

**PSİKOLOJİK KAVRAMLAR**  
ve  
**PSİKOPATOLOJİ İNCELEMELERİ**

**Editör: Yusuf BİLGE**



# **BİDGE Yayınları**

Psikolojik Kavramlar ve Psikopatoloji İncelemeleri

**Editör:** Doç. Dr. Yusuf BİLGE

ISBN: 978-625-372-342-2

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Kapak Tasarımı: Gülbeyza ÇAKIR

Yayınlama Tarihi: 15.12.2024

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

[www.bidgeyayinlari.com.tr](http://www.bidgeyayinlari.com.tr) - [bidgeyayinlari@gmail.com](mailto:bidgeyayinlari@gmail.com)

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltpe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /  
Ankara



## İçindekiler

<b>ÖNSÖZ.....</b>	<b>3</b>
<b>1.Duygusal ve Sosyal Düzenleme Zorluklarının Bir Dışavurumu: İntihar Amacı Olmayan Kendine Zarar Verme Davranışı.....</b>	<b>8</b>
<b>Tuğba AKBALIK- Yusuf BİLGE</b>	
Giriş .....	8
Tanı Kriterleri.....	10
Epidemiyoloji .....	11
Etiyoloji ve İşlevler .....	12
Risk Faktörleri .....	17
Komorbidite.....	20
Değerlendirme ve Tedavi .....	27
Sonuç .....	29
Kaynakça .....	35
<b>2.Sosyal Kaygı ve Paranoya: “Endişeli” ve “Şüpheli” Düşünme .....</b>	<b>49</b>
<b>Büşra ŞAHİN- Yusuf BİLGE</b>	
Giriş .....	49
Paranoid Düşünce ve Paranoid Düşünceyi Açıklayan Modeller	52
Sosyal Kaygı ve Sosyal Kaygıyı Açıklayan Modeller .....	57
Sosyal Kaygı ve Paranoid Düşünceyi Birlikte İnceleyen Çalışmalar.....	58
Paranoid Düşünce ve Sosyal Kaygıda Ortak Görülen ve Farklılaşan Özelliklerin Değerlendirilmesi .....	62
Sonuç .....	67
Kaynakça .....	70

### **3.Yaşlılıkta Depresyonun Klinik Görünümü: Somatik Yakınmalar Üzerine Bir Derleme..... 76**

**Merve SEPETÇİ**

Yaşamın Yeniden Gözden Geçirilmesi ve Gelişimsel Bir Dönem Olarak Yaşlılık .....	76
Yaşlılıkta Depresyon .....	80
Yaşlılıkta Somatik Yakınmalar .....	82
Yaşlılıkta Depresyonun Klinik Bir Görünümü Olarak Somatik Yakınmalar .....	85
Sonuç .....	86
Kaynakça .....	90

### **4.Değer Kavramı ve Psikoterapi: Kabul ve Kararlılık Terapisi Çerçevesinde Bir İnceleme ..... 95**

**Hatice Rumeysa IŞIK**

Giriş .....	95
Felsefe ve Değer Kavramı .....	96
Ana Akım Psikoloji Yaklaşımlarında Değer Kavramı .....	97
Bilişsel Davranışçı Terapiler ve Değerler .....	100
Davranış Analizi ve Değerler .....	102
İlişkisel Çerçeve Kuramı, Kabul ve Kararlılık Terapisi ve Değerler .....	103
Klinik Uygulamada Kabul ve Kararlılık Terapisi ve Değerler .....	106
Kabul ve Kararlılık Terapisi Bağlamında Değerler ile İlgili Araştırma Sonuçları .....	109
Kabul ve Kararlılık Terapisi Bağlamında Değerler için Kullanılan Ölçekler .....	111
Kaynakça .....	115

**5.Zihinselleştirme: Kavramsal Çerçeve ve Ölçüm Yöntemleri**  
..... 126

**Zümrüt GENÇ- Gülşah BALABAN**

Zihinselleştirme: Kavramsal Çerçeve ve Psikopatoloji.....	126
Zihinselleştirmenin Ölçümü ve Değerlendirilmesi .....	132
İşlem .....	134
Bulgular .....	135
Tartışma.....	147
Sonuç .....	151
Kaynakça .....	153

**6.Psikopatoloji Araştırmalarında Makine Öğrenmesi Yaklaşımları** ..... 169

**Hafize İHTİYAR KARAKUŞ-Gülşah BALABAN**

Giriş .....	169
Makine Öğrenmesine Genel Bir Bakış.....	170
Psikolojide Makine Öğrenmesinin Kullanılması .....	173
Bir Yöntem Örneği: Karar Ağaçları .....	176
Türkiye’de Makine Öğrenmesi Kullanılan Psikopatoloji Araştırmaları.....	178
Sonuç ve Öneriler .....	183
Kaynakça .....	185

## BÖLÜM VI

### Psikopatoloji Araştırmalarında Makine Öğrenmesi Yaklaşımları

Hafize İHTİYAR KARAKUŞ<sup>1</sup>  
Gülşah BALABAN<sup>2</sup>

#### Giriş

Psikoloji, tarihsel olarak insan davranışlarını tanımlamak, açıklamak ve tahmin etmekle ilgilenmiştir. Birçok araştırma, çeşitli eylemlere yol açan nedensel mekanizmaları anlamayı amaçlamıştır (Gerrig & Zimbardo, 2012). Psikolojinin daha çok, davranışın nedenlerine dair karmaşık teoriler geliştirmeye odaklanması, geleceğe yönelik davranışların tahmin edilmesinde

---

<sup>1</sup> Uzm. Kinik Psikolog, Doktora Öğrencisi, İstanbul Sabahattin Zaim Üniversitesi, Lisansüstü Eğitim Enstitüsü, Klinik Psikoloji Doktora Programı, İstanbul/Türkiye, Orcid: 0000-0003-1260-9094, hafize.ihdiy@std.izu.edu.tr

<sup>2</sup> Dr. Öğr. Üyesi, İstanbul Sabahattin Zaim Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Psikoloji Bölümü, İstanbul / Türkiye, Orcid: 0000-0002-2412-4249, gulsah.balaban@izu.edu.tr

yetersiz kalmasına sebep olmuştur (Yarkoni & Westfall, 2017). Bu nedenle makine öğrenmesi yöntemlerinin alana kazandırılmasıyla psikolojinin daha öngörülebilir bir bilim olacağına inanılmaktadır (Jacobucci & ark., 2020).

