Haliç Üniversitesi Sağlık Bilimleri Dergisi 2026
Özel Sayı: 2. Cansağlığı Uluslararası Tıp Öğrenci Kongresi Sayfa no: 47-56

Halic University Journal of Health Sciences 2026
Special Issue: 2nd International Medical Student Conference Page no: 47-56

ISSN: 2618-625X
e-ISSN: 2667-5765

*Sorumlu Yazar/Corresponding Author, hacerbusra.aslan@st.uskudar.edu.tr
Aslan HB, ORCID: 0009-0002-8343-798X
Doi: 10.48124/husagbilder.1951198 Geliş tarihi: 14 Mayıs 2026 Kabul tarihi: 30 Temmuz 2026

Systematic Review / Sistematik Derleme

Fonksiyonel Bağlantısallık Çerçevesinde Makine Öğrenmesinin OKB Şiddeti Tahmininde Kullanılması: Derleme Çalışması

The Use of Machine Learning in the Prediction of OCD Severity within the Framework of Functional Connectivity: A Review Study

Hacer Büşra ASLAN[1*]

[1] Üsküdar Üniversitesi, Sağlık Bilimleri Enstitüsü, Nörobilim Anabilim Dalı, İstanbul, Türkiye

ÖZ

Obsesif Kompulsif Bozukluk (OKB) farklı tür ve şiddetlerde görülebilen, tanı koyma sürecinde bütüncül analiz gerektiren bir bozukluktur. Fakat semptom şiddeti belirlemede kesin ve doğru sonuçlara ulaşılmayabilmektedir. Bu doğrultuda, nörobiyolojik değişiklikler değerlendirilen EEG ve fMRI verileri makine öğrenmesiyle analiz edilerek daha objektif sonuçlar elde edilmesi hedeflenmektedir. Bu derlemenin amacı, OKB'de fonksiyonel bağlantısallık temelli EEG ve fMRI yöntemleri aracılığıyla elde edilen fonksiyonel bağlantısallık verilerinin makine öğrenmesi (ML) yöntemleriyle analiz edilerek şiddet tahmini potansiyelini incelemektir. Derlemede, PubMed, Scopus ve Google Scholar veri tabanlarında son 6 yıl içindeki araştırmalar taranmıştır. OKB'li bireylerde EEG ve fMRI/rsfMRI teknikleriyle ML algoritmalarını birleştirerek OKB semptom şiddetini (ör. Y-BOCS skorları) tahmin eden özgün makaleler dahil edilmiştir. Derlemeye, meta analiz, editoryal çalışmalar, fonksiyonel bağlantısallık verilerini içermeyen çalışmalar, semptom şiddetiyle ilgili bulgu içermeyen çalışmalar ve hayvan deneyleri dahil edilmemiştir. Fonksiyonel bağlantısallık temel alınarak yapılan EEG ve fMRI çalışmalarına bakıldığında, varsayılan mod ağı (DMN), fronto-parietal kontrol ağı, orbitofrontal korteks (OFC), dorsolateral prefrontal korteks (DLPFC), kortiko-striatal yolakta fonksiyonel bağlantısallık açısından bozulmalar olduğu görülmüştür. Semptom şiddeti açısından fonksiyonel bağlantılar ve Y-BOCS skorlarına bakıldığında bağlantılardaki değişimlerin semptom şiddetiyle ilgili olabileceği görülmektedir. Makine öğrenimi açısından ele alındığında, SVM, Random Forest ve KNN gibi ML yöntemlerinin semptom şiddetini tahmin etmede kullanılabileceği görülmektedir. Sonuç olarak, fonksiyonel bağlantısallık temelli EEG ve fMRI verilerinin makine öğrenimiyle analiz edilmesi, klinik bağlamda tanı, semptom şiddetinin doğru belirlenmesi ve kişiye özgü tedaviler için önemli bir yer tutmaktadır. Bu bağlamda, OKB şiddet tahmininde makine öğreniminin kullanılması henüz yeterli güvenirlilikte olmasa da klinik karar sistemleri için potansiyel taşımaktadır.

Anahtar Kelimeler: EEG, fMRI, fonksiyonel bağlantısallık, kortikostriatal yolak, makine öğrenimi, obsesif kompulsif bozukluk.

ABSTRACT

Obsessive-compulsive disorder (OCD) is a disorder that can be seen in various types and severity levels, requiring a holistic analysis in the diagnostic process. However, certain and correct results in determining symptom severity may not always be achieved. Therefore, this review aims to obtain more objective results by analyzing EEG and fMRI data, which assess neurobiological changes, using machine learning. The purpose of this review is to examine the potential of predicting OCD symptom severity by analyzing functional connectivity data obtained through functional connectivity-based EEG and fMRI methods using machine learning (ML) methods. This review included research from the PubMed, Scopus, and Google Scholar databases covering the past 6 years. Original articles that predict OCD symptom severity (e.g., Y-BOCS scores) in individuals with OCD by combining EEG and fMRI/rsfMRI techniques with ML algorithms were included. Meta-analyses, editorial studies, studies lacking functional connectivity data, studies without findings related to symptom severity, and animal experiments were excluded from the review. EEG and fMRI studies based on functional connectivity revealed impairments in functional connectivity in the default mode

network (DMN), frontoparietal control network, orbitofrontal cortex (OFC), dorsolateral prefrontal cortex (DLPFC), and cortico-striatal pathway. When functional connectivity and Y-BOCS scores are examined in relation to symptom severity, changes in connectivity appear to be related to symptom severity. From a machine learning perspective, ML methods such as SVM, Random Forest, and KNN can be used to predict symptom severity. In conclusion, the analysis of functional connectivity-based EEG and fMRI data using machine learning holds significant importance in clinical diagnosis, accurate determination of symptom severity, and personalized treatments. In this context, while the use of machine learning in predicting OCD severity is not yet sufficiently reliable, it holds potential for clinical decision-making systems.

Keywords: EEG, fMRI, functional connectivity, corticostriatal pathway, machine learning, obsessive-compulsive disorder.

