleminden oluşur. Birinci sınıflandırma problemi, EEG ile bir P300 varlığını tespit etmektir. İkincisi ise, yazılacak doğru karakteri belirlemek için farklı P300 yanıtlarının kombinasyonunun bulunmasıdır. Ağ topolojisi, zaman alanındaki P300 dalgalarının tespit edilmesine uyarlanmıştır [Lukas & Pavel, 2016]. KSA'ya dayalı yedi sınıflandırıcı; farklı özelliklere sahip dört adet tekli sınıflandırıcı ve üç adet çoklu sınıflandırıcıdan oluşmaktadır. Bu modeller, üçüncü BBA rekabet veri seti 2 üzerinde test edilmiş ve karşılaştırılmıştır. En iyi sonuç, yüzde %95,5'lik bir tanıma oranına sahip çoklu-sınıflandırıcı model ile elde edilir [Cecotti, 2011].

3.4. Epilepsi Nöbetlerinin Öngörülmesi

Epilepsi değerlendirmesinde elektrofizyolojik gözlem önemli rol oynamaktadır. Bununla birlikte, beyin sinyallerinin, insana bağlı yorumlamaları subjektiftir ve yanlış tanıya yatkındır. Bu süreci otomatikleştirmek, özellikle kafa derisi ve kafa içi tabanlı EEG'ye dayanan nöbet tespiti, son yıllarda yapılan araştırmaların odak noktası olmuştur [Hosseini vd., 2017 ; Antoniadis vd., 2017 ; Thodoroff vd., 2016].

Bununla birlikte, birçok zorluk kesin bir çözümü engellemiştir. Derin öğrenme alanında cereyan eden son gelişmelerden esinlenerek, UKDB ağlarını kullanan TSA'lar temelinde EEG zaman serileri için yeni bir sınıflandırma yaklaşımı önerilmiştir. Önerilen derin ağ, EEG sıralı verilerinden ayırt edici zamansal kalıpları etkili bir şekilde öğrenir ve modeller. Basit mimarileri kullanmak, düşük hesaplama karmaşıklığı sağladığı ve büyük eğitim veri kümeleri için indirgenmiş gereksinimleri dikkate aldığından dolayı, pratik senaryoda önemli ölçüde fayda sağlar. Çok katlı bir çapraz bağlanma şeması, deneyde tanımlanan tüm kümeler arasında %95.54'lük bir ortalama doğruluğu ve ROC eğrisinin 0.9582'lik bir ortalama AUC'yi göstermiştir [Ahmedt-Aristizabal vd., 2018]. Epilepsi, yaygın bir kronik nörolojik bozukluktur. Epilepsi nöbetleri, beynin geçici ve beklenmeyen elektriksel bozukluğunun bir sonucu olmaktadır. Dünya çapında yaklaşık elli milyon insan, epilepsi hastasıdır. Epilepsi saptanması, EEG sinyalleri analiz edilerek mümkün hale gelmiştir. EEG sinyallerine dayalı epilepsi nöbetlerinin belirlenmesi için, genellikle KSA'lar kullanılmıştır [Acharya vd., 2018a].

DeneySEL sonuçlar, derin öğrenme ağlarının, EEG verisine dayalı nörolojik tanı için umut verici bir yaklaşım olarak öne çıktığını göstermektedir [Cilasun & Yalcın, 2016 ; Tjepkema-Cloostermans vd., 2018 ; Antoniadis vd., 2016]. UKDB ağları, epileptik nöbet tahmininde, KSA'ya bağlı öğrenme algoritmalarının kullanımı genişletilerek uygulanmıştır. UKDB ağının en uygun mimarisini bulmak

için modül ve bellek birimi katmanları, ön analiz ile test edilmiştir. Bu sonuçlara dayanarak, iki farklı UKDB ağ üzerinde, 15 dakika ile 2 saat arasında değişen dört farklı uzunlukta ön-pencere kullanılarak nöbet tahmin performansı değerlendirilmiştir. UKDB modeli, zaman ve frekans alanı özellikleri, EEG kanallarının çapraz korelasyonu ve graf metrikleri gibi sınıflandırmadan önce çıkartılan öznitelik kümelerini kullanır. Değerlendirme; açık CHB-MIT Scalp EEG veritabanından alınan uzun süreli EEG kayıtları kullanılarak gerçekleştirilmiş ve önerilen metodolojinin 185 nöbeti tahmin edebildiği ve yüksek oranda nöbet tahmini duyarlılığı ile düşük yanlış tahmin oranlarını sağladığı görülmüştür [Tsiouris vd., 2018].

Çok kanallı EEG üzerinden, kritik kanalların belirlenmesi için kanal seçimine dayalı derin öğrenme teknikleri üzerinde de çalışılmıştır. Bunlardan birisi, kanal-farkında dikkat mekanizmasına sahip, ChannelAtt isimli derin öğrenme modelidir. ChannelAtt, ortaklaşa çoklu görüş temsilini ve katkı puanlarını öğrenir. Zaman-frekans alanında, çok kanallı EEG sinyallerinin, dikkat temsilini öğrenmek için iki farklı dikkat mekanizması önerilmiş ve bu modelin, epileptik nöbetlerin tespit edilmesinde yüksek performans gösterdiği doğrulanmıştır [Yuan vd., 2018]. EEG sinyallerinden bilgi çıkartmak için frekans alanı özellikleri (normalleştirilmiş bant içi güç spektral yoğunluğu) kullanılmıştır. Nöbet tespitinin doğruluğunu artırmak için çok katmanlı algılayıcılara dayanan derin bir öğrenme tekniği uygulanmış ve sonuçlar, modelin, nöbet geçiren ve nöbet geçirmeyen bölümleri yaklaşık %95'lik bir F-ölçüm doğruluğu ile, verimli ve otomatik olarak tespit edebildiğini göstermiştir [Birjandtalab vd., 2017]. EEG senkronizasyonunun, iki değişkenli özellikleri (çapraz korelasyon, doğrusal olmayan karşılıklı bağımlılık, dinamik sürüklenme, dalgacık senkronizasyonu vb.) hesaplanmıştır. Özellikler, tüm kanal çiftlerinden ve frekanslarından, şablonlar oluşturmak için ardışık zaman noktalarında toplanmıştır. Hastaya özel, makina öğrenmesi tabanlı sınıflandırıcılar (karar destek makinaları, lojistik regresyon veya KSA'lar), preictal özellik şekilleri arasında, interiktal ayırmak için eğitilmiştir. Örneklem-dışı nöbet tahmin performansı değerlendirilmiş ve her özellik tipi ve sınıflandırıcı kombinasyonu karşılaştırılmıştır. Değerlendirilen yöntemler arasında; dalgacık koheransı ile birleştirilmiş KSA'lar vardır. Örneklem dışı nöbetler, yanlış alarm olmaksızın, 15 hastada %71 duyarlılık ve 0 yanlış pozitif sonuç vermiştir. Sonuç olarak, EEG senkronizasyonunun uzaysal-zamansal dinamiklerini öğrenen şablon tanıma, hastaya özgü nöbet öncülerini yakalayabilir [Mirowski vd., 2009].

