

Mobil EEG Cihazları ile Veri Toplama: Metodolojik Bir Kılavuz ve Uygulamalarla Değerlendirme

Çağatay Murat YILMAZ^{1*}, Bahar Hatipoğlu YILMAZ²

Öz

EEG (Elektroensefalografi), beyin aktivitelerinin invaziv olmayan şekilde ölçülmesini sağlayan ve nörolojik bozuklukların teşhis ve tedavisinde ile beyin-bilgisayar arayüzleri gibi çeşitli alanlarda kullanılan önemli bir teknolojidir. Mobil EEG kayıt cihazları, klinik alternatiflerine benzer kalitede sinyaller kaydedebilmektedir. Geleneksel EEG sistemlerinin gerektirdiği sabit ve kontrollü kayıt ortamlarına olan bağımlılığı ortadan kaldırarak, gerçek yaşam koşullarında, hatta hareket halindeyken bile beyin sinyallerinin gerçek zamanlı izlenmesini ve analizini mümkün kılmaktadır. Bu çalışma, mobil EEG ile kayıt alma sürecine dair literatürdeki deneyim eksikliğini gidermeyi amaçlamaktadır. Kayıt sürecinin deneysel aktarımıyla, benzer araştırmalarda özellikle kayıt alma sürecinde yöntemsel güvenilirliğin artırılması hedeflenmiştir. Çalışma kapsamında, EEG sinyallerinin kaydedilmesi ve ön işlenmesine ilişkin adımlar teknik detaylarla aktarılmış; motor hareket hayali ve duygu tanıma görevleri için oluşturulan veri setleri kullanılarak deneysel değerlendirmeler yapılmıştır. Mobil EEG cihazlarının teknik farklılıklarına rağmen, araştırmalarda güvenilir biçimde kullanılabileceği ortaya konmuştur. Sunulan yöntemsel kılavuz, mobil EEG sistemleriyle çalışacak araştırmacılar için pratik bir başvuru kaynağı niteliği taşımaktadır.

Anahtar Kelimeler: EEG, Mobil cihazlar, Motor hareket hayali, Duygu tanıma, Beyin-bilgisayar arayüzü.

Data Acquisition with Mobile EEG Devices: A Methodological Guide and Evaluation with Applications

Abstract

EEG (Electroencephalography) is an important technology that enables non-invasive measurement of brain activity and is used in various fields such as diagnosis and treatment of neurological disorders and brain-computer interfaces. Mobile EEG devices can record signals of similar quality to clinical counterparts. Eliminating the dependence on the fixed and controlled recording environments required by clinic EEG systems enables real-time monitoring and analysis of brain signals under real-life scenarios, even on the move. This paper addresses the lack of experience in the mobile EEG recording process literature. By experimentally demonstrating the recording process, this study aims to enhance methodological reliability for future research, particularly regarding data acquisition. Within the scope of the study, the steps regarding the recording and preprocessing EEG signals are described in technical detail, and experimental evaluations are made on the datasets generated for motor imagery and emotion recognition tasks. The findings demonstrate that mobile EEG devices can be used reliably in research despite their technical limitations. The methodological framework presented here is a practical reference for researchers utilizing mobile EEG systems.

Keywords: EEG, Mobile devices, Motor imagery, Emotion recognition, Brain-computer interface.

¹Karadeniz Teknik Üniversitesi, Yazılım Mühendisliği Bölümü, Trabzon, Türkiye, cmymaz@ktu.edu.tr

²Karadeniz Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Trabzon, Türkiye, baharhatipoglu@ktu.edu.tr

*Sorumlu Yazar/Corresponding Author

1. Giriş

Elektroensefalografi (EEG), beyin sinyallerinin ölçülmesi, kaydedilmesi ve incelenmesini sağlayan müdahalesiz bir nörogörüntüleme yöntemidir. EEG sinyalleri başta teşhis ve tedavi amaçlı sağlık uygulamaları olmak üzere insanları anlama ve yardım etmede sıklıkla kullanılır. Ayrıca insanlara ait duyguları, düşünceleri, niyetleri ve davranışları anlamak için önemli bir araçtır. İnsanların hayatına girmesi özellikle sinyal işleme ve yapay zeka tekniklerindeki ilerlemeler ile gün geçtikçe artmıştır. Günümüzde insansız hava araçlarını, (sanal) dronları, robotik kolları ve sanal gerçeklik ortamlarını kontrol etme gibi birçok problemin çözümü için kullanılır (Yılmaz ve ark., 2025). Örneğin, Li ve ark. bir alt ekstremite dış iskelet destek sistemi için yüzey elektromiyografisi (sEMG) ve motor hareket hayali (MHH) EEG sinyalleri ile beyin-bilgisayar arayüzü (BBA) tasarlamıştır (Li ve ark., 2024). EEG sinyallerinin sanal gerçeklik gibi teknolojilerle birleştirilmesi insan-bilgisayar etkileşimi, psikoloji ve sinirbilimi gibi alanlarda yeni yaklaşımlar sunar. Örneğin, Doma, EEG'nin sanal gerçeklik ortamında bir BBA giriş yöntemi olarak kullanımını göstermek amacıyla bir sanal gerçeklik oyunu geliştirmiştir. EEG ile tanımlanmış beyin dalgası örüntüleri bir dizi komut olarak kullanılmış, duygu durumları ve konsantrasyon değişiklikleri aracılığıyla sanal gerçeklik ortamlarıyla etkileşim sağlanmıştır (Doma, 2024). EEG sinyalleri özellikle sanal gerçeklik ile birlikte insan merkezli mimari tasarımlar için dahi fırsatlar sunmaktadır (Taherysayah ve ark., 2024).

EEG sinyalleri çok düşük genlikli elektrofizyolojik potansiyellerdir. Bu sinyallerin arka plan gürültülerinden ve farklı türdeki sinyallerden ayrılması kayıtların doğru alınması için önemlidir. Bu nedenle, EEG kayıtlarının teknik yönleri anlaşılmalı ve kayıtlar doğru alınmalıdır. Hem anlamlı EEG örüntülerini kaydetmek hem de sinyalleri doğru yorumlamak için elektrofizyoloji, kaydın biyolojik yönleri ve EEG'nin fiziksel ilkeleri bilinmelidir. Günümüzde sensör ve cihaz teknolojisinde ilerleme kaydedilmiştir, ancak yorumlanabilir EEG'yi çok az bozulmayla kaydetmek teknik açıdan zordur (William Tatum ve ark., 2025). Ayrıca, klinik EEG özellikle tıbbi alanlarda önemli bir araç olduğundan doğru veri kaydı bu alanlarda daha önemlidir. Tıbbi işlemlerde kayıt alma prosedürleri çoğunlukla sabittir ve işlemler sağlık uzmanları veya uzman teknisyenler tarafından yapılır. EEG uygulamalarında gerekli uzmanlık bilgisi, ya deneyime dayalı kuşaklar arası aktarım yoluyla ya da elektronörofizyoloji teknikerliği gibi alanlara özgü akademik ve mesleki eğitimlerle edinilir. Bu eğitimler, EEG cihazlarının etkin kullanımı, elektrot yerleşimi, kayıt sürecinin yürütülmesi, sinyal analizi, artefaktların tespiti, frekans bileşenlerinin hesaplanması ve klinik EEG bulgularının raporlanması gibi çeşitli becerilerin kazandırılmasını hedefler. Öte yandan, EEG verilerinin tanı amacıyla yorumlanması ise ileri düzey uzmanlık gerektirir (Jain ve ark., 2024).

Beyin-bilgisayar arayüzü (BBA) gibi uygulamalarda EEG sinyalleri, çoğunlukla özel tıbbi eğitim almamış kullanıcılar tarafından mobil EEG (mEEG) cihazlarıyla kaydedilmektedir. EEG sinyalleri kullanılarak geliştirilecek sistemlerin etkinliği, elde edilen sinyallerin doğruluğu ve güvenilirliğine bağlıdır. Çünkü, örneğin, status epileptikus hastalık teşhisinin EEG ile analizinde dikkat edilmesi gereken birçok husus vardır ve EEG kayıtları başarısız alınırsa teşhis olumsuz etkilenir (Wang ve ark., 2023). Bu nedenle, sağlıklı ve güvenilir sonuçlar için kayıt süreci titizlikle ele alınmalıdır. EEG sinyalleri ile yürütülen araştırmaların çoğunda veri kaydı ile ilgili deneysel bilgi yetersiz sunulur. Çalışmaların çoğu hazır veri setlerini kullanır. Bu veri setleri sadece veriler ve deneyler ile ilgili katılımcı sayısı, elektrot sayısı ve yerleşimi, örnekleme frekansı, görev türü (motor hareket hayali, duygu tanıma, görsel uyarılmış potansiyeller, vb.), kayıt süreleri gibi bilgiler içerir (OpenBCI-Datasets, 2025). Çalışmaların diğer bir kısmında hem veri setleri oluşturulur hem de bu veri setleri kullanılarak bilimsel araştırmalar yapılır (örn., Shi ve ark., 2023). Bu çalışmalarda veri setlerine ilişkin bilgiler daha ayrıntılı sunulur. Ancak, EEG sinyallerinin kaydı deneysel bir süreç şeklinde aktarılmaz. EEG kayıt cihazlarının kullanım kılavuzları ise sadece teknik dokümanlardır. Bu nedenlerle, EEG kayıtlarının alım sürecinin deneysel olarak aktarımı literatürdeki önemli bir eksikliktir. Çalışmada mobil EEG sistemlerinde kayıt alım sürecindeki tecrübe eksikliğini gidermek ve araştırmaların metodolojik kalitesini artırmak hedeflenmiştir. Motor hareket hayali ve duygu tanıma veri setlerine ilişkin EEG kayıtlarının alınmasından ön işleme aşamasına kadar olan süreç genel bilgiler eşliğinde sunulmuş, çalışmalarda elde edilen deneysel çıktılar verilmiştir. Bu çalışmanın literatüre sağladığı temel katkılar aşağıda sıralanmıştır:

- Mobil EEG cihazları ile gerçekleştirilen uygulamalarda, kayıt alma sürecinin deneysel aktarımına odaklanarak literatürdeki metodolojik boşluk doldurmaya çalışılmış, kayıt alma sürecindeki yöntemsel güvenilirliği artırmaya yönelik deneysel tecrübeler aktarılmıştır.
- Mobil EEG teknolojilerinin klinik ve araştırma uygulamalarındaki yeri değerlendirilmiş, mobil EEG sistemlerinin avantajları, kısıtları ve potansiyel kullanım alanları tartışılmıştır.
- Elektrot türlerinin teknik özellikleri ve avantaj-dezavantajlarını karşılaştırılmış, uygulamaya yönelik sistem tasarımı ve cihaz seçimine katkısı verilmiştir.
- Salin solüsyon kullanan yarı kuru elektrotlarla mobil EEG kayıtlarında sinyal iletim kalitesini korumaya yönelik uygulamalı öneriler ifade edilmiştir.
- EEG sinyallerinin güvenilir analizine yönelik ön işleme aşamaları incelenmiş ve bu süreçte kullanılabilecek örnek yöntem ve araçlar sunulmuştur.
- Önerilen kayıt alma prosedürleriyle oluşturulan motor hareket hayali ve duygu tanıma veri setlerinden elde edilen sonuçlar, literatürdeki benzer çalışmalarla karşılaştırılmış ve önerilen yaklaşımların etkinliği deneysel olarak değerlendirilmiştir.

