



TÜRKİYE CUMHURİYETİ  
MARMARA ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**BASKETBOL SERBEST ATIŞ PERFORMANSINDA  
ELEKTROFİZYOLOJİK ÖLÇÜMLEME TABANLI  
YAPAY ZEKA MODELİ**

RAMAZAN SEMİH TEKE  
YÜKSEK LİSANS TEZİ

DANIŞMAN  
PROF. DR. ADİL DENİZ DURU  
SPORDA BİLİŞİM TEKNOLOJİLERİ YÜKSEK LİSANS PROGRAMI

İSTANBUL – 2025



TÜRKİYE CUMHURİYETİ  
MARMARA ÜNİVERSİTESİ  
SAĞLIK BİLİMLERİ ENSTİTÜSÜ

**BASKETBOL SERBEST ATIŞ PERFORMANSINDA  
ELEKTROFİZYOLOJİK ÖLÇÜMLEME TABANLI  
YAPAY ZEKA MODELİ**

RAMAZAN SEMİH TEKE  
YÜKSEK LİSANS TEZİ

DANIŞMAN  
PROF. DR. ADİL DENİZ DURU  
SPORDA BİLİŞİM TEKNOLOJİLERİ YÜKSEK LİSANS PROGRAMI

İSTANBUL – 2025

## TEŞEKKÜR

Bu tezin her satırında, bana ilham olan, yol gösteren, düşerken kaldıran ve birlikte yürümeye cesaret veren insanların izleri var. Öncelikle, bu hikâyenin en başındaki kahramana, sevgili danışmanım Prof. Dr. Adil Deniz Duru'ya en derin şükranlarımı sunmak isterim. Bilgisi, tecrübesi, kararlılığı ve her daim motive eden duruşu sayesinde bu çalışma yalnızca akademik bir süreç değil, aynı zamanda kişisel bir dönüşüm yolculuğuna dönüştü. Aynı şekilde, uzmanlığı, yardımseverliği ve gösterdiği hassasiyetle bu yolculukta her daim yanımda olan sevgili eşi kıymetli hocam Dr. Öğr. Üyesi Dilek Göksel Duru'ya da içtenlikle teşekkür ederim.

Çalışmanın her aşamasında rehberliğiyle vizyon katan Prof. Dr. Emin Süel hocama; desteğini bir an bile esirgemeyen, sorunları çözümedeki pratikliği ve içten yaklaşımıyla sürece büyük katkılar sağlayan Dr. Öğr. Üyesi Recep Göçmen hocama; samimiyeti, desteği ve katkısıyla sevgili doktora öğrencisi arkadaşım Gamze Takmaz'a da teşekkür ederim. Ayrıca, katkıları ve katılımlarıyla çalışmanın temelini oluşturan Marmara Üniversitesi Beden Eğitimi ve Spor Bilimleri öğrencilerine, araştırmanın yürütülmesinde olanak sağlayan fakülte yönetimine ve tüm ilgili personele de şükran borçluyum.

Akademik teşekkürlerimi, yüksek lisans sürecimde hem akademik donanımı hem de hayata bakış açımı şekillendirmemde etkisi büyük olan, vizyon kazandıran dersleriyle hafızamda iz bırakan kıymetli hocam Prof. Dr. Haldun Akpınar ile tamamlamak isterim.

Bir büyük teşekkür de eğitim hayatımda önemli bir yeri olan çocukluk arkadaşım sevgili Mustafa Külcü'ye etmeden geçemem. Doğrudan ve dolaylı katkılarına da hayat boyu samimi dostluğuna da hep minnettarım.

Bugünlere gelmemde her zaman yanımda olan, hayatımın temeli olan annem Mariye Teke'ye; gurur kaynağım olan kardeşlerim Mehmet Furkan Teke ve Melike Teke'ye gönülden teşekkür ederim. Onların varlığı, her zaman güvendiğim bir liman oldu.

Hayat arkadaşım, sevgili eşim Büşra Teke'ye... En çok da sana teşekkür ederim. Yanımda oluşun, sabrın, sevgini eksik etmeyişin, en zorlu anlarda bile içimi ısıtan desteklerin olmasaydı, bu yol bu kadar anlamlı olmazdı. Minnetimi kelimelere sığdırmak zor.

Ve bu çalışmayı, hayatımda tanıdığım en güzel insan, çocukluk kahramanım, örnek aldığım değerli babam İbrahim Teke'ye adıyorum. Kalbimde daima senin ışığın var.

# İÇİNDEKİLER

<b>KISALTMALAR LİSTESİ</b> .....	<b>i</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>ii</b>
<b>TABLO LİSTESİ</b> .....	<b>iii</b>
<b>1. ÖZET</b> .....	<b>1</b>
<b>2. SUMMARY</b> .....	<b>2</b>
<b>3. GİRİŞ ve AMAÇ</b> .....	<b>3</b>
<b>4. GENEL BİLGİLER</b> .....	<b>6</b>
4.1. Serbest Atışın Sportif Önemi .....	6
4.2. EEG ve Spor Performansı .....	9
4.3. Serbest Atış ve EEG .....	13
4.4. EEG Verilerinin Makine Öğrenmesi ile Analizi .....	16
4.4.1. Destek vektör makineleri (SVM).....	16
4.4.2. K-En yakın komşu (k-NN) .....	16
4.4.3. Ensembl ağaç yöntemleri (Bagged ve Boosted Trees) .....	17
4.4.4. Yapay sinir ağları (ANN) .....	17
4.4.5. Konvolüsyonel sinir ağları (CNN).....	17
4.4.6. Uzun kısa süreli bellek (LSTM) .....	17
<b>5. GEREÇ ve YÖNTEM</b> .....	<b>20</b>
5.1. Araştırma Tasarımı.....	20
5.2. Katılımcılar.....	20
5.3. EEG Kayıt Sistemi ve Kurulumu .....	21
5.4. Deneysel Protokol .....	22
5.5. EEG Veri İşleme ve Özellik Çıkartımı.....	23
5.6. İstatistiksel Analiz .....	23
5.7. Makine Öğrenmesi Uygulamaları .....	24
5.8. Yöntemsel Güç ve Literatürel Dayanak .....	25
<b>6. BULGULAR</b> .....	<b>26</b>
6.1. Başarılı Serbest Atışların Pre-Post EEG Özellikleri .....	26
6.2. Başarılı Atışların Makine Öğrenmesi İle Sınıflandırılması .....	27

6.3. Başarısız Atışların EEG Özellikleri .....	29
6.4. Başarısız Atışların Makine Öğrenmesi İle Sınıflandırılması .....	30
6.5. Başarılı Ve Başarısız Atışların Atış Öncesi EEG Özellikleri .....	31
6.6. Başarılı Ve Başarısız Atışların Makine Öğrenmesi İle Sınıflandırılması .....	32
6.7. ROC Eğrisi Değerlendirmeleri.....	33
<b>7. TARTIŞMA VE SONUÇ .....</b>	<b>35</b>
<b>8. KAYNAKLAR .....</b>	<b>41</b>
<b>9. ÖZGEÇMİŞ .....</b>	<b>46</b>
<b>10. BİLİMSEL FAALİYETLER.....</b>	<b>46</b>
<b>11. EKLER.....</b>	<b>48</b>
11.1. Etik Kurul Onayı .....	48

## KISALTMALAR LİSTESİ

AI	: Yapay Zekâ (Artificial Intelligence)
AUC	: ROC Eğrisi Altındaki Alan (Area Under the Curve)
BH-FDR	: Benjamini-Hochberg Yanlı Pozitiflik Düzeltmesi (Benjamini-Hochberg False Discovery Rate)
CNN	: Evrimsel Evrişimsel Sinir Ağı (Convolutional Neural Network)
EEG	: Elektroensefalografi (Electroencephalography)
EMG	: Elektromiyografi (Electromyography)
ERP	: Olay İlişkili Potansiyeller (Event-Related Potentials)
F1	: Harmonik Ortalama Performans Skoru (F1 Score)
FFT	: Hızlı Fourier Dönüşümü (Fast Fourier Transform)
FN	: Yanlış Negatif (False Negative)
FP	: Yanlış Pozitif (False Positive)
Hz	: Hertz (Saniyede Titreşim Sayısı)
ICA	: Bağımsız Bileşen Analizi (Independent Component Analysis)
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
ML	: Makine Öğrenmesi (Machine Learning)
PSD	: Güç Spektral Yoğunluğu (Power Spectral Density)
PSS	: Algılanan Stres Ölçeği (Perceived Stress Scale)
ROC	: Alıcı İşlem Karakteristiği Eğrisi (Receiver Operating Characteristic Curve)
SD	: Standart Sapma (Standard Deviation)
SVM	: Destek Vektör Makineleri (Support Vector Machines)
T-Testi	: Örneklem Ortalamaları Karşılaştırma Testi (Student's t-test)
TN	: Doğru Negatif (True Negative)
TP	: Doğru Pozitif (True Pozitif)

## ŞEKİL LİSTESİ

### Sayfa Numarası

Şekil 1.	James Naismith, basketbolun mucidi.....	6
Şekil 2.	FIBA resmi basketbol sahası.....	7
Şekil 3.	Serbest atış çizgisi kort ölçüleri.....	8
Şekil 4.	Kafa derisi üzerindeki 16 kanallı elektrot dağılımı .....	10
Şekil 5.	Bir katılımcının serbest atış öncesi elektrotların yerleşimi.....	11
Şekil 6.	Atış görevini gerçekleştirirken kaydedilen örnek bir EEG verisi.....	12
Şekil 7.	EEG kayıt aşaması görüntüsü.....	22
Şekil 8.	Başarılı atışların ROC eğrisi,.....	33
Şekil 9.	Başarısız atışların ROC eğrisi.....	33
Şekil 10.	Başarılı atışların atış öncesi ve sonrası ROC eğrisi.....	34

## TABLO LİSTESİ

	<b>Sayfa Numarası</b>
<b>Tablo 1.</b> Katılımcı bilgileri .....	21
<b>Tablo 2.</b> Başarılı atışların pre-post istatistiksel özellikleri.....	26
<b>Tablo 3.</b> Başarısız atışların konfüzyon matrisi.....	28
<b>Tablo 4.</b> Başarılı atışların sınıflandırılması.....	28
<b>Tablo 5.</b> Başarısız atışların pre-post istatistiksel özellikleri.....	29
<b>Tablo 6.</b> Başarısız atışların konfüzyon matrisi.....	30
<b>Tablo 7.</b> Başarısız atışların sınıflandırılması.....	30
<b>Tablo 8.</b> Başarılı ve başarısız atışların sınıflandırılması.....	31
<b>Tablo 9.</b> Başarılı ve başarısız atışların sınıflandırılması.....	32

## 1. ÖZET

**Tezin başlığı :** Basketbol Serbest Atış Performansında Elektrofizyolojik Ölçümlere Tabanlı Yapay Zekâ Modeli

**Öğrencinin Adı Soyadı :** Ramazan Semih TEKE

**Danışmanın Adı Soyadı :** Prof. Dr. Adil Deniz DURU

**Programın Adı :** Sporda Bilişim Teknolojileri Yüksek Lisans Programı

**Amaç:** Bu çalışma, basketbolda serbest atış performansı sırasında ortaya çıkan beyin elektriksel aktivite örüntülerini analiz ederek, atışın başarılı mı yoksa başarısız mı olacağını tahmin edebilecek bir yapay zekâ modeli geliştirmeyi amaçlamaktadır. EEG sinyalleri ile dikkat ve motor hazırlık süreçleri arasındaki ilişki değerlendirilmiş; bu verilerden elde edilen özelliklerin sınıflandırma algoritmaları ile yorumlanabilirliği incelenmiştir. Ayrıca çalışma, serbest atış gibi durağan ancak psikolojik olarak yüksek baskı içeren spor anlarında kortikal aktivite örüntülerinin performans üzerindeki etkisini daha bütüncül bir yaklaşımla ortaya koymayı hedeflemektedir.

**Gereç ve Yöntem:** Araştırmaya, 20–34 yaş aralığında ve en az 8 yıllık basketbol deneyimine sahip sekiz elit sporcu katılmıştır. Katılımcılar, ısınma sonrası serbest atışlar yaparken, 16 kanallı EEG cihazı ile kayıt alınmıştır. Veriler, atış öncesi ve sonrası dönemlere göre epoklanmıştır; delta, theta, alfa ve beta bantlarında güç spektrumu hesaplanmıştır. Özellikler, ilgili beyin bölgelerine göre sınıflandırılmış ve istatistiksel analizlerde eşleştirilmiş t-testi ile FDR düzeltilmesi uygulanmıştır. Makine öğrenmesi algoritmaları (SVM, KNN, NN vb.) ile 5 katlı çapraz doğrulama kullanılarak sınıflandırma yapılmıştır.

**Bulgular:** EEG bant gücü analizleri, özellikle santral ve paryeto-okspital bölgelerde pre-post farkların anlamlı olduğunu göstermiştir ( $p < 0,05$ ). Başarılı atış öncesinde theta ve delta gücü artarken, alfa ve beta azalmıştır. En yüksek sınıflandırma doğruluğu %74,9 ile İnce Gaussian SVM modelinde elde edilmiştir. Sadece atış öncesi EEG verileri kullanıldığında doğruluk %55'in altında kalmıştır.

**Sonuç:** EEG tabanlı veriler, motor hazırlık ve dikkat süreçlerini değerlendirmede önemli biyobelirteçler sunmaktadır. Bu çalışma, EEG sinyallerinin yapay zekâ uygulamalarıyla spor performans analizinde kullanılabilirliğini göstermekte; ancak atış başarısının öngörülmesinde daha gelişmiş yöntemlere ihtiyaç olduğunu da ortaya koymaktadır.

**Anahtar Kelimeler:** Basketbol, elektroensefalografi (EEG), nörofizyolojik analiz, yapay zekâ, serbest atış

## 2. SUMMARY

**Title of Thesis:** Electrophysiological Data-Driven Artificial Intelligence Modeling for Basketball Free Throw Performance

**Student Name, Surname:** Ramazan Semih TEKE

**Supervisor Name :** Prof. Dr. Adil Deniz DURU

**Program Name :** Information Technologies in Sports Master of Science Program

**Objective:** This study explores the neural basis of basketball free throw performance by analyzing EEG data recorded during shot execution, aiming to identify brainwave patterns linked to successful and unsuccessful attempts. It further contributes to neuroperformance research by developing machine learning models that integrate cognitive and motor markers to classify shot outcomes. Additionally, this study aims to provide a more comprehensive understanding of how cortical activity patterns influence athletic performance during static yet psychologically high-pressure moments, such as basketball free throws.

**Materials and Methods:** Eight experienced male athletes (ages 20–34) participated voluntarily. EEG was recorded using a 16-channel BrainProducts V-Amp system during self-paced free throws. Signals were segmented into pre- and post-shot phases, and spectral power was calculated for delta, theta, alpha, and beta bands. Features were statistically tested (paired t-test, FDR correction) and used to train machine learning models (SVM, KNN, neural networks) with 5-fold cross-validation.