Nöbet tahmini için BBA geliştirmek, epileptik hastaların daha iyi bir yaşam kalitesine sahip olmalarına yardımcı olabilir. Bununla birlikte, böyle bir sistemi hastalara gerçek-zamanlı yaşam desteği olarak geliştirmede birçok zorluk vardır. EEG sinyallerinin durağan olmayan yapısı nedeniyle, durağan modeller ve nöbet modelleri farklı hastalara göre değişir. Beyin üzerinden gerçek-zamanlı kayıt alan implant-elektrot kullanıldığında, büyük miktarlarda veri üretilir. Bu büyük veri, gerçek-zamanlı işlem için güvenli depolama ve yüksek hesaplama kaynaklarına ihtiyaç duyar. Bu zorlukları ele almak için, büyük EEG verilerinin analizini yapan, bulut-tabanlı bir BBA sistemi sunulmuştur. İlk olarak, sınıflandırma doğruluğunu artırmak, iletişim bant genişliğini ve hesaplama süresini azaltmak için bir

boyut azaltma tekniği geliştirilmiştir. İkinci olarak, derin bir öğrenme yaklaşımını takip ederek, istiflenmiş özerk kodlayıcı, denetimsiz öznitelik çıkarımı ve sınıflandırması için iki adımda eğitilmiştir. Üçüncü olarak, büyük EEG verilerinin gerçek-zamanlı analizi için, bir bulut bilişim çözümü önerilmiştir. Karşılaştırmalı bir klinik veri setindeki sonuçlar, önerilen hastaya-özel BBA'nın, alternatif bir yöntem olarak üstünlüğünü ve epilepsi hastalarının gerçek-zamanlı yaşam desteğinde beklenen yararlılığı sağladığını göstermektedir [Hosseini vd., 2016]. EEG verileri epileptik nöbetlerin tespit doğruluğunu olumsuz yönde etkileyen çok sayıda gürültü türüne yatkındır. Bu zorlukları ele almak için, epileptik nöbetlerin ayırıcı EEG özelliklerini otomatik olarak öğrenen, derin öğrenme temelli yaklaşım geliştirilmiştir. Spesifik olarak, ardışık veri örnekleri arasındaki korelasyonu ortaya çıkarmak için, zaman serisi EEG verileri ilk olarak, örtüşmeyen dönemler dizisine bölünür. Daha sonra, UKDB ağı, durağan modellerin ve nöbet modellerinin üst düzey temsillerini öğrenmek için kullanılır. Son olarak, bu temsiller, eğitim ve sınıflandırma için yumuşak-maks operatörüne beslenir. İyi bilinen bir karşılaştırmalı klinik veri kümesi ile elde edilen sonuçlar, önerilen yaklaşımın mevcut durumdaki yöntemlere olan üstünlüğünü göstermektedir. Ayrıca, yaklaşımın, gürültülü ve gerçek yaşam koşullarında dayanıklı olduğu gösterilmiştir. Önerilen yöntem, gürültüye karşı hassas olan mevcut yöntemlere kıyasla, yaygın EEG artefaktlarının (kas aktiviteleri ve göz kırpması) ve beyaz gürültünün varlığında, yüksek algılama performansını korur [Ullah vd., 2018].

3.5. Uyku Seviyesi Sınıflandırılması

Uyku aşaması sınıflandırması, uyku bozukluklarının tanısında önemli bir aşamadır. Bu işlem, geleneksel olarak, EEG, Elektrookulogram (EOG), Elektrokardiyogram (ECG) ve Elektromiyogram (EMG) gibi sinyallerin görsel incelemesine dayanarak, her 30 sn.'lik bölüme bir uyku evresi atayan uzmanlar tarafından gerçekleştirilir. Uyku apnesi, parasomnia ve hipersomnia gibi uyku bozuklukları önemli bir çoğunluğu etkilemektedir. EEG sinyalleri kullanılarak, beyin izleme dahil olmak üzere, gecelik polisomnografik uyku bozuklukları için tanısız değerlendirme yapılır. Büyük fizyolojik veri kümeleriyle birleştirilen güçlü sinir ağlarına dayalı öğrenme algoritmalarındaki son yükselme, otomasyon olasılığını artırmakta ve potansiyel olarak uzman seviyesinde uyku analizini daha yaygın bir şekilde sunmaktadır [Manzano vd., 2017]. SLEEPNET (Uyku EEG nöral ağı), uyku evrelemesi için özelleşmiş bir ek açıklama aracıdır. SLEEPNET, Massachusetts Genel Hastanesi Uyku Laboratuvarı'ndan 10.000'in üzerinde hastadan toplanan polisomnografilerden oluşan bugüne kadar yapılmış en büyük uyku fizyolojisi veritabanında eğitilmiş, derin TSA mimarisi kullanılmaktadır. SLEEPNET, uzmanlar arası karşılaştırılabilir, %85.76'lık bir ortalama doğruluk ve bağımsız bir test setinde, %79.46'lık (insan seviyesinde) ek açıklama performansına ulaşmıştır [Biswal vd., 2017].

Spektrogramlar hesaplanmadan, uçtan uca öğrenen, tüm çok değişkenli ve çok modlu sinyalleri kullanan uyku aşaması sınıflandırması için derin öğrenme yaklaşımı sunulmuştur. Her modalite için, ilk katman, sinyal-gürültü oranını artırmak için sensör dizisini kullanan doğrusal uzamsal filtreleri öğrenir ve son katman da öğrenilen

gösterimi bir yumuşak-maks sınıflandırıcıya besler. Model, KSA'ya veya karar ağaçlarına dayalı alternatif otomatik yaklaşımlarla karşılaştırılmıştır. 20 adet kadar EEG kanalı ile 61 adet denekten toplanarak elde edilen sonuçlar, oldukça yüksek performans göstermişlerdir. İlgili sinyal, mekânsal-zamansal dağılım üzerine bir dizi görüş ortaya koymaktadır. Optimal sınıflandırma performansı, 2 EOG (sol ve sağ) ve 3 EMG çene kanalı ile 6 EEG kullanılmaktadır. Ayrıca, her bir veri bölümünden önce ve sonra bir dakikalık verilerin kullanılması, sınırlı sayıda kanal mevcut olduğunda en güçlü gelişmeyi sunmaktadır. Uyku sırasında EEG sinyalleri, klinisyenler tarafından çeşitli nörolojik bozuklukları değerlendirmek için kullanılır. Uyku tıbbında, uyku evreleri gibi makro-olayların (>10 sn.) ve K-kompleksleri gibi mikro olayların (<2 sn.) tespit edilmesi önemlidir [Chambon vd., 2018a]. Olay türlerini tespit etmek için otomatik algoritmalar geliştirilmiştir, ancak bunlar olaya özgüdür. EEG zaman serilerindeki yerler, süreler ve olay türlerini ortak olarak öngören, ham EEG sinyallerinden bir öznitelik temsili oluşturan KSA'ya dayalı derin bir öğrenme yöntemi geliştirilmiştir [Chambon vd., 2018b].

Uyku puanlaması, uyku çalışmalarında gerekli ve zaman alıcı bir görevdir [Vilamala vd., 2017]. Hayvan modellerinde (fareler gibi) veya insanlarda, bu sıkıcı süreci otomatikleştirmek, uzun vadeli çalışmaları kolaylaştırmayı ve veriye dayalı bir alan olarak uyku biyolojisini geliştirmeyi vaat etmektedir. Örneklem-dışı veriler için, mükemmel puanlama sonuçları ile, EEG ve EMG kayıtlarından, farelerde farklı bilinç durumlarını (Uyanık, REM-olmayan, REM) tahmin edebilen derin sinir ağı modeli sunulmuştur. Tahminler, 4 sn.'lik uzunluktaki dönemler üzerinde yapılmıştır [Schwabedal vd., 2018].

DKA'lara bağlı denetimsiz bir öznitelik öğrenme mimarisi uygulanmış ve buna bağlı olarak, uyku aşaması geçişinin doğru şekilde yakalanması içi gizli Markov modelinin son işlemi kullanılarak, sonuçlar öznitelik tabanlı yaklaşımlarla karşılaştırılmıştır. DKA gibi derin bir mimariye sahip ham verileri kullanan sonuçlar, klinik veri setlerinde doğrulanmış ve öznitelik bazlı bir yaklaşımlarla karşılaştırılabilir hale gelmiştir [Långkvist vd., 2012].

3.6. Duygudurum Tanımlama

İnsan duyguları, karar verme süreçlerinde önemli bir rol oynamaktadır. Heyecan ve can sıkıntısının yanı sıra, sevmek veya hoşlanmamak gibi çeşitli duygu kalıplarının doğru bir şekilde tanımlanabilmesi, nöropazarlama, duyuşsal eğlence, sanal rehabilitasyon ve bilinçaltı insan duygudurum durumlarını kullanan adli nörobilimdeki yeni uygulamaları kolaylaştıracaktır. Günümüzde, insan-bilgisayar etkileşimi alanındaki hızlı gelişmeler, akıllı cihazlarla farklı duygudurumlarının saptanmasına yönelik ilginin artmasına neden olmuştur [Zheng vd., 2014 ; Li vd., 2016b ; Rayatdoost & Soleymani, 2018]. EEG sinyalleri aracılığı ile, duygudurumların tespiti üzerinde makul analizler yapılabilir. Duygudurum tespitinde, standart makina öğrenmesi yöntemlerinde karşılaşılan zorlukların üstesinden gelmek için, yeni bir yarı-denetimli derin öğrenme mimarisi geliştirilmiştir. İlk olarak, hem denetlenen etiket bilgilerini, hem de kanal seçiminde ortak karar vermek için denetimsiz yapı bilgilerini içeren iki seviyeli bir prosedür benimsenmiştir. Daha sonra, sınıflandırma görevi için bir üretken KBM modeli

eklenmiş ve ayrımcı eğitimi ortaklaşa düzenlemek için üretken öğrenme ve denetimsiz öğrenmenin eğitim hedefleri kullanılmıştır. Sonra da, mevcut sistem, pahalı etiketleme problemini çözen aktif öğrenme senaryosuna genişletilmiştir [Jia vd., 2014].