2. EEG Sistemleri: Genel Bilgiler, Zorluklar, Kayıt Cihazları ve Elektrot Teknolojileri

2.1. EEG Sinyallerinin Sınıflandırılmasını Zorlaştıran Etmenler

EEG sinyallerinin analiz ve sınıflandırma sürecinde hem EEG'nin doğası hem de deneysel koşullardan kaynaklanan zorluklar bulunur. EEG aynı anda farklı konumlardaki elektrotlardan kaydedilir. Bu durum, kanal korelasyonu, yüksek boyutluluk gibi zorluklara neden olur. Ayrıca kafa derisi, kafatası ve diğer beyin katmanlarından geçen hacim iletimi uzamsal çözünürlüğü olumsuz etkiler (Brunner ve ark., 2007). Ayrıca, uyaranlar, duygusal durumlar, uyanıklık/uyku döngüleri, beyin hastalıkları, dikkat seviyeleri ve diğer faktörlere bağlı beyin aktiviteleri sürekli değişir. EEG'nin durağan ve doğrusal olmayan yapısı ile farklı kaynaklara ait birçok gürültü içermesi yorumlama ve analizini zorlaştırır.

Ayırt edici bilgileri taşıyan EEG sinyallerini yakalamak diğer önemli bir problemdir. Çünkü, her EEG bandı (delta, teta, alfa, beta, gama) çeşitli nörolojik süreçlerle ilintilidir. Probleme özgü frekansların belirlenmesiyle önemli beyin aktiviteleri yakalanır, ilgisiz frekans bileşenleri elenir, veri işleme maliyeti azaltılır. Örneğin, bir motor hareket hayali problemde faydalı örüntüler sıklıkla alfa ve beta bantlarında yer alır. Bu bantların performansları uygulamalara (Al-Saegh ve ark., 2021) ve kişilere bağlı olarak değişebilir. Duygu tanıma problemleri için de benzer durum geçerlidir. Örneğin, Zheng ve Lu duygu analizi için gama ve beta alt bantlarını kullanmıştır (Zheng ve Lu, 2015). Yang ve ark. ise duyguları ayırt etmek için yüksek gama frekanslarını kullanmıştır (Yang ve ark., 2020). Zhao ve ark. ise alfa ve beta gücünün olumlu duyguları verimli bir şekilde ayırt edebileceğini fakat teta gücünün olumsuz duygulardan büyük ölçüde etkilendiğini öne sürmüştür (Zhao ve ark., 2018). Zhang ve ark. adaptif bir şekilde frekans bandı üst ve alt sınırlarını belirleyen ve önemli beyin bölgeleriyle zaman aralıklarını vurgulayan bir ağ geliştirmiştir. Adaptif frekans bant seçimi BBA görevlerinin sınıflandırılmasında etkili olmuştur (Zhang ve ark., 2024).

Probleme ait ayırt edici bilgileri taşıyan elektrotların tespiti diğer önemli bir husustur. Çünkü, tüm elektrotlardan gelen verileri kullanmak yerine, probleme özgü bilgi taşıyan elektrotları belirlemek, veri boyutunu azaltıp yapay zeka modelleri ile analizi daha odaklı hale getirir (Arvaneh ve ark., 2011). Alakasız veya gürültülü elektrotları devre dışı bırakmak, sınıflandırma ve tahmin performansını yukarı çektiği gibi hesaplama verimliliğini artırır ve faydasız bilgilerin olası olumsuz etkilerini azaltır. Probleme özgü olmayan elektrotlar ek gürültü de getirebilir. Bu elektrotları kullanmamak sinyal kalitesini ve güvenilirliğini artırır. Örneğin, ortalama referans yöntemi ile tüm kanallara ait sinyal değerlerinin bir referansa göre yeniden hesaplanmasında gürültü içeren bir elektrotun referans alınması tüm sinyallerin kalitesini düşürür (Newman, 2025). Bu nedenle, probleme özgü elektrotların tespiti başarılı sistemlerin geliştirilmesini sağlar. Örneğin, BBA

görevlerine ait spesifik nöral aktiviteler yüksek sinyal kalitesi ile ancak uygun elektrotlardan edinilebilir. Ayrıca, farklı elektrot konumlarına ait sinyal güçleri kişiden kişiye değişkenlik gösterir. Bu nedenle, performansı optimize edecek elektrot konumları belirlenmelidir (Arvaneh ve ark., 2011). Örneğin, Kucukler ve ark. faydasız kanalların performansı olumsuz etkileyeceğini göz önüne almış ve performansı arttırmak için en ideal kanalları tespit etmeye çalışmıştır. Kanalların etkinliği kısa zamanlı Fourier dönüşümü ve Gramian Angular Fields (GAF) çıktıları çeşitli derin öğrenme modellerinde işlenerek belirlenmiştir (Kucukler ve ark., 2024). Bir duygu tanıma probleminde kanal sayısı arttıkça doğruluğun azaldığı ve kanal sayısı ile sınıflandırma performansı arasında ters korelasyon olduğu görülmüştür.

Denek içi değişkenlik (intra-subject variability), bir deneğin aynı görevi birden fazla tekrarında sinyallerde oluşan farkı ifade eder. Denekler arası değişkenlik (inter-subject variability) ise farklı deneklerin aynı görevdeki sinyal değişimlerini ifade eder (Zhao ve ark., 2021). EEG sinyallerinin denek içi ve denek arası değişim göstermesi, sinyal işleme, model oluşturma ve nörolojik araştırmalar için ciddi zorluk oluşturur (Huang ve ark., 2023). Sinyal değişkenlikleri farklı deneklerde ve zamanlarda beynin işleyişindeki farklılıkları yansıtır. Bu nedenle, aynı yöntemler farklı deneklerde başarılı olmayabilir ve değişkenlikler yapay zeka yöntemlerinin genelleme yeteneğini azaltabilir. Denek içi ve arası değişkenlikler ayırt edici bilgilerin dağılımında oldukça fazla değişkenliğe yol açsa da literatürde yeterince irdelenmemiştir (Huang ve ark., 2023).

2.2. İnvaziv Olmayan Mobil EEG Cihazları

EEG sinyallerinin kaydedilmesi, işlenmesi ve analizi zor bir problemdir. Günümüzde nörolojik hastalıkların teşhis ve tedavisinden BBA'lara kadar birçok alanda çalışmalar yürütülmektedir. EEG sinyalleri ile gerçekleştirilen çalışmaların (deneysel, laboratuvar, prototip/ürün geliştirme ve mühendislik) önemli aşamalarından biri kayıtların doğru alınmasıdır. Kayıtlar tıbbi cihazlarla alınabileceği gibi düşük maliyetli mobil cihazlarla da alınabilir. Tıbbi EEG cihazları, beynin elektriksel aktivitesini zamana bağlı ölçen ve kaydeden tanı amaçlı sistemlerdir. Klinik uygulamalarda epilepsi, uyku bozuklukları, koma değerlendirmesi ve beyin işlevi izleme gibi nörolojik durumların teşhis ve takibinde yaygın kullanılır. Mobil EEG cihazları ise beynin elektriksel aktivitesini sabit laboratuvar ortamları ve tıbbi amaçlar dışında gerçek zamanlı kaydedebilen taşınabilir sistemlerdir. Bu cihazlar nörobilim, bilişsel araştırmalar ve BBA'lar gibi uygulama alanlarında kullanılır. Günümüzde epilepsi gibi birçok sağlık uygulamasında mobil EEG'nin potansiyel klinik değeri incelenmiş, zaman, maliyet, kullanılabilirlik ve güvenilirlik açısından avantajları olduğu görülmüştür (Biondi ve ark., 2022). Örneğin, Titgemeyer ve ark. epilepsi hastalarının mobil ve klinik EEG kayıtlarını eşzamanlı almış, çeşitli kısıtlamalar altında klinik video

EEG'nin mobil EEG'den daha üstün olduğunu, ancak mobil EEG'nin teşhiste yardımcı olabileceğini gözlemlemiştir (Titgemeyer ve ark., 2020). Kutafina ve ark. mobil ve klinik EEG ile dinlenme durumunda eş zamanlı veri toplamıştır. Klinik EEG Micromed Brain Quick Plus Evolution cihazı ile 10-20 sistemine göre 21 elektrottan 256 Hz örnekleme oranıyla kaydedilmiştir. Mobil EEG ise Emotiv Epoc ile 10-20 sistemine göre 14 elektrottan 128 Hz örnekleme oranıyla kaydedilmiştir. Kayıtlarda kullanılan elektrot sayıları, konumları ve referanslar farklıdır. Mobil elektrotlar klinik EEG elektrotlarına mümkün olduğunca yakın yerleştirilmiştir. Farklıklara rağmen mobil ve klinik cihazlar arasında 0,64'lük bir ortalama doğrusal korelasyon elde edilmiştir (Kutafina ve ark., 2020).

Mobil EEG cihazları, teknik sınırlamalara karşı özellikle BBA ve nörobilim alanlarında yüksek potansiyel sunmaktadır. Geliştirilmekte olan mobil sensörler bu alanlarda yeni araştırma fırsatları oluşturmaktadır. Mobil EEG cihazları ve sensörleri tıbbi alternatiflerinden farklılıklar içerir. Bu cihazlar taşınabilir olmaları ve çeşitli problemlerde kullanılmaları için daha farklı yapılarda tasarlanır. Örneğin, bir sanal gerçeklik uygulamasında, BBA oluşturulurken, doğada yürüyüş yaparken veya uyurken EEG kaydı mobil cihazlarla daha kolaydır. Mobil cihazlar genellikle tıbbi cihazlara göre daha az sayıda kanala sahiptirler ve dolayısıyla daha düşük çözünürlük sunarlar. Genellikle kablosuz bağlantı kullanırlar ve dahili bataryalarla çalışırlar. Kullanıcılar için hareket özgürlüğü, kolay kurulum ve daha basit kullanım kolaylığı sağlarlar. Örneğin, bir BBA'da EEG kabloları hareket kapasitesini kısıtlayarak ek bir yük getirir. Mobil cihazlar beyin aktivitelerinin gerçek zamanlı ölçümü ve işlenmesini sağlayarak için yeni çözümler sunarlar. Bu cihazlar beyin aktivitelerinin taşınabilir ve sürekli izlenmesini de mümkün kılar. Cerrahi müdahaleyle yerleştirilen invaziv elektrotlarla daha iyi kaynaklardan daha yüksek çözünürlük ve hassasiyette, daha az gürültülü EEG kayıtları alınabilir. Ancak cerrahi müdahale gerektirmesi bu tekniğin en önemli dezavantajıdır (Shah ve Mittal, 2014). Günümüzde, farklı kullanım senaryolarına ve uygulama alanlarına hitap eden çok sayıda taşınabilir EEG cihazı piyasaya sunulmuştur. BioSemi EEG sistemleri (BioSemi, 2025), CGX EEG cihazları (CGX, 2025), Brain Products nörofizyoloji EEG çözümleri (Brain Products, 2025), OpenBCI donanım ve yazılımları (OpenBCI, 2025), Muse baş bantları (Muse, 2025), NeuroSky MindWave mobil başlık seti (NeuroSky, 2025), Emotiv Epoc X, Flex, Insight başlıkları ve MN8 earbudları (Emotiv, 2025) bazı popüler mobil EEG kayıt cihazlarıdır.