**Results:** Significant EEG spectral changes were observed in sensorimotor regions, particularly mu rhythm desynchronization before successful shots. The highest classification accuracy (74.9%) in distinguishing pre- vs. post-shot phases was achieved with Fine Gaussian SVM. However, attempts to classify shot success based solely on pre-shot EEG data yielded accuracies below 55%, indicating limited predictive power from EEG alone.

**Conclusion:** EEG signals reflect cognitive and motor readiness during free throws and can be used to model temporal dynamics of performance. While neural features aid in distinguishing motor states, further improvement in outcome prediction requires advanced signal integration. This research supports the application of brain-based analytics in sports performance and training development.

**Keywords:** Basketball, electroencephalography (EEG), neurophysiological analysis, artificial intelligence, free throw

### 3. GİRİŞ ve AMAÇ

Basketbol, yüksek düzeyde fiziksel yeterlilik kadar bilişsel esneklik, hızlı karar verme ve ileri düzey motor koordinasyon becerilerini de gerektiren çok boyutlu bir takım sporudur. Bu dinamik yapısı hem bireysel hem de takım performansını eş zamanlı olarak test eden karmaşık bir yapıya sahiptir. Basketbol oyununda yer alan ve oyunun akışında önemli kırılma noktaları oluşturan serbest atışlar, yalnızca teknik beceri değil, aynı zamanda psikolojik dayanıklılık, zihinsel hazırlık ve dikkat sürekliliği gibi zihinsel süreçleri de içeren özel bir performans bileşeni olarak kabul edilmektedir. Serbest atışlar, oyunun seyri içerisinde savunma müdahalesi olmaksızın gerçekleştirilen nadir pozisyonlardandır ve çoğu zaman maçın sonucunu belirleyebilecek kadar kritik bir öneme sahiptir. Bu nedenle serbest atış başarısı, yalnızca bireysel teknik yeterliliğin değil; aynı zamanda zihinsel istikrarın ve dikkat regülasyonunun da bir yansıması olarak değerlendirilmelidir (Chuang ve ark., 2013; Su & Yang, 2018).

Literatürde serbest atış sırasında dikkat, bilişsel kontrol ve motor hazırlık süreçlerinin birlikte çalışmasının, atışın sonucunu doğrudan etkileyen faktörler arasında yer aldığı ortaya konmuştur. Özellikle frontal korteksin dikkat ve planlama süreçlerine katkısı, prefrontal EEG ölçümleri ile desteklenmiştir. Bu süreçte, oyuncuların zihinsel hazırlık durumları, algısal odaklanma düzeyleri ve otomatikleşmiş motor yanıtlarının kortikal temsil biçimi performans üzerinde belirleyici olmaktadır. Serbest atış gibi durağan ancak yüksek baskı altında gerçekleştirilen motor eylemler, klasik motor görevlerden farklı olarak daha fazla bilişsel kaynak kullanımı gerektirebilmektedir. Bu nedenle, bu tür görevlerin nörofizyolojik temellerinin anlaşılması, sportif performansın ölçülmesi ve iyileştirilmesi açısından büyük önem taşımaktadır.

Son yıllarda spor bilimlerinde yalnızca biomekanik ve performansa dayalı ölçütlerle değil, aynı zamanda bilişsel ve sinirsel göstergelerle de değerlendirme yapılmasına olan ilgi artmıştır. EEG (elektroensefalografi) bu noktada, beyin aktivitesinin anlık değişimlerini yüksek zaman çözünürlüğü ile kaydedebilen non-invaziv bir teknik olarak ön plana çıkmaktadır. Özellikle delta (0–4 Hz), theta (4–8 Hz), alfa (8–13 Hz) ve beta (13–30 Hz) frekans bantlarında ölçülen EEG dalga örüntüleri, bireylerin zihinsel durumları, dikkat odakları ve motor hazırlık seviyeleri hakkında önemli bilgiler sunmaktadır. Araştırmalar, başarılı serbest atışlar öncesinde frontal bölgelerde artan theta aktivitesinin dikkat regülasyonu ile ilişkili olduğunu, santral bölgelerdeki mu ritmi desenkronizasyonunun ise motor hazırlıkla doğrudan ilişkili olduğunu ortaya koymuştur (Chuang ve ark., 2013).

Bu bağlamda EEG verilerinin sadece betimleyici olarak değil, aynı zamanda tahmine dayalı analizlerde de kullanılması, performans bilimlerinde devrim niteliğinde bir dönüşüm yaratmıştır. Özellikle yapay zekâ ve makine öğrenmesi algoritmaları, zaman serisi niteliğindeki EEG sinyallerinden anlamlı örüntüleri çıkarmada yüksek başarı göstermektedir. SVM (Support Vector Machines), k-NN (k-En Yakın Komşu), yapay sinir ağları (ANN), CNN (Convolutional Neural Networks) ve Boosted Trees gibi algoritmalar, EEG verileri ile spor performansını sınıflandırma, tahmin etme ve bireysel modellemeler geliştirme konularında literatürde geniş şekilde kullanılmaktadır (Minami ve ark., 2024; Ibáñez-Redin ve ark., 2023). Bununla birlikte, EEG verileri ile doğrudan sportif sonuç tahminine dair çalışmalar halen sınırlı sayıdadır. Bu da, serbest atış gibi spesifik motor görevlerde EEG verilerine dayalı makine öğrenmesi modellerinin geliştirilmesi ihtiyacını ortaya koymaktadır.

Bu çalışmanın temel amacı, EEG sinyallerinden elde edilen özellikler ile basketbol oyuncularının serbest atışlardaki başarı ya da başarısızlık durumlarını sınıflandırabilecek bir makine öğrenmesi modeli geliştirmektir. Çalışma, EEG verilerinden delta, theta, alfa ve beta bantlarında elde edilen güç spektrumları ile oluşturulan özellik setlerinin, başarılı ve başarısız atışların pre ve post dönemlerini sınıflandırmada kullanılıp kullanılmayacağını araştırmaktadır. Ayrıca, her bir frekans bandı ve kortikal bölge düzeyinde elde edilen örüntülerin istatistiksel olarak anlamlı olup olmadıkları da test edilmiştir. Çalışma kapsamında, 16 kanallı EEG cihazı kullanılarak elde edilen sinyaller, artefakt temizliği ve bant gücü hesaplamalarından sonra makine öğrenmesi algoritmalarıyla modellenmiştir.

Bu bağlamda araştırmanın özgün katkıları şu şekilde özetlenebilir:

- Serbest atış gibi sınırlı süreli ve tekrar edilebilir motor görevlerde EEG örüntülerinin sistematik olarak analiz edilmesi,
- Başarılı ve başarısız atışların hem atış öncesi hem de sonrası EEG örüntüleri üzerinden karşılaştırmalı analiz yapılması,
- Elde edilen EEG sinyallerinden anlamlı özellikler çıkarılarak bu özelliklerin makine öğrenmesi ile sınıflandırılması,
- EEG temelli verilerle bireysel performansın nörobiyolojik temellerinin ortaya konması,
- Nörofizyolojik ölçümler ile spor eğitimi, performans analizi ve antrenman programlarının kişiselleştirilmesine katkı sağlanması.

Sonuç olarak, bu çalışmanın amacı yalnızca EEG ile serbest atış başarısını tahmin etmek değil; aynı zamanda bu başarının arkasındaki kortikal dinamikleri ortaya çıkarmak ve bu veriler

aracılıđıyla gelecekteki performans analizlerinin daha bütüncül bir çerçevede yapılmasına katkıda bulunmaktır. Geliştirilen modeller, hem akademik alanda literatürün genişlemesine katkı sağlayacak, hem de saha uygulamaları açısından nöro-bilişsel tabanlı sporcu destek sistemlerinin geliştirilmesinde bir temel oluşturacaktır.

## 4. GENEL BİLGİLER

### 4.1. Serbest Atışın Sportif Önemi

Basketbol, 1891 yılında James Naismith tarafından Amerika Birleşik Devletleri'nde icat edilmiş olup, günümüzde dünya genelinde en çok takip edilen ve sevilen spor dallarından biridir. Oyunun temel hedefi, rakip takımın potasına basket atarak mümkün olduğunca çok sayı elde etmek şeklinde tanımlanabilir. Basketbolun dinamik yapısı, oyuncuların üst düzey fiziksel kondisyon, zihinsel çeviklik, hızlı karar verme ve takım koordinasyonu gibi birçok farklı yetenek gerektirmektedir (International Basketball Federation [FIBA], 2022).



**Şekil 1.** 1891 yılında Springfield, Massachusetts'te çekilen bu kare, James Naismith'i, basketbolun mucidi, elinde ilk basketbol topu ve oyunun ilk potası olarak kullanılan şeftali sepetiyle birlikte göstermektedir. ([1] [https://upload.wikimedia.org/wikipedia/commons/4/4a/Dr.\\_James\\_Naismith.jpg](https://upload.wikimedia.org/wikipedia/commons/4/4a/Dr._James_Naismith.jpg)).

Basketboldaki sayı üretme yöntemlerinden biri olan serbest atış, genellikle oyun sırasında gerçekleştirilen fauller sonrasında rakip takımın müdahalesi olmaksızın atış hakkı tanıyan kritik bir oyun unsurudur. Serbest atışın oyun kurallarına eklenmesi, 1894 yılına dayanmaktadır. Başlangıçta orta sahadan gerçekleştirilen serbest atışlar, 20. yüzyılın başlarında bugünkü






serbest atış süreci, rutin oluşturma, zihinsel hazırlık ve baskı altında etkin karar verme gibi psikolojik bileşenleri içeren özel bir performans alanıdır.

Bu nedenle serbest atış pratiği, profesyonel basketbol takımlarının antrenmanlarında önemli bir yer tutmaktadır. Antrenmanların sonlarına doğru, oyunculara genellikle "yorgunluk altında serbest atış" egzersizleri yaptırılır. Böylece oyuncuların hem motor koordinasyon hem de mental dayanıklılık becerileri eşzamanlı olarak geliştirilir. Son yıllarda, yapay zekâ ve EEG gibi nörobilimsel ve biyoteknolojik yöntemlerin gelişimi sayesinde, serbest atış esnasında beyin aktivitesi ölçülerek oyuncuların motor hazırlık süreçleri detaylı şekilde incelenebilmektedir (Chuang ve ark., 2013; Keshvari ve ark., 2023).

Serbest atışın bir diğer önemli yönü, oyuncuların özgüven gelişimine katkıda bulunmasıdır. Başarıyla gerçekleştirilen serbest atışlar, sporcuların kendilerine olan güvenlerini artırırken, olumsuz sonuçlanan denemeler ise uzun vadede oyuncunun performansında psikolojik dalgalanmalara yol açabilir. Bu bağlamda, serbest atış antrenmanları, genç sporcular için temel motor becerilerin geliştirilmesi ve zihinsel sağlamlığın güçlendirilmesi açısından kritik öneme sahiptir. Sonuç olarak serbest atış, basketbol oyununun önemli bir stratejik unsuru olmanın ötesinde, bireysel ve takım performansının çok yönlü değerlendirilmesini sağlayan temel bir performans göstergesidir. Fiziksel yeterliliklerin yanında psikolojik dayanıklılık ve konsantrasyon gibi zihinsel faktörlerin de öne çıktığı bu özel oyun bileşeni, spor bilimi alanındaki araştırmaların ve uygulamaların merkezinde yer almaktadır. EEG, yapay zekâ ve ileri veri analitiği yöntemlerinin entegrasyonu, serbest atış performansının bilimsel olarak daha etkin şekilde değerlendirilmesini ve geliştirilmesini mümkün kılmaktadır.

#### **4.2.EEG ve Spor Performansı**

Elektroensefalografi (EEG), beyindeki elektriksel aktivitenin zaman içinde değişimini non-invaziv olarak ölçmeye imkân tanıyan nörofizyolojik bir yöntemdir. EEG, beyindeki nöron gruplarının senkronize aktivitesinden kaynaklanan elektriksel dalgalanmaları mikrovolt ( $\mu\text{V}$ ) düzeyinde kaydeder. Başlıca avantajlarından biri olan yüksek zaman çözünürlüğü sayesinde, özellikle sporcularda motor eylemler öncesi ve sırasında ortaya çıkan bilişsel süreçlerin ayrıntılı olarak izlenmesini mümkün kılar. EEG ölçümü sırasında kullanılan elektrotlar, Uluslararası 10-20 sistemi olarak bilinen standart bir yöntemle göre kafa derisine yerleştirilir. Bu yöntem, elektrotların doğru anatomik konumlarda sabitlenmesini sağlayarak, beynin spesifik bölgelerindeki aktivitenin güvenilir şekilde ölçülmesini mümkün hale getirir (Neuper & Pfurtscheller, 2001).

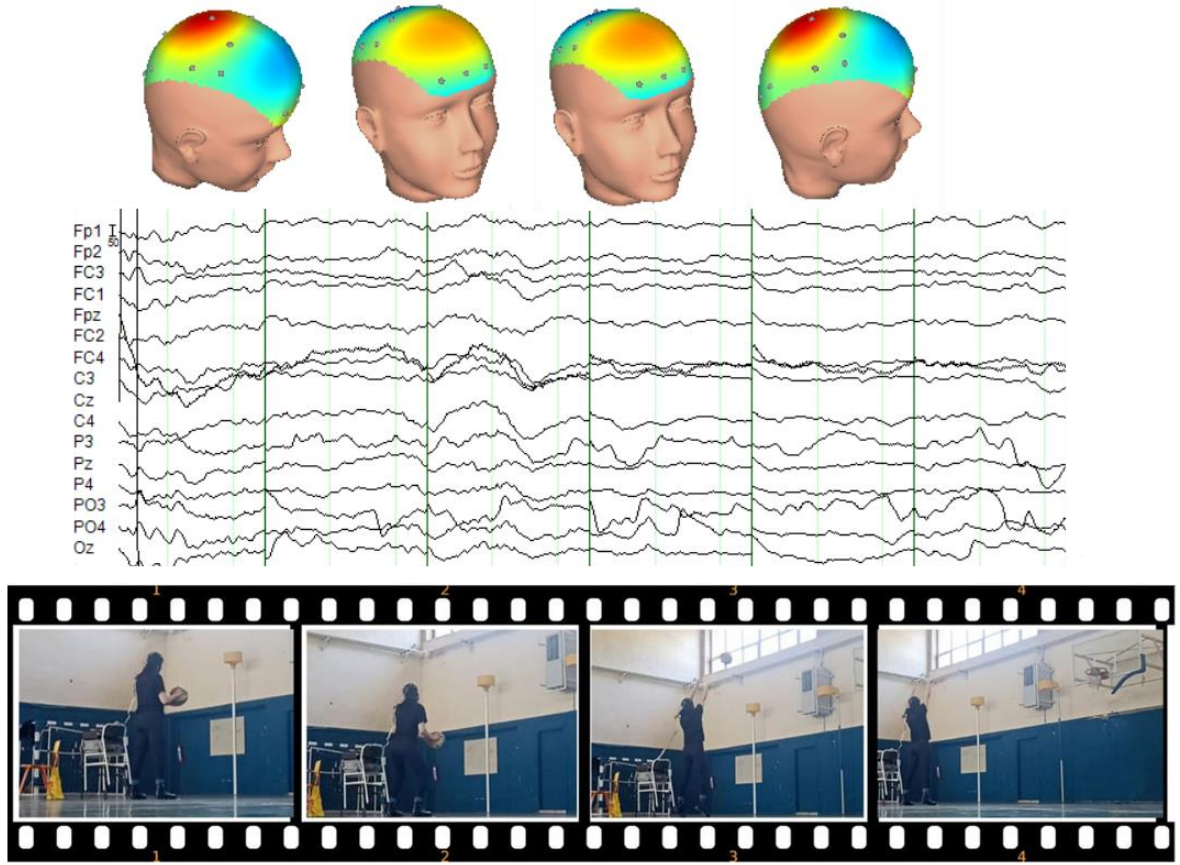


**Şekil 4.** Kafa derisi üzerindeki 16 kanallı elektrot dağılımı. Kaynak : Teke, R. S., Takmaz, G., Göçmen, R., Göksel Duru, D., Süel, E., & Duru, A. D. (2025). Analysis of Brain Electrical Signals During the Execution of Basketball Free Throws: A Machine Learning Approach. [Research in Sports Science], yayına kabul edildi.



