

Psikiyatride Makine Öğrenmesi Yöntemlerinin Kullanımı

Use of Machine Learning Methods in Psychiatry

İlkim Ecem Emre¹ , Cumhuriyet Taş² , Çiğdem Erol³ 

Öz

Yapay zeka ve veri analizinde gün geçtikçe daha popüler hale gelen makine öğrenmesi yöntemleri birçok farklı alanda veriden öğrenmeyi sağlamaktadır. Sağlık alanında yapılan çalışmalarda bu yöntemler sağlık çalışanlarına ve hekimlere destek sunmaktadır. Psikiyatri de bu alanlardan bir tanesidir. Hastalıkların tanı, hastalık seyrinin tahmini veya bir tedaviye verilecek yanıtın gözlemlenmesi gibi problemlere makine öğrenmesi yöntemleri destek sağlamaktadır. Bu çalışma kapsamında psikiyatri alanında yapılmış olan makine öğrenmesi çalışmaları incelenmiştir. Çalışmanın amacı, makine öğrenmesi yöntemlerinin psikiyatri alanında kullanımının araştırılmasıdır. Özellikle elektroensefalografi (EEG) verisi kullanılan araştırmalara odaklanılmıştır. Bu amaçla, psikiyatride alanında yapılan makine öğrenmesi ile ilgili olan SCOPUS ve Google Scholar kaynaklarındaki yayınlar incelenmiştir. Literatürdeki genel durumun ortaya konması amacıyla, psikiyatri alanında makine öğrenmesi yöntemlerinden yararlanılan çalışmalara incelenmiştir. Sonrasında ise daha detaylı bir şekilde psikiyatri alanında makine öğrenmesi ve EEG verisi kullanılarak yapılan araştırmalar incelenmiştir. Bu çalışmanın psikiyatride makine öğrenmesi ile ilgili yapılan yayınlar ve özellikle EEG verisi kullanılan yayınların derlenmesi açısından araştırmacılara faydalı olabileceği umulmaktadır.

Anahtar sözcükler: Psikiyatri, makine öğrenmesi, psikiyatrik hastalıklar

Abstract

Machine learning methods, which are becoming more and more popular in artificial intelligence and data analysis, provide learning from data in many different fields. In the studies conducted in the field of health, these methods support healthcare professionals and physicians. Psychiatry is one of these areas. Machine learning methods provide support to problems such as diagnosis, prediction of disease course or monitoring response to a treatment. In this study, machine learning studies in the field of psychiatry are examined. The aim of the study is to examine the studies of machine learning in the field of psychiatry and especially the studies conducted using electroencephalography (EEG) data. Accordingly, studies on machine learning in the field of psychiatry in SCOPUS and Google Scholar sources were examined. In order to reveal the general situation in the literature, studies using machine learning methods in the field of psychiatry were examined. Afterwards, studies using both machine learning methods and EEG data in psychiatry were examined. It is hoped that this study will be useful to researchers in terms of the publications about machine learning in psychiatry and especially the publications using EEG data.

Keywords: Psychiatry, machine learning, psychiatric diseases

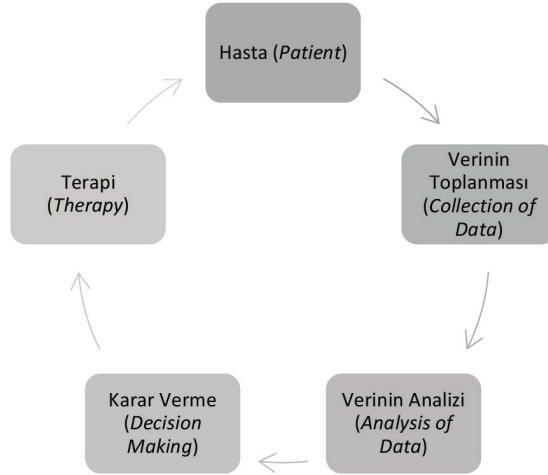
¹Marmara Üniversitesi, İstanbul, Türkiye

²İstanbul Üniversitesi, İstanbul, Türkiye

³Üsküdar Üniversitesi, İstanbul, Türkiye

✉ İlkim Ecem Emre, Marmara Üniversitesi İşletme Fakültesi, Yönetim Bilişim Sistemleri Bölümü, İstanbul, Türkiye
ecem.emre@marmara.edu.tr | 0000-0001-9507-8967

YAPAY zeka ve onun alt dalları olan veri madenciliği ve makine öğrenmesi yöntemlerinin günümüzde çokça ilgi gören araştırma ve uygulama alanlarından biri de sağlık alanıdır. Sağlık çalışmalarında bu yöntemlerin kullanılması, hastalıkların erken teşhisi ve tahmini ile ilgili faydalar sağlarken temelde insanların yaşam kalitesinin artırılmasını hedefler. Kutlu (2010), hastadan alınan fizyolojik sinyallerin toplandığı ve analiz edildiği tıbbi bakım sürecini Şekil 1'deki gibi sembolize etmiştir. Buna göre ilk aşamada belli bir şikayet ile doktora başvuran hastadan veri toplanır, veri analiz edilir ve bu analiz sonucunda bir karar verme süreci devreye girer. Hastalığın teşhisi veya gidişatıyla ilgili verilen karar sonucunda ilgili adımlar atılarak terapi yani tedavi evresine geçilir. Yapay zeka ile ilgili teknoloji, model veya yöntem olarak adlandırılacak birçok kavramın aslında karar vermemize destek olduğu söylenebilir. Yapay zekanın alt dalı olarak makine öğrenmesi yöntemlerinden bahsedildiğinde bu yöntemlerin günümüzde doktorların kararlarına destek verecek şekilde modeller oluşturmada kullanıldığı, hastalıkların teşhisinden tedavisine kadar birçok farklı şekilde bu yöntemlerin fayda sağlayabileceği görülmektedir.



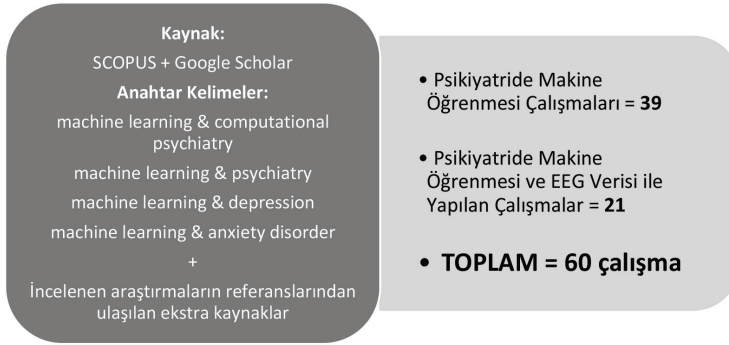
Şekil 1. Tıbbi bakım sisteminin temel unsurları (Kutlu 2010)

Çalışma kapsamında incelenen, psikiyatri alanında makine öğrenmesi yöntemlerinden yararlanmış olan çalışmalara bakıldığında; hasta sayılarının çok fazla olmadığı, çok merkezli veri toplama işleminin gerçekleştirilmediği, bazı çalışmalarda tek tip veri kullanıldığı ve ikiden fazla hastalığın aynı anda ele alınmadığı görülmüştür. Bu araştırmanın amacı, psikiyatri alanında yapılan makine öğrenmesi çalışmalarının incelenmesi ve aynı zamanda spesifik olarak elektroensefalografi (EEG) verisi kullanılarak yapılan çalışmalarının araştırılmasıdır. Çalışma, “Psikiyatrik Hastalıkların Makine Öğrenmesi ile Ayırıştırılması” başlıklı doktora tez çalışmasına temel oluşturmak için yapılan literatür taramasının kapsamının sınırlandırılması ile oluşturulmuştur. Buna göre, genel kapsamda psikiyatri alanında yapılan makine öğrenmesi çalışmaları incelenmiştir. Aynı zamanda genel kapsam daraltılarak, tez çalışmasının da konusu olan, psikiyatri alanında makine öğrenmesi yöntemleri ve EEG verisi kullanan çalışmalar daha detaylı bir şekilde incelenmiştir. Bu çalışmanın psikiyatride

makine öğrenmesi ile ilgili yapılan çalışmalar ve EEG verisi özelinde yapılan çalışmalarını derlemesi sebebiyle araştırmacılara faydalı olabileceği umulmaktadır.

Yöntem

Literatür taraması, iki farklı başlık temelinde yapılandırılmıştır. Buna göre tündengelim yaklaşımı benimsenmiştir. Psikiyatri alanında makine öğrenmesi yöntemlerini kullanılan araştırmalar (n=39) ve psikiyatride EEG verisi ve makine öğrenmesi yöntemleri kullanılmış olan araştırmalar (n=21) ele alınarak incelenmiştir. Çalışmaya dahil edilen araştırmaların kapsamı Şekil 2'de gösterilmiştir.



Şekil 2. Çalışmaya dahil edilen araştırmaların kapsamı

Çalışma kapsamında incelenen ve yararlanılan kaynaklar Google Scholar ve SCOPUS veri tabanlarında yapılan farklı taramalar sonucunda elde edilmiştir. Tarama “machine learning”&“computational psychiatry”, “machine learning”&“psychiatry”, “machine learning”&“depression”, “machine learning”&“anxiety disorder” anahtar kelimeleri kullanılarak, Ekim 2019-Kasım 2019 tarih aralığında arama yapılmıştır. Elde edilen araştırmalardan 60 tanesi çalışmaya dahil edilmiştir. Daha sonra elde edilen makalelerin yararlandığı kaynaklar incelenerek taramanın kapsamı genişletilmiştir. Belirtilen kriterlere göre EEG verisi, psikiyatrik hastalıklar ve makine öğrenmesi yöntemlerini içeren çalışmalar tespit edilmiş ve detaylı olarak incelenmiştir.

