

Makine Öğrenmesi ile Üniversite Öğrencilerinde Depresyonun Tahmini: Akademik, Psikolojik ve Demografik Faktörlerin Rolü

Hasan Aykut Karaboğa¹

Abdülkadir Keskin²

Özet

Depresyon, üniversite öğrencileri arasında yaygın olarak görülen ve akademik başarıyı, sosyal ilişkileri ve genel yaşam kalitesini olumsuz etkileyen bir ruh sağlığı sorunudur. Bu çalışmada, farklı makine öğrenmesi algoritmalarını kullanarak üniversite öğrencilerinin depresyon durumunu tahmin etmek amaçlanmıştır. Araştırmada bağımlı değişken olarak depresyon durumu (var/yok) ele alınmış ve bağımsız değişkenler olarak yaş, cinsiyet, not ortalaması, uyku süresi, meslek, akademik baskı, çalışma memnuniyeti, iş memnuniyeti, beslenme alışkanlıkları gibi değişkenler kullanılmıştır.

Çalışmada, Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (Neural Networks), Lojistik Regresyon, k-En Yakın Komşu (kNN) ve Gradient Boosting algoritmaları kullanılarak depresyon tahmini gerçekleştirilmiştir. Sonuçlar, Lojistik Regresyon ve SVM modellerinin en iyi genelleme yeteneğine sahip olduğunu göstermektedir. Öte yandan, Yapay Sinir Ağları ve Gradient Boosting algoritmalarının eğitim verisinde yüksek performans sergilediği ancak test verisinde aşırı öğrenme (overfitting) nedeniyle başarının düştüğü belirlenmiştir. Bu çalışma, makine öğrenmesi yöntemleriyle üniversite öğrencilerinde depresyon tahminine yönelik yeni bir bakış açısı sunmakta ve öğrenci ruh sağlığını iyileştirmeye yönelik veri odaklı yaklaşımlar geliştirilmesine katkıda bulunmaktadır.

- 1 Dr. Öğr. Üyesi, Amasya Üniversitesi, Eğitim Fakültesi, Eğitim Bilimleri Bölümü, h.aykut.karaboga@amasya.edu.tr, ORCID: 0000-0001-8877-3267
- 2 Arş. Gör. Dr., İstanbul Medeniyet Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, İstatistik Bölümü, abdulcadir.keskin@medeniyet.edu.tr, ORCID: 0000-0002-4795-1028

1. Giriş

Gençlerde depresyon hayat kalitesini düşüren ve gençlerin gelecek planlarını alt üst edebilen bir sorundur. Okul hayatları devam eden bireylerde akademik başarıları düşmekte, kaygı düzeyleri artmakta ve yaşam tarzları olan genel alışkanlıkları nedeniyle sosyal alışkanlıkları ve genel refah düzeyleri depresyon nedeniyle bozulmaktadır (Astafeva vd., 2024; Gillooly vd., 2024). Özellikle eğitimlerinde ilerlemeler kaydetmiş ve çalışma hayatına yakın olan üniversite öğrencileri arasında depresyon daha yaygın bir ruh sağlığı sorunudur. Üniversite döneminde genç yetişkinlik çağında bulunan öğrenciler hayatlarının en önemli döneminde akademik ve sosyal baskılarla karşı karşıya kalmaktadır. Bu da akademik olarak tatmin olmamalarına ve baskı hissetmelerine neden olmaktadır (Mirhosseini vd., 2021). Hissedilen baskılar, öğrencilerin psikolojik sağlıkları üzerinde olumsuz etkilere yol açabilmektedir. Bu durum depresyonun üniversite öğrencileri arasında daha yaygın bir sorun olarak ortaya çıkmasına neden olmaktadır (İbrahim vd., 2013; Trigueros vd., 2020). Problemi çözmek veya önerilerde bulunabilmek için depresyona katkıda bulunan faktörleri belirlemek ve erken müdahale stratejileri tasarlamak bu alandaki en değerli çalışmalardandır.

Depresyonu etkin biçimde tahmin ederek doğru zamanda müdahalelerde bulunmak, belirtilen bu problemlerin erkenden çözüme kavuşturulmasını sağlayabilecektir. Her ne kadar kişilerle birebir görüşülerek ya da çeşitli anketler yoluyla depresyonu tespit etmeye çalışan geleneksel yöntemler hala etkin olsa da erişilebilirlik sorunları ve yanıt yanlılığı gibi sorunlar nedeniyle sınırlı başarı gösterebilmektedir (İbrahim vd., 2013; Pedrelli vd., 2015). Yapay zekâ ve veri bilimindeki gelişmeler makine öğrenmesi yöntemlerinin depresyon riski taşıyan kişileri belirlemek veya depresyondaki kişileri tahmin etmek için güçlü altyapı sağlamaktadır. Ele alınan büyük ölçekli veri kümelerinden yararlanarak sosyolojik, akademik, psikolojik ve demografik faktörler yardımıyla makine öğrenmesi modelleri zihinsel sağlık sorunları yaşayan öğrenciler için erken teşhis ve kişiselleştirilmiş yardım önerileri sağlayabilir (Shatte vd., 2019; He, 2024).

Makine öğrenmesi, klasik yöntemlerle ulaşılması ve analizi zor olan sosyal medya verileri, yapılan anketlerin sonuçları ve kişilerin sanal âlemde bıraktıkları dijital izler gibi çeşitli kaynaklardan elde edilen verileri işleyerek bireylerin ruhsal durumunu ve varsa depresyon varlığını tahmin etme potansiyeline sahiptir. Dijital veriler, anketlerle desteklenerek depresyonun semptomlarının zaman içindeki seyrini izlemeye de olanak tanır. Bu bağlamda, makine öğrenmesi algoritmaları, bireylerin ruh halini etkileyen çok sayıda faktörü dikkate alarak daha doğru ve zamanında tahminler yapabilmektedir

(Liu vd., 2024). Makine öğrenmesi algoritmalarının kişilerin depresyon tahmininde klasik değerlendirme yöntemleri ile bütünleştirilmesi, özneliği en aza indirirken öngörü doğruluğunu artıran daha veri odaklı bir yaklaşıma olanak tanır. Böylece, depresyonun erken teşhis edilmesi ve bireylere uygun müdahalelerin uygulanması sürecinde makine öğrenmesi uygulamaları, ruh sağlığı profesyonellerine önemli derecede yardımcı olabilir (He, 2024).