**Şekil 5.** Bir katılımcının serbest atış öncesi elektrotların yerleşimi

EEG sinyallerinin ölçülmesinde kullanılan cihazlar genellikle yüksek hassasiyetli amplifikatörlerle çalışmakta ve kaydedilen veriler bilgisayar ortamında dijital olarak işlenmektedir. EEG sinyallerinin analizi genellikle zaman serisi (time-series) formatında olup, analiz sürecinde sinyallerin frekans spektrumları incelenir. Frekans analizi genellikle Fourier Dönüşümü (Fast Fourier Transform - FFT) veya Kısa Süreli Fourier Dönüşümü (Short Time Fourier Transform - STFT) gibi yöntemlerle gerçekleştirilir. Bu yöntemler EEG verilerini farklı frekans bantlarına ayrıştırarak spor performansı ve bilişsel süreçlerle ilişkili belirli aktivasyonları ortaya çıkarmayı amaçlar.



**Şekil 6.** Bir katılımcının serbest atış görevini gerçekleştirirken kaydedilen örnek bir EEG verisi. İlk satırda, belirli zaman aralıklarına karşılık gelen (-2 ila -1 s, -1 ila 0 s, 0 ila 1 s ve 1 ila 2 s) kafa derisi topografyaları gösterilmektedir. İkinci satırda çok kanallı EEG verileri, üçüncü satırda ise atış hareketinin fazları sunulmaktadır.

EEG frekans bantlarının ve spor performansı ile ilişkilerinin detayları şöyledir:

- Delta (0–4 Hz): Genellikle derin uyku ve bilinçaltı süreçlerle ilişkilendirilen delta dalgaları, dikkat ve konsantrasyon gerektiren görevler sırasında frontal bölgelerde artış gösterebilir. Özellikle yüksek bilişsel yük altında, odaklanmanın sürdürüldüğü durumlarda delta aktivitesinde belirgin değişiklikler gözlenmiştir (Harmony, 2013).
- Theta (4–8 Hz): Frontal orta hat theta aktivitesi, dikkat kontrolü ve çalışma belleği süreçleriyle güçlü biçimde ilişkilidir. Başarılı motor görevlerde, özellikle serbest atış gibi yüksek dikkat gerektiren durumlarda theta aktivitesinin arttığı görülür. Bu artış, dikkat ve zihinsel odaklanmanın nörofizyolojik bir işareti olarak kabul edilir (Cavanagh & Frank, 2014).
- Alpha (8–13 Hz): Alfa dalgaları genellikle dinlenme veya gözlerin kapalı olduğu durumlarda yüksek güç gösterir. Dikkat gerektiren motor görevler sırasında alfa aktivitesi baskılanır ve bu duruma alfa blokajı adı verilir. Alfa blokajı, zihinsel odaklanmanın önemli bir göstergesi olarak değerlendirilir (Babiloni ve ark., 2008).

- Beta (13–30 Hz): Beta dalgaları motor hazırlık, hareket planlama ve yürütme süreçleriyle doğrudan ilişkilidir. Özellikle sensorimotor kortekste görev odaklı değişimler gösterirler. Motor eylemlerin öncesinde ve sırasında beta dalgalarının yoğunluğunda artış veya azalış, motor korteksin aktivasyon seviyesini ve hareketin doğruluğunu etkiler (Pfurtscheller & Lopes da Silva, 1999).

EEG sinyallerinin analizinde sıklıkla kullanılan yöntemlerden biri Güç Spektral Yoğunluğu (Power Spectral Density - PSD) analizidir. PSD, EEG sinyalinin belirli bir frekans bandında içerdiği enerjiyi belirlemek için kullanılır ve (1) numaralı formül ile hesaplanır:

$$PSD(f) = |X(f)|^2 / T \quad (1)$$

Burada  $X(f)$ , sinyalin Fourier dönüşümüdür ve  $T$  kayıt süresini temsil eder. Bu analiz sayesinde, EEG'nin farklı frekans bantlarında meydana gelen aktivitenin miktarı belirlenebilir ve bu da zihinsel durum ve motor performans ile ilişkilendirilebilir.

Basketbol serbest atışı sırasında EEG ölçümü yapılırken, oyuncuların kafa derisine sabitlenen elektrotlar kullanılır ve mümkün olduğunca hareket ve kas artefaktlarından arındırılmış veri kaydı amaçlanır. EEG verileri, oyuncunun atışı gerçekleştirdiği sırada göz kırpması, kas kasılması ve baş hareketleri gibi hareket artefaktlarından temizlenir. Bu temizleme işlemi genellikle Bağımsız Bileşen Analizi (Independent Component Analysis - ICA) gibi yöntemlerle gerçekleştirilir. Temizlenen veriler, genellikle atıştan önceki ve sonraki -1 ile +1 saniyelik epoklar şeklinde ayrıştırılarak analiz edilir. Her epok, belirli frekans bantlarında analiz edilerek, atış öncesi ve sonrası dönemdeki zihinsel hazırlık ve motor kontrol durumları değerlendirilir (Chuang ve ark., 2013).

EEG kullanımının spor bilimleri literatüründe artan bir popüleriteye sahip olmasıyla, golf, atıcılık ve basketbol gibi birçok spor dalında araştırmalar yapılmıştır. Babiloni ve arkadaşları (2008), golf atışları sırasında EEG aktivitesini analiz ederek sensorimotor ritimlerdeki değişimleri ortaya koymuş; benzer şekilde Harmony (2013), delta ve theta aktivitelerinin dikkat süreçleriyle ilişkisini vurgulamıştır. Bu araştırmalar EEG'nin serbest atış gibi kritik anlarda, zihinsel hazırlık düzeyinin ve performansın objektif değerlendirilmesinde önemli bir yöntem olduğunu ortaya koymaktadır.

### **4.3.Serbest Atış ve EEG**

Basketbol serbest atışı sırasında EEG (Elektroensefalografi) kullanılarak yapılan beyin aktivitesi çalışmaları, sporcunun zihinsel durumu, motor hazırlığı ve dikkat seviyesi hakkında

önemli bilgiler sunmaktadır. EEG yöntemi, beyin farklı bölgelerindeki elektriksel aktiviteleri yüksek zaman çözünürlüğüyle izleyerek motor eylemlerin öncesindeki ve sırasındaki bilişsel süreçleri detaylı olarak ortaya koyar. Bu süreçler, sporcuların performanslarını optimize etmek için kritik önem taşımaktadır.

Frontal bölgelerdeki theta aktivitesinin serbest atış başarısıyla ilişkili olduğuna dair önemli bulgular mevcuttur. Chuang ve arkadaşları (2013), elit basketbol oyuncularında başarılı atışlar öncesinde frontal midline theta gücünün arttığını ve bunun odaklanma ile bağlantılı olduğunu ortaya koymuşlardır. Benzer sonuçlar, farklı bilişsel görevlerde artan frontal theta aktivitesinin dikkat kontrolü ve bilişsel yüklenme ile yakından ilişkili olduğunu gösteren diğer EEG araştırmaları ile de desteklenmektedir (Klimesch, 1999).

Neuper ve Pfurtscheller (2001), motor hazırlık evresindeki mu ritmi (8–13 Hz) desenkronizasyonunun özellikle santral motor korteks bölgelerinde belirgin olduğunu ve motor planlama sürecini yansıttığını bulmuşlardır. Bu desenkronizasyon, motor korteksteki nöral aktivitenin arttığını ve hareket öncesi zihinsel hazırlığın tamamlandığını gösteren bir işarettir.

Serbest atışlar sırasında alfa ve beta dalgalarının rolü de kritiktir. Alfa dalgaları genellikle rahatlama durumlarında artış gösterirken, dikkat gerektiren motor eylemlerde baskılanmaktadır. Bu durum, “alfa blokajı” olarak adlandırılır ve odaklanmış dikkat durumunu gösterir. Del Percio ve arkadaşları (2011), başarılı atışlar öncesinde alfa gücünün azaldığını ve beta gücünün arttığını belirtmiştir. Beta dalgalarındaki bu artış, motor hazırlık, dikkat kontrolü ve hareket planlama ile ilişkilendirilmektedir. Bu EEG desenleri, atış öncesi konsantrasyon düzeylerinin objektif olarak değerlendirilmesi için kullanılabilir.

Başarısız serbest atışlarla ilişkili EEG desenleri ise farklılık göstermektedir. Uusitalo ve arkadaşları (2004), başarısız atışlardan önce delta ve theta dalgalarının fronto-sentral bölgelerde düzensiz ve anormal seyrettiğini, bunun da dikkat dağınıklığı veya zihinsel kararsızlık belirtisi olabileceğini öne sürmüşlerdir. Bu durum, yüksek stres veya baskı altındaki performans düşüklüğüyle açıklanabilir. Yüksek baskı altında, artan kortikal uyarılma seviyeleri frontal bölgelerdeki theta dalgalarını artırabilirken, bu artışın aşırı olması performans üzerinde negatif bir etkiye yol açabilir.

Son yıllarda EEG verilerinin sportif başarıyı öngörmede makine öğrenmesi yöntemleri ile kullanımı yaygınlaşmaktadır. Guo ve arkadaşları (2014), EEG verilerini kullanarak golf sporcularının putt başarılarını SVM algoritmaları ile tahmin etmişlerdir. Benzer yöntemlerin basketbol serbest atışları için de uygulanabilir olduğu ileri sürülmektedir. Özellikle

kişiselleştirilmiş EEG profillerinin oluşturulması ve bu profillerin yapay zeka destekli tahmin modelleri ile analiz edilmesi, sporcuların bireysel performansını daha etkili şekilde değerlendirmeye imkân sağlamaktadır.

Sporda nörofizyolojik adaptasyonlara ilişkin EEG çalışmaları, sporcuların uzmanlık seviyeleri ile delta ve gamma dalgalarındaki aktivasyon farklılıklarının performans ve dikkat düzeyleriyle yakından bağlantılı olduğunu göstermiştir (Fang ve ark., 2022). Bu adaptasyonlar, düzenli ve yüksek yoğunluklu antrenmanların beyin üzerindeki pozitif etkilerini de ortaya koymaktadır. Bu bağlamda, EEG ölçümleri ile tespit edilen nöral adaptasyonlar, sporcuların performans gelişimi için etkili müdahale stratejilerinin tasarlanmasında kullanılabilir.

Mobil EEG uygulamalarıyla yapılan çalışmalar, serbest atış gibi sportif eylemler sırasında "bilişsel zamanlama"nın önemini ortaya koymaktadır. Park ve arkadaşları (2015), mobil EEG sistemlerini kullanarak frontal theta ve alfa dalgaları arasındaki dinamik ilişkilerin sportif performans üzerindeki etkilerini tartışmıştır. Ayrıca, Chikara ve Ko (2016), EEG'nin faz modülasyonu ile serbest atış gibi hızlı karar ve hareket gerektiren görevlerde başarı tahmini yapılabileceğini göstermiştir. Bu yöntem, sporcuların motor planlama ve karar verme süreçlerinin objektif değerlendirmesi açısından büyük potansiyele sahiptir.

EEG yönteminin spor bilimlerindeki uygulamalarının genişlemesiyle, farklı spor branşlarında da önemli bulgular elde edilmiştir. Babiloni ve arkadaşları (2008), golf sporcularının atışları sırasındaki sensorimotor ritimlerini EEG ile analiz ederek performans üzerindeki nöral etkileri incelemiştir. Ayrıca Harmony (2013), EEG bantları arasında özellikle delta ve theta aktivitelerinin bilişsel yük ve dikkat kontrolü ile ilişkilerini vurgulayarak, EEG'nin spor performansı analizindeki önemini güçlendirmiştir. Sonuç olarak, EEG ile basketbol serbest atışı performansının analiz edilmesi, zihinsel odaklanma, motor hazırlık ve dikkat süreçlerinin detaylı şekilde incelenmesine imkân tanımaktadır. Bu bulgular, neurofeedback uygulamaları, dikkat artırıcı müdahaleler ve psikofizyolojik eğitim yöntemleri geliştirmek için güçlü bir temel oluşturmaktadır. EEG verilerinin yapay zekâ yöntemleriyle birleştirilmesi, spor performansını objektif ve bilimsel temellere dayanarak değerlendirmenin yeni bir boyutunu sunmaktadır. Bu yaklaşım, sportif performansını geliştirmek ve sporcuların bilişsel ve motor süreçlerini optimize etmek adına kapsamlı müdahale stratejileri geliştirilmesine imkân tanıyabileceği düşünülmektedir.

#### **4.4.EEG Verilerinin Makine Öğrenmesi ile Analizi**

Makine öğrenmesi (ML) algoritmaları, elektroensefalografi (EEG) verilerinden elde edilen karmaşık örüntüleri tanımlamak ve spor performansı gibi süreçleri sınıflandırmak amacıyla son yıllarda giderek yaygınlaşmaktadır. EEG'nin yüksek zaman çözünürlüğü, beyindeki anlık nöral aktivite değişimlerini yakalamayı mümkün kılarken, ML algoritmalarının güçlü örüntü tanıma ve veri analizi yetenekleri, bu verilerin etkili bir şekilde değerlendirilmesine imkân tanımaktadır. Özellikle basketbol serbest atışı gibi motor görevlerde sporcuların zihinsel durumları, konsantrasyon seviyeleri, stres tepkileri ve motor hazırlık seviyeleri gibi karmaşık süreçlerin tahmininde EEG verileri ile ML yöntemlerinin bir araya getirilmesi önemli sonuçlar vermektedir.