Kişilik tanımlaması da, duygudurum tanımlama işleminin başka bir modudur. EEG sinyallerinin doğası gereği, EEG tabanlı kişilik tanımlanması, zihinsel görevler üzerinden yürütülür. KSA ve TSA'nın kombinasyonu olan derin öğrenme mimarileri, sırasıyla mekânsal ve zamansal bilgilerin çıkartılması için uygulanmıştır. İki çeşit TSA, KSA-UKDB ve KSA-KTB değerlendirilmiş, sonuç olarak önerilen yöntem, 40 denekten gelen duygusal veri seti DEAP üzerinde test edilmiştir. Sonuçlar, KSA-KTB ve KSA-UKDB'nin farklı duyuşsal durumlardan, güç spektral yoğunluğunu kullanan karar destek makinası tabanlı sistemi, önemli ölçüde geride bırakan, %99,90 civarında ortalama Doğru Tanıma Oran'larına ulaşabileceğini göstermektedir [Wilaiprasitporn vd., 2018]. Duygunun nöral ifadesi ile ilişkili çok sayıda parametre nedeniyle, hala EEG sinyalinin özgül uzamsal ve spektral korelasyonu ve duyuşsal durumların ifadesi hakkında pek çok bilinmeyen olgu vardır. Bu korelasyonu incelemek için, iki tip yarı-denetimli derin öğrenme yaklaşımı, yığılmış OK ve DKA, uygulanmıştır. Önerilen yarı-denetimli yaklaşımların etkinliğini değerlendirmek için, 2-B etki durumlarının sınıflandırılmasına yönelik, DEAP veri tabanı üzerinde konuya özgü bir duyuşsal sınıflandırma deneyi gerçekleştirilmiştir. DKA tabanlı model, sınıflandırma performansını önemli ölçüde geliştiren, sırasıyla uyarılma, değerlendirme ve beğenme durumlarının sınıflandırılmasında ortalama %86.67, %86.60 ve %86.69'luk F1 puanları elde etmiştir. Her bir tabakadaki ağırlık vektörleri incelenerek, en ayırt edici öznelitliklerin, mekânsal veya spektral konumları da kavranmıştır [Xu & Plataniotis, 2016]. Ham EEG verilerinin, bileşimsel mekânsal ve zamansal temsillerini etkin bir şekilde öğrenerek, insanın amaçlanan hareketlerini ve talimatlarını tam olarak tanımlamak için hem kaskat hem de paralel konvolüsyon TSA modelleri tanıtılmıştır. Geniş ölçekli bir hareket niyetiyle ilgili kapsamlı deneyler sonucunda, her iki model ile, %98.3 civarında yüksek bir doğruluk elde edilmiştir. Geliştirilen modeller, gerçek bir BBA ile daha fazla değerlendirilir ve beş temel niyet üzerinden, %93'lük bir tanıma doğruluğu elde edilir. Önerilen modeller, farklı niyet ve BBA sistemlerine bağlı olarak genelleştirilebilir [Zhang vd., 2018]. 3-D görsel uyaranlar sunulduğunda, EEG kullanımı yoluyla, insan tercihlerini ve heyecanını pasif olarak tanımlayan BBA, elde edilen beyin sinyallerini sınıflandırmak için derin sinir ağıları biçiminde makina öğrenimini kullanmaktadır. Daha önceki benzer çalışmalarda, k-En Yakın Komşu sınıflandırıcıları ve Karar Destek Makinaları içeren geleneksel makine öğrenme yaklaşımlarının kullanımı ile, %65 ile %89 arasında tahmin doğruluğu oranları elde edilirken, derin öğrenme yaklaşımı kullanılarak, %78-%96 oranlarına ulaşmıştır [Teo vd., 2018]. Giriş özellikleri, 32 denekten toplanan 32-kanallı EEG sinyallerinin güç spektral yoğunlukları şeklinde tanımlanarak, hiyerarşik öznelitlik öğrenme yaklaşımını kullanan yığılmış OK tabanlı model kullanılmıştır. Aşırı uyum problemini azaltmak için temel bileşen analizi ve EEG sinyallerinin durağan olmayan etkisini en aza indirmek için ana bileşenlerin ortak değişken kaydırma uyarlaması uygulanmıştır. Deneyisel

sonuçların, sırasıyla, %49.52 ve %46.03'lük doğruluk ile üç farklı değerlik ve uyarılma düzeyinin sınıflandırılabilirdiği gösterilmiştir. Temel bileşen tabanlı eş-değişkenli kayma uyumu, ilgili sınıflandırma doğruluğunu %5.55 ile %6.53 oranında artırır. Ayrıca, DSA, karar destek makinası ve naif Bayesçi sınıflandırıcılara kıyasla daha iyi bir performans sunar [Jirayucharoensak vd., 2014].

3.7. Sürücülerin Yorgunluk Seviyelerinin Kestirilmesi

Sürücü yorgunluğu, toplum ve ailelere büyük zarar veren trafik kazalarının ana sebebi olduğu için giderek daha fazla dikkat çekmektedir. Sürücünün dikkatini koruma yeteneği, trafiğin güvenliğini sağlamak için çok önemlidir. Sürücülerin, uykulu ve uyarıcı durumlarının tahmin edilebilmesi için derin kovaryans öğrenme modelleri sunulmuştur. Üç çeşit temel derin kovaryans öğrenme modeli (SPDNet, KSA, DSA) önerilmektedir. Test sonuçları, tüm derin kovaryans öğrenme yöntemlerinin, Riemann usülleri ve EEG sınıflandırması için daha önce önerilen bir KSA modeli dahil olmak üzere, sıg öğrenme yöntemlerinden daha iyi bir performans sergilediğini göstermektedir [Hajinoroozi vd., 2017]. Derin kovaryans öğrenme yöntemleri arasında, en iyi sınıflandırma performansı, %86.14 olarak, örnek uzaysal EEG kovaryans matrislerine uygulanan bir KSA modeli ile elde edilir. Derin kovaryans öğrenmenin, sürücülerin yorulma tahmini için çok umut verici bir yaklaşım olduğu gösterilmiştir. Bilişsel iş yükünü tespit etmek için, EEG sinyalleri üzerinde derin bir öğrenme yöntemi önerilmiştir. Bu çalışmada kullanılan veriler, yüksek güvenilirlikli bir sürüş simülatörü üzerinde yürütülen çoklu sürüş seansları boyunca toplanmaktadır. Sadece 4 EEG kanalı üzerinde yapılan ön deneysel sonuçlar, önerilen sistemin, sürücünün bilişsel iş yükünü doğru şekilde saptayabildiğini göstermektedir [Almogbel vd., 2018]. EEG-Conv ve EEG-Conv-R adı verilen iki zihinsel durum sınıflandırma modeli geliştirilmiştir. İç ve dış konu üzerinde test edilen sonuçlar, her iki modelin de geleneksel makine öğrenmesi tabanlı sınıflandırıcılardan daha iyi performans gösterdiğini doğrulamaktadır. Başlıca bulgular; Hem EEG-Conv hem de EEG-Conv-R, zihinsel durum tahmini için çok iyi sınıflandırma performansı sağlar; EEG-Conv-R, olgular arası zihinsel durum tahmini için daha uygundur; EEG-Conv-R, EEG-Conv'den daha hızlı tepki verir [Zeng vd., 2018]. EEG verilerinin benzersiz özelliklerini ele alan yeni bir kanal-bilişimsel KSA önerilmiştir. Ayrıca, konvolüsyon filtreleri değiştirmek için KBM'yi kullanan varyasyonları tartışılıp, ayrıntılı bir algoritma türetilmiştir. Model performanslarını test etmek için, 37 çalışma grubundan alınan 70 seanslık örnekleri içeren, üç sürücü yorgunluğu çalışmasından büyük bir EEG veri seti oluşturulmuştur [Hajinoroozi vd., 2016 ; Hajinoroozi vd., 2015].