Bu çalışmada yaş, cinsiyet, akademik performans, uyku süresi, iş ve akademik baskılar, çalışma memnuniyeti, beslenme alışkanlıkları ve coğrafi konum gibi bir dizi bağımsız değişkene dayalı olarak üniversite öğrencilerinde depresyon durumunu tahmin etmek için makine öğrenmesi yöntemlerinin kullanılabilirliğini araştırmaktadır. Çalışmanın öncelikli amacı öğrencileri depresyonda veya değil şeklinde ikili sınıflandırmada farklı makine öğrenmesi algoritmalarının etkinliğini değerlendirmektir. Bir diğer amaç ise model performans değerlendirmesinin yanında öğrenci depresyonunu arttıran faktörleri belirleyerek üniversitelerin ve politika yapıcılarının öğrencilere yönelik baskıları azaltıcı müdahaleler geliştirmesine yardımcı olabilmektir.

Çalışma 5 bölümden oluşmaktadır: ikinci bölümde öğrenciler arasındaki depresyon tahmininde kullanılan makine öğrenmesi uygulamalarıyla ilgili literatür incelemesi sunulmuştur. Üçüncü bölümde veri ön işleme, özellik seçimi ve model değerlendirmesi için kullanılan metodolojik yaklaşımlar ayrıntılı olarak verilmiştir. Dördüncü bölümde makine öğrenmesi modellerinin karşılaştırmalı analiz sonuçları gösterilmiştir. Son olarak, beşinci bölümde elde edilen temel bulguları, çalışmanın sınırlılıkları ve gelecekteki araştırma önerileri tartışılmıştır.

2. Literatür İncelemesi

Depresyon, dünya genelinde hemen hemen 280 milyon kişiyi etkileyen zorlu bir ruhsal hastalıktır (Dünya Sağlık Örgütü, 2021). Genel olarak her yaştan insanda görülebilse de üniversite öğrencileri arasında depresyon oranları finansal ve akademik baskılar ve sosyal beklentiler nedeniyle çok daha yüksektir (Hunt ve Eisenberg, 2010; Assari, 2018). Üniversite öğrencilerinin %34,5'i stres belirtileri gösterirken %23,6 ile %18,4 arası öğrenciler kaygı ve depresyon belirtileri göstermektedir. Bu durum genel olarak aile ilişkileri, üniversiteye uyum zorluğu ve bağımsız problem çözme becerisinin yeterliliği gibi faktörlerle ilişkili olduğu belirtilmiştir (Ramón-Arbués vd., 2020).

Çalışmalar, yaşın, cinsiyetin, uyku düzenlerinin, akademik stresin ve iş-yaşam dengesinin öğrencilerin ruh sağlığını önemli ölçüde etkilediğini göstermiştir (Beiter vd., 2015). Ayrıca, öğrencilerin geleceğe dair kaygıları, iş

yaşamına hazırlık süreçleri ve ailelerin onlara karşı tutumları gibi faktörler de depresyon belirtileri üzerinde etkili olmaktadır (Ozen vd., 2010). Ergenlikten genç yetişkinlik dönemine geçen üniversiteli bireyler bulundukları farklı ortamlardan ötürü sosyal, ekonomik, biyolojik ve psikolojik faktörlerin değişimi nedeniyle ruhsal hastalıklara karşı duyarlılık yaşarlar (Eisenberg vd., 2013). Bu durum üniversite öğrencilerinin genel nüfusa göre daha yüksek bir depresyon riski taşıdığını göstermektedir (İbrahim vd., 2013).

Ruhsal sorunlarda önemli sosyo-demografik faktörlerin yaş, cinsiyet ve ekonomik durum olduğu söylenebilir. Genç öğrenciler bulundukları ortamlara uyum sağlama konusunda yaşadıkları zorluklar nedeniyle daha büyük duygusal sıkıntılarla karşı karşıya kalırlar (Bayram ve Bilgel, 2008). Depresyon yaygınlığında kadınlar erkeklerden daha yüksek oranda depresif semptomlar göstermektedir (Piccinelli ve Wilkinson, 2000; Ceyhan ve Ceyhan, 2011). Biyolojik, sosyal ve kültürel faktörler bu farklılığa katkıda bulunur; çünkü kadınlar genellikle duygusal sıkıntıyı ifade etme ve yardım arama olasılıkları daha yüksekken, erkekler toplumsal beklentiler nedeniyle semptomları eksik bildirebilir (Hyde vd., 2008). Bu yönüyle erkek öğrenciler, kadın öğrencilere göre daha yüksek yalnızlık ve depresyon seviyelerine sahiptir. Çünkü depresyonun nedeniyle yalnızlaşan öğrencilerin sosyal etkileşimleri olumsuz etkilenmekte ve destek alabilecekleri sosyal destek ağları zayıflayacaktır (Ceyhan ve Ceyhan, 2011).

Öğrencinin yaşadığı bölgenin çevresel, sosyoekonomik ve kültürel faktörleri de ruh sağlığını olumsuz yönde etkileyebilir. Çalışmalar, kentsel öğrencilerin genellikle daha yüksek akademik stres ve rekabet yaşadığını, kırsal öğrencilerin ise sosyal izolasyon ve daha az ruh sağlığı kaynağıyla mücadele edebileceğini göstermektedir. Ayrıca üniversite öğrencilerinin karşılaştığı ekonomik zorlukların ruh sağlığı üzerindeki olumsuz etkileri ortaya konulmaktadır (Lund vd., 2010; Shao vd., 2020).

Akademik performans genellikle zihinsel refahla ilişkilendirilir ve hem yüksek hem de düşük başarı gösterenler depresyon riski altındadır. Düşük not ortalamalarına sahip öğrenciler öz saygı sorunları ve akademik baskı yaşayabilirken, yüksek başarı gösterenler mükemmeliyetçilik ve tükenmişlikle mücadele edebilir. Derse uyum ve başarı kaygıları ile mücadele öğrencilerin ruh sağlığı üzerinde önemli derecede olumsuz etki göstermektedir. (Ozen vd., 2009). Araştırmalar, akademik başarısızlık yaşayan öğrencilerin akranlarına kıyasla depresif semptomlar geliştirme olasılığının iki kat daha fazla olduğunu göstermektedir (Andrews ve Wilding, 2004).

İş ve akademik hayatı dengelemek, özellikle ders yüküyle birlikte yarı zamanlı işleri de idare eden üniversite öğrencileri için önemli bir stres kaynağı

olabilir (Arastaman vd., 2020). İş baskısı artan stres ve azalan akademik performansla ilişkilidir ve bu da bitkinliğe ve zihinsel sağlıkta düşüşe yol açar (Glozier, 2002). Benzer şekilde, genellikle sıkı teslim tarihleri, performans beklentileri ve başarısızlık korkusundan kaynaklanan akademik baskı, öğrenci depresyonunun önde gelen bir öngörücüsüdür (Arslan vd., 2009).