2.3. EEG Elektrot Türleri: Islak, Kuru ve Yarı Kuru Yaklaşımlar

EEG beynin elektriksel aktivite salınımlarını kafa derisine yerleştirilen elektrotlarla kaydeder. Sinyallerinin kaydedilmesinde ıslak, kuru veya yarı kuru elektrotlar kullanılabilir (Li ve ark., 2020; Yuan ve ark., 2021). Klasik ıslak elektrotlarda kafa derisi ile elektrot yuvaları arasındaki boşluklar jel ile doldurup iletkenlik sağlanır. Bu elektrotlar özellikle klinik EEG sinyallerini (uyku çalışmaları,

epilepsi teşhisi, beyin tümörü veya travmatik beyin hasarı değerlendirmesi gibi) kaydetmede kullanılır. Nispeten uzun süreli ve stabil veri toplamaya olanak sağlarlar. Hareket ve temas artefaktlarına karşı kuru elektrotlara göre daha dayanıklıdır. Ancak, jel uygulamasının zaman alması hazırlık süreci gerektirir. Jel uzun süreli kullanımda kuruyabilir ve iletkenlik düşebilir (Yuan ve ark., 2021; Guger ve ark., 2012; Li ve ark., 2020). Ayrıca, sinyallerin alınmasından sonra jel temizlenmelidir. BBA gibi günlük yaşam uygulamaları için avantaj ve dezavantajları dikkate alınmalıdır. Çünkü, jel sürülmesi kullanıcı açısından rahatsız edicidir, hazırlık süresi gerektirir ve kullanıcı konforu açısından yetersiz olabilir. Kuru elektrotlar ise kafa derisi ile temas için herhangi bir iletken sıvıya ihtiyaç duymaz (Soufineyestani ve ark., 2020). Islak elektrotlara kıyasla hızlı kurulum sağlarlar ve daha kullanıcı dostudurlar. Ancak, kuru elektrotların pratik kullanımlarını sınırlayan bazı problemler vardır. Örneğin, elektrot teması daha düşük olacağı için sinyal kalitesi nispeten düşüktür. Ayrıca, kafa hareketlerinden dolayı oluşan sinyal bozulmalarına daha duyarlıdır. Son yıllarda hem ıslak hem de kuru elektrotların avantajlarını bir araya getirip az miktarda elektrolit sıvısı gerektiren yarı kuru elektrotlar kullanılmaya başlamıştır (Li ve ark., 2020). Bu elektrotlar hem ıslak elektrotlar gibi güvenilir sinyalleri toplayabilir hem de kurulumları kuru elektrotlar gibi kolaydır. Islak elektrotlarla karşılaştırıldığında, yarı kuru elektrotların kurulumu daha pratiktir ve temizlik işlemleri daha kısa sürede tamamlanır.

2.4. EPOC Flex Salin Sensör EEG Kayıt Cihazı Seti

Emotiv Epoc Flex birçok araştırma alanında sıklıkla kullanılan ve araştırma kalitesinde veri toplama kapasitesine sahip invaziv olmayan bir mobil EEG cihazıdır (Williams ve ark., 2020). Bu çalışmada sunulan deneylerde EPOC Flex Model 1.0 kiti kullanılmıştır. Güncel versiyonu 256 Hz örnekleme destekleyen EPOC Flex Model 2.0'dır. Kit içerisinde, kontrol ünitesi, şarj için USB kablosu, USB PC alıcı-verici dongle, salin solüsyon sıvısı (jel sensörlü cihazlarda jel), EasyCap başlık, kırmızı renkteki sağ elektrot ağaçları, mavi renkteki sol elektrot ağaçları, kenarlıklar ve keçe pedleri yer alır. Güncel versiyonlarında kabloları düzenleyip hareket halinde başlığa sabitlemek için siyah kablo bağları ve bağlamak için iğne gibi eklerde yer alır.

Cihazda EEG kayıtlarının iletimi kablosuz bağlantı ile gerçekleştirilir. PC alıcı-verici dongle, başlık setinin bir bilgisayara bağlanması ve sinyallerin 2.4 GHz kablosuz bir protokolle kontrol ünitesinden kayıt cihazına aktarılması için kullanılır. Elektrot sensörler paketinde 32 normal elektrot ile 2 referans elektrot bulunur. Kırmızı renkteki sağ ve mavi renkteki sol elektrot ağaçları kontrol ünitesinin ilgili yönüne takılır, elektrotlar yerleştirilir, temas ve EEG sinyal kalitesi iyiye kayda başlanır. Şekil 1(a)'da temel hatları verilen başlık seti aynı anda 32 konumdan kayıt alabilir (Flex 2 Saline, 2025). EasyCap başlık elektrot yerleşimi için Şekil 1(b)'deki gibi 72 farklı açıklık içerir

artmıyor veya kayıt alınırken sürekli değişiyorsa (aynı veya farklı elektrotlarda düşük veya yüksek şeklinde) elektrotların doğru konuma yerleşiminde sorun olması muhtemeldir. Bu durumlarda başlık çıkarılmalı ve keçe pedleri salin solüsyonla tekrar doyurulmalıdır. Ardından başlık yeniden yerleştirilmelidir. Başlık yerleştirmeden önce saçların temasa engel olup olmadığı kontrol edilmelidir. Keçe pedleri salin solüsyonla ıslatıldıktan bir süre sonra kurumaya başlar ve zamanla elektrot teması düşer. Epoc Flex paketinde yer alan kenar aparatları kurumayı yavaşlatır, salin solüsyonun yayılmasını önler ve elektrotların başlığa daha iyi tutunmasını sağlar (EPOC Flex User Manual, 2025; Yılmaz, 2021).


Deneylerde oturur pozisyonda kayıtlar alınmasına rağmen kayıt süresince elektrot temasının bazen oldukça düştüğü gözlenmiştir. Bu durumlarda sinyal iletim düzeyi yukarıda verilen yöntemlerle arttırılmış ve stabil kalması sağlanmıştır. EEG kayıtlarının özellikle hareket halinde alındığı durumlarında, başta referans elektrotlar olmak üzere tüm kayıt elektrotlarının iletkenlik düzeyi sürekli yüksek tutulmalıdır. Çünkü, hareket halinde kaydedilen EEG sinyallerinde, vücut hareketlerinden kaynaklanan artefaktlar daha belirgin hale gelir. Bunların fark edilmemesi beyin aktivitelerinin yanlış yorumlamalara neden olabilir. Bu tarz deneylerde jel kullanan sıvı elektrotların kullanılması yerinde olabilir. Çünkü, jel yapışkanlık sağlayıp hem kafa derisini hem de elektrotu tuttuğundan özellikle kafa hareketlerinin olduğu deneylerde jel kullanan elektrotlar daha dayanıklıdır.

3.2. EEG Sinyallerinin Kaydedilme Süreci

Deneylerde EEG sinyallerinin kaydedilmesi, cihazın ve elektrot sinyal veriminin kontrolü, EEG sinyallerin izlenmesi ve temel bazı analiz işlemler için Emotiv PRO yazılımı kullanılmıştır (EmotivPRO, 2025); ancak farklı cihaz kullanıcıları benzer işlemleri kendi cihazlarının desteklediği yazılımlarla gerçekleştirebilir. EEG kayıtlarında öncelikle hangi elektrotların kullanılacağı belirlenmelidir. Epoc Flex'te standart elektrot yerleşimi Şekil 1(b)'deki gibidir. Bu senaryoda 32 elektrot kayıt için kullanılırken, CMS ve DLR referans olarak kullanılır. Kırmızı renkteki sağ ve mavi renkteki sol elektrot ağaçları kontrol ünitesinin ilgili yönüne takılır. Temas sağlanacak biçimde elektrotlar ilgili konumlarına yerleştirilir ve elektrot teması yeterliyse kayıt toplamaya başlanır. Epoc Flex'te kırmızı renkteki elektrotlar başın sağ kısmına, mavi renktekiler ise sol kısmına yerleştirilir. Örneğin, beyin sol tarafında mavi renkteki H kodlu elektrot (LH) yerleşim şemasına göre frontal lobda Fp1 konumundaki açıklığa yerleştirilir. Benzer şekilde, sağ tarafta kırmızı renkteki H kodlu elektrot (RH) frontal lobda Fp2 konumundaki açıklığa yerleştirilir. CMS elektrodu TP9, DLR ise TP10 konumuna yerleştirilir (EPOC Flex User Manual, 2025; Yılmaz, 2021).

EEG kaydında farklı problemlere göre farklı elektrot yerleşimleri de kullanılabilir. Örneğin, 32 elektrotla sadece ön bölgelerden daha yoğun kayıtlar alınmak istenebilir. Benzer şekilde, daha az

sayıdaki 24 elektrotla farklı konumlardan kayıtlar alınmak istenebilir. Epoc Flex ile daha az sayıda elektrottan kayıtların alınması durumunda kayıt için en az 14-16 elektrotun (referans elektrotlar dışında) kullanılması verilerin sağlıklı alınması için oldukça önemlidir. Farklı elektrot yerleşimlerinin kullanılacağı durumlarda EmotivPro’da yeni bir yerleşim konfigürasyonu oluşturulmalıdır. Çünkü EEG sinyalleri bu konfigürasyonlarla kontrol ünitesine iletilir. Kullanılmayacak elektrotlar elektrot ağaç konnektörlerinden çıkarılmalıdır.




Şekil 3. Motor hareket hayali sinyallerinin kaydı için örnek bir elektrot yerleşim düzeni

Motor hareket hayali görevlerine ait EEG sinyallerinin kaydedilmesinde kullanılan örnek bir elektrot yerleşim düzeni Şekil 3'te verilmiştir. Veri kaydında C3, Cz ve C4 ile çevresindeki toplam 17 elektrottan EEG kaydı alınmıştır. Bunlar; C3 ve çevresindeki FC3, C1, CP3, C5; Cz ve çevresindeki FCz, C2, CPz, C1; C4 ve çevresindeki FC4, C6, CP4, C2 ile yoğunluğunu arttırmak için eklenen FC1, CP1, FC2 ve CP2 elektrotlarıdır. DRL ve CSM referansları olarak sırasıyla P9 ve P10 kullanılmıştır. Elektrotların etiketleri ve konumları ise şu şekildedir. Mavi renkteki sol elektrot ağacına ait LA elektrodu C5, LB elektrodu FC3, LC elektrodu C3, LD elektrodu CP3, LE elektrodu FC1, LF elektrodu C1, LG elektrodu CP1 ve LH elektrodu FCz konumlarındadır. Kırmızı renkteki sağ elektrot ağacına ait RA elektrodu Cz, RB elektrodu CPz, RC elektrodu FC2, RD elektrodu C2, RE elektrodu CP2, RF elektrodu FC4, RG elektrodu C4, RH elektrodu CP4 ve RJ elektrodu C6 konumlarındadır. Referans elektrotlar farklı çalışmalarda farklı konumlara yerleştirilebilir. Örneğin, Emotiv EPOC + cihazı ile gerçekleştirilen bir nöro-oyun çalışmasında P3 and P4 konumları kullanılmıştır (Paszkiel ve ark., 2021). Duygu tanıma deneylerinde ise kayıtlar Fp1-Fp2, AF3-AF4, F7-F3-Fz-F4-F8, FC5-FC1-FC2-FC6, T7-C3-Cz-C4-T8, CP5-CP1-CP2-CP6, P7-P3-Pz-P4-P8, PO3-PO4, O1-Oz-O2 elektrotlarından alınmıştır. Elektrot yoğunluğunun fazla olması tüm elektrotların aynı anda yüksek derecede temas sağlama olasılığını düşürür. Duygu tanıma

deneylerinde özellikle bazı kadın katılımcıların saç yoğunluğunun fazla olması nedeniyle bağlantı kalitesinde zorluk yaşanmıştır. Bu katılımcılarda 32 elektrodun tamamı kullanılmamıştır. Sadece duyu tanıma ile ilişkisi en yüksek bölgelerdeki elektrotlar kullanılmıştır.