Dijital çağda ortaya çıkan modern yaklaşımlardan biri olan makine öğrenmesi, geniş bir kullanım alanına sahiptir ve ruh sağlığı alanını da oldukça etkilemeye başlamıştır. Birçok problemde klasik yöntemlerden daha iyi performans gösterdiği için bu tekniklerin yaygın olarak kullanılacağı ve özellikle klinik psikoloji ile psikiyatriye önemli katkılar sunacağı düşünülmektedir (Dwyer, Falkai & Koutsouleris, 2018). Güncel çalışmalara bakıldığında psikolojik rahatsızlıkların teşhis, tahmin ve tedavi süreçlerinde makine öğrenmesi yöntemlerinin gittikçe artan bir öneme sahip olduğu görülmektedir (D'Alfonso, 2020; Jiang, Gradus & Rosellini, 2020). Örneğin, bu yöntemler bir danışana ait bilgileri kullanarak kişiye özgü tedavi planı oluşturabilir ve daha isabetli klinik kararların verilmesine katkı sağlayabilir (Dwyer, Falkai & Koutsouleris, 2018). Ayrıca bir psikopatolojinin prognozu, tedavi uyumu ve tanı sürecinde uzmanlara destek sunarak doğru kararların alınmasına yardımcı olabilir ancak henüz klinik uygulamalardaki kullanımı oldukça yenidir ve bu alanda yapılacak çalışmalara ihtiyaç duyulmaktadır (Doom vd., 2020).

### **Makine Öğrenmesine Genel Bir Bakış**

Makine öğrenmesi terimi, karmaşık ve büyük veri yığınları içinden anlamlı ilişkilerin belirlenmesi için modern bilgisayarların hesaplama becerisinin kullanıldığı matematiksel

teknikleri ifade etmektedir (Yarkoni & Westfall, 2017). Genel mantığı, insan öğrenmesini taklit ederek çeşitli istatistik temelli algoritmaların kullanımıyla ileriye yönelik tahmin modelleri üretmektir. Başka bir ifadeyle, makine öğrenmesi yöntemleri, veri madenciliği sürecinde kullanılan teknikler bütününe karşılık gelmektedir. Veri madenciliğinden kastedilen, karmaşık ve büyük verilerin çeşitli istatistiksel analiz yöntemleriyle işlenerek yararlı bilgilerin elde edilmesidir (Alp & Öz, 2019). Bu tekniklerin ortak özelliği, veri setinde yer alan anlamlı ilişki modellerini tanımlamaları, ardından bu modelleri bağımsız veri kümeleri aracılığıyla test ederek genelledebilmeleridir (Yarkoni & Westfall, 2017). Bir veri setindeki anlamlı ilişki örüntülerinin keşfedilmesi ve tanımlanması sürecinde algoritma iki aşama kullanmaktadır: eğitim ve test aşaması (Coutanche & Hallion, 2020; Jiang, Gradus & Rosellini, 2020).

İlk olarak eğitim aşaması için çalışmanın veri seti hazırlanır, uç değerler ve normallik derecesi kontrol edilerek gerekli düzenlemeler yapılır. Model hangi algoritma seçildiyse ona göre eğitilir, örneğin kümeleme için belirli kriterler ayarlanır. Ardından eğitilen modelin, öğrendiği kuralı ne kadar genelleyebileceği, test veri seti üzerinde uygulama yapılarak değerlendirilir. Örneğin doğruluk,  $R^2$ , F1 skorlarına bakılır (Han & ark., 2011). Burada amaç, modelin var olan veri setindeki ilişkileri anlaması ve sonrasında yeni veriler üzerinde benzer ilişki kalıplarını kurabilmesi için eğitilmesidir. Son olarak eğitilen model, yeni veriler üzerinden kararlar alır ve ileriye yönelik tahminleme yapar. Örneğin yeni bir vakanın verileri girildiğinde depresyon teşhisi koyup koymaması gerektiğini

eđitim ařamasındaki verilere dayanarak belirlemeye alıřır (Sivakumar, Parthasarathy & Padmapriya, 2024).

Bu yntemlerdeki ortak nokta, eđitilmiř bir modelin bařka veri setinde (yani eđitilmemiř) bulunan anlamlı iliřki kalıplarını tahmin edebilme bařarisına yapılan vurgudur. Geleneksel istatistiksel yaklařımlarla benzer řekilde makine đrenmesi modelleri de verilerdeki anlamlı iliřkilere odaklanır. Ancak geleneksel yaklařımda, rneđin dođrusal regresyonun veri setindeki iliřkiyi ne derece iyi aıkladıđına bakılırken; eđitilmiř bir makine đrenmesi modelinde yeni veri setindeki iliřkilerin ne derece dođru tahmin edildiđine bakılır. Deđiřkenler arasındaki iliřkilerin yn kolayca grlebilir (Albayrak & Yılmaz, 2009) ve geleneksel yntemlerle fark edemeyeceđimiz alt grupların keřfedilmesi sađlanır. Makine đrenmesinde daha dinamik ve esnek modeller oluřturulabilir ve verinin yapısına gre adapte edilebilir. Nedensellikten ok tahmin etme performansına odaklanılır (Baizyldayeva, Uskenbayeva & Amanzholova, 2013).

Bir veri setinde eđitilmiř bir modelin, yeni veriler zerindeki iliřki kalıplarını tahmin etme becerisine modelin genelleme yeteneđi denir (Coutanche & Hallion, 2020). Genelleme yeteneđini artırmak iin modele geniř varyanslı rneklemden alınan veriler dahil edilebilir. Yani eřitlilik gsteren bir rnekleme sahip veri setiyle eđitilmiř bir model, yeni datalar zerinde daha gl tahminler sunabilecektir. nk veri setinde yer alan rnekleme bilgisinin detaylı ve ok ynl olması, modele daha fazla bilgi kaynađı sađlayacaktır. Bylece farklı bir datanın daha kolay anlařılması ve sistemin daha dođru karar vererek tahminleme yapabilmesi sađlanır (Coutanche &

Thompson-Schill, 2012). Geliştirilecek modelin en iyi performansı göstermesi için çeşitli sorular sorularak düzenleme yapılabilir. Örneğin, belirlenen semptomun ya da patolojinin tahmin edilmesinde teorik olarak anlamlı görünen ilişkili risk faktörlerinin veya öncüllerin modele dahil edilip edilmemesi ne kadar önemlidir? Modelin tahmin yeteneğini değiştiren faktörler nelerdir? Hangi klinik özellikler, tedaviden alınan yanıtı veya prognoz sürecini tahmin etmede büyük etkiye sahiptir? Bazı klinik özelliklerin eklenmesi veya çıkarılması, modelin birbiriyle ilişkili iki faktörü ayırt etme becerisini etkiler mi? (Chekroud & ark., 2016). Kurulan modelde yer alan değişkenlere dair edinilen teorik bilgiler çerçevesinde bu gibi sorulara cevap aranarak modelin tahmin gücü iyileştirilebilir ve çalışmanın işlevselliğine katkı sağlanabilir. Özellikle psikoloji verilerinin analizinde makine öğrenmesi tekniklerinin kullanılmasıyla geleneksel istatistiğin ötesinde yeni imkanlar oluşacağına inanılmaktadır (Cuartas Arias, 2017).