Bir öğrencinin çalışmalarından ve işinden duyduğu memnuniyet düzeyi, zihinsel sağlığını önemli ölçüde etkiler. Akademik yaşamdan duyulan memnuniyetsizlik strese ve depresif semptomlara yol açabilir (Hysaj vd., 2018). Aynı şekilde, çalışan öğrenciler arasında iş memnuniyetsizliği stresi artırabilir, genel yaşam memnuniyetini azaltabilir ve depresyon riskini artırabilir (Arastaman vd., 2020; Méndez vd., 2020; Satuf vd., 2018).

Uyku yoksunluğu, öğrenciler arasında ruh sağlığı sorunlarına en sık katkıda bulunan etkenlerden biridir. Araştırmalar, gecede altı saatten az uyuyan öğrencilerin depresyon ve anksiyete semptomları yaşama olasılığının daha yüksek olduğunu göstermektedir (Lund vd., 2010). Kötü uyku kalitesi, düzensiz uyku saatleri ve yatmadan önce aşırı ekran süresi de artan depresif semptomlarla bağlantılıdır (Baglioni vd., 2011; Musliner vd., 2016; Zhang vd., 2018). Beslenme koşulları da öğrencilerin ruh sağlığında kritik bir rol oynamaktadır. Bilinçsizce tüketilen işlenmiş gıdalar ve şeker açısından zengin diyetler daha yüksek depresyon oranlarıyla ilişkilendirilir (Jacka vd., 2010; Özenoğlu, 2018). Öğün atlama veya aşırı kafein ve fast food tüketme gibi sağlıksız beslenme alışkanlıkları olan öğrenciler, ruh sağlığı sorunları açısından daha büyük risk altındadır (O'Neil vd., 2014; Tokpunar, 2024).

Tüm bu değişkenler ve durumlar depresyon ve ruh sağlığı sorunları ile ilgili çalışmaları daha kritik ve daha karmaşık hale getirmektedir. Bu gibi durumlarda önleyici müdahaleler yapabilmek için tahmin yeteneği güçlü modellere ihtiyaç duyulmaktadır. Yapay zeka alanındaki gelişmeler, makine öğrenme teknikleri kullanılarak ruh sağlığı bozuklukları için güçlü tahmin modellerinin geliştirilmesini kolaylaştırmıştır (Thieme vd., 2020; Ahmed vd., 2020). Ruh sağlığı çalışmalarında makine öğrenmesi uygulamaları, metin analizi (Baminiwatta, 2022), sosyal medya aktivitesi (Villegas ve Martinez, 2022), giyilebilir cihazlar (Williamson vd., 2024) ve anket tabanlı veri kümeleri (Ferrari vd., 2018; Karam vd., 2014) gibi yaklaşımlarla kullanılabilir (D'Ambrosio vd., 2023).

Sınıflandırma görevleri için en basit ancak etkili yöntemlerden biri olan lojistik regresyon, yorumlanabilir olması ve verimliliği nedeniyle depresyon tahmini için kullanılabilir. Ayrıca SVM modelleri, yüksek boyutlu verilerdeki sağlamlıkları nedeniyle depresyon tespitinde kullanılabilir. Araştırmalar, anket ve klinik veriler üzerinde eğitilen SVM modellerinin yüksek doğruluk

oranı ile çalışabildiğini göstermektedir (Shatte vd., 2019). Çok katmanlı algılayıcılar (MLP) gibi modeller de yüksek doğruluk sunmasına rağmen kara kutu sayılan yöntemlerdir (Feng vd., 2019). Ayrıca k-En Yakın Komşu (kNN) ve Gradient Boosting algoritmaları da klasik makine öğrenmesi yöntemlerinin etkin yaklaşımlarındandır. Bu yöntemler ile depresyonda olan ve olmayan bireylerin tahmin başarıları irdelenerek ruh sağlığı araştırmalarında bu yöntemlerin kullanılabilirliği araştırılacaktır.

3. Materyal ve Metot

Bu çalışmada kullanılan veri seti, Kaggle platformundan alınmış olup 1500 bireyin demografik, akademik ve psikolojik özelliklerini içermektedir (Shamim, 2024). Veri setinin bağımlı değişkeni “Depresyon” olup, bireylerin depresyon durumlarını (1 = depresyon var, 0 = depresyon yok) olarak sınıflandırmaktadır. Depresyon değişkeninin dağılımına bakıldığında, bireylerin %58,6’sının depresyon belirtileri gösterdiği gözlemlenmiştir. Bu durum, veri setinde depresyonda olan bireylerin, olmayanlara kıyasla daha fazla olduğunu göstermektedir.

Bağımsız değişkenler bireylerin demografik, akademik, psikolojik ve sosyal özelliklerini kapsamaktadır. Yaş (Age) değişkeni sürekli bir değişken olup, veri setindeki bireylerin yaş ortalaması 25,74 olarak hesaplanmıştır. Bu değer, örneklemdaki bireylerin çoğunlukla genç yetişkinlerden oluştuğunu göstermektedir. Akademik baskı (Academic Pressure) değişkeninin ortalama değeri 3,16 olup, bu da bireylerin akademik sorumluluklarını orta düzeyde stres verici olarak algıladıklarını göstermektedir. Benzer şekilde, bireylerin finansal stres (Financial Stress) düzeyi ortalama 3,10 olup, birçok bireyin finansal sıkıntılar yaşadığını göstermektedir.

Akademik başarı açısından değerlendirildiğinde, bireylerin Genel Not Ortalaması (CGPA) 7,69 olup, en düşük not 5,06 ve en yüksek not 10’dur. Çalışma süresi açısından bakıldığında, bireylerin günlük ortalama çalışma süresi 7,14 saat olarak belirlenmiştir. Ancak bireyler arasında geniş bir dağılım bulunmaktadır; bazı bireyler hiç ders çalışmazken, bazıları günde 12 saate kadar çalışmaktadır. Çalışma memnuniyeti (Study Satisfaction) ortalama 2,91 olup, bireylerin akademik çalışmalarından tam anlamıyla tatmin olmadıklarını göstermektedir.

Psikolojik faktörler arasında bireylerin uyku düzenleri önemli bir yer tutmaktadır. Uyku süresi (Sleep Duration) kategorik bir değişken olup, bireylerin %29,4’ü günde 5 saatten az uyuduğunu belirtmiştir. Bu da akademik ve psikolojik baskıların uyku süresini kısaltabileceğini düşündürmektedir. Beslenme alışkanlıkları (Dietary Habits) açısından bakıldığında, bireylerin

%36,4'ü sağlıklı beslendiğini belirtmiştir. Ruh sağlığıyla ilişkili bir diğer önemli değişken olan intihar düşüncesi (Suicidal Thoughts) bireylerin %63,1'inde gözlemlenmiştir. Bu oldukça yüksek bir oran olup, bireylerin ruhsal iyi oluş düzeylerinin düşük olabileceğini göstermektedir.