Bulgular

Literatür taraması sonucunda elde edilen bulgular Şekil 2'de belirtilen iki başlık altında verilmiştir; başlıkların alt kısımlarında başlık kapsamında incelenmiş olan çalışmalar yer almaktadır. Literatür incelendiğinde farklı hastalıklarla ilgili çalışmalarda makine öğrenmesi yöntemlerinden yararlandığı görülmektedir. Psikiyatride makine öğrenmesi teknikleri ile yapılan çalışmalar farklı hastalıkları, farklı veri tiplerini ve farklı analiz yöntemlerini içermektedir. Tablo 1'de incelenen çalışmalar, kullandıkları veri sayısı ve yöntem adı verilmiştir.

Dikkat eksikliği ve hiperaktivite bozukluğu (DEHB)

Mueller ve arkadaşları (2010) ve Öztoprak ve arkadaşları (2017), DEHB hastaları ve

Tablo 1. Psikiyatride makine öğrenmesi teknikleri kullanılan çalışmalar

Kaynak	Ele Alınan Hastalık	Örnek Sayısı	Yöntem
1 Mueller ve ark. (2010)	DEHB	148 74 DEHB 74 sağlıklı	SVM
2 Öztoprak ve ark. (2017)	DEHB	108 70 DEHB 38 sağlıklı	SVM
3 Kuang ve He (2014)	DEHB	545 450 DEHB 95 sağlıklı	Derin öğrenme
4 Nouretdinov ve ark. (2011)	Depresyon	38 19 depresyon 19 sağlıklı	Transductive conformal predictor, SVM
5 Suhasini ve ark. (2011)	Depresyon, anksiyete	400 DEHB	BPNN, RBFNN, SVM
6 Perlis ve ark. (2012)	Depresyon	5198 depresyon	LJR, NLP
7 Perlis (2013)	Depresyon	-	LJR, NB, RF, SVM
8 Redlich ve ark. (2016)	Depresyon	68 47 depresyon 21 sağlıklı	Gaussian process classifier, SVM
9 Dipnall ve ark. (2017),	Depresyon	2123 depresyon	Self-organised mapping, boosted regression, multivariate LJR
10 Walss-Bass ve ark. (2018)	Depresyon, anksiyete	254 depresyon, anksiyete	Component-wise gradient boosting
11 Zilcha-Mano ve ark. (2018)	Depresyon	174 depresyon	RF
12 Hatton ve ark. (2019)	Depresyon	284 depresyon	Extreme gradient boosting, LJR
13 Li ve ark. (2017)	Depresyon, anksiyete	321	Bayesian parametrik olmayan kümeleme
14 Yoon ve ark. (2012)	Şizofreni	102 51 şizofreni 51 sağlıklı	LDA
15 Brodersen ve ark. (2014)	Şizofreni	41 şizofreni 42 sağlıklı	SVM, Gaussian mixture model
16 Dowd ve ark. (2016)	Şizofreni	38 şizofreni 37 sağlıklı	Q-learning
17 Cao ve ark. (2018)	Şizofreni	262 131 şizofreni 131 sağlıklı	MTL_NET (multi-task learning with network structure), MTL_SNET (sparse network structure), MTL_L21 (joint feature learning), MTL_EN (joint feature learning with elastic net), MTL_Trace (low-rank structure), LJR, SVM, RF
18 Viviano ve ark. (2018)	Şizofreni	188 113 şizofreni 75 sağlıklı	SVM
19 Barzilay ve ark. (2019)	Şizofreni	25 şizofreni	SVM
20 Fond ve ark. (2019)	Şizofreni	549 hasta	CART
21 Pinaya ve ark. (2019)	Şizofreni, otistik spektrum bozukluğu	263 hasta 1113 sağlıklı	deep autoencoder, SVM

Tablo 1. Devamı

	Kaynak	Ele Alınan Hastalık	Örnek Sayısı	Yöntem
22	Galatzer-Levy ve ark. (2014)	PTSB	957 PTSB	Linear SVM, optimized linear SVM, polynomial SVM, RF, AdaBoost, kernel ridge regression, Bayesian binary regression
23	Karstoft ve ark. (2015)	PTSB	957 PTSB	SVM
24	Papini ve ark. (2018),	PTSB	271 PTSB	XGBoost
25	Mwangi ve ark. (2016)	Bipolar	256 128 bipolar 128 sağlıklı	Relevance vector machine learning algorithm
26	Eugene ve ark. (2018)	Bipolar	120 bipolar	DT, RF
27	Perez Arribas ve ark. (2018)	Bipolar Bozukluk, sınır kişilik bozukluğu	130 48 bipolar 31 sınır kişilik bozukluğu 51 sağlıklı	RF
28	Edgcomb ve ark. (2019)	Bipolar	552 bipolar	CART
29	Han ve ark. (2020)	Opioid	41579 opiyat kullanıcısı	ANN, distributed RF, gradient boosting machine
30	Ellis ve ark. (2019)	Opioid	716533 9518 opioid 707015 sağlıklı	RF
31	Zhao ve So (2019)	Şizofreni, depresyon, anksiyete bozukluğu	3478 hasta 12436 gen	DNN, SVM, RF, gradient boosted machine (with trees), LJR (with elastic net regularization)
32	Mellem ve ark. (2020)	Şizofreni, bipolar bozukluk, DEHB	272 50 şizofreni 49 bipolar 43 DEHB 130 sağlıklı	LASSO regression, elastic net regression, RF
33	Sohn ve ark. (2011)	Diğer	335 örnek	C4,5
34	Qin ve ark. (2014)	Diğer	76 örnek	LNR
35	Bedi ve ark. (2015)	Diğer	34 örnek 5 psikoz 29 psikoz değil	Convex hull classifier
36	Just ve ark. (2017)	Diğer	34 17 intihar düşünen 17 kontrol	Gaussian Naive Bayes
37	Sato ve ark. (2018)	Diğer	622 örnek	One-class SVM
38	Walsh ve ark. (2018)	Diğer	1470 örnek	RF, LJR
39	Stamate ve ark. (2019)	Diğer	272 260 psikoz 212 sağlıklı	RF, SVM, Gaussian Processes, LJR, ANN

ANN: Yapay sinir ağları (artificial neural network), DT: Karar ağacı (decision tree)

ELM: Aşırı öğrenme makinesi (extreme learning machine, KNN: K-En yakın komşu (k-nearest neighbor)

LDA: Lineer diskriminant analizi (linear discriminant analysis), LJR: Lojistik regresyon (logistic regression)

NB: Sade Bayes (naïve Bayes), PLSR: Kısmi en küçük kareler regresyonu (partial least squares regression)

RF: Rastgele orman (random forest), SVM: Destek vektör makinesi (support vector machine)

sağlıklı bireylerin birbirinden ayrıştırılması amacıyla SVM (destek vektör makinesi (support vector machine)) yönetimini kullanmıştır. Kuang ve He (2014), DEHB hastaları ile sağlıklı bireylerin ve hastalığın alt gruplarının ayrıştırılmasında derin öğrenme yöntemini kullanmıştır.

Depresyon

Nouretdinov ve arkadaşları (2011), depresyon hastalığında diagnostik ve prognostik belirteçlerin tahminine yönelik çalışmalarında transductive conformal predictor ve SVM kullanmıştır. Suhasini ve arkadaşları (2011), depresyon ve anksiyetinin tespit edilmesine yönelik olarak SVM, geri yayımlı ANN (back propagation neural network - BPNN) ve radyal tabanlı ANN (radial basis function neural network - RBFNN) tekniklerinden yararlanan bir karar destek sistemi geliştirmiştir. Perlis ve arkadaşları (2012), depresyon tedavisinin uzun dönemli etkilerinin incelenmesine yönelik olarak LJR (lojistik regresyon (logistic regression)) ve NLP (doğal dil işleme (natural language processing)) ile verilecek tedavi yanıtının sınıflandırılmasına yönelik bir çalışma yapmıştır. Perlis (2013), depresyon hastalarında tedavi direnci riskinin tahmin edilmesine yönelik olarak LJR, NB (sade Bayes (naïve Bayes)), RF (rasgele orman (random forest)), SVM temelli bir model geliştirmiştir. Redlich ve ark. (2016), depresyon tedavisinde elektro konvülsif tedaviye (EKT) karşı verilecek tedavi yanıtının tahmin edilmesinde Gaussian process classifier ve SVM yöntemlerini kullanmıştır. Dipnall ve ark. (2017), depresyonun altında yatan örüntülerin keşfedilmesine yönelik olarak self-organised mapping, boosted regression, multivariate LJR yöntemlerini kullanmıştır. Walss-Bass ve ark. (2018), depresyon ve kaygı gelişimine yönelik tahminde kullanılması hangi enflamatuvar belirteçlerin kullanılabileceğini belirlemek amacıyla component-wise gradient boosting algoritmasını kullanmıştır. Zilcha-Mano ve ark. (2018), depresyon hastalarında plasebo ve ilaç tedavisine yanıt verme tahmininin yapılması amacıyla RF kullanmıştır. Hatton ve arkadaşları (2019), yaşlı bireylerde depresyon tahmini için bir çalışma gerçekleştirmiş ve extreme gradient boosting modeli ile LJR yöntemlerini kullanmıştır. Li ve arkadaşları (2017), kanser hastalarında kaygı ve depresyonun kümelenmesine yönelik olarak Bayesian parametrik olmayan kümeleme (Bayesian nonparametric cluster analysis) yöntemini kullanarak bir çalışma gerçekleştirmiştir.