### **Psikolojide Makine Öğrenmesinin Kullanılması**

Psikolojinin teorik birikimi, makine öğrenmesi yöntemlerine entegre edilerek çeşitli avantajlar sağlanabilir. Araştırmacı, yürüteceği çalışmanın teorik çerçevesine göre veri setindeki onlarca özellik yerine yalnızca işine yarayan sınırlı sayıda özelliğe odaklanabilir. Ölçmek istediği bağımlı değişken ile en çok ilişkili olan bağımsız değişkenleri önem sırasına göre belirleyebilir. Ayrıca teoriye dayalı bir istatistiksel model oluşturma fırsatı elde eder (Elhai & Montag, 2020). Çeşitli tekniklerle veri yığınlarından ruh sağlığı modelleri çıkarılarak problemin tespiti, tahmini ve çözümü açısından birçok kolaylık

sağlanabilir (D'Alfonso, 2020). Örneğin, denetimli öğrenme teknikleriyle etiketli hasta verileri üzerinden sınıflandırma ve tahminlemeler yapılabilirken; denetimsiz öğrenme ile etiketsiz veriler birbirleriyle olan ilişki düzeylerine göre gruplandırılarak alt kümeler oluşturulabilir (Dorn & ark., 2020). Bu yöntemler, tedavi planlamaları için de oldukça umut vadetmektedir. Herkese uyacak türden bir yaklaşım yerine hastalardan alınan verilere dayanarak kişiye özgü tedavi seçenekleri belirlenebilir (Joyner & Paneth, 2019). Ayrıca bu yöntemler, müdahale öncesinde klinisyenin alacağı karara destek olarak tedavi sürecini iyileştirebilmektedir. Örneğin, Koutsouleris ve arkadaşları (2016), makine öğrenmesini kullanarak yaptıkları çalışmada ilk atak psikoz hastalarının tedavi sonuçlarını yaklaşık %70 doğrulukla öngörmeyi başarmıştır. Bu sayede, elde edilen veriler üzerinden tedavi yönteminin seçilmesi, kişiselleştirilmiş tedavi modeli oluşturulması ve prognoz takibinin yapılması mümkün olabilir.

Literatüre bakıldığında psikolojik bozuklukların değerlendirilmesine yönelik yürütülen birçok araştırma görülmektedir. Makine öğrenmesi yöntemleri kullanılarak ele alınan bazı hastalıklar arasında depresyon (Hatton & ark., 2019; Perlis & ark., 2012), bipolar bozukluk (Eugene, Mesiak & Eugene, 2018; Edgcomb & ark., 2019), şizofreni (Birnbaum & ark., 2017; Cao & ark., 2018; Fond & ark., 2019), DEHB (Altun, Alkan & Altun, 2022; Öztoprak & ark., 2017), PTSD (Karstoft & ark., 2015) ve anksiyete bozukluğu (Arif & ark., 2020; Na, Cho & Cho, 2021) yer almaktadır. Shatte ve arkadaşları (2019), makine öğrenmesi yöntemleriyle çalışılan en yaygın

rahatsızlıkların depresyon, Alzheimer ve şizofreni olduğunu belirlemiştir. Bu çalışmalar tanı, tedavi, toplum sağlığı ve klinik uygulama olmak üzere dört ana başlık altında yoğunlaşmaktadır.

Örneğin yapılan bir çalışma, sosyal medya platformu Twitter'ın verileri makine öğrenmesi teknikleriyle dil içeriği bakımından inceleyerek şizofreni hastalarını sağlıklı kullanıcılardan %88 oranında doğrulukla ayırt etmeyi başarmıştır (Birnbaum & ark., 2017). Benzer şekilde bir başka araştırma da Twitter verileri üzerinde makine öğrenmesi algoritmalarını kullanarak intihar riski yüksek olan kişileri %92 oranında doğrulukla tespit etmiştir. Bu sayede, sosyal medya verileri aracılığıyla toplum popülasyonundan intihar riski taşıdığı belirlenen insanlara yönelik önleme müdahaleleri yapılabileceği düşünülmektedir (Braithwaite & ark., 2016).


Bir diğer kullanım alanı farmakolojidir (Vidyasagar, 2015). Kullanılan ilaçların farklı semptomlarda farklı sonuçlar vermesi tedavinin etkinliğini azaltabilmektedir (Stroup & ark., 2019). Bu nedenle mevcut bilgilerden yararlanılarak semptoma özgü ilaç tedavileri modellenebilmektedir. Örneğin, depresyon hastalarıyla yapılan bir çalışmada kümeleme yöntemi kullanılarak temel semptomlar gruplandırılmıştır ve antidepresan tedavisinden alınan sonucun semptom kümelerine göre farklılaştığı belirlenmiştir (Chekroud & ark., 2017). Depresyon vakaları üzerinde yapılan bir diğer çalışmada ise semptom türüne göre farmakolojik tedavilerin belirlendiği ve ileriye yönelik tahminlerin modellendiği bir program geliştirilerek patentlenmiştir (Chekroud & ark., 2017).

Makine öğrenmesi tekniklerinden, bilişsel davranışçı terapi müdahaleleri gibi psikoterapi uygulamalarında da yararlanılmaktadır (Kelly & ark., 2012). Örneğin, klinik tedaviye verilen yanıtın değerlendirilmesi ya da prognozun takip edilmesi sürecinde kullanılmasıyla klinisyenin bir öngörü geliştirmesine yardımcı olmaktadır (Hasanpour & ark., 2018; Webb & ark., 2020). Ayrıca çevrimiçi (online) psikoterapi uygulamalarındaki kullanımı da gittikçe yaygınlaşmaktadır (Békés & ark., 2021).