Aile geçmişi de bireylerin ruhsal sağlığını etkileyebilecek önemli faktörlerden biridir. Ailede ruhsal hastalık geçmişi (Family History of Mental Illness) değişkeni incelendiğinde, bireylerin %51,1'inin ailesinde herhangi bir ruhsal hastalık geçmişi olmadığını belirtmesi dikkat çekicidir. Bu durum, depresyonun sadece genetik faktörlerden değil, çevresel ve akademik faktörlerden de etkilenebileceğini göstermektedir.

Tablo 1. Tanımlayıcı İstatistikler

Değişken	Türü	Ortalama	Std Sapma	Min	Medyan	Max	Mod	En Sık Kategori (%)
Yaş (Age)	Sayısal	25,740	4,880	18	25	42	-	-
Akademik Baskı (Academic Pressure)	Sayısal	3,160	1,410	1	3	5	-	-
Genel Not Ortalaması (CGPA)	Sayısal	7,690	1,460	5,060	7,800	10	-	-
Çalışma Memnuniyeti (Study Satisfaction)	Sayısal	2,910	1,350	1	3	5	-	-
İş Memnuniyeti (Job Satisfaction)	Sayısal	0,002	0,077	0	0	3	-	-
Çalışma/Saatleri (Work/Study Hours)	Sayısal	7,140	3,740	0	8	12	-	-
Finansal Stres (Financial Stress)	Sayısal	3,100	1,460	1	3	5	-	-
Depresyon (Bağımlı Değişken)	Kategorik	-	-	0	1	1	1	58,60%
Cinsiyet (Gender)	Kategorik	-	-	-	-	-	Erkek	54,20%
Uyku Süresi (Sleep Duration)	Kategorik	-	-	-	-	-	5 saatten az	29,40%
Beslenme Alışkanlıkları (Dietary Habits)	Kategorik	-	-	-	-	-	Sağlıksız	36,40%
İntihar Düşüncesi (Suicidal Thoughts)	Kategorik	-	-	-	-	-	Evet	63,10%
Ailede Ruhsal Hastalık Geçmişi (Family History of Mental Illness)	Kategorik	-	-	-	-	-	Hayır	51,10%

Bu çalışmada, öğrencilerin depresyon durumunu tahmin etmek amacıyla denetimli makine öğrenmesi algoritmaları uygulanmıştır. Veri seti, bağımlı değişken olarak depresyon durumunu (1 = depresyon var, 0 = depresyon yok) ve bağımsız değişkenler olarak bireylerin demografik, akademik,

Tablo 2. Kullanılan algoritmaların özellikleri

Algoritma	Varsayılan Özellikler/Parametreler	Notlar
SVM	- Kernel: RBF	Veri ölçeklendirmesi önemlidir.
	- C: 1,0	
	- Gamma: Otomatik (1/özellik sayısı)	
Yapay Sinir Ağları (MLP)	- Gizli Katman Sayısı: 1	Overfitting durumunda düzenleme (dropout, erken durdurma vb.) gerekebilir.
	- Nöron Sayısı: Otomatik belirlenir	
	- Öğrenme Hızı: 0,3	
	- Momentum: 0,2	
	- Epoch: 500	
Lojistik Regresyon	- Regularizasyon: L2	Basit ve yorumlanabilir; lineer sınıflandırmada etkilidir.
	- C: 1,0	
	- Çözümleyici: LBFGS	
	- Maksimum Iterasyon: 100	
k-En Yakın Komşu	- k (Komşu Sayısı): 5	Özellik ölçeklendirmesi özellikle önemlidir.
	- Mesafe Ölçütü: Öklid	
	-Ağırlıklandırma: Eşit ağırlık	
Gradient Boosting	- Estimator Sayısı: 100	Hiperparametre ayarları performansı büyük ölçüde etkileyebilir.
	- Öğrenme Hızı: 0,1	
	- Maksimum Derinlik: 3	

Modeli tahmin etmek için kullanılan beş algoritmaya ait genel özellikler Tablo 2’ de gösterilmektedir. Bu tabloda, her bir algoritmanın varsayılan ayarları ve temel parametreleri detaylandırılmıştır. Örneğin, SVM algoritması için kullanılan RBF çekirdek, C parametresi ve gamma değeri, verinin doğrusal olmayan yapısını yakalayabilmek adına özenle seçilmiştir. Ancak bu ayarların veri ölçeklendirmesi gibi ön işleme adımlarıyla birlikte optimize edilmesi gerekmektedir. Neural Network (MLP) modelinde ise tek katmanlı gizli yapı, öğrenme hızı ve momentum gibi parametreler modelin hızlı öğrenmesini sağlarken, eğitim sürecinde aşırı öğrenme (overfitting) riskine karşı dikkatle izlenmelidir. Lojistik Regresyon, L2 regularizasyonu ve LBFGS çözümleyicisiyle basit fakat güçlü bir yaklaşım sunarak, özellikle lineer sınıflandırmada net ve yorumlanabilir sonuçlar elde edilmesine olanak tanır. k-En Yakın Komşu algoritması, belirlenen komşu sayısı ve kullanılan mesafe ölçütü ile örnekler arasındaki benzerlikleri değerlendirirken, özelliklerin uygun şekilde ölçeklendirilmesinin önemine vurgu yapar. Son olarak, Gradient Boosting algoritması, sınırlı derinlik ve belirli bir öğrenme hızı ile çoklu zayıf tahminicileri birleştirerek güçlü bir sınıflandırma performansı hedefler; fakat hiperparametre ayarlarının modelin genelleme kabiliyeti üzerinde doğrudan etkisi olduğu unutulmamalıdır. Bu özelliklerin her biri, modelin tahmin performansını, öğrenme hızı, genelleme yeteneğini ve aşırı

öğrenme riskini belirlemede önemli rol oynar. Dolayısıyla, her algoritmanın özellikleri ve varsayılan ayarları, uygulanan veri setine ve probleme göre dikkatlice değerlendirilmelidir.

3.1. Makine Öğrenmesi Algoritmalarının Performansı

Bu çalışmada, model performansını değerlendirmek için beş temel ölçüt kullanılmıştır: sınıflandırma doğruluğu (CA), F1 skoru, duyarlılık (recall), kesinlik (precision) ve eğri altındaki alan (AUC). AUC, ROC eğrisi ile ilişkili olup, modelin duyarlılık ve özgüllük dengesini ne kadar iyi sağladığını gösterir. Değerin 1'e yaklaşması, modelin yüksek performans sergilediğini gösterir. Sınıflandırma doğruluğu (CA), doğru tahmin edilen örneklerin toplam örnek sayısına oranını verir. Ancak, veri setinde dengesizlik olması durumunda tek başına yeterli bir değerlendirme ölçütü olmayabilir. F1 skoru, duyarlılık ve kesinlik arasındaki dengeyi sağlayarak modelin genel başarısını ölçer. Duyarlılık (recall), modelin pozitif sınıfları doğru şekilde tespit etme oranını ifade ederken, kesinlik (precision), modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten pozitif olduğunu gösterir.