##### **4.4.1. Destek vektör makineleri (SVM)**

Destek Vektör Makineleri (SVM), sınıflandırma problemlerinde yüksek doğruluk sağlayan, özellikle küçük veri kümelerinde güçlü genelleme yeteneğine sahip denetimli öğrenme algoritmalarıdır (Vapnik, 1998). SVM, EEG sinyallerinde sınıflandırma yaparken farklı çekirdek fonksiyonları kullanarak doğrusal olmayan ayrımlar gerçekleştirebilir. Gaussian çekirdekli SVM varyantları, EEG verilerinde en sık tercih edilen modeller arasındadır.

Fine Gaussian SVM, düşük bant genişliği ile çalışır ve EEG sinyallerindeki ince detayları yakalayarak yüksek doğruluk sağlar. Bu model, özellikle sporcularda motor hazırlık süreçlerinin tahmininde başarıyla uygulanmıştır (Minami ve ark., 2024). Medium Gaussian SVM, daha geniş bir çekirdek kullanarak modelin genellenebilirliğini artırırken, Quadratic ve Cubic SVM ise polinomsal çekirdeklerle çalışarak doğrusal olmayan sınırlarda sınıflandırma yapar (Lamaakal ve ark., 2025).

##### **4.4.2. K-En yakın komşu (k-NN)**

k-En Yakın Komşu (k-NN) algoritması, sınıflandırılmak istenen örneğin, eğitim setindeki en yakın k komşusunun sınıfına göre karar vermektedir. Bu algoritma, basit yapısı ve parametrik olmayan doğası sayesinde küçük EEG veri kümelerinde tercih edilmektedir (Cover & Hart, 1967). Minami ve arkadaşları (2024), eSpor oyuncularının EEG verilerinde k-NN algoritmasını kullanarak yüksek doğrulukla rekabetçi başarı tahmini yapabilmişlerdir.

#### **4.4.3. Ensembl ağaç yöntemleri (Bagged ve Boosted Trees)**

Ensemble yöntemleri, birden fazla karar ağacının birlikte çalıştığı güçlü sınıflandırıcılardır. Bagged Trees algoritması (örneğin Random Forest), EEG verilerindeki varyansı azaltmak ve aşırı uyumu önlemek için sıklıkla tercih edilmektedir. Özellikle yüksek sayıda EEG kanalından elde edilen özelliklerin yorumlanmasında etkili olmuştur (Abidin & Erdem, 2025).

Boosted Trees algoritmaları ise her ağacın bir öncekinden öğrenmesini sağlayarak sınıflandırma doğruluğunu artırır. EEG sinyalleri ile sporcu performansı analizlerinde özellikle dikkat seviyesinin tahmini ve tepki süresi sınıflandırmalarında etkili olduğu görülmüştür (Lamaakal ve ark., 2025).

#### **4.4.4. Yapay sinir ağları (ANN)**

Yapay Sinir Ağları (ANN), çok katmanlı yapılar ile EEG sinyallerindeki doğrusal olmayan örüntüleri öğrenebilme kapasitesine sahiptir. Minami ve arkadaşları (2024), iki ve üç katmanlı sinir ağları kullanarak EEG tabanlı başarı tahmini modelleri geliştirmişlerdir. Özellikle Medium Neural Network, yüksek alan altında eğri (AUC) değeri ile öne çıkarken, Narrow ve Wide Neural Network yapılarının farklı veri boyutlarında avantaj sağladığı görülmüştür (Ibáñez-Redin ve ark., 2023).

#### **4.4.5. Konvolüsyonel sinir ağları (CNN)**

CNN'ler, EEG sinyallerinden zamansal ve uzaysal özellikleri otomatik olarak çıkarabilen güçlü modellerdir. Sporcularda motor imgeleme ve karar verme süreçlerini analiz etmek için sıkça tercih edilmektedir (Fang ve ark., 2022). CNN'lerin EEG verilerinden spektral özellik çıkarımı yaparak serbest atış başarısı gibi karmaşık performans parametrelerini sınıflandırabildiği gösterilmiştir (Khanmohammadi ve ark., 2024).

#### **4.4.6. Uzun kısa süreli bellek (LSTM)**

LSTM ağları, EEG gibi zaman serisi verilerinde uzun dönemli bağımlılıkları modellemek için tasarlanmıştır. Spor performansında ardışık dikkat ve tepki örüntülerinin analizinde etkili olmuştur (Chikara & Ko, 2016). Özellikle motor imgeleme görevlerinde EEG dalga örüntülerinin zaman içindeki değişimini yakalamada başarı göstermektedir.

Son dönemlerde birçok çalışma EEG tabanlı makine öğrenmesi yöntemlerinin spor performansını tahmin etme ve optimize etme alanında başarıyla uygulanabileceğini göstermektedir. Minami ve arkadaşları (2024), profesyonel eSpor oyuncularının EEG verilerini kullanarak rekabet sonuçlarını k-en yakın komşu (k-NN), destek vektör makineleri (SVM) ve

konvolüsyonel sinir ağıları (CNN) algoritmalarıyla analiz etmiş ve bu yöntemlerin yüksek doğruluk oranlarıyla sonuçları öngörebildiğini ortaya koymuştur. Bu bulgular, EEG verilerinin performans değerlendirmede etkin bir zihinsel performans göstergesi olarak kullanılabileceğini desteklemektedir.

Benzer bir yaklaşımı benimseyen Ibáñez-Redin ve ekibi (2023), giyilebilir EEG teknolojileri kullanılarak atletik performansın sınıflandırılabilceğini göstermiştir. Bu çalışma, KNN, SVM ve yapay sinir ağıları (ANN) modellerinin EEG verilerinden elde edilen özelliklerle sporcuların performans düzeylerini güvenilir biçimde belirleyebildiğini ortaya koymuştur. Mobil EEG cihazlarının kullanımıyla saha içi ve gerçek zamanlı uygulamaların mümkün olduğunu ve bu verilerin antrenman sırasında performans optimizasyonu için kullanılabilceğini de vurgulamıştır.

Basketbol performansını tahmin etmek amacıyla çoklu veri kaynaklarını birleştiren Khanmohammadi ve arkadaşları (2024), "MambaNet" adını verdikleri hibrit sinir ağı modelini geliştirmiştir. Bu model, EEG verileriyle birlikte biyomekanik ve fizyolojik verileri entegre ederek NBA oyuncularının saha içi ve serbest atış performanslarını yüksek doğrulukla tahmin edebilmiştir. Benzer olarak, Abidin ve Erdem (2025), bisiklet sporcularında yetenek tanımlama ve performans değerlendirme için EEG ve Kinect verilerini birleştirerek kNN ve Random Forest algoritmalarıyla etkili sonuçlar almıştır. Bu tür veri entegrasyon yaklaşımları, spor bilimlerinde veri füzyonunun önemini vurgulamakta ve doğruluk oranlarını artırmaktadır.

Kar ve arkadaşları (2021), EEG verilerini robotik hareket hedefleme görevleri üzerine çalışarak SVM algoritmalarıyla analiz etmiş ve bu tür görevlerin EEG verileriyle başarılı şekilde tahmin edilebileceğini göstermiştir. Bu bulgular, basketbol serbest atışları gibi benzer motor görevlerin analizinde EEG verilerinin etkin şekilde kullanılabilceğini desteklemektedir. Kişiyeye özgü sınıflandırma modelleri üzerine odaklanan Kanjilal ve arkadaşları (2023), subtransfer learning yöntemlerini kullanarak EEG verilerinden motor aktiviteleri başarıyla sınıflandırmayı başarmıştır. Bu araştırma, Gaussian SVM, kNN ve Bagged Trees algoritmalarıyla EEG temelli kişiyeye özel performans tahmin modellerinin geliştirilebileceğini göstermektedir.

Derin öğrenme tekniklerinin EEG verileriyle entegrasyonu, son yıllarda bu alanda büyük bir gelişim göstermiştir. Fang ve arkadaşları (2022), EEG sinyallerinin dalga özelliklerini CNN algoritmalarıyla işleyerek gerçek zamanlı sporcu performansı ile yüksek korelasyonlar elde etmiş ve bu yöntemlerin etkinliğini göstermiştir. Ayrıca Lamaakal ve ekibi (2025), EEG ve EMG verilerini entegre ederek davranış analizi yapmış, kNN, LDA ve SVC algoritmalarıyla

sınıflandırma performanslarını karşılaştırmalı olarak değerlendirmiş ve farklı spor senaryolarında en etkin algoritmaları belirlemiştir.

Son yıllardaki araştırmalar, EEG tabanlı makine öğrenmesi yöntemlerinin temelini oluşturan alfa, beta, theta bantları ile zaman-frekans analizinden elde edilen özelliklerin performans tahmini için etkin kullanıldığını göstermiştir. Literatürde Gaussian çekirdekli SVM, KNN, CNN, LSTM ve Random Forest algoritmaları sıklıkla tercih edilmektedir. Ayrıca bireysel EEG farklılıkları nedeniyle kişiselleştirilmiş modellerin doğruluk oranlarını artırdığı ve genel modellerden daha etkin sonuçlar verdiği vurgulanmaktadır.

Mobil EEG sistemlerinin geliştirilmesi, saha içi ölçümlerin anlık olarak yapılabilmesini sağlamıştır. Park ve arkadaşları (2015), mobil EEG sistemleri kullanarak frontal theta ve alfa bantları arasındaki dinamik ilişkileri incelemiş ve bu ilişkilerin performans üzerindeki önemini göstermiştir. Chikara ve Ko (2016) ise EEG faz modülasyonu yöntemini kullanarak motor hareketlerin ve hızlı karar verme süreçlerinin başarıyla tahmin edilebildiğini göstermiştir.

Sonuç olarak EEG verilerinin makine öğrenmesi yöntemleri ile analizi, spor bilimlerinde performans tahmininde yenilikçi ve etkili bir araç olarak kabul edilmektedir. Özellikle basketbol serbest atışı gibi motor görevlerde performansın anlık ve objektif olarak değerlendirilmesine imkân tanıyan EEG tabanlı ML yöntemleri, sporcuların performansını geliştirmek ve optimize etmek için önemli fırsatlar sunmaktadır. Gelecekte, kişiselleştirilmiş ve adaptif ML modellerinin geliştirilmesi ve EEG verilerinin farklı sensörlerle entegrasyonu yoluyla spor performansının daha hassas ve kapsamlı biçimde tahmin edilebilmesi mümkün olacaktır.

## 5. GEREÇ ve YÖNTEM

### 5.1.Araştırma Tasarımı

Bu çalışma deneysel desene yapılandırılmıştır ve basketbol serbest atışları sırasında elektroensefalografi (EEG) kullanılarak kaydedilen beyin elektriksel aktivitenin analizine dayanır. Çalışmanın amacı, EEG verilerini kullanarak motor hazırlık ve dikkat süreçlerini anlamak ve bu verilere dayalı makine öğrenmesi modelleri ile serbest atış başarılarını sınıflandırmaktır. Hem davranışsal (video analizi ve atış sonuçları) hem de nörofizyolojik (EEG sinyalleri) veriler eş zamanlı olarak toplanmıştır. Çalışma Marmara Üniversitesi Sağlık Bilimleri Fakültesi Spor Bilimleri Bölümü spor salonunda gerçekleştirilmiş ve Marmara Üniversitesi Sağlık Bilimleri Etik Kurulu'nun 17.12.2024 tarih ve 118 sayılı kararı ile onaylanmıştır.

### 5.2.Katılımcılar


Çalışmaya katılan tüm sporcular, Marmara Üniversitesi Spor Bilimleri Fakültesi öğrencilerinden seçilmiş olup, üniversitenin basketbol takımı bünyesinde aktif olarak antrenman yapan ve rekabetçi seviyede deneyime sahip bireylerden oluşmaktadır. Katılımcıların yaşları 20 ile 34 arasında değişmekte olup, toplam sekiz (n=8) elit düzey erkek sporcu araştırmaya gönüllü olarak katılmıştır. Bu grup, düzenli sportif geçmişleri ve teknik yeterlilikleri doğrultusunda değerlendirilmiş; serbest atış becerilerindeki yetkinlikleri sayesinde EEG verilerinin güvenilirliğini artıracak nitelikte seçilmiştir. Ayrıca, katılımcı grubunun benzer yaş aralığı, eğitim seviyesi ve antrenman sıklığı açısından homojen bir yapı göstermesi, elde edilen verilerin tutarlı şekilde yorumlanmasını kolaylaştırmıştır. Katılımcıların seçimi, spor antrenörlerinin ve akademik danışmanların yönlendirmeleri eşliğinde, gönüllülük esasına dayalı olarak gerçekleştirilmiştir. Araştırmanın kapsamı, amacı ve olası etkileri her katılımcıya detaylı biçimde açıklanmış; etik ilkeler doğrultusunda her bireyden yazılı aydınlatılmış onam formu alınmıştır. Tüm süreç boyunca kişisel verilerin gizliliği korunmuş ve araştırma, Helsinki Bildirgesi ilkelerine ve Marmara Üniversitesi Sağlık Bilimleri Etik Kurulu'nun yönergelerine uygun şekilde yürütülmüştür.

**Tablo 1.** Katılımcı bilgileri

Katılımcı No	Yaş/ Cinsiyet	Tecrübe (Yıl)	Sürelerin ortalaması/Standart Sapması (ms)	Başarılı Atış	Başarısız Atış	Boy/Kilo (cm/kg)
#1	29/M	14	6783 / 1885	98	98	181/98
#2	22/F	15	7360 / 2775	57	17	185/77
#3	20/F	12	4477 / 1598	55	51	168/60
#4	20/F	8	4631 / 1312	47	65	174/64
#5	20/M	9	9355 / 2233	51	10	185/75
#8	21/M	14	8663 / 1406	52	13	195/88
#9	22/F	6	5887 / 2527	53	101	175/70
#10	34/F	24	9922 / 2262	82	7	180/77

### 5.3.EEG Kayıt Sistemi ve Kurulumu

EEG verileri, 16 kanallı aktif elektrot sistemine sahip BrainProducts V-Amp cihazı ile kaydedilmiştir. Elektrot yerleşimi, uluslararası 10–20 sistemine uygun şekilde frontal (Fp1, Fp2, Fpz), fronto-sentral (F3, F4, F7, F8), santral (C3, C4, Cz) ve paryeto-okspital (P3, Pz, P4, O1, Oz, O2) bölgeleri kapsayacak şekilde gerçekleştirilmiştir. EEG sinyalleri 500 Hz örnekleme hızıyla kaydedilmiş ve 0,1–40 Hz bant geçişli filtreleme uygulanmıştır. Göz kırpması, kas hareketleri ve elektriksel gürültü gibi artefaktlar, Independent Component Analysis (ICA) yöntemi ile temizlenmiştir. ICA, sinyali oluşturan bağımsız kaynakları ayırarak nörolojik olmayan bileşenleri elimine eder. Artefaktların tanımlanması hem algoritmik hem de görsel denetimle gerçekleştirilmiştir.