### **Bir Yöntem Örneği: Karar Ağaçları**

Karar ağaçları, sınıflandırmalar için yaygın olarak kullanılan makine öğrenmesi yöntemlerinden biridir (Emel & Taşkın, 2005). Bu yöntem, verileri sınıflandırarak birbiriyle ilişkili anlamlı örüntülerin keşfedilmesini ve öngörülmesini sağlar (Beck, 2005). Tümevarımsal bir yaklaşımla, sisteme girilen eğitim verileri üzerinden bağımlı ve bağımsız değişkenler arasındaki kurallar öğrenilir ve hedefteki karar tahmin edilir. Şekil 1’de gösterilen örnekte olduğu gibi kök, dal ve yapraklara doğru uzanan bir ağaç şeklinde karar şeması çıkarılır (Hu & ark., 2012). Bu şemaların sınıflandırma kuralları, bir seçeneğin tercih edilip edilmemesine bağlı olarak değişebilen varsayımlardır. Her karar kriteri, bir seçeneğin tercih edilmesiyle ortaya çıkan koşullara (if-then) bağlı bir hipotez olarak görülebilir (eğer hava yağmurluysa şemsiye alacağım gibi). Sistemin eğitilmesiyle elde edilen şemaların tahmin başarıları ve genellenebilirliği farklı veriler aracılığıyla test edilir (Beck, 2005). Görsel olarak anlaşılması kolay bir akış şeklinde sunulan şemalar üzerinden, bağımlı ve bağımsız değişkenler arasındaki anlamlı ilişkilerin

önem sırası ve yönü gösterilir (Şekil 1) (Albayrak & Yılmaz, 2009).



Şekil 1. Karar ağacı örneği

Karar ağacı yöntemi, tanı koyma (Topaloğlu & Sur, 2015) ve tedaviyi belirleme (Breslin & ark., 2000; Montbriand, 1995) gibi amaçlarla birçok araştırmada kullanılmaktadır. Psikoloji ve psikiyatri alanlarındaki kullanımı oldukça yeni olsa da (Valero & ark., 2014), bu sistemler klinik verilerle birlikte kullanıldığında, hastalık, semptom ve müdahale yöntemlerini işlevsel şekilde sınıflandırarak sağlık çalışanlarının işlerini kolaylaştırabilir (Mendonça, 2004). Çeşitli çalışmalarda tahmine dayalı modeller oluşturmak için karar ağacı yönteminden yararlanılması (Békés & ark., 2021), farmakolojik tedavilerde semptom, tedavi yöntemi ve tedaviye verilen yanıtın en iyi şekilde modellenmesine, tedavi metodunun iyileştirilmesine, remisyon süresinin kısalmasına ve maliyetin düşürülmesine yardımcı olmaktadır (Beck, 2005; Hasanpour & ark., 2018).

Karar ağacı ile çoklu modeller üreterek rastgele bir orman oluşturmak, tahmine dayalı yöntemin iki avantajını da kullanır: İlk olarak çok sayıda birbiriyle ilişkili faktörlerle bir sonucu tahmin eder (örneğin, tedaviye erişim), ikinci olarak da kullanılan verilerden bilerek çıkarılan ya da modele dahil edilen vakalar/gözlemler için modelin ne derece iyi performans sergilediğini test eder (Grömping, 2009; James & ark., 2013). Rastgele orman algoritması ile birden çok karar ağacı modeli içerisinde tahmin gücü en iyi olan seçilerek daha isabetli bir sınıflandırma yapılabilir (Biau & Scornet, 2016).

### **Türkiye’de Makine Öğrenmesi Kullanılan Psikopatoloji Araştırmaları**

Google akademik üzerinden “Makine öğrenmesi ve psikopatoloji” başlığıyla yapılan literatür taraması sonucunda tespit edilen Türkçe çalışmalar Tablo 2’de yer almaktadır. Son yıllarda oldukça popülerleşen bir yaklaşım olan makine öğrenmesi, disiplinler arası çalışmalarda ve özellikle psikoloji araştırmalarında yaygın olarak kullanılmasına rağmen (Mabry, 2011) ülkemizdeki literatürün bu alanda yetersiz kaldığı görülmektedir. Ancak derlenen çalışmalara bakıldığında, bu alana ilginin gittikçe arttığı ve ilerleyen yıllarda daha fazla çalışma yapılabileceği düşünülmektedir.

Tablo 1. Türkiye’de makine öğrenmesi ve psikopatoji alanında yapılmış çalışmalar

YIL	YAZAR- MAKALE ADI	AMAÇ
2013	Aksehirli, Ö. Y., Ankaralı, H., Aydın, D. & Saraçlı, Ö. (2013). Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. <i>Türkiye Klinikleri Biyoistatistik</i> , 5(1), 19-28.	Çalışmada, makine öğrenmesi yöntemlerinden destek vektör makinaları kullanılarak gece-yeme sendromu tanısı alan hastaların sınıflandırılması amaçlanmıştır.
2018	Karaöz, B. & Gürsoy, U. T. (2018). Adaptif Öğrenme Sözlüğü Temelli Duygu Analiz Algoritması Önerisi. <i>Bilişim Teknolojileri Dergisi</i> , 11(3), 245-253.	Bu çalışmada, yarı denetimli öğrenme yöntemi ile belirli düzeyde yazılım bilgisine sahip kişilere hitap eden bir duygu analizi modeli sunulmuştur.
2019	Taş, E., & Kamaşak, M. E. (2019, September). Prediction of personality traits from videos by using machine learning algorithms. In <i>2019 4th International Conference on Computer Science and Engineering (UBMK)</i> , (pp. 778-782).	Bu makale, makine öğrenmesi ve görüntü işleme tekniklerini kullanarak videodan kişilik özelliklerinin otomatik olarak tespit edilmesini amaçlayan yapay zeka temelli bir çalışmadır.
2019	Yöntem, M. K. & Kemal, A. D. E. M. (2019). Otomatik Düşüncelere Makine Öğrenme Yöntemlerinin Uygulanması ile Aleksitimi Düzeyinin Tahmini. <i>Psikiyatride Güncel Yaklaşımlar</i> , 11, 64-78.	Çalışmada, veri kümesi ile Yapay Sinir Ağı ve Destek Vektör Makinesi makine öğrenmesi yöntemleriyle aleksitimi düzeyi tahmin edilmiş ve bu sayede önceliğin hangi otomatik düşüncelere verilmesi gerektiği konusunda bir yol haritası sunulması amaçlanmıştır.