4. Derin Öğrenmeye Dayalı Modellemede Karşılaşılan Zorluklar ve Olası Çözümleri

DSA'ların performansı, farklı performans ölçütleri ile değerlendirilir. Bunlar sırasıyla; hassasiyet, özgüllük, doğruluk ve F-puanı şeklindedir. Hassasiyet, doğru şekilde belirlenmiş gerçek pozitiflerin oranını gösterirken, özgüllük, doğru şekilde belirlenmiş gerçek negatifleri gösterir. Sınıflandırıcının performansı ise doğru sınıflandırmaların genel oranını gösterir. F-puanı ise hassasiyet ya da pozitif öngörülen değerler ile duyarlılığın birleşimi sonucu

oluşmuş bir ölçüttür. Dengelenmiş doğruluk ise, her sınıf üzerinde elde edilmiş ortalama doğruluğa karşılık gelir [Sahiner vd., 2008]. Derin öğrenmeye dayalı modellemede karşılaşılan özel zorluklar (zamansallık, düzensizlik, çoklu modaliteler, etiket eksikliği vb.) ve model özelliklerinden (yorumlanabilirlik vb.) kaynaklanır. Bu bölümde, bu zorluklar incelenecek ve literatürde geliştirilmiş olası çözümler verilecektir.

4.1. Zamansallık ve Düzensizlik

Boylamsal tıbbi veriler, hastaların sağlık koşullarının zaman içindeki seyrini tanımlar. Bu verilerde, tıbbi olaylar arasında kısa süreli yerel veya global bağımlılıklar vardır. Bunlar, klinik değişkenler arasındaki gizli ilişkileri (teşhisler, prosedürler, ilaçlar vb.) ve hastalıkla ilgili öngörülerin sonuçlarını etkiler. Bununla birlikte, klinik olaylar arasındaki karmaşık ilişkilerden dolayı uzun dönemli bağlamdan gerçek sinyallerin tanımlanması zordur. Ayrıca, bazı düzensiz kayıtlar, veri yoğunluğu açısından önemli ölçüde farklılık gösterirler. Bu düzensizlikler, uygun şekilde ele alınmaz ise, model performansını etkiler [Choi vd., 2016a ; Baytas vd., 2017].

Kapılı mimari: UKDB veya KTB'ler, uzun vadeli bağımlılıkları, kapılı yapılar kullanarak ele alma yetenekleri nedeniyle, bilgilendirici ve uzun vadeli bağlamların çıkartılması zorluğunu çözmek için tercih edilir. Klinik olaylar arasındaki uzun vadeli bağımlılıkları modellemek ve tahminlerde bulunmak için UKDB ve KTB'lerin uygulandığı örnekler [Jagannatha & Yu, 2016 ; Pham vd., 2016]'da verilmiştir.

Düzensizlik için stratejiler: Zaman düzensizliğine ilişkin zorlukları çözmek amacı ile çeşitli stratejiler önerilmiştir. Dinamik zaman bükülmesi fikri, iki değişken hızlı temporal sekans arasındaki benzerliği ölçen bir algoritma tarafından kullanılmıştır. Böylece, sağlık verileri dizileri, çift yönlü olarak hizalanmıştır. UKDB belleği, bir alt uzay ayrışımını öğrenmek için önerilmiş ve böylece geçen hafızanın, geçen zamana göre olan etkisi azaltılmıştır [Baytas vd., 2017].

4.2. Çoklu Modalite

Elektronik Sağlık Verileri (ESV); laboratuvar testleri, klinik notlar, sürekli izleme verileri gibi sayısal değerler dahil olmak üzere birden çok veri modalitesini kapsar. Bunlar arasında fMRI, EEG, ECG vb. farklı frekans, zaman ve uzaysal çözünürlüklere sahip veri türleri bulunmaktadır. Araştırmacılar, çoklu modaliteye sahip verilerin, öğrenme sisteminin tanı, tahmin ve genel performansının doğruluğunu arttırabileceğini doğrulamıştır. Ancak, çok-modlu öğrenme, verilerin heterojenliği nedeniyle zorlu bir süreçtir [Henao vd., 2016].

Çoklu-görev öğrenme: Çok-modlu elektronik sağlık verisi öğrenimi, nöral ağ modelinde belirli nöronların tüm görevler arasında paylaşılmasını gerektiren bir stratejiyi ve belirli nöronların belirli görevler için uzmanlaşmasını gerektirir. Görevler farklı tipte veri modalitelerine sahip olabilir, örneğin [Nojavanasghari vd., 2016]'da, iki veri modalitesine dayanan tahmin görevlerini ortak olarak modellemek için bir çoklu-görev öğrenme yaklaşımı kullanılmıştır [Ding vd., 2018].

4.3. Etiketlerin Eksikliği

Etiketler, klinik sonuçların gerçek durumları veya gerçek

hastalık fenotipleri gibi ilgilenilen altın standart hedefini ifade eder. Altın standart etiketler, genellikle ESV'lerde sürekli olarak yakalanmaz ve bu nedenle genellikle eğitim modelleri için çok sayıda kullanılamaz. ESV'leri etiketlemek için etkili yollar belirlemek, ESV'lerin derinlemesine öğrenilmesinin önündeki en büyük engellerden birisidir. Etiket edinimi, genellikle iyi eğitilmiş alan uzmanlarını içeren alan bilgisini gerekli kılar. Bundan bağımsız olarak, transfer öğrenimi, alternatif yaklaşımlar sunabilir.

Aktarıma dayalı öğrenme: Bu yöntemde ESV'ler örtük olarak etiketlenmeye çalışılır. Tanı kodlarının sekanslarını modellemek için UKDB, hastalık ilerlemesi için bir sınır problem kullanılmıştır ve öğrenilen bilginin aynı görev için yeni veri setlerine aktarılabilirliği gösterilmiştir. OK varyantı mimarileri, tanı kodlarından gelen reçeteler gibi belirli bir hedefi tahmin etmek amacı ile, genel ESV'den aktarıma dayalı öğrenmeyi gerçekleştirmek için uygulanmıştır.

4.4. Yorumlanabilirlik

Derin öğrenme modelleri, doğru tahminler üretebilmesine rağmen genellikle yorumlanabilirlikten yoksun, iç çalışma mekanizması şeffaf olmayan kara kutu modelleri olarak ele alınırlar. Bu önemli bir problemdir, çünkü klinisyenler genellikle sonucun altında yatan akıl yürütmeye dayalı açıklık olmadan, makina öğrenmesine dayalı önerileri kabul etmeme eğilimindedirler. Son zamanlarda, kara kutu derinlikli modelleri açıklamak için bazı çabalar olmuştur. ESV modellemesinde, yorumlanabilirlik ve saydamlığın arttırılması için çeşitli yaklaşımlar ileri sürülmüştür.

Dikkat mekanizması: Dikkat mekanizmasına dayalı öğrenme, tarihsel bilginin hangi bölümünün hastalık başlangıcını veya gelecekteki olayları tahmin etmede daha fazla olduğunu anlamak için geliştirilmiş bir yöntemdir. Dikkat ağırlıkları, modelin, hastalık başlangıçlarını veya gelecekteki olayları tahmin edebilme becerisini belirtir [Choi vd., 2016b].

Bilgi damıtma: Bilgi damıtma, karmaşık bir modelden öğrenilen bilgiyi, dağıtımı daha kolay olan daha basit bir modele sıkıştırır. Mimik öğrenme/bilgi damıtılması, karmaşık bir modelden (örneğin, derin bir sinir ağından) daha basit bir modele (karar ağacı) bilgi aktarmanın bir yolunu sağlamıştır. Ağaçların güçlendirilmesi yolu ile derin modellerin yorumlanabilirliğini arttırmak için kullanılmaktadır. Ana fikir, karmaşık bir modelin daha basit bir modeli eğitmek için, yumuşak-etiketli örnekler oluşturulmasıdır [Che vd., 2015].