Şizofreni

Yoon ve arkadaşları (2012), şizofreni hastalarının ayrıştırılması amacıyla LDA (lineer diskriminant analizi (linear discriminant analysis)) ile sınıflandırma modeli geliştirmiştir. Brodersen ve arkadaşları (2014), şizofreni hastası ve sağlıklı bireyleri birinden ayırmaya yönelik olarak denetimli ve denetimsiz makine öğrenmesi yöntemlerinden yararlanmıştır. SVM yöntemi ile sınıflandırma ve Gaussian mixture modeli ile kümeleme modeli oluşturulmuştur. Dowd ve arkadaşları (2016), şizofrenide anhedoni ve avolisyonun verisine göre anlaşılmasına yönelik olarak pekiştirmeli öğrenme yöntemlerinden Q-learning algoritmasından yararlanmıştır. Cao ve arkadaşları. (2018), gen verisi kullanarak

makine öğrenmesi yöntemleri ile şizofreni hastaları ve sağlıklı bireyleri birbirinden ayırt etmiştir. Çalışmada; MTL_NET (multi-task learning with network structure), MTL_SNET (sparse network structure), MTL_L21 (joint feature learning), MTL_EN (joint feature learning with elastic net), MTL_Trace (low-rank structure), LJR, SVM ve RF algoritmaları kullanılmıştır. Viviano ve arkadaşları (2018), şizofreni hastalarında, sosyal bilişsel ve nörobilişsel performansın değerlendirilmesine ve biyobelirteçlerin keşfedilmesine yönelik yaptıkları çalışmada SVM yöntemine başvurmuştur. Barzilay ve arkadaşları (2019), şizofreni hastalarının tahmin edilmesine yönelik olarak yüz tanıma sistemi geliştirmiş, sınıflandırma için SVM kullanmıştır. Fond ve arkadaşları (2019), şizofreni epizolarının tekrarlaması (relapse) ve hastanın tedaviyi bırakma olasılıklarının tahminine yönelik olarak karar ağaçlarından CART (sınıflandırma ve regresyon ağacı (classification and regression tree)) yöntemini kullanmıştır. Pinaya ve arkadaşları (2019), şizofreni ve otizm spektrum bozukluğu hastalarında beyindeki anomalilerin tespitine yönelik olarak deep autoencoder ve SVM yöntemini kullanmıştır.

Post-travmatik stres bozukluğu (PTSB)

Galatzer-Levy ve arkadaşları (2014), travmatik bir olayın ardından ortaya çıkabilecek kronik PTSB durumunu tahmin etmeye yönelik farklı SVM yöntemleri (linear SVM, optimized linear SVM, polynomial SVM), RF, AdaBoost, kernel ridge regression, Bayesian binary regression yöntemleri ile bir çalışma gerçekleştirmiştir. Karstoft ve arkadaşları (2015), PTSB riskini tahmin etme amacıyla SVM kullanmıştır. Papini ve ark. (2018), PTSB gelişiminin tahminine yönelik olarak XGBoost yöntemini kullanmıştır.

Bipolar bozukluk

Mwangi ve ark. (2016), bipolar bozukluğa sahip bireylerin sağlıklı bireylerden ayrıştırılmasına yönelik olarak relevance vector machine learning algoritmasından yararlanmıştır. Eugene ve ark. (2018), bipolar hastalarında lityum tedavisine verilecek tepkinin tahmin edilmesi amacıyla gen verisi üzerinde DT (karar ağacı (decision tree)) ve RF yöntemlerini kullanmıştır. Perez Arribas ve arkadaşları (2018), bipolar ve sınır kişilik bozukluğu hastalarının ayrıştırılmasına yönelik olarak RF ile bir model geliştirmiştir. Edgcomb ve arkadaşları (2019), bipolar bozukluk ve başka bir tıbbi bir hastalığa birlikte sahip olan bireylerde psikiyatrik yeniden başvuruya yönelik faktörlerin belirlenmesi amacıyla CART kullanarak bir model geliştirmiştir.

Opiyat kullanım bozukluğu

Han ve ark. (2020), yetişkinlerde opiyat kötüye kullanımının tahmin edilmesine yönelik olarak ANN (yapay sinir ağları (artificial neural network)), RF (distributed random forest), gradient boosting machine yöntemlerini kullanmıştır. Ellis ve arkadaşları (2019), elektronik sağlık verilerini analiz ederek opiyat bağımlılığını tahmin etme amacıyla RF kullanarak bir model geliştirmiştir.

Karma (birden fazla hastalığın ele alınması)

Zhao ve So (2019), şizofreni, depresyon, anksiyete bozukluğu hastalıklarında ilaçlarla ilgili yaptıkları çalışmada DNN, SVM, RF, gradient boosted machine (with trees), LJR (with elastic net regularization) yöntemlerinden yararlanmıştır. Mellem ve ark. (2020), düzensiz duygudurum, anksiyete ve anhedoni durumlarının tahmin edilmesi amacıyla şizofreni, bipolar bozukluk ve DEHB hastalarına yönelik LASSO regression, elastic net regression, RF yöntemleri ile çalışmıştır.

Diğer bozukluklar

Sohn ve arkadaşları (2011), psikiyatri ve psikoloji alanlarında kullanılan ilaçların yan etkilerinin öngörülmesi amacıyla C4,5 algoritmasını kullanmıştır. Qin ve arkadaşları (2014), çocukluk dönemi kaygı bozuklarının tahmin edilmesine yönelik olarak LNR kullanmıştır. Bedi ve arkadaşları (2015), ses ve konuşma analiz verileri ile convex hull classifier yöntemini kullanarak bireylerin psikoz riskinin tahmin edilmesine yönelik bir çalışma gerçekleştirmiştir. Just ve arkadaşları (2017), intihar riskinin değerlendirilmesine yönelik olarak gaussian naive Bayes yöntemi ile bir model geliştirmiştir. Sato ve arkadaşları (2018), beyin bağlantısallığı verileri kullanarak (brain connectivity) SVM yönteminin bir türü olan one-class SVM psikopatolojinin tahmininde kullanmıştır. Walsh ve arkadaşları (2018), yetişkinlerde intihar riskinin tahmin edilmesine yönelik olarak RF ve LJR kullanmıştır. Stamate ve arkadaşları (2019), RF, SVM, Gaussian Processes, LJR, ANN kullanarak psikoz (psikotik spektrum bozukluğu) hastası ve sağlıklı bireyleri birbirinden ayırmaya yönelik bir çalışma gerçekleştirmiştir.

Psikiyatride makine öğrenmesi ve EEG verisi ile yapılan çalışmalar

Literatür taramasının bu aşamasında bu araştırmanın da konusu olan psikiyatri alanında EEG verisi ve makine öğrenmesi yöntemleri kullanılarak yapılan çalışmalar incelenmiştir. Böylece hastalık, kullanılan veri tipi ve yöntemler temelinde, literatürdeki çalışmaların karşılaştırılması mümkün kılınmıştır. Bu amaç doğrultusunda hem ulusal hem de uluslararası literatürde bulunan çalışmalar incelenmiştir. EEG verisi kullanılarak psikiyatri alanında makine öğrenmesi teknikleri ile yapılan ulusal ve uluslararası çalışmalar Tablo 2'de verilmiştir.

Günümüzde araştırmacıların farklı alanlarda karşısına çıkan makine öğrenmesi kavramı, yapay zekanın alt dallarından biridir. Bu yöntemler farklı alanlardaki araştırmalarda veriden anlamlı sonuçların çıkarılabilmesi için algoritmalar sunar. Makine öğrenmesi; “performansı iyileştirmek veya doğru tahminler yapmak için deneyim kullanarak hesaplama yöntemleri” olarak tanımlanmaktadır (Mohri ve ark., 2012). Flach (2012), makine öğrenmesinin; “doğru görevleri gerçekleştiren doğru modelleri oluşturmak için doğru özellikleri kullanmakla ilgili” olduğunu belirtmiştir. Bu çalışma kapsamına dahil edilen çalışmalarda hangi yöntemlerin kullanıldığının incelenmesinin sebebi, farklı faktörlerin makine öğrenmesi algoritmalarının performansına etki etmesidir. Balaban ve Kartal (2018), makine öğrenmesi yöntemlerinin

Tablo 2. Psikiyatride makine öğrenmesi teknikleri ile yapılan ve EEG verisi kullanılan çalışmalar

Kaynak	Ele alınan hastalık	Veri seti kaynağı/etik kurul/destekleyen kuruluş	Veri tipi	Örnek sayısı	Yöntem	Uygulama dili/program	Validasyon	Performans
1	Khodayari-Rostamabad ve ark. (2010a)	St. Joseph's Hospital, Centre for Mountain Health Services, Hamilton, Ontario	QEEG	37 şizofreni 23 (R=12, NR=11) 14 (R=7, NR=7)	PLSR	MATLAB	LOOCV	belirleyicilik, duyarlılık ortalaması %87,12 duyarlılık %83,33, belirleyicilik %90,91% belirleyicilik, duyarlılık ortalaması %89,7 duyarlılık %85,7, belirleyicilik %93,75% belirleyicilik, duyarlılık ortalaması %85,7 duyarlılık %85,7, belirleyicilik %85,7
2	Khodayari-Rostamabad ve ark. (2010b)	Natural Sciences and Engineering Research Council of Canada (NSERC)	EEG	22 depresyon (R=8, NR=14)	PLSR	-	nested 11-fold cross-validation	belirleyicilik, duyarlılık ortalaması %86,6 belirleyicilik %85,7 duyarlılık %87,5
3	Khodayari-Rostamabad ve ark. (2011)	Natural Sciences and Engineering Research Council of Canada (NSERC), Etherden Fellowship at St. Joseph's Healthcare Foundation	EEG	27 depresyon (R=9, NR=9)	mixture of factor analysis	-	leave-2-out (L20) cross-validation	belirleyicilik, duyarlılık ortalaması %80 belirleyicilik %83,3 duyarlılık %77,8
4	Ahmadlou ve ark. (2012)	Atieh Comprehensive Center for Psych and Nerve Disorders, Tahrhan, Iran	EEG	30 DEHB (15 pozitif tepki veren, 15 negatif tepki veren)	LDA	-	(%60 eğitim %40 test) * 100	doğruluk %84,2 belirleyicilik %80,6 duyarlılık %88
5	Hosseiniard ve ark. (2013)	Psychiatry Centre Atieh, Tehran, Iran	EEG	90 45 depresyon 45 sağlıklı	KNN, LDA, LJR	MATLAB	2/3 eğitim 1/3 test	doğruluk %73,3 (KNN) doğruluk %76,6 (LDA) doğruluk %76,6 (LJR)
6	Khodayari-Rostamabad ve ark. (2013)	St. Joseph's Health Care, Hamilton, Ontario, Canada	EEG	113 22 depresyon (R=7, NR=15) 91 sağlıklı	mixture of factor analysis	-	leave-2-out (L20) cross-validation * 100	belirleyicilik, duyarlılık ortalaması %87,9 belirleyicilik %80,9 duyarlılık %94,9