Tablo 1'in devamı: Türkiye'de makine öğrenmesi ve psikopatoloji alanında yapılmış çalışmalar

YIL	YAZAR- MAKALE ADI	AMAÇ
2019	Altınbaşak, G. (2019). <i>Bipolar ve unipolar bozuklukların uygun biyobelirteç kullanarak makine öğrenme yöntemleri ile sınıflandırılması</i> (Yüksek Lisans Tezi, Sağlık Bilimleri Enstitüsü).	Bu çalışma, iki aşamalı hibrit bir metodolojinin bipolar bozukluğun tanı sürecinde kullanılmasına ilişkin potansiyel bir model sunmaktadır.
2019	Karakuş, A. (2019). <i>Obsesif kompulsif bozukluk ve trikotilomani bozukluklarının uygun biyobelirteç kullanılarak makine öğrenme yöntemleri ile sınıflandırılması</i> (Yüksek Lisans Tezi, Sağlık Bilimleri Enstitüsü).	Bu çalışma, Obsesif Kompulsif Bozukluk (OKB) ve Trikotilomani (TTM) bozukluklarının tanı koyma sürecinde makine öğrenmesi yöntemlerinden yararlanılarak sınıflandırma yapılmasını amaçlamıştır.
2020	Türk, B. & Tali H.H. (2020). <i>Makine Öğrenmesi Yöntemleri ile Somatizasyon ve Duygusal Öz Farkındalık Üzerinden Şiddetin Tahmini. Adli Tıp Bülteni, 25(2): 99-105.</i>	Bu çalışma, somatizasyon ve duygusal öz farkındalık aracılığıyla, gözetimli öğrenmenin sınıflandırma algoritmaları ile bireylerin şiddet mağduriyetlerini tahmin etmeyi amaçlamaktadır.
2021	Emre, İ. E., Cumhuri, T. A. Ş. & Çiğdem, E. R. O. L. (2021). <i>Psikiyatride Makine Öğrenmesi Yöntemlerinin Kullanımı. Psikiyatride Güncel Yaklaşımlar, 13(2), 332-353.</i>	Bu çalışma, psikiyatri ve makine öğrenmesi hakkında derleme çalışmasıdır.

Tablo 1'in devamı: Türkiye'de makine öğrenmesi ve psikopatoloji alanında yapılmış çalışmalar

YIL	YAZAR- MAKALE ADI	AMAÇ
2021	Halisdemir, N., Filiz, E., Güral, Y. & Gürcan, M. Doğanın İnsan Yaşamı Üzerine Etkilerinin Karar Ağacı Algoritmaları ile İncelenmesi. <i>Batı Karadeniz Tıp Dergisi</i> , 5(3), 444-451.	Çalışmada, psikiyatri polikliniğine gelen 195 hastaya çeşitli anketler uygulanmıştır. Bağımlı değişken olarak mutluluk seçilmiş ve bu değişkeni etkileyen faktörler, karar ağacı kullanılarak incelenmiştir.
2021	Sağbaş, E. A., Korukoğlu, S., & Ballı, S. (2021). Akıllı Telefon Verileri ve Makine Öğrenmesi Yöntemleri Kullanılarak Stres Tespiti Çalışmaları Üzerine Bir Literatür Araştırması. <i>Mühendislik Bilimleri ve Tasarım Dergisi</i> , 9(3), 1030-1038.	Bu çalışmada, sadece akıllı telefon verileri kullanılarak gerçekleştirilen stres tespiti çalışmaları ele alınmış ve stres tespitinde kullanılan veri kaynakları, türleri ve sınıflandırmada kullanılan makine öğrenmesi yöntemleri incelenmiştir.
2021	Yarğ, V., & Postalcıoğlu, S. (2021). EEG işareti kullanılarak bağımlılığa yatkınlığın makine öğrenmesi teknikleri ile analizi. <i>El-Cezeri</i> , 8(1), 142-154.	Bu çalışmada, alkolizme yatkınlığın EEG sinyalleri kullanılarak teşhisi amaçlanmıştır.
2022	Usta, M. B., & Karabekiroğlu, K. (2022). Nörogelişimsel Bozukluklarda Yapay Zekâ ve Makine Öğrenmesi. <i>Türkiye Klinikleri Child Psychiatry-Special Topics</i> , 8(1), 122-126.	Çalışmada nörogelişimsel bozukluklar için yapay zeka ve makine öğrenmesi yöntemlerinin kullanımı tartışılmaktadır.

Tablo 1'in devamı: Türkiye'de makine öğrenmesi ve psikopatoji alanında yapılmış çalışmalar

YIL	YAZAR- MAKALE ADI	AMAÇ
2023	Altun, S. (2023). Derin Öğrenme & Makine Öğrenmesi Yöntemleriyle Polisomnografi Sinyallerinden Uyku Evrelerinin Sınıflandırılması. <i>Karadeniz Fen Bilimleri Dergisi</i> , 13(2), 583-600.	Bu çalışma, uyku bozukluklarının teşhisinde önemli parametreler olan uyku evrelerini otomatik olarak oluşturmak için derin öğrenme ve makine öğrenmesi tekniklerini kullanmayı amaçlamaktadır.
2023	Naghiyev, M., Taş, İ. Ç., & Tekin, Y. (2023). Bağımlılık Yapıcı Madde Kullanımı Riskinin Makine Öğrenmesi Yöntemleriyle Tahmini. <i>Abant Sağlık Bilimleri ve Teknolojileri Dergisi</i> , 3(2), 1-13.	Çalışmanın amacı, bağımlılık yapıcı madde kullanan kişilerin ileride başka hangi bağımlılık yapan maddeleri kullanma risklerinin olabileceğini makine öğrenmesi yöntemleri ile tahminlemektir.
2023	Özer, E., & Temeltürk, R. D. (2023). Okuma bozukluğunun göz izleme ve makine öğrenmesiyle belirlenmesi: Alanyazının gözden geçirilmesi. <i>Klinik Psikoloji Dergisi</i> , 7(2), 258-270.	Çalışmanın amacı, göz takibi ve makine öğrenmesi kullanılarak disleksili bireylerin belirlenmesi için yapılan araştırmaların analizi ve özetlenmesidir.
2024	Aras, S., Aras, N., & Engin, M. A. (2024). Depresyonda motor aktivitenin makine öğrenmesi ile değerlendirilmesi. <i>Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi</i> , 13(1), 1-1.	Çalışmada, depresyonlu bireylerin günlük fiziksel aktivitelerine ait veri seti kullanılarak, depresyon tanısı için makine öğrenimi temelli objektif bir tanı destekleyici yöntem geliştirmek amaçlanmıştır.

## **Sonuç ve Öneriler**

Ruh sađlıđı alanında yapay zeka ve makine öğrenmesi tekniklerinin, psikoterapi uygulamaları gibi çeşitli amaçlarla kullanımı giderek yaygınlaşmaktadır. Geleceđe yönelik gelişmelerin takip edilebilmesi ve deđişime uyum sađlanması için özellikle klinik psikoloji ve psikoterapi eğitim programlarında makine öğrenmesi yöntemlerinin yer alması gerektiđine inanılmaktadır. Bu nedenle mevcut müfredatın gözden geçirilmesinin önemli bir adım olacađına inanılmaktadır (Blease ve ark., 2020.) Lisans eğitiminden itibaren veri bilimiyle ilişkili tekniklerin ve araçların psikoloji öğrencilerine kazandırılması, yakın gelecekteki gelişmeleri yakalayabilmek açısından kritik öneme sahiptir (Jack, Crivelli & Wheatley, 2018; Mandinach, 2012). Böylece teoride tespit edilen ilişkilerin mekanik olarak modellenmesi kolaylaşabilir ve iki yaklaşım arasındaki ilişkinin daha iyi anlaşılmasıyla klinik çalışmaların önü açılabilir (Dwyer, Falkai & Koutsouleris, 2018). Planlanan bir araştırmada hangi algoritma tekniđinin seçileceđi ve nasıl kullanılacağı konusunda hata payını azaltmak için psikologlarla makine öğrenmesi araştırmacıları arasında disiplinler arası iş birliđinin sađlanması çok önemlidir (Shatte, Hutchinson & Teague, 2019).