5. Tartışma

Bu derlemede, EEG verilerinin modellenmesinde kullanılan mevcut derin öğrenme algoritmalarına genel bir bakış açısı sunduk. İncelenen makalelerden elde edilen sonuçlar, diğer makine öğrenmesine dayalı yaklaşımlara kıyasla, derin öğrenme modellerinin, ham verileri modellemede, ön işleme ve öznetelik çıkartma mühendisliği ihtiyacını en aza indirmede ve birçok analitik görevde yüksek performans gösterilmesinde oldukça etkili olduğunu göstermiştir. Derin öğrenme modellerinin, EEG'den alınan zaman serileri verisine bağlı olarak hastalıkların tanınması ya da klinik olayların ya da sonuçların öngörülmesi için ideal araçlar olduğu dikkate değerdir. Derin öğrenme teknikleri birçok analiz görevini yerine getirmede umut vaat edici sonuçlar göstermesine karşın, bazı açık zorluklar devam etmektedir. İlk

olarak, çeşitli girişimlere rağmen üretilen verilerin ve etiketlerin kalitesinin iyileştirilmesi yer almaktadır. Ardından, verilerin çeşitliliğinin eksikliği, veri üretiminin danışman altında gerçekleştirilmesine dayalı olarak üretilen verilerin tahmin görevine doğru olan yanlılığı sayılabilir. Derin modeller, çoğu zaman veri ve etiketlerin aktarımına dayalı öğrenilmesinde ortaya çıkan belirsizlikleri yakalayamamaktadırlar. Bu durum da, veri dağılımındaki değişikliklerin ele alınmasında modelleri daha dayanıklı kılar. Böylece, gerçek EEG verilerine dayalı modellerin gelecekteki tahminleri geçersiz kılabilme riski vardır. Modelin yorumlanabilirliği ve şeffaflığı ile ilgili geliştirilen mevcut yöntemler, genellikle tahminleri açıklamaya çalışır. EEG verilerinden oluşturulan derin modellerin gerçek-zamanlı uygulamalarının yapılabilmesi için, genellikle modellerin çalıştığı mekanizmaların anlaşılması gerekir. Son olarak, doğrudan klinik etki faktörü için, derin öğrenme modellerinin konuşlandırılması ve otomasyonu dikkate alınmalıdır. Standartlaştırılmış girdiler oluşturmak için çok miktarda EEG verisi işlenir. Derin EEG modellerinin EEG sistemlerine entegre edilmesi için büyük EEG veri setlerinin elde edilmesi zorluğunun giderilmesine dönük altyapıların oluşturulması şarttır.

Onam bilgisi: Onam formu gerekli değildir.

Etik kurul onayı: Etik kurul onayı sunulmuştur.

Çıkar çatışması: Çıkar çatışması bulunmamaktadır.

Finansal destek: Finansal destek bulunmamaktadır.

Referanslar

- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. (2018a). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*, 100, 270-278. doi:10.1016/j.combiomed.2017.09.017
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., Adeli, H., & Subha, D. P. (2018b). Automated EEG-based screening of depression using deep convolutional neural network. *Computer Methods and Programs in Biomedicine*, 161, 103-113. doi:10.1016/j.cmpb.2018.04.012
- Ahmedt-Aristizabal, D., Fookes, C., Nguyen, K., & Sridharan, S. (2018). Deep Classification of Epileptic Signals. 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Hawaii. doi:10.1109/embc.2018.8512249
- Almogbel, M. A., Dang, A. H., & Kameyama, W. (2018, Şubat). EEG-signals based cognitive workload detection of vehicle driver using deep learning. 2018 20th International Conference on Advanced Communication Technology (ICACT), South Korea. doi:10.23919/icact.2018.8323716
- An, X., Kuang, D., Guo, X., Zhao, Y., & He, L. (2014). A Deep Learning Method for Classification of EEG Data Based on Motor Imagery. *Intelligent Computing in Bioinformatics Lecture Notes in Computer Science*. 203-210. doi:10.1007/978-3-319-09330-7_25
- Antoniades, A., Spyrou, L., Martin-Lopez, D., Valentin, A., Alarcon, G., Sanei, S., & Took, C. C. (2017). Detection of Interictal Discharges With Convolutional Neural Networks Using Discrete Ordered Multichannel Intracranial EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(12), 2285-2294. doi:10.1109/tnsre.2017.2755770
- Antoniades, A., Spyrou, L., Took, C. C., & Sanei, S. (2016). Deep learning for epileptic intracranial EEG data. 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP). doi:10.1109/mlsp.2016.7738824
- Bashivan, P., Bidelman, G. M., & Yeasin, M. (2014). Spectrotemporal dynamics of the EEG during working memory encoding and maintenance predicts individual behavioral capacity. *European Journal of Neuroscience*, 40(12), 3774-3784. doi:10.1111/ejn.12749
- Bashivan, P., Rish, I., Yeasin, M., Codella, N. (2016). Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks. *ICLR Conference*.
- Baytas IM, Xiao C, Zhang X, Wang F, Jain AK, Zhou J. (2017). Patient subtyping via time-aware LSTM networks. In: proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Halifax, NS, Canada: ACM. 65-74.
- Bengio, Y. (2009). Learning Deep Architectures for AI. *Foundations and Trends in Machine Learning*, 2(1), 1-127. doi:10.1561/2200000006
- Birjandtalab, J., Heydarzadeh, M., & Nourani, M. (2017). Automated EEG-Based Epileptic Seizure Detection Using Deep Neural Networks. 2017 IEEE International Conference on Healthcare Informatics (ICHI). doi:10.1109/ichi.2017.55
- Biswal, S., J. Kulas, H. Sun, B. Goparaju, M. B. Westover, M. T. Bianchi, and J. Sun. (2017). "SLEEPNET: automated sleep staging system via deep learning," *CoRR*, vol. abs/1707.08262.
- Carvalho, S. R., Filho, I. C., Resende, D. O., Siravenha, A. C., Souza, C. D., Debarba, H. G., Boulic, R. (2017). A Deep Learning Approach for Classification of Reaching Targets from EEG Images. 2017 30th SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI). doi:10.1109/sibgrapi.2017.30
- Cecotti, H., & Graser, A. (2011). Convolutional Neural Networks for P300 Detection with Application to Brain-Computer Interfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(3), 433-445. doi:10.1109/tpami.2010.125
- Chaiyakunapruk, N., Chong, H. Y., Teoh, S. L., Wu, D. B., Kotirum, S., & Chiou, C. (2016). Global economic burden of schizophrenia: A systematic review. *Neuropsychiatric Disease and Treatment*, 357. doi:10.2147/ndt.s96649
- Chambon, S., Galtier, M. N., Arnal, P. J., Wainrib, G., & Gramfort, A. (2018a). A Deep Learning Architecture for Temporal Sleep Stage Classification Using Multivariate and Multimodal Time Series. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(4), 758-769. doi:10.1109/tnsre.2018.2813138
- Chambon, S., Thorey, V., Arnal, P. J., Mignot, E., & Gramfort, A. (2018b). A Deep Learning Architecture to Detect Events in EEG Signals During Sleep. 2018 IEEE 28th International Workshop on Machine Learning for Signal Processing (MLSP). doi:10.1109/mlsp.2018.8517067
- Che, Z., Cheng, Y., Zhai, S., Sun, Z., Liu, Y. (2017). Boosting deep learning risk prediction with generative adversarial networks for electronic health records. *IEEE International Conference on Data Mining (ICDM)*. New Orleans, LA, USA: IEEE; 2017: 787-92.
- Che Z, Purushotham S, Khemani R, Liu Y. (2015). Distilling Knowledge from Deep Networks with Applications to Healthcare Domain. *arXiv [Stat. ML]*. <http://arxiv.org/abs/1512.03542>
- Chiarelli, A. M., Croce, P., Merla, A., & Zappasodi, F. (2018). Deep learning for hybrid EEG-fNIRS brain-computer interface: Application to motor imagery classification. *Journal of Neural Engineering*, 15(3), 036028. doi:10.1088/1741-2552/aaaf82
- Cho, K., Merriënboer, B. V., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. doi:10.3115/v1/d14-1179
- Choi, E., Bahadori, M. T., Schuetz, A., Stewart, W. F., Sun, J. (2016a). Doctor AI: predicting clinical events via recurrent neural networks. In: *Machine Learning for Healthcare Conference*. 301-18.
- Choi, E., Bahadori, M. T., Sun, J., Kulas, J., Schuetz, A., Stewart, W. (2016b). RETAIN: an interpretable predictive model for healthcare using reverse time attention mechanism. In: Lee DD, Sugiyama M, Luxburg UV, Guyon I, Garnett R, eds. *Advances in Neural Information Processing Systems 29*. Curran Associates, Inc.; 2016, 3504-12.
- Choi, E., Biswal, S., Malin, B., Duke, J., Stewart, W. F., Sun, J. (2017). Generating Multilabel Discrete Electronic Health Records Using Generative Adversarial Networks. *arXiv preprint arXiv: 1703.06490*. <https://arxiv.org/abs/1703.06490>
- Cilasun, M. H., & Yalcin, H. (2016). A deep learning approach to EEG based epilepsy seizure determination. 2016 24th Signal Processing and Communication Application Conference (SIU). doi:10.1109/siu.2016.7496054
- Ciresan, D., Meier, U., & Schmidhuber, J. (2012). Multi-column deep neural networks for image classification. 2012 IEEE Conference on Computer Vision and Pattern Recognition. doi:10.1109/cvpr.2012.6248110
- Ding, D. Y., Simpson, C., Pfohl, S., Kale, D. C., Jung, K., & Shah, N. H. (2018). The Effectiveness of Multitask Learning for Phenotyping with Electronic Health Records Data. *Biocomputing 2019*. doi:10.1142/9789813279827_0003
- Dose, H., Möller, J. S., Iversen, H. K., & Puthusserypady, S. (2018b). An end-to-end deep learning approach to MI-EEG signal classification for BCIs. *Expert Systems with Applications*, 114, 532-542. doi:10.1016/j.eswa.2018.08.031
- Dose, H., Möller, J. S., Puthusserypady, S., & Iversen, H. K. (2018a). A Deep Learning MI-EEG Classification Model for BCIs. In *Proceedings of 2018 26th European Signal Processing Conference (pp. 1690-93)*. IEEE.