EmotivPro, EEG sinyallerini kaydetme, görüntüleme, analiz etme ve dışa aktarma için gerekli bileşenleri içerir. Bu nedenle, sinyallerin hem gerçek zamanlı incelenmesi hem de kaydedilmiş verilerin görüntülenmesi bu yazılımla gerçekleştirilmiştir. Motor hareket hayali görevi sırasında kaydedilen örnek bir EEG sinyali arayüzde Şekil 4’te verilmiştir. Hareket etme, göz kırpması, sinyal iletim düzeyi düşüklüğü gibi problemler nedeniyle oluşan bozulmaların bir kısmı veri toplamada ham sinyallerde gözlemlenebilir. EmotivPro elektrot kurulum arayüz haritalarıyla doğru yerleştirilmemiş ve iletkenlik seviyesi yetersiz elektrotların anlık izlenmesine olanak verir. Deneylerde sinyal iletim düzeyi kayıt alım süresince yüksek tutulmuştur. Sensörlerde aşınma ve kirlilik olup olmadığı kayıt öncesinde kontrol edilmiştir. Kayıt sonrasında ise sensörler saf suyla temizlenip kurulanmıştır. Kablosuz aktarımın başarılı olması için USB PC alıcı-vericisi kontrol ünitesini doğrudan göreceği bir konuma yerleştirilmiştir.



Şekil 4. EmotivPro arayüzü ve motor hareket hayali amacıyla kaydedilen örnek bir EEG sinyali

3.3. Veri Setleri

3.3.1 Motor Hareket Hayaline Dayalı Beyin-Mobil Telefon Arayüzü Veri Seti

Motor hareket hayalinde fiziksel hareketler yapıp motor sistem ve kaslar kullanılmaz, hareketler sadece beyinde simüle edilerek gerçekleştirilir. Örneğin, bir kişinin parmaklarını fiziksel

olarak hareket ettirmeden zihninde hareket ettirdiğini düşünmesi motor hareketin hayal edilmesine bir örnektir. Motor hareket hayaline dayalı beyin-mobil telefon arayüzü veri seti (MHH-BMTA) mobil telefonların kullanımındaki motor hareketlerden olan tıklama ve kaydırma hareketlerinin hayallerine ait EEG verilerini içermektedir. Tıklama mobil bir cihazın ekranına parmakla hafif bir şekilde tıklamanın hareket hayalini, kaydırma ise ekranındaki nesneleri başparmakla aşağı doğru kaydırma hareketinin hayalini ifade eder. Veri seti TÜBİTAK proje desteğiyle Yılmaz (2021) çalışmasında oluşturulmuştur.

Deneklere, mobil cihazlara yönelik motor hareket hayali görevlerine alışmaları amacıyla ön bilgilendirme yapılmış ve her oturum öncesinde test kayıtları alınmıştır. Çünkü motor hareketlerin zihinsel olarak hayal edilmesi zordur. Kayıtlar sabah saatlerinde (10:00–13:00) alınmıştır. Denekler konforlu bir koltukta oturmuş, kayıtlar EPOC Flex ile müdahalesiz alınmıştır. Veri seti, Karadeniz Teknik Üniversitesi'nde öğrenim gören veya çalışan 8 (2 kadın, 6 erkek) gönüllüden elde edilmiştir. Güvenilir veri elde edebilmek adına, daha önce EEG veya BBA sistemleriyle deneyim sahibi olan ve verilecek talimatları doğru şekilde uygulayabilecek denekler tercih edilmiştir. Bir denek için deney ortamı ve elektrot yerleşim düzeni Şekil 5'teki gibidir. Veri seti bölüm 3.1 ve 3.2'te sunulan kayıt alma adımları ile oluşturulmuştur. Sinyaller ön işlenmesi ise bölüm 3.4'te sunulan adımların bir kısmı ile gerçekleştirilmiştir. Kayıtların alınması, deney ortamı ve işlenmesi ile ilgili detaylı bilgilere Yılmaz (2021) ve Yılmaz ve ark. (2025) çalışmalarından erişilebilir.



Şekil 5. Kayıt alma ortamı ve elektrot sensörlerin yerleştirilme düzeni (Yılmaz, 2021)

3.3.2 Karadeniz Teknik Üniversitesi Çok Modlu Duygu Tanıma Veri Seti

Çok modlu duygu tanıma sistemlerinin doğru analizi ve performanslarının artırılabilmesi için sistemli bir biçimde oluşturulmuş kaliteli veri setleri gerekir. Katılımcılardan aynı anda birden fazla biyolojik veri toplamak kolay bir işlem olmadığından, çok modlu veri setlerinin sayısı literatürde oldukça sınırlıdır. Bu veri setlerinin başarısı, kayıt ortamının dış etkenlerden arındırılmış ve kontrollü olması, katılımcıların yeterli ve iyi bilgilendirilmiş olması, ayrıca deney materyallerinin eksiksizliği gibi birçok faktöre bağlıdır.

KMED veri seti, Karadeniz Teknik Üniversitesi'nde öğrenim gören lisans ve lisansüstü öğrenciler ile akademisyenlerden oluşan 14 sağlıklı katılımcıya (11 erkek, 3 kadın) ait EEG sinyalleri ile yüz görüntüsü kayıtlarını içermektedir. Kayıtlar, her bir katılımcı için iki ayrı günde alınmıştır. Erkek katılımcılardan her duygu sınıfı (komik, korku, tiksinti ve rahatlama) için bir oturumda 40 olmak üzere, iki oturumda toplamda 320 kayıt alınmıştır. Kadın katılımcılardan ise her sınıf için bir oturumda 35 deneme olmak üzere iki oturumda toplamda 280 kayıt alınmıştır. Kadın katılımcılardan alınan kayıt sayısının daha az olmasının nedeni, EEG sinyallerinin elde edilmesini güçleştiren yüksek saç yoğunluğu gibi faktörlerdir. Veri seti, Hatipoğlu Yılmaz (2022) tarafından yürütülen TÜBİTAK destekli bir proje kapsamında hazırlanmıştır. Kayıt ortamında kadın ve erkek katılımcılardan alınan örnek görüntüler Şekil 6'da verilmiştir. Veri seti bölüm 3.1 ve 3.2'te sunulan kayıt alma adımları ile oluşturulmuştur. Sinyaller ön işlenmesi ise bölüm 3.4'te sunulan adımların bir kısmı ile gerçekleştirilmiştir. Kayıtların alınması, deney ortamı ve işlenmesi ile ilgili detaylı bilgilere Hatipoğlu Yılmaz (2022) ve Hatipoglu Yılmaz ve ark. (2025) çalışmalarından erişilebilir.



Şekil 6. EEG ile yüz görüntülerinin eş zamanlı kaydı ve kayıt ortamında erkek (solda) ve kadın (sağda) katılımcılardan alınan örnek görüntüler (Hatipoğlu Yılmaz, 2022)

3.4. EEG Sinyallerinin Önışlenmesi ve Kullanıma Uygun Hale Getirilmesi

Ortamdaki radyo dalgaları EEG sinyallerini etkiler ve gürültüye neden olabilir. Bu nedenle, kayıt ortamında gürültüye neden olan etmenlere dikkat edilmelidir. Epoc Flex 1.0'ın gömülü yazılımı elektriksel güç kaynaklı paraziti gidermek için 50 ve 60 Hz'de çift çentik filtresi uygular. Filtre yaklaşık 45 Hz'e kadar etki ettiğinden üst limit 43 Hz civarındadır. Nyquist-Shannon örnekleme teoremine göre, örnekleme hızının yarısının üzerindeki frekans bileşenleri yeniden yapılandırılmaz ve Nyquist-Shannon sınırının üzerindeki herhangi bir frekansın analizi gerçekleştirilemez (Weiergräber ve ark., 2016). Bu nedenle, EEG cihazının seçimi, hedeflenen frekans aralıkları ve çalışma koşulları dikkate alınarak yapılmalıdır. Örneğin, gamma frekans bandını (30-100 Hz) incelemek için cihaz en az 200 Hz örnekleme hızına sahip olmalıdır. Yeterli örnekleme hızı, uygun frekans aralığı, yüksek sinyal gürültü oranı ve elektrot kalitesi, doğru ve güvenilir ölçümler için önemlidir. Epoc Flex kayıt cihazı şehir elektrik şebekeleri kaynaklı harmonikleri kaldırmak için 85 Hz üzeri bir filtre ve 64 Hz de alçak geçiren bir filtre uygular (Emotiv EPOC+, 2025). Farklı mobil EEG cihazları çeşitli donanım filtreleri, göz kırpması ve kas hareketleri gibi artefaktlar için tespit ve giderim teknikleri, referanslama ve dijital örnekleme gibi araçlar içerir.


Ön işleme artefaktları filtreleme, veri kalitesi artırma ve analiz için temiz sinyalleri elde etmeyi amaçlar. EEG sinyallerinin daha doğru ve güvenilir analizine olanak tanır. EEG cihazlarının uyguladığı önışlemler temiz EEG sinyallerinin elde edilmesi için yeterli değildir. Bu nedenle ek önışlemler yapılmalıdır. EEG sinyallerinin işlenmesinde hazır kütüphanelerin (örneğin EEGLAB, FieldTrip, Brainstorm, MNE, BioSPPy, OpenViBE) kullanılması, sinyal filtreleme, bozuklukların giderimi, zaman-frekans analizi gibi karmaşık işlemlerin doğrulukla uygulanmasını sağlar. EEG sinyalleri için ön işlemenin evrensel bir yolu yoktur, çünkü farklı veri setleri, sinyal türleri ve yöntemlere göre veri ön hazırlığı adımları değişebilmektedir. Deneme yanılma ve sinyal analizi ile en iyi adımlar ve hangi sırada uygulanacakları belirlenir. Literatürde, ön işleme adımlarının etkinliğini değerlendiren ve bu süreçleri tartışan çalışmalar da mevcuttur (Delorme, 2023). Deneylerde ve sonraki çalışmalarda, cihazların uyguladığı önışlemlere ek olarak şu adımların uygulanmasının EEG sinyallerinin sınıflandırılmasına katkı sağlayacağı gözlenmiştir. Bazı adımlarda kullanılabilecek örnek uygulamalar EEGLAB Matlab araç seti (Delorme ve Makeig, 2004; EEGLAB, 2025) ve bazı kütüphaneler ile verilmiştir.