1. Giriş

Obsesif Kompulsif Bozukluk (OKB), obsesyon (takıntı) ve/veya kompulsiyonların (zorlantı) eşlik ettiği Obsesif Kompulsif Bozukluk ve İlişkili Bozuklar başlığı altında sınıflandırılan bir psikiyatrik bir bozukluk olarak tanımlanmaktadır. DSM- 5 tanı kriterlerine göre istenmeden ve zorla gelen, kişide anksiyete ya da sıkıntıya neden olan yineleyici düşünceler ve dürtüler obsesyon olarak adlandırılmaktadır (1). Bu obsesyonları rahatlatmak içinse tepki olarak belirli kurallara göre yapılan kompulsiyonlar obsesyonları takip edebilmektedir. OKB tür ve şiddeti kişiden kişiye değişebilmektedir. Bu tür ve şiddetteki değişimlerse tanı ve tedavi süreci için önemli bir yer tutmaktadır. Genel olarak temizlik ve bulaş, simetri ve düzen, dini, somatik, cinsel ve kontrol etme gibi obsesyon ve kompulsiyonlar bu türler içinde sayılmaktadır.

Bozukluğun türü kadar şiddeti de tedavi sürecinde önemli bir yer tutmaktadır. Genel olarak bozukluğun şiddeti hastaların öz bildirim ölçeklerini doldurması, psikiyatrist ve psikologların gözlemleri, aile görüşmeleri ve bireylerin sözlü ifadelerine göre belirlenmektedir. Şiddete göre oluşturulan tedavi planlarındaysa kimi zaman psikoterapi kimi zaman ilaç tedavisi kullanılabilmekte bazı vakalardaysa her iki tedavi yöntemine de başvurulabilmektedir. Bu nedenle doğru tedavi yönteminin seçilmesi için bozukluğun şiddetinin doğru bir şekilde belirlenmesi gerekmektedir. Özellikle Yale- Brown Obsesif Kompulsif Ölçeği (Y-BOCS) ve Klinik Genel İzlenim- Şiddet Ölçeği (CGI-S) gibi öz bildirim ölçekleri kullanılarak bireylerin semptom şiddeti karşılaştırmalı olarak değerlendirilebilir hale gelmesiyle tedavilerin daha standardize edilmesi sağlanabilmektedir (2). Fakat kullanılan bu yöntemler her zaman semptom şiddetini belirlemede kesin ve doğru sonuçlar vermeyebilmektedir. Bu doğrultuda, hastalık/ bozukluk boyunca beyinde gerçekleşen nörobiyolojik değişikliklerde göz önüne alınarak EEG ve fMRI çalışmaları yapılabilmekte ve makine öğrenmesiyle analizler yapılarak daha objektif sonuçlar elde edilmesi hedeflenmektedir. Bu sistematik derlemenin amacı, OKB'de fonksiyonel bağlantısallık temelli EEG ve fMRI çalışmalarını semptom şiddetinin tahmininde makine öğrenimi yöntemlerinin kullanılmasını incelemektir.

2. Gereç ve Yöntem

2.1. Araştırma Tasarımı

Yapılan araştırma, fonksiyonel bağlantısallık temelli EEG ve fMRI çalışmalarının OKB semptom şiddeti tahmininde makine öğrenmesi yöntemlerinin kullanılmasına yönelik, ilgili çalışmaların sistematik olarak değerlendirilmesi amacıyla yürütülmüş bir sistematik derlemedir. Derleme, PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) kılavuzuna uygun olarak planlanmış ve yürütülmüştür.

Literatür taraması boyunca, PubMed, Scopus ve Google Scholar veri tabanlarından "obsessive compulsive disorder", "machine learning" "functional connectivity" "corticostriatal pathway", "default mode network", "EEG" ve "fMRI" anahtar kelimeleri ve kombinasyonları kullanılmıştır. Anahtar kelimeler Boolean operatörleri (AND, OR) kullanılarak birleştirilmiştir. Tarama süreci 2020-2026 yılları arasında sınırlandırılmıştır.

2.2. Dahil Etme/ Hariç Tutma Kriterleri

Sistematik derlemede obsesif kompulsif bozukluk (OKB) şiddetinin tahmininde fonksiyonel bağlantısallık verileri ve makine öğrenmesi yöntemleri kullanan çalışmalar incelenmiştir. Dahil etme kriterleri kapsamında; [1] OKB tanısı almış bireyleri içeren, [2] fonksiyonel manyetik görüntüleme/ dilenim durumu fonksiyonel manyetik görüntüleme (fMRI / rs-fMRI) veya elektroensefalografi (EEG) tekniklerini kullanan, [3] OKB'de makine öğrenmesi veya yapay zeka yöntemlerini kullanan, [4] OKB şiddetini (örneğin Yale-Brown Obsesif Kompulsif Ölçeği – Y-BOCS skorları) tahmin eden veya sınıflandıran ve [5] hakemli dergilerde Türkçe ve İngilizce olarak yayımlanmış özgün araştırma makaleleri çalışmaya dahil edilmiştir.

Dışlama kriterleri kapsamında; [1], derleme (review), meta analiz ve editoryal çalışmalar, [2] OKB tanısını sınıflandırmaya odaklanan fakat semptom şiddetini değerlendirmeyen çalışmalar, [3] fonksiyonel bağlantısallık verilerini incelemeyen çalışmalar ve [4] hayvan deneyleri araştırma dışında bırakılmıştır.

2.3. Verilerin Seçilmesi

Literatür taraması sonucunda ulaşılan çalışmalar başlık ve özetlerine göre değerlendirilmiş, derlemenin amacına uygun görülen çalışmaların tam metin halleri dahil edilme kriterleri çerçevesinde değerlendirilmiştir.

Sistematik derleme sürecinde toplam 173 makale başlık ve özetlerine göre taranmış, bunlardan 91'i dışlanmış, kalan 82 makaleninse tam metinleri değerlendirilmiştir. Tam metni taranan 82 makaleninse 60'ı dışlama kriterleri çerçevesinde araştırmaya dahil edilmemiş olup kalan 22 çalışma derlemeye dahil edilmiştir.