Tablo 2. Devamı

Kaynak	Ele alınan hastalık	Veri seti kaynağı/etik kurul/destekleyen kuruluş	Veri tipi	Örnek sayısı	Yöntem	Uygulama dili/program	Validasyon	Performans
7	Zhang ve ark. (2013)	National Basic Research Pro-gram of China, National Natural Science Foundation of China, EU's Seventh Framework Programme OPTIMIL, Fundamental Research Funds for the Central Universities	EEG	15 13 depresyon 2 sağlıklı	BPNN, KNN	SPSS	2/3 eğitim, 1/3 test + 3-kat CV	mean classification rate %94,2 (BPNN) mean classification rate 92,9 (KNN)
8	Tenev ve ark. (2014)	DEHB = ADHD Project of EU- Cost Action B27, sağlıklı = profesyonel çalışanlar ve toplumsal organizasyon Skopje, Macedonia	QEEG	117 67 DEHB 50 sağlıklı	SVM	-	10 kat CV	doğruluk %82,3
9	Ergüzel ve ark. (2015a)	İstanbul Nöropsikiyatri Hastanesi	QEEG kordans	55 depresyon R=30, NR=25	ANN	MATLAB	6,8,10 kat CV	doğruluk %89,09 (k=6), %85,45 (k=8) %87,27 (k=10)
10	Ergüzel ve ark. (2015b)	trikotilomani - obsesif kompulsif bozukluk NPIstanbul Hospital	QEEG kordans	79 39 TTM, 40 OKB	ANN, SVM, KNN, NB	MATLAB	6, 10 kat CV	doğruluk %63,29 YSA doğruluk %67,08 DVM doğruluk %59,96 KNN doğruluk %56,96 naive Bayes doğruluk %81,04 özmitelik seçimi + DVM
11	Ergüzel ve ark. (2015c)	İstanbul Nöropsikiyatri Hastanesi	QEEG kordans	101 46 bipolar 55 depresyon	SVM (linear kernel, polynomial kernel, RBF kernel)	MATLAB	6-kat CV (dışta), 5-kat CV (içte)	doğruluk %62,37 (özmitelik seçimi yok) doğruluk DVM + PSO (%73,26) doğruluk DVM + GA (%75,24) doğruluk DVM + ACO (%78,21) doğruluk DVM + IACO (%80,19)
12	Mohammadi ve ark. (2015)	Royal Ottawa HealthCare Group, the University of Ottawa Social Sciences and Humanities Research Ethics Boards	QEEG	98 53 depresyon 43 sağlıklı	C4,5	MATLAB, IBM SPSS Modeler	% 70 eğitim, % 30 test	doğruluk %80
13	Al-Kaysi ve ark. (2016)	Black Dog Institute, Human Research Ethics Committee of the University of New South Wales	EEG	10 hasta	SVM, LDA, ELM	-	100CV	hata oranı 0,2167

Tablo 2. Devamı

Kaynak	Ele alınan hastalık	Veri seti kaynağı/etik kurul/destekleyen kuruluş	Veri tipi	Örnek sayısı	Yöntem	Uygulama dili/program	Validasyon	Performans
Johannesen ve ark. (2016)	şizofreni	VA Connecticut Healthcare (VACHS) Human Studies Subcommittee, Yale University Human Investigation Committee	EEG	40 şizofreni 12 sağlıklı	SVM	-	3-kat CV	%87 doğruluk, %90 duyarlılık, %77 belirleyicilik
Ramyead ve ark. (2016)	psikoz	FePsy Clinic at University Psychiatric Clinics Basel, University Psychiatric Outpatient Department of Basel ya da psikiyatristin özel muayenehanesinden gelen hastalar	EEG	53 ARMS-NT=35, ARMS-N=18	LASSO (least absolute shrinkage and selection operator)	R	10-kat CV * 10	balanced accuracy %57 (LPS), %47 duyarlılık, %67 belirleyicilik balanced accuracy %69 (CSD), %63 duyarlılık, %76 belirleyicilik balanced accuracy %70 (stacked), %58 duyarlılık, %83 belirleyicilik
Mumtaz ve ark. (2017a)	depresyon	Outpatient clinic of Hospital Universiti Sains Malaysia (HUSM), Malaysia	EEG	63 33 depresyon 30 sağlıklı	LJR, NB,SVM	-	10-kat CV * 100	doğruluk %97,6, duyarlılık %96,66, belirleyicilik %98,5 (LR) doğruluk %96,8, duyarlılık %96,6, belirleyicilik %97,02 (NB) doğruluk %98,4, duyarlılık %96,66, belirleyicilik %100 (DVM)
Mumtaz ve ark. (2017b)	depresyon	Hospital Universiti Sains Malaysia (HUSM), Kelantan, Malaysia	EEG	74 30 sağlıklı 34 hasta (R=16, NR=18)	LJR	MATLAB	10-kat CV * 100	doğruluk %87,5, duyarlılık %95, belirleyicilik %80
S. Zhao ve ark. (2017)	depresyon	Beijing Anding Hospital Affiliated to Capital University of Medical Sciences	EEG	170 81 depresyon, 89 sağlıklı	Local classification (KNN + NB), SVM (RBF Kernel), Xgboost (Gbtree + LJR)	-	%75 eğitim, %25 test 10-kat CV	Local classification(KNN + Naive Bayes) %78,4, DVM (RBF Kernel) %77,8, Xgboost (Gbtree + Logistic Regression) %75,8

Tablo 2. Devamı

Kaynak	Ele alınan hastalık	Veri seti kaynağı/etik kurul/destekleyen kuruluş	Veri tipi	Örnek sayısı	Yöntem	Uygulama dili/program	Validasyon	Performans
19	Bailey ve ark. (2018)	Monash Alfred Psychiatry Research Centre	EEG	39 depresyon (R=10, NR=29) 20 sağlıklı	SVM	-	200,000* 5- kat CV	balanced accuracy 91% duyarlılık %90 belirleyicilik %92
20	Ergüzel ve İnanhan (2018)	Neuropsychiatry Istanbul	qEEG	147 depresyon (R=90, NR=57)	ANN, SVM, DT	-	10- kat CV	doğruluk %82,9, duyarlılık %88,9 (ANN) doğruluk %86,4, duyarlılık %95,6 (DVM) doğruluk %78,3 duyarlılık %85,6 (KA)
21	Ergüzel ve ark. (2019)	Neuropsychiatry Istanbul Hospital Department of Psychiatric Outpatient Clinics	qEEG	134 75 opioid 59 sağlıklı	LJR, ANN	MATLAB	8- kat CV	doğruluk %84,3 (LR) doğruluk (overall accuracy) %94,89 (ANN)

Yöntem

- ANN = yapay sinir ağı (artificial neural network)
- DT = karar ağacı (decision tree)
- ELM = aşırı öğrenme makinesi (extreme learning machine)
- KNN = k-en yakın komşu (k-nearest neighbor)
- LDA = lineer diskriminant analizi (linear discriminant analysis)
- LJR = lojistik regresyon (lojistik regression)
- NB = sade Bayes (naïve Bayes)
- PLSR = kısmi en küçük kareler regresyonu (partial least squares regression)
- RF = rasgele orman (random forest)
- SVM = destek vektör makinesi (support vector machine)

Validasyon

- CV = çapraz geçiş (cross validation)
- LOOCV = birini dışarıda bırak çapraz geçiş (leave-one-out-cross validation)

Örnek Sayısı & Ele Alınan Hastalık

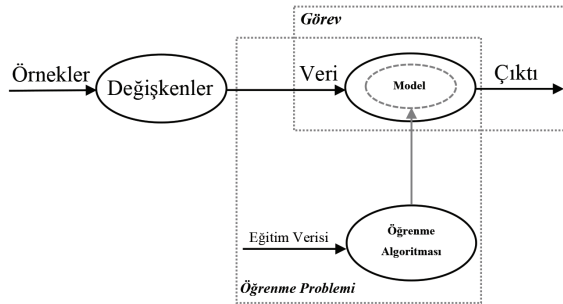
- ARMS-NT = durumu psikoza dönmeyen risk durumundaki hastalar (at-risk mental state patients did not made a transition to psychosis)
- ARMS-T = durumu psikoza dönen risk durumundaki hastalar (at-risk mental state patients made a transition to psychosis)
- R = tedaviye yanıt veren (responder)
- NR = tedaviye yanıt vermeyen (non-responder)

* Çalışmaların bazılarında birden fazla parametre veya algoritma ile birden fazla sonuç elde edilmiştir. Tüm sonuçları birden tabloya eklemek mümkün olmadığından en iyi sonuç veya araştırmanın yazarlarının öne çıkardığı sonuçlar aktarılmıştır. Tüm sonuçlara ulaşmak için orijinal kaynaklar incelenebilir.

performansını etkileyen faktörleri şu şekilde belirtmektedir:

- Veri seti: Veri seti algoritmaya “öğrenme” amacıyla verildiği için deneyim olarak adlandırılmaktadır. Deneyimin fazla olması ve farklı durumlara dair veri içermesi performansı olumlu etkilemektedir.
- Sonuca etki eden değişkenlerin varlığı: Araştırılan probleme uygun niteliklere uygun nitelik/değişken (sütun) varlığı sonuca etki etmektedir.
- Seçilen öğrenme stratejisi: Araştırılan probleme veya veri setinin yapısına uygun olan öğrenme stratejisinin seçilmesi sonuçlara etki etmektedir.
- Kullanılan algoritma ve varsa algoritmaya ait parametreler: Veri setinin yapısına ve seçilen öğrenme stratejisine uygun algoritmanın ve varsa parametrelerin seçilmesi performansı etkileyebilmektedir.