- Örnekleme oranı yeniden ayarlanarak hem veri boyutu azaltılabilir hem de frekans içeriği analiz amacına uygun bir şekilde optimize edilebilir.
- 0.5 Hz veya 1 Hz yüksek geçiren filtre uygulanır. İlgili alanındaki frekans bileşenlerini kapsayacak şekilde bant geçiren (örneğin motor hareket hayali için 8-30 Hz) süzgeçlerle de filtreleme yapılabilir.


- EEG sinyalleri referanslar temel alınarak ölçülür. Ancak, yanlış referans seçimi, gürültü veya istenmeyen etkilere neden olabilir. Bu nedenle, sinyaller başka bir referansa göre yeniden hesaplanabilir. Ortalama referanslama (average reference) ve referans elektrot standardizasyon tekniği (reference electrode standardization technique) gibi yöntemler kullanılabilir. Referans montajı ve elektrot kurulumu kafa derisinden ölçülen EEG potansiyellerini oldukça etkileyebilir. Örneğin, Hu ve ark. referans elektrot standardizasyon tekniğinin yeniden referanslama için tercih edilebileceğini ve ortalama referanslamamanın yüksek seviyeli sensör gürültüsü durumlarında alternatif bir seçenek olabileceğini göstermiştir (Hu ve ark., 2018).
- Problemlerle ilişkili EEG zaman dilimleri epoklar halinde çıkarılabilir. Uygun olmayan veri periyotları ve kanallar kaldırılabilir. Sinyal bozukluğu içeren kayıtlar manuel olarak silinebileceği gibi bu işlemleri otomatik yapan yöntemler de kullanılabilir. Örneğin, EEGLAB'ın Clean Rawdata eklentisi ile şu kriterlere uyan sinyaller kaldırılabilir: 10 saniyeden uzun bir süre sabit kalan, maksimum kabul edilebilir yüksek frekanslı gürültü standart sapması 4 Hz üstünde olan ve komşu kanallarla kabul edilebilir korelasyonu 0.6'dan düşük olan. Ayrıca, artefakt alt uzay yeniden yapılandırması (artifact subspace reconstruction, ASR) EEG arka plan aktivitesi koruyup göz kırpması, kas ve sensör hareketinden kaynaklanan gürültüler kaldırılabilir (Mullen ve ark, 2015). Örneğin, Arad ve ark. (2018) hareket halinde EEG sinyallerinde bu yöntemle başarılı sonuçlar almıştır. ASR uygulanmadan önce bazı önkoşullar yerine getirilmelidir. Örneğin, yüksek geçiren filtre uygulanmalı (sinyal ortalaması sıfır olmalı) ve veriler tüm-rank (full-rank) yani tüm kanallar bağımsız olmalıdır. ASR öncesi ortak ortalama referanslama (Common Average Reference) gibi verilerde bağımlılık oluşturacak işlemlerin yapılmamasına dikkat edilmelidir (Kothe, 2025).
- EEG sinyalleri, yalnızca beyin aktivitelerini değil, aynı zamanda göz kırpması, kas hareketleri ve çevresel gürültüler gibi istenmeyen sinyal bozulmalarını da içerir. Bir kör kaynak ayırma (blind source separation) yöntemi olan bağımsız bileşen analizi (independent components analysis, ICA) gibi tekniklerle, sinyaller bağımsız bileşenlere ayırarak farklı kaynaklardan gelen sinyaller belirlenebilir ve asıl beyin aktiviteleri daha net bir şekilde analiz edilebilir. Örneğin, EMG ile EEG zamansal ve uzamsal düzlemlerde istatistiksel bağımsızlığa sahiptir (Jiang ve ark., 2019). Bu prensibe dayanarak EMG gibi bileşen artefaktlarını elimine etmek için bağımsız bileşen analizi ve çeşitli istatistiksel yöntemler kullanılır (Li ve ark., 2021). Sinyallerin bağımsız bileşenlere ayrıştırması manuel olarak incelenebilir, seçilebilir ve yorumlanabilir, ancak bunu yapmak hem zaman hem de deneyim gerektirir. Çünkü bağımsız bileşenlerin bir düzeni veya özgün yorumları yoktur. Literatürde bağımsız bileşenlerin sınıflandırılması için otomatik yaklaşımları önerilmiştir. Bu yaklaşımlar EEG sinyallerinin

analizini hızlandırır ve bağımsız bileşenlere ayrıştırmanın gerçek zamanlı uygulamalara yakın kullanımını sağlar (Pion-Tonachini ve ark. 2019). ICLabel (Pion-Tonachini ve ark. 2019) bağımsız bileşenlerin otomatik sınıflandırılmasında kullanılabilen başarılı yaklaşımlardan biridir. Bu araç bileşenlerin beyin aktivitesi mi yoksa kas, göz, kalp atışı, hat gürültüsü, kanal gürültüsü gibi farklı kategorilere ait olup olmadığını tespit eder. Örneğin, bu yaklaşım kullanılarak EEG aktivitesiyle ilgili olmayan göz hareketleri ve kanal gürültüleri olasılıklarına göre EEG sinyallerinin çıkarılabilir. Kör kaynakları ayırmak için temel bileşen analizi (principal component analysis) ve kanonik korelasyon analizi gibi (canonical correlation analysis) yöntemler de kullanılabilir. Literatürde artefaktları kaldırmak için regresyon analizi, dalgacık dönüşümü, ampirik mod ayırma (empirical mode decomposition), çeşitli filtreleme metotları ve seyrek ayrıştırma (sparse decomposition) gibi yöntemler de yaygındır (Jiang ve ark., 2019). Farklı veri setleri ve sinyallere göre bu artefakt kaldırma tekniklerinin başarısı değişebilir. EEGLAB gibi araç setleri sinyal işlemeye yönelik birçok eklenti içerir (EEGLAB Plugins, 2025).

Motor hareket hayali görevlerine ait EEG sinyalleri için yapılan örnek bir ön işleme şu şekildedir: Epoklarına ayrılan sinyaller 0.5 Hz yüksek geçiren ve 8-30 Hz bant geçiren süzgeçlerle filtrelenmiştir. Ardından, sinyaller ICA ile bağımsız bileşenlerine ayrılmış, bağımsız bileşenler ICLabel ile otomatik sınıflandırılmış ve farklı kaynaklardan (kas, göz, kalp atışı, hat gürültüsü, kanal gürültüsü ve diğer) olma olasılıkları 0.9 üstü olan bileşenler işaretlenip kaldırılmıştır. Ön işleme öncesi ham sinyaller Şekil 7, ön işlemler uygulandıktan sonra elde edilen sinyaller ise Şekil 8’de verilmiştir.



Şekil 7. Ön işlemler öncesi örnek bir motor hareket hayali EEG sinyali



Şekil 8. Önışlemler sonrası örnek bir motor hareket hayali EEG sinyali

4. Bulgular ve Tartışma

Emotiv EPOC Flex cihazı ile yapılan kayıtlar, mobil EEG sistemlerinin hem bilişsel hem de duygusal durumların ayrıştırılmasında etkin bir şekilde kullanılabileceğini ortaya koymuştur. Bu bölümde, mobil EEG sistemleriyle toplanan verilerde gerçekleştirilen motor hareket hayali ve duygu tanıma görevlerine yönelik sınıflandırma performanslarına ilişkin bulgular sunulmaktadır. MI-BMPI veri setinde mobil telefonlarda tıklama ve kaydırma hareketlerinin motor hareket hayallerine ait sinyaller iki kategorili olarak sınıflandırılmıştır. Bu veri setinde değerlendirmeler yaşları 25-35 arasında değişen sekiz denek için yürütülmüştür. Performans ölçümü doğruluk ve Kappa metrikleri ile yapılmıştır. Çalışmada tüm frekans bantları ve zaman segmentleri kombinasyonlarına yarı olasılıksal dağılım modelleri uygulanmış ve tüm sınıflandırıcı çıktıları çoğunluk oylama ile birleştirilmiştir. Deneklerde %78,4% ile %86,25 arası maksimum doğruluklar ve 0,56 ile 0,73 arası maksimum Kappa değerleri elde edilmiştir. Tüm denekler boyunca ortalama $82 \pm 2,76$ sınıflandırma doğruluğu ve $0,65 \pm 0,06$ Kappa değeri elde etmiştir. Deneyler hakkında detaylı bilgi ve sonuçlar Yılmaz ve ark. (2025) tarafından yayınlanmıştır. MI-BMPI çalışma bünyesinde oluşturulan yeni bir veri seti olduğundan farklı çalışmalarda kullanılmamıştır. Tablo 1’de çeşitli mobil EEG cihazları ile farklı alanda yürütülen bazı çalışmalar verilmiştir. Fakhruzzaman ve ark., (2015) Emotiv EPOC’un motor hareket hayali görevleri için kullanılabilirliği üzerine yaptığı çalışmada el, ayak ve baş hareketlerini çeşitli senaryolarda sınıflandırmıştır. Sağ ayak hareketi için %91,67 doğruluk elde ederken eşzamanlı sol el hareketi ile baş sallama için başarı %13,33’e kadar düşmüştür. Permana ve ark. (2019) Neurosky Mindwave Mobile 2 ile kaydettikleri EEG sinyalleri ile tekerlekli sandalyeleri

kontrol eden bir BBA oluşturmuştur. Hareketsizlik durumu ile dört yöndeki hareketlerde %17,78 ile %82,22 arası başarı elde etmiştir. Saichoo ve ark. (2022) simüle tekerlekli sandalyelerin motor hareket hayali BBA paradigması ile kontrol edilebilirliğini ölçmüş, çeşitli sol/sağ motor hareket hayali paradigmaları için sonuçlar almıştır. Motor hareket hayalinde kullanıcı yeterliliğine göre önerilen uzuv hareket paradigması kullandığında ortalama %83,7 doğruluk ile en yüksek başarıyı elde edilmiştir. Al-Hamadani ve ark. bilgi toplama fonksiyonları temelli normalize edilmiş üç farklı ağ mimarisi kullanmıştır: yığın normalleştirilmiş evrişimsel sinir ağları (b-CNN), katman normalize uzun kısa süreli bellek (l-LSTM) ve hibrit tekrarlayan evrişimsel sinir ağları (R-CNN). Dört deneğin her biri için üç sınıflı motor hareket hayali problemlerini sınıflandırmaya çalışmış ve %67,28 ile 90,17 arası değişen sonuçlar almışlardır. Literatür çalışmalarında görüleceği üzere mobil cihazlarla alınan sonuçların çok geniş bir aralığa dağıldığı görülmektedir. Veri kaydının yeterli doğrulukta olmaması veya problemin zorluğuna göre başarı oldukça düşmektedir. Bu çalışmada verilen kayıt alım ve işleme prosedürleri ile oluşturulan sistem literatüre kıyasla oldukça tutarlı sonuçlar elde etmiştir. Elde edilen bulgular, mobil EEG cihazlarının araştırma ve uygulamalardaki potansiyelini güçlendirmekte ve sinyal kalitesi ile sınıflandırma başarısı arasında pozitif yönde bir ilişki olduğunu göstermektedir.