Dahil edilen çalışmalar [1] yazar(lar) ve yayın yılı, [2] ilgili beyin ağı/bölgesi, [3] bağlantı değişimi (yönü), [4] şiddet ilişkisi (Y-BOCS) ve [5] yorum başlıkları altında sistematik olarak tabloya dökülmüştür.

2.4. Veri Analizi ve Sentezi

Dahil edilen çalışmaların sentezi, kullanılan makine öğrenme yöntemleri, hedef değişken türü ve incelenen beyin ağları çerçevesinde gruplandırarak yapılmıştır. Gruplama bulguların karşılaştırmalı ve sistematik bir şekilde incelenmesini sağlamaktadır.

3. Bulgular

Çalışma sistematik literatür taraması kapsamında PubMed, Scopus ve Google Scholar veri tabanları taranarak 2020- 2026 yılları arası çalışmaları kapsamaktadır. Toplam 82 araştırma makalesine erişilmiştir (tekrar eden makaleler kaldırılmıştır). Makalelerin başlık ve özetlerinin incelenmesinden sonra dahil etme kriterleri kapsamında 60 makale dışlanmış ve toplam 22 makale derlemeye dahil edilmiştir.

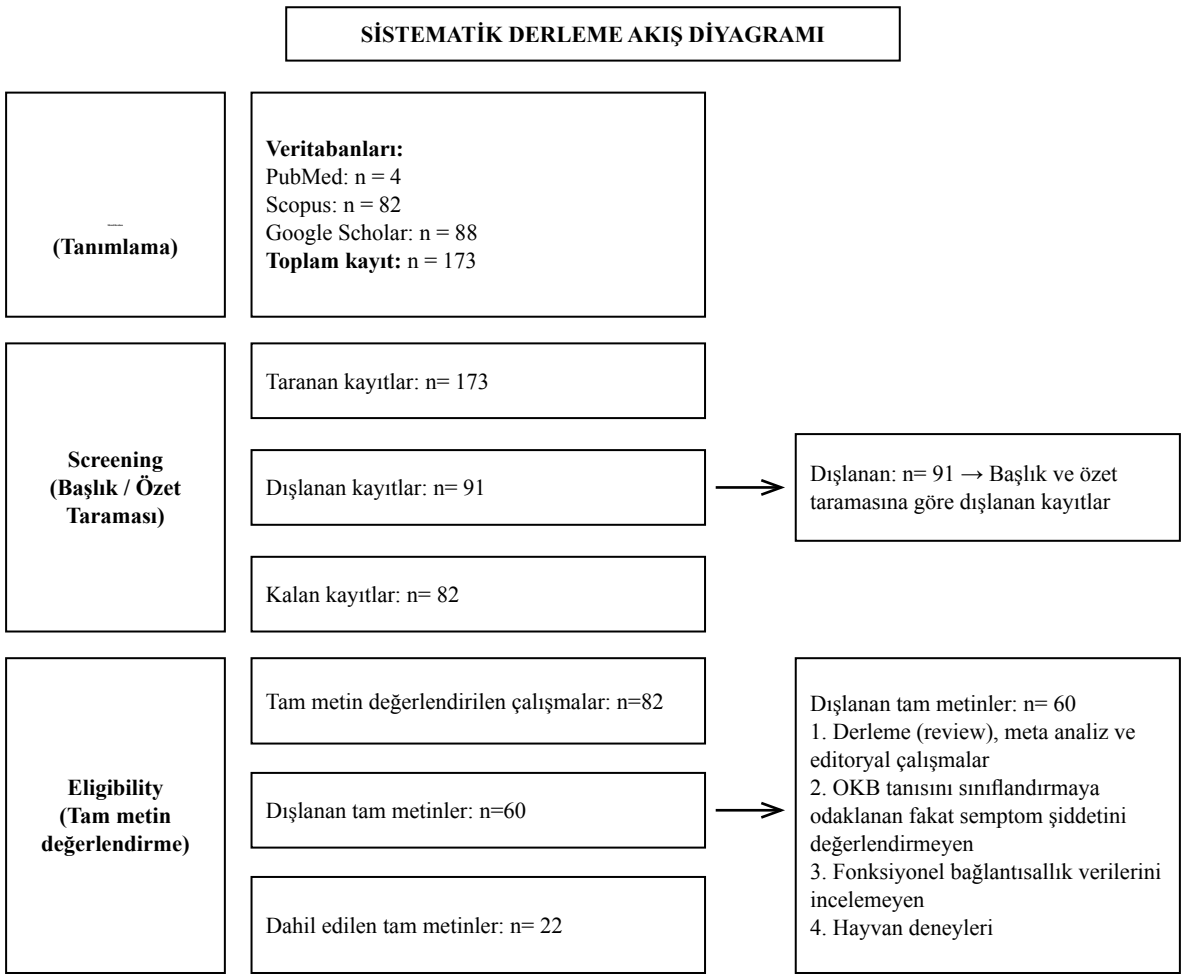

Şekil 1. PRISMA (2020) Protokolüne Göre Çalışma Seçim Sürecini Gösteren Akış Diyagramı

Derlemeye dahil edilen çalışmaların 8'i OKB'de büyük ölçekli beyin ağları, 5'i frontal bölgeler ve 7'si kortiko-striatal devrelerde fonksiyonel bağlantısallık değişimlerine odaklanmaktadır. OKB'de fonksiyonel bağlantısallığın izlendiği bu çalışmaların bulguları semptom şiddetinin ağlardaki bağlantısal organizasyonu incelemek için derlemeye dahil edilmiştir. Dahil edilen çalışmaların özellikleri Tablo 1, Tablo 2 ve Tablo 3'te sunulmuştur. Makine öğrenmesinin şiddet tahmininde kullanılmasına yönelik bulgularsa Tablo 4'te sunulmuştur.