Flach (2012), makine öğrenmesinin uygulanma mantığını Şekil 3’teki gibi göstermektedir. Belli bir görevi yerine getirmek amacıyla, örneklerden (sütun) ve değişkenlerden oluşan (sütun) bir veri seti kullanılır. Seçilen öğrenme stratejisine uygun olarak, veri setinin bir kısmı veya tamamı algoritmanın öğrenmesi için kullanılır ve seçilen algoritma eğitim verisine (training data) uygulanarak model elde edilir. Modelin çıktılarına göre farklı ölçütler hesaplanır ve performans değerlendirmesi yapılır. Öğrenme stratejisi mevcut veri setinin yapısına göre değişiklik göstermektedir; veri setindeki sınıf değerlerinin belli olduğu durumlarda öğrenme stratejisi denetimli veya danışmanlı (supervised) olarak adlandırılırken sınıf değerlerinin belli olmadığı durumlarda öğrenme stratejisi denetimsiz veya danışmansız (unsupervised) olarak adlandırılır (Mohri ve ark. 2012). Daha açık ifade etmek gerekirse, denetimli öğrenme yaklaşımında, veri setindeki her bir örneğin ait olduğu kategori/etiket bellidir ve bu değerler üzerinden analiz yapılır. Denetimsiz öğrenmede ise bu değerler belli değildir. Denetimli öğrenme yaklaşımında sınıflandırma (classification), regresyon (regression) gibi yöntemler ile geleceğe dönük çıkarımlar yapılmaya çalışılırken, denetimsiz öğrenme yaklaşımında ise kümeleme (clustering) gibi yöntemlerle veri içerisindeki özelliklerin keşfedilmesi hedeflenir (Bishop 2006).



Şekil 3. Belli bir görev/amaca yönelik olarak makine öğrenmesinin genel çalışma mantığı (Flach 2012).

Tablo 2’de “Yöntem” olarak tabloda verilen sütun kullanılan algoritmaları ifade etmektedir. Tüm çalışmalarda denetimli öğrenme yaklaşımına göre çalışan farklı sınıflandırma algoritmaları

veya istatistiksel yöntemler kullanılmıştır. “Uygulama dili/Program” olarak ifade edilen sütunda makine öğrenmesi algoritmalarının uygulanması için kullanılan programlama dili ve bu dilin yazıldığı platform ifade edilmiştir. “Validasyon” yani model performans değerlendirme yöntemlerini ifade eden sütunda, sınıflandırma algoritmaları uygulanırken eğitim veri setinin hangi yöneme göre seçildiği/ayrıldığı ifade edilmiştir. Sınıflandırma yöntemlerinde eğitim ve test olmak üzere veri seti ikiye ayrılır; eğitim veri seti ile model oluşturulurken test veri seti ile modelin performansı test edilir. İstenen sayıda örneğin rastgele seçildiği bootstrap (Efron ve Tibshirani 1993), veri setinin belirlenen orana göre eğitim ve test olarak veri setinin bölündüğü hold-out (Kohavi 1995) ve veri setinin eşit sayılarda parçalara ayrılarak her seferinde bir parçanın test ve geri kalan parçaların eğitim olarak atandığı çapraz geçirme yöntemi (cross validation) (Mosteller ve Tukey1968, Stone 1974) bu yöntemler arasında sıkça kullanılanlardır. Model performans değerlendirme ölçütlerini ifade eden “Performans” sütununda ise oluşturulan modellerin performanslarının hangi hesaplama değerine göre değerlendirildiği belirtilmiştir. Şekil 4'teki (Han ve ark. 2012) değerler baz alınarak göre sınıflandırma algoritmalarının doğruluk (accuracy), hata oranı (error rate), duyarlılık (sensitivity, recall), belirleyicilik (specificity), pozitif öngörü değeri (positive predictive value), negatif öngörü değeri (negative predictive value), F-ölçütü (F-score) gibi farklı değerler hesaplanır ve modelin değerlendirmesi buna göre yapılır.

Şekil 4. Karmaşıklık matrisi (Han ve ark. 2012)

Karmaşıklık Matrisi		Tahmin		
		Pozitif	Negatif	Toplam
Gerçek	Pozitif	TP doğru pozitif	FN yanlış negatif	P
	Negatif	FP yanlış pozitif	TN doğru negatif	N
Toplam		P'	N'	P+N

P: Gerçekte pozitif sınıfa ait olan örneklerin sayısı; **N:** Gerçekte negatif sınıfa ait olan örneklerin sayısı

P': Pozitif sınıfta olduğu tahmin edilen örneklerin sayısı; **N':** Negatif sınıfta olduğu tahmin edilen örneklerin sayısı

Khodayari-Rostamabad ve arkadaşları (2010a), şizofreni hastalarında klozapin tedavisine (clozapine therapy) verilecek tepkinin tahmin edilmesine yönelik bir çalışma gerçekleştir ve kısmi en küçük kareler regresyonu (kernel partial least squares regression - KPLRS) yöntemini kullanmıştır. Belirleyicilik, duyarlılık değerlerinin ortalaması alınarak modelin performansı %87,12 ve %89,7 olarak hesaplanmış, başka bir grup hasta ile yapılan testin sonucu olarak modelin performansı ise %85,7 olarak hesaplanmıştır.

Khodayari-Rostamabad ve arkadaşları (2010b), depresyon tedavisinde kullanılan bir antidepresanın etkilerinin etkinliğinin tahmin edilmesi amacıyla kısmi en küçük kareler regresyonu (kernel partial least squares regression - KPLRS) yöntemini kullanmıştır. Modelin değerlendirilmesi için belirleyicilik (%85,7) ve duyarlılık (%87,5) değerlerinin ortalaması alınmış ve bu değer %86,6 olarak hesaplanmıştır.

Khodayari-Rostamabad ve arkadaşları (2011), tekrarlayan transkraniyal manyetik uyurım tedavisi – tTMU (repetitive transcranial magnetic stimulation - rTMS) tedavisine verilecek

tepkinin tahmin edilmesi amacıyla mixture of factor analysis tekniğini kullanmıştır. Modelin değerlendirilmesi için belirleyicilik (%83,3), duyarlılık (%77,8) değerlerinin ortalaması alınmış ve bu değer %80 olarak hesaplanmıştır.

Ahmadlou ve arkadaşları (2012), DEHB hastalarının neurofeedback tedavisine (neurofeedback treatment) verecekleri tepkinin tahmin edilmesi amacıyla bir çalışma gerçekleştirmiştir. Tahmin için LDA ile model oluşturulmuş; doğruluk 84,2%, belirleyicilik 80,6%, duyarlılık 88,2% elde edilmiştir.

Hosseiniyard ve arkadaşları (2013), EEG frekans bantlarıyla beraber lineer olmayan özellikleri de dahil ettikleri bir sınıflandırma çalışması yaparak depresyon hastaları ve sağlıklı bireyleri birbirinden ayırmışlardır. Sınıflandırıcı olarak KNN, LDA, LJR kullanılmıştır. Öznitelik seçimi ve lineer olmayan özelliklerin de dahil edildiği farklı modeller elde edilmiştir. EEG frekans bantlarına göre yapılan sınıflandırma modellerine göre doğruluk değerleri %73,3 (KNN), %76,6 (LDA) ve %76,6 (LJR) olarak elde edilmiştir.

Khodayari-Rostamabad ve arkadaşları (2013), SSRI (seçici serotonin geri alım inhibitörleri) antidepresan tedavisinin depresyon hastaları üzerindeki etkisinin tahmin edilmesi amacıyla yaptıkları çalışmada mixture of factor analysis kullanmıştır. Modelin değerlendirilmesi için belirleyicilik %80,9 ve duyarlılık %94,4 değerlerinin ortalaması alınmış ve bu değer %87,9 olarak hesaplanmıştır.

Zhang ve arkadaşları (2013), çalışmalarında depresyon hastası ve sağlıklı grubun birbirinden ayrılmasına yönelik olarak geri yayımlı ANN (back propagation neural network - BPNN) ve KNN (k=1) kullanarak sırasıyla %94,2 ve %92,9 doğruluk değeri elde etmiştir.

Tenev ve arkadaşları (2014), yaptıkları çalışmada DEHB ve kontrol gruplarını SVM ile birbirinden ayırmıştır. Çalışmada birden fazla şekilde sınıflandırma modeli oluşturulmuştur. Bunlar arasından hasta ve sağlıklı gruplarını ayırmak için kurulan modelin doğruluğu en yüksek %82,3 olarak elde edilmiştir.

Ergüzel ve arkadaşları (2015a), depresyon hastalarında tekrarlayan transkraniyal manyetik uyarım tedavisi - rTMS (repetitive transcranial magnetic stimulation - rTMS) tedavisinin yararlı olup olmayacağını tahmin edilmesi amacıyla ANN ile tahmin etmiştir. Farklı parametreler ile kurulan modellerde en yüksek doğruluk değeri %89,09 olarak elde edilmiştir.

Ergüzel ve arkadaşları (2015b), trikotilomani (TTM) ve obsesif kompulsif bozukluk (OKB) hastalarının sınıflandırılmasına yönelik yaptıkları çalışmada ANN, SVM, KNN, NB yöntemleri ile öznitelik seçimi yaparak kurdukları modellerde farklı doğruluk değerleri elde etmişlerdir. En yüksek doğruluk değeri karınca kolonisi optimizasyon algoritması ile geliştirilmiş versiyonu ile öznitelik seçimi yapılarak ve SVM uygulanarak %81,04 olarak elde edilmiştir.

Ergüzel ve arkadaşları (2015c), depresyon ve bipolar bozukluk hastalarının birbirinden ayrıştırılması amacıyla yaptıkları çalışmada sınıflandırıcı olarak SVM kullanmış ve farklı öznitelik seçme yöntemleri ile oluşturdukları SVM modellerinden farklı performans değerlendirme ölçütleri elde etmiştir. Bunlar arasından en yüksek doğruluk değeri %80,19 olarak elde edilmiştir.

Mohammadi ve arkadaşları (2015), depresyon hastalarının ve sağlıklı bireylerin birbirinden

ayrılmasına yönelik yaptıkları çalışmada C4,5 karar ağacı algoritmasını kullanmış, farklı öznitelikler ve yöntemler kullanarak modeller kurmuştur. Buna göre modelde en yüksek doğruluk değeri %80 olarak elde edilmiştir.