Tablo 1. Mobil EEG tabanlı bazı motor hareket hayali çalışmalarında elde edilen sınıflandırma doğrulukları

Fakhruzzaman ve ark. (2015)	Emotiv EPOC	- Sol el hareketi için %76,67 - Sağ ayak hareketi için %91,67 - Eşzamanlı sol el ve sağ el hareketi için %28,33 - Eşzamanlı sol el hareketi ve baş sallama için %13,33 - Eşzamanlı sağ ayak ve sol ayak hareketi için %60 - Eşzamanlı sağ ayak hareketi ve baş sallama için %76,67
Permana ve ark. (2019)	Neurosky Mindwave Mobile 2	- Varsayılan hareketsizlik için %82,22 - İleri hareket için %70 - Geri hareket için %73,33 - Sağa dönüş için %46,67 - Sola dönüş için %17,78
Saichoo ve ark. (2022)	Emotiv EPOC X	- Bilek hareketleri kullanıldığında %75,3 - Dirsek hareketleri kullanıldığında %80,6 - Ayak bileği hareketleri kullanıldığında %75,0 - Kullanıcı yeterliliğine dayalı uzuv hareketi paradigması ile %83,7
Al-Hamadani ve ark. (2023)	EMOTIV EPOC	- Sol el, sağ el ve eylemsizlik için b-CNN ile ortalama %80,46 - Sol el, sağ el ve eylemsizlik için l-LSTM ile ortalama %77,92 - Sol el, sağ el ve eylemsizlik için R-CNN ile ortalama %81,98
Yilmaz ve ark. (2025)	Emotiv Epoc Flex	Mobil telefonlarda tıklama ve kaydırma hareketleri için ortalama $\%82 \pm 2,76$

Duygular, çeşitli his, düşünce ve davranışlardan üretilen psikolojik durumlar dizisini ifade etmekle birlikte, insan iletişimde önemli bir rol oynar (He ve ark., 2020). Dahili ve harici aktivitelerle ilgili karmaşık bir psiko-fizyolojik süreç olan duygu, günlük yaşantımızda önemli bir yer tutar (Zheng ve ark., 2019). İnsan duygusunu anlamak için yüz ifadeleri, ses sinyalleri, mimik gibi dışsal etkenler yanında EEG gibi biyolojik sinyallerde kullanılır (Boehner ve ark., 2007). Duygu

tanıma çalışmalarında veri toplama sürecinin kolaylığı nedeniyle sıklıkla yüz görüntüleri tercih edilmektedir. Ancak geçici yüz hareketleri, ortam gürültüsü, aydınlatma değişiklikleri ve kafa hareketleri gibi faktörler performansı olumsuz etkiler. Kişinin yüz ifadesini kontrol edebilmesi nedeniyle oluşan denek bağımlılığı ise diğer bir problemidir. Yüz tabanlı sistemlerde denek müdahalesi gibi sınırlılıklar nedeniyle, EEG sinyalleri duygu tanımda tarafsız bir alternatif sunabilir.

İkinci çalışmada çok modlu KMED veri setinde komik, korkunç, tiksiniç ve rahatlama kategorilerindeki dört duygunun ikili kombinasyonları kendi aralarında sınıflandırılmıştır. Bu veri setinde değerlendirmeler yaşları 23-35 arasında değişen on dört denek için yürütülmüştür. Performans ölçümü doğruluk metrikleri ile yapılmıştır. Sadece yüz görüntüleri kullanıldığında düşük sonuçlar alınmıştır. Sadece EEG sinyalleri kullanıldığında sonuçlar ortalama %8 iyileşmiştir. Yüz görüntüleri ile EEG sinyalleri özellik seviyesinde birleştirildiğinde ise tüm deneklerde ortalama $89,95 \pm 3,87$ 'ye (iki sınıflı tiksiniç-rahatlama problemi için) kadar çıkan doğruluklar elde edilmiştir. Deneyler hakkında detaylı bilgi ve sonuçlar Hatipoglu Yılmaz ve ark. (2025) tarafından yayınlanmıştır. KMED çalışma bünyesinde oluşturulan yeni bir veri seti olduğundan farklı çalışmalarda kullanılmamıştır. Tablo 2'de çeşitli mobil EEG cihazları ile farklı alanda yürütülen bazı çalışmalar verilmiştir. Cruz-Vazquez ve ark. (2025) Emotiv Epoc+ ile oluşturdukları EEG veri setinde derin öğrenme teknikleri ile mutluluk, üzüntü ve nötr duyguları kendi aralarında tanımaya çalışmıştır. Duyguların ayrılabilirliğini iyileştirmek için Fourier sinir ağları ve kuantum döndürme gibi dönüşüm yöntemlerinin başarısı araştırılmıştır. Sınıflandırmada ise evrişimsel sinir ağları (convolutional neural network, CNN) ve yoğun sinir ağları (dense neural network, DNN) kullanılmıştır. Kuantum döndürmeler ile evrişimli sinir ağları birlikte kullanıldığında tüm duygu durumlarında %90 üzeri başarı elde edilmiştir. Tülay ve Bali (2024) EEG verilerinin olaya ilişkin potansiyel (ERP) bileşenlerinden faydalanarak pozitif, negatif ve nötr duygu durumlarını sınıflandırmayı amaçlamıştır. İlgisiz özellikler ileri öznitelik seçimi algoritması ile kaldırılmış ve sınıflandırma için doğrusal bir destek vektör makinesi kullanılmıştır. Acharya ve ark. (2020) çeşitli film kliplerine yapılan tepkilerini kullanarak duyguları gerçek zamanlı tespit etmeye çalışmıştır. EEG sinyalleri NeuroSky Mind Wave 2 ile kaydedilmiş, öznitelikler hızlı Fourier dönüşümü ile çıkarılmış ve sınıflandırma genetik programlama ile yapılmıştır. Vazquez ve ark. (2024) katılımcıların film videolarına verdikleri duygusal tepkilerden çıkardıkları öznitelikleri destek vektör makineleri (support vector machines), k-en yakın komşu algoritması (k-nearest neighbor algorithm), rastgele orman (random forest) ve yapay sinir ağları (artificial neural networks) gibi temel yaklaşımlarla sınıflandırmıştır. Literatürde, mobil cihazlarla duygu tanımda elde edilen sonuçların geniş bir aralıkta dağıldığı ve doğruluğun problemin zorluğuna bağlı değişmektedir. Bu çalışmada verilen kayıt alım ve işleme prosedürleri ile oluşturulan duygu tanıma sistemi literatüre kıyasla oldukça tutarlı sonuçlar göstermiştir.

Tablo 2. Mobil EEG tabanlı bazı duygu tanıma çalışmalarında elde edilen sınıflandırma doğrulukları

Cruz-Vazquez ve ark. (2025)	Emotiv Epoc+	- Fourier özellikleri + CNN ile mutluluk için %53; üzüntü için %100 ve nötr duygu için %59 - Kuantum döndürme + CNN ile mutluluk için %91; üzüntü için %99 ve nötr duygu için %97
Vazquez ve ark. (2024)	Emotiv Epoc+	Mutlu, üzgün ve nötr durumları için %79,09
Acharya ve ark. 2020	NeuroSky Mind Wave 2	Mutlu, sakin, korku ve üzüntü duygu durumları için ortalama %89,14
Tülay ve Balli, 2024	Brain Products	- Negatif ve nötr uyaranları tanımlamak için %70,16 - Negatif ve nötr uyaranları tanımlamak için %79,84 - Pozitif ve negatif uyaranları tanımlamak için %75,00 - Pozitif ve nötr uyaranları tanımlamak için %68,55
Hatipoglu Yilmaz ve ark. (2025)	Emotiv Epoc Flex	Komik, korkunç, tiksiniç ve rahatlama duygularının ikili kombinasyonları için %86,92±4,61 ile %89,95±3,87 arası doğruluk

Mobil EEG cihazları, sınırlı laboratuvar ortamına bağlı kalmadan, gerçek ortamlarda hareket halindeyken bile beyin sinyallerinin gerçek zamanlı kayıt ve analizine olanak tanır. Bu özellik, dış mekân aktiviteleri, sanal gerçeklik uygulamaları ve doğal koşullarda günlük yaşayış sırasındaki beyin aktivitelerini incelemek için değerlidir. Klinik ve mobil cihazlarla eş zamanlı yapılan çalışmalarda (Kutafina ve ark. 2020; Titgemeyer ve ark., 2020), mobil cihaz sinyallerinin klinik cihazlarla kaydedilen EEG sinyalleri ile uyum gösterdiği gözlenmiştir. Bu çalışmalar mobil EEG'nin güvenilir bir alternatif olabileceğini gösterir. Mobil cihazların klinik alternatiflerine kıyasla düşük maliyetleri, kolay kurulum ve kablolu bağlantı özellikleri ile gelecekte birçok araştırma alanında kullanılması beklenmektedir. Ayrıca, mobil sensör teknolojilerindeki gelişmeler tıbbi araştırmalara dahi yeni olanaklar sunmaktadır. Örneğin, mobil EEG cihazları epilepsi gibi nörolojik ve psikiyatrik bozuklukların düşük maliyetli taramasında potansiyel kullanım alanları doğurmaktadır (Kutafina ve ark., 2020). Deneysel çalışmalar, mobil EEG cihazlarının motor hareket hayali görevleri ve duygu tanıma uygulamalarında başarıyla kullanılabileceği gösterilmiştir. Motor hareket hayali görevlerinde elde edilen sinyaller, ilgili motor hareketlerin örüntülerini yüksek doğrulukla tespit etmiştir. Bu, BBA gibi uygulamaların geliştirilmesinde mobil EEG cihazlarının etkinliğini ortaya koymuştur. Ayrıca, duygu tanıma deneyleri, EEG sinyallerinin duygusal durumları ayırt etme kapasitesine sahip olduğunu göstermiştir. Bu bulgular hem mühendislik uygulamaları hem de nörolojik araştırmalar için mobil EEG cihazlarının değerini desteklemektedir. Bu çalışmada elde edilen bulgular, mobil EEG cihazlarının taşınabilirlik ve kullanım kolaylığı gibi avantajlarını göstermenin ötesinde, çeşitli uygulama örneklerinde başarı elde edebileceğini göstermektedir. Mobil cihazlarla çalışırken kafa derisi ile elektrotlar arasındaki iletkenlik seviyesinin sabit tutulmasının sinyal kalitesini etkileyen en önemli faktör olduğu gözlenmiştir. Bununla birlikte, mobil EEG cihazlarının sınırlı kanal sayısı ve nispeten düşük uzaysal çözünürlüğü gibi bazı dezavantajlarının olduğu da görülmüştür. Gelecekteki

çalıřmalarda mobil cihazlarla alınan sonuçların verimlilikleri ve genelleme yetenekleri irdelenmelidir. Tıbbi cihazlardaki gibi hassasiyet ve güvenilirlik standartlarını karřılamalıdırlar. Özellikle batarya ömrü veya kaliteli elektrot temasının uzun süre korunması konusunda arařtırmalar yapılmalıdır. Klinik alternatiflere göre daha konforlu kullanım saęlasa da kafa derisine sürekli temas gerektiren elektrotlara alternatif sensör teknolojileri geliştirilmelidir. Ancak, denek içi ve denekler arası deęiřkenliklerin detaylı incelenmesi, daha geniř örneklem gruplarıyla deneylerin tekrarlanması ve uzun vadeli kullanım senaryolarının deęerlendirilmesi, bu cihazların potansiyelinin tam anlamıyla ortaya çıkarılması için kritik öneme sahiptir. Çalıřmanın saęladığı tecrübe, mobil EEG cihazlarının kullanımında metodolojik bir rehber sunarak arařtırmalar için önemli bir temel oluřturmaktadır.