Şekil 7. EEG kayıt aşaması görüntüsü

#### 5.4. Deneysel Protokol

Katılımcılar, ısınma protokolünü tamamladıktan sonra kendi belirledikleri hızda ardışık serbest atışlar gerçekleştirmişlerdir. Atışlar sırasında EEG kaydı alınmış, atış zamanları eş zamanlı olarak video ile kaydedilmiştir. Her atışın başlangıcı ve bitişi manuel olarak EEG zaman çizelgesine senkronize edilmiştir. Her atış için atış öncesi (pre-shot) ve atış sonrası (post-shot) dönemlerden oluşan dört adet birer saniyelik epoklar tanımlanmıştır. Epok uzunluğu olarak bir saniye tercih edilmiştir, çünkü literatürde kısa süreli epokların (1–3 saniye) sınıflandırma doğruluğunu artırdığı gösterilmiştir (Gomez-Tapia, 2022; Gangapuram & Manian, 2023).

## 5.5. EEG Veri İşleme ve Özellik Çıkartımı

Preprocessing aşamasında EEG sinyalleri FieldTrip Toolbox kullanılarak işlenmiş ve her epok için delta (0–4 Hz), theta (5–8 Hz), alfa (9–13 Hz) ve beta (14–30 Hz) frekans bantlarında güç spektral yoğunluğu (Power Spectral Density, PSD) hesaplanmıştır. Elektrotlar dört bölgesel gruba ayrılmış ve her bant için ortalama değerler bu gruplar üzerinden elde edilmiştir. Toplamda 1000'in üzerinde artefaktsız epok başarılı ve başarısız atışlar ile pre/post dönemlerine göre etiketlenmiştir. Bu sayede sınıflandırma için dengeli ve etiketlenmiş veri seti oluşturulmuştur.

## 5.6. İstatistiksel Analiz

Atış öncesi ve sonrası dönemlerde elde edilen EEG bant gücü değerleri arasındaki farkları belirlemek amacıyla eşleştirilmiş örneklem t-testi uygulanmıştır. Çoklu karşılaştırmalardan kaynaklanan yalancı pozitiflik riskini kontrol altına almak için Benjamini-Hochberg (BH) yöntemiyle False Discovery Rate (FDR) düzeltmesi yapılmıştır. Anlamlılık düzeyi  $p < 0.05$  olarak kabul edilmiştir (Rousselet ve ark., 2025).

Bu çalışmada EEG verilerinden elde edilen bant gücü özelliklerinin analizinde klasik istatistiksel yöntemler uygulanmıştır. Özellikle atış öncesi ve sonrası dönemlerdeki frekans bileşenlerinin karşılaştırılmasında, eşleştirilmiş örneklem t-testi (paired samples t-test) tercih edilmiştir. Bu test, aynı bireylere ait iki farklı koşul (pre ve post dönemler) arasındaki ortalama farkın anlamlı olup olmadığını değerlendirmek amacıyla kullanılmıştır. Her bir EEG özelliği için uygulanan bu test, kısa zaman pencerelerine ayrılmış toplam 16 farklı elektrot ve frekans bandı bileşenine dayanmaktadır.

Çoklu karşılaştırma yapılması nedeniyle, istatistiksel analizlerde yalancı pozitiflik riskini azaltmak adına False Discovery Rate (FDR) kontrolü uygulanmıştır. Bu amaçla, Benjamini-Hochberg (BH) prosedürü tercih edilmiştir. BH prosedürü, yapılan çoklu testler sonucunda elde edilen p-değerlerini sıralayarak, her bir test için ayarlanmış anlamlılık eşiği hesaplar. Bu yöntem, family-wise error rate'i kontrol altına almanın yanı sıra, istatistiksel gücü de koruduğu için özellikle EEG, genomik ve bilişsel nörobilim gibi yüksek sayıda karşılaştırma içeren alanlarda sıkça tercih edilmektedir (Rousselet ve ark., 2025).

Benjamini-Hochberg yöntemi şu şekilde işlemektedir: öncelikle elde edilen p-değerleri küçükten büyüğe sıralanır. Her bir sıralı p-değeri,  $(i/m) \times \alpha$  formülü ile karşılaştırılır; burada  $i$  p-değerinin sırası,  $m$  toplam test sayısı (bu çalışmada 16), ve  $\alpha$  anlamlılık düzeyidir (0,05). Eğer sıralı p-değeri bu eşiği aşmıyorsa, test anlamlı olarak kabul edilir. BH yöntemi, Bonferroni gibi

katı düzeltmelerin aksine, daha esnek bir yaklaşım sunar ve anlamlı ancak küçük etkilerin gözden kaçırılmasının önüne geçer.

Bu analizler sonucunda, hem başarılı hem de başarısız atışlara ilişkin pre ve post dönem karşılaştırmalarında, özellikle belirli beyin bölgelerine ve frekans bantlarına karşılık gelen bazı EEG özelliklerinin FDR düzeltmesi sonrasında dahi istatistiksel olarak anlamlı kaldığı görülmüştür. Bu durum, yalnızca makine öğrenmesi modelleriyle değil, aynı zamanda klasik istatistiksel değerlendirmelerle de EEG örüntülerinin anlamlı farklılıklar içerdiğini desteklemektedir. Başarılı atışlara ait analizde, delta ve theta bantlarındaki artış ile alfa ve beta bantlarındaki azalmaların santral ve paryeto-okspital bölgelerde anlamlı olduğu belirlenmiştir. Benzer şekilde, başarısız atışlarda da dikkat dağınıklığına ve motor hazırlık eksikliğine işaret eden bant gücü varyasyonları FDR düzeltmesi sonrasında anlamlı kalmıştır.

Bu istatistiksel bulgular, makine öğrenmesi temelli sınıflandırma sonuçlarını desteklemekte olup, EEG verilerinden elde edilen sinyallerin yalnızca sınıflandırma algoritmalarına değil, geleneksel parametrik testlere de duyarlı yapılar içerdiğini göstermektedir. Böylece, çalışmada kullanılan istatistiksel yaklaşım hem veri güvenilirliğini artırmakta hem de elde edilen sonuçların bilimsel dayanaklarını güçlendirmektedir.

Çalışmada katılımcıların psikolojik durumlarını değerlendirmek amacıyla Algılanan Stres Ölçeği (Perceived Stress Scale – PSS) uygulanmış; ancak elde edilen puanların gruplar arasında anlamlı varyasyon göstermemesi ve veri dağılımının analiz kriterlerini karşılamaması nedeniyle bu ölçüt istatistiksel hesaplamalara dahil edilmemiştir.

### **5.7. Makine Öğrenmesi Uygulamaları**

Özellik setleri kullanılarak üç farklı sınıflandırma senaryosu test edilmiştir:

1. Başarılı atışların pre ve post dönemlerinin sınıflandırılması,
2. Başarısız atışların pre ve post dönemlerinin sınıflandırılması,
3. Tüm atışların pre dönemlerinden başarılı/başarısız ayırımı.

Bu analizler için K-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Karar Ağaçları (Decision Trees), Boosted Trees, Yapay Sinir Ağları (Artificial Neural Networks, ANN), Ayrım Analizi (Discriminant Analysis) ve Genelleştirilmiş Doğrusal Modeller (GLM) kullanılmıştır. Tüm modeller MATLAB 2024 ortamında, 5 katlı çapraz doğrulama yöntemiyle test edilmiştir. Başarı kriterleri olarak sınıflandırma doğruluğu, eğitim süresi ve varyans

analizleri dikkate alınmıştır. En yüksek doğruluk oranı (%74,9), başarılı atışların pre ve post dönemlerini ayırt eden İnce Gaussian SVM modeliyle elde edilmiştir.

### **5.8. Yöntemsel Güç ve Literatürel Dayanak**

EEG tabanlı sınıflandırma çalışmalarında, özellikle zaman serisi özelliklerinin etkin şekilde çıkarılması, model başarısı açısından belirleyici bir unsurdur. Bu bağlamda, delta, theta, alfa ve beta bantlarının güç spektrumları, motor davranışların nörofizyolojik göstergeleri olarak öne çıkmaktadır. Babiloni ve arkadaşları (2008), EEG ile ölçülen sensorimotor ritimlerin, motor eylem öncesi dönemde önemli değişiklikler gösterdiğini ve bu örüntülerin sınıflandırma algoritmalarına girdi olarak sunulmasının yüksek ayırt edici güç sağladığını belirtmiştir. Çalışmamızda da benzer şekilde bu dört temel frekans bandı, bölgelerle eşlenerek 64 özellik vektörüne dönüştürülmüş ve makine öğrenmesi algoritmaları için anlamlı bir giriş uzayı oluşturmuştur.

Ayrıca, bu çalışmada uygulanan 5 katlı çapraz doğrulama protokolü, veri setinin nispeten sınırlı olduğu senaryolarda model genelleştirilebilirliğini artırmak amacıyla seçilmiştir. Hastie, Tibshirani ve Friedman (2009), küçük örneklemlerle veri setlerinde model varyansını düşürmek için çapraz doğrulamanın etkili bir yöntem olduğunu vurgulamıştır. Bunun yanı sıra, öz nitelik seçimi yapılmaksızın tüm özelliklerin modele dahil edilmesi, overfitting riskine karşı klasik istatistiksel önlemlerin yanı sıra bölgesel gruplama stratejileriyle desteklenmiştir. Bu yapı, hem sinyal bütünlüğünü bozmadan sınıflandırma başarısını sürdürmüş hem de örüntü tanıma süreçlerinde topolojik nörolojik bilgiyi korumuştur. Literatürde benzer stratejilerle desteklenen bu yöntemsel çerçeve, çalışmamızın metodolojik geçerliliğini güçlendirmektedir.

## 6. BULGULAR

Bu bölümde, basketbol serbest atışları sırasında kaydedilen EEG verilerine dayalı olarak yapılan istatistiksel analizlerin sonuçları ve makine öğrenmesi algoritmalarıyla gerçekleştirilen sınıflandırma performansları ayrıntılı bir biçimde sunulmuştur. Bulgular, başarılı ve başarısız atışların atış öncesi (pre-shot) ve atış sonrası (post-shot) dönemlerine göre karşılaştırmalı olarak analiz edilmiş ve elde edilen frekans bandı örüntüleri bölgesel EEG aktivitesi temelinde değerlendirilmiştir.

### 6.1. Başarılı Serbest Atışların Pre-Post EEG Özellikleri

Başarılı atışların pre ve post dönemleri arasında yapılan karşılaştırmada, özellikle fronto-sentral ve santral bölgelerde delta, theta, alfa ve beta bantlarındaki frekans gücü farklılıkları istatistiksel olarak anlamlı bulunmuştur. En dikkat çekici değişim, santral bölgelerde gözlemlenen 8–13 Hz aralığındaki alfa bandı aktivitesinde olmuştur. Bu frekans bandında görülen belirgin düşüş, motor hazırlığın fizyolojik bir göstergesi olarak yorumlanmakta ve literatürde "mu ritmi desenkronizasyonu" olarak adlandırılmaktadır.

- Fronto-sentral delta gücü: Pre-shot > Post-shot ( $p < 0,001$ , FDR düzeltilmeli)
- Parieto-okcipital alfa gücü: Post-shot > Pre-shot ( $p < 0,001$ )
- Santral theta gücü: Pre-shot > Post-shot ( $p < 0,01$ )
- Fronto-sentral beta gücü: Post-shot > Pre-shot ( $p < 0,05$ )

Bu bulgular, frontal dikkat sistemlerinin ve santral motor korteksin pre-atış döneminde daha aktif olduğunu, post-atış döneminde ise sensorimotor toparlanma sürecinin başladığını göstermektedir.

**Tablo 2.** Başarılı atışların pre-post istatistiksel özellikleri

Özellik	t	Standart Sapma	p	Atış Öncesi Ortalama	Atış Sonrası Ortalama	Cohen'in d Etki Büyüklüğü	FDR Eşik Değeri
Fronto-Central Delta *	5,33	0,14	<0,001	0,14	0,09	0,33	0,0031
Frontal Delta *	4,85	0,17	<0,001	0,20	0,14	0,30	0,0063
Parieto-Occipital Alpha *	-3,70	0,12	<0,001	0,12	0,15	0,23	0,0094
Central Theta *	-3,19	0,11	<0,001	0,15	0,17	0,20	0,0125
Fronto-Central Beta *	2,66	0,07	<0,01	0,05	0,04	0,16	0,0156
Parieto-Occipital Delta *	2,60	0,33	<0,01	0,45	0,40	0,16	0,0188
Parieto-Occipital Theta *	-2,37	0,13	0,02	0,15	0,17	0,15	0,0219

Central Alpha *	-2,35	0,09	0,02	0,11	0,13	0,15	0,0250
Parieto-Occipital Beta *	-2,32	0,16	0,02	0,15	0,17	0,14	0,0281
Fronto-Central Theta	1,57	0,05	0,12	0,04	0,04	0,10	0,0313
Fronto-Central Alpha	0,94	0,05	0,35	0,04	0,03	0,06	0,0344
Frontal Alpha	-0,86	0,06	0,39	0,05	0,05	0,05	0,0375
Central Delta	-0,81	0,32	0,42	0,50	0,51	0,05	0,0406
Central Beta	0,75	0,11	0,45	0,14	0,14	0,05	0,0438
Frontal Beta	0,71	0,09	0,48	0,07	0,07	0,04	0,0469
Frontal Theta	0,16	0,07	0,87	0,06	0,06	0,01	0,0500

Başarılı atışların öncesi ve sonrası dönemlerinden elde edilen özellikler arasındaki istatistiksel farklar. Bağımsız çoklu t-testleri, BH FDR (Benjamini-Hochberg Yanlış Keşif Oranı) eşikleri kullanılarak istatistiksel olarak sınırlandırılmıştır. Yıldız (\*) ile işaretlenen özellikler bu eşiği geçmiştir. Tablo sütunları olan t, sd, p, Ortalama (önce), Ortalama (sonra), Cohen's d, FDR eşiği sırasıyla şu anlamlara gelmektedir: t-istatistiği, standart sapma, anlamlılık düzeyi, ön dönemle ilişkili normalize edilmiş değerlerin ortalaması, son dönemle ilişkili normalize edilmiş değerlerin ortalaması, etki büyüklüğü ve BH FDR eşiği.

## 6.2. Başarılı Atışların Makine Öğrenmesi İle Sınıflandırılması

Başarılı atışlara ait EEG epoklarının sınıflandırılmasında Fine Gaussian SVM modeli en yüksek doğruluğu (%74,23) sağlamıştır. Model, 5 katlı çapraz doğrulama ile test edilmiş ve toplamda 1040 epok üzerinden işlem gerçekleştirilmiştir.