Al-Kaysi ve arkadaşları (2016), depresyon hastalarında transkraniyal doğru akım uyarımı (transcranial direct current stimulation - tDCS) tedavisine verilecek tepkinin tahmin edilmesi amacıyla SVM, LDA, aşırı öğrenme makinesi (extreme learning machine - ELM) yöntemlerini kullanmış; sınıflandırmanın değerlendirilmesi için hata oranı (error rate) değeri verilmiştir. Bu değer üç modelin ortalaması olarak 0,2167 elde edilmiştir.

Johannesen ve arkadaşları (2016), şizofreni ile ilgili yaptıkları çalışmada, SVM sınıflandırıcısı ile şizofreni ve sağlıklı bireyleri %87 doğruluk oranı ile birbirinden ayırtı edebilen bir model geliştirmiştir.

Ramyeed ve arkadaşları (2016), psikoz riski altındaki hastaların klinik sonuçlarını tahmin etmeye yönelik olarak gerçekleştirdikleri çalışmada EEG değerlerine bağlı olarak hesaplanan CSD (gamma current-source density) LPS (lagged phase synchronisation) değerleri ile LASSO (least absolute shrinkage and selection operator) algoritması kullanmıştır. Buna göre modelin değerlendirilmesine ROC eğrisi altına kalan alandan yararlanılmış ve farklı modellerden balanced accuracy %0,57 (LPS), %0,69 (CSD) ve %0,70 (LPS-CSD kombinasyonu) olarak elde edilmiştir.

Mumtaz ve arkadaşları (2017a), depresyon hastası ve sağlıklı bireylerin ayırt edilmesine yönelik olarak yaptığı çalışmada farklı modeller ile farklı sonuçlar elde etmiştir. Interhemispheric alpha asymmetry değerlerine göre LJR ile %97,6, NB ile %96,8, SVM ile %98,4 doğruluk değerleri elde edilmiştir.

Mumtaz ve arkadaşları (2017b), depresyon hastalarının antidepresan tedavisine verecekleri yanıtın tahmin edilmesine yönelik bir çalışma gerçekleştirmiştir. Farklı öznitelik çıkarımı (feature extraction) ve öznitelik seçimi (feature selection) yöntemlerinin kullanılması ile kurulan LJR modellerinden, farklı model performans ölçütleri elde edilse de elde edilen en yüksek doğruluk değeri %87,5'tir.

Zhao ve arkadaşları (2017), depresyon tanısı konması amacıyla giyilebilir bir sistem geliştirmiştir. Local classification (KNN + NB), SVM (RBF Kernel), Xgboost (Gmtree + LJR) sınıflandırıcıların kullanıldığı çalışmada hasta ve kontrol gruplarındaki bireylerin ayrıştırılması sırasıyla %78,4, %77,8, %75,8 olarak elde edilmiştir.

Bailey ve arkadaşları (2018), depresyon hastalarında tekrarlayan transkraniyal manyetik uyarım tedavisine - tTMU (repetitive transcranial magnetic stimulation - rTMS) verilecek tepkinin tahmin edilmesine yönelik olarak lineer SVM ile sınıflandırma modeli kurmuş ve doğruluk değerini %91 olarak elde etmiştir.

Ergüzel ve Tarhan (2018), tekrarlayan transkraniyal manyetik uyarım tedavisine - tTMU (repetitive transcranial magnetic stimulation - rTMS) yanıt verecek ve vermeyecek hastaların tahmin edilmesine yönelik olarak ANN, SVM ve DT kullanmış sırasıyla % 82,9, %86,4, %78,3 doğruluk değerlerini elde etmiştir.

Ergüzel ve arkadaşları (2019), opioid bağımlısı olan hasta ve kontrol bireyleri arasında

sınıflandırma yapılması amacıyla LJR ve ANN ile model kurup performanslarını karşılaştırmıştır. Her bir frekans bandı için mutlak güç (absolute power), relative power ve kordans (cordance) değerleri kullanılarak ayrı ayrı birden fazla sonuç elde edilmiştir. Tabloda yer alan her bir model için elde edilmiş olan en yüksek doğruluk değerleri olarak elde edilmiştir. LJR modelinden beta frekans bandı ve mutlak güç değerleri ile en yüksek doğruluk değeri %84,3 olarak, yapay sinir ağları modelinden ise teta frekans bandından mutlak güç değerleri ile ortalama doğruluk (overall accuracy) %94,89 olarak elde edilmiştir

Tartışma

Bu çalışma kapsamında psikiyatri alanında yapılmış olan çalışmalar incelenmiştir. Psikiyatri alanında yapılan makine öğrenmesi çalışmaları ve psikiyatri alanında EEG verisi ve makine öğrenmesi kullanılarak yapılan çalışmaların mevcut durumu ortaya konmaya çalışılmıştır. Makine öğrenmesi yöntemlerinin genel kullanım şekline dair psikiyatri alanından örnekler incelenmiş; ancak özellikle EEG verisi kullanan çalışmaların detaylı bir şekilde ele alınması amaçlanmıştır.

Psikiyatride makine öğrenmesi yöntemleri ile yapılan çalışmalara bakıldığında destek vektör makinesi (support vector machine - SVM) ve rasgele orman (random forest - RF) yöntemlerinin incelenen çalışmalar arasında öne çıktığı görülmüştür. Kullanılan yöntemlerin performansları tercih edilen parametrelere göre değişkenlik göstermektedir. Bazı çalışmalarda farklı yöntemler ile kurulan modellerin karşılaştırılması yoluyla en iyi sonuç veren model elde edilmeye çalışılırken, bazı çalışmalarda ise aynı yöntem ile farklı şekillerde model kurulması sağlanmıştır. Örnek sayılarının ise yine çalışmadan çalışmaya değişkenlik gösterdiği görülmüştür. EEG verisi dışında veri ile yapılan çalışmalarda genellikle MRI, sosyodemografik veri, klinik veri, genetik veri gibi farklı veri türleri kullanılmıştır. İncelenen 39 çalışmada genellikle tek bir hastalığın ele alınarak hasta-sağlıklı şeklinde bir ayırıştırma yapılmaya çalışıldığı ancak az da olsa bazı çalışmalarda birden fazla hastalığın ele alındığı görülmüştür.

Makine öğrenmesi ve EEG kullanan mevcut çalışmaların tümünde, veri analizinde kullanılan araçların (programlama dili, platform, program gibi) belirtilmediği görülmüştür. Bazı araştırmalarda araçlar belirtilirken bazılarında belirtilmemiştir. Bazı çalışmalarda hem EEG hem de veri analizi için hangi programların veya dillerin kullanıldığı belirtilirken bazılarında tek bir araçtan bahsedilmektedir. Bu durumda çalışmanın hangi aşamasında hangi aracın kullanıldığı belirsiz kalmaktadır. Ancak özellikle bir programının çalışmanın bir aşamasında kullanıldığı belirtildiyse sonraki aşamalarında da bu araç ile devam edildiği varsayımı yapılmıştır. Çalışmaların hangi araçlar ile yapıldığını belirtmesi diğer araştırmacılar açısından faydalı olabilir. Araçların belirtildiği çalışmalara bakıldığında ise yoğunlukla MATLAB programının kullanıldığı görülmüştür. MATLAB sıklıkla birçok farklı alanda kullanılan bir program olsa da veri bilimi araştırmacıları tarafından sıklıkla R ve Python dilleri tercih edilmektedir. İncelenen çalışmalar daha çok psikiyatri veya tıp alanlarında çalışan araştırmacılar tarafından yapılmış olduğundan çalışmalar arasında bu programın daha sık kullanıldığı düşünülmektedir. Veri bilimi alanında çalışan araştırmacılar ile psikiyatri gibi farklı

alanlardan araştırmacıların bir araya gelmesi disiplinler arası çalışmaların artmasını ve yapay zeka, makine öğrenmesi, veri madenciliği gibi birçok güncel kavram ve yöntemin kullanımının yaygınlaşmasını sağlayacaktır.

Çalışmalarda kullanılan veri setlerine örnek sayıları açısından bakıldığında sayıların 10 ile 170 arasında değiştiği görülmektedir. Birçok alanda veri sayısı çok daha yüksekken sağlık çalışmalarında özellikle psikiyatri alanında bu durum normaldir. Çalışmalarda yapılan ayrıştırma, bireylerin hasta, normal veya bir tedaviye verilecek tepkiye göre tepki veren (R=responder), tepki vermeyen (NR=non responder) şeklinde sınıflandırılması amacıyla yapılandırılmıştır. Birden fazla hastalığın örneğin bireylerin DEHB, şizofreni, depresyon, bipolar olup olmadığına yönelik hastalık çeşidi açısından kapsamlı bir çalışmaya rastlanmamıştır. Depresyon-bipolar, OKB-TTM ayrıştırmasının yapıldığı iki çalışma haricinde diğer çalışmalar bir tedaviye verilen tepki veya hasta-normal ayrıştırması olarak yapılandırılmıştır. İki'den fazla hastalığın birlikte ele alındığı, ayrıştırma açısından daha kapsamlı veri setleri ile çalışılmadığı görülmüştür. Bu durumun sebebi psikiyatri alanının kendi doğasından kaynaklanıyor olabilir. Ancak yine de birden fazla hastalığın ayrıştırılmasına yönelik çalışmaların bu alana katkı sağlayabileceği düşünülmektedir.

İncelenen çalışmalarda, modellerin değerlendirilmesi için model performans değerlendirme metriklerinden bazıları kullanılmıştır. Her çalışmada aynı metriklerin kullanılmaması, farklı çalışmalardaki modellerin karşılaştırmasını zorlaştırmaktadır. Bazı çalışmalarda sadece doğruluk değeri verilirken bazılarında duyarlılık, hassasiyet gibi diğer metriklerde bazıları da verilmiştir. Bütün metrikleri paylaşan çalışmalara ait sonuçların hepsini bu çalışma kapsamında vermek mümkün olmadığı gibi her çalışmada aynı metriklerin paylaşılmaması, modellerin aynı temelde karşılaştırılmasını mümkün kılmamaktadır.