Patolojilerin teşhis ve tedavisinde makine öğrenmesinin rolü henüz kesinleşmiş deđildir. Ancak klinisyenlerin kararını tamamen deđiştirmek yerine, klinik sezgi ve deneyimin yanında genellenebilirliđi yüksek ve başarılı bir modelden faydalanılabilir (Linden, 2012). Daha birçok açıdan tahmine dayalı yöntemlerin öncelenmesi ve psikolojideki açıklama odaklı bakışın ikinci planda ele alınmasının kısa ve uzun vadede daha verimli sonuçlar

doğuracağına inanılmaktadır (Yarkoni & Westfall, 2017). Özellikle günümüzde teşhis ve ayırt edilmesinde zorlanılan belirli patoloji tiplerinde alınacak kararlar için makine öğrenmesinin kullanımı oldukça yararlı olacaktır (örneğin, unipolar ve bipolar depresyon) (Perlis & ark., 2006). Binlerce açık data erişimleri kullanılarak oluşturulan modeller üzerinden hastalıkların tetikleyicileri, ortak özellikleri ve semptomları kolaylıkla ayırt edilebilir. Nadir görülen patolojiler ise, elde edilmiş verilerin sentetik data üretme gibi yöntemlerle çoğaltılması sayesinde daha iyi anlaşılabilir.

Çeşitli araştırmalardaki kullanım amaçları incelendiğinde, makine öğrenmesi yöntemlerinden psikoloji alanındaki araştırmacıların yararlanmasının oldukça kritik bir öneme sahip olduğu görülmektedir. Son yıllarda tüm dünyada artan bir trende sahip olduğu bilinen bu yöntemlerin (Liem & ark., 2018) ülkemizdeki çalışmalarda da yaygın olarak kullanılabilmesi ve avantajlarından yararlanılabilmesi için disiplinler arası iş birliğinin desteklenmesi gerektiği düşünülmektedir. Böylece araştırma öznesi ve veri kaynağı insan olan psikoloji biliminin, nesnel yöntemleri kullanarak kişilerin yanılgularından ve zanlarından uzak bir şekilde insana daha objektif bakabilmesinin de önü açılacaktır.

## Kaynakça

Aksehirli, Ö. Y., Ankaralı, H., Aydın, D., & Saraçlı, Ö. (2013). Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. *Türkiye Klinikleri Biyoistatistik*, 5(1), 19-28.

Albayrak, A. S., & Yılmaz, S. K. (2009). Veri madenciliği: Karar ağacı algoritmaları ve İMKB verileri üzerine bir uygulama. *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences*, 14(1), 31-52.

Altınbaşak, G. (2019). *Bipolar ve unipolar bozuklukların uygun biyobelirteç kullanarak makine öğrenme yöntemleri ile sınıflandırılması* (Yüksek Lisans Tezi, Sağlık Bilimleri Enstitüsü).

Altun, S. (2023). Derin Öğrenme ve Makine Öğrenmesi Yöntemleriyle Polisomnografi Sinyallerinden Uyku Evrelerinin Sınıflandırılması. *Karadeniz Fen Bilimleri Dergisi*, 13(2), 583-600. <https://doi.org/10.31466/kfbd.1246482>

Altun, S., Alkan, A., & Altun, H. (2022). Application of deep learning and classical machine learning methods in the diagnosis of attention deficit hyperactivity disorder according to temperament features. *Concurrency and Computation: Practice and Experience*, 34(13), 1-10. DOI: 10.1002/cpe.6908

Alp, S. & Öz, E. (2019). *Makine Öğrenmesinde Sınıflandırma Yöntemleri ve Veri Uygulamaları*. Ankara: Nobel Akademik Yayıncılık.

Aras, S., Aras, N., & Engin, M. A. (2024). Depresyonda motor aktivitenin makine öğrenmesi ile değerlendirilmesi. *Niğde*

Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 13(1), 49-59. doi: 10.28948/ngumuh.1351103

Arif, M., Basri, A., Melibari, G., Sindi, T., Alghamdi, N., Altalhi, N., & Arif, M. (2020). Classification of anxiety disorders using machine learning methods: a literature review. *Insights Biomed Res*, 4(1), 95-110. DOI: 10.36959/584/455

Beck, K. A. (2005). Ethnographic decision tree modeling: A research method for counseling psychology. *Journal of Counseling Psychology*, 52(2), 243. <https://doi.org/10.1037/0022-0167.52.2.243>

Békés, V., Aafjes-van Doorn, K., Zilcha-Mano, S., Prout, T., & Hoffman, L. (2021). Psychotherapists' acceptance of telepsychotherapy during the COVID-19 pandemic: A machine learning approach. *Clinical Psychology & Psychotherapy*, 28(6), 1403-1415. <https://doi.org/10.1002/cpp.2682>

Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.

Birnbaum, M. L., Ernala, S. K., Rizvi, A. F., De Choudhury, M., & Kane, J. M. (2017). A collaborative approach to identifying social media markers of schizophrenia by employing machine learning and clinical appraisals. *Journal of medical Internet research*, 19(8), e7956. [doi:10.2196/jmir.7956](https://doi.org/10.2196/jmir.7956)

Blease, C., Kharko, A., Annoni, M., Gaab, J., & Locher, C. (2020). Machine Learning in Clinical Psychology and Psychotherapy Education: A Survey of Postgraduate Students at

a SwissUniversity. *medRxiv*, 2020-11.  
doi:[10.3389/fpubh.2021.623088](https://doi.org/10.3389/fpubh.2021.623088)

Braithwaite, S. R., Giraud-Carrier, C., West, J., Barnes, M. D., & Hanson, C. L. (2016). Validating machine learning algorithms for Twitter data against established measures of suicidality. *JMIR mental health*, 3(2), e4822. doi:[10.2196/mental.4822](https://doi.org/10.2196/mental.4822)