Doğru sınıflandırılan örnekler:

- 373 adet pre-shot epoku doğru sınıflandırıldı (True Positive)
- 399 adet post-shot epoku doğru sınıflandırıldı (True Negative)
- 121 adet post-shot epoku yanlışlıkla pre olarak sınıflandırıldı (False Positive)
- 147 adet pre-shot epoku yanlışlıkla post olarak sınıflandırıldı (False Negative)

**Tablo 3.** Başarısız atışların konfüzyon matrisi

	Gerçek : Atış Öncesi (Pre)	Gerçek :Atış Sonrası (Post)
Tahmin : Atış Öncesi (Pre)	373 (TP)	121 (FP)
Tahmin : Atış Sonrası (Post)	147 (FN)	399 (TN)

#### Performans Ölçütleri :

- Doğruluk (Accuracy):

$$(TP + TN) / \text{Toplam} : (373 + 399) / 1.040 \approx \%74,23$$

- Hassasiyet (Recall):

$$TP / (TP + FN) : 373 / (373 + 147) \approx \%71,74$$

- Kesinlik (Precision):

$$TP / (TP + FP): 373 / (373 + 121) \approx \%75,5$$

- F1 Skoru:

$$2 \times (\text{Kesinlik} \times \text{Hassasiyet}) / (\text{Kesinlik} + \text{Hassasiyet}) \approx \%73,6$$

**Tablo 4.** Başarılı atışların sınıflandırılması

Model	Doğruluk %	Eğitim Süresi (sn)
Fine Gaussian SVM	74,23	3,01
Bilayered Neural Network	73,46	3,93
Medium Gaussian SVM	73,37	3,89
Cubic SVM	72,98	9,40
Boosted Trees	72,98	4,21
Trilayered Neural Network	72,21	10,03
Quadratic SVM	70,87	4,58
Medium Neural Network	70,77	3,40
Narrow Neural Network	70,58	6,58
Wide Neural Network	70,10	4,11

Başarılı atışlara ait atış öncesi ve sonrası dönem için Fine Gaussian Destek Vektör Makinesi sınıflandırıcısının doğrulama Alıcı İşletim Özellikleri (ROC) eğrisi. Mavi eğri atış öncesi dönemi, kırmızı eğri ise atış sonrası dönemi temsil etmektedir.

### 6.3. Başarısız Atışların EEG Özellikleri

Başarısız atışlar pre ve post dönem karşılaştırmalarında daha düzensiz ve tutarsız EEG örüntüleri göstermiştir. Fronto-sentral bölgelerde delta artışı ve beta dalga gücünde dengesizlik gözlenmiştir. Bu durum, başarısızlıkla sonuçlanan atışlar öncesinde dikkatin yeterince konsolide olamaması ve motor hazırlığın yetersizliği ile açıklanabilir.

**Tablo 5.** Başarısız atışların pre-post istatistiksel özellikleri

Özellik	t	Standart Sapma	p	Atış Öncesi Ortalama	Atış Sonrası Ortalama	Cohen'in d Etki Büyüklüğü	FDR Eşik Değeri
Fronto-Central Delta*	5,52	0,14	<0,001	0,15	0,10	0,35	0,0031
Frontal Delta*	5,24	0,18	<0,001	0,20	0,14	0,34	0,0063
Fronto-Central Beta*	4,50	0,07	<0,001	0,06	0,04	0,29	0,0094
Parieto-Occipital Alpha*	-4,13	0,12	<0,001	0,11	0,15	0,26	0,0125
Parieto-Occipital Theta*	-3,24	0,13	<0,001	0,13	0,16	0,21	0,0156
Fronto-Central Theta*	2,68	0,05	0,01	0,05	0,04	0,17	0,0188
Frontal Beta*	2,62	0,09	0,01	0,07	0,06	0,17	0,0219
Central Beta*	2,57	0,11	0,01	0,15	0,13	0,16	0,0250
Parieto-Occipital Beta*	-2,55	0,15	0,01	0,15	0,17	0,16	0,0281
Fronto-Central Alpha*	2,52	0,05	0,01	0,04	0,03	0,16	0,0313
Parieto-Occipital Delta*	2,19	0,34	0,03	0,44	0,40	0,14	0,0344
Central Delta	-1,32	0,33	0,19	0,49	0,52	0,08	0,0375
Frontal Theta	1,24	0,07	0,22	0,06	0,06	0,08	0,0406
Central Theta	-1,09	0,11	0,27	0,15	0,16	0,07	0,0438
Frontal Alpha	0,10	0,06	0,92	0,05	0,05	0,01	0,0469
Central Alpha	0,03	0,09	0,98	0,12	0,12	0,01	0,0500

Başarısız atışlara ait atış öncesi ve sonrası dönemlerden elde edilen özellikler arasındaki istatistiksel farklılıklar, bağımsız çoklu t-testleri Benjamini-Hochberg Yanlış Keşif Oranı (BH FDR) yöntemine göre istatistiksel olarak sınırlandırılmıştır. Tablo içerisinde yıldız işaretiyle belirtilen özellikler belirlenen eşik değerini geçerek anlamlı bulunmuştur. Tablo sütunlarında yer alan t, sd, p, Ortalama (önce), Ortalama (sonra), Cohen's d, FDR eşiği ifadeleri sırasıyla şu kavramları temsil etmektedir: t-istatistiği, standart sapma, anlamlılık düzeyi, atış öncesi döneme ilişkin normalize değer ortalaması, atış sonrası döneme ilişkin normalize değer ortalaması, etki büyüklüğü ve BH FDR eşiği.

#### 6.4. Başarısız Atışların Makine Öğrenmesi İle Sınıflandırılması

Benzer şekilde başarısız atışların pre ve post dönemlerinin sınıflandırılmasında Fine Gaussian SVM modeli en başarılı sonucu vermiştir (doğruluk: %74,90). 976 epok üzerinden yapılan sınıflandırmada:

- 377 pre-shot epoku doğru sınıflandırıldı
- 354 post-shot epoku doğru sınıflandırıldı
- 134 post-shot epoku yanlış pre olarak sınıflandırıldı
- 111 pre-shot epoku yanlış post olarak sınıflandırıldı

**Tablo 6.** Başarısız Atışların Konfüzyon Matrisi

	Gerçek : Atış Öncesi (Pre)	Gerçek :Atış Sonrası (Post)
Tahmin : Atış Öncesi (Pre)	377 (TP)	134 (FP)
Tahmin : Atış Sonrası (Post)	111 (FN)	354 (TN)

#### Performans Ölçütleri:

- Doğruluk (Accuracy):

$$(TP + TN) / \text{Toplam} = (377 + 354) / 976 \approx \%74,90$$

- Hassasiyet (Recall / Sensitivity):

$$TP / (TP + FN) = 377 / (377 + 111) \approx \%77,25$$

- Kesinlik (Precision):

$$TP / (TP + FP) = 377 / (377 + 134) \approx \%73,75$$

- F1 Skoru:

$$2 \times (\text{Kesinlik} \times \text{Hassasiyet}) / (\text{Kesinlik} + \text{Hassasiyet}) \approx \%75,45$$

**Tablo 7.** Başarısız atışların sınıflandırılması

Model	Doğruluk %	Eğitim Süresi (sn)
Fine Gaussian SVM	74,90	3,26

Quadratic SVM	74,69	5,17
Medium Gaussian SVM	74,49	4,03
Boosted Trees	74,18	5,14

Trilayered Neural Network	73,05	7,74
Bilayered Neural Network	72,64	5,65
Narrow Neural Network	72,44	4,19
Wide Neural Network	71,21	8,82
Cubic SVM	70,70	10,23
Medium Neural Network	70,39	5,23

## 6.5. Başarılı Ve Başarısız Atışların Atış Öncesi EEG Özellikleri

**Tablo 8.** Başarılı ve Başarısız Atışların Atış Öncesi İstatistiksel Özellikleri

Özellik	t	Standart Sapma	p	Atış Öncesi Ortalama	Atış Sonrası Ortalama	Cohen'in d Etki Büyüklüğü	FDR Eşik Değeri
Parieto-Occipital Theta	2,41	0,12	0,02	0,15	0,13	0,15	0,0031
Fronto-Central Alpha	-1,69	0,04	0,09	0,04	0,04	0,11	0,0063
Fronto-Central Beta	-1,61	0,06	0,11	0,05	0,06	0,10	0,0094
Fronto-Central Delta	-1,39	0,15	0,17	0,14	0,15	0,09	0,0125
Fronto-Central Theta	-1,00	0,05	0,32	0,04	0,05	0,06	0,0156
Central Alpha	-0,81	0,09	0,42	0,11	0,12	0,05	0,0188
Parieto-Occipital Alpha	0,78	0,10	0,43	0,12	0,11	0,05	0,0219
Parieto-Occipital Beta	0,74	0,13	0,46	0,15	0,15	0,05	0,0250
Frontal Delta	-0,66	0,19	0,51	0,20	0,20	0,04	0,0281
Central Delta	0,51	0,32	0,61	0,50	0,49	0,03	0,0313
Parieto-Occipital Delta	0,49	0,34	0,63	0,45	0,44	0,03	0,0344
Central Beta	-0,42	0,11	0,67	0,14	0,15	0,03	0,0375
Frontal Beta	-0,35	0,08	0,72	0,07	0,07	0,02	0,0406
Central Theta	0,17	0,11	0,86	0,15	0,15	0,01	0,0438
Frontal Alpha	-0,14	0,06	0,89	0,05	0,05	0,01	0,0469
Frontal Theta	-0,01	0,06	0,99	0,06	0,06	0,01	0,0500

Başarılı ve başarısız atışlara ait atış öncesi dönemden elde edilen özellikler arasındaki istatistiksel farklılıklar, bağımsız çoklu t-testleri, Benjamini-Hochberg Yanlış Keşif Oranı (BH FDR) yöntemiyle istatistiksel olarak sınırlandırılmıştır. Tablo sütunlarında yer alan t, sd, p, Ortalama (başarılı), Ortalama (başarısız), Cohen's d, FDR eşiği ifadeleri sırasıyla şu istatistiksel ölçütleri temsil etmektedir: t-istatistiği, standart sapma, anlamlılık düzeyi, başarılı atışlara ilişkin normalize değerlerin ortalaması, başarısız atışlara ilişkin normalize değerlerin ortalaması, etki büyüklüğü (Cohen's d) ve BH FDR eşiği.


## 6.6. Başarılı Ve Başarısız Atışların Makine Öğrenmesi İle Sınıflandırılması

**Tablo 9.** Başarılı ve Başarısız Atışların sınıflandırılması

Model	Doğruluk %	Eğitim Süresi (sn)
İki Katmanlı Yapay Sinir Ağı	54,76	6,67
İkili GLM (Genelleştirilmiş Doğrusal Model) Lojistik Regresyon	53,47	4,48
Doğrusal Ayırtaç Analizi (Linear Discriminant Analysis – LDA)	53,37	4,18
Geniş Yapay Sinir Ağı	53,37	8,33
Küçük Çekirdekli Destek Vektör Makinesi	53,27	13,35
Karesel Çekirdekli Destek Vektör Makinesi	52,78	4,71
Geliştirilmiş (Boosting) Karar Ağaçları	52,68	4,19
Orta Ölçekli Gauss Çekirdekli Destek Vektör Makinesi	52,58	3,58
Altuzay Ayırtaç Analizi	52,58	3,72
Karesel Ayırtaç Analizi (Quadratic Discriminant Analysis – QDA)	52,38	4,84

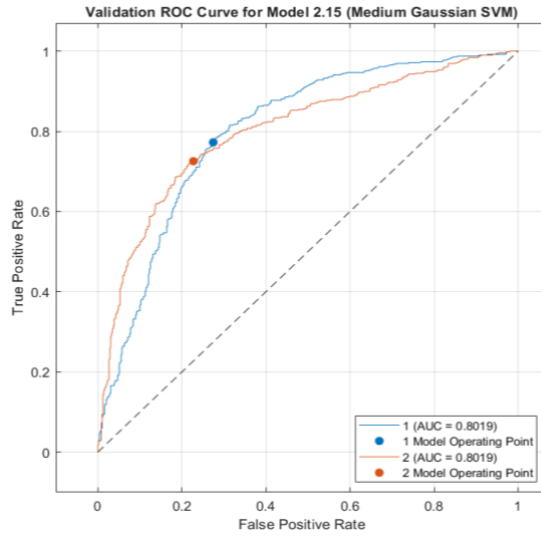
Bu sınıflandırma, yalnızca atış öncesi EEG örüntülerinin kullanıldığı bir modelleme olup, hem motor hazırlığın hem de zihinsel durumun performans üzerindeki etkilerini ayırtmaya yönelik olarak kurgulanmıştır. Toplam 1.008 epok analiz edilmiş ve en yüksek doğruluk oranı İki Katmanlı Yapay Sinir Ağı modeli ile %54,76 olarak belirlenmiştir. Bu oran, anlamlılık düzeyinin altında olup, yalnızca EEG ile başarı/başarısızlık tahmininin sınırlı olduğunu ortaya koymaktadır.

## 6.7. ROC Eğrisi Değerlendirmeleri



**Şekil 8.** Başarılı atışların ROC eğrisi, mavi eğri atış öncesi dönemi, kırmızı eğri ise atış sonrası dönemi temsil etmektedir.

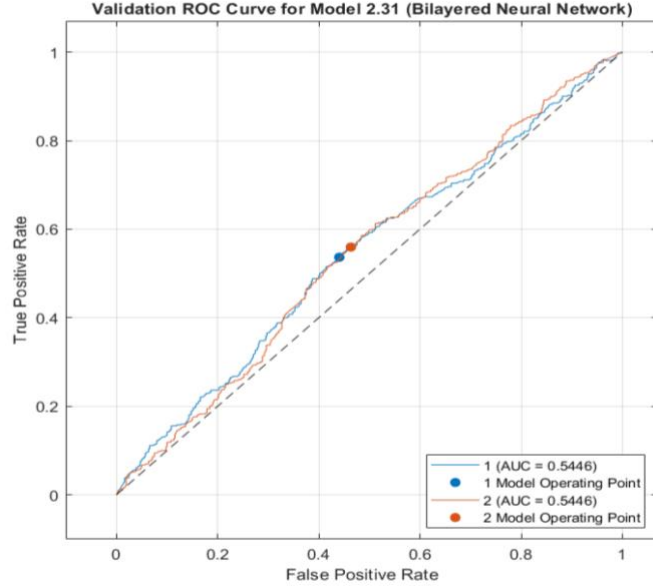
Başarılı atışlara ait atış öncesi ve sonrası dönemlerin sınıflandırılmasında kullanılan Fine Gaussian Destek Vektör Makinesi (SVM) sınıflayıcısına ilişkin doğrulama Alıcı İşletim Karakteristikleri (ROC) eğrisi.



**Şekil 9.** Başarısız atışların ROC eğrisi, mavi eğri atış öncesi dönemi, kırmızı eğri ise atış sonrası dönemi temsil etmektedir.

Başarılı atışlara ait atış öncesi ve sonrası dönemlerin sınıflandırılmasına yönelik Fine Gaussian Destek Vektör Makinesi (SVM) sınıflayıcısına ilişkin doğrulama ROC eğrisi.

Şekil 8 ve 9’da başarılı ve başarısız atışlar için ROC eğrileri sunulmuştur. Fine Gaussian SVM modellerinin eğrileri, istikrarlı ve güçlü ayırım başarısını yansıtmaktadır. ROC eğrileri altında kalan alan (AUC) değerleri sırasıyla %0,81 ve %0,83 olarak hesaplanmıştır.