3.1. Büyük Ölçekli Ağlara İlişkin Bulgular

Dahil edilen çalışmalar DMN, FPN, SN ve DAN arasındaki etkileşimlere odaklanmaktadır. Çalışma sonuçlarına bakıldığında DMN- FPN arasında hiper-bağlantısallık ve hipo-bağlantısallık olduğu rapor edilmiştir. Bu durum OKB'de ağlar arası dengenin bozulduğunu ve semptom şiddetiyle ilişkilendirilebildiğini göstermektedir.

Liu vd. ve Bakay vd. yaptıkları çalışmalarda hiper-bağlantısallığı daha çok kompulsif semptomlarla ilişkilendirmişlerken, Gürsel vd., Sha vd., Gaffen vd. ve Lui vd.'yse yaptıkları çalışmalarda bağlantısal zayıflığın da semptom şiddetiyle pozitif yönde ilişkili olduğu görmüştür (3-9). Bunun yanında üçlü ağ modeli kapsamında gözlemlenen bozulmaların da semptom şiddetiyle pozitif yönde ilişkili olduğu görülmektedir. Bulgular Tablo 1'de sunulmuştur.

Tablo 1. Büyük Ölçekli Ağlara İlişkin Bulgular

Beyin Ağı / Bölge	Bağlantı Değişimi	Şiddet İlişkisi (Y-BOCS)	Yorum	Kaynak
DMN - FPN	Beta bandında ↑	FPN'yle Negatif ilişki (ters orantı)	Kompulsif semptomla ilişkili	9

DMN – FPN	Hipo-konnektivit (bağlantı zayıflığı)	Pozitif ilişki	Şiddetini arttırabilir	8
DAN-FPN	Bağlantısal dengede bozulma (hiper-konektif bağlantı)	Pozitif korelasyon	Obsesyon ve kompulsiyon seviyesinde artış	4
DMN-FPN	Hiper-bağlantı	Negatif korelasyon (SPL aktivasyonuyla)	Bilişsel esneklikte azalma, kompulsiyon şiddetinde artma, bilişsel görevlerde zorluk	3
DMN-FPN	Bağlantısal anormallik- hiper-bağlantısallık	Pozitif korelasyon (obsesyon skorlarıyla)	Obsesif düşüncelerin baskılanmasında ve hedefe yönelik eylemlerin gerçekleştirilmesinde zorluk	10
Üçlü ağ modeli	Bağlantısal bozulma	Negatif korelasyon (kompulsiyon skorlarıyla)	Kompulsif davranışların kontrolünde ↓	
DMN-FPN	Hiper-bağlantısallık	Pozitif bağlantı	Bilişsel işlevlerde dengesizlik, semptom şiddetiyle ilişkili	7
Üçlü ağ modeli	Hipo-bağlantısallık	Negatif bağlantı	Zayıflaması semptom şiddetiyle ilişkili	
DMN-FPN	Hiper-bağlantısallık	Negatif bağlantı	OKB arttıkça ağ arası etkileşim ↓	5
DMN- SN	Bağlantı dinamiklerinde değişim	Pozitif bağlantı	Şiddetle ilişkili	
DMN-FPN	Anormal bağlantılar	Pozitif bağlantı	Şiddetle ilişkili	6

Kısaltmalar: ***DMN:*** *Default Mode Network [varsayılan mod ağı],* ***FPN:*** *Frontoparietal Network****, SN:*** *Salience Network*

2. Frontal Bölgeler ve Kortikal Bağlantılara İlişkin Bulgular

OKB'de Frontal kontrol ağları içinde DLPFC ve OFC arasındaki bağlantısal değişimler dikkat çekmektedir. Jia vd., Sha vd., ve Li vd. DLPFC–OFC bağlantısındaki azalmanın izlendiği çalışmalarda kompulsif davranış artışı ve OKB şiddeti arasında negatif bir ilişki gözlemlerken, Rayindran vd. posterior singulat korteks (PCC)–OFC bağlantısında artış semptom şiddetiyle pozitif bir ilişki gözlemlemiştir (11, 6, 12, 13). Bulgular Tablo 2'de sunulmuştur.

Tablo 2. Frontal Bölgeler ve Kortikal Bağlantılara İlişkin Bulgular

Beyin Ağı / Bölge	Bağlantı Değişimi	Şiddet İlişkisi (Y-BOCS)	Yorum	Kaynak
DLPFC	↓ bağlantı	Negatif korelasyon	Kompulsif davranışlarda artış	14
DLPFC- OFC	↓ bağlantı	Negatif korelasyon	Şiddetle ilişkili	12
Posterior singulat korteks- OFC	↑ bağlantı	Pozitif korelasyon	Şiddetle ilişkili	13
DLPFC- OFC (sağ)	↓ bağlantı	Negatif korelasyon	Şiddetle ilişkili	6
DLPFC- OFC	↓ voxel-mirrored homotopic connectivity (VMHC)	Negatif korelasyon	İnterhemisferik bağlantılarda bozulma, şiddetle ilişkili	11

Kısaltmalar: ***DLPC:*** *Dorsolateral Prefrontal Korteks,* ***OFC:*** *Orbitofrontal Korteks*

3. Kortikostriatal Devreyle (CSTC) İlişkin Bulgular

Dahil edilen çalışmalarda CSTC devrelerinde hiper ve hipobağlantısallık yönünde bulgulara rastlanılmıştır. Bağlantısallığın artması OKB şiddetiyle pozitif yönde ilişkiliyken bağlantısallıkta azalma

kompulsif semptomlarla negatif olarak ilişkilendirilmiştir. Sha vd. yaptıkları çalışmada kaudat nucleusla iki beyin bölgesi arasındaki bağlantısallığı izleyerek kaudat çekirdek- DLPFC arasında görülen bağlantısallık artışını semptom şiddetiyle pozitif yönde ilişkilendirirken aynı bölgeyle ACC arasında izlenen bağlantı azalmasını semptom şiddetiyle negatif olarak ilişkilendirmiştir (6). Bulgular Tablo 3'te sunulmuştur.