- Du, X., Li, W., Hu, B. (2018). Application of artificial intelligence in ophthalmology. *International Journal of Ophthalmology*, 11(9), 1555-1561. doi:10.18240/ijo.2018.09.21
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. doi:10.1038/nature21056
- Fei, B., & Liu, J. (2006). Binary tree of SVM: a new fast multiclass training and classification algorithm. *IEEE Transactions on Neural Networks*, 17(3), 696-704. doi:10.1109/tnn.2006.872343
- Gibson, M., Cook, G., & Zhan, P. (2017). Semi-supervised training strategies for deep neural networks. 2017 IEEE Automatic Speech Recognition and Understanding Workshop (ASRU). doi:10.1109/asru.2017.8268919
- Golovko, V., & Kroshchanka, A. (2016). Theoretical Notes on Unsupervised Learning in Deep Neural Networks. Proceedings of the 8th International Joint Conference on Computational Intelligence, Portugal. doi:10.5220/0006084300910096
- Gómez-Silva, M. J., Armingol, J. M., & Escalera, A. D. (2017). Deep Part Features Learning by a Normalised Double-Margin-Based Contrastive Loss Function for Person Re-Identification. Proceedings of the 12th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, Portugal. doi:10.5220/0006167002770285
- Graves, A. (2017). Plenary talks: Frontiers in recurrent neural network research. 2017 International Joint Conference on Neural Networks (IJCNN). doi:10.1109/ijcnn.2017.7965820
- Graves, A., & Schmidhuber, J. (2005). Framework phoneme classification with bidirectional LSTM and other neural network architectures. *Neural Networks*, 18(5-6), 602-610. doi:10.1016/j.neunet.2005.06.042
- Hajinorozi, M., Mao, Z., & Huang, Y. (2015). Prediction of drivers drowsy and alert states from EEG signals with deep learning. 2015 IEEE 6th International Workshop on Computational Advances in Multi-Sensor Adaptive Processing (CAMSAP). doi:10.1109/camsap.2015.7383844
- Hajinorozi, M., Mao, Z., Jung, T., Lin, C., & Huang, Y. (2016). EEG-based prediction of drivers cognitive performance by deep convolutional neural network. *Signal Processing: Image Communication*, 47, 549-555. doi:10.1016/j.image.2016.05.018
- Hajinorozi, M., Zhang, J. M., & Huang, Y. (2017). Drivers fatigue prediction by deep covariance learning from EEG. 2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC). doi:10.1109/smc.2017.8122609
- Hassanzadeh, A., Kaarna, A., & Kauranne, T. (2017). Unsupervised Multi-manifold Classification of Hyperspectral Remote Sensing Images with Contractive Autoencoder. *Image Analysis Lecture Notes in Computer Science*, 169-180. doi:10.1007/978-3-319-59129-2_15
- Henao R, Lu J. T., Lucas J. E., Ferranti J, Carin L. (2016). Electronic health record analysis via deep poisson factor models. *Journal of Machine Learning Research*, 17, 1-32.
- Hinton, G. E., Osindero, S., & Teh, Y. (2006). A Fast Learning Algorithm for Deep Belief Nets. *Neural Computation*, 18(7), 1527-1554. doi:10.1162/neco.2006.18.7.1527
- Hosseini, M., Pompili, D., Elisevich, K., & Soltanian-Zadeh, H. (2017). Optimized Deep Learning for EEG Big Data and Seizure Prediction BCI via Internet of Things. *IEEE Transactions on Big Data*, 3(4), 392-404. doi:10.1109/tbdata.2017.2769670
- Hosseini, M., Soltanian-Zadeh, H., Elisevich, K., & Pompili, D. (2016). Cloud-based deep learning of big EEG data for epileptic seizure prediction. 2016 IEEE Global Conference on Signal and Information Processing (GlobalSIP), U.S. doi:10.1109/globalsip.2016.7906022
- Huang, J., Ji, D., Yao, S., & Huang, W. (2016). Character-Aware Convolutional Neural Networks for Paraphrase Identification. *Neural Information Processing Lecture Notes in Computer Science*, 177-184. doi:10.1007/978-3-319-46672-9_21
- Jagannatha, A. N., Yu, H. (2016). Structured prediction models for RNN based sequence labeling in clinical text. *Proc Conf Empir Methods Nat Lang Process 2016*; 2016: 856-65.
- Janod, K., Morchid, M., Dufour, R., Linarès, G., & Mori, R. D. (2016). Deep Stacked Autoencoders for Spoken Language Understanding. *Interspeech 2016*. doi:10.21437/interspeech.2016-63
- Jha, D., & Kwon, G. (2017). Alzheimers Disease Detection Using Sparse Autoencoder, Scale Conjugate Gradient and Softmax Output Layer with Fine Tuning. *International Journal of Machine Learning and Computing*, 7(1), 13-17. doi:10.18178/ijmlc.2017.7.1.612
- Jia, X., Li, K., Li, X., & Zhang, A. (2014). A Novel Semi-Supervised Deep Learning Framework for Affective State Recognition on EEG Signals. 2014 IEEE International Conference on Bioinformatics and Bioengineering. doi:10.1109/bibe.2014.26
- Jiang, H., Liu, W., & Lu, Y. (2017). Analyze EEG Signals with Convolutional Neural Network Based on Power Spectrum Feature Selection. Proceedings of The 7th International Conference on Computer Engineering and Networks — PoS(CENet2017), China. doi:10.22323/1.299.0002
- Jirayucharoensak, S., Pan-Ngum, S., & Israsena, P. (2014). EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation. *The Scientific World Journal*, 1-10. doi:10.1155/2014/627892
- Kang, G., Jin, S., Kim, D. K., & Kang, S. W. (2018). T59. EEG artifacts removal using machine learning algorithms and independent component analysis. *Clinical Neurophysiology*, 129. doi:10.1016/j.clinph.2018.04.060
- Koenig, T., Marti-Lopez, F., & Valdes-Sosa, P. (2001). Topographic Time-Frequency Decomposition of the EEG. *NeuroImage*, 14(2), 383-390. doi:10.1006/nimg.2001.0825
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90. doi:10.1145/3065386
- Kuang, D., & He, L. (2014). Classification on ADHD with Deep Learning. 2014 International Conference on Cloud Computing and Big Data, U.S.A. doi:10.1109/ccbd.2014.42
- Kumar, M. A., & Gopal, M. (2011). Reduced one-against-all method for multiclass SVM classification. *Expert Systems with Applications*. doi:10.1016/j.eswa.2011.04.237
- Kumar, S., Sharma, A., Mamun, K., & Tsunoda, T. (2016). A Deep Learning Approach for Motor Imagery EEG Signal Classification. 2016 3rd Asia-Pacific World Congress on Computer Science and Engineering (APWC on CSE). doi:10.1109/apwc-on-cse.2016.017
- Långkvist, M., Karlsson, L., & Loutfi, A. (2012). Sleep Stage Classification Using Unsupervised Feature Learning. *Advances in Artificial Neural Systems*, 1-9. doi:10.1155/2012/107046
- Lawhern, V.J., Solon, A.J., Waytowich, N.R., Gordon, S.M., Hung, C.P., Lance, B.J. (2016). EEGNet: A compact convolutional network for EEG-based brain-computer interfaces. *arXiv:1611.08024 [cs, q-bio, stat]* arXiv:1611.08024
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. doi:10.1038/nature14539
- Lee, Y., Yen, T., Huang, H., & Chen, H. (2017). Structural-fitting Word Vectors to Linguistic Ontology for Semantic Relatedness Measurement. Proceedings of the 2017 ACM on Conference on Information and Knowledge Management - CIKM 17. doi:10.1145/3132847.3133152
- Li, J., & Cichocki, A. (2014). Deep Learning of Multifractal Attributes from Motor Imagery Induced EEG. *Neural Information Processing Lecture Notes in Computer Science*, 503-510. doi:10.1007/978-3-319-12637-1_63
- Li, M., Zhang, M., & Sun, Y. (2016a). A novel motor imagery EEG recognition method based on deep learning. Proceedings of the 2016 International Forum on Management, Education and Information Technology Application. doi:10.2991/ifmeita-16.2016.133
- Li, X., Song, D., Zhang, P., Yu, G., Hou, Y., & Hu, B. (2016b). Emotion recognition from multi-channel EEG data through Convolutional Recurrent Neural Network. 2016 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). doi:10.1109/bibm.2016.7822545
- Lu, N., Li, T., Ren, X., & Miao, H. (2017). A Deep Learning Scheme for Motor Imagery Classification based on Restricted Boltzmann Machines. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(6), 566-576. doi:10.1109/tnsre.2016.2601240
- Lukas, V., & Pavel, M. (2016). Using stacked autoencoders for the P300 component detection. *Frontiers in Neuroinformatics*, 10. doi:10.3389/conf.fninf.2016.20.00067
- Mahto, S., Yamamoto, H., & Koshinaka, T. (2017). I-Vector Transformation Using a Novel Discriminative Denoising Autoencoder for Noise-Robust Speaker Recognition. *Interspeech 2017*, 3722-3726. doi:10.21437/interspeech.2017-731
- Majumdar, A., & Ward, R. (2016). Real-time reconstruction of EEG signals from compressive measurements via deep learning. 2016 International Joint Conference on Neural Networks (IJCNN), Budapest. doi:10.1109/ijcnn.2016.7727560
- Manzano, M., Guillén, A., Rojas, I., & Herrera, L. J. (2017). Deep Learning Using EEG Data in Time and Frequency Domains for Sleep Stage Classification. *Advances in Computational Intelligence Lecture Notes in Computer Science*, 132-141. doi:10.1007/978-3-319-59153-7_12
- Mellouli, D., Hamdani, T. M., Ayed, M. B., & Alimi, A. M. (2017). Morph-CNN: A Morphological Convolutional Neural Network for Image Classification. *Neural Information Processing Lecture Notes in Computer Science*, 110-117. doi:10.1007/978-3-319-70096-0_12