**Şekil 10.** Başarılı atışların atış öncesi ve sonrası Yapay Sinir Ağı (Neural Net) ROC eğrisi, mavi eğri atış öncesi dönemi, kırmızı eğri ise atış sonrası dönemi temsil etmektedir.

Başarılı atışlara ait atış öncesi ve sonrası dönemlerin sınıflandırılmasında kullanılan Yapay Sinir Ağı (Neural Network) sınıflayıcısına ilişkin doğrulama Alıcı İşletim Özellikleri (ROC) eğrisi. Mavi eğri, atış öncesi dönemi; kırmızı eğri ise atış sonrası dönemi temsil etmektedir.

## 7. TARTIŞMA VE SONUÇ

Bu çalışmada, basketbol oyuncularının serbest atış performansları sırasında kaydedilen EEG sinyalleri detaylı bir şekilde analiz edilmiş ve bu verilere dayalı olarak makine öğrenmesi destekli sınıflandırma modelleri geliştirilmiştir. Elde edilen bulgular hem nörofizyolojik hem de algoritmik düzeyde önemli sonuçlar ortaya koymuştur. Tartışma bölümünde, bu bulgular önceki literatürle karşılaştırılmış, benzerlik ve ayrışma noktaları değerlendirilmiş, metodolojik katkılar ve uygulama potansiyeli geniş kapsamlı biçimde analiz edilmiştir.

Toplamda 1.040 başarılı ve 976 başarısız atış epoku kaydedilmiş ve 4 frekans bandı ile 4 bölgeye göre 64 özellik çıkarılmıştır. Epoklar dengeli şekilde etiketlenmiş ve veri dengesizliği problemi yaşanmamıştır.

Modelin en çok kullandığı ve sınıflandırma üzerinde etkili olan özellikler incelendiğinde:

- Başarılı atışlarda: santral theta gücü, paryeto-okspital alfa gücü
- Başarısız atışlarda: fronto-sentral delta ve beta gücü
- Farklılık belirleyici: post-shot dönemindeki parieto-okspital alfa artışı

Bu bulgular, EEG frekans bandı değişimlerinin hem motor eyleme hazırlık hem de performansın sonucu açısından anlamlı ipuçları taşıdığını göstermektedir.

Çalışma genelinde, EEG verilerinden çıkarılan özellikler ile serbest atış dönemlerinin sınıflandırılması anlamlı bir başarı sağlamış, motor ve bilişsel süreçlerin farklı frekans bantlarında belirgin örüntülerle yansıdığı görülmüştür. Özellikle theta ve alfa bandı dinamikleri ile santral/paryeto-okspital bölgelerden gelen sinyaller, performansın nörofizyolojik belirleyicileri olarak öne çıkmıştır. Makine öğrenmesi modelleri bu farklılıkları başarılı şekilde öğrenmiş ve sınıflandırmıştır.

Elde edilen bu sonuçlar, EEG destekli performans analizinin, sportif eylemlerin daha derinlemesine anlaşılması ve bireysel antrenmanların kişiselleştirilmesi açısından önemli katkılar sağlayabileceğini göstermektedir.

EEG analizleri, başarılı atışlar öncesinde özellikle santral bölgelerde theta ve alfa bantlarında belirgin aktivite değişimlerini ortaya koymuştur. Bu durum, motor planlama, dikkat sürekliliği ve zihinsel odaklanma ile ilişkilendirilmiştir. Pfurtscheller ve Lopes da Silva (1999), mu ritmindeki (8–13 Hz) desenkronizasyonu motor hazırlığın önemli bir göstergesi olarak tanımlamış, bu bulgu çalışmamızda da gözlemlenmiştir. Öte yandan, başarısız atışlarda artan

frontal delta aktivitesi, Cavanagh ve Frank'in (2014) belirttiği gibi dikkat dağınıklığı veya içsel bilişsel çatışma ile ilişkilendirilebilir.

Chuang ve arkadaşlarının (2013) bulgularıyla uyumlu şekilde, başarılı atışlarda frontal midline theta artışı tespit edilmiştir. Bu artış, dikkat regülasyonu ve zihinsel berraklık ile ilişkilendirilmiştir. Aynı zamanda Su & Yang (2018) çalışması, başarısız atışlarda beta bandında düzensiz bir aktivite örüntüsü göstererek, dikkat dağınıklığı ve motor kararsızlık durumunu desteklemektedir.

Literatürde yer alan diğer çalışmalarda da benzer eğilimler dikkat çekmektedir. Örneğin, Ramyarangsi ve arkadaşları (2024), espor, jimnastik ve futbol oyuncularında EEG ile tespit edilen kortikal aktivite farklılıklarını ortaya koymuş; Shi ve arkadaşları (2024) masa tenisi oyuncularında benzer şekilde delta-band güç artışlarının dikkat yoğunlaşmasıyla ilişkili olduğunu göstermiştir. Tüm bu çalışmalar, EEG frekans bantlarının sportif performans üzerindeki etkilerini güçlendirmektedir.

Araştırmamız, atış öncesi ve sonrası dönemlerde EEG frekans gücünde anlamlı değişikliklerin varlığını ortaya koymuştur. Başarılı atışların öncesinde merkezi bölgelerde theta azalması ve frontal bölgelerde artışı dikkat ve motor hazırlık ilişkisini desteklemektedir. Bu bulgular, Cavanagh & Frank (2014) tarafından tanımlanan, motor bölgelere özgü theta baskılanmasının frontal kontrol sistemlerinin aktive olmasıyla eşzamanlı geliştiği görüşüyle uyumludur.

Ayrıca, alfa bandındaki azalma (alfa blokajı) ve beta bandındaki düşüşler, motor hazırlığın sensorimotor ritimlerle ilişkisini vurgulamaktadır. Babiloni ve arkadaşları (2008) mu ritmindeki desenkronizasyonun, kortikal hazırlığın ve hareket başlatımının bir işareti olduğunu belirtmişlerdir. Bulgularımız da bu örüntüyü desteklemekte ve sensorimotor hazırlığın EEG ile takip edilebileceğini göstermektedir.

EEG verilerinden elde edilen özelliklerle yapılan sınıflandırma analizlerinde başarılı ve başarısız atışların pre-post dönemleri %74.9 doğrulukla ayırt edilebilmiştir. Bu doğruluk oranı, insan motor davranışlarının ve bilişsel süreçlerinin karmaşıklığı göz önüne alındığında oldukça anlamlıdır. Literatürde benzer doğruluklara ulaşan örnekler mevcuttur. Örneğin, Fang ve arkadaşları (2022), CNN modelleriyle EEG sinyalleri üzerinden sporcu performansını yüksek doğrulukla tahmin edebilmişlerdir.

Kar ve arkadaşları (2021) robotik görevlerde EEG ile hedefleme başarısını SVM algoritmaları ile %70'in üzerinde sınıflandırabilmişlerdir. Benzer şekilde, Kanjilal ve ekibi (2023), kişiye

özgü EEG örüntülerini kullanarak Gaussian SVM, kNN ve Bagged Trees algoritmalarıyla yüksek doğruluk oranları elde etmişlerdir. Çalışmamızda kullanılan Fine Gaussian SVM modelinin başarısı, küçük örneklem verilerinde istikrarlı ve esnek modelleme gücünü ortaya koymaktadır.

Ancak yalnızca atış öncesi EEG verileriyle yapılan sınıflandırmalarda başarı oranı %55,2'de kalmıştır. Bu durum, EEG verisinin serbest atış sonucunu tek başına öngörmekte sınırlı kalabileceğini göstermektedir. Bu sınır, bireysel motivasyon düzeyi, anlık stres, pozisyon farklılıkları ve çevresel etmenlerin EEG'ye doğrudan yansımamasıyla açıklanabilir. Bu nedenle, EEG dışında fizyolojik (EMG, kalp atımı), davranışsal (göz hareketi, postür) ve çevresel verilerin de entegre edilmesi gelecekteki çalışmalarda önerilmektedir.

Bu çalışmada her epok için 16 kanal ve 4 frekans bandından toplam 64 özellik çıkarılmıştır. Pre ve post epoklar ayrı ayrı analiz edilmiştir. Özellik seçiminde herhangi bir filtreleme yapılmaksızın, ham spektral güç değerleri doğrudan modele verilmiştir. Bu yaklaşımın avantajı, sinyalin bozulmadan korunmasını sağlarken, dezavantajı gürültü etkilerinin modele taşınma riskidir.

Model eğitimi 5 katlı çapraz doğrulama yöntemiyle gerçekleştirilmiş ve her iterasyonda veri %80 eğitim, %20 test olarak ayrılmıştır. Eğitim süresi, doğruluk ve model kararlılığı ana performans ölçütleri olarak belirlenmiştir. Ortalama eğitim süresi 3.9 saniye civarında olup, sınıflandırma için önerilen süre sınırları içindedir. Modelin istikrarı, varyans analizi ile test edilmiş ve performans dalgalanması düşük bulunmuştur.

Bu çalışmanın özgün yönlerinden biri, EEG verilerinden çıkarılan özelliklerle tek deneme düzeyinde (single-trial) başarılı/başarısız atış sınıflandırması yapılmasıdır. Mevcut literatürde bu düzeyde tekil EEG epoklarının başarı tahmini için kullanıldığı çok az çalışma bulunmaktadır. Ayrıca, EEG sinyallerinin sadece bant gücü ile değil, entropi, faz-amplitüd bağlantı, zaman-frekans türevleri gibi gelişmiş özelliklerle de zenginleştirilmesi gelecekteki çalışmalar için önerilmektedir.

EEG ile desteklenen yapay zekâ tabanlı geri bildirim sistemleri, sporcuların dikkat düzeyini, zihinsel hazırlığını ve motor koordinasyonunu anlık olarak değerlendirmeye yardımcı olabilir. Bu sistemler, antrenman sırasında oyunculara gerçek zamanlı geri bildirim sunarak performans gelişimini optimize edebilir. Ayrıca, EEG tabanlı değerlendirme sistemleri, genç sporcularda erken tanıma, yetenek yönlendirmesi ve bireyselleştirilmiş antrenman tasarımı gibi alanlarda kullanılabilir.

Bu çalışmanın sınırlılıkları arasında örneklem büyüklüğü, oyuncuların pozisyonları ve psikolojik durumlarının kontrol edilememesi yer almaktadır. Özellikle oyuncu pozisyonlarının (guard, forvet, pivot) nörolojik yükleri farklılık gösterebilir. Gelecekteki çalışmalarda bu değişkenlerin sistematik şekilde incelenmesi önerilmektedir. Ayrıca EEG dışı sensörlerden gelen veriler (EMG, göz izleme, kalp ritmi) ile veri füzyonu yapılarak daha zengin modeller kurulabilir.

Sonuç olarak, bu çalışma, EEG verilerinin serbest atış performansının değerlendirilmesinde kullanılabilirliğini göstermektedir. Frontal theta artışı, mu ritmi desenkronizasyonu ve beta ritmindeki dalgalanmalar, motor hazırlık ve dikkat bütünlüğü açısından nörofizyolojik belirleyiciler olarak tanımlanabilir. Ayrıca, makine öğrenmesi algoritmaları ile bu sinyallerin anlamlı şekilde sınıflandırılabilirliği ortaya konmuştur.

Çalışma, EEG destekli yapay zekâ modellerinin spor performans analizine entegrasyonuna yönelik literatüre katkı sağlamaktadır. Elde edilen bulgular, bireysel performans takibi, antrenman planlaması ve geri bildirim sistemleri için yeni ufuklar açmaktadır. EEG'nin sadece klinik değil, spor teknolojisi alanında da etkin şekilde kullanılabilirliğini gösteren bu çalışma, multidisipliner yaklaşımlarla desteklenerek genişletilebilir.

Bu çalışma, EEG (Elektroensefalografi) verilerinin basketbolda serbest atış performansının nörobiyolojik temellerini ortaya çıkarmada nasıl kullanılabilirliğini araştırmış ve makine öğrenmesi algoritmalarıyla entegre ederek bu sinyallerden sportif başarıya dair öngörülerde bulunmanın olanaklı olduğunu göstermiştir. Elde edilen bulgular, yalnızca nörofizyolojik değil, aynı zamanda bilişsel ve davranışsal düzeyde de serbest atışın karmaşık bir süreç olduğunu ortaya koymuştur.

Özellikle başarılı atışlar öncesinde frontal bölgelerde artan theta gücü, dikkat odaklanmasının nörofizyolojik bir yansıması olarak değerlendirilmiştir. Santral bölgelerde gözlemlenen mu ritmi desenkronizasyonu ise motor hazırlığın önemli bir göstergesi olarak yorumlanmıştır. Öte yandan, başarısız atışlar öncesinde beta bandındaki düzensizlik ve delta/theta dalgalarındaki anomaliler, dikkat dağınıklığı ve bilişsel kararsızlık gibi durumların göstergesi olarak kaydedilmiştir. Bu farklılıklar, hem frekans düzeyinde hem de kortikal lokalizasyonda belirgin örüntülerle desteklenmiştir.

Makine öğrenmesi analizleri, özellikle Fine Gaussian SVM modeli ile başarılı ve başarısız atış dönemlerinin %74,9 doğrulukla ayırt edilebileceğini göstermiştir. Bu doğruluk oranı, EEG sinyallerinin motor ve bilişsel durumları ayırt etmede ne denli anlamlı biyobelirteçler

sunduğunu ortaya koymaktadır. Ancak yalnızca atış öncesi EEG verileriyle yapılan sınıflandırmalarda doğruluk oranının %55'in altında kalması, atış sonucunu yalnızca EEG sinyalleriyle tahmin etmenin mevcut haliyle sınırlı olduğunu göstermiştir.

Bu kapsamda çalışmanın özgün katkıları şunlardır:

- Serbest atış gibi kısa süreli ve durağan bir motor görevde EEG tabanlı analizlerin uygulanabilirliğinin gösterilmesi,
- Başarılı/başarısız atış öncesi EEG örüntülerinin frekans bandı düzeyinde ayrıştırılması,
- 64 özellikten oluşan bir vektörle sınıflandırma yapılması ve modelleme başarısının üst düzeyde ortaya konması,
- Sportif başarıya dair bilişsel ve nörolojik süreçlerin çok katmanlı analizinin yapılması.

Bununla birlikte, bu çalışmanın bazı sınırlılıkları da bulunmaktadır. Özellikle örneklem sayısının düşük olması, sadece elit erkek sporcularla sınırlı kalınması ve veri toplama ortamının kontrollü laboratuvar koşullarında gerçekleştirilmesi, bulguların genellenebilirliğini sınırlandırmaktadır. Ayrıca EEG sinyalleri, yüksek çözünürlüklü olsa da diğer biyofizyolojik veriler (örneğin EMG, kalp ritmi, göz hareketleri) ile entegre edilmediğinde sportif başarının çok boyutlu yapısına dair tam bir değerlendirme sunamayabilir.