AUC (Area Under the Curve): AUC, ROC (Receiver Operating Characteristic) eğrisinin altında kalan alandır ve modelin sınıflandırma performansını ölçer. AUC değeri 0 ile 1 arasında değişir. 1'e yakın değerler, iyi bir sınıflandırma performansını gösterir. AUC, ROC eğrisinin altındaki alanı hesaplar. Matematiksel olarak belirli bir formülü yoktur, ancak ROC eğrisinin hesaplanmasıyla elde edilir.

CA (Correct Accuracy) / Doğru Doğruluk: Doğru doğruluk, doğru sınıflandırılan örneklerin toplam örnek sayısına oranıdır. Modelin genel başarısını gösterir ve aşağıda gösterildiği şekilde hesaplanır:

$$CA = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

F1-Score: F1 skoru, modelin hem doğruluk (precision) hem de duyarlılık (recall) dengesi üzerinde yoğunlaşan bir metriktir. F1, precision ve recall'un harmonik ortalamasıdır. Özellikle sınıflar arasındaki dengesizlik durumunda kullanılır. Aşağıdaki şekilde ifade edilmektedir:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2)$$

Precision (Kesinlik): Kesinlik, modelin pozitif tahminlerinden kaç tanesinin doğru olduğunu gösterir. Kesinlik, modelin pozitif olarak tahmin ettiği örneklerin pozitif olanlara oranıdır ve aşağıdaki şekilde hesaplanır:

$$\text{Precision} = \frac{FP}{FP+TN} \quad (3)$$

Recall (Duyarlılık): Duyarlılık, gerçek pozitiflerin kaç tanesinin doğru bir şekilde tespit edildiğini gösterir. Hassasiyet, gerçek pozitif örneklerin toplam pozitif örneklere oranıdır ve aşağıdaki şekilde hesaplanır:

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

Bu formüller, sınıflandırma modelinin performansını ölçmek için kullanılır ve her metrik modelin farklı yönlerini değerlendirmeye yardımcı olur. **AUC**, ROC eğrisinin altında kalan alanı ölçerken, **CA** sınıflandırma doğruluğunu gösterir. **F1 skoru**, kesinlik (precision) ve duyarlılık (recall) arasındaki dengeyi sağlar. Kesinlik ve duyarlılık, modelin pozitif ve negatif tahminlerindeki doğruluğunu değerlendirir.

4. Bulgular

Elde edilen sonuçlar değerlendirildiğinde, Yapay Sinir Ağları ve Gradient Boosting modellerinin eğitim verisi üzerinde oldukça yüksek başarı gösterdiği görülmektedir. Yapay Sinir Ağlarının eğitim setindeki AUC değeri 0,974, doğruluk oranı 0,919 ve F1 skoru 0,932 iken Gradient Boosting için bu değerler sırasıyla 0,973, 0,913 ve 0,926 olarak hesaplanmıştır. Ancak test verisi üzerinde bu başarıların belirgin şekilde düştüğü gözlemlenmiştir. Yapay Sinir Ağlarının test AUC değeri 0,866'ya, doğruluk oranı 0,787'ye gerilemiştir. Benzer şekilde, Gradient Boosting'in test setindeki AUC değeri 0,871 olarak hesaplanmıştır. Bu durum, bu modellerin eğitim verisine fazla uyum sağladığını ve yeni verilere genelleme yapmada zorluk yaşadığını (overfitting) göstermektedir. Elde edilen sonuçlar Tablo 3'te gösterilmektedir.

Tablo 3. Algoritmaların Eğitim ve Test Aşamalarının Performans Ölçümleri

	Train					Test				
	AUC	CA	F1	Precision	Recall	AUC	CA	F1	Precision	Recall
SVM	0,927	0,843	0,867	0,856	0,877	0,885	0,796	0,836	0,799	0,877
Neural Network	0,974	0,919	0,932	0,917	0,946	0,866	0,787	0,826	0,803	0,851
Logistic Regression	0,927	0,846	0,869	0,862	0,876	0,890	0,793	0,832	0,805	0,862
k-NN	0,935	0,870	0,890	0,870	0,912	0,823	0,762	0,810	0,773	0,851
Gradient Boosting	0,973	0,913	0,926	0,925	0,926	0,871	0,784	0,823	0,806	0,840

Öte yandan, SVM ve lojistik regresyon modelleri hem eğitim hem de test verisi üzerinde daha dengeli sonuçlar vermiştir. Lojistik regresyonun test setindeki AUC değeri 0,890, doğruluk oranı 0,793 ve F1 skoru 0,832 olarak hesaplanmıştır. SVM modeli de test setinde AUC 0,885, doğruluk oranı 0,796 ve F1 skoru 0,836 ile istikrarlı bir performans sergilemiştir. Bu sonuçlar, lojistik regresyon ve SVM'nin aşırı öğrenmeye daha az eğilimli olduğunu ve daha iyi genelleme sağladığını göstermektedir.


Yapay sinir ağları modeli, eğitim setinde AUC 0,974, doğruluk oranı 0,919 ve F1 skoru 0,932 gibi oldukça yüksek başarı göstermiştir. Kesinlik (0,917) ve duyarlılık (0,946) değerleri de oldukça güçlüdür. Ancak test setindeki başarısı belirgin şekilde düşmüştür (AUC 0,866, doğruluk 0,787, F1 skoru 0,826). Bu düşüş, modelin eğitim verisine fazla uyum sağladığını ve genelleme gücünün zayıfladığını göstermektedir. SVM modeli, eğitim verisi üzerinde AUC 0,927, doğruluk 0,843 ve F1 skoru 0,867 ile dengeli bir performans sergilemiştir. Test setinde de bu başarı büyük oranda korunmuştur (AUC 0,885, doğruluk 0,796 ve F1 skoru 0,836). Eğitim ve test skorları arasındaki farkın diğer modellere kıyasla daha az olması, SVM'nin genelleme yeteneğinin güçlü olduğunu göstermektedir. Lojistik regresyon modeli, eğitim setinde AUC 0,927, doğruluk 0,846 ve F1 skoru 0,869 ile tutarlı bir başarı sergilemiştir. Test setindeki sonuçları da benzer şekilde AUC 0,890, doğruluk 0,793 ve F1 skoru 0,832 olarak hesaplanmıştır. Modelin eğitim ve test skorları arasındaki farkın minimal olması, aşırı öğrenme problemine karşı dayanıklı olduğunu ve istikrarlı bir model sunduğunu göstermektedir.

kNN modeli eğitim setinde AUC 0,935, doğruluk 0,8695 ve F1 skoru 0,890 ile güçlü bir performans göstermiştir. Ancak test setinde başarısı belirgin şekilde düşmüştür (AUC 0,823, doğruluk 0,762 ve F1 skoru 0,810). Bu fark, kNN'nin aşırı öğrenme eğiliminde olduğunu ve genelleme yeteneğinin düşük olduğunu göstermektedir. Gradient Boosting, eğitim verisi üzerinde AUC 0,973, doğruluk 0,913 ve F1 skoru 0,926 gibi oldukça yüksek başarılar sergilemiştir. Ancak test setindeki değerlerin düşmesi (AUC 0,871, doğruluk 0,784 ve F1 skoru 0,823), modelin aşırı öğrenme eğiliminde olduğunu ortaya koymaktadır.