Tablo 3. Kortikostriatal Devreyle İlişkin Bulgular

Beyin Ağı / Bölge	Bağlantı Değişimi	Şiddet İlişkisi (Y-BOCS)	Yorum	Kaynak
CSTC devresindeki bağlantılar	↑ bağlantı	Pozitif korelasyon	Şiddetle ilişkili	15
Kortiko- striatal devre	↓ bağlantı	Negatif korelasyon	Kompulsif semptom şiddetiyle ilişkili	16
Ventral& Dorsal Frontostiratal devreler	↑ bağlantı	Pozitif korelasyon	Şiddetle ilişkili	17
OFC- Striatum	↓ bağlantı	Negatif korelasyon	Obsesif düşüncelerin ve kompulsif davranışların artmasıyla ilişkili	18
DC- ACC	↓ bağlantı	Negatif korelasyon	Şiddetle ilişkili	19
Striatal posterior alanlarda- DCP- VRP	↑ bağlantı	Pozitif korelasyon	Kompulsif semptom şiddetiyle ilişkili	20
Kaudat- DLPFC	↑ bağlantı	Pozitif korelasyon	Şiddetle ilişkili	6
Kaudat- ACC	↓ bağlantı	Negatif korelasyon	Şiddetle ilişkili	

Kısaltmalar: ***CSTC:*** *Kortikostriatal Korteks,* ***OFC:*** *Orbitofrontal Korteks,* ***DC*** *:Dorsal Caudate,* ***DCP:*** *Dorsal Caudal Putamen:* ***VRP****: Ventral Rostral Putamen:* ***DLPFC****: Dorsolateral Prefrontal Korteks* ***ACC:*** *Anterior Singulat Korteks*

4. EEG/fMRI ve Makine Öğrenmesine İlişkin Bulgular

Fonksiyonel bağlantısallık verilerinin makine öğrenmesi yöntemleriyle OKB şiddet tahmininde salt olarak kullanan çalışmalar olmasa da dahil edilen çalışmalarda EEG ve fMRI yöntemlerinin makine öğrenimiyle kullanılarak şiddet tahmininde kullanılabileceği görülmektedir. Daha çok rsEEG ve rsfMRI verileri kullanılarak yapılan bu çalışmalarda SVM, RF ve KNN gibi makine öğrenimi yöntemleri kullanılmaktadır.

Dahil edilen makalelere bakıldığında, rsEEG tabanlı çalışmalarda SVM, LDA, KNN ve RF gibi makine öğrenim yöntemini kullanarak Lee vd. tarafından yapılan çalışmada %78 doğruluk oranı gözlemlenmiştir (21). Chen vd.'se DMN- FPN gibi büyük ölçekli ağlarda bağlantı artışının kompulsiyonla ilişkilendirdikleri çalışmada SVM algoritmasıyla %87,9 doğruluk oranı izlemiştir (9). van de Mortel vd., yaptıkları fMRI tabanlı çalışmada klinik değişkenlerin tek başına sınırlı öngörü gücüne sahip olduğunu bildirilmiştir (AUC≈0.59) (22). Bulgular Tablo 4'te sunulmuştur.

Tablo 4. EEG/fMRI ve Makine Öğrenmesine İlişkin Bulgular

Yöntem	ML Yöntemi	Ana Bulgular	Tahmin Performansı	Kaynak
rsEEG	LDA, SVM, KNN, NB	SMN bağlantıları ↑, şiddet ile ilişkili	%78 accuracy	21
rsEEG	SVM	Büyük ölçekli ağlarda (DMN–FPN) bağlantı artışı, kompulsiyon ile ilişkili (beta ↑)	%87,9 accuracy	9
EEG	SVM, RF, KNN, NN	Kaudat- ACC bağlantıları ↓, şiddetle ilişkili	Korelasyon bulunamadı	23
rsfMRI	SVM, RF	Klinik veriler OKB şiddetini tahmin etmede etkili	AUC=0.59	22
rsEEG	SVM, LR, GNB	Entropi ve Lempel- Ziv karmaşıklığı ↑	%85 doğruluk	24

Kısaltmalar: ***rsEEG:*** *resting-state electroencephalography,* ***rsfMRI:*** *resting state functional Magnetic Resonance Imaging*

[dinlenim durumu fonksiyonel manyetik rezonans görüntüleme], ***SVM:*** *Support Vector Machines [Destek Vektör Makineleri]* ***LDA:*** *Linear Discriminant Analysis* ***KNN:*** *K-Nearest Neighbors* ***NB****: naïve Bayes* ***RF:*** *Random Forest,* ***NN:*** *Neural Network,* ***GNB:*** *Gaussian Naive Bayes,* ***SMN:*** *Sensorimotor Network*

Dahil edilen çalışmalar kapsamında makine öğrenimi yöntemleri karşılaştırıldığında, şiddet tahmini için en sık kullanılan yöntemin SVM olduğu görülmektedir. SVM kullanılan çalışmalarda doğruluk oranlarının %78- %87,9 arasında olduğu görülmektedir. Random Forest algoritmasıysa daha sınırlı sayıda çalışmada kullanılmıştır. rsfMRI kullanılan bir çalışmada RF algoritmasının yer aldığı modelde AUC değerinin 0,59 olduğu görülmüştür. Bunların yanında, LDA ve lojistik regresyon yöntemleri kullanılmış olsa da algoritmaların tekil performanslarından ziyade genel model performansları sunulmuştur bu nedenle hangi yöntemlerin daha üstün performans sergilediğiyle ilgili çıkarımda bulunulamamaktadır.