Sonuç

Psikiyatri alanında makine öğrenmesi yöntemlerinin uygulanabileceği, alan uzmanlarının karar verme mekanizmalarına destekleyici nitelikte sonuçlar ortaya çıkarabileceği düşünülmektedir. Uzman doktorlar hem DSM-V ve ICD gibi uluslararası kabul gören referanslar hem de kendi tecrübeleri çerçevesinde belirti tabanlı olarak tanı koymaktadır. Belirti tabanlı tanı koyma yaklaşımı, mevcut yapay zeka teknolojileri ile desteklenerek tanı, tedavi, ilaç dozajlarının ayarlanması, hastalanma veya iyileşme sürelerinin tahmin edilmesi, risk grubundaki bireylerin belirlenmesi, hastalıkların önceden tahmin edilmesi veya insan gözünün kaçırabileceği ayrıntıları yakalayabilmesi gibi pek çok açıdan psikiyatri alanında fayda sağlayabilir. Bunların yanında bu yöntemler; bireylerin çevresel, genetik, biyolojik faktörleri birlikte değerlendirerek çok daha geniş bir perspektiften bütüncül bir yaklaşım ile hastalıklara çözüm sağlama amacıyla kullanılabilir. Ayrıca EEG, MRI (manyetik rezonans görüntüleme – magnetic resonance imaging) gibi görüntü verisi, klinik veri, genetik veri, biyolojik veri gibi farklı veri türünün bir araya getirildiği büyük veri setleri ile yapılacak çalışmalar bu alandaki araştırmaların güvenilirliğini artırabilir. Farklı hastalıkların çalışmalarda birlikte ele alınarak hastalıklar arasında kapsamlı bir ayrıştırma yapılması mümkün kılabilir. Hasta ve kontrol gruplarının tek

kurumdan değil farklı kurumlardan toplanarak çalışmaların kapsamlarının ulusal hatta mümkünse uluslararası anlamda genişletilmesi sağlanarak araştırmaların sonuçlarının genelleştirilmesi sağlanabilir. Bu çalışmada olduğu gibi veri analizi için istatistiksel yöntemlerin dışında veri bilimine hizmet eden yöntemlerin kullanılarak çalışmaların disiplinler arası bir niteliğe getirilmesi önemli görülmektedir. İlerleyen çalışmalarda bunlar ve benzeri şekillerde araştırmaların geliştirilmesinin, psikiyatri alanında yapılan çalışmaların kapsamının genişletilmesine katkı sağlayacağı düşünülmektedir.

Kaynaklar

- Ahmadlou M, Rostami R, Sadeghi V (2012) Which attention-deficit/hyperactivity disorder children will be improved through neurofeedback therapy? A graph theoretical approach to neocortex neuronal network of ADHD. *Neurosci Lett*, 516:156-160.
- Al-Kaysi AM, Al-Ani A, Loo CK, Breakspear M, Boonstra TW (2016) Predicting brain stimulation treatment outcomes of depressed patients through the classification of EEG oscillations. *Annu Int Conf IEEE Eng Med Biol Soc*: 5266-5269. 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)
- Bailey NW, Hoy KE, Rogasch NC, Thomson RH, McQueen S, Elliot D et al. (2018) Responders to rTMS for depression show increased fronto-midline theta and theta connectivity compared to non-responders. *Brain Stimul*, 11:190-203.
- Balaban ME, Kartal E (2018) Veri Madencilği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları (2 baskı.). İstanbul, Çağlayan Kitapevi.
- Barzilay R, Israel N, Krivoy A, Sagy R, Kamhi-Nesher S, Loebstein O et al. (2019) Predicting affect classification in mental status examination using machine learning face action recognition system: a pilot study in schizophrenia patients. *Front Psychiatry*, 10:288.
- Bedi G, Carrillo F, Cecchi GA, Slezak DF, Sigman M, Mota NB et al. (2015) Automated analysis of free speech predicts psychosis onset in high-risk youths. *NPJ Schizophren*, 1:15030.
- Bishop, C (2006). *Pattern Recognition and Machine Learning*. Information Science and Statistics. New York, Springer-Verlag.
- Brodersen, KH, Deserno, L, Schlagenhaut, F, Zhihao, L, Penny, WD, Buhmann, JM ve Stephan, KE (2014). Dissecting psychiatric spectrum disorders by generative embedding. *Neuroimage Clin*, 4:98-111.
- Cao H, Meyer-Lindenberg A, Schwarz E (2018) Comparative evaluation of machine learning strategies for analyzing big data in psychiatry. *Int J Mol Sci*, 19:3387.
- Dipnall J F, Pasco J A, Berk M, Williams LJ, Dodd S, Jacka FN et al. (2017) Why so GLUMM? Detecting depression clusters through graphing lifestyle-environs using machine-learning methods (GLUMM). *Eur Psychiatry*, 39:40-50.
- Dowd EC, Frank MJ, Collins A, Gold JM, Barch DM (2016) Probabilistic reinforcement learning in patients with schizophrenia: relationships to anhedonia and avolition. *Biol Psychiatry Cogn Neurosci Neuroimaging*, 1:460-473.
- Edgcomb J, Shaddox T, Helleman G, Brooks JO (2019) High-risk phenotypes of early psychiatric readmission in bipolar disorder with comorbid medical illness. *Psychosomatics*, 60:563-573.
- Efron B, Tibshirani R (1993) *An Introduction to the Bootstrap*. New York, Chapman & Hall.
- Ellis RJ, Wang Z, Genes N, Ma'ayan A (2019) Predicting opioid dependence from electronic health records with machine learning. *BioData Mining*, 12:3.
- Ergüzel TT, Noyan CO, Eryılmaz G, Ünsalver BÖ, Cebi M, Tas C et al. (2019) Binomial logistic regression and artificial neural network methods to classify opioid-dependent subjects and control group using quantitative EEG power measures. *Clin EEG Neurosci*, 50:303-310.
- Ergüzel TT, Özkes S, Gültekin S, Tarhan N, Hızlı Sayar G, Bayram A (2015a) Neural network based response prediction of rTMS in major depressive disorder using QEEG cordance. *Psychiatry Investig*, 12:61-65.
- Ergüzel TT, Özkes S, Sayar GH, Tan O, Tarhan N (2015b) A hybrid artificial intelligence method to classify trichotillomania and obsessive compulsive disorder. *Neurocomputing*, 161:220-228.
- Ergüzel TT, Taş C, Cebi M (2015c) A wrapper-based approach for feature selection and classification of major depressive disorder–bipolar disorders. *Comput Biol Med*, 64:127-137.
- Ergüzel TT, Tarhan N (2018) Machine learning approaches to predict repetitive transcranial magnetic stimulation treatment response in major depressive disorder. In *Proceedings of SAI Intelligent Systems Conference (IntelliSys) 2016* (Eds Y Bi, S Kapoor, R Bhatia):391-401. Cham: Springer International Publishing.

- Eugene A R, Masiak J, Eugene B (2018) Predicting lithium treatment response in bipolar patients using gender-specific gene expression biomarkers and machine learning. *F1000Res*, 7:474.
- Flach P (2012). *Machine Learning: The Art and Science of Algorithms That Make Sense of Data*. Cambridge, Cambridge University Press.
- Fond G, Bulzacka E, Boucekine M, Schürhoff F, Berna F, Godin O et al. (2019) Machine learning for predicting psychotic relapse at 2 years in schizophrenia in the national FACE-SZ cohort. *Prog Neuropsychopharmacol Biol Psychiatry*, 92:8-18.
- Galatzer-Levy IR, Karstoft, K-I, Statnikov A, Shalev AY (2014) Quantitative forecasting of PTSD from early trauma responses: A Machine Learning application. *J Psychiatr Res*, 59:68-76.
- Han D-H, Lee S, Seo DC (2020) Using machine learning to predict opioid misuse among U.S. adolescents. *Prev Med*, 130:105886.
- Han J, Kamber M, Pei J (2012) *Data Mining: Concepts and Techniques* (3rd edition.). New York, Morgan Kaufman Publishers.
- Hatton CM, Paton L W, McMillan D, Cussens J, Gilbody S, Tiffin PA (2019) Predicting persistent depressive symptoms in older adults: A machine learning approach to personalised mental healthcare. *J Affect Disord*, 246:857-860.
- Hosseinifard B, Moradi MH, Rostami, R (2013) Classifying depression patients and normal subjects using machine learning techniques and nonlinear features from EEG signal. *Comput Methods Programs Biomed*, 109:339-345.
- Johannesen JK, Bi J, Jiang R, Kenney JG, Chen C-M A (2016) Machine learning identification of EEG features predicting working memory performance in schizophrenia and healthy adults. *Neuropsychiatr Electrophysiol*, 2:3.
- Just MA, Pan L, Cherkassky VL, McMakin DL, Cha C, Nock MK et al. (2017) Machine learning of neural representations of suicide and emotion concepts identifies suicidal youth. *Nat Hum Behav*, 1:911-919.
- Karstoft K-I, Galatzer-Levy IR, Statnikov A, Li Z, Shalev AY, For members of the Jerusalem Trauma Outreach and Prevention Study (J-TOPS) group (2015) Bridging a translational gap: Using machine learning to improve the prediction of PTSD. *BMC Psychiatry*, 15:30.
- Khodayari-Rostamabad A, Hasey GM, MacCrimmon DJ, Reilly JP, Bruin H de (2010a) A pilot study to determine whether machine learning methodologies using pre-treatment electroencephalography can predict the symptomatic response to clozapine therapy. *Clin Neurophysiol*, 121:1998-2006.
- Khodayari-Rostamabad A, Reilly JP, Hasey G, de Bruin H, MacCrimmon D (2010b) Using pre-treatment EEG data to predict response to SSRI treatment for MDD. *Annu Int Conf IEEE Eng Med Biol Soc:6103-6106*. 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology, Buenos Aires, Arjantin.
- Khodayari-Rostamabad A, Reilly JP, Hasey GM, de Bruin H, MacCrimmon D (2011) Using pre-treatment electroencephalography data to predict response to transcranial magnetic stimulation therapy for major depression. *Annu Int Conf IEEE Eng Med Biol Soc: 6418-6421*. 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Boston, IEEE.
- Khodayari-Rostamabad A, Reilly JP, Hasey GM, de Bruin H, MacCrimmon DJ (2013) A machine learning approach using EEG data to predict response to SSRI treatment for major depressive disorder. *Clin Neurophysiol*, 124:1975-1985.
- Kohavi R (1995). A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *Proceedings of the 14th International Joint Conference on Artificial Intelligence:1137-1145*. International Joint Conference on Artificial Intelligence.
- Kuang D, He L (2014) Classification on ADHD with Deep Learning. *2014 International Conference on Cloud Computing and Big Data: 27-32*. 2014 International Conference on Cloud Computing and Big Data, Wuhan, China: IEEE.
- Kutlu Y (2010) *Modelden bağımsız yöntemler kullanılarak EEG ve EKG içindeki anormal örüntülerin çok katlı sınıflandırılması*. (Doktora tezi). İzmir, Dokuz Eylül Üniversitesi.
- Li Y, Rosenfeld B, Pessin H, Breitbart W (2017) Bayesian Nonparametric Clustering of Patients with Advanced Cancer on Anxiety and Depression. *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA):674-678*. 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), Cancun, Meksika, IEEE.
- Mellem MS, Liu Y, Gonzalez H, Kollada M, Martin WJ, Ahammad P (2020) Machine learning models identify multimodal measurements highly predictive of transdiagnostic symptom severity for mood, anhedonia, and anxiety. *Biol Psychiatry Cogn Neurosci Neuroimaging*, 5(1):56-67.
- Mohammadi M, Al-Azab F, Raahemi B, Richards G, Jaworska N, Smith D et al. (2015) Data mining EEG signals in depression for their diagnostic value. *BMC Med Inform Decis Mak*, 15:108.
- Mohri M, Rostamizadeh A, Talwalkar A (2012) *Foundations of Machine Learning*. Boston, MIT Press.
- Mosteller F, Tukey J (1968) *Data analysis, including statistics*. *Handbook of Social Psychology*, vol. 2 (Eds G Lindzey, E Aronson):80-203. Addison Wesley.
- Mueller A, Candrian G, Kropotov J D, Ponomarev V A, Baschera G-M (2010) Classification of ADHD patients on the basis of independent ERP components using a machine learning system. *Nonlinear Biomed Phys*, 4(Suppl 1): S1.