- Mirowski, P., Madhavan, D., Lecun, Y., & Kuzniecky, R. (2009). Classification of patterns of EEG synchronization for seizure prediction. *Clinical Neurophysiology*, 120(11), 1927-1940. doi:10.1016/j.clinph.2009.09.002
- Morabito, F. C., Campolo, M., Mammone, N., Versaci, M., Franceschetti, S., Tagliavini, F., . . . Aguglia, U. (2017). Deep Learning Representation from Electroencephalography of Early-Stage Creutzfeldt-Jakob Disease and Features for Differentiation from Rapidly Progressive Dementia. *International Journal of Neural Systems*, 27(02), 1650039. doi:10.1142/s0129065716500398
- Movahedi, F., Coyle, J. L., & Sejdic, E. (2018). Deep Belief Networks for Electroencephalography: A Review of Recent Contributions and Future Outlooks. *IEEE Journal of Biomedical and Health Informatics*, 22(3), 642-652. doi:10.1109/jbhi.2017.2727218
- Nie, S., Zheng, M., & Ji, Q. (2018). The Deep Regression Bayesian Network and Its Applications: Probabilistic Deep Learning for Computer Vision. *IEEE Signal Processing Magazine*, 35(1), 101-111. doi:10.1109/msp.2017.2763440
- Nojavanasghari, B., Gopinath, D., Koushik, J., Baltrušaitis, T., & Morency, L. (2016). Deep multimodal fusion for persuasiveness prediction. *Proceedings of the 18th ACM International Conference on Multimodal Interaction - ICMI 2016*. doi:10.1145/2993148.2993176
- Park, J., Cho, H., & Hwang, S. (2017). Understanding Relations using Concepts and Semantics. *Proceedings of the 3rd International Workshop on Data Science for Macro--Modeling with Financial and Economic Datasets - DSMM17*. doi:10.1145/3077240.3077250
- Patnaik, S., Moharkar, L., & Chaudhari, A. (2017). Deep RNN learning for EEG based functional brain state inference. *2017 International Conference on Advances in Computing, Communication and Control (ICAC3)*, India. doi:10.1109/icac3.2017.8318753
- Pattanayak, S. (2017). Convolutional Neural Networks. *Pro Deep Learning with TensorFlow*, 153-221. doi:10.1007/978-1-4842-3096-1_3
- Pham T, Tran T, Phung D, Venkatesh S. (2016). DeepCare: a deep dynamic memory model for predictive medicine. In: Bailey, James and Khan, Latifur and Washio, Takashi and Dobbie, Gill and Huang, Joshua Zhexue and Wang, Ruili eds, *Advances in Knowledge Discovery and Data Mining*. Cham: Springer International Publishing; 2016: 30-41.
- Rayatdoost, S., & Soleymani, M. (2018). Cross-Corpus Eeg-Based Emotion Recognition. *2018 IEEE 28th International Workshop on Machine Learning for Signal Processing (MLSP)*. doi:10.1109/mlsp.2018.8517037
- Razavian, A. S., Azizpour, H., Sullivan, J., & Carlsson, S. (2014). CNN Features Off-the-Shelf: An Astounding Baseline for Recognition. *2014 IEEE Conference on Computer Vision and Pattern Recognition Workshops*. doi:10.1109/cvprw.2014.131
- Ren, Y., & Wu, Y. (2014). Convolutional deep belief networks for feature extraction of EEG signal. *2014 International Joint Conference on Neural Networks (IJCNN)*. doi:10.1109/ijcnn.2014.6889383
- Roux, N. L., & Bengio, Y. (2008). Representational Power of Restricted Boltzmann Machines and Deep Belief Networks. *Neural Computation*, 20(6), 1631-1649. doi:10.1162/neco.2008.04-07-510
- Sahiner, B., Chan, H., & Hadjiiski, L. (2008). Classifier performance prediction for computer-aided diagnosis using a limited dataset. *Medical Physics*, 35(4), 1559-1570. doi:10.1118/1.2868757
- Sakhavi, S., Guan, C., & Yan, S. (2015). Parallel convolutional-linear neural network for motor imagery classification. *2015 23rd European Signal Processing Conference (EUSIPCO)*. doi:10.1109/eusipco.2015.7362882
- Scalzo, F., & Piater, J. (2005). Statistical Learning of Visual Feature Hierarchies. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR05) - Workshops*. doi:10.1109/cvpr.2005.532
- Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D., Glasstetter, M., Eggenberger, K., Tangemann, M., Ball, T. (2017b). Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11), 5391-5420. doi:10.1002/hbm.23730
- Schirrmester, R., Gemein, L., Eggenberger, K., Hutter, F., & Ball, T. (2018). P64. Deep learning for EEG diagnostics. *Clinical Neurophysiology*, 129(8). doi:10.1016/j.clinph.2018.04.699
- Schirrmester, R., Gemein, L., Eggenberger, K., Hutter, F., & Ball, T. (2017a). Deep learning with convolutional neural networks for decoding and visualization of EEG pathology. *2017 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*. doi:10.1109/spmb.2017.8257015
- Schwabedal, J. T. C., Sippel, D., Brandt, M. D., Bialonski, S. (2018). Automated Classification of Sleep Stages and EEG Artefacts in Mice with Deep Learning. *Quantitative Biology, Quantitative Methods*. https://arxiv.org/abs/1809.08443
- Sinha, A., & Ayush, K. (2018). Towards Mathematical Reasoning: A Multimodal Deep Learning Approach. *2018 25th IEEE International Conference on Image Processing (ICIP)*. doi:10.1109/icip.2018.8451353
- Stober, S. (2017). Learning discriminative features from electroencephalography recordings by encoding similarity constraints. *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. doi:10.1109/icassp.2017.7953343
- Suk, H., Lee, S., & Shen, D. (2014). Subclass-based multi-task learning for Alzheimers disease diagnosis. *Frontiers in Aging Neuroscience*, 6. doi:10.3389/fnagi.2014.00168
- Tabar, Y. R., & Halici, U. (2016). A novel deep learning approach for classification of EEG motor imagery signals. *Journal of Neural Engineering*, 14(1), 016003. doi:10.1088/1741-2560/14/1/016003
- Tang, T. A., Mhamdi, L., McInerney, D., Zaidi, S. A., & Ghogho, M. (2018). Deep Recurrent Neural Network for Intrusion Detection in SDN-based Networks. *2018 4th IEEE Conference on Network Softwarization and Workshops (NetSoft)*. doi:10.1109/netsoft.2018.8460090
- Tang, Z., Li, C., & Sun, S. (2017). Single-trial EEG classification of motor imagery using deep convolutional neural networks. *Optik*, 130, 11-18. doi:10.1016/j.ijleo.2016.10.117
- Teo, J., Chew, L.H., Chia, J.T., Mountstephens, J. (2018). Classification of Affective States via EEG and Deep Learning. *International Journal of Advanced Computer Science and Applications(IJACSA)*, 9(5). http://dx.doi.org/10.14569/IJACSA.2018.090517
- Tewari, A., Zollhofer, M., Kim, H., Garrido, P., Bernard, F., Perez, P., & Theobalt, C. (2017). MoFA: Model-Based Deep Convolutional Face Autoencoder for Unsupervised Monocular Reconstruction. *2017 IEEE International Conference on Computer Vision, (ICCV)*, Italy. doi:10.1109/iccv.2017.401
- Thodoroff P, Pineau J, Lim A (2016): Learning Robust Features using Deep Learning for Automatic Seizure Detection. In *JMLR Workshop and Conference Proceedings*, volume 56.
- Tjepkema-Cloostermans, M. C., Carvalho, R. C., & Putten, M. J. (2018). Deep learning for detection of focal epileptiform discharges from scalp EEG recordings. *Clinical Neurophysiology*, 129(10), 2191-2196. doi:10.1016/j.clinph.2018.06.024
- Tsang, W. (2003). Kernel methods in supervised and unsupervised learning. doi:10.14711/thesis-b805964
- Tsiouris, K.M., Pezoulas, V. C., Zervakis, M., Konitsiotis, S., Koutsouris, D. D., & Fotiadis, D. I. (2018). A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals. *Computers in Biology and Medicine*, 99, 24-37. doi:10.1016/j.combiomed.2018.05.019
- Ullah, I., Hussain, M., Qazi, E., & Aboalsamh, H. (2018). An automated system for epilepsy detection using EEG brain signals based on deep learning approach. *Expert Systems with Applications*, 107, 61-71. doi:10.1016/j.eswa.2018.04.021
- Vilamala, A., Madsen, K. H., & Hansen, L. K. (2017). Deep convolutional neural networks for interpretable analysis of EEG sleep stage scoring. *2017 IEEE 27th International Workshop on Machine Learning for Signal Processing (MLSP)*. doi:10.1109/mlsp.2017.8168133
- Wen, H., Shi, J., Zhang, Y., Lu, K., Cao, J., & Liu, Z. (2017). Neural Encoding and Decoding with Deep Learning for Dynamic Neural Vision. *Cerebral Cortex*, 28(12), 4136-4160. doi:10.1093/cercor/bhx268
- Weston, J., Ratle, F., & Collobert, R. (2008). Deep learning via semi-supervised embedding. *Proceedings of the 25th International Conference on Machine Learning - ICML 08*. doi:10.1145/1390156.1390303
- Wilaiprasitporn, T., Dittaphon, A., Matchaparn, K., Tongbuasirilai, T., Banluesombatkul N., Chuangsuwanich, E. (2018). Affective eeg-based person identification using the deep learning approach. *arXiv preprint arXiv:1807.03147*.
- Wu, Y., & Qiu, W. (2017). Facial expression recognition based on improved deep belief networks. doi:10.1063/1.4992947
- Xu, H., & Plataniotis, K. N. (2016). Affective states classification using EEG and semi-supervised deep learning approaches. *2016 IEEE 18th International Workshop on Multimedia Signal Processing (MMSP)*. doi:10.1109/mmmsp.2016.7813351
- Yahi A, Vanguri R, Elhadad N, Tatonetti N. P. (2017). Generative Adversarial Networks for Electronic Health Records: A Framework for Exploring and Evaluating Methods for Predicting Drug-Induced Laboratory Test Trajectories. *arXiv [Cs.LG]*. http://arxiv.org/abs/1712.00164
- Yang, H., Sakhavi, S., Ang, K. K., & Guan, C. (2015). On the use of convolutional neural networks and augmented CSP features for multi-class motor imagery of EEG signals classification. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. doi:10.1109/embc.2015.7318929
- Yu, X., & Chu, T. (2017). Dynamic link prediction using restricted Boltzmann machine. *2017 Chinese Automation Congress (CAC)*. doi:10.1109/cac.2017.8243496