Model performansları genel olarak, lojistik regresyon ve SVM'nin en dengeli sonuçları verdiği görülmektedir. Lojistik regresyon modeli, test setinde en yüksek AUC değerine (0,890) sahip olup, doğruluk ve F1 skorları açısından da güçlüdür. SVM de benzer şekilde başarılı bir genelleme göstermektedir. Öte yandan, Yapay Sinir Ağları ve Gradient Boosting gibi karmaşık modeller eğitim setinde çok yüksek doğruluk sergilemelerine rağmen, test setinde bu başarıyı sürdürememiştir. Bu durum, bu modellerin

eğitim verisine aşırı uyum sağladığını ve yeni veriler üzerinde performans kaybı yaşadığını göstermektedir. kNN modeli ise test setinde en düşük doğruluk oranına sahip olup, genelleme gücü açısından diğer modellere kıyasla daha zayıf bir performans göstermiştir.

Aşağıdaki şekilde tüm değişkenlere ait ROC eğrisini göstermektedir. ROC eğrileri incelendiğinde, modellerin pozitif sınıflandırmayı ne kadar iyi ayırt edebildiği görsel olarak ortaya konmaktadır. Eğrilerin altında kalan alan (AUC) değerleri incelendiğinde, özellikle SVM ve Lojistik Regresyon modellerinin test verisinde 0,885 ve 0,890 seviyelerinde AUC elde etmesi, bu iki modelin diğerlerine göre daha iyi genelleme yaptığını göstermektedir. Diğer taraftan, Yapay Sinir Ağı ve Gradient Boosting eğitim verisinde oldukça yüksek AUC değerlerine ulaşmış olsa da test aşamasında daha düşük değerlere gerilemesi, potansiyel bir aşırı öğrenme belirtisidir. Dolayısıyla, ROC eğrilerinin genel şekli ve AUC değerleri birlikte değerlendirildiğinde hem doğru sınıflandırma oranının hem de yanlış pozitif oranının dengeli bir şekilde optimize edildiğini görmek, model seçimi ve hiperparametre iyileştirmesi açısından önemli ipuçları sunmaktadır.



Şekil 2. Algoritmaların ROC eğrileri

Sonuç olarak, en iyi genelleme yeteneğini gösteren modeller lojistik regresyon ve SVM olmuştur. Eğer aşırı öğrenme azaltılabilirse Yapay Sinir Ağları ve Gradient Boosting gibi güçlü algoritmalar daha başarılı sonuçlar

üretebilecektir. Ancak mevcut durumda Lojistik regresyon ve SVM, en istikrarlı ve güvenilir sonuçları sağlamaktadır.

5. Tartışma ve Sonuç

Bu çalışmada ele alınan çeşitli demografik, akademik, sosyolojik ve psikolojik faktörleri göz önünde bulundurarak makine öğrenmesi yöntemleri yardımıyla üniversite öğrencilerinin depresyonda olup olmadığının tahmini amaçlanmıştır. Kullanılan yöntemlerden Lojistik Regresyon ve Destek Vektör Makineleri (SVM) en iyi genellemeyi sağlamıştır. Yapay Sinir Ağları ve Gradient Boosting yöntemleri ise eğitim verilerinde yüksek doğruluk sergilemesine rağmen test verilerinde daha düşük performansla aşırı uyum eğilimleri göstermiştir. Bu bulgular, makine öğreniminin zihinsel sağlık bozuklukları için erken tespit ve müdahale stratejilerini geliştirebileceğini gösteren önceki araştırmaları desteklemektedir.

Elde edilen bulgular incelendiğinde akademik stres, uyku süresi, iş tatmini ve beslenme alışkanlıkları gibi değişkenlerin üniversite öğrencilerinde depresyon tahmininde kullanılabilecek önemli değişkenler olduğunu göstermektedir. Bu bulgular, akademik baskının ve yaşam tarzı ile ilgili faktörlerin öğrenci ruh sağlığı üzerindeki etkisini vurgulayan önceki araştırmalarla uyum göstermektedir (Andrews ve Wilding, 2004; Bayram ve Bilgel, 2008; Eisenberg vd., 2007). Özellikle akademik stres üniversite öğrencileri açısından depresyonu tetikleyen önemli bir risk faktörüdür. Yüksek sosyal beklentiler, başarısızlık korkusu ve iş yükü baskıları depresyonun tetikleyicilerindendir (Hunt ve Eisenberg, 2010; Arslan vd., 2009). Daha yüksek akademik baskıya maruz kalan öğrencilerin depresif semptomlar yaşama olasılığı daha yüksektir (Mirhosseini vd., 2021). Uykusuzluk da bilişsel işlevi, duygusal düzenlemeyi ve fiziksel sağlığı olumsuz etkileyerek öğrencileri depresyona daha yatkın hale getirir (Lund vd., 2010; Baglioni vd., 2011; Astafeva vd., 2024). Araştırmalar öğrenim görürken yarı zamanlı çalışan ve düşük iş tatmini olan öğrencilerin depresyon yaşama olasılığının daha yüksek olduğunu göstermektedir (Glozier, 1998; Assari, 2018; Satuf vd., 2018). Ayrıca beslenmenin ruh sağlığındaki üzerindeki rolü giderek daha fazla ilgi görmektedir. Bu da beslenme şekillerinin depresyon üzerinde etkili olabileceğini göstermektedir (Jacka vd., 2010; O'Neil vd., 2014; Tokpunar, 2024).

Bu çalışmanın sonuçları depresyon tahmininde makine öğrenmesi modellerinin kullanılabilme potansiyelini ve son otuz yılda ruh sağlığı değerlendirmesinde artan ilginin desteklendiğini göstermiştir (Baminiwatta, 2022). Bazı çalışmalar davranışsal, fizyolojik ve demografik verileri

birleştirirken, depresyonu ve diğer psikolojik bozuklukları yüksek doğrulukla tespit etmek için makine öğrenimi tekniklerini kullanmıştır (Karam vd., 2014; Liu vd., 2024).