- Mumtaz W, Xia L, Ali SSA, Yasin MAM, Hussain M, Malik AS (2017a) Electroencephalogram (EEG)-based computer-aided technique to diagnose major depressive disorder (MDD). *Biomed Signal Process Control*, 31:108-115.
- Mumtaz W, Xia L, Yasin MAM, Ali SSA, Malik AS (2017b) A wavelet-based technique to predict treatment outcome for major depressive disorder. *PLoS One*, 12:e0171409.
- Mwangi B, Wu M-J, Cao B, Passos IC, Lavagnino L, Keser Z et al. (2016) Individualized prediction and clinical staging of bipolar disorders using neuroanatomical biomarkers. *Biol Psychiatry Cogn Neurosci Neuroimaging*, 1:186-194.
- Nouretdinov I, Costafreda SG, Gammerman A, Chervonenkis A, Vovk V, Vapnik V et al. (2011) Machine learning classification with confidence: Application of transductive conformal predictors to MRI-based diagnostic and prognostic markers in depression. *Neuroimage*, 56:809-813.
- Öztoprak H, Toyçan M, Alp YK, Arıkan O, Doğutepe E, Karakaş S (2017) Machine-based classification of ADHD and nonADHD participants using time/frequency features of event-related neuroelectric activity. *Clin Neurophysiol*, 128:2400-2410.
- Papini S, Pisner D, Shumake J, Powers MB, Beevers CG, Rainey EE et al. (2018) Ensemble machine learning prediction of posttraumatic stress disorder screening status after emergency room hospitalization. *J Anxiety Disord*, 60:35-42.
- Perez Arribas I, Goodwin G M, Geddes JR, Lyons T, Saunders KEA (2018) A signature-based machine learning model for distinguishing bipolar disorder and borderline personality disorder. *Transl Psychiatry*, 8:274.
- Perlis RH, Iosifescu DV, Castro VM, Murphy SN, Gainer VS, Minnier J et al. (2012) Using electronic medical records to enable large-scale studies in psychiatry: Treatment resistant depression as a model. *Psychol Med*, 42:41-50.
- Perlis R (2013) A clinical risk stratification tool for predicting treatment resistance in major depressive disorder. *Biol Psychiatry*, 74:7-14.
- Pinaya WHL, Mechelli A, Sato JR (2019) Using deep autoencoders to identify abnormal brain structural patterns in neuropsychiatric disorders: A large-scale multi-sample study. *Hum Brain Mapp*, 40:944-954.
- Qin S, Young C B, Duan X, Chen T, Supekar K, Menon V (2014) Amygdala subregional structure and intrinsic functional connectivity predicts individual differences in anxiety during early childhood. *Biol Psychiatry*, 75:892-900.
- Ramyead A, Studerus E, Kometer M, Uttinger M, Gschwandtner U, Fuhr P et al. (2016) Prediction of psychosis using neural oscillations and machine learning in neuroleptic-naïve at-risk patients. *World J Biol Psychiatry*, 17:285-295.
- Redlich R, Opel N, Grotegerd D, Dohm K, Zaremba D, Burger C et al. (2016) Prediction of individual response to electroconvulsive therapy via machine learning on structural magnetic resonance imaging data. *JAMA Psychiatry*, 73:557-564.
- Sato JR, Biazoli CE, Salum G A, Gadelha A, Crossley N, Vieira G et al. (2018) Association between abnormal brain functional connectivity in children and psychopathology: A study based on graph theory and machine learning. *World J Biol Psychiatry*, 19:119-129.
- Stamate D, Katrinecz A, Stahl D, Verhagen SJW, Delespaul PAEG, van Os J et al. (2019) Identifying psychosis spectrum disorder from experience sampling data using machine learning approaches. *Schizophr Res*, 209:156-163.
- Sohn S, Kocher J.-P A, Chute C G, Savova G K (2011) Drug side effect extraction from clinical narratives of psychiatry and psychology patients. *J Am Med Inform Assoc*, 18(Suppl 1):144-149.
- Stone M (1974) Cross-validatory choice and assessment of statistical predictions. *J R Stat Soc Series B Stat Methodol*, 36:111-147.
- Suhasini A, Palanivel S, Ramalingam V (2011) Multimodel decision support system for psychiatry problem. *Expert Syst Appl*, 38:4990-4997.
- Tenev A, Markovska-Simoska S, Kocarev L, Pop-Jordanov J, Müller A, Candrian G (2014) Machine learning approach for classification of ADHD adults. *Int J Psychophysiol*, 93:162-166.
- Viviano JD, Buchanan RW, Calarco N, Gold JM, Foussias G, Bhagwat N et al. (2018) Resting-state connectivity biomarkers of cognitive performance and social function in individuals with schizophrenia spectrum disorder and healthy control subjects. *Biol Psychiatry*, 84:665-674.
- Walsh CG, Ribeiro JD, Franklin JC (2018) Predicting suicide attempts in adolescents with longitudinal clinical data and machine learning. *J Child Psychol Psychiatry*, 59:1261-1270.
- Walss-Bass C, Suchting R, Olvera RL, Williamson DE (2018) Inflammatory markers as predictors of depression and anxiety in adolescents: statistical model building with component-wise gradient boosting. *J Affect Disord*, 234:276-281.
- Yoon JH, Nguyen DV, McVay LM, Deramo P, Minzenberg MJ, Ragland JD et al. (2012) Automated classification of fMRI during cognitive control identifies more severely disorganized subjects with schizophrenia. *Schizophr Res*, 135:28-33.
- Zhang X, Hu B, Zhou L, Moore P, Chen J. (2013) An EEG based pervasive depression detection for females. In *Pervasive Computing and the Networked World, Lecture Notes in Computer Science 7719* (Eds Q Zu, B Hu, A Elçi): 848-861. Berlin, Springer.
- Zhao K, So HC (2019) Drug repositioning for schizophrenia and depression/anxiety disorders: a machine learning approach leveraging

expression data. IEEE J Biomed Health Inform, 23:1304-1315.

Zhao S, Zhao Q, Zhang X, Peng H, Yao Z, Shen J et al. (2017) Wearable EEG-based real-time system for depression monitoring. In Brain Informatics. BI 2017. Lecture Notes in Computer Science, vol 10654 (Eds Y Zeng, Y He, JH Kotaleski, M Martone, B Xu, H Peng et al.):190-201. Cham: Springer.

Zilcha-Mano S, Roose SP, Brown PJ ve Rutherford BR (2018) A machine learning approach to identifying placebo responders in late-life depression trials. Am J Geriatr Psychiatry, 26:669-677.

Yazarların Katkıları: Yazarlar çalışmaya önemli bir bilimsel katkı sağladıklarını ve makalenin hazırlanmasında veya gözden geçirilmesinde yardımcı olduklarını kabul etmişlerdir.

Danışman Değerlendirmesi: Dış bağımsız.

Çıkar Çatışması: Yazarlar çıkar çatışması bildirmemiştir.

Finansal Destek: Yazarlar bu çalışma için finansal destek almadıklarını beyan etmişlerdir.

Teşekkür: Çalışmanın İngilizce çevirisinin yapılmasını sağlayan Işık KİRİBRAHİM'e teşekkür ederiz. Bu çalışma İstanbul Üniversitesi Fen Bilimleri Enstitüsü Enformatik Anabilim Dalı'nda yürütülmekte olan doktora tez çalışmasından üretilmiştir.

Authors Contributions: The authors attest that they made an important scientific contribution to the study and have assisted with the drafting or revising of the manuscript.

Peer-review: Externally peer-reviewed.

Conflict of Interest: No conflict of interest was declared by the authors.

Financial Disclosure: The authors declared that this study has received no financial support.

Acknowledgement: We would like to thank Işık KİRİBRAHİM for the English translation of the study. This study has been produced from the doctoral thesis study conducted in the Informatics Department of the Institute of Science of Istanbul University.