Yuan, Y., Xun, G., Ma, F., Suo, Q., Xue, H., Jia, K., & Zhang, A. (2018). A novel channel-aware attention framework for multi-channel EEG seizure detection via multi-view deep learning. 2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI). doi:10.1109/bhi.2018.8333405

Zeng, H., Yang, C., Dai, G., Qin, F., Zhang, J., & Kong, W. (2018). EEG classification of driver mental states by deep learning. Cognitive Neurodynamics, 12(6), 597-606. doi:10.1007/s11571-018-9496-y

Zhang, D., Yao, L., Zhang, X., Wang, S., Chen, W., Boots, R., Benatallah, B. (2018). Cascade and Parallel Convolutional Recurrent Neural Networks on EEG-based Intention Recognition for Brain Computer Interface. AAAI Conference on Artificial Intelligence, North America.

Zhang, J., Yan, C., & Gong, X. (2017). Deep convolutional neural network for decoding motor imagery based brain computer interface. 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). doi:10.1109/icspcc.2017.8242581

Zhang, Q., and Liu, Y. (2018). Improving brain computer interface performance by data augmentation with conditional Deep Convolutional Generative Adversarial Networks. In proc of the National Natural Science Foundation of China. 19 Jun 2018.

Zheng, W., Zhu, J., Peng, Y., & Lu, B. (2014). EEG-based emotion classification using deep belief networks. 2014 IEEE International Conference on Multimedia and Expo (ICME). doi:10.1109/icme.2014.6890166