Depresyon ile ilişkili biyolojik, psikolojik ve sosyal faktörlerin birbiri ile karmaşık etkileşiminden tahmin sonuçları etkilenmektedir (Hyde vd., 2008; Musliner vd., 2016). Bu karmaşık yapının bir temsilcisi olarak alınan bu çalışmada elde edilen bulgular tüm üniversite öğrencilerini tam olarak temsil etmeyebilir. Daha çeşitli veri kümeleri ile model performansını ve sonuçların genelleştirilebilirliği test edilebilir. Kesitsel bir veri yapısının kullanıldığı bu çalışmanın sonuçlarının iyileştirilmesi için panel veriler ile depresyon risk faktörlerinin zaman içinde nasıl değiştiği anlaşılabilir. Değişkenler açık erişimli belirli özellikleri içeren bir veri setidir. Bu veri setinde yer almayan ancak depresyon üzerinde etkin olabilecek, karmaşıklığı arttırabilecek çeşitli değişkenler yer alabilir. Bu değişkenlerin de araştırılarak ilerleyen çalışmalarda daha kapsamlı değişken seçimi yapılabilir.

Yapay Sinir Ağları ve Gradient Boosting gibi bazı modeller verilerle aşırı uyum sergileyerek düzenleme ve hiperparametre ayarlaması gibi daha fazla optimizasyon tekniğine ihtiyaç olduğunu göstermiştir. Depresyon tahmininde makine öğrenmesi kullanımı, veri gizliliği, modellerdeki olası önyargılar ve yanlış sınıflandırma riskiyle ilgili etik endişeler de mevcuttur. Gelecekteki araştırmalarda karar alma sürecinde şeffaflık ve hesap verebilirlik konularında iyileştirmeler yapıp farklı yapay zeka tekniklerini değerlendirme süreçlerine entegre ederek bu zorluklar aşılabılır.

Sonuçlar, makine öğrenmesinden yararlanarak ruh sağlığı profesyonelleri ve eğitimcilerin öğrencilerin refahını desteklemek için veri odaklı stratejiler geliştirebileceğini göstermiştir. Makine öğrenmesi teknikleri yapay zekâ alanındaki gelişmelerle birlikte gelişmeye devam ettikçe kişiselleştirilmiş müdahaleler ve ruhsal sorunların erken tespit edilmesi için büyük potansiyel içermektedir. Böylece depresyon gibi diğer psikolojik rahatsızlıkların da erken tanı ve tespitinin yanında şeffaf şekilde yönetilebileceği de anlaşılmıştır.

Kaynakça

- Ahmed, Z., Mohamed, K., Zeeshan, S., & Dong, X. (2020). Artificial intelligence with multi-functional machine learning platform development for better healthcare and precision medicine. *Database*, 2020, baaa010.
- Andrews, B., & Wilding, J. M. (2004). The relation of depression and anxiety to life-stress and achievement in students. *British journal of psychology*, 95(4), 509-521.
- Arastaman, G., Çetin, O. U., Arslan, S. Y., & Kerimoğlu, P. N. G. (2020). Eğitim yönetimi alanında doktora öğrencisi olmak: Lisansüstü öğrencilerin bakış açısından fenomenolojik bir inceleme. *Eğitimde Nitel Araştırmalar Dergisi*, 8(4), 1323-1346.
- Arslan, G., Ayranci, U., Unsal, A., & Arslantas, D. (2009). Prevalence of depression, its correlates among students, and its effect on health-related quality of life in a Turkish university. *Upsala journal of medical sciences*, 114(3), 170-177.
- Assari, S. (2018). Multiplicative effects of social and psychological risk factors on college students' suicidal behaviors. *Brain Sciences*, 8(5), 91.
- Astafeva, D., Konstantinov, D., Syunyakov, T., Kolsanov, A., Davydkin, I., Pavlichenko, A., ... & Smirnova, D. (2024). Depression and Anxiety Among COVID-19 Patients Admitted to a "Red Zone" Intensive Care Unit: Do the Factors of Self-Awareness of Somatic Health, Anxiety, and Depression Contribute to the Course of Sars-Cov-2 Infection?. *Psychiatria Danubina*, 36(suppl 2), 103-114.
- Baglioni, C., Battagliese, G., Feige, B., Spiegelhalder, K., Nissen, C., Voderholzer, U., ... & Riemann, D. (2011). Insomnia as a predictor of depression: a meta-analytic evaluation of longitudinal epidemiological studies. *Journal of affective disorders*, 135(1-3), 10-19.
- Baminiwatta, A. (2022). Global trends of machine learning applications in psychiatric research over 30 years: A bibliometric analysis. *Asian Journal of Psychiatry*, 69, 102986.
- Bayram, N., & Bilgel, N. (2008). The prevalence and socio-demographic correlations of depression, anxiety and stress among a group of university students. *Social psychiatry and psychiatric epidemiology*, 43, 667-672.
- Beiter, R., Nash, R., McCrady, M., Rhoades, D., Linscomb, M., Clarahan, M., & Sammut, S. (2015). The prevalence and correlates of depression, anxiety, and stress in a sample of college students. *Journal of affective disorders*, 173, 90-96.
- Ceyhan, E., & Ceyhan, A. (2011). Loneliness and Depression Levels of Students Using a University Counseling Center. *Eğitim ve Bilim-Education and Science*, 36(160).

- D'Ambrosio, E., Abrol, A., & Pigoni, A. (2023). Machine learning and psychosis: Diagnosis, prognosis and treatment. *Frontiers in Psychiatry*, 14, 1133072.
- Eisenberg, D., Gollust, S. E., Golberstein, E., & Hefner, J. L. (2007). Prevalence and correlates of depression, anxiety, and suicidality among university students. *American journal of orthopsychiatry*, 77(4), 534-542.
- Feng, L., Xu, S., Wang, F., Liu, S., & Qiao, H. (2019). Rough extreme learning machine: A new classification method based on uncertainty measure. *Neurocomputing*, 325, 269-282.
- Ferrari, C., Macis, A., Rossi, R., & Cameletti, M. (2018). Multivariate statistical techniques to manage multiple data in psychology. *Open Access Journal of Behavioural Science & Psychology*, 1(2).
- Gillooly, A., Dagnan, D., Hastings, R., Hatton, C., McMeekin, N., Baines, S., ... & Jahoda, A. (2024). Behavioural activation for depressive symptoms in adults with severe to profound intellectual disabilities: Modelling and initial feasibility study. *Journal of Applied Research in Intellectual Disabilities*, 37(2), e13197.
- Glozier, N. (1998). Workplace effects of the stigmatization of depression. *Journal of occupational and environmental medicine*, 40(9), 793-800.
- He, Y. M. (2024). Online Assessment of Mental Health Micromedia for College Students Incorporating Bayesian Network Algorithm. *International Journal of Maritime Engineering*, 1(1), 83-96.
- Hunt, J., & Eisenberg, D. (2010). Mental health problems and help-seeking behavior among college students. *Journal of adolescent health*, 46(1), 3-10.
- Hyde, J. S., Mezulis, A. H., & Abramson, L. Y. (2008). The ABCs of depression: integrating affective, biological, and cognitive models to explain the emergence of the gender difference in depression. *Psychological review*, 115(2), 291.
- Hysaj, A., Elkhoully, A., Qureshi, A. W., & Abdulaziz, N. (2018, December). Analysis of engineering students' academic satisfaction in a culturally diverse university. In *2018 IEEE international conference on teaching, assessment, and learning for engineering (TALE)* (pp. 755-760). IEEE.
- Ibrahim, A. K., Kelly, S. J., Adams, C. E., & Glazebrook, C. (2013). A systematic review of studies of depression prevalence in university students. *Journal of psychiatric research*, 47(3), 391-400.
- Jacka, F. N., Kremer, P. J., Leslie, E. R., Berk, M., Patton, G. C., Toumbourou, J. W., & Williams, J. W. (2010). Associations between diet quality and depressed mood in adolescents: results from the Australian Healthy Neighbourhoods Study. *Australian & New Zealand journal of psychiatry*, 44(5), 435-442.