Tablo 5. Makine Öğrenmesi Algoritmalarının Performans Karşılaştırması

Algoritma	Kullanıldığı Çalışmalar	Performans
SVM	21, 22, 24	%78–87,9 doğruluk
KNN	21, 23	Bazı çalışmalarda sınıflandırmada kullanılmış, performans ayrı raporlanmamış
RF	22, 23	AUC≈0,59 veya diğer algoritmalarla birlikte raporlanmış
LDA	21	%78 doğruluk elde edilen model içinde yer almış
LR	24	%85 doğruluk elde edilen model içinde yer almış

Kısaltmalar: ***SVM:*** *Support Vector Machines [Destek Vektör Makineleri]* ***LDA:*** *Linear Discriminant Analysis* ***KNN:*** *K- Neatrest Neighbors* ***NB****: naïve Bayes* ***RF:*** *Random Forest,* ***NN:*** *Neural Network,* ***GNB:*** *Gaussian Naive Bayes,* ***SMN:*** *Sensorimotor Network*

4. Tartışma

Obsesif kompulsif bozukluk (OKB) istenmeden ve zorla gelen zorlayıcı düşünce ya da dürtülerin belirmesi (obsesyon) ve obsesyonları rahatlatmak için belirli kurallar çerçevesinde, kısa dönemli rahatlık sağlayan (kompulsiyon) tepkilerin verilmesini içeren bir bozukluk olarak görülmektedir (1). OKB'nin tanı süreci önemli bir yer tutmaktadır. Birçok alt türe sahip olan bu bozuklukta obsesyon-kompulsiyonların belirlenmesi ve şiddetinin objektif olarak değerlendirilmesi gerekmektedir. Tanı süreci boyunca yapılan görüşmeler doğrultusunda sözlü beyanların yanında Yale-Brown Obsesif Kompulsif Ölçeği (Y-BOCS) gibi öz-bildirim ölçekleri kullanılabilmekte, aile görüşmelerinde ailelerin sözlü ifadelerine dikkat edilmekte ve psikolog/psikiyatristlerin gözlemleri anamnezlerde önemli bir yer tutmaktadır. Bununla birlikte, ailenin ve danışanın/ hastanın sözlü ifadelerinde bozukluktan bahsederken kendini/danışını/hastayı olduğundan daha iyi göstermeye dair bir yanlılığı olabileceği ve tedavi sürecini etkileyebileceğinden dolayı daha objektif değerlendirme araçlarına ihtiyaç duyulmaktadır.

Yapılan sistematik derlemede incelenen çalışmaların bulgularına bakıldığında OKB'de fonksiyonel bağlantısallık değişimlerinin belirli beyin bölgeleriyle sınırlı kalmadığı, büyük ölçekli beyin ağları düzeyinde meydana gelen bozuklukla ilişkilendirilebildiği görülmektedir. DMN-FPN arasındaki fonksiyonel bağlantısallığa bakıldığında, hiper ve hipo-bağlantısallık görülmesi OKB'de tek yönlü bir bağlantısallık değişimin olmadığını ve ağlar arası dengelerde bozulmalar yaşandığını göstermektedir (3-10). Bunun yanında üçlü ağ modelinde yer alan salience networkün (SN) kompulsiyonlar üzerindeki etkisi de görülmektedir. İçsel ve dışsal uyaranların filtrelenmesinde önemli bir rolü olan SN, özellikle DMN ve FPN arasında aracı olarak çalışmaktadır. OKB'deyse bu bağlantısallığın bozulmasıyla SN'nin filtreleme işlevi zayıflamakta ve bireyin tekrarlayan obsesyonlardan (DMN aktivitesi) sıyrılması ve amaca yönelik işlevleri (FPN aktivesi) yerine getirmesi zorlaşmaktadır (9, 25). Derlemeye dahil edilen çalışmalara bakıldığında, bu üçlü ağ modelinde negatif yönde bir ilişki olduğu, bağlantısallık azaldıkça kompulsiyon şiddetinin arttığı görülmektedir (7, 10).

Frontal bölgelere ilişkin bulgulara bakıldığında, OFC ve DLPFC arasındaki bağlantısal

değişimler OKB patofizyolojisinde önemli bir yer tutmaktadır. Dahil edilen çalışmalara bakıldığında DLPFC- OFC bağlantısındaki azalmanın kompulsiyonların sürdürülmesinde etkisi olduğu görülmekte (6,11), aynı şekilde bağlantı artışıyla da semptom şiddeti arasında pozitif bir korelasyon olduğu görülmektedir (13). Bu durum OKB'de DLPFC- OFC arasındaki bağlantısallığın da tek yönlü bir işleyişte olmadığını ve şiddet tahmini açısından önemli bir yer tuttuğunu göstermektedir.

OKB için en önemli devrelerden biri olan kortikostriatal devre (CSTC), bozukluğun nörobiyolojisini anlamak için önemli bir yer tutmaktadır. CSTC'nin hedefe yönelik esnek davranışlar ve otomatikleşen alışkanlar arasındaki geçiş ve dengeyi yönettiği düşünüldüğünde OKB hastalarında bu ağda görülen bozukluklar bu geçişi yavaşlatmakta/ bozmaktadır (25-26). Özellikle OFC, kaudat çekirdek ve ACC arasındaki bağlantısal değişimler, kompulsif davranışların sürdürülmesinde ve OKB şiddetinde rol oynadığı görülmektedir (6, 19).

Fonksiyonel bağlantısallık açısından OKB'nin nörobiyolojisi hakkında bilgi veren bu bağlantısal değişimler makine öğrenmesiyle birlikte ele alındığında, OKB şiddet tahminine yönelik önemli bir bulgu kümesi ortaya çıkmaktadır. Makine öğrenimi yöntemleri OKB tanı, tedavi yanıtı ve semptom sınıflandırmada kullanılan yöntemlerden biridir. Son yıllarda yapılan çalışmalarda OKB'de psikofarmakolojik ve psikolojik tedaviye verilecek yanıtın önceden tahmin edilmesine dair ML yöntemlerini kullanan çalışmaların olduğu görülmektedir (27-28). Tedavi yanıtının yanında OKB sınıflandırmasında da ML yöntemleri sık kullanılmaktadır (29-30).