Breslin, F. C., Gladwin, C. H., Borsoi, D. & Cunningham, J. A. (2000). Defacto client treatment matching: How clinicians make referrals to outpatient treatment for substance abuse. *Evaluation and Program Planning*, 23, 281–291. [https://doi.org/10.1016/S0149-7189\(00\)00014-8](https://doi.org/10.1016/S0149-7189(00)00014-8)

Chekroud, A. M., Gueorguieva, R., Krumholz, H. M., Trivedi, M. H., Krystal, J. H., & McCarthy, G. (2017). Reevaluating the efficacy and predictability of antidepressant treatments: a symptom clustering approach. *JAMA psychiatry*, 74(4), 370-378. doi:[10.1001/jamapsychiatry.2017.0025](https://doi.org/10.1001/jamapsychiatry.2017.0025)

Chekroud, A., Krystal, J. H., Gueorguieva, R., & Chandra, A. (2017). *WO2017210502A1*. World Intellectual Property Organization. Retrieved from <https://patents.google.com/patent/WO2017210502A1/en>

Chekroud, A. M., Zotti, R. J., Shehzad, Z., Gueorguieva, R., Johnson, M. K., Trivedi, M. H., ... Corlett, P. R. (2016). Cross-trial prediction of treatment outcome in depression: a machine learning approach. *The Lancet. Psychiatry*, 3(3), 243–250.

Coutanche, M. N. & Hallion, L. S. (2020). Machine learning for clinical psychology and clinical neuroscience. In A. G. C. Wright and M. N. Hallquist (Eds.), *The Cambridge Handbook of Research Methods in Clinical Psychology*. Cambridge, UK: Cambridge University Press.

Coutanche, M. N., & Thompson-Schill, S. L. (2012). The advantage of brief fMRI acquisition runs for multi-voxel pattern detection across runs. *Neuroimage*, *61*(4), 1113-1119. <https://doi.org/10.1016/j.neuroimage.2012.03.076>

Cuartas Arias, J. M. (2017). Big data for use in psychological research. *International Journal of Psychological Research*, *10*(1), 6-7.

D'Alfonso, S. (2020). AI in mental health. *Current Opinion in Psychology*, *36*, 112-117. <https://doi.org/10.1016/j.copsyc.2020.04.005>

Doorn, A., Kamsteeg, C., Bate, J., & Aafjes, M. (2020). A scoping review of machine learning in psychotherapy research. *Psychotherapy Research*, *31*, 92 - 116. <https://doi.org/10.1080/10503307.2020.1808729>.

Dwyer, D. B., Falkai, P., & Koutsouleris, N. (2018). Machine learning approaches for clinical psychology and psychiatry. *Annual review of clinical psychology*, *14*, 91-118.

Elhai, J. D., & Montag, C. (2020). The compatibility of theoretical frameworks with machine learning analyses in psychological research. *Current Opinion in Psychology*, *36*, 83-88. <https://doi.org/10.1016/j.copsyc.2020.05.002>

Emel, G.G. & Taşkın, Ç. (2005). Veri madenciliğinde karar ağaçları ve bir satış analizi uygulaması. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 6(2), 221-239.

Emre, İ. E., Cumhuri, T. A. Ş. & Çiğdem, E. R. O. L. (2021). Psikiyatride Makine Öğrenmesi Yöntemlerinin Kullanımı. *Psikiyatride Güncel Yaklaşımlar*, 13(2), 332-353. <https://doi.org/10.18863/pgy.779987>

Eugene, A. R., Masiak, J., & Eugene, B. (2018). Predicting lithium treatment response in bipolar patients using gender-specific gene expression biomarkers and machine learning. *F1000Research*, 7. doi: [10.12688/f1000research.14451.3](https://doi.org/10.12688/f1000research.14451.3)

Gerrig, R. J., & Zimbardo, P. G. (2012). *Psikolojiye Giriş: Psikoloji ve Yaşam*. (G. Sart, Çev.). Ankara: Nobel Akademik Yayıncılık.

Grömping, U. (2009). Variable importance assessment in regression: linear regression versus random forest. *The American Statistician*, 63(4), 308-319. <https://doi.org/10.1198/tast.2009.08199>

Halisdemir, N., Filiz, E., Güral, Y., & Gürcan, M. Doğanın İnsan Yaşamı Üzerine Etkilerinin Karar Ağacı Algoritmaları İle İncelenmesi. *Batı Karadeniz Tıp Dergisi*, 5(3), 444-451. <https://doi.org/10.29058/mjwbs.895853>

Han, J., Kamber, M., & Pei, J. (2011). *Data mining: Concepts and techniques*. Elsevier.

Hasanpour, H., Meibodi, R. G., Navi, K., & Asadi, S. (2018). Novel ensemble method for the prediction of response to fluvoxamine treatment of obsessive-compulsive disorder. *Neuropsychiatric Disease and Treatment*, *14*, 2027-2038.

Hu, Y. J., Ku, T. H., Jan, R. H., Wang, K., Tseng, Y. C., & Yang, S. F. (2012). Decision tree-based learning to predict patient controlled analgesia consumption and readjustment. *BMC medical informatics and decision making*, *12*(1), 1-15.

Jack, R. E., Crivelli, C., & Wheatley, T. (2018). Data-driven methods to diversify knowledge of human psychology. *Trends in cognitive sciences*, *22*(1), 1-5.

Jacobucci, R., Littlefield, A. K., Millner, A. J., Kleiman, E., & Steinley, D. (2020). Pairing machine learning and clinical psychology: How you evaluate predictive performance matters. *Psychological Methods*, *25*(1), 1–12. <https://doi.org/10.1037/met0000249>

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An introduction to statistical learning with applications in R*. New York: Springer.

Jiang, T., Gradus, J. L., & Rosellini, A. J. (2020). Supervised machine learning: a brief primer. *Behavior Therapy*, *51*(5), 675-687.

<https://doi.org/10.1016/j.beth.2020.05.002>

Joyner, M. J., & Paneth, N. (2019). Promises, promises, and precision medicine. *The Journal of clinical investigation*, *129*(3), 946-948.

Karaöz, B. & Gürsoy, U. T. (2018). Adaptif Öğrenme Sözlüğü Temelli Duygu Analiz Algoritması Önerisi. *Bilişim Teknolojileri Dergisi*, *11*(3), 245-253.  
<https://doi.org/10.17671/gazibtd.342419>

Karstoft, K. I., Galatzer-Levy, I. R., Statnikov, A., Li, Z., & Shalev, A. Y. (2015). Bridging a translational gap: using machine learning to improve the prediction of PTSD. *BMC psychiatry*, *15*(1), 1-7.