- Karam, Z. N., Provost, E. M., Singh, S., Montgomery, J., Archer, C., Harrington, G., & Mcinnis, M. G. (2014, May). Ecologically valid long-term mood monitoring of individuals with bipolar disorder using speech. In *2014 IEEE international conference on acoustics, speech and signal processing (ICASSP)* (pp. 4858-4862). IEEE.
- Liu, H., Li, C., Zhang, X., Zhang, F., Wang, W., Ma, F., ... & Zhang, X. (2024, March). Depression detection via capsule networks with contrastive learning. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 38, No. 20, pp. 22231-22239).
- Lund, H. G., Reider, B. D., Whiting, A. B., & Prichard, J. R. (2010). Sleep patterns and predictors of disturbed sleep in a large population of college students. *Journal of adolescent health, 46*(2), 124-132.
- Méndez, I., Martínez-Ramón, J. P., Ruiz-Esteban, C., & García-Fernández, J. M. (2020). Latent profiles of burnout, self-esteem and depressive symptomatology among teachers. *International Journal of Environmental Research and Public Health, 17*(18), 6760.
- Mirhosseini, S., Bazghaleh, M., Basirinezhad, M. H., Abbasi, A., & Ebrahimi, H. (2021). The relationship between depression and academic satisfaction in medical science students. *The Journal of Mental Health Training, Education and Practice, 16*(2), 99-111.
- Musliner, K. L., Munk-Olsen, T., Eaton, W. W., & Zandi, P. P. (2016). Heterogeneity in long-term trajectories of depressive symptoms: Patterns, predictors and outcomes. *Journal of affective disorders, 192*, 199-211.
- O'neil, A., Quirk, S. E., Housden, S., Brennan, S. L., Williams, L. J., Pasco, J. A., ... & Jacka, F. N. (2014). Relationship between diet and mental health in children and adolescents: a systematic review. *American journal of public health, 104*(10), e31-e42.
- Özenoğlu, A. (2018). Duygu durumu, besin ve beslenme ilişkisi. *Acıbadem Üniversitesi Sağlık Bilimleri Dergisi, 9*(4), 357-365.
- Pedrelli, P., Nyer, M., Yeung, A., Zulauf, C., & Wilens, T. (2015). College students: mental health problems and treatment considerations. *Academic psychiatry, 39*(5), 503-511.
- Piccinelli, M., & Wilkinson, G. (2000). Gender differences in depression: Critical review. *The British Journal of Psychiatry, 177*(6), 486-492.
- Ramón-Arbués, E., Gea-Caballero, V., Granada-López, J. M., Juárez-Vela, R., Pellicer-García, B., & Antón-Solanas, I. (2020). The prevalence of depression, anxiety and stress and their associated factors in college students. *International journal of environmental research and public health, 17*(19), 7001.

- Sakin Ozen, N., Ercan, I., Irgil, E., & Sigirli, D. (2010). Anxiety prevalence and affecting factors among university students. *Asia Pacific Journal of Public Health*, 22(1), 127-133.
- Satuf, C., Monteiro, S., Pereira, H., Esgalhado, G., Marina Afonso, R., & Loureiro, M. (2018). The protective effect of job satisfaction in health, happiness, well-being and self-esteem. *International journal of occupational safety and ergonomics*, 24(2), 181-189.
- Shamim, A. (2024, July 19). Student Depression Dataset. Kaggle. <https://www.kaggle.com/datasets/adilshamim8/student-depression-dataset>
- Shao, R., He, P., Ling, B., Tan, L., Xu, L., Hou, Y., ... & Yang, Y. (2020). Prevalence of depression and anxiety and correlations between depression, anxiety, family functioning, social support and coping styles among Chinese medical students. *BMC psychology*, 8, 1-19.
- 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.
- Thieme, A., Belgrave, D., & Doherty, G. (2020). Machine learning in mental health: A systematic review of the HCI literature to support the development of effective and implementable ML systems. *ACM Transactions on Computer-Human Interaction (TOCHI)*, 27(5), 1-53.
- Tokpunar, M. (2024). Sürdürülebilir Diyet Modellerinin Depresyon ile İlişkisi: Derleme. *Genel Sağlık Bilimleri Dergisi*, 6(2), 346-363.
- Trigueros, R., Padilla, A., Aguilar-Parra, J. M., Lirola, M. J., García-Luengo, A. V., Rocamora-Pérez, P., & López-Liria, R. (2020). The influence of teachers on motivation and academic stress and their effect on the learning strategies of university students. *International journal of environmental research and public health*, 17(23), 9089.
- Villegas, C. A., & Martinez, M. J. (2022). Lessons from Harvey: Improving traditional damage estimates with social media sourced damage estimates. *Cities*, 121, 103500.
- Williamson, G., Trompeter, N., Murphy, D., Saba, S., Pedersen, E. R., Davis, J. P., & Leightley, D. (2024). Using passive and active data to predict posttraumatic stress disorder symptoms and cannabis use in recently discharged UK veterans: A protocol for the MAVERICK feasibility study. *Mental Health Science*, 2(3), e75.
- World Health Organization (WHO). (2021). Depression and other common mental disorders: Global health estimates. Retrieved from https://www.who.int/mental_health/management/depression/en/
- Zhang, Y., Peters, A., & Chen, G. (2018). Perceived stress mediates the associations between sleep quality and symptoms of anxiety and depression

among college nursing students. *International journal of nursing education scholarship*, 15(1), 20170020.