5. Sonuçlar ve Öneriler

Mobil EEG sistemleri, düşük kanal sayısı, farklı elektrot konumları ve örnekleme oranlarına raęmen klinik EEG sistemleriyle anlamlı düzeyde korelasyon göstermiştir. Bu sonuç, mobil EEG'nin özellikle saha çalıřmaları, ön tanı süreçleri ve kaynak kısıtlı ortamlarda güvenilir bir alternatif olarak deęerlendirilebileceğini ortaya koymaktadır. Yapılan deneysel çalıřmalar, bu sistemlerin motor hareket hayali ve duygu tanıma gibi görevlerde yüksek doęrulukla çalıřabildiğini göstermiştir. Bu bulgular, BBA uygulamaları ve nörolojik arařtırmalar açısından mobil EEG'nin etkinliğini ve uygulanabilirliğini desteklemektedir. Gelecekte, problemlere özgü mobil EEG cihazlarının tasarlanması EEG'nin farklı problemlerde kullanımda önemli katkılar saęlayacaktır. Örneğin, sanal gerçeklik uygulamaları için sanal gerçeklik başlıkları ile kullanılabilen mobil EEG cihazları tasarlanabilir. Artırılmış gerçeklik ve oyun teknolojileri gibi alanlarda mobil cihazlar oldukça yüksek katkı saęlayabilir. Bu nedenle, sanal gerçeklik ve artırılmış gerçeklik gibi teknolojilere entegre cihazların geliştirilmesi duygu tanıma gibi uygulamalarda ilerlemeler saęlayabilir.

Tasarlanacak mobil EEG cihazları düşük maliyetli, küçük boyutlu, kablosuz, sinyal iletim düzeyi uzun süre korunabilen, yüksek hassasiyetli, düşük güç tüketimli olmalıdır. Elektrot teknolojisindeki ilerlemeler sinyal iletim düzeyini artıracak yeni sensörlerin geliştirilmesini mümkün kılabilir. Batarya ömrünü uzatacak ve uzun süreli kullanımda sinyal kalitesini koruyacak teknolojiler geliştirilmelidir. Kullanıcılar arası deęiřkenliklerin etkilerini azaltmak için adaptif ve bireyselleřtirilmiş algoritmalar ile EEG cihazları tasarlanmalıdır. EEG cihazlarının tak-çalıřtır şeklinde çalıřması kullanıcı deneyimi açısından oldukça faydalı olacaktır. Karmařık kurulum süreçlerinin kolaylařtırılması ve kayıt için teknik bilgi ihtiyacının azaltılması, EEG cihazlarının daha erişilebilir ve verimli bir şekilde kullanılmasını saęlayacaktır. Bu özellikler, kullanıcıların cihazı kolayca baęlayıp sinyalleri hızlıca toplamasına olanak verir. Tak-çalıřtır sistemlerin en önemli faydalarından bir kısmı özellikle çeřitli hastalıkların tespit ve izlenmesinde ortaya çıkılacaktır.

Örneğin, beyin dalgaları sürekli izlenerek epileptik nöbetlerin önceden tespiti hastaların kendileri tarafından yapılabilir. Benzer şekilde, Alzheimer hastalığı, Parkinson hastalığı, demans, inme, psikiyatrik, gelişimsel ve nörogelişimsel bozukluklar ve uyku bozukluklarına kadar birçok olguda bu tarz ileri düzeydeki mobil EEG sistemleri önemli fayda ve kolaylıklar sağlayacaktır.

Teşekkür

Bu çalışma 119E397 nolu “EEG Temelli Beyin Bilgisayar Arayüzü Sistemlerine ait Motor Hareket Hayali Görevlerinin Sınıflandırılmasına Yönelik Örüntü Tanıma Yöntemlerin Geliştirilmesi” ve başlıklı TÜBİTAK 1002 Hızlı Destek Programı projesi tarafından desteklenerek edinilen EEG cihazı ve ilişkili çalışmaların katkısıyla gerçekleştirilmiştir. Duygu tanıma çalışmaları ise 121E002 nolu “Sinyal Görüntü Dönüşümü Yöntemi Yardımıyla Çok Yönlü Duygu Tanıma Sisteminin Geliştirilmesi” başlıklı TÜBİTAK 1002 Hızlı Destek Programı projesi kapsamında tamamlanmıştır. Verdikleri destek için TÜBİTAK'a teşekkür ederiz.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- Acharya, D., Billimoria, A., Srivastava, N., Goel, S., Bhardwaj, A. (2020). Emotion recognition using fourier transform and genetic programming. *Applied Acoustics*, 164, 107260. <https://doi.org/10.1016/j.apacoust.2020.107260>
- Al-Hamadani, A. A., Mohammed, M. J., Tariq, S. M. (2023). Normalized deep learning algorithms based information aggregation functions to classify motor imagery EEG signal. *Neural Computing and Applications*, 35(30), 22725-22736. <https://doi.org/10.1007/s00521-023-08944-9>
- Al-Saegh, A., Dawwd, S.A., Abdul-Jabbar, J.M. (2021). CutCat: An augmentation method for EEG classification. *Neural Networks*, 141: 433-443. <https://doi.org/10.1016/j.neunet.2021.05.032>

- Arad, E., Bartsch, R. P., Kantelhardt, J. W., Plotnik, M. (2018). Performance-based approach for movement artifact removal from electroencephalographic data recorded during locomotion. *PloS one*, 13(5), e0197153. <https://doi.org/10.1371/journal.pone.0197153>
- Arvaneh, M., Guan, C., Ang, K. K. et al. (2011). Optimizing the channel selection and classification accuracy in EEG-based BCI. *IEEE Transactions on Biomedical Engineering*, 58(6), 1865-1873. <https://doi.org/10.1109/TBME.2011.2131142>
- Biondi, A., Santoro, V., Viana, P. F., Laiou, P., Pal, D. K., Bruno, E., Richardson, M. P. (2022). Noninvasive mobile EEG as a tool for seizure monitoring and management: A systematic review. *Epilepsia*, 63(5), 1041-1063. <https://doi.org/10.1111/epi.17220>
- BioSemi Products. <https://www.biosemi.com/research.htm> (2025, Mart 25).
- Boehner, K., DePaula, R., Dourish, P., Sengers, P. (2007). How emotion is made and measured. *International Journal of Human-Computer Studies*, 65(4), 275-291. <https://doi.org/10.1016/j.ijhcs.2006.11.016>
- Brain Products Neurophysiology EEG Solutions. Available online: <https://www.brainproducts.com/solutions/> (2025, Mart 25).
- Brunner, C., Naeem, M., Leeb, R., Graimann, B., Pfurtscheller, G. (2007). Spatial filtering and selection of optimized components in four class motor imagery EEG data using independent components analysis. *Pattern Recognition Letters*, 28(8): 957-964. <https://doi.org/10.1016/j.patrec.2007.01.002>
- CGX EEG Headsets and Devices. <https://www.cgxsystems.com/products> (2025, Mart 25).
- Cruz-Vazquez, J. A., Montiel-Pérez, J. Y., Romero-Herrera, R., Rubio-Espino, E. (2025). Emotion recognition from EEG signals using advanced transformations and deep learning. *Mathematics*, 13(2), 254. <https://doi.org/10.3390/math13020254>
- Delorme, A. (2023). EEG is better left alone. *Scientific reports*, 13(1), 2372. <https://doi.org/10.1038/s41598-023-27528-0>
- Delorme, A., Makeig, S. (2004). EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. *Journal of neuroscience methods*, 134(1), 9-21. <https://doi.org/10.1016/j.jneumeth.2003.10.009>
- Doma, O.O. (2024). EEG as an Input for Virtual Reality. In: Lee, N. (eds) *Encyclopedia of Computer Graphics and Games*. Springer, Cham. https://doi.org/10.1007/978-3-031-23161-2_176
- EEGLAB. <https://scn.ucsd.edu/eeglab/index.php> (2025, Nisan 11).
- EEGLAB Plugins. https://scn.ucsd.edu/eeglab/plugin_uploader/plugin_list_all.php (2025, Nisan 11).
- Emotiv, Emotiv Brain Data Measuring Hardware and Software Solutions. <https://www.emotiv.com/> (2025, Mart 25).
- EmotivPRO. <https://emotiv.gitbook.io/system-requirements/emotivpro-v3.0> (2025, Ocak 02).
- EPOC Flex Cap. <https://www.emotiv.com/products/epoc-flex-cap> (2025, Ocak 02).
- EPOC Flex User Manual. <https://emotiv.gitbook.io/epoc-flex-user-manual> (2025, Ocak 02).
- Fakhruzzaman, M. N., Riksakomara, E., Suryotrisongko, H. (2015). EEG wave identification in human brain with Emotiv EPOC for motor imagery. *Procedia Computer Science*, 72, 269-276. <https://doi.org/10.1016/j.procs.2015.12.140>
- Flex 2 Saline - 32 Channel Wireless EEG Head Cap System. <https://www.emotiv.com/products/flex-saline> (2025, Ocak 02).
- Guger, C., Krausz, G., Allison, B. Z., Edlinger, G. (2012). Comparison of dry and gel based electrodes for P300 brain-computer interfaces. *Frontiers in neuroscience*, 6, 60. <https://doi.org/10.3389/fnins.2012.00060>
- Hatipoğlu Yılmaz, B., (2022). Sinyal Görüntü Dönüşümleri Yardımıyla Çok Modlu Duygu Tanıma Sisteminin Geliştirilmesi. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Hatipoğlu Yılmaz, B., Kose, C., Yılmaz, C. M. A novel multimodal EEG-image fusion approach for emotion recognition: introducing a multimodal KMED dataset. *Neural Comput & Applic* 37, 5187–5202 (2025). <https://doi.org/10.1007/s00521-024-10925-5>
- He Z, Li Z, Yang F, Wang L, Li J, Zhou C, Pan J. Advances in Multimodal Emotion Recognition Based on Brain-Computer Interfaces. *Brain Sciences*. 2020 Sep 29;10(10):687. <https://doi.org/10.3390/brainsci10100687>
- Hu, S., Lai, Y., Valdes-Sosa, P. A., Bringas-Vega, M. L., Yao, D. (2018). How do reference montage and electrodes setup affect the measured scalp EEG potentials?. *Journal of neural engineering*, 15(2), <https://www.doi.org/10.1088/1741-2552/aaa13f>