Kelly, J., Gooding, P., Pratt, D., Ainsworth, J., Welford, M., & Tarrier, N. (2012). Intelligent real-time therapy: Harnessing the power of machine learning to optimise the delivery of momentary cognitive-behavioural interventions. *Journal of Mental Health*, *21*(4), 404-414.  
<https://doi.org/10.3109/09638237.2011.638001>

Koutsouleris, N., Kahn, R. S., Chekroud, A. M., Leucht, S., Falkai, P., Wobrock, T., ... & Hasan, A. (2016). Multisite prediction of 4-week and 52-week treatment outcomes in patients with first-episode psychosis: a machine learning approach. *The Lancet Psychiatry*, *3*(10), 935-946.

Liem, C., Langer, M., Demetriou, A., Hiemstra, A. M., Sukma Wicaksana, A., Born, M. P., & König, C. J. (2018). Psychology meets machine learning: Interdisciplinary perspectives on algorithmic job candidate screening.

In *Explainable and interpretable models in computer vision and machine learning* (pp. 197-253). Springer, Cham.

Mandinach, E. B. (2012). A perfect time for data use: Using data-driven decision making to inform practice. *Educational Psychologist*, 47(2), 71-85. <https://doi.org/10.1080/00461520.2012.667064>

Mendonça, E. A. (2004). Clinical decision support systems: perspectives in dentistry. *Journal of dental education*, 68(6), 589-597. <https://doi.org/10.1002/j.0022-0337.2004.68.6.tb03777.x>

Montbriand, M. J. (1995). Decision tree model describing alternate health care choices made by oncology patients. *Cancer Nursing*, 18, 104–117.

Na, K. S., Cho, S. E., & Cho, S. J. (2021). Machine learning-based discrimination of panic disorder from other anxiety disorders. *Journal of Affective Disorders*, 278, 1-4. <https://doi.org/10.1016/j.jad.2020.09.027>

Naghiyev, M., Taş, İ. Ç., & Tekin, Y. (2023). Bağımlılık Yapıcı Madde Kullanımı Riskinin Makine Öğrenmesi Yöntemleriyle Tahmini. *Abant Sağlık Bilimleri ve Teknolojileri Dergisi*, 3(2), 1-13.

Özer, E., & Temeltürk, R. D. (2023). Okuma bozukluğunun göz izleme ve makine öğrenmesiyle belirlenmesi: Alanyazının gözden geçirilmesi. *Klinik Psikoloji Dergisi*, 7(2), 258-270.

Öztoprak, H., Toycan, M., Alp, Y. K., Arıkan, O., Doğutepe, E., & Karakaş, S. (2017, May). Machine-based learning system: Classification of ADHD and non-ADHD

participants. In *2017 25th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE. DOI: [10.1109/SIU.2017.7960704](https://doi.org/10.1109/SIU.2017.7960704)

Perlis, R. H., Brown, E., Baker, R. W., & Nierenberg, A. A. (2006). Clinical features of bipolar depression versus major depressive disorder in large multicenter trials. *The American Journal of Psychiatry*, *163*(2), 225–231. <https://doi.org/10.1176/appi.ajp.163.2.225>

Sağbaşı, E. A., Korukoğlu, S., & Ballı, S. (2021). Akıllı Telefon Verileri ve Makine Öğrenmesi Yöntemleri Kullanılarak Stres Tespiti Çalışmaları Üzerine Bir Literatür Araştırması. *Mühendislik Bilimleri ve Tasarım Dergisi*, *9*(3), 1030-1038. <https://doi.org/10.21923/jesd.790845>

Shatte, A. B., Hutchinson, D. M., & Teague, S. J. (2019). Machine learning in mental health: a scoping review of methods and applications. *Psychological medicine*, *49*(9), 1426-1448. <https://doi.org/10.1017/S0033291719000151>

Stroup, T. S., Gerhard, T., Crystal, S., Huang, C., Tan, Z., Wall, M. M., ... & Olfson, M. (2019). Comparative effectiveness of adjunctive psychotropic medications in patients with schizophrenia. *JAMA psychiatry*, *76*(5), 508-515.

Sivakumar, M., Parthasarathy, S., & Padmapriya, T. (2024). Trade-off between training and testing ratio in machine learning for medical image processing. *PeerJ Computer Science*, *10*, e2245. <https://doi.org/10.7717/peerj-cs.2245>

Taş, E. & Kamaşak, M. E. (2019, September). Prediction Of Personality Traits From Videos By Using Machine Learning Algorithms. In *2019 4th International Conference on Computer Science and Engineering (UBMK)* (pp. 778-782). **DOI:** [10.1109/UBMK.2019.8907179](https://doi.org/10.1109/UBMK.2019.8907179)

Topaloğlu M. & Sur, H. (2015). Sarılık semptomlarında yanlış teşhisi azaltmak için karar ağacı uygulaması. *Nobel Medicus*, 11(3): 64-73.

Türk, B. & Tali H.H. (2020). Makine Öğrenmesi Yöntemleri ile Somatizasyon ve Duygusal Öz Farkındalık Üzerinden Şiddetin Tahmini. *Adli Tıp Bülteni*, 25(2): 99-105.

Usta, M. B., & Karabekiroğlu, K. (2022). Nörogelişimsel Bozukluklarda Yapay Zekâ ve Makine Öğrenmesi. *Türkiye Klinikleri Child Psychiatry-Special Topics*, 8(1), 122-126.

Valero, S., Daigre, C., Rodríguez-Cintas, L., Barral, C., Gomà-i-Freixanet, M., Ferrer, M., ... & Roncero, C. (2014). Neuroticism and impulsivity: their hierarchical organization in the personality characterization of drug-dependent patients from a decision tree learning perspective. *Comprehensive Psychiatry*, 55(5), 1227-1233. <https://doi.org/10.1016/j.comppsy.2014.03.021>

Vidyasagar, M. (2015). Identifying predictive features in drug response using machine learning: opportunities and challenges. *Annual review of pharmacology and toxicology*, 55, 15-34. <https://doi.org/10.1146/annurev-pharmtox-010814-124502>

Yarđı, V., & Postalcıođlu, S. (2021). EEG iřareti kullanılarak bađımlılıđa yatkınlıđın makine renmesi teknikleri ile analizi. *El-Cezeri*, 8(1), 142-154. <https://doi.org/10.31202/ecjse.787726>

Yarkoni, T. & Westfall, J. (2017). Choosing prediction over explanation in psychology: Lessons from machine learning. *Perspectives on Psychological Science*, 12(6), 1100-1122. <https://doi.org/10.1177/1745691617693393>

Yntem, M. K. & Kemal, A. (2019). Otomatik Dřüncelere Makine renme Yntemlerinin Uygulanması ile Aleksitimi Dzeyinin Tahmini. *Psikiyatride Gncel Yaklařımlar*, 11, 64-78. <https://doi.org/10.18863/pgy.554788>