EEG ve fMRI temelli çalışmalar ele alındığında fonksiyonel bağlantısallık verileri OKB şiddet tahmini için potansiyel olarak kullanılabilmektedir. Literatürde salt olarak şiddet tahminine yönelik çalışmalara çok fazla rastlanmasa da birçok çalışmada farklı nörogörüntüleme yönetmeleri ve bağlantısallık çalışmalarını Y-BOCS skorlarıyla karşılaştırarak makine öğrenmesi yöntemleriyle şiddet tahmini yönünden bulgular elde edilmiştir. Şiddet tahminine yönelik yapılan bir çalışmada MRG (manyetik rezonans görüntüleme) verilerinde gri madde hacimleri incelenmiş, Y-BOCS ve boyutsal versiyonu olan DY-BOCS ölçekleriyle arasındaki ilişki Destek Vektör Regresyonu (SVR) kullanılarak izlenmiş ve makine öğreniminin tahmin ettiği hastalık şiddeti skorlarıyla hastaların/ danışanların ölçek skorları arasında anlamlı bir ilişki bulunmuştur (31). EEG temelli çalışmalara bakıldığında, SVM, lojistik regresyon ve rastgele orman (Random Forest) gibi algoritmalar kullanılarak orta/yüksek düzeyde doğruluk oranlarına ulaşılan çalışmalar olduğu görülmektedir (24, 9,21). fMRI çalışmalarındaysa çalışma sayısının azlığı ve doğruluk oranlarının düşüklüğü nedeniyle daha çok çalışmanın yapılması gerekliliğini göstermektedir.

5. Sonuç

OKB tanı ve tedavi süreçleri açısından tür ve şiddet tahminin en doğru şekilde yapılması gereken psikiyatrik bozukluklardan biridir. Mevcut tanılama ve gözlem araçları her ne kadar psikiyatrist/psikoloğa tanı- tedavi sürecinde yardımcı araçlardan olsa da daha objektif araçlara ihtiyaç duyulmaktadır. Fonksiyonel bağlantısallık açısından beyin ağlarında meydana gelen bozuklukların makine öğrenimi yöntemleriyle değerlendirilmesi OKB semptom şiddetinin bu yöntemlerle daha objektif bir şekilde değerlendirilebileceğini göstermektedir. Yapılan çalışmalardan elde edilen bulgular yüksek doğruluk oranlarının nörogörüntüleme teknikleri ve makine öğrenmesi yöntemlerinin kullanılarak klinik tanı ve kişiye özel tedavi süreçlerinin planlanması için potansiyel yöntemlerden biri haline gelebileceğini göstermektedir. Bununla birlikte, klinik kullanım için yeterli veri ve araştırmaların olmaması, bu alanda daha çok bağlantısallık ve makine öğrenimi çalışmalarının yapılması gerektiğini göstermektedir.

Makine öğrenmesi algoritmalarının klinik uygulama süreçlerinde uygulanabilmesi için farklı merkezlerden elde edilen geniş örneklemlerle çalışılan ve geliştirilen modellerin yaygınlaştırılması, standartlaştırılmış veri toplama ve analiz araçlarının oluşturulması, farklı hasta gruplarında denenerek modellerin tutarlılığının izlenmesi gerekmektedir. Bunun yanında, geliştirilen makine öğrenimi algoritmaları ve yapay zeka modellerinin etik açıdan ve veri güvenliği açısından düzenlemelerin sağlanması gerekmektedir. Yapılacak olan yeni çalışmalar daha güvenilir makine öğrenimi ve yapay zeka araçlarının geliştirilmesi için önemli bir yer tutmaktadır.

Çıkar Çatışması Beyanı

Bu çalışma ile ilgili herhangi bir çıkar çatışması beyan edilmemektedir.

Araştırma Desteği

Bu çalışma herhangi bir kurum veya kuruluş tarafından finansal olarak desteklenmemiştir.

Yazarların Katkısı

Fikir/Kavram: H.B.Aslan ; **Tasarım ve Dizayn:** H.B.Aslan; **Denetleme/ Danışmanlık:** H. B. Aslan; **Kaynaklar**: H.B.Aslan **Malzemeler:** H.B.Aslan; **Veri Toplama ve/veya İşleme:** H.B.Aslan; **Analiz ve/veya Yorum:** H.B.Aslan; **Literatür Taraması:** H.B.Aslan; **Yazı Yazan:** H.B.Aslan; **Eleştirel İnceleme:** H. B. Aslan

Not: Bu çalışma kongrede poster bildiri olarak sunulmuştur. 2nd Cansağlığı International Medical Student Conference 11-12 Nisan 2026 İstanbul, Türkiye