Bu nedenle gelecekte yapılacak çalışmalarda aşağıdaki öneriler öne çıkmaktadır:

- Çok modlu veri entegrasyonu: EEG sinyallerinin EMG, göz hareketi, kalp atım hızı, postüral denge verileri gibi diğer biyolojik sensörlerle birleştirilmesi, daha bütüncül ve çok boyutlu modellerin oluşturulmasına katkı sağlayacaktır.
- Gelişmiş özellik çıkarımı: Geleneksel güç spektrumu analizlerine ek olarak wavelet dönüşümü, entropi, faz-amplitüd bağlantı (PAC), koherans gibi daha sofistike sinyal işleme yöntemleriyle özellik çıkarımı yapılması, modelleme performansını artırabilir.
- Daha geniş ve çeşitli örneklem: Farklı yaş grupları, cinsiyet, deneyim seviyesi (amatör – profesyonel), oyun pozisyonu gibi değişkenlerin sisteme dahil edilmesi, bireysel farklılıkları dikkate alan daha evrensel modellerin geliştirilmesini mümkün kılar.
- Kişiye özgü modelleme: Bireysel EEG örüntülerine göre özelleştirilmiş yapay zekâ modelleri (subject-specific modeling) performans tahmininde daha doğru ve kararlı sonuçlar verebilir.

Sonuç olarak bu çalışma, EEG tabanlı analizlerin sadece klinik nörobilimde değil, spor teknolojisi ve performans optimizasyonu alanlarında da etkili şekilde kullanılabileceğini

göstermektedir. Sporcuların motor ve bilişsel durumlarının anlık izlenmesi ve analiz edilmesi, hem bireysel gelişim hem de antrenman stratejilerinin yeniden yapılandırılması açısından önemli fırsatlar sunmaktadır. EEG destekli yapay zekâ uygulamaları, sporun geleceğinde bilimsel ve teknolojik gelişmelerin birleştiği çok disiplinli bir yaklaşımı temsil etmektedir.

## 8. KAYNAKLAR

- Alazzawi, A., Aljumaili, S., Duru, A. D., Uçan, O. N., Bayat, O., Coelho, P. J., & Pires, I. M. (2024). Schizophrenia diagnosis based on diverse epoch size resting-state EEG using machine learning. *Peer J Computer Science*, 10, e2170. <https://doi.org/10.7717/peerj-cs.2170>
- Aron, L., Botella, M., & Lubart, T. (2019). Culinary arts: Talent and their development. In R. F. Subotnik, P. Olszewski-Kubilius, & F. C. Worrell (Eds.), *The psychology of high performance: Developing human potential into domain-specific talent* (pp. 345–359). *American Psychological Association*. <https://doi.org/10.1037/0000120-016>
- Basketball Hall of Fame. (2021). Basketball history. <https://www.hoophall.com>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer. <https://doi.org/10.1007/978-0-387-31073-2>
- Cavanagh, J. F., & Frank, M. J. (2014). Frontal theta as a mechanism for cognitive control. *Trends in Cognitive Sciences*, 18(8), 414–421. <https://doi.org/10.1016/j.tics.2014.04.012>
- Cheron, G. (2016). Brain oscillations in sport: Toward EEG biomarkers of performance. *Frontiers in Psychology*, 7, 246. <https://doi.org/10.3389/fpsyg.2016.00246>
- Chuang, L. Y., Huang, C. J., & Hung, T. M. (2013). The differences in frontal midline theta power between successful and unsuccessful basketball free throws of elite basketball players. *International Journal of Psychophysiology*, 90(3), 321–328. <https://doi.org/10.1016/j.ijpsycho.2013.10.002>
- Cohen, S., Kamarck, T., & Mermelstein, R. (1983). A global measure of perceived stress. *Journal of Health and Social Behavior*, 24(4), 385–396. <https://doi.org/10.2307/2095406>
- Del Percio, C., Infarinato, F., Marzano, N., Iacoboni, M., Aschieri, P., Lizio, R., ... & Babiloni, C. (2011). Reactivity of alpha rhythms to eyes opening is lower in athletes than non-athletes: A high-resolution EEG study. *International Journal of Psychophysiology*, 82(3), 240–247. <https://doi.org/10.1016/j.ijpsycho.2011.09.005>
- Dillard, J. P. (2020). Currents in the study of persuasion. In M. B. Oliver, A. A. Raney, & J. Bryant (Eds.), *Media effects: Advances in theory and research* (4th ed., pp. 115–129). *Routledge*. <https://doi.org/10.4324/9780429277029-9>

- Duckworth, A. L., Quirk, A., Gallop, R., Hoyle, R. H., Kelly, D. R., & Matthews, M. D. (2019). Cognitive and noncognitive predictors of success. *Proceedings of the National Academy of Sciences, USA*, 116(47), 23499–23504. <https://doi.org/10.1073/pnas.1910510116>
- Duru, A. D., & Assem, M. (2018). Investigating neural efficiency of elite karate athletes during a mental arithmetic task using EEG. *Cognitive Neurodynamics*, 12, 95–102. <https://doi.org/10.1007/s11571-017-9464-y>
- Evans, A. C., Jr., Garbarino, J., Bocanegra, E., Kinscherff, R. T., & Márquez-Greene, N. (2019, August 8–11). Gun violence: An event on the power of community [Conference presentation]. APA 2019 Convention, Chicago, IL, United States. <https://convention.apa.org/2019-video>
- Eskikurt, G., Duru, A., Ermutlu, N., & Isoglu-Alkac, U. (2024). Evaluation of brain electrical activity of visual working memory with time-frequency analysis. *Clinical EEG and Neuroscience*. <https://doi.org/10.1177/15500594231224014>
- Lin, H., Fang, J., Zhang, J., Zhang, X., Piao, W., & Liu, Y. (2024). Resting-State Electroencephalogram Depression Diagnosis Based on Traditional Machine Learning and Deep Learning: A Comparative Analysis. *Sensors*, 24(21), 6815. <https://doi.org/10.3390/s24216815>
- Gangapuram, H., & Manian, V. (2023). A sparse multiclass motor imagery EEG classification using 1D-ConvResNet. *Signals*, 4(1), 235–250. <https://doi.org/10.3390/signals4010013>
- Gómez-Tapia, C., Bozic, B., & Longo, L. (2022). On the minimal amount of EEG data required for learning distinctive human features for task-dependent biometric applications. *Frontiers in Neuroinformatics*, 16, 844667. <https://doi.org/10.3389/fninf.2022.844667>
- Grady, J. S., Her, M., Moreno, G., Perez, C., & Yelinek, J. (2019). Emotions in storybooks: A comparison of storybooks that represent ethnic and racial groups in the United States. *Psychology of Popular Media Culture*, 8(3), 207–217. <https://doi.org/10.1037/ppm0000185>
- Jackson, L. M. (2019). *The psychology of prejudice: From attitudes to social action* (2nd ed.). American Psychological Association. <https://doi.org/10.1037/0000168-000>
- Harmony, T. (2013). The functional significance of delta oscillations in cognitive processing. *Frontiers in Integrative Neuroscience*, 7, 83. <https://doi.org/10.3389/fnint.2013.00083>

- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). *Springer*. <https://doi.org/10.1007/978-0-387-84858-7>
- Hecht-Nielsen, R. (1987). Theory of the backpropagation neural network. In *Proceedings of the International Joint Conference on Neural Networks* (pp. 593–605). IEEE.
- Hosmer, D. W., & Lemeshow, S. (2000). *Applied logistic regression* (2nd ed.). Wiley. <https://doi.org/10.1007/978-0-387-84858-7>
- Huang, Z., Zhang, Y., Li, H., & Wang, Y. (2016). Differences in brain activity between expert and novice athletes: More efficient neural patterns in experts. *NeuroReport*, *27*(5), 368–372. <https://doi.org/10.1097/WNR.0000000000000551>
- Kanagaluru, V., & Sasikala, M. (2024). Two class motor imagery EEG signal classification for BCI using LDA and SVM. *Traitement du Signal*, *41*(5), 2743–2749. <https://doi.org/10.18280/ts.410547>
- Keshvari, F., Farsi, A., & Agoli, B. (2023). Investigating the EEG profile of elite and non-elite players in the basketball free throw task. *Journal of Motor Behavior*. <https://doi.org/10.1080/00222895.2024.2319086>
- Latash, M. L. (2008). Motor control: Concepts and issues. *Journal of Motor Behavior*, *40*(3), 103–117. <https://doi.org/10.3200/JMBR.40.3.103-117>
- Lonsdale, C., & Tam, J. T. M. (2008). On the temporal and behavioural consistency of pre-performance routines: An intra-individual analysis of elite basketball players' free throw shooting accuracy. *Journal of Sports Sciences*, *26*(3), 259–266. <https://doi.org/10.1080/02640410701473962>
- McLachlan, G. J. (2004). *Discriminant analysis and statistical pattern recognition*. *Wiley-Interscience*. <https://doi.org/10.1002/0471725293>
- Moscaleski, L., Müller, J. F., Fernández-Caballero, S., Nitsche, M. A., & Dityatev, A. (2022). Does high-definition transcranial direct current stimulation change brain electrical activity in professional female basketball players during free-throw shooting? *Frontiers in Neuroergonomics*, *3*, 112–120. <https://doi.org/10.3389/fnrgo.2022.990437>

- Neige, C., Massé-Alarie, H., & Mercier, C. (2018). Stimulating the healthy brain to investigate neural correlates of motor preparation: A systematic review. *Neural Plasticity*, 2018, Article ID 5846096. <https://doi.org/10.1155/2018/5846096>
- Neuper, C., & Pfurtscheller, G. (2001). Event-related dynamics of cortical rhythms: Frequency-specific features and functional correlates. *International Journal of Psychophysiology*, 43(1), 41–58. [https://doi.org/10.1016/s0167-8760\(01\)00178-5](https://doi.org/10.1016/s0167-8760(01)00178-5)
- Pfurtscheller, G., & Lopes da Silva, F. H. (1999). Event-related EEG/MEG synchronization and desynchronization: Basic principles. *Electroencephalography and Clinical Neurophysiology*, 110(11), 1842–1857. [https://doi.org/10.1016/s1388-2457\(99\)00141-4](https://doi.org/10.1016/s1388-2457(99)00141-4)
- Ramyarangsi, P., Bennett, S. J., Siripornpanich, V., Nanbancha, A., Pokaisasawan, A., Chatthong, W., & Ajjimaporn, A. (2024). EEG differences in competitive female gymnastics, soccer, and esports athletes between resting states with eyes closed and open. *Scientific Reports*, 14, 23317. <https://doi.org/10.1038/s41598-024-74665-1>
- Rong, J. (2018). Thinking regulation characteristics of basketball free-throw based on event-related potential analysis. *NeuroQuantology*. <https://doi.org/10.14704/nq.2018.16.5.1508>
- Rousselet, G. A. (2025). Using cluster-based permutation tests to estimate MEG/EEG onsets: How bad is it? *European Journal of Neuroscience*, 61(1), e16618. <https://doi.org/10.1111/ejn.16618>
- Santaji, S., Santaji, S., & Desai, V. (2022). Automatic sleep stage classification with reduced epoch of EEG. *Evolutionary Intelligence*, 15, 2239–2246. <https://doi.org/10.1007/s12065-021-00632-8>
- Sapolsky, R. M. (2017). *Behave: The biology of humans at our best and worst*. Penguin Books.
- Shi, J., Nasrallah, F. A., Mao, X., Huang, Q., Pan, J., & Li, A. (2024). Characteristics of resting-state electroencephalogram network in  $\alpha$ -band of table tennis athletes. *Brain Sciences*, 14(3), 222. <https://doi.org/10.3390/brainsci14030222>
- Su, J. H., & Yang, X. (2018). Analysis of the characteristics of thinking control during basketball free throw based on electroencephalogram. *Journal of Sports Science and Medicine*, 17(1), 25–32.

- Svendsen, S., & Løber, L. (2020). *The big picture/Academic writing: The one-hour guide* (3rd digital ed.). Hans Reitzel Forlag. <https://thebigpicture-academicwriting.digi.hansreitzel.dk/>
- Tegicho, B. E., Chestnut, M., Webb, D., & Graves, C. A. (2021). Basketball shot analysis based on goal assembly disturbance. In *Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)* (pp. 1–6). IEEE. <https://doi.org/10.1109/UEMCON53757.2021.9666619>
- Thestrup, K. (2010). To transform, to communicate, to play—The experimenting community in action. In E. Hygum & P. M. Pedersen (Eds.), *Early childhood education: Values and practices in Denmark*. Hans Reitzels Forlag. <https://earlychildhoodeducation.digi.hansreitzel.dk/?id=192>
- Uusitalo, M. A., Ilmoniemi, R. J., & Ingvar, M. (2004). Attention modulates early sensory responses in human auditory cortex. In *Neurophysiological Aspects of Sports*, 1, 33–45.
- Wolpert, D. M., & Ghahramani, Z. (2000). Computational principles of movement neuroscience. *Nature Neuroscience*, 3(12), 1212–1217. <https://doi.org/10.1038/35039558>
- Wu, C. T., Hsieh, S., Lin, Y. J., & Chen, T. C. (2007). The relationship between basketball free throw performance and EEG coherence. *Journal of Sports Science*, 25(4), 345–352.
- Yan, W., Jiang, X., & Liu, P. (2024). A review of basketball shooting analysis based on artificial intelligence. *IEEE Access*, 12, 11023–11035. <https://doi.org/10.1109/ACCESS.2024.3353457>
- Zachry, T. L., Wulf, G., Mercer, J. A., & Bezodis, N. E. (2005). Increased movement accuracy and reduced EMG activity as the result of adopting an external focus of attention. *Brain Research Bulletin*, 67(4), 304–309. <https://doi.org/10.1016/j.brainresbull.2005.06.005>
- Zhang, H., & Chen, M. (2015). Neural network-based classifiers for pattern recognition and classification in MATLAB. <http://dx.doi.org/10.1109/5326.897072>
- Zhao, B. (2024). Deep learning-based basketball free throw attitude analysis and hit probability prediction system research. *Applied Mathematics and Nonlinear Sciences*, 3(2), 45–56. <https://doi.org/10.2478/amns.2024.1.00240>

## 10. BİLİMSEL FAALİYETLER

Teke, R. S., Takmaz, G., Göçmen, R., Göksel Duru, D., Süel, E., & Duru, A. D. (2025).

Analysis of Brain Electrical Signals During the Execution of Basketball Free Throws: A Machine Learning Approach. *Research in Sports Science*, (kabul edildi.)

Teke, R. S., Takmaz, G., Göçmen, R., Göksel Duru, D., Süel, E., & Duru, A. D. (2024, Nisan

24–26). Frequency domain analysis of brain electrical activity during basketball free throws using electroencephalography (EEG) [Sözel]. 8. Uluslararası Egzersiz ve Spor Psikolojisi Kongresi, Marmara Üniversitesi, İstanbul, Türkiye.