- Huang, G., Zhao, Z., Zhang, S. et al. (2023). Discrepancy between inter-and intra-subject variability in EEG-based motor imagery brain-computer interface: Evidence from multiple perspectives. *Frontiers in neuroscience*, 17, 1122661. <https://doi.org/10.3389/fnins.2023.1122661>
- Jain, A., Raja, R., Srivastava, S. et al. (2024). Analysis of EEG signals and data acquisition methods: a review. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 12 (1), 2304574. <https://doi.org/10.1080/21681163.2024.2304574>
- Jiang, X., Bian, G. B., Tian, Z. (2019). Removal of artifacts from EEG signals: a review. *Sensors*, 19(5), 987. <https://doi.org/10.3390/s19050987>
- Kancaoğlu, M., Kuntalp, M. (2024). Low-cost, mobile EEG hardware for SSVEP applications. *HardwareX*, 19, e00567. <https://doi.org/10.1016/j.ohx.2024.e00567>
- Kaveh, R., Schwendeman, C., Pu, L. et al. Wireless ear EEG to monitor drowsiness. *Nat Commun* 15, 6520 (2024). <https://doi.org/10.1038/s41467-024-48682-7>
- Kothe, C., The Artifact Subspace Reconstruction Method, <https://scn.ucsd.edu/githubwiki/files/asr-final-export.pdf> (2025, Nisan 24).
- Kucukler, O. F., Amira, A., Malekmohamadi, H. (2024). EEG channel selection using Gramian Angular Fields and spectrograms for energy data visualization. *Engineering Applications of Artificial Intelligence*, 133, 108305.
- Kutafina, E., Brenner, A., Titgemeyer, Y., Surges, R., Jonas, S. (2020). Comparison of mobile and clinical EEG sensors through resting state simultaneous data collection. *PeerJ*, 8, e8969. <https://doi.org/10.7717/peerj.8969>
- Li GL, Wu JT, Xia YH, He QG, Jin HG. Review of semi-dry electrodes for EEG recording. *J Neural Eng*. 2020 Oct 23;17(5):051004. doi: 10.1088/1741-2552/abbd50.
- Li, W., Ma, Y., Shao, K., Yi, Z. et. al. "The Human–Machine Interface Design Based on sEMG and Motor Imagery EEG for Lower Limb Exoskeleton Assistance System," in *IEEE Transactions on Instrumentation and Measurement*, vol. 73, pp. 1-14, 2024, Art no. 6502914, doi: 10.1109/TIM.2024.3375980
- Li, Y., Wang, P. T., Vaidya, M. P., Flint, R. D., Liu, C. Y., Slutzky, M. W., Do, A. H. (2021). Electromyogram (EMG) Removal by Adding Sources of EMG (ERASE)—A novel ICA-based algorithm for removing myoelectric artifacts from EEG. *Frontiers in neuroscience*, 14, 597941. <https://doi.org/10.3389/fnins.2020.597941>
- Mullen, T. R., Kothe, C. A., Chi, Y. M., Ojeda, A., Kerth, T., Makeig, S., Cauwenberghs, G. (2015). Real-time neuroimaging and cognitive monitoring using wearable dry EEG. *IEEE transactions on biomedical engineering*, 62(11), 2553-2567. <https://www.doi.org/10.1109/TBME.2015.2481482>
- Muse: the brain sensing headband. <https://choosemuse.com/> (2025, Mart 25).
- NeuroSky brainwave sensing headsets. <https://store.neurosky.com/> (2025, Mart 25).
- Newman, A. J., Neural Data Science, Averaging and Re-Referencing ERPs. https://neuraldatascience.io/7-eeeg/erp_avg_reref.html (2025, Mart 25).
- OpenBCI EEG Hardware and Software. <https://openbci.com/> (2025, Mart 25).
- OpenBCI-Datasets, Publicly Available EEG Datasets. <https://openbci.com/community/publicly-available-eeeg-datasets/> (2025, Nisan 04).
- Paszkziel, S., Rojek, R., Lei, N., Castro, M.A. (2021) A Pilot Study of Game Design in the Unity Environment as an Example of the Use of Neurogaming on the Basis of Brain–Computer Interface Technology to Improve Concentration. *NeuroSci*, 2, 109-119. <https://doi.org/10.3390/neurosci2020007>
- Permana, K., Wijaya, S. K., Prajitno, P. (2019, November). Controlled wheelchair based on brain computer interface using Neurosky Mindwave Mobile 2. In *AIP Conference Proceedings* (Vol. 2168, No. 1). AIP Publishing. <https://doi.org/10.1063/1.5132449>
- Pion-Tonachini, L., Kreutz-Delgado, K., Makeig, S. (2019). ICLabel: An automated electroencephalographic independent component classifier, dataset, and website. *NeuroImage*, 198, 181-197. <https://doi.org/10.1016/j.neuroimage.2019.05.026>
- Saichoo, T., Boonbrahm, P., Punsawad, Y. (2022). Investigating user proficiency of motor imagery for EEG-based BCI system to control simulated wheelchair. *Sensors*, 22(24), 9788. <https://doi.org/10.3390/s22249788>
- Sartipi, S. ve Cetin, M., "Subject-Independent Deep Architecture for EEG-Based Motor Imagery Classification," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 32, pp. 718-727, 2024. <https://www.doi.org/10.1109/TNSRE.2024.3360194>
- Shah AK, Mittal S. Invasive electroencephalography monitoring: Indications and presurgical planning. *Ann Indian Acad Neurol*. 2014 Mar;17(Suppl 1):S89-94. <https://www.doi.org/10.4103/0972-2327.128668>

- Shi, T. W., Chang, G. M., Qiang, J. F., Ren, L., Cui, W. H. (2023). Brain computer interface system based on monocular vision and motor imagery for UAV indoor space target searching. *Biomedical Signal Processing and Control*, 79, 104114.
- Soufineyestani, M.; Dowling, D.; Khan, A. Electroencephalography (EEG) Technology Applications and Available Devices. *Appl. Sci.* 2020, 10, 7453. <https://doi.org/10.3390/app10217453>
- Taherysayah, F., Malathouni, C., Liang, H. N., Westermann, C. (2024). Virtual reality and electroencephalography in architectural design: A systematic review of empirical studies. *Journal of Building Engineering*, 108611. <https://doi.org/10.1016/j.jobbe.2024.108611>
- Titgemeyer, Y., Surges, R., Altenmüller, D. M., Fauser, S., Kunze, A., Lanz, M. et al. (2020). Can commercially available wearable EEG devices be used for diagnostic purposes? An explorative pilot study. *Epilepsy & Behavior*, 103, 106507. <https://doi.org/10.1016/j.yebeh.2019.106507>
- Tülay, E. E., Balli, T. (2024). Decoding functional brain data for emotion recognition: a machine learning approach. *ACM Transactions on Applied Perception*, 21(3), 1-18. <https://doi.org/10.1145/3657638>
- Vazquez, J. A. C., Pérez, J. Y. M., Herrera, R. R. (2024, June). Emotion Recognition Through EEG Signals With Movie Clips Stimuli. In 2024 4th Interdisciplinary Conference on Electrics and Computer (INTCEC) (pp. 1-6). IEEE. <https://www.doi.org/10.1109/INTCEC61833.2024.10602937>
- Wang, Y., Zibrandtsen, I. C., Lazon, R. H. et al. (2023). Pitfalls in EEG analysis in patients with nonconvulsive status epilepticus: A preliminary study. *Clinical EEG and Neuroscience*, 54(3), 255-264. <https://doi.org/10.1177/15500594211050492>
- Weiergräber, M., Papazoglou, A., Broich, K., Müller, R. (2016). Sampling rate, signal bandwidth and related pitfalls in EEG analysis. *Journal of neuroscience methods*, 268, 53-55. <https://doi.org/10.1016/j.jneumeth.2016.05.010>
- Why Does Emotiv EPOC+ Stop At 43 Hz In Range? Is There A Way To Expand This Somehow? <https://www.emotiv.com/tools/knowledge-base/faq/emotiv-epoc-stop-at-43-hz-in-range> (2025, Ocak 02).
- William Tatum, D. O., Feyissa, A. M. et al., Technical Aspects of EEG. <https://www.medlink.com/articles/technical-aspects-of-eeeg> (2025, Mart 26).
- Williams, N. S., McArthur, G. M., de Wit, B., Ibrahim, G., Badcock, N. A. (2020). A validation of Emotiv EPOC Flex saline for EEG and ERP research. *PeerJ*, 8, e9713. <https://www.doi.org/10.7717/peerj.9713>
- Yang, K., Tong, L., Shu, J., Zhuang, N., Yan, B., Zeng, Y. (2020). High gamma band EEG closely related to emotion: evidence from functional network. *Frontiers in human neuroscience*, 14, 89, <https://www.doi.org/10.3389/fnhum.2020.00089>
- Yilmaz, C. M., (2021). Motor Hareket Hayali Görevlerine ait EEG Sinyallerinin 2-B Öznitelikler ve Yarı Olasılıksal Dağılım Modelleri ile Sınıflandırılması. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Yilmaz, C. M., Yilmaz, B. H., Kose, C. MI-BMPI motor imagery brain–mobile phone dataset and performance evaluation of voting ensembles utilizing QPDM. *Neural Comput & Applic* 37, 4679–4696 (2025). <https://doi.org/10.1007/s00521-024-10917-5>
- Yuan, H., Li, Y., Yang, J. et al. (2021). State of the art of non-invasive electrode materials for brain–computer interface. *Micromachines*, 12(12), 1521. <https://doi.org/10.3390/mi12121521>
- Zhang, X., Wang, Y., Tang, Y. et al. Adaptive filter of frequency bands based coordinate attention network for EEG-based motor imagery classification. *Health Inf Sci Syst* 12, 11 (2024). <https://doi.org/10.1007/s13755-024-00270-1>
- Zhao, G., Zhang, Y., Ge, Y. (2018). Frontal EEG asymmetry and middle line power difference in discrete emotions. *Frontiers in behavioral neuroscience*, 12, 225, <https://www.doi.org/10.3389/fnbeh.2018.00225>
- Zhao K, Zhang Z, Wen H, Scano A. Intra-Subject and Inter-Subject Movement Variability Quantified with Muscle Synergies in Upper-Limb Reaching Movements. *Biomimetics* (Basel). 2021 Oct 20;6(4):63. doi: 10.3390/biomimetics6040063. PMID: 34698082; PMCID: PMC8544238.
- Zheng WL, Liu W, Lu Y, Lu BL, Cichocki A. EmotionMeter: A Multimodal Framework for Recognizing Human Emotions. *IEEE Trans Cybern.* 2019 49 (3), 1110-1122, <https://www.doi.org/10.1109/TCYB.2018.2797176>
- Zheng, W. L., Lu, B. L. (2015). Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Transactions on autonomous mental development*, 7(3), 162-175., <https://www.doi.org/10.1109/TAMD.2015.2431497>