Kaynaklar

1. American Psychiatric Association. Ruhsal Bozuklukların Tanısal ve Sayımsal Elkitabı (DSM-5). Köroğlu E, çeviri editörü. Ankara: Hekimler Yayın Birliği; 2013.
2. Lewin AB, Piacentini J, De Nadai AS, Jones AM, Peris TS, Geffken GR, et al. Defining clinical severity in pediatric obsessive-compulsive disorder. Psychol Assess. 2014;26(2):679-84.
3. Liu Q, Gao F, Wang X, Xia J, Yuan G, Zheng S, et al. Cognitive inflexibility is linked to abnormal frontoparietal-related activation and connectivity in obsessive-compulsive disorder. Hum Brain Mapp. 2023;44(16):5460-70.
4. Bakay H, Ulasoglu-Yildiz C, Kurt E, Demiralp T, Tükel R. Hyperconnectivity between dorsal attention and frontoparietal networks predicts treatment response in obsessive-compulsive disorder. Psychiatry Res Neuroimaging. 2024;337:111763.
5. Gürsel DA, Reinholz L, Bremer B, Schmitz-Koep B, Franzmeier N, Avram M, et al. Frontoparietal and salience network alterations in obsessive-compulsive disorder: insights from independent component and sliding time window analyses. J Psychiatry Neurosci. 2020;45(3):214-21.
6. Sha Z, Edmiston EK, Versace A, Fournier JC, Graur S, Greenberg T, et al. Functional disruption of cerebello-thalamo-cortical networks in obsessive-compulsive disorder. Biol Psychiatry Cogn Neurosci Neuroimaging. 2020;5(4):438-47.
7. Geffen T, Smallwood J, Finke C, Olbrich S, Sjoerds Z, Schlagenhauf F. Functional connectivity alterations between default mode network and occipital cortex in patients with obsessive-compulsive disorder. Neuroimage Clin. 2022;33:102915.
8. Zhang ZF, He Y, Su YQ, Liu JM. Decreased inter- and intra-network connectivity after group cognitive behavioral therapy in patients with unmedicated obsessive-compulsive disorder. World J Psychiatry. 2025;15(8):107860.
9. Chen K, Xiao Y, Zhu S, Cao F, Che Q, Liu Y, et al. Electroencephalography source-space functional connectivity reveals frequency-specific brain network dysfunctions in obsessive-compulsive disorder. Prog Neuropsychopharmacol Biol Psychiatry. 2025;143:111561.
10. Zhu C, Fu Z, Chen L, Yu F, Zhang J, Zhang Y, et al. Multi-modality connectome-based predictive modeling of individualized compulsions in obsessive-compulsive disorder. J Affect Disord. 2022;311:595-603.
11. Jia C, Ou Y, Chen Y, Li P, Lv D, Yang R, et al. Decreased resting-state interhemispheric functional connectivity in medication-free obsessive-compulsive disorder. Front Psychiatry. 2020;11:559729.
12. Li H, Hu X, Gao Y, Cao L, Zhang L, Bu X, et al. Neural primacy of the dorsolateral prefrontal cortex in patients with obsessive-compulsive disorder. Neuroimage Clin. 2020;28:102432.
13. Ravindran A, Richter M, Jain T, Ravindran L, Rector N, Farb N. Functional connectivity in obsessive-compulsive disorder and its subtypes. Psychol Med. 2020;50(7):1173-81.
14. Zhong Z, Ou Y, Chen Y, Li P, Shi H, Lv D, et al. Reduced functional connectivity of the right dorsolateral prefrontal cortex at rest in obsessive-compulsive disorder. Brain Behav. 2024;14(1):e3333.
15. Springer SA, Deshmukh R, Klei L, Devlin B, Glausier JR, Lewis DA, et al. Transcriptomes of higher order thalamic nuclei in obsessive compulsive disorder. J Affect Disord. 2026;403:121330.
16. Brydevall M, Suo C, Albertella L, Rotaru K, O'Brien T, Yücel M, et al. Differences in resting state functional connectivity in striatal and frontal networks associated with task-behaviour elicited by gamified two-stage decision task. Neuroimage. 2025;317:121362.
17. Naze S, Hearne LJ, Sanz-Leon P, Robinson C, Hall CV, Sonkusare S, et al. Mechanisms and interventions promoting healthy frontostriatal dynamics in obsessive-compulsive disorder. Nat Commun. 2025;16(1):7400.
18. Park H, Kim M, Kwak YB, Cho KIK, Lee J, Moon SY, et al. Aberrant cortico-striatal white matter connectivity

and associated subregional microstructure of the striatum in obsessive-compulsive disorder. Mol Psychiatry. 2022;27(8):3460-7.
19. Xu T, Gu Q, Zhao Q, Wang P, Liu Q, Fan Q, et al. Impaired cortico-striatal functional connectivity is related to trait impulsivity in unmedicated patients with obsessive-compulsive disorder. J Affect Disord. 2021;281:899-907.
20. Park J, Kim T, Kim M, Lee TY, Kwon JS. Functional connectivity of the striatum as a neural correlate of symptom severity in patients with obsessive-compulsive disorder. Psychiatry Investig. 2020;17(2):87-95.
21. Lee T, Park SS, Im CH, Lee SH. Altered resting-state sensorimotor network in patients with obsessive-compulsive disorder: an EEG study. J Affect Disord. 2026;399:121110.
22. van de Mortel LA, Bruin WB, Alonso P, Bertolín S, Feusner JD, Guo J, et al. Development and validation of a machine learning model to predict cognitive behavioral therapy outcome in obsessive-compulsive disorder using clinical and neuroimaging data. J Affect Disord. 2025;389:119729.
23. Zhao Z, Wang J, Niu Y, Qiu M, Zhu M, Li M, et al. Exploring potential resting-state EEG biomarkers of obsessive-compulsive disorder based on explainable machine learning analysis of independent training and test samples. BMC Psychiatry. 2025;25(1):1164.
24. Ren H, Ran X, Qiu M, Lv S, Wang J, Wang C, et al. Abnormal nonlinear features of EEG microstate sequence in obsessive-compulsive disorder. BMC Psychiatry. 2024;24(1):881.
25. Perera MN, Gotsis ES, Bailey NW, Fitzgibbon BM, Fitzgerald PB. Exploring functional connectivity in large-scale brain networks in obsessive-compulsive disorder: a systematic review of EEG and fMRI studies. Cereb Cortex. 2024;34(8):bhae327.
26. Wang L, Tian Y, Luo Y, Lu Q, Sun G, Deng X, et al. Differences in brain functioning between obsessive-compulsive disorder and generalized anxiety disorder: a clinical study using functional near-infrared spectroscopy. Front Psychiatry. 2026;17:1757526.
27. Tubío-Fungueiriño M, Cernadas E, Fernández-Delgado M, Arrojo M, Bertolin S, Real E, et al. Prediction of pharmacological response in OCD using machine learning techniques and clinical and neuropsychological variables. Span J Psychiatry Ment Health. 2025;18(1):51-57.
28. Zaboski BA, Bednarek L. Precision psychiatry for obsessive-compulsive disorder: clinical applications of deep learning architectures. J Clin Med. 2025;14(7):2442.
29. Ma M, Lu B, Gong Y, Xiao C, Yang Y, Ju Y, et al. EEG microstate analysis and machine learning classification in patients with obsessive-compulsive disorder. J Psychiatr Res. 2025;182:186-94.
30. Aljebreen WS, Alturaiqi NA, Almushyti MI, Alhasson HF, Alharbi SS. Advancing precision psychiatry: machine learning integration with neuroimaging for early detection and diagnosis of obsessive-compulsive disorder. Psychiatry Res Neuroimaging. 2026;357:112137.
31. Hoexter MQ, Miguel EC, Diniz JB, Shavitt RG, Busatto GF, Sato JR. Predicting obsessive-compulsive disorder severity combining neuroimaging and machine learning methods. J Affect Disord. 2013;150(3